

UNIVERSIDAD COMPLUTENSE DE MADRID

FACULTAD DE GEOGRAFÍA E HISTORIA



## **TESIS DOCTORAL**

Modelos de localización-asignación de servicios en Sistemas de Información Geográfica: incorporando el dinamismo de la distribución de la demanda y del funcionamiento de las redes

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

Onel Antonio Pérez Fernández

DIRECTOR

Juan Carlos García Palomares

**UNIVERSIDAD COMPLUTENSE DE MADRID**  
**FACULTAD DE GEOGRAFÍA E HISTORIA**



**TESIS DOCTORAL**

**Modelos de localización-asignación de servicios en  
Sistemas de Información Geográfica: incorporando el  
dinamismo de la distribución de la demanda y del  
funcionamiento de las redes**

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

**Onel Antonio Pérez Fernández**

Director

**Juan Carlos García Palomares**

**Madrid, 2023**

**UNIVERSIDAD COMPLUTENSE DE MADRID**  
**FACULTAD DE GEOGRAFÍA E HISTORIA**  
**PROGRAMA DE DOCTORADO EN GEOGRAFÍA**



**TESIS DOCTORAL**

Modelos de localización-asignación de servicios en Sistemas de Información Geográfica: incorporando el dinamismo de la distribución de la demanda y del funcionamiento de las redes

**MEMORIA PARA OPTAR AL GRADO DE DOCTOR**

**PRESENTADA POR**

Onel Antonio Pérez Fernández

**DIRECTOR**

Juan Carlos García Palomares

# AGRADECIMIENTO

Durante el programa de doctorado en Geografía, he recibido el apoyo de muchas instituciones y personas. Esta sección se dividirá en dos apartados. Comenzaré agradeciendo a todas aquellas instituciones que permitieron presentarme como candidato al programa de doctorado. En primer lugar, agradezco a la Secretaría Nacional de Ciencia y Tecnología (Senacyt) y al Instituto de Formación y Desarrollo de Recursos Humanos (IFARHU) de la República de Panamá. Ellos, a través de sus programas de becas, me eligieron para realizar estudios de doctorado fuera de las fronteras panameñas. Dicha beca, constituyó el soporte financiero que me permitió sufragar los diversos gastos que implica estudiar en el extranjero.

Asimismo, estoy sumamente agradecido con el Ministerio de Educación y la Universidad de Panamá por su colaboración al permitir que me ausentara de mi trabajo mientras realizaba el doctorado en Madrid, España. En esta última institución agradezco a mis colegas del Departamento de Geografía del Centro Regional Universitario de Veraguas, por hacerse responsables de mi trabajo el tiempo que estuve ausente. Un agradecimiento especial al director César García y al rector Eduardo Flores por concederme la licencia para realizar mis estudios.

Un enorme agradecimiento a la Universidad Complutense de Madrid, en concreto al Departamento de Geografía, por aceptarme como estudiante en el programa de doctorado. Dentro del Departamento agradezco de forma particular al grupo de investigación de Transporte e Infraestructuras y Territorio, tGIS, y en especial a su director el Dr. Javier Gutiérrez Puebla, que me recibió con los brazos abiertos una vez que puse mi primer pie en Madrid. Por otro lado, quiero agradecer expresamente al Ayuntamiento de Madrid y a la empresa Muving por facilitarme algunos de los datos utilizados en el desarrollo de la tesis. Como parte de la administración del Ayuntamiento de Madrid, un inmenso agradecimiento al Servicio de Atención Municipal Urgencias y Rescate Protección Civil (SAMUR-PC).

Comienzo este segundo bloque de agradecimientos mencionando a todas las personas que me apoyaron sin reservas para continuar con mi proyecto de investigación. Quiero agradecer a los compañeros que compartieron durante los años de mi doctorado. Un agradecimiento especial a Borja Moya Gómez por colaborar con

la confección de la red TomTom, a Marcin Stępniaak por su apoyo con la red de datos GTFS y a Daniela Arias por facilitarme los datos de la empresa de motos compartidas Muving. También, estoy muy agradecido con Carolina Barros por sacar tiempo de su apretada agenda para apoyarme cuando las cosas se pusieron difíciles. Igualmente, agradezco a Julio Gómez todo el respaldo ofrecido antes y durante mi etapa en el programa de doctorado. A todos los demás compañeros, Joaquín Arjona, Sofía Mendoza, Chema Fernández, Rubén Talavera, Rocío Campaña y Enrique por compartir durante los almuerzos y cafés. Ha sido una pena que muchas de las reuniones de intercambio se hayan suspendido por la pandemia.

Para la siguiente persona son pocas las palabras que puedo dedicar. Me refiero a mi director, el Dr. Juan Carlos García Palomares, a quien agradezco profundamente su orientación, comprensión, asistencia amable y apoyo durante mis estudios de doctorado. Por sus detalladas revisiones y constructivos comentarios. Porque siempre sacaba tiempo de su apretada agenda para atender mis consultas y dudas.

Quiero dar las gracias a los miembros de mi familia de los que he estado distanciado durante los últimos años. Agradecer a mis padres, hermanos, sobrinos, suegros y cuñados por su apoyo incondicional. Agradezco en particular a mi suegro Secundino González su tiempo dedicado a la lectura de mi tesis. Al compadre Oscar Ortiz por su ayuda desinteresada desde el primer momento en que inicié esta aventura académica.

Por último, estas palabras son para mi esposa, Yenizeth González, que siempre ha estado pendiente de mis necesidades en Panamá y España. Para ella, el mayor agradecimiento del mundo. En todo momento me animó a seguir adelante en este viaje, en especial cuando me desanimaba a continuar. A esta mujer le estaré infinitamente agradecido.

Para terminar, quiero expresar mi gratitud a los diferentes proyectos en los que se han incluido mis artículos. Así pues, agradecer al Programa de Actividades de I+D entre Grupos de Investigación de la Comunidad de Madrid en Ciencias Sociales y Humanidades (H2019/HUM-5761) entidad financiadora del proyecto INNJOBMAD-CM y al Ministerio de Ciencia e Innovación (Plan Nacional I+D+i) entidad financiadora del proyecto PID2020-116656RB-I00 (NEWGEOMOB): MCIN/AEI/

10.13039/501100011033.

# INDICE DE CONTENIDO

<b>AGRADECIMIENTO</b> .....	<b>iv</b>
<b>INDICE DE CONTENIDO</b> .....	<b>vi</b>
<b>INDICE DE FIGURAS</b> .....	<b>ix</b>
<b>INDICE DE TABLAS</b> .....	<b>xiv</b>
<b>RESUMEN</b> .....	<b>xvii</b>
<b>ABSTRACT</b> .....	<b>xx</b>
<b>1 INTRODUCCIÓN</b> .....	<b>1</b>
<b>1.1 Interés y oportunidad de la investigación</b> .....	<b>2</b>
<b>1.2 Preguntas de investigación</b> .....	<b>10</b>
<b>1.3 Objetivos</b> .....	<b>14</b>
1.3.1 Objetivo general .....	14
1.3.2 Objetivos específicos .....	14
<b>1.4 Estructura de la tesis</b> .....	<b>20</b>
<b>1.5 Publicaciones y Congresos</b> .....	<b>22</b>
<b>2 MARCO TEÓRICO</b> .....	<b>24</b>
<b>2.1 Modelos de localización-asignación de equipamientos o servicios</b> .....	<b>25</b>
2.1.1 Evolución de los modelos .....	27
2.1.2 Datos de entrada de los modelos de localización-asignación óptima de servicios .....	40
2.1.3 Clasificación y objetivo de las instalaciones a localizar .....	47
2.1.4 Tipos de soluciones en los MLA .....	56
2.1.5 Campos de aplicación de los MLA en entornos SIG .....	73
<b>2.2 Big Data y nuevas fuentes de datos</b> .....	<b>77</b>
2.2.1 Datos masivos geolocalizados .....	79
2.2.2 Fortalezas e inconvenientes del uso del Big Data .....	84
2.2.3 Nuevas redes de transporte .....	85
2.2.4 Nuevas formas de localización de la demanda .....	91
<b>2.3 Oportunidades de investigación</b> .....	<b>110</b>
<b>3 AREA DE ESTUDIO, DATOS Y METODOLOGÍA</b> .....	<b>120</b>
<b>3.1 Área de estudio</b> .....	<b>121</b>

3.1.1	Área metropolitana de Madrid .....	121
3.1.2	Municipio de Madrid.....	124
3.1.3	La Almendra central.....	126
<b>3.2</b>	<b>Fuentes de datos utilizadas .....</b>	<b>127</b>
3.2.1	Datos sobre la oferta de equipamientos .....	128
3.2.2	Datos sobre la distribución de la demanda .....	129
3.2.3	Redes de transporte .....	130
<b>3.3</b>	<b>Metodología.....</b>	<b>136</b>
3.3.1	Limpieza y agregación de datos .....	136
3.3.2	Construcción de las redes digitales de transporte.....	139
3.3.3	Modelos de localización dinámicos en entornos SIG.....	143
3.3.4	Análisis y visualización de los datos.....	147
<b>4</b>	<b>APLICACIONES PRÁCTICAS .....</b>	<b>150</b>
<b>4.1</b>	<b>Modelos con demanda fija en el tiempo y redes dinámicas de transporte público y privado: aplicaciones a la localización de servicios sanitarios y equipamientos comerciales.....</b>	<b>151</b>
4.1.1	Análisis de la asignación de la demanda a hospitales y hospitales de referencia.....	152
4.1.2	Metodología utilizada para el desarrollo del modelo de hospitales y hospitales de referencia .....	157
4.1.3	Resultados de los modelos.....	163
4.1.4	Aplicación a la localización de centros comerciales.....	191
4.1.5	Metodología utilizada para el desarrollo del modelo de evaluación de la localización de centros comerciales .....	193
4.1.6	Resultados .....	195
<b>4.2</b>	<b>Modelos con demanda variable en el tiempo y redes estáticas: aplicación a la localización de estacionamientos para servicios de movilidad compartida.....</b>	<b>227</b>
4.2.1	Descripción del caso de estudio: Aparcamientos para servicios de motos eléctricas en Madrid	227
4.2.2	Metodología utilizada para encontrar los aparcamientos de las motos compartidas....	231
4.2.3	Resultados .....	236
<b>4.3</b>	<b>Modelos con demanda variable en el tiempo y redes dinámicas de transporte privado: aplicaciones a la localización de estaciones para un servicio de emergencias médicas .....</b>	<b>253</b>
4.3.1	Caso de estudio: localización de estaciones del Servicio de Asistencia Municipal de Urgencia y Rescate de Madrid (SAMUR-PC).....	253
4.3.2	Metodología para la ubicación de las estaciones SAMUR-PC .....	257
4.3.3	Resultados .....	261

<b>5</b>	<b>CONCLUSIONES</b> .....	<b>297</b>
5.1	Aportaciones en relación con las preguntas de investigación planteadas al inicio.....	298
5.2	Conclusiones en relación con la pregunta principal de la tesis.....	310
5.3	Futuras líneas de investigación.....	312
	<b>REFERENCIAS</b> .....	<b>315</b>
	<b>ANEXOS</b> .....	<b>361</b>

# INDICE DE FIGURAS

Figura 1. Relación entre objetivos y preguntas de investigación .....	19
Figura 2. Evolución de los MLA .....	27
Figura 3. Taxonomía alternativa de modelos de localización .....	57
Figura 4. Temática de los estudios de MLA aplicados en entornos SIG .....	76
Figura 5. Resultados de búsqueda en Scopus y Web of Science .....	81
Figura 6. Análisis foda del Big Data.....	84
Figura 7. Usuarios de diferentes redes sociales (octubre 2022).....	104
Figura 8. Zonificación del área metropolitana.....	122
Figura 9. Densidad de habitantes y renta a nivel de municipio.....	123
Figura 10. Municipio de Madrid y áreas de salud .....	124
Figura 11. Población de los Distritos del municipio de Madrid 2020.....	125
Figura 12. Distritos de la Almendra Central de Madrid .....	127
Figura 13. Frecuencias de viajes en un día laborable (jueves) en la red GTFS .....	132
Figura 14. Frecuencias de viajes en fin de semana (sábado) en la red GTFS.....	133
Figura 15. Congestión del tráfico en día laborable (los jueves) según TomTom ....	134
Figura 16. Congestión del tráfico en fin de semana (sábados) según TomTom.....	135
Figura 17. Estructura de las tablas del fichero GTFS utilizado .....	140
Figura 18. Herramientas utilizadas para construir la red GTFS.....	141
Figura 19. Metodología general de los diversos modelos desarrollados .....	146
Figura 20. Herramientas utilizadas en el desarrollo de la tesis.....	149
Figura 21. Metodología para el desarrollo del modelo de hospitales y hospitales de referencia.....	158
Figura 22. Hospitales públicos, hospitales de referencia y áreas de salud .....	159
Figura 23. Localización de hospitales y densidad de población a partir de los centroides de secciones censales .....	160

Figura 24. Población cubierta por hospital según red GTFS .....	165
Figura 25. Población cubierta por hospital según red TomTom .....	166
Figura 26. Población cubierta y porcentaje de cambio entre jueves y sábado según hospitales .....	168
Figura 27. Población cubierta por los hospitales asignados a las áreas de salud (GTFS).....	170
Figura 28. Población cubierta por área de salud (GTFS) .....	171
Figura 29. Población cubierta por los hospitales asignados a las áreas de salud (TomTom).....	173
Figura 30. Población cubierta por área de salud (TomTom) .....	174
Figura 31. Porcentaje de cambio los jueves (GTFS) respecto a las 8 horas según hospitales de referencia .....	176
Figura 32. Porcentaje de cambio los sábados (GTFS) respecto a las 8 horas según hospitales de referencia .....	177
Figura 33. Porcentaje de cambio respecto a las 8 horas por área de salud (GTFS).....	178
Figura 34. Porcentaje de cambio los jueves (TomTom) respecto a las 8 horas según hospitales de referencia .....	179
Figura 35. Porcentaje de cambio los sábados (TomTom) respecto a las 8 horas según hospitales de referencia.....	180
Figura 36. Porcentaje de cambio respecto a las 8 horas por áreas de salud (TomTom).....	181
Figura 37. Población cubierta por los hospitales de referencia y localización y cobertura del nuevo hospital (jueves - red GTFS) .....	189
Figura 38. Población cubierta por los hospitales de referencia y localización y cobertura del nuevo hospital (jueves - red TomTom) .....	190
Figura 39. Metodología para el desarrollo del modelo de centros comerciales .....	194
Figura 40. Densidad de población a partir de los centroides de secciones censales .....	197

Figura 41. Población cubierta por la red de centros comerciales según red GTFS	198
Figura 42. Población cubierta por la red de centros comerciales según red TomTom	200
Figura 43. Población cubierta y porcentaje de cambio entre las 12 y las 18 horas (GTFS)	203
Figura 44. Población cubierta y porcentaje de cambio entre las 12 y las 18 horas (TomTom)	204
Figura 45. Promedio de población cubierta según horas	205
Figura 46. Asignación de la población a los centros comerciales usando la red GTFS	208
Figura 47. Detalle de la asignación de la población a los centros comerciales (GTFS y jueves)	209
Figura 48. Detalle de la asignación de la población a los centros comerciales (GTFS y sábado)	210
Figura 49. Población cubierta y cambios horarios respecto a las 18 horas (jueves - GTFS)	212
Figura 50. Detalle de las secciones censales no asignadas para un jueves, usando GTFS	213
Figura 51. Detalle de las secciones censales no asignadas para un sábado, usando GTFS	214
Figura 52. Asignación de la población a los centros comerciales usando la red TomTom	217
Figura 53. Población asignada y cambios horarios con respecto a las 18 horas (jueves - TomTom)	219
Figura 54. Detalle de las secciones censales no asignadas para un jueves, usando TomTom	220
Figura 55. Detalle de las secciones censales no asignadas para un sábado, usando TomTom	221

Figura 56. Porcentaje de población asignada según la solución empleada (red GTFS y TomTom).....	222
Figura 57. Centros comerciales actuales y nuevos en la solución maximizar cuota de mercado objetivo (incremento al 22%) (GTFS) .....	225
Figura 58. Centros comerciales actuales y nuevos en la solución maximizar cuota de mercado objetivo (incremento al 98%) (TomTom).....	226
Figura 59. Localizaciones consideradas como candidatas MLA .....	233
Figura 60. Promedio de viajes por día y hora .....	236
Figura 61. Distancia media recorrida por horas.....	237
Figura 62. Duración media de los viajes por horas.....	238
Figura 63. Duración media de los viajes según días de la semana.....	238
Figura 64. Distancia media de los viajes por hora y día .....	239
Figura 65. Duración media en minutos de los viajes por hora y día .....	240
Figura 66. Viajes mensuales por horas .....	240
Figura 67. Densidad de viajes por hectáreas según origen y destino del viaje .....	241
Figura 68. Densidad de viajes (orígenes) por hectáreas según franjas horarias....	242
Figura 69. Escenario de referencia: localización óptima de los estacionamientos a partir del total de los orígenes de los viajes.....	244
Figura 70. Escenario de referencia: Demanda cubierta por cada estacionamiento y diferencias en la demanda cubierta total entre franjas horarias. ....	246
Figura 71. Escenario de referencia: Nivel de especialización de los estacionamientos según franja temporal. ....	248
Figura 72. Escenarios parciales: Ubicación óptima de estacionamientos con modelos dinámicos adaptados a la demanda en cada una de las franjas temporales .....	249
Figura 73. Escenario optimizado: Número de estacionamientos por franja temporal.....	251
Figura 74. Escenario optimizado .....	252

Figura 75. Metodología para el modelo de localización.....	258
Figura 76. Sucesos atendidos por el SAMUR-PC en 2019 y 2020.....	260
Figura 77. Evolución de los sucesos ocurridos en 2019 y 2020 .....	262
Figura 78. Evolución de los tipos de sucesos 2019-2020.....	263
Figura 79. Sucesos por hora y día 2019-2020.....	264
Figura 80. Tipos de sucesos por hora y día año 2019 - 2020 .....	266
Figura 81. Promedio de sucesos por hexágono según horario año 2019 vs 2020 .	269
Figura 82. Promedio por hexágono según tipo de suceso 2019-2020 .....	270
Figura 83. Sucesos atendidos en 2019-2020 y porcentaje de cambio .....	272
Figura 84. Análisis de Moran 1 año 2019-2020 .....	272
Figura 85. Cantidad de sucesos según días y franjas horarias .....	274
Figura 86. Análisis LISA de la distribución de sucesos atendidos en 2019 y 2020 según franjas temporales .....	276
Figura 87. Combinación del clúster HH de los tipos de eventos.....	278
Figura 88. Cobertura de sucesos por estaciones según día de la semana y año 2019-2020 .....	279
Figura 89. Sucesos cubiertos por estación en día laborable y fin de semana en los años 2019 y 2020. ....	280
Figura 90. Promedio del tipo de sucesos atendidos por las estaciones actuales ...	281
Figura 91. Sucesos cubiertos por las estaciones actuales en año 2019 .....	283
Figura 92. Sucesos cubiertos por las estaciones actuales en año 2020 .....	284
Figura 93. Asignaciones de los MLA a las estaciones actuales año 2019 .....	287
Figura 94. Asignaciones de los MLA a las estaciones actuales año 2020 .....	288
Figura 95. Sucesos cubiertos por las estaciones en 5-8-10 minutos año 2019.....	290
Figura 96. Sucesos cubiertos por las estaciones en 5-8-10 minutos año 2020.....	291
Figura 97. Sucesos cubiertos por las estaciones actuales y nuevas 2019 .....	294
Figura 98. Sucesos cubiertos por las estaciones actuales y nuevas 2020 .....	295

# INDICE DE TABLAS

Tabla 1. Resumen de estudios aplicando MLA casos públicos/privados .....	30
Tabla 2. Resumen de casos de estudio aplicando MLA en SIG .....	73
Tabla 3. Resumen de investigaciones con telefonía móvil .....	95
Tabla 4. Investigaciones que utilizaron redes sociales .....	106
Tabla 5. Estudios realizados en los últimos cinco años.....	112
Tabla 6. Estadísticas del conjunto de datos .....	137
Tabla 7. Cantidad de hexágonos con sucesos recogidos por el SAMUR totales y por franjas temporales .....	138
Tabla 8. Atributos y descripción del producto <i>Historical Speed Profile</i> .....	142
Tabla 9. Modelos de localización aplicados a hospitales .....	154
Tabla 10. Población cubierta por hospitales a diferentes horas del día utilizando la red GTFS.....	164
Tabla 11. Población cubierta por los hospitales a diferentes horas del día utilizando la red TomTom .....	166
Tabla 12. Diferencias entre la población cubierta el sábado y jueves (resta de la demanda del sábado menos el jueves) .....	167
Tabla 13. Población cubierta por hospitales asignados a las áreas de salud (GTFS) .....	169
Tabla 14. Población cubierta por hospitales asignados a las áreas de salud (TomTom).....	172
Tabla 15. Diferencias entre la población cubierta el sábado y jueves (sábados menos jueves) .....	175
Tabla 16. Población cubierta por los hospitales de referencia de las áreas de salud (jueves - GTFS) .....	183

Tabla 17. Población cubierta por los hospitales de referencia de las áreas de salud (sábados – GTFS) .....	183
Tabla 18. Población cubierta por los hospitales de referencia de las áreas de salud (jueves - TomTom) .....	184
Tabla 19. Población cubierta por los hospitales de referencia de las áreas de salud (sábado - TomTom).....	184
Tabla 20. Diferencias en la población cubierta por los hospitales de referencia entre día laborable y fin de semana (sábados-jueves GTFS).....	185
Tabla 21. Diferencias en la población cubierta por los hospitales de referencia entre día laborable y fin de semana (sábados-jueves TomTom).....	185
Tabla 22. Población cubierta por hospitales de referencia actuales y con el nuevo hospital (Red GTFS).....	187
Tabla 23. Población cubierta por hospitales de referencia actuales y con el nuevo hospital (Red TomTom).....	187
Tabla 24. Población cubierta por los centros comerciales (GTFS).....	197
Tabla 25. Población cubierta por la red de centros comerciales (TomTom).....	199
Tabla 26. Diferencias en la población cubierta entre el sábado y jueves (sábado-jueves).....	201
Tabla 27. Población asignada a los centros comerciales a diferentes horas del día utilizando la red GTFS.....	207
Tabla 28. Población asignada a los centros comerciales a diferentes horas del día utilizando la red TomTom .....	215
Tabla 29. Diferencias entre la población asignada (sábado - jueves) .....	216
Tabla 30. Estadísticas descriptivas de la densidad de orígenes y destinos de viajes por hectárea .....	242
Tabla 31. Estadísticas descriptivas de la densidad de orígenes por hectárea y franja temporal.....	243
Tabla 32. Estadística descriptiva de la demanda cubierta en el escenario de referencia según estacionamiento.....	244

Tabla 33. Escenario de referencia: demanda cubierta por franjas horarias .....	245
Tabla 34. Demanda cubierta por los estacionamientos en cada uno de los momentos temporales .....	250
Tabla 35. Escenarios parciales: Número de estacionamientos según la franja temporal en la que aparecen activos.....	250
Tabla 36. Demanda cubierta por los estacionamientos en cada uno de los momentos temporales según modelos.....	252
Tabla 37. Estadísticas de la distribución de los sucesos según hexágonos durante 2019 .....	267
Tabla 38. Estadísticas de la distribución de los sucesos según hexágonos durante 2020 .....	267
Tabla 39. Estadísticas de la distribución por hexágonos por tipo de sucesos año 2019 .....	268
Tabla 40. Estadísticas de la distribución por hexágonos por tipo de sucesos año 2020 .....	268
Tabla 41. Promedio de sucesos por hexágono y porcentaje de cambio 2019-2020 .....	269
Tabla 42. Promedio por hexágono según tipo de suceso y porcentaje de cambio 2019-2020 .....	270
Tabla 43. Número de hexágonos según clústeres por año y franja temporal.....	277
Tabla 44. Cobertura de la red de SAMUR: sucesos cubiertos con el modelo maximizar cobertura (tiempo de respuesta 8 minutos).....	278
Tabla 45. Variaciones de la distribución de los sucesos y tráfico (TomTom) en la red según franjas horarias .....	285
Tabla 46. Modelos con los sucesos y congestión de la red según franjas horarias 2019-2020 .....	292
Tabla 47. Demanda cubierta por las actuales y nuevas estaciones .....	296

# RESUMEN

Los modelos de localización-asignación se ocupan para conseguir una ubicación más adecuada de los servicios y equipamientos. La configuración de los modelos requiere los siguientes elementos: puntos de oferta, puntos de demanda y una red que los conecte. En el pasado, los investigadores realizaban modelos de localización estáticos a partir de datos procedentes de fuentes oficiales. Ahora, con la aparición del Big Data, en especial por sus características espacio-temporales, se pueden presentar modelos que incluyan variables dinámicas, ya sea en la oferta, la demanda o en la red. Dentro de la variedad de Big Data se aprovechan los registros GPS y las redes del transporte público y privado para elaborar esta investigación.

Para el desarrollo de la tesis, se aplicó Big Data geolocalizado en modelos de localización-asignación de servicios en entornos SIG; con el fin de realizar un análisis dinámico de la localización de la demanda y del funcionamiento de las redes de transporte. En este sentido, se utilizan varias fuentes novedosas para construir las redes de transporte y obtener la localización diaria de la oferta y la demanda. Por ejemplo, las redes dinámicas fueron confeccionadas con los ficheros GTFS del transporte público de Madrid y los perfiles históricos de velocidad, almacenados por la empresa de navegación TomTom. Mientras tanto, para la representación de la oferta y la demanda se utilizaron los registros GPS de los viajes realizados por los usuarios de la empresa Muving de motocicletas compartidas y los registros GPS de los sucesos atendidos por el Servicio de Asistencia Municipal de Urgencia y Rescate y Protección Civil de Madrid (SAMUR-PC).

Los casos de estudio fueron realizados dentro de la ciudad y el área metropolitana de Madrid. Se ha seguido una metodología general que incluye desde la recopilación, preparación y limpieza de los datos, a la ejecución de los modelos de localización-asignación, incluyendo dentro de ellos los parámetros sobre el papel de la distribución cambiante de la demanda y del funcionamiento de las redes según diferentes franjas horarias del día.

Un primer modelo de localización-asignación se aplica a la localización de servicios hospitalarios y centros comerciales, evaluando la dinámica de la accesibilidad durante el día. Para ello, se incorpora el dinamismo que ofrece la red de transporte público,

construida a partir de archivos GTFS, y la red de transporte privado diseñada con información obtenida de los archivos de tráfico de la empresa TomTom. El segundo modelo, realizado con los datos GPS de las motocicletas, tiene como objetivo encontrar lugares óptimos de aparcamientos para servicios de micromovilidad compartida sin bases fijas. Por último, se realizó un análisis comparativo entre los patrones espacio-temporales de los eventos en los que intervino el SAMUR-PC, antes y después del inicio de la pandemia COVID-19. Este análisis sirvió para evaluar la ubicación actual de las estaciones del SAMUR-PC y proponer su ampliación.

Los resultados obtenidos con el modelo para hospitales y centros comerciales indican que la accesibilidad del transporte público es notablemente mejor en días laborables que en fines de semana. En cambio, con los datos de TomTom, los efectos de la congestión hacen que la accesibilidad a los hospitales y a los centros comerciales sea menor entre semana. Esta investigación demuestra que el estudio de la cantidad de demanda a captar por los servicios estudiados debe considerar los cambios que se producen en función de la variación de las frecuencias del transporte público o de las condiciones del tráfico en las calles durante las distintas franjas horarias del día.

En el caso de los estacionamientos para las motos compartidas se obtuvo una distribución eficiente de las plazas de aparcamiento. Esta eficiencia se mantiene a lo largo del día, aunque la mayor dispersión de los viajes en la franja de la mañana hace que la cobertura disminuya. Mientras, durante la noche la demanda está más concentrada y la eficiencia de las plazas de aparcamiento aumenta.

Por último, con el estudio de las estaciones del SAMUR-PC los resultados del análisis espacio-temporal indican una disminución del número de eventos atendidos por el SAMUR-PC, lo que evidencia el impacto del COVID-19. Por otro lado, los valores obtenidos a partir de los modelos de localización que consideran los cambios temporales de la distribución de los sucesos y funcionamiento de las redes permiten cubrir mejor la demanda. Además, se probó incluir tres nuevas estaciones de servicio en cada franja horaria, que permiten una mejora notable de cobertura de las bases actuales. También, se ejecutó un modelo en el que se considera los sucesos totales sin dividirlos en franjas horarias, obteniendo niveles de cobertura inferiores.

Durante el desarrollo del trabajo, surgieron nuevas ideas de investigación que no estaban contempladas y que serán oportunidades para el desarrollo futuro. Por

ejemplo, realizar modelos predictivos de la demanda, comparar nuestros resultados con otras redes de transporte como Google Maps y utilizar otras fuentes de datos para comprender la localización de la demanda durante el día. Para terminar, se concluye que con las nuevas fuentes de datos geolocalizados es posible entender mejor la distribución de la población y los patrones de comportamiento de las redes de transporte público y privado durante el día y aplicar modelos de localización y asignación de servicios y equipamientos mucho más eficientes.

# ABSTRACT

Location-allocation models are used to achieve the optimal location of services and facilities. Setting up the models requires the following elements: supply points, demand points and a network that connects them. In the past, researchers made static location models based on data from official sources. Now, with the emergence of Big Data, especially because of its Spatial-temporal characteristics, models can be presented that include dynamic variables, whether on the supply, demand, or network side. Within the variety of Big Data, GPS records and public and private transport networks are used to develop this research.

For the development of the thesis, geolocated Big Data has been applied in service location-allocation models in GIS environments; to conduct a dynamic analysis of the location of the demand and the operation of the transport networks. In this sense, several novel sources are used to build transport networks and obtain the daily location of supply and demand. For example, the dynamic networks were built with the GTFS files of Madrid's public transport and historical speed profiles, stored by the navigation company TomTom. Meanwhile, for the representation of supply and demand, GPS records of journeys made by users of Muving motorbikes sharing company and GPS records of events attended by the Municipal Emergency and Rescue Assistance Service and Civil Protection of Madrid (SAMUR-PC) were used.

The case studies were conducted within the city and metropolitan area of Madrid. A general method has been followed that includes data collection, preparation, and cleaning, to the execution of the location-allocation models, containing within the parameters on the role of the changing distribution of demand, and the operation of the network according to different time slots of the day.

A first location-allocation model is applied to the location of hospitals services and shopping centres, evaluating the dynamics of accessibility during the day. For this purpose, the dynamism offered by the public transport network, built from GTFS files, and the private transport network designed with information obtained from the traffic files of the TomTom company are incorporated. The second model, made with GPS data from motorbikes, the aim was to find optimal parking spaces for sharing micromobility services without fixed bases. Finally, a comparative analysis was

conducted between the spatial-temporal patterns of the events in which SAMUR-PC intervened, before and after the start of the COVID-19 pandemic. This analysis was used to evaluate the current location of the SAMUR-PC stations and to propose their expansion.

Results obtained with the model for hospitals and shopping centres show that public transport accessibility is significantly better on weekdays than on weekends. In contrast, with the TomTom data, the effects of congestion mean that access to hospitals and shopping centres is lower on weekdays. This research shows that the study of the amount of demand to be captured by the services studied must consider the changes that occur depending on the variation of public transport frequencies or traffic conditions on streets during different time slots of the day.

In the case of bike-share parking, an efficient distribution of parking spaces was obtained. This efficiency is maintained throughout the day, although the more dispersed nature of the trips in the morning period means that coverage decreases. Meanwhile, during the night, demand is more concentrated, and the efficiency of parking spaces improves.

Finally, with the study of the SAMUR-PC stations, results of the spatial-temporal analysis indicate a decrease in the number of events attended by SAMUR-PC, which is evidence of COVID-19's impact. On the other hand, values obtained from the dynamic location models that consider changes in the distribution of events and network operation allow for a better coverage of demand. In addition, the inclusion of three new service stations in each time slot was evaluated, allowing for a significant improvement in the coverage of the current bases. Furthermore, a model was run in which total events are considered without dividing them into time slots obtaining lower levels of coverage.

During the work, new research ideas appeared that had not been contemplated and which will be opportunities for future development. For example, predictive modelling of demand, comparing our results with other transport networks such as Google Maps and using other data sources to understand the location of demand during the day. Finally, it is concluded that with the new geolocated data sources, it is possible to better understand the population distribution and behavioural patterns of public and private

transport networks during the day and to apply much more efficient location and allocation models for services and facilities.

# **1 INTRODUCCIÓN**

## 1.1 Interés y oportunidad de la investigación

La tendencia al crecimiento de la población urbana implica una serie de problemas. La contaminación ambiental, el abastecimiento energético o la congestión del tráfico, son algunos de ellos. Es necesario un intenso proceso de planificación y gestión urbana, que evite que estos problemas se intensifiquen y proponga soluciones eficaces a los mismos. Pero además, la rápida transición de la sociedad hacia una población urbanizada supone también cubrir con las expectativas de toda una serie de servicios, como la educación, la sanidad, la seguridad, etc., que convierten a las ciudades en ecosistemas sociales donde resulta esencial garantizar la sostenibilidad y un adecuado nivel de vida (Arroub et al., 2016).

En consecuencia, la ciudad necesita de una planificación y equipamientos suficientes, para afrontar las tensiones de la rápida urbanización. Sin una planificación urbana eficiente, la calidad de vida, la seguridad, la eficiencia de los servicios, la condición medioambiental, el desarrollo y el atractivo económico pueden deteriorarse, afectando la convivencia y la prosperidad de la comunidad (Daniel & Doran, 2013).

Ante este escenario, administraciones e investigadores de todo el mundo han presentado un importante número de modelos de ciudades futuras. Sus objetivos críticos se centran en la tecnología, la conectividad, la sostenibilidad, el confort o la seguridad. Es en este marco donde las ciudades empiezan a tomar conciencia del concepto de ciudades inteligentes (Arroub et al., 2016).

El concepto de ciudades inteligentes –*smart cities*– destaca la importancia de las tecnologías de la información y la comunicación (TIC) (Giffinger et al., 2007). El objetivo de estas ciudades es utilizar las TIC para mejorar la calidad de vida de la ciudad, el medioambiente y la sostenibilidad urbana (Karlı & Selma Çelikyay, 2021). De hecho, estas ciudades contribuyen a satisfacer las necesidades y expectativas de la vida urbana, al tiempo que proporcionan unos servicios de alta calidad.

Una ciudad inteligente facilita la interacción con los habitantes de múltiples maneras y se adapta a sus necesidades en tiempo real. Todo ello buscando unos servicios y equipamientos de alta calidad y rentabilidad. Además, ofrece soluciones y servicios dirigidos a las personas, para que ciudadanos y empresas puedan afrontar los efectos del crecimiento urbano, tanto en el ámbito público como en el privado (Del Rivero,

2017). En efecto, las TIC son esenciales para aumentar la eficiencia de los sistemas urbanos. Permiten a los humanos mejorar los procesos de gobernanza, y ser capaces de comprender, evaluar y planificar mejor la ciudad. La ciudad inteligente parte del desarrollo de infraestructuras inteligentes y de la integración de las TIC y de los ciudadanos.

En el desarrollo de las TIC y su aplicación a las ciudades inteligentes, aparecen dispositivos como sensores, cámaras y receptores GPS, por mencionar algunos, capaces de detectar y recoger una cantidad masiva de datos, formando parte de lo que conocemos con el concepto de Big Data (Arroub et al., 2016).

A los conceptos de Smart City y Big Data se incorpora también la *location intelligence* –localización inteligente–(Hassan & Vijayaraghavan, 2019). Esto incluye la transformación de los datos geolocalizados en conocimiento. Gracias a estos datos, las aplicaciones de localización inteligente pueden mostrar patrones ocultos de asociaciones espaciales que son imposibles de encontrar por otros medios. Además, ayudan a tomar las mejores decisiones sobre dónde ocurren los hechos, por qué ocurren en determinados sitios y cómo evolucionan.

La localización inteligente aprovecha los modelos de localización óptima de servicios y equipamientos y los datos geolocalizados, contribuyendo así a conseguir los objetivos de las ciudades inteligentes. Entre ellos, ofrece mejores servicios a los ciudadanos y les proporciona información en tiempo real. De este modo, se les ayuda a tomar mejores decisiones y se contribuye a la solución de los problemas cotidianos de la ciudad.

En concreto, los modelos de localización-asignación (*Location-Allocation Models*) implementados en Sistemas de Información Geográfica (SIG) pertenecen a un subconjunto de modelos de optimización, que se utilizan para determinar la ubicación ideal de un servicio o equipamiento, en una ciudad o territorio, en función de la distribución espacial de la demanda de ese servicio. Los modelos de localización-asignación (MLA) se han desarrollado mediante la aplicación de diferentes algoritmos realizados en programas de Sistemas de Información Geográfica, que utilizan la impedancia en la red de calles, para la selección óptima de los candidatos a la localización del servicio y la asignación de los sitios de demanda a esas localizaciones.

Los modelos de localización asignación de servicios permiten optimizar una o varias funciones. Entre ellas se incluye soluciones que priman la eficiencia del sistema, buscando por ejemplo maximizar la cobertura de la demanda en un determinado servicio o maximizar la satisfacción del cliente. Otras soluciones buscan atender criterios de equidad en la distribución de los servicios, con algoritmos como la minimización de la distancia recorrida del conjunto de la demanda a las localizaciones asignadas. Efectivamente, todos los casos buscando localizaciones de una o varias instalaciones del servicio en un rango dado de ubicaciones candidatas (Elkady & Abdelsalam, 2015).

Específicamente, esta tesis doctoral se enfoca en los modelos de localización-asignación que consideran la red de calles para simular la conexión entre los sitios candidatos a la instalación y la distribución de la demanda. Los MLA se han utilizado ampliamente en el pasado. Sin embargo, en la actualidad el desarrollo de la computación y la aparición de datos cada vez más detallados y de fácil acceso han despertado el interés de los académicos de la geografía, la planificación urbana, del transporte, del marketing, de la medicina y de otros campos por estos modelos.

Muchos problemas de localización de servicios se han resuelto gracias a la ayuda de estos modelos. Integrados en un Sistema de Información Geográfica (SIG), permiten planificar, de forma más adecuada, la distribución espacial de los distintos equipamientos que se ofrece a los habitantes para el desarrollo de sus actividades cotidianas. En consecuencia, con la implementación de los MLA y los Sistemas de Información Geográfica (SIG) se pretende obtener resultados óptimos para la ubicación de las instalaciones y los equipamientos que permitan satisfacer las necesidades de la población.

Los MLA requieren tres datos básicos: la localización de la demanda, la oferta y los puntos candidatos para futuras localizaciones y una red de transporte. La demanda representa a los usuarios potenciales del servicio a localizar. En general, se expresa como el número de personas que se espera que utilicen la instalación y suele representarse en el SIG mediante una serie de puntos o polígonos distribuidos por el territorio. Estos polígonos representan, con frecuencia, secciones censales o incluso áreas geográficas postales a las que se asocian los datos de demanda, habitualmente de la población (Tomintz & Alfadhli, 2015). La oferta comprende instalaciones relacionadas con todo tipo de servicios, desde los más tradicionales: escuelas,

hospitales, centros comerciales, a otros más recientes como las bases de un servicio de bicicletas compartidas. Asociada a la oferta, un elemento fundamental es la representación de los sitios candidatos donde poder ubicar las nuevas instalaciones. Estos pueden representar solares disponibles o una "nube" de localizaciones homogéneas en la ciudad, que represente posibles alternativas a esas localizaciones. Finalmente, los modelos de localización asignación requieren de una red digital de transporte, en la que se simula el movimiento, ya sea desde sus localizaciones a los puntos de oferta o viceversa, cuando el desplazamiento se realiza desde la oferta a la demanda (por ejemplo, un servicio de mensajería o de bomberos).

Debido a las limitaciones de los datos, los MLA tradicionales asumen que la localización de la demanda es invariable en el tiempo. Lo mismo ocurre con los puntos de oferta y la red de transporte, que se utilizan de forma estática, sin tener en cuenta su comportamiento dinámico. Sin embargo, la distribución de la demanda y el comportamiento de la red de transporte presentan variaciones espaciales y temporales. Por ejemplo, en un modelo de localización que trabaja con desplazamientos por la red de carreteras, habitualmente, no se consideran los efectos de la congestión a determinadas horas del día. Por lo tanto, la distribución de la demanda, el funcionamiento de la red y la oferta considerados de forma estática pueden desviarse mucho de su comportamiento real, lo que conduce a soluciones menos eficientes en los MLA.

En comparación con los modelos tradicionales, en esta tesis se propone un enfoque dinámico a la hora de representar mejor las características espacio-temporales de los datos de entrada en los MLA. Estos datos cubren mejor las actividades dinámicas de los usuarios y, por consiguiente, permiten obtener un resultado más óptimo cuando se trata de localizar las instalaciones (Yang et al., 2020).

En definitiva, la demanda, la oferta y el funcionamiento de las redes de transporte son dinámicos, con variaciones en su ubicación a lo largo del día. Por consiguiente, el enfoque de la tesis está dado en implementar métodos para incorporar ese componente dinámico a los modelos y en estudiar el efecto de este dinamismo en los resultados del modelo. Para conseguir este fin, trataremos de aprovechar las bondades asociadas al Big Data. Esta investigación obtiene la demanda y la red de transporte a partir de nuevas fuentes de datos o Big Data.

El Big Data enriquece, como decíamos inicialmente, la experiencia del funcionamiento de las ciudades. Muchas de las teorías y aplicaciones en los estudios y la planificación urbana se han basado en datos de baja resolución temporal. Estos datos permiten conocer lo que ocurre en las ciudades a lo largo de meses o años. Sin embargo, el comportamiento diario de la ciudad, es menos tratado. Con el Big Data ahora es posible analizar variables que antes se recogían cada diez años en los censos de población, como la distribución de la población, estudiar su distribución en diferentes momentos del día y considerar ese dinamismo en la planificación de los servicios (Batty, 2013).

El auge del Big Data en los entornos urbanos interesa, de manera particular, a la Geografía. Las ciudades inteligentes aprovechan las TIC para conectar sensores y dispositivos a los objetos. Esto se hace con el fin de captar y almacenar grandes volúmenes de datos sobre la dinámica de la ciudad. Esta conectividad permite el desarrollo del llamado Internet de las Cosas (IoT). Gracias al IoT es posible conectar la realidad física y virtual a través de un conjunto de sensores. Con ellos, se almacenan datos que ayudan a comprender mejor la necesidad de nuevos servicios públicos o de cómo gestionar los negocios de forma más eficiente. Por ejemplo, los datos de las llamadas a los centros de bomberos y emergencias, históricamente, estaban protegidos y eran confidenciales e inaccesibles para cualquier persona ajena a la institución. Ahora, ese material puede recuperarse fácilmente a través de Internet. Se espera que los macrodatos generados por el IoT mejoren la disponibilidad de los datos utilizados en los modelos de localización (Church & Murray, 2018).

El Big Data está en auge en las publicaciones científicas y en las conferencias académicas y no académicas. Manyika et al. (2011) sugieren que el Big Data representa una fuente de innovación, competencia y productividad, e impulsa un cambio hacia la investigación basada en datos masivos. El flujo de Big Data se incrementa cada vez más. Estos proceden de diversos sensores, de sistemas de mensajería, de redes sociales y de métodos más tradicionales de medición y observación. Estos dispositivos de almacenamiento de datos espaciales y no espaciales están presentes en numerosas facetas de la vida cotidiana.

De especial interés en este trabajo es el Big Data geoespacial. Los datos geoespaciales describen objetos y cosas sobre el espacio geográfico, a menudo con coordenadas de localización en un sistema de referencia espacial (Li et al., 2016), que

permiten a los responsables en la toma de decisiones, hacer frente a una variedad de situaciones. Por ejemplo, las de vigilancia de las enfermedades (como vivimos durante la pandemia), la respuesta a las catástrofes, el control de las infraestructuras vitales o el transporte.

En definitiva, la captura de datos geoespaciales ha evolucionado de un escenario de escasez de datos a otro de riqueza de estos. Hace unos años, la adquisición de datos geoespaciales requería dispositivos, técnicamente exigentes, caros y complicados, que convertían el propio proceso de medición a veces en un arte. Hoy se capturan y almacenan datos a través de múltiples fuentes. Específicamente, los teléfonos móviles, las tarjetas inteligentes de transporte público y las redes sociales tienen un alto índice de penetración en la población; por consiguiente, desde el punto de vista de la detección social, pueden captar vastas actividades, ritmos y preferencias humanas (Liu et al., 2018, Tu et al., 2020). Estas nuevas fuentes de datos proporcionan información detallada sobre las actividades e interacciones humanas en toda la ciudad (Shaw, Tsou, & Ye, 2016; Xu et al., 2018). Todas estas fuentes se caracterizan por captar información geográfica, sobre el entorno, con un nivel de precisión geométrica, resolución temporal y granularidad temática nunca visto. Algunos de los dispositivos son compactos, fáciles de manejar y capaces de adquirir datos, incluso cuando no se utilizan conscientemente (Li et al., 2016).

En definitiva, las diversas fuentes de Big Data geolocalizado dan lugar a novedosas oportunidades para integrarlas en los modelos de localización asignación para la planificación de servicios y equipamientos, ya que permiten identificar escenarios o soluciones casi óptimas para la gestión de servicios públicos o privados de forma más cuantitativa y científica (Cao et al., 2020). Con la irrupción y el crecimiento del Big Data geolocalizado, los modelos de localización encuentran interesantes oportunidades.

Efectivamente, las nuevas fuentes de datos ayudan a transformar y mejorar los métodos tradicionales de planificación aplicados en diversas situaciones. De forma particular los MLA pueden explotar el componente espacial y temporal de los datos del Big Data para la localización de instalaciones. Incorporar el Big Data geolocalizado en los MLA proporciona un proceso de optimización más detallado, a una escala mucho más fina, y permite una transición de las aplicaciones de optimización espacial estáticas a las dinámicas o en tiempo real.

La tesis fija su interés en utilizar algunas fuentes de Big Data para incorporar el dinamismo en los tres datos de entrada –oferta, demanda y red de transporte– que requieren los MLA. En el caso de la oferta y la demanda, interesa conocer su distribución espacial cambiante a lo largo del tiempo. Mientras que, en la red de transporte, la novedad será aprovechar las oportunidades que ofrece el Big Data para incluir escenarios de congestión de vehículos o de frecuencias de transporte público durante el día. Así, los MLA, acompañados de Big Data, resultan una tendencia atractiva y novedosa que desempeña un papel importante en diversas situaciones de optimización en la era de las ciudades inteligentes.

En fin, las fuentes alternativas de Big Data urbano geolocalizado han demostrado, recientemente, considerables beneficios en la captura de las interacciones dinámicas entre los residentes y el área urbana (Shaw et al., 2016). En comparación con las típicas encuestas sobre el terreno y los conjuntos de datos del censo urbano, el Big Data presenta numerosas ventajas para obtener información sobre el dinamismo urbano. Destaca la alta penetración de estas fuentes entre la población o en la ciudad, su amplia cobertura espacial y la información sobre las actividades humanas que pueden capturar.

Estos enormes e inestimables conjuntos de datos han suscitado nuevas ideas sobre la cuantificación de la dinámica de las ciudades (Tu et al., 2020). Así pues, el reciente desarrollo de las tecnologías de la información y la comunicación (TIC) ha hecho posible la recopilación de datos de movimientos individuales a gran escala de detalle (Chen et al., 2016; Gutiérrez-Puebla, García-Palomares, & Salas-Olmedo, 2016).

En este sentido, aparecen algunas investigaciones que abordan el dinamismo en los datos de entrada –oferta, demanda, red de transporte– necesarios para desarrollar MLA que incorporen datos procedentes de Big Data. Es el caso de estudios que utilizan Big Data, como registros GPS, para representar la oferta en los modelos de localización de estaciones de bicicletas o de las ubicaciones del abordaje y descenso de los pasajeros de los taxis (Park & Young Sohn, 2017 y Zhang et al., 2019). Otros trabajos emplean datos telefónicos para analizar la distribución de la población flotante (población que se desplaza a lo largo del día) (Dibene et al., 2017; Han et al., 2020; Park & Young Sohn, 2017; Tu et al., 2016; Yang et al., 2020; Yu et al., 2020; Zhang et al., 2019; Zhu et al., 2016). Veremos con detalle estas aportaciones en la revisión de la literatura.

También con respecto a las investigaciones que incorporan variables temporales dinámicas en la construcción de las redes utilizadas en los MLA, aparecen algunos trabajos que utilizan datos de las aplicaciones como AutoNavi y Amap Maps. Los trabajos de Han et al. (2020); Wang et al. (2021); Zhou et al. (2020), por ejemplo, abordan las situaciones de congestión en la red cuando proponen sus modelos de localización-asignación.

Sin embargo, como veremos después en la revisión de la literatura, son pocos los trabajos que abordan modelos de localización de forma dinámica a partir de fuentes de Big Data. La mayoría de las publicaciones solo utilizan las fuentes de Big Data para obtener la posición geográfica de la demanda o de los candidatos y omiten aprovechar los datos temporales recogidos por los dispositivos y sensores. Además, ninguno ha utilizado datos combinados de redes de transporte privadas o públicas, como los datos de TomTom y GTFS para el diseño de la red.

Para contribuir a llenar este vacío de conocimiento, el interés de esta tesis radica en la ejecución de modelos de localización y asignación en los que se utiliza Big Data. No se trata solo de explotar la localización geográfica de los fenómenos estudiados. Si no que se aprovecha la información temporal de los datos para hacer propuestas que consideren el comportamiento de la demanda, la oferta y la red a lo largo del día.

En consecuencia, en esta tesis se realizan aplicaciones de los modelos de localización-asignación en diferentes ámbitos. Se utilizan los MLA para localizar las siguientes instalaciones: sitios para el aparcamiento de una empresa de micromovilidad, Muving; estaciones para las ambulancias del Servicio de Asistencia Municipal Urgencia, Rescate y Protección Civil (SAMUR-PC) del municipio de Madrid; y hospitales públicos y centros comerciales.

Además del interés académico, esta investigación tiene mucha utilidad al ser aplicada en la planificación urbana, y en la gestión de servicios y transportes. Puede resultar de mucho provecho para la administración pública y privada.

Desde el punto de vista público, los MLA pueden utilizarse en la planificación de escuelas, hospitales, estaciones de ambulancia, parques de bomberos, áreas de patrulla policial, entre otros servicios. Resultan de utilidad para una adecuada gestión de los recursos económicos y humanos. Por ejemplo, una mala ubicación de las estaciones de emergencia puede aumentar la probabilidad de daños materiales o la

pérdida de vidas humanas. En el caso de la ubicación de los equipamientos sanitarios, la estimación del número de pacientes y el tiempo de viaje son fundamentales para determinar el número de instalaciones sanitarias a ofrecer, los servicios que prestan y su ubicación geográfica. La ubicación eficiente de un centro puede suponer un ahorro de costes y un mayor uso.

Desde el ámbito privado, los MLA pueden aplicarse a numerosos negocios, ya sean financieros, minoristas, centros comerciales o servicios de movilidad compartida, por citar algunos. Ellos se apoyan en la toma de decisiones al buscar ubicaciones para los negocios en las que se minimizan los costes, se maximiza la productividad y se busca obtener situaciones más competitivas. Por ejemplo, el caso del modelo para buscar aparcamientos que se presenta en esta tesis puede ser de gran interés para los planificadores y gestores de la movilidad urbana, que se enfrentan al reto de entender y anticipar el impacto de los nuevos servicios de micromovilidad en los centros urbanos. Esto contribuye a diseñar políticas y acciones capaces de regular las nuevas demandas de estos sistemas, especialmente, los problemas y conflictos que está generando el mal aparcamiento de los vehículos. Es imprescindible que las empresas de micromovilidad implementen acciones conjuntas con los planificadores para mejorar el servicio y evitar conflictos con otros modos de transporte o con los peatones que perjudiquen la imagen del sistema.

En definitiva, el éxito o el fracaso de las instalaciones, públicas y privadas, depende en gran medida de la ubicación elegida para estas instalaciones (Daskin, 2011). Los MLA ayudan a los responsables de las tomas de decisiones, a la hora de elegir las ubicaciones eficientes no solo en el estado actual del sistema, sino a medida que la población evoluciona (Meskarian et al., 2017).

## **1.2 Preguntas de investigación**

Tras esta presentación y una vez realizada la revisión de la literatura, que se presentará posteriormente, adelantamos aquí las preguntas de investigación y los objetivos de esta tesis.

La pregunta principal a la que pretende responder este trabajo es la siguiente: *¿Es posible incorporar la dinámica urbana a los modelos de localización-asignación de servicios a partir de fuentes Big Data?*

El espacio urbano se presenta en un cambio permanente, donde fluyen las actividades generadas por los ciudadanos. La dinámica urbana muestra una variabilidad en la distribución de la población durante el día. Dicha dinámica genera variaciones en la localización diaria de la población y en el funcionamiento de las redes de transporte público o privado, lo que afecta la provisión de servicios. Los servicios y equipamientos sufren las consecuencias de la congestión vehicular y de los cambios en las frecuencias del transporte público. Por ello, al plantear los MLA de servicios, es necesario incorporar el dinamismo de la demanda y del funcionamiento de la red. Esto permite obtener resultados más ajustados al comportamiento real de la demanda, la red o la oferta. En fin, la ciudad es un sistema que presenta cambios constantes durante el día, que debemos considerar en los MLA, para lo cual las fuentes Big Data pueden ofrecer enormes posibilidades.

De la pregunta general se derivan cinco preguntas específicas que guían el desarrollo de la tesis. Estas contemplan las tareas relacionadas con la revisión bibliográfica. Además, se explica la importancia de incorporar Big Data como datos de entrada para el desarrollo de modelos de localización-asignación de servicios. Otra de las interrogantes apunta a las aplicaciones prácticas en donde se proponen diferentes escenarios dinámicos. A continuación, se explica la finalidad de cada una de las preguntas específicas.

*P.1. ¿Qué trabajos previos se han realizado con la aplicación de MLA en SIG que integren una perspectiva dinámica?*

Los MLA han sido objeto de estudio durante muchos años. Sin embargo, la mayoría de las investigaciones carecen de una perspectiva dinámica sobre los datos de entrada que requieren este tipo de modelos. Se procederá a revisar los trabajos relacionados con los modelos de localización-asignación que integran variables dinámicas en la demanda, la oferta o la red utilizada en el planteamiento del problema a resolver. Algunos trabajos han empleado *Big Data* procedente de dispositivos GPS instalados en taxis o bicicletas compartidas, pero con esta pregunta nos planteamos evaluar hasta qué punto los trabajos previos aprovechan la información temporal que tienen las nuevas fuentes de datos y si dichos trabajos omiten el análisis del comportamiento temporal de la demanda y de la red durante las diferentes franjas horarias.

*P.2. ¿Qué importancia tiene analizar la distribución cambiante de la población a lo largo del día para la localización de nuevos equipamientos y servicios urbanos?*

Analizar la distribución cambiante de la población, a lo largo del tiempo, permite conocer la demanda potencial de cara a determinar la ubicación de las instalaciones de servicios. Con las nuevas fuentes de datos es posible conocer dónde se concentra la demanda en cada momento del día. Para las instalaciones públicas y privadas, puede ser interesante la información sobre el comportamiento temporal de los clientes o consumidores (demanda). Esta información les permite ajustarse al tipo de servicio que ofrecen. Con base a lo anterior, es posible gestionar los horarios de apertura o cierre de las instalaciones para aumentar o eliminar el exceso de establecimientos ineficientes. Para ello se ha de tener en cuenta la presencia o ausencia de demanda. Este interrogante va dirigido a analizar cómo cambia la ubicación de la población, por día y por hora, y busca evaluar la importancia que tiene la consideración dinámica de la localización de la demanda en los resultados de los modelos de localización-asignación de servicios.

*P.3. ¿Es factible utilizar las nuevas fuentes de datos para determinar la localización cambiante de la demanda y la oferta de servicios como uno de los elementos de los modelos de localización-asignación?*

Si los cambios en la distribución de la demanda a lo largo del tiempo son importantes, será necesaria su implementación en los MLA. Con el surgimiento del *Big Data*, es factible que los investigadores tengan acceso a datos de la distribución de la población urbana con un gran nivel de detalle temporal y espacial. Este interrogante va dirigido a analizar cómo incorporar los datos de diferentes fuentes de Big Data sobre la demanda en los MLA realizados en SIG. Por ejemplo, procedentes de redes sociales, registros GPS de los viajes realizados por usuarios de sistemas de movilidad compartida o a la localización geográfica de los sucesos atendidos por los servicios de urgencias serán incorporados a nuestros modelos.

*P.4. ¿Es posible incorporar la información de redes dinámicas de transporte (de redes de carreteras o de transporte público) en la aplicación de modelos de localización-asignación de servicios en un SIG y cuál es su importancia en los resultados de los modelos?*

Uno de los elementos requeridos para implementar los MLA son las redes de transporte, con el objetivo de simular el desplazamiento de la población a los equipamientos o servicios. Los MLA se han desarrollado, tradicionalmente, utilizando redes estáticas de transporte, que no incluyen aspectos como la influencia del tráfico diario y la congestión en los tiempos de viaje o de las propias frecuencias de servicios en el transporte público.

Esta tesis explora la posibilidad de incorporar en los MLA redes de transporte dinámicas como, por ejemplo, las proporcionadas por TomTom para los vehículos privados o los archivos GTFS para el transporte público. Se pretende averiguar los efectos de las variaciones en los tiempos de viaje a lo largo del día, sobre los resultados obtenidos en los modelos de localización-asignación de servicios. De esta forma resulta interesante evaluar cómo aumenta o disminuye la demanda cubierta por las instalaciones en diferentes días y horas debido al estado de la red de transporte público o privado.

*P.5. ¿Qué aplicaciones prácticas se le pueden dar a las nuevas fuentes de datos como insumos dinámicos de la oferta, la demanda y la red para los análisis realizados en los modelos de localización-asignación de los servicios?*

Las nuevas fuentes de datos permiten implementar MLA que incluyen, como uno de sus elementos, la demanda dinámica que facilita conocer cómo es la distribución de la población en el día. Se aplica a cualquier tipo de servicio que requiere la población. El motivo por el cual los modelos de localización-asignación no consideraban la movilidad de la población fue la inexistencia de datos, que permitieran conocer los patrones de movilidad de la población en el transcurso del día. Hoy, con el surgimiento de nuevas fuentes de datos, es posible tener una idea, aproximada, de la distribución de la población en las diferentes horas del día. Con este interrogante planteamos indagar en diferentes tipos de aplicaciones de los modelos de localización-asignación donde sea clave la utilización de una perspectiva dinámica.

## 1.3 Objetivos

### 1.3.1 Objetivo general

La comunidad internacional, ante los impactos generados por la rápida urbanización, busca alternativas inspiradas en los objetivos del desarrollo sostenible de la Organización de las Naciones Unidas. Algunos de esos objetivos plantean el reto de planificar ciudades más inteligentes y sostenibles, con el fin de satisfacer las necesidades de la población actual y futura en términos económicos, sociales y medioambientales. La ciudad inteligente aprovecha las TIC para innovar y mejorar la eficiencia de los servicios urbanos. Hoy en día, con la incorporación de las TIC, las ciudades disponen de redes de dispositivos y sensores que captan grandes volúmenes de datos (Big Data) relacionados con la vitalidad urbana. En este sentido, los datos recogidos por los sensores pueden ser aprovechados para la correcta localización de los servicios.

En los últimos años, ha crecido el interés por el uso del *Big Data* en los estudios urbanos, en general, y en especial en lo referente a la movilidad y los patrones de comportamiento de los ciudadanos. Tomando en consideración lo anterior, el objetivo general de esta investigación es analizar el efecto de la componente dinámica de la demanda y de las redes de transporte, a partir de la incorporación de nuevas fuentes de datos -Big Data geolocalizada- en los modelos de localización-asignación empleando para ello un entorno SIG.

La finalidad del trabajo se enfoca en la utilización de diferentes fuentes para conocer la distribución de la demanda y sus desplazamientos diarios, a través de redes de transporte que incorporen un componente dinámico. Reflejando así la distribución de la demanda y el funcionamiento de las redes en cada momento del día. Es decir, se pretende evaluar las variaciones espacio-temporales en algunos de los parámetros de los MLA a partir de la incorporación del dinamismo de la demanda y de las redes de transporte en los MLA, los cuales, tradicionalmente, fueron efectuados utilizando datos estáticos provenientes de las fuentes estadísticas oficiales.

### 1.3.2 Objetivos específicos

Los objetivos específicos, derivados del objetivo general, se detallan a continuación:

1. *Revisar las fuentes bibliográficas relacionadas con el tema para establecer un marco teórico y conceptual que sustente la investigación en relación con la aplicación de modelos de localización-asignación y la posible aplicación del Big Data con el fin de incorporar una perspectiva temporal en su desarrollo.*

Es de suma importancia realizar un estudio completo, detallado y actual de la bibliografía existente sobre MLA, en especial, los que tienen un componente temporal, para conocer sus fundamentos teóricos y conceptuales. Se examinará con detalle todo lo relacionado con los MLA, las metodologías implementadas, las aplicaciones en función del tipo de servicio o el equipamiento a localizar, en concreto, las realizadas en entornos SIG. A su vez, se exploran aspectos conceptuales y metodológicos relacionados con las nuevas fuentes de datos asociadas al Big Data.

Se analizan aquellas investigaciones que contemplan una perspectiva dinámica en los distintos elementos requeridos en los MLA, ya sea, en la oferta, la demanda o en la red. Así pues, se estudian los trabajos que incorporan las nuevas fuentes de datos para evaluar el efecto del dinamismo en la distribución de la demanda en el tiempo y el desplazamiento a través de la red.

El análisis de la literatura existente permite reconocer las ventajas y limitaciones al utilizar las nuevas fuentes de datos en los MLA, al igual que los retos y oportunidades que puedan aparecer durante y después del desarrollo de esta investigación.

A partir de la revisión de la literatura se obtiene una panorámica, teórica y metodológica, de los diferentes algoritmos y soluciones utilizados en los modelos de localización-asignación desarrollados en entornos SIG. Además, se explora la diversidad de aplicaciones en las que se pueden aprovechar las nuevas fuentes de datos para incorporar un enfoque dinámico en cada uno de los datos de entrada requeridos por los MLA.

2. *Identificar y seleccionar las fuentes de datos que permitan tener una aproximación de la distribución cambiante de la demanda de servicios o equipamientos a lo largo del día.*

En esta investigación se busca identificar diversas fuentes de datos procedentes de dispositivos o sensores que almacenan grandes volúmenes de datos. Con miras a seleccionar aquellas que permitan conocer los patrones de distribución espacial de la

población en el transcurso del día. En esta tesis se van a evaluar, especialmente, la utilidad de datos provenientes de registros GPS.

- 3. Realizar diagnósticos previos de la distribución de la demanda de servicios con ayuda de los datos provenientes de fuentes Big Data, según las aplicaciones a realizar en los MLA.*

En este objetivo se persigue realizar un diagnóstico, de los fenómenos analizados, a partir de las fuentes de Big Data, que permita obtener los cambios que se producen en la distribución de la demanda a lo largo del día. Por ejemplo, con la ayuda de los datos provenientes de los registros GPS de los vehículos de movilidad compartida y los datos de sucesos atendidos por las instituciones de emergencias se conocerá la distribución aproximada o los sitios de mayor concentración (puntos calientes) de usuarios en diversos momentos del día, semana o mes. Con estos datos se calculan los MLA para diversas franjas horarias en el transcurso del día, obteniendo resultados que toman en consideración la movilidad de la población, para realizar un análisis del efecto de la distribución cambiante de la demanda durante el día sobre los resultados de los modelos.

- 4. Identificar y seleccionar las fuentes de datos que permitan incorporar el papel del dinamismo de las redes en los modelos de localización-asignación.*

Otro de los elementos que incluyen los MLA son las redes de transporte. El uso de datos, de redes dinámicas, para el análisis del MLA representa uno de los principales objetivos que interesan en esta tesis, puesto que el nivel de servicio de las redes de transporte varía a lo largo del día, ya sea por las diferentes frecuencias en el transporte público o por los efectos de la congestión del tráfico en el transporte privado. Esas variaciones, en la eficiencia de las redes, se traducen en cambios en los tiempos de acceso de la población a los equipamientos y servicios.

Con este objetivo se pretende conocer cómo esos cambios afectan a los resultados de los modelos de localización-asignación. Para ello vamos a trabajar con redes dinámicas, procedentes de fuentes de Big Data, que permitan analizar las frecuencias del transporte público y los niveles de congestión durante el día.

Este estudio innovará los MLA al incorporar redes de transporte que tienen registros de congestión de tráfico. Ejemplo de este tipo de nuevas redes de transporte es la que ofrece la empresa de navegadores TomTom. Además, se utilizan los archivos GTFS

que poseen información del transporte público. La finalidad es comparar el efecto de la congestión en transporte privado y de las frecuencias en las rutas del transporte público, en la asignación de la demanda y de la localización de los equipamientos en diferentes franjas horarias.

5. *Implementar los procedimientos necesarios para el diseño de las redes de transporte destinadas al planteamiento de MLA, con el fin de simular el movimiento de la demanda en el transporte público o privado.*

Con este objetivo se pretende aprender los procedimientos o tareas preliminares necesarias para la construcción de las redes requeridas en el desarrollo de los MLA. La investigación se basa en las nuevas fuentes de datos disponibles, en particular las redes de transporte. Para crear las redes de transporte que se van a utilizar en el planteamiento del MLA resulta necesario combinar varios tipos de datos procedentes de diversas fuentes.

Para simular los viajes en coche se emplean los perfiles de velocidad históricos almacenados por la empresa TomTom, que requieren una preparación previa antes de crear la red. Es necesario realizar tareas de limpieza y correcciones de errores en los registros, para luego configurar varios atributos que permitan simular un escenario en condiciones de tráfico. Por otro lado, en el caso de los ficheros GTFS, descargados del servidor del Consorcio de Transportes de Madrid, se requieren tareas de preparación, previas para depurar y corregir errores topológicos en la red. Una vez preparadas ambas fuentes de red, es posible desplegarlas en programas SIG.

6. *Explorar y utilizar herramientas de Sistemas de Información Geográfica para la elaboración de modelos de localización-asignación de servicios y la representación de los resultados.*

Una vez se cuente con los datos de entrada requeridos se ejecutan los MLA en entornos SIG. Los MLA, tienen una amplia gama de opciones que cambian en función del objetivo que se persigue en el análisis, por ejemplo: maximizar la cobertura, minimizar la impedancia, maximizar la asistencia, minimizar las instalaciones, entre otros.

También se emplean los SIG para la representación cartográfica de los resultados, además, de otros programas como Excel, Python y Rstudio, para la confección de los

gráficos, con la finalidad de obtener visualizaciones de los resultados que puedan transmitir la información a personas no expertas en la temática.

7. *Establecer y desarrollar las tareas previas de tratamiento y depuración de los datos de demanda seleccionados para su incorporación en MLA en entornos SIG.*

Es necesario considerar que los datos provenientes de Big Data requieren una serie de tratamientos previos para eliminar algunos problemas que tengan, ya sea al momento del almacenamiento o debido a defectos en los dispositivos recolectores. Así pues, para disponer de datos de calidad, es necesario un intenso trabajo de preproceso de datos previo.

En primer lugar, se debe realizar el proceso de descarga de los datos. A continuación, hay que limpiarlos eliminando los registros en blanco y los errores de coordenadas. Luego, los datos deben transformarse a formatos geospaciales para su posterior manipulación en programas SIG. Para el planteamiento de los modelos de localización-asignación se tendrán en cuenta diferentes tipos de datos que poseen entre sus atributos variables temporales que permiten incorporar el dinamismo de la población.

8. *Implementar diferentes aplicaciones prácticas para el desarrollo de MLA que incorporen la componente temporal con el fin de experimentar el dinamismo en la oferta, la demanda y la red.*

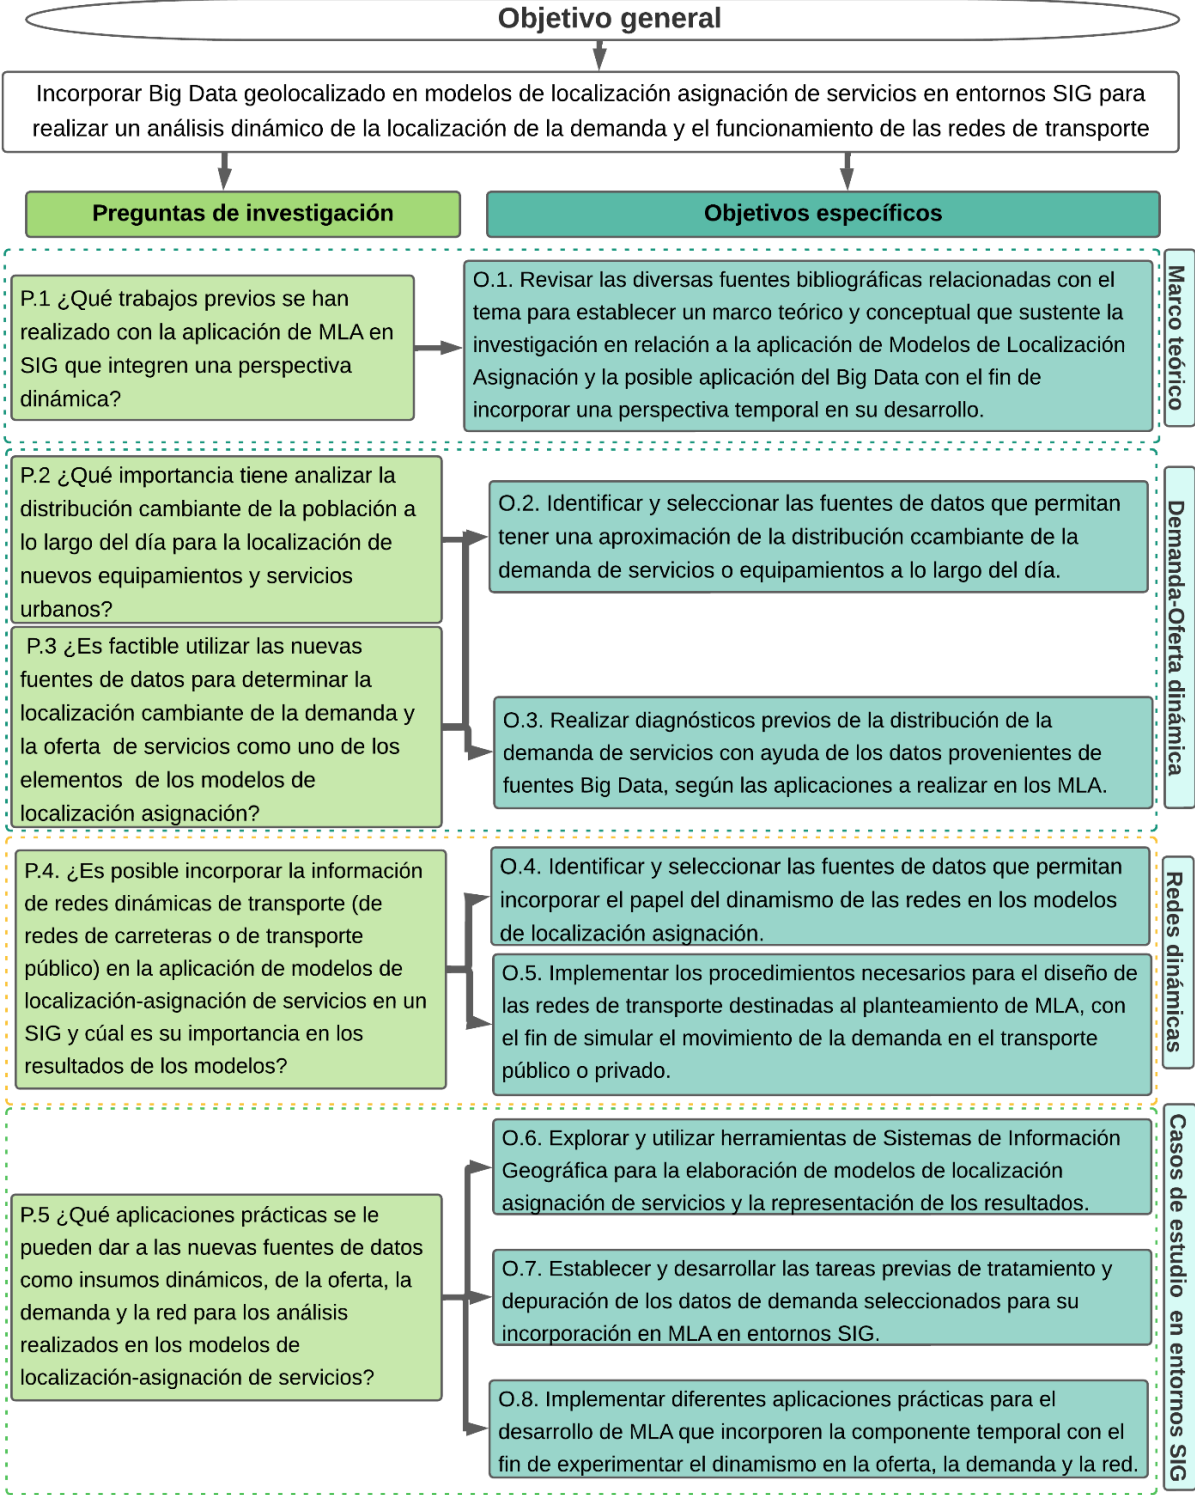
La disponibilidad de fuentes de Big Data se traduce en la oportunidad de presentar una perspectiva dinámica, espacio-temporal, en los enfoques de los MLA. En este sentido, se exploran diversas aplicaciones para localizar las instalaciones que se ofrecen a los usuarios.

Primero, se van a plantear casos en los que solo la red tiene componente dinámico, mientras que la oferta y la demanda son estáticos. En otras aplicaciones, se incorpora el dinamismo en los datos de oferta y demanda, pero se utiliza la red sin información temporal. Por último, se desarrolla un modelo que intenta incluir un componente dinámico temporal en los tres datos de entrada, es decir, que la oferta, la demanda y la red incluyan propiedades cambiantes a lo largo del día.

En definitiva, la introducción de componentes dinámicos, en los datos de entrada del MLA, repercute en la ubicación de las instalaciones que dependerán, en gran medida,

de la distribución temporal de la demanda, de las condiciones de congestión de la red y las frecuencias del transporte público. La Figura 1, ilustra la relación entre los objetivos y las preguntas de investigación planteadas en la tesis.

Figura 1. Relación entre objetivos y preguntas de investigación



Fuente: Elaboración propia.

## 1.4 Estructura de la tesis

Esta investigación se organiza en cinco capítulos. El primer capítulo presenta la introducción de la tesis, donde se explica el interés y la oportunidad de la investigación, las preguntas de investigación a las que se trata de dar respuesta y los objetivos generales y específicos que guiarán el estudio. También se describe la estructura de la tesis.

El segundo capítulo contiene el marco teórico de la investigación. Luego de una revisión de la literatura existente, se exponen los antecedentes del tema. En el mismo se explica la evolución de los modelos de localización-asignación (MLA). Se presentan los conceptos y los cambios, que implementan distintos autores, para cada una de las soluciones existentes en los MLA. Señalamos los datos de entrada que requieren los MLA. Se describen las investigaciones que explican cómo se obtienen los sitios candidatos y la demanda. Con respecto a la demanda analizamos las diversas maneras de agregación espacial aplicadas en los trabajos revisados. Además, abordamos aspectos relacionados con la red empleada en los planteamientos. También, se presentan las categorías y los objetivos de las instalaciones, clasificadas en equipamientos deseables y no deseables. Abordamos los tipos de soluciones utilizadas en los planteamientos de los modelos de localización-asignación y los campos de aplicación en entornos SIG. Finalmente, en este capítulo se informa de las oportunidades que ofrece la investigación y las posibles aportaciones a realizar en este campo de estudio.

En este apartado de revisión bibliográfica también se hace referencia al Big Data y a las nuevas fuentes de datos, desarrollándose las generalidades del Big Data, en especial del geolocalizado, destacando sus fortalezas e inconvenientes. Además, aborda las nuevas redes de transporte generadas a partir de los archivos GTFS y los datos de TomTom. Al mismo tiempo evalúa las nuevas fuentes de localización de la demanda.

El tercer capítulo detalla el área de estudio, los datos y la metodología utilizadas. En este apartado se describen las fuentes de datos empleadas para el desarrollo de la investigación. Una primera fuente son los registros GPS de los viajes realizados por los usuarios de las motos eléctricas de la empresa Muving. Otra fuente son los registros GPS recolectados por el Servicio de Asistencia Municipal de Urgencia y

Rescate Protección Civil de Madrid (SAMUR-PC). Como última fuente de datos, las nuevas redes (GTFS y TomTom) empleadas en el planteamiento de los modelos. Además, se detallan otras fuentes de datos tradicionales consideradas en la tesis. Todos estos conjuntos de datos están delimitados dentro de la ciudad o el área metropolitana de Madrid. Finalmente, este capítulo describe la metodología seguida. Detalla el proceso para la limpieza de los datos y su posterior tratamiento con el programa ArcMap 10.6. En el caso de las redes de transporte se explican los procedimientos seguidos para su diseño. También, presenta los modelos de localización-asignación en entornos SIG. Por último, resume las herramientas SIG empleadas para el análisis de los datos y la visualización de los resultados.

El cuarto capítulo plantea las aplicaciones prácticas a los modelos de localización-asignación con enfoque dinámico en sus datos de entrada. Se plantean los casos con demanda fija y las redes dinámicas, en otros la demanda variable y las redes estáticas; y los modelos con demandas variables y las redes dinámicas.

En el primer caso de estudio, se incorpora el dinamismo en la red a partir de los datos GTFS y TomTom. Se propone evaluar el impacto de los cambios de la frecuencia del transporte público y de la congestión sobre la población cubierta por los hospitales y centros comerciales, durante diferentes horas de un día de la semana y fin de semana. Además, se han utilizado distintas soluciones en los MLA.

El segundo caso desarrollado se refiere a los modelos con demanda variable y redes estáticas. En este modelo, el objetivo consiste en encontrar los mejores sitios para estacionar las motocicletas eléctricas de una empresa de micromovilidad. Para ello se analiza, a partir de registros GPS, la distribución de la demanda de viajes en tres franjas temporales y se evalúa el impacto de los cambios de la demanda durante el día.

El último caso de estudio se aplica a un servicio de emergencias. A partir de las coordenadas GPS de los sucesos atendidos por este servicio, se busca la mejor ubicación para estaciones de ambulancias. Para ello se realiza un análisis temporal de los datos. En este sentido, los datos se dividen en sucesos atendidos en los días laborables y los fines de semana, considerando tres franjas horarias. Además, se efectúan los modelos con estas franjas horarias, tanto para el año 2019, como el 2020. A fin de comparar el servicio de emergencia antes y durante el COVID-19.

El quinto capítulo contiene las conclusiones que pueden extraerse de la investigación. Se ofrecen probables respuestas a las distintas preguntas de la investigación. Asimismo, se presentan sugerencias para futuros estudios derivados de la realización de esta tesis. Tales estudios ayudarán a ampliar el conocimiento sobre el uso de Big Data, en los datos de entrada requeridos, para aplicar los modelos de localización-asignación con un enfoque dinámico.

## 1.5 Publicaciones y Congresos.

Algunos de los métodos y resultados de la tesis se han difundido a través de artículos y congresos científicos:

- Artículos:

1. Pérez-Fernández, O. A. and García-Palomares, J.C. (2021) ***Parking Places to Moped-Style Scooter Sharing Services Using GIS Location-Allocation Models and GPS Data***. International Journal of Geo-Information, 10, 230 [JCR Impact factor: 3.099, Q2] <https://doi.org/10.3390/ijgi10040230>
2. Pérez-Fernández, O. A. (2021). ***Modelos de localización asignación utilizando redes dinámicas a partir de ficheros GTFS y datos de TomTom***. GeoFocus, Revista Internacional de Ciencia y Tecnología de la Información Geográfica, 28, 59–81 [JCR, Q4]. <http://dx.doi.org/10.21138/GF.751>
3. Pérez-Fernández, O. P. and Moya-Gómez, B. (2023) ***Modelos de localización-asignación para evaluar el rendimiento espacio-temporal del servicio de emergencias de Madrid***. Boletín de la Asociación Española de Geografía, 96 [JCR, Q3 y SJR 2020 0.37, Q2]. <https://doi.org/10.21138/bage.3247>

- Congresos y eventos:

1. Pérez-Fernández, O. A. and García-Palomares (2018). ***Estacionamientos para servicios de motocicletas compartidas a partir de modelos de localización-asignación SIG y datos GPS***. IX Jornadas de Geografía Económica-VII Congreso del grupo de Estudios Regionales-IX Congreso de Geografía de los servicios, Madrid 6-7 de mayo de 2021.
2. Pérez-Fernández, O. A. (2021) ***Modelos de localización-asignación utilizando redes dinámicas a partir de ficheros GTFS y datos de TomTom***.

XXVII Congreso de la Asociación Española de Geografía, San Cristóbal de La Laguna 14-17 de diciembre 2021.

3. Pérez-Fernández, O. A. (2021) ***Análisis espacio temporal y localización óptima de servicios de emergencia usando SIG y registros GPS.*** Conferencia de usuarios de ESRI España, Madrid 18-22 de octubre de 2021.
4. Pérez-Fernández, O. A. (2021). ***Big data y modelos de localización óptima de servicios*** VI PhDay Facultad de Geografía e Historia de la Universidad Complutense de Madrid, 4-5 de octubre de 2021.
5. Pérez-Fernández, O. A. (2021) ***Big Data geolocalizada: oportunidades para la investigación en Geografía. Seminario de actualización geográfica. Geografía: una ciencia de múltiples facetas en un mundo cambiante.*** Universidad de Panamá, Veraguas 23-26 de noviembre 2021.

## **2 MARCO TEÓRICO**

## **2.1 Modelos de localización-asignación de equipamientos o servicios**

Los MLA son utilizados para buscar los mejores sitios donde ubicar nuevas instalaciones de equipamientos o servicios. Elegir el lugar óptimo para la ubicación de un equipamiento o un determinado negocio es de interés y preocupación para la administración pública y privada (Frade & Ribeiro, 2015; Namazian & Roghanian, 2019).

Estos modelos son de gran ayuda en la planificación de una gran diversidad de instalaciones, por lo general, pensando en el bienestar de la población servida. Para ello se toma en cuenta la mejor distribución de la demanda con respecto a un conjunto de instalaciones candidatas, es decir, que la demanda que sea asignada debe considerar los parámetros de impedancia al desplazamiento, tales como la distancia más corta o el menor tiempo recorrido. Los modelos también pueden permitir la incorporación de la capacidad para realizar el servicio de la instalación, entre otras restricciones (Lei et al., 2016). En definitiva, los MLA seleccionan los sitios candidatos para una instalación en base a una función objetivo que trata de optimizar la distribución de la demanda a los puntos elegidos (Fotheringham et al., 1995). Además, los MLA ayudan a conocer la cantidad de demanda asignada a los puntos elegidos y la distancia desde el lugar de demanda hasta ese punto de oferta asignado.

Así lo señalan Buzai & Baxandale (1995), cuando dicen que los MLA intentan evaluar las ubicaciones actuales, de los equipamientos, sobre la base de la distribución de la demanda y generar alternativas para lograr una distribución espacial más eficiente y/o equitativa. Ellos buscan las ubicaciones óptimas (localización) y determinan las mejores vinculaciones de la demanda (asignación). El problema de los MLA consiste en ubicar un conjunto de nuevas instalaciones, de manera que, se minimice el coste de transporte de los equipos a los clientes. A su vez, un número óptimo de instalaciones tiene que estar ubicado en una zona en la que satisfaga la demanda de los usuarios (Azarmand & Neishabouri, 2009).

Desde la década de los años 60, se han estado desarrollando MLA, tanto desde un punto de vista teórico como de aplicaciones prácticas (Austin, 1974; McAllister, 1976; ReVelle & Swain, 1970). A inicios de la década de los años 90, se comenzó a emplear los MLA haciendo uso de la tecnología SIG (Densham, 1991).

En este sentido, Church (1999) describe parte de la evolución de los modelos de localización apoyados en los SIG. Además, consideran que los Sistemas de Información Geográfica tienen un impacto, significativo, en la aplicación de los modelos de localización, ya que proporcionan una mejor forma de organizar los datos espaciales y la posibilidad de observar los resultados mediante mapas. Por su parte, Murray (2010) explica la contribución de los SIG, a la ciencia de la localización, en términos de entrada de datos, visualización y resolución de problemas. También, afirma que el espacio geográfico representa uno de los principales componentes en la toma de decisiones, por lo que destaca la importancia de los SIG en cuanto a la manipulación y la observación de los resultados.

Con respecto al espacio geográfico, Church & Murray (2009) enuncian tres leyes básicas que se dan en la localización de un equipamiento, estableciendo que: 1) algunas localizaciones son mejores que otras; 2) la eficiencia de una localización se puede ver alterada por el contexto espacial; 3) los emplazamientos de un patrón espacial, con múltiples instalaciones, deben ser seleccionados, simultáneamente, en vez de hacerlo de forma independiente unos de otros.

Los estudiosos de los modelos de localización han desarrollado un amplio número de algoritmos y metodologías. Específicamente, esta tesis se centra en los modelos de localización desarrollados en entornos SIG. Dado que los SIG proporcionan una mejor visualización de los resultados obtenidos con los modelos (Revelle & Eiselt, 2005).

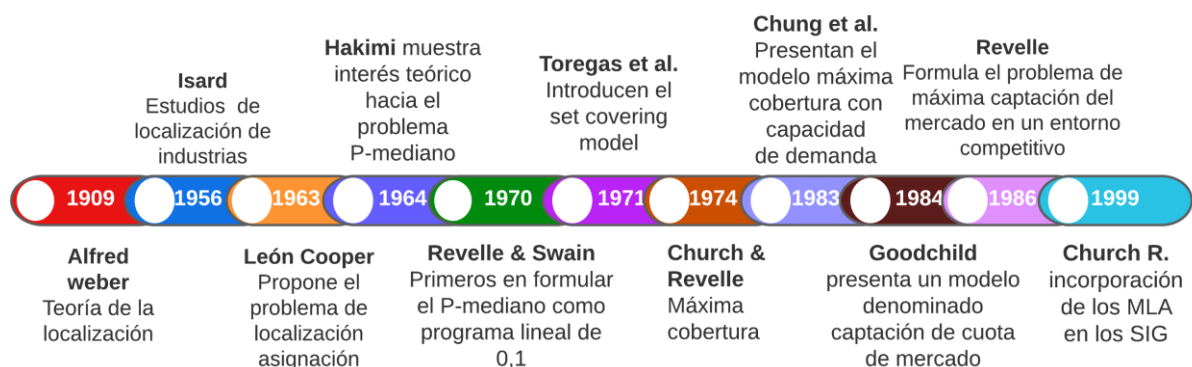
Los MLA suelen aplicarse en función de los distintos objetivos que se persiguen con la nueva instalación de servicio; es decir, si están relacionados con la eficiencia o la equidad. Las soluciones que apuntan a la eficiencia son las que buscan el mínimo número de instalaciones, teniendo en cuenta que todos los lugares de demanda se cubren en una distancia o tiempo predeterminados. Ejemplos de estas soluciones son: maximizar la cobertura, minimizar las instalaciones, maximizar la cuota de mercado, maximizar la asistencia. Mientras tanto, las soluciones que tienden a la equidad espacial se centran en garantizar que la demanda no esté demasiado alejada de los puntos de suministro. Esto permite condiciones de acceso razonables, para la mayoría de la población. Un ejemplo de este tipo de solución es la conocida como minimización de la impedancia. Todas estas soluciones se tratarán, en apartados de la tesis, más adelante. Se describirá el enunciado y la ecuación matemática de cada una.

### 2.1.1 Evolución de los modelos

Estos modelos han sido ampliamente estudiados desde los años sesenta (Cooper, 1963; Ghosh & Rushton, 1987; L. J. Hakimi, 1964; ReVelle & Swain, 1970; Scott, 1970). Rahman & Smith (2000) sostienen que los MLA son modelos matemáticos, empleados para identificar la ubicación óptima de los equipamientos, basándose en un conjunto de variables definidas. Esto implica la selección, simultánea, de un conjunto de ubicaciones para las instalaciones y la asignación de la demanda repartida, espacialmente, entre las instalaciones, según criterios predefinidos.

En este apartado presentamos algunos de los MLA incorporados como módulos de análisis espacial en la mayoría de los softwares de SIG, pero estas soluciones tienen un desarrollo matemático anterior. En este sentido, la Figura 2 muestra una línea de tiempo que describe la evolución teórica de los MLA. Hakimi en el año 1964, empieza a mostrar interés en los problemas de localización y propone el modelo P-mediano o de minimización de la impedancia. Su finalidad consiste en encontrar la ubicación de un determinado número de centros, que minimicen la distancia total o el tiempo de viaje desde todos los puntos de demanda. Dicho modelo es mejorado en el año 1970 por ReVelle & Swain. Durante la década de los noventa, se presentan investigaciones que buscan validar el método P-mediano y el de máxima cobertura; además, se exponen las problemáticas que pueden surgir, al momento de utilizar los datos al integrarlos a un Sistema de Información Geográfica, tales como la representación de la demanda, la definición de la zona y de los posibles errores (Church, 1999; Fotheringham et al., 1995; Yeh & Chow, 1996).

Figura 2. Evolución de los MLA



Fuente: Elaboración propia.

Por otro lado, Toregas et al. (1971), introducen el modelo de la cobertura del conjunto (Set Covering Problem). La solución consiste en elegir el mínimo número de instalaciones que permitan cubrir todos los sitios de demanda en una determinada distancia de servicio. En el año 1974, los autores Church & ReVelle desarrollan un MLA conocido como máxima cobertura. Este modelo procura alcanzar la máxima cantidad de población atendida dentro de una distancia o tiempo de acceso al servicio. Para ello, disponen de un número limitado de instalaciones. Debido a la sencillez de su funcionamiento y a su utilidad para numerosos servicios y equipamientos dicho modelo ha sido el más utilizado. Es el modelo de referencia, por ejemplo, a la hora de encontrar la mejor ubicación de los equipamientos de servicios de emergencias, que deben llegar a la demanda del servicio en un determinado umbral de tiempo de respuesta.

Más tarde, Chung et al. (1983) modifican el modelo de máxima cobertura y le agregan una restricción relacionada a equipamientos con límite de capacidad de atención de demanda, dando origen al modelo conocido como máxima cobertura con restricción de capacidad. El modelo pretende maximizar la cantidad de demanda cubierta con un número fijo de instalaciones, de manera que la demanda asignada a cada instalación no supere su capacidad de servicio (Pirkul & Schilling, 1989).

Por otra parte, Goodchild (1984) y ReVelle (1986), formulan modelos que incluyen condiciones de competencia entre los equipamientos candidatos, los cuales denominaron modelos de máxima captación de mercado, en un entorno competitivo. La función objetivo de estos modelos se especializa en maximizar la demanda total asignada a las localizaciones elegidas o alcanzar una determinada cuota de mercado en relación con los competidores, partiendo de la base, de que se conocen las ubicaciones y las características de los equipamientos de los competidores.

Los MLA presentados anteriormente fueron los más empleados en las investigaciones iniciales, pero con el transcurrir de los años se han ido realizando modificaciones o mejoras para adaptarlos a diferentes problemas de localización, en función del tipo de servicio o equipamiento a desarrollar.

Así con el desarrollo de la tecnología se comienza a incorporar los MLA en los programas de SIG (Church, 1999). En esta línea, Murray (2010), realiza un estudio evolutivo de la ciencia de la localización que describe con detalle los trabajos

realizados sobre modelos de localización. Además, involucra los Sistemas de Información Geográfica como una herramienta que permite efectuar análisis espaciales y visualizar los resultados de los modelos de localización y que pueden ser aplicados a numerosas actividades, como los servicios financieros, las torres de teléfonos, al establecimiento de franquicias, entre otros. Estos modelos, con el apoyo de los SIG, pueden ayudar a conseguir otros objetivos. En esta línea, más adelante, en el apartado sobre aplicaciones de los MLA, se presentarán los estudios de casos de algunos autores que han implementado los MLA incorporados en programas SIG.

Brandeau & Chiu (1989) y Hale & Moberg (2003) presentan una revisión de aquellas investigaciones realizadas sobre los modelos de localización, en ellas se recopila de manera detallada (por años y autor) el tipo de problema utilizado, el método y el tipo de instalación. Las revisiones de Brandeau & Chiu (1989); Reville & Eiselt (2005); Scott, (1970); Serra & Marianov, (2002) y Xu et al.(2018), recopilan los diferentes MLA que se han utilizado y las diversas aplicaciones que se han dado en el sector público y privado, donde se muestran las formulaciones que fundamentan los MLA, tomando en cuenta la función del objetivo que se buscaba resolver. Igualmente, se encuentran trabajos que revisan los MLA que se basan en el tipo de servicio al que se busca la mejor ubicación. Es el caso de la revisión realizada por Farahani et al., (2012a), quienes explican, detalladamente, los diferentes modelos de cobertura y todas las variaciones que se derivan de estos; al igual exponen la diversidad de casos en los que se ha aplicado.

Por otra parte, Plastria (2001) pone la atención en los modelos de mercado competitivo. Proporciona una visión general de los problemas de optimización. Se centra en aquellos que tratan de ubicar una nueva instalación en un entorno, donde ya existen establecimientos competidores. Mientras, Daskin (2008), revisa y presenta una clasificación general de los diferentes MLA, donde explica los diversos algoritmos que existen. Se centra en aquellos que clasifica como modelos de localización discreta. Incluyendo, en esta clasificación, aquellos modelos que buscan maximizar la cobertura o minimizar impedancia. Finalmente, el trabajo realizado por Ramírez & Bosque Sendra (2001), plantea algunos aspectos conceptuales de los MLA, tales como: la oferta, la demanda y la red. Además, elaboran dos modelos, en los cuales se utilizaron datos, en formato ráster y vectorial. Cada uno poseía características

distintas, estos fueron aplicados para encontrar la ubicación óptima de los servicios de salud.

Existen otros trabajos que han aplicado los diversos MLA en la búsqueda de una determinada función objetivo. La Tabla 1, muestra un listado de publicaciones que han sido agrupadas basándose en: el tipo de sector (público o privado), el tipo de solución aplicada o el tipo de instalaciones. De acuerdo con el tipo de solución, se puede apreciar que el modelo de máxima cobertura es el más utilizado en los diversos casos de estudio.

Entre los autores que aplican la solución maximizar cobertura se encuentran, por ejemplo, Chuang & Lin, (2007), Erdoğan et al. (2010) o Repede & Bernardo (1994) que todos desarrollaron MLA destinados a encontrar los lugares más adecuados para servicios de emergencia médica. Repede & Bernardo (1994) integran el modelo en un sistema de apoyo a las decisiones, para ayudar a los planificadores a evaluar alternativas para localizar las estaciones de ambulancias del sistema de emergencias de Louisville Kentucky. Proponen incrementar el número de vehículos para determinar el aumento de los niveles de atención. Además, plantea su ubicación en zonas donde se producen sucesos extraordinarios. Por su parte, Chuang & Lin (2007) señalan la posibilidad que la capacidad del servicio de urgencias se vea afectada debido a factores como: el tamaño de la flota, su localización y la probabilidad de que las unidades estén ocupadas en el momento de la intervención. Mientras que Erdoğan et al. (2010) abordan el problema de dos maneras. En primer lugar, se refieren a la distribución del horario para el personal del cuerpo de urgencia, a lo largo de un periodo de planificación. En segundo lugar, consideran el reparto de vehículos por regiones geográficas.

Tabla 1. Resumen de estudios aplicando MLA casos públicos/privados

Autores	Título	Aplicación	Solución	Sector
(Toregas et al., 1971)	The location of emergency services facilities	Servicio de emergencia	Minimizar instalaciones	Privado
(Richard et al., 1990)	The location of fire stations in a rural environment: a case study	Servicio de emergencia	P-mediano	Público

(Pastor, 1994)	Bicriterion Programs and Managerial Location Decisions: Application to the Banking Sector	Bancos	Máxima cobertura	Privado
(Repede & Bernardo, 1994)	Developing and validating a decision support system for locating emergency medical vehicles in Louisville, Kentucky	Servicio de emergencia	Máxima cobertura	Privado
(Yeh & Chow, 1996)	An integrated Gis and location-allocation approach to public facilities planning - An example of open space planning	Parques	P-mediano	Público
Ribeiro & Antunes (2002)	A Gis based decision support tool for public facility planning	Salud	Pmediano y máxima cobertura	Público
(Min & Melachrinoudis, 2001)	The Three-Hierarchical Location-Allocation of Banking Facilities with Risk and Uncertainty	Bancos	Maximizar mercado compartido	Privado
(Miliotis et al., 2002)	A Hierarchical Location Model for Locating Bank Branches in a Competitive Environment	Bancos	Máxima cobertura	Privado
(Serra & Marianov, 2002)	New trends in Public Facility Location Modeling	Servicio de emergencia	P-mediano	Público
(Kanakoglou et al., 2005)	Establishing an air pollution monitoring network for intra-urban population exposure assessment: A location-allocation approach	Sensores	P-Mediano/ maximizar asistencia	Público
(Chuang & Lin, 2007)	A maximum expected covering model for an ambulance location problem	Servicio de emergencia	Máxima cobertura	Privado

(Teixeira & Antunes, 2008)	A hierarchical location model for public facility planning	Escuela	P-Mediano	Público
(Murray, 2010)	Advances in location modeling: GIS linkages and contributions	Gis		
(G. Lee & Murray, 2010)	Maximal covering with network survivability requirements in wireless mesh networks	Red wifi	Máxima cobertura	Privado
(Erdoğan et al., 2010)	Scheduling ambulance crews for maximum coverage	Servicio de emergencia	Máxima cobertura	Público
( Li et al., 2011)	Covering models and optimization techniques for emergency response facility location and planning: A review	Servicio de emergencia	Máxima cobertura	Público
(García-Palomares et al., 2012)	Optimizing the location of stations in bike-sharing programs: A GIS approach	Bases de bicicletas	Máxima cobertura	Público
(Shariff et al., 2012)	Location allocation modeling for healthcare facility planning in Malaysia	Salud	Máxima cobertura	Público
(Zhang et al., 2013)	Spatial Location-Allocation Modeling of Bike Sharing Systems: A Literature Search	Bicicletas	Máxima cobertura, P-mediano	Privado
(Ajebon & Asikhia, 2013)	Geographical Analysis of Smoking in Leeds: A GIS-Based Location-Allocation Technique for the Optimal Location of Smoking Cessation Services	Centros para no fumadores	Máxima cobertura, P-mediano	Público

(Guo & Qi, 2014)	Modeling and Simulation of Emergency Service Facilities Location Problem Under Fuzzy Environment	Servicio de emergencia	Minimizar instalaciones	Público
(Beheshtifar & Alimoahmadi, 2015)	A multiobjective optimization approach for location-allocation of clinics	Salud	Pmediano	Privado
(Berry et al., 2016)	Sensor Placement in Municipal Water Networks with Temporal Integer Programming Model	Sensores	Pmediano	Público
(Giménez-Gaydou et al., 2016)	Optimal location of battery electric vehicle charging stations in urban areas: A new approach	Estaciones de recarga eléctrica	Maximizar cobertura	Privado
(Yang et al., 2017)	A data-driven optimization-based approach for siting and sizing of electric taxi charging stations	Recarga eléctrica	Máxima cobertura	Privado
(Özceylan et al., 2017)	Optimizing the location-allocation problem of pharmacy warehouses: A case study in Gaziantep	Salud	P-mediano	Privado
(Malik & Shivamallu, 2017)	Location-Allocation model applied to urban public services: Spatial analysis of fire stations in Mysore urban area Karnataka, India	Servicio de emergencia	Máxima cobertura	Público
(Radaković, 2017)	Utilizing Geographic Information System (GIS) for determining new locations of post office in Novi Sad, Serbia	Oficinas postales	Maximizar cobertura	Público

(Rodríguez et al., 2017)	Application of geographical information systems for the optimal location of a commercial network	Red comercial	P-mediano/Maximizar mercado	Privado
(Erfani et al., 2018)	Using applied operations research and geographical information systems to evaluate effective factors in storage service of municipal solid waste management systems	Contenedores de basura	Minimizar instalaciones, maximizar cobertura y maximizar la asistencia	Público
(Bolouri et al., 2018)	The Ordered Capacitated Multi-Objective Location-Allocation Problem for Fire Stations Using Spatial Optimization	Servicio de emergencia	P-mediano	Público
(Berman et al., 2018)	Reconfiguring a set of coverage-providing facilities under travel time uncertainty	Servicio de emergencia	Máxima cobertura	Público
(Metek et al., 2018)	Location and coverage analysis of bike-sharing stations in university campus	Bicicletas	Máxima cobertura	Público
(Fredriksson et al., 2019)	Analyzing the spatial distribution of public services: Political effects, misallocation, and welfare	Oficinas	P-mediano	Público
(Chukwuma, 2019)	Facility location allocation modelling for bio-energy system in Anambra State of Nigeria: Integration of GIS and location model	Plantas de bioenergía	Minimizar instalaciones	Público
(Shan et al., 2019)	Optimization of competitive facility location for chain stores	Cadena de tiendas	Mercado compartido	Privado

(Abdelkarim, 2019)	Integration of location-allocation and accessibility models in GIS to improve urban planning for health services in Al-Madinah Al-Munawwarah, Saudi Arabia	Salud	Máxima cobertura	Público
(ÖZKAN et al., 2019)	Gis-Based Maximum Covering Location Model in Times of Disasters: The Case of Tunceli	Refugios/desastres	Maximizar cobertura con capacidad	Público
(El-Hallaq & Mosabeh, 2019)	Optimization of Municipal Solid Waste Management of Bins Using GIS. A Case Study: Nuseirat City	Rellenos sanitarios	Maximizar cobertura	Público
(Rahman & Smith, 2000)	Use of location-allocation models in health service development planning	Salud	P-mediano	Público
(Tassone & Choudhury, 2020)	A comprehensive survey on the ambulance routing and location problems	Servicio de emergencia	Máxima cobertura	Público
(Ngowi & William, 2020)	Geospatial Location-Allocation Approach to Optimize Healthcare Facilities in Peri-Urban dwellers in Mbeya City, Tanzania	Salud	Máxima cobertura	Público
(Banerjee et al., 2020)	Optimal locations for bikeshare stations: A new GIS based spatial approach	Bicicletas	Maximizar mercado compartido	Público
(L. Zhou et al., 2020)	A multi-factor spatial optimization approach for emergency medical facilities in Beijing	Servicio de emergencia	Máxima cobertura/P-mediano	Público

(Al-Sabbagh, 2020)	GIS location-allocation models in improving accessibility to primary schools in Mansura city-Egypt.	Escuelas	Máxima cobertura/P-mediano	Público
(Yu et al., 2020)	Fire stations siting with multiple objectives and geospatial big data	Servicio de emergencia	Máxima cobertura	Público
(Taiwo, 2021)	Maximal covering location problem for nuclear medicine clinics allocation in Nigeria	Salud	Máxima cobertura	Público
(Norheim et al., 2021)	A geospatial decision support tool for suitable location of monitoring stations in urban areas	Sensores	Maximizar cobertura/Minimizar instalaciones	Público
(Rizeei et al., 2019)	Allocation of emergency response centers in response to pluvial flooding-prone demand points using integrated multiple layer perceptron and maximum coverage location problem models	Servicio de emergencia	Máxima cobertura	Público
(Rahman et al., 2021)	Location-allocation modeling for emergency evacuation planning with GIS and remote sensing: A case study of Northeast Bangladesh	Servicio de emergencia	Máxima cobertura/P-mediano	Público
(Amato et al., 2021)	Geographic Coverage and Verification of Trauma Centers in a Rural State: Highlighting the Utility of Location Allocation for Trauma System Planning	Salud	Máxima cobertura	Público

Fuente: Elaboración propia.

Por otro lado, se encuentran publicaciones que aplican la solución de maximizar cobertura para evaluar los otros tipos de servicios de emergencias. Tal es el caso de los servicios de bomberos, como las investigaciones de Malik & Shivamallu (2017) o Yu et al. (2020). En particular, Yu et al. (2020) desarrollan un modelo de localización multiobjetivo. logrando estimar, con precisión, la demanda de rescate en situaciones de incendios y los costes de viaje. Su trabajo lo plantean en Nanjing (China), y los resultados muestran que el método resulta eficaz para optimizar la ubicación de las estaciones de bomberos. En concreto, emplean el historial de incidentes para calcular la variación espacial del peligro de incendio (demanda), que es fundamental para identificar las zonas de alto riesgo en la ciudad. En su planteamiento establecen un umbral de 5 minutos para definir las áreas de servicio. Por otro lado, el estudio desarrollado en Mysoure (India), por Malik & Shivamallu (2017) propone un enfoque basado en el SIG para analizar el rendimiento del parque de bomberos utilizando su infraestructura actual. Se detectan los sitios cubiertos y aquellos en los que el sistema de urgencias es ineficaz.

Con respecto a las aplicaciones de los modelos de localización implementados dentro de la temática de salud, se encuentran una diversidad de estudios (Tabla 1). La mayoría de estos emplean nuevamente la solución máxima cobertura para encontrar la ubicación óptima de hospitales y clínicas (Ajebon & Asikhia, 2013; Ribeiro & Antunes, 2002; Shariff et al., 2012). Ribeiro & Antunes (2002) proponen crear una herramienta SIG para el apoyo en la toma de decisiones en materia de instalaciones de salud. Para ello combinan las capacidades de los SIG con avanzados métodos de optimización en un programa informático que llamaron MapFL. También Shariff et al. (2012) plantean un modelo, en entornos SIG, para examinar el porcentaje de población cubierta por una red de hospitales. Los centroides de las secciones censales representan la población, utilizada como demanda del servicio, y eligen para candidatos a los actuales hospitales. Comparan su ubicación actual y evalúan una posible ampliación del número de estos. Por su parte, Ajebon & Asikhia (2013) pretenden encontrar lugares más adecuados para las unidades terapéuticas destinadas a rehabilitar a fumadores. Identifican las zonas geográficas donde se produce la mayor concentración de consumidores de cigarrillos en la ciudad de Leeds, Reino Unido, mediante el análisis de autocorrelación de Moran. Los resultados demuestran que la mayoría de los sitios de rehabilitación están concentrados en la

zona central del área estudiada. Ngowi & William (2020) analizan la accesibilidad a los centros hospitalarios en la urbe de Mbeya (Tanzania, África) y recomiendan las ubicaciones óptimas de los nuevos centros hospitalarios. En su enfoque ocupan datos del censo y de la red hospitalaria. Los hallazgos revelan que la mitad de los habitantes no tiene acceso a un hospital en una distancia de 5 km.

Otra aplicación habitual de los modelos de localización en entornos SIG es ubicar los lugares de gestión y tratamiento de los residuos sólidos. En este sentido, Erfani et al. (2018) proponen localizar los sitios donde colocar los contenedores para el depósito de los desechos y averiguar qué porcentaje de la demanda se destina a cada uno. Por último, aplican un análisis de la zona cubierta para definir la cantidad de población a la que se presta servicio, en un radio de acción reducido. En la misma línea de investigación anterior, El-Hallaq & Mosabeh (2019) ocupan los MLA con el fin de optimizar la ubicación de los receptores de basura y determinar la mejor ruta para su recogida. Los resultados indican que es necesario redistribuir algunos de los receptores de residuos, ya que muchas zonas quedan fuera de la cobertura del sistema de limpieza. En su estudio, la demanda procede de los edificios, mientras que las ubicaciones actuales de los recipientes se utilizan como candidatas.

Los MLA, a partir de la solución de maximizar cobertura, también resultan útiles para ubicar otros tipos de servicios e instalaciones. Por ejemplo, los MLA han servido para localizar estaciones de bicicletas (Banerjee et al., 2020; García-Palomares et al., 2012; Mete et al., 2018; Zhang et al., 2013), bancos (Miliotis et al., 2002), oficinas de correos, (Radaković, 2017), puntos de carga eléctrica de vehículos (Giménez-Gaydou et al., 2016), entre muchas otras aplicaciones.

En el caso de las estaciones para el servicio de bicicletas compartidas, Mete et al. (2018) tiene como objetivo determinar los posibles sitios donde ubicarlas dentro de un campus universitario. Su planteamiento está diseñado para abarcar el mayor número de estudiantes. Utiliza los apartamentos, los dormitorios y la cafetería, en calidad de puntos de interés, al ser, estos, los lugares más frecuentados por los universitarios. También, toma en cuenta varios umbrales de distancia para comparar los resultados. Por otro lado, García-Palomares et al. (2012) proponen una metodología basada en la distribución espacial de los potenciales usuarios de viajes, estiman su capacidad y definen las características de la demanda de estas.

Otra solución utilizada en los MLA es la conocida como minimización de la impedancia o p-mediana. Se ha empleado para localizar servicios educativos (Al-Sabbagh, 2020; Teixeira & Antunes, 2008), parques (Yeh & Chow, 1996) sensores (Kanaroglou et al., 2005), farmacias (Özceylan et al., 2017), y otras instalaciones más. El trabajo de Al-Sabbagh (2020) trata de analizar la distribución geográfica de las escuelas y propone la creación de nuevas. Diseña escenarios donde evalúa la ubicación actual, y luego sugiere una redistribución, comparando los indicadores estadísticos de los diferentes modelos. El alumnado potencial se genera a partir de centroides extraídos de complejos residenciales y sus candidatos se obtienen con la localización de los colegios actuales. Teixeira & Antunes (2008) desarrollaron un modelo orientado a minimizar la distancia recorrida por los estudiantes hacia los centros educativos. Este modelo contempla varios niveles de demanda en función del tipo de escuela. Para desarrollar su modelo emplean los programas XPRESS Mosel 1.4 y Arcview 3. Su metodología se utilizó para resolver un problema real de la planificación escolar en el municipio de Coimbra, Portugal.

Por otro lado, el trabajo de Yeh & Chow (1996) trataba de identificar los mejores lugares para construir un parque. Para ello utilizaron el lenguaje de programación C++ y el programa ARC/INFO, ya que exportan los resultados a un entorno de SIG. Extrae los centroides a cada eje de la calle, los cuales se consideran puntos de demanda ponderados con un campo de población. También, aparecen publicaciones sobre la localización de sensores para el control de la calidad del aire en los centros urbanos. Utilizan información relacionada con el uso del suelo, los habitantes y con los sensores que están colocados en sitios estratégicos para evaluar la exposición al dióxido de nitrógeno, en la ciudad de Toronto (Canadá). Como unidad de análisis espacial emplean celdas de 2500 m de resolución (Kanaroglou et al., 2005). Por otra parte, existen investigaciones cuyo objetivo consiste en encontrar la mejor ubicación de las farmacias (Özceylan et al., 2017). Con ese fin, proponen varios escenarios, considerando las distancias y el número de locales a ubicar. En el desarrollo del modelo recurren a farmacias y hospitales actuales. Se probaron casos donde se evalúan las localizaciones que presenta este tipo de negocio, luego se considera la búsqueda de instalaciones adicionales y, por último, se aprovechan las ubicaciones existentes y las nuevas para obtener los resultados óptimos.

En cuanto a los MLA que abordan situaciones en entornos de competencia de servicios, aparecen estudios en los que utilizan la solución de maximización del mercado compartido. Se han aplicado para la ubicación de tiendas, bancos, aparcamientos de bicicletas, por mencionar algunos. En el caso de las tiendas, Shan et al. (2019) no solo se centran en el problema de optimizar la localización más competitiva de nuevas cadenas de comercios, sino que consideran el efecto del precio con el que compiten dos empresas. Además, toman en cuenta la distancia de circulación y el coste del producto, al medir el atractivo de las instalaciones. Min & Melachrinoudis (2001) aplican un modelo para localizar un banco en Framingham, Massachusetts (EE. UU.). En su enfoque manejan múltiples objetivos, dentro de los cuales se encuentran el mayor rendimiento, el poder de atracción de los clientes y el menor riesgo. Estos aspectos son esenciales para el emplazamiento de una entidad bancaria, por lo que ayudan al planificador a realizar diversas compensaciones, en términos de criterios contrapuestos, como el beneficio frente al riesgo, especialmente, cuando el banco debe cambiar sus prioridades en la evaluación del sitio. Por otro lado, Banerjee et al. (2020) proponen emplazar tres estaciones adicionales para el programa de bicicletas compartidas en la ciudad de Baltimore (Estados Unidos). Para ello aprovechan las coordenadas de los viajes realizados por los usuarios de la bicicleta. Los factores que miden el nivel de interés son: la proximidad a las paradas del autobús, las atracciones turísticas y los restaurantes. En su planteamiento, adoptan una separación de 1.000 metros entre las bases.

En definitiva, son muchas las aplicaciones que se pueden abordar con las distintas soluciones que ofrecen los MLA. Cada una de ellas dependerá del objetivo que busquen los planificadores, según se trate del tipo de instalación. Es importante tener presente que para plantear un MLA se requiere una serie de elementos o componentes, por lo general, de geometría puntual que representen la demanda y la oferta; además, de una red que ponga en contacto los otros elementos del MLA. A continuación, explicaremos en qué consisten estos elementos.

### 2.1.2 Datos de entrada de los modelos de localización-asignación óptima de servicios

La planificación de los modelos de localización-asignación requiere elementos geográficos, que representen los lugares candidatos que ofrezcan nuevos servicios o instalaciones a la población. Además, es necesario disponer de la localización de los

puntos de demanda a los que se presta el nuevo servicio. Generalmente, para obtener los puntos de demanda se utiliza la población censada en diferentes niveles de agregación, como pueden ser las secciones censales, distritos, celdas, hexágonos, etc. Otro insumo para el desarrollo del MLA es la red de transporte, que permite interconectar los puntos de oferta con la demanda. A continuación, se explica con detalle cada uno de los datos de entrada.

#### *2.1.2.1 Oferta o puntos candidatos para su localización*

Un dato fundamental para la correcta utilización de los MLA es establecer la distribución espacial de la oferta de un determinado servicio. De este modo se conoce la cantidad y la distribución de las instalaciones ya existentes en una localidad. Por lo tanto, la distribución espacial de la oferta estará vinculada a los puntos donde se proveen los bienes o servicios requeridos por la población (Bosque Sendra et al., 2000). Además, teniendo en cuenta la demanda, es posible incorporar nuevas instalaciones para lo que necesitaremos localizaciones candidatas a esa posible instalación o eliminar las que no cumplan los parámetros deseados.

La geometría de la oferta suele ser una capa de puntos, que hace referencia a las instalaciones o equipamientos que ofrecen un determinado servicio. Como hemos visto anteriormente, pueden ser los relacionados con: la salud, las emergencias, el transporte, el ocio, entre otros. Algunos trabajos usan estos modelos para determinar si la ubicación de los equipamientos es la más adecuada. Así por ejemplo, Ledesma & Zurita (1995), para determinar si la ubicación actual de los hospitales públicos es la más adecuada, empleando como sitios candidatos las ubicaciones actuales de los hospitales de la provincia de Chaco en Argentina.

Para el desarrollo de los MLA es necesario contar con sitios candidatos que representen la oferta del servicio que se pretende localizar. La distribución de los sitios candidatos suele obtenerse de los nodos de la propia red, estaciones de bus, de los centroides, de los ejes de las manzanas, de puntos GPS agregados en celdas, espacios públicos o técnicas de análisis multicriterio.

Ejemplos de trabajos que han utilizado como candidatos los nodos de la propia red tenemos a Shariff et al.(2012). Ellos buscan aumentar el número de hospitales. Por su parte, Arturo Blanco (2016) obtiene los candidatos para ubicar contenedores de basura a partir de los nodos contenidos en la red viaria.

Otros trabajos emplean las estaciones de autobuses y ejes de las manzanas para representar a los sitios candidatos. Por ejemplo, Banerjee et al. (2020) emplean las paradas de autobuses, los restaurantes y los bares como candidatos para posibles estaciones de bicicletas. Por su parte, García-Palomares et al. (2012) obtienen los sitios candidatos a partir de los centroides de los ejes de las manzanas.

En cuanto a los trabajos que obtienen los sitios candidatos a partir de los centroides de celdas que contienen información procedente de dispositivos GPS, encontramos a Park & Young Sohn (2017), quienes proponen crear un nuevo sistema de bicicletas compartidas con bases fijas en Seúl, Corea, para ello, como candidatos aprovechan las coordenadas de recogida y entrega de los usuarios de taxis. En la misma línea, Zhang et al. (2019) plantean la creación de cercas virtuales para el aparcamiento de un sistema de bicicletas compartidas sin base fija; para ello usan como candidatos las coordenadas de origen y destino generadas por los dispositivos GPS incorporados en las propias bicicletas. Por su parte, Yu et al. (2020) agrega los incidentes de incendios en celdas de  $200 \times 200$  y luego les extrae el centroide para utilizarlos como los sitios candidatos en su modelo.

También, existen investigaciones que aprovechan diversos espacios públicos como candidatos. Por ejemplo, centros comerciales, oficinas del gobierno, centros de salud, enfermerías, escuelas, parques y otros espacios abiertos para ubicar servicios de salud y emergencias (Abdelkarim, 2019; Dibene et al., 2017; Polo et al., 2015; Shi et al., 2019; Zhou et al., 2020). Un caso reciente es el planteado por Alhothali et al., (2022). Ellos aprovechan la localización de los centros de convenciones, los estadios, edificios públicos, y en algunos casos escuelas o centros comerciales para localizar los sitios que funcionarían como centros de vacunación contra el COVID-19. Otro estudio toma en cuenta el plan de uso de suelo urbano, seleccionando como candidatos aquellos terrenos mayores a 2000 metros cuadrados para la construcción de un parque de bomberos (Han et al., 2020).

Por otro lado, encontramos publicaciones que obtienen los candidatos con la utilización de técnicas multicriterio, donde se toman en cuenta datos de pendiente, tipos de suelos, elevación, entre otros, para localizar estaciones de bomberos (Bolouri et al., 2020). Mientras que Rahman et al. (2021) utilizan estas técnicas para la localización de posibles candidatos para centros de refugio en caso de evacuación ante emergencias.

Cabe señalar, que, en los modelos de localización, en algunos casos, además de los candidatos potenciales, se emplean instalaciones requeridas. Por lo general son representadas con las ubicaciones de los servicios existentes. Ejemplo de ello tenemos a Bolouri et al. 2020 y Yu et al. (2020), quienes presentan un modelo donde toman como instalaciones requeridas las estaciones de bomberos existentes. De la misma manera, los trabajos de Wang et al. (2021) y Yin & Mu (2012) emplean en sus MLA las ubicaciones actuales de las estaciones de bomberos para realizar sus planteamientos.

En sus publicaciones, García-Palomares et al. (2012) y Banerjee et al. (2020) utilizan las ubicaciones de las bases operativas de un sistema de bicicletas compartidas como sitios requeridos u obligatorios en sus modelos. Otros casos donde se usan como sitios requeridos los servicios existentes encontramos a Abdelkarim (2019); Amato et al. (2021) y Zhu et al. (2016) para casos de localización de hospitales. Mientras Beheshtifar & Alimoahmadi (2015) aprovechan las localizaciones de centros de salud y clínicas actuales en sus modelos.

En síntesis, los distintos estudios presentados, en los párrafos anteriores, emplean las instalaciones actuales como requeridas para evaluar la cobertura, ya sea de hospitales, clínicas, puestos de ambulancia o instalaciones para bicicletas. En el caso de los modelos de localización que buscan aumentar el número de instalaciones, recurren a los equipamientos en servicio como ubicaciones requeridas y obtienen los candidatos de diferentes maneras. Algunos se obtienen a partir de nodos de calles, parques, edificios gubernamentales o con la ayuda de técnicas de evaluación multicriterio que consideran, en función de una serie de variables, cuáles son las más adecuadas para establecer nuevas instalaciones.

#### *2.1.2.2 Demanda*

A la hora de realizar los MLA, es necesario disponer además de información puntual sobre la localización de la demanda del servicio, es decir, la distribución espacial de los consumidores que utilizarán el nuevo servicio o instalación. La distribución de la demanda suele obtenerse del censo y puede agregarse en polígonos a escala de parcelas, secciones censales, hexágonos, celdas, manzanas, códigos postales u otros niveles geográficos (Pastor, 1994).

Para que sean funcionales, en un MLA, estas divisiones geográficas poligonales se les extrae el centroide, que contiene los atributos de la población, edad, sexo, ingresos, etc. (Bosque Sendra et al., 2000). Así, los MLA suponen que la demanda se agrega a un conjunto de puntos, donde se les asigna información como campo para ponderar la demanda cuando se ejecuta el modelo.

Como ejemplo de MLA que desagrega la población censada a escala de parcela, podemos citar el trabajo de Beheshtifar & Alimoahmmadi (2015), cuyo objetivo es distribuir la demanda entre las clínicas existentes.

Por otro lado, muchos estudios utilizan la población desagregada a partir de las secciones censales, ya que, suele ser el nivel mínimo de detalle donde las instituciones oficiales de los países muestran la información espacial. Así, se mencionan las investigaciones de Amato et al., (2021); Ngowi & William, (2020); Yin & Mu, (2012) que se basan en las estadísticas oficiales de población, obtenidas de las secciones censales, para asignarla a los establecimientos de salud y emergencia.

Del mismo modo, existen trabajos que agregan los datos censales a nivel de celdas con distintos tamaños de resolución según la escala de trabajo, por ejemplo,  $100 \times 100$  metros,  $250 \times 250$ ,  $1000 \times 1000$  y  $5000 \times 5000$ . El modelo de localización-asignación de Kotavaara (2018), emplea la población agregada en celdas de  $250 \times 250$ , para la localización de los establecimientos de salud. Pu et al. (2020), trabajan con una trama de  $100 \times 100$  m, que contiene la población mundial, descargada del sitio web de World Pop<sup>1</sup>. Su modelo determina la ubicación óptima de los nuevos centros de salud en la República Democrática del Congo. Por su parte Munir et al. (2020) disponen de un ráster de población global descargado del sitio web Landscan<sup>2</sup> a 1000 metros de resolución, para evaluar la accesibilidad a los centros de salud. Vora et al. (2015) utilizan la población desagregada a 1000 metros para localizar los centros de salud que atienden a las madres pobres, en la India.

También, se encuentran trabajos que emplean otras unidades espaciales de agregación de la población. Abdelkarim (2019) y Zhu et al. (2016), trabajan con polígonos a escala de distrito. Ledesma & Zurita (1995) y Shariff et al. (2012) desagregan la población a escala de áreas y regiones de salud. Además, se

---

<sup>1</sup> <https://www.worldpop.org/methods/populations>

<sup>2</sup> <https://landscan.ornl.gov/landscan-datasets>

encuentran trabajos que agregan la demanda según ejes de calles, carriles bici, aceras (Banerjee et al., 2020). Finalmente, encontramos investigaciones que aprovechan las coordenadas de los eventos históricos de emergencias e incendios registrados por puntos GPS. Estos puntos suelen agregarse en celdas o hexágonos para extraer el centroide, usado en el planteamiento del MLA. Al respecto, se puede citar el trabajo de Han et al. (2020), que utiliza hexágonos de 1.000 metros de lado para agregar las coordenadas de los lugares de incendios. Por su parte, Yang et al. (2020), recurren a las coordenadas de origen y destino, almacenadas por los GPS que portan las bicicletas compartidas. Estos puntos GPS se agregan en celdas de  $100 \times 100$  para obtener el centroide empleado en los MLA.

En síntesis, la demanda hace referencia a los individuos servidos por las instalaciones. Para el sector público la demanda representa aquella población que necesita algún servicio, en específico. Mientras que en el sector privado la demanda la constituyen los clientes potenciales.

### *2.1.2.3 Red de transporte*

Otro elemento que debe incorporarse, para desarrollar un MLA, es la red de transporte, formada por una serie de arcos y nodos. A través de esta red se pueden considerar los tiempos de viaje, según el modo a utilizar. Se trata de establecer el vínculo para que la oferta y la demanda se pongan en contacto y se produzca la prestación del servicio (Bosque et al., 2012).

En el caso de la red para desplazamiento por carretera, es posible que incluya características relacionadas con el sentido de circulación, límites de velocidad, tráfico, restricciones de giro, calles sin salida, pendientes o la dificultad de conducir por ellas. Por ejemplo, cuando se trabaja con la distancia de recorrido que realizan los peatones, interesa la longitud de los arcos, la distancia media de recorrido, los pasos cebra, semáforos, o aspectos como la seguridad de las calles, la pendiente, entre otros.

En la construcción de una red de transporte público es necesario proporcionar datos como: tiempo de espera de las unidades de transporte, tiempo de viaje hasta la parada, ruta de transporte, tráfico, horarios, así como frecuencias, paradas, elevación, conectividad, tiempos de llegada y salida. Por lo tanto, con los archivos de transporte público se dispone de información sobre los horarios de la flota de vehículos y las

frecuencias de los viajes. Dicha información permite incorporar impedancias en la red relacionadas con el tiempo de viaje.

Por otro lado, para los desplazamientos en coche, la red de transporte construida ha de incluir información a los diferentes ejes de las calles. Por ejemplo: longitud de los ejes, datos de tráfico, tiempos de viaje, las vías en construcción, el número de carriles, intersecciones, restricciones de giro, calles privadas, jerarquías de los ejes y los costes de viaje que pueden producirse en tiempo o distancia entre otros atributos.

Las nuevas redes de transporte permiten conocer los perfiles históricos de velocidad y el flujo de vehículos en tiempo real. Estos perfiles de velocidad permiten introducir, en la red, las impedancias que tienen en cuenta la congestión de vehículos en diferentes momentos del día. Es conocido que la densidad del tráfico varía a lo largo del día, de la semana y de la temporada; por eso es por lo que se añade un componente temporal al problema. En este sentido, el volumen de tráfico en la carretera, en un momento dado, supone un factor importante (Ghosh & Rushton, 1987). Por lo tanto, al construir la red se debe considerar la impedancia, o sea el coste del desplazamiento, que puede ser medido en términos de distancias, tiempos de recorrido, o costes económicos.

Cabe destacar que la mayoría de los modelos de localización-asignación se han implementado utilizando redes estáticas. Es decir, que solo toman en cuenta los límites de velocidad, la jerarquía de los ejes viales y el sentido del tráfico, tal como proponen en sus investigaciones (Abdelkarim, 2019; Amato et al., 2021; Huotari et al., 2020; Munir et al., 2020; Zhu et al., 2016). Todos estos trabajos carecen de información sobre el tráfico o las frecuencias del transporte público a lo largo del día; como consecuencia de la escasa disponibilidad de datos que existía en el pasado.

Hoy en día, con las nuevas fuentes de datos, es posible conocer el estado del tráfico recogido por los dispositivos GPS, instalados en los coches u otros medios de recogida voluntaria de información geográfica, como, por ejemplo: Waze, Here o TomTom. Estas fuentes se mencionan; más adelante; en diferentes apartados de esta tesis.

Sin embargo, pocos estudios de localización-asignación consideran el efecto del tráfico vehicular y las frecuencias del transporte público en la distribución de la demanda que debe satisfacer un centro de salud, un centro comercial, los servicios

de emergencia o cualquier otra instalación. Uno de los pocos trabajos en este sentido es el de Zhou et al.(2020) que añaden a los ejes de las calles información histórica sobre el tráfico en momentos concretos. En este caso, los datos proceden de la aplicación de tráfico Gaode. Su modelo busca las mejores ubicaciones de las instalaciones médicas de emergencia, teniendo en cuenta el tráfico durante algunas horas del día. Por su parte, Wang et al. (2021) utilizan la información de la velocidad en los distintos tramos de carretera, a partir de los datos descargados de la aplicación AutoNavi, (aplicación china que ofrece servicios de localización). Los autores proponen investigar la cobertura, actual, de los cuarteles de bomberos, en el centro de Pekín (China), bajo diferentes condiciones de tráfico. El trabajo de Dibene et al. (2017) emplea el tiempo medio de viaje en algunos ejes de calles extraídos de la aplicación de Google. Plantean un MLA para determinar la ubicación de un refugio de emergencia, tomando en cuenta los costes de viaje. Por otro lado, Han et al. (2020) emplean datos históricos de tráfico descargados de la aplicación Amap OPEN API, para realizar un modelo de localización de estaciones de emergencia en Nanjing, China, considerando las condiciones de tráfico.

En síntesis, los MLA deben tener capas de puntos (demanda, oferta), capas de líneas (red vial) que son fundamentales para realizar el análisis y así poder encontrar la mejor ubicación que beneficie a la mayor cantidad de habitantes. Puerto-Albandoz (1996), expone que los puntos de demanda representan la idealización de la posición geográfica del usuario. Del mismo modo, los sitios de oferta corresponden a la abstracción de los potenciales lugares donde es posible ubicar un nuevo equipamiento.

En la siguiente sección se exponen los tipos de servicios o equipamientos a localizar que se han clasificado como instalaciones deseables y no deseables.

### 2.1.3 Clasificación y objetivo de las instalaciones a localizar

Los MLA son empleados para localizar servicios o equipamientos que se pueden clasificar como deseables y no deseables. Además, toman en cuenta los objetivos de eficiencia, equidad y cobertura espacial (Bosque et al., 2012). En algunos casos el propósito de los MLA es lograr un equilibrio entre la eficiencia y la equidad espacial. Por lo tanto, si la accesibilidad fuera el único aspecto por optimizar, el modelo podría sugerir la localización de los servicios donde todos los usuarios tengan condiciones

similares de accesibilidad (mejor equidad). En cambio, cuando solo fuera considerado el coste financiero, se debería localizar un número reducido de instalaciones para cubrir el máximo de demanda (mejor eficiencia) (Thomas, 2002).

#### *2.1.3.1 Instalaciones deseables*

Para Hodgart (1978) las instalaciones a donde los consumidores deben acudir para disponer de un servicio utilizado por la mayoría de la población, en general, son juzgadas, positivamente, por los habitantes de la zona. Estas instalaciones suelen denominarse "deseables" (atractivas). En consecuencia, se considera que no tienen características cuestionables. En estos casos, los beneficios, para la sociedad, de una instalación potencial se miden por la posibilidad de reducir el coste o los inconvenientes de los desplazamientos de los usuarios.

Según Brimberg & Juel (1998) y Erkut & Neuman (1989), los clientes prefieren que la instalación esté cerca para utilizar el servicio al menor coste de desplazamiento. En consecuencia, se espera que la demanda tenga fácil acceso a las instalaciones desde el punto de vista espacial. La población apoya este tipo de instalaciones porque se beneficia de sus servicios. Además, generan externalidades favorables en su entorno al resultar agradables para los usuarios de los equipamientos (Bosque Sendra et al., 2000; Song et al., 2013).

Las instalaciones deseables pueden ser de carácter público, lo que permite el uso gratuito por parte de toda la población cubierta. También, hay instalaciones privadas cuyo objetivo es situarse en los lugares próximos a los consumidores y con menores costes de producción, para obtener los mayores beneficios. Un claro ejemplo son los supermercados. Para la población, este tipo de instalaciones comerciales, resultan atractivas por las ventajas que brinda al tener un supermercado cerca de sus hogares.

La mayoría de los problemas de localización están orientados a ubicar las instalaciones deseables. En opinión de Daskin (2011), la calidad del servicio mejora, en cierta manera, a medida que las instalaciones son más próximas a las personas o bienes a los que se presta el servicio. En este sentido, ambulancias, parques de bomberos, escuelas, hospitales, oficinas de correos, comisarías y almacenes son ejemplos comunes de instalaciones deseables. Su objetivo es promover el bienestar y la satisfacción de los usuarios. Así, por ejemplo, es frecuente que las estaciones de metro o autobús obtengan el beneplácito de los habitantes de las zonas cercanas, ya

que les proporcionan un fácil acceso al transporte público y podrían aumentar la revalorización de la propiedad (Song et al., 2013).

En fin, las instalaciones deseables pretenden cubrir la demanda, ubicando los servicios lo más cerca posible de la población que los necesita. Por lo tanto, los costes de ida y vuelta son un factor importante en el funcionamiento de la mayoría de las instalaciones (Erkut & Neuman, 1989). Del mismo modo, (Bose & Wang, 2002; R. L. Church & Drezner, 2022; Gokalp, 2020; Hamacher et al., 2002; Medina Tapia & Cerda Troncoso, 2008; Melachrinoudis, 1967) señalan que, en los problemas tradicionales de localización de instalaciones, los investigadores intentan situar las instalaciones deseables a la menor distancia posible de los lugares de demanda. Por ejemplo, socialmente resulta deseable escoger la ubicación de un parque donde se reduzca, al mínimo, la distancia media de desplazamiento de un individuo desde su lugar de origen (Yamaguchi, 2011).

#### *2.1.3.2 Instalaciones no deseables*

Este grupo de instalaciones resultan indeseable para la población circundante que los evita y trata de mantenerse alejada de ellos. Para Melachrinoudis (1967) las instalaciones que tienen un impacto negativo sobre las personas o el medio ambiente no son bienvenidas, porque representan una fuente de contaminación y riesgo para las personas que viven cerca de estas.

Como ejemplo de instalaciones no deseables se encuentran: las gasolineras, incineradores, cárceles, bases militares, los vertederos de basura, plantas químicas, reactores nucleares, y plantas contaminantes (Hosseini & Moharerhaye, 2012; Melachrinoudis, 1967; Verter & Lapierre, 2002). La salud y la seguridad pública de la población podría estar en peligro ante la presencia de este tipo de instalaciones (Flahaut et al., 2002). Song et al. (2013), afirman que los equipamientos no deseables causan costes medioambientales, económicos y psicológicos que recaen principalmente en la comunidad que alberga la instalación indeseable. Los equipamientos no deseados producen una depreciación de los bienes o ponen en riesgo la calidad de vida por la contaminación atmosférica e hídrica (Brimberg & Juel, 1998; Song et al., 2013). A pesar de las molestias producidas a los habitantes, muchos de estos equipamientos son requeridos para el funcionamiento de la sociedad, por lo general, se ubican en sitios que están alejados de los lugares con gran concentración

de habitantes y lugares con hábitat de interés natural (Bose & Wang, 2002; Brimberg & Juel, 1998).

Determinar dónde y cuándo desarrollar una instalación no deseable suele ser difícil, porque la sociedad exige que estos servicios se ubiquen lo más lejos posible de las zonas pobladas, especialmente, por el deterioro real o percibido de los barrios donde se ubican (Murray & Church, 1998). En el mismo sentido, Erkut & Neuman (1989), subrayan que, a la hora de ubicar instalaciones no deseadas, la exigencia de una distancia preestablecida es un supuesto válido y natural, debido a todas las externalidades que estos servicios conllevan.

En cuanto a los MLA de equipamientos no deseables encontramos autores que presentan una revisión detallada (Bosque Sendra, J., & Franco Maass, 1995; Erkut & Neuman, 1989; Farahani et al., 2012b; Murray & Church, 1998; Yong Gu et al., 2017). En este sentido, Verter & Lapierre (2002), plantean que los objetivos de las instalaciones no deseables se denominan, frecuentemente, objetivos de empuje, ya que alejan, normalmente de las zonas residenciales, los equipamientos indeseables. En cambio, los objetivos de los equipamientos deseables (atractivos) se denominan objetivos de atracción, ya que acercan la instalación a los clientes.

Por su parte, Wichapa & Khokhajaikiat (2018) buscan la localización de un sitio para la eliminación de los desechos peligrosos, utilizando modelos de localización óptima y técnicas de análisis multicriterio. Medina Tapia & Cerda Troncoso (2008) aplican un modelo de localización para ubicar estaciones de transferencia y rellenos sanitarios. Consideran que los modelos de localización de actividades indeseables presentan dos objetivos a optimizar: primero la instalación debe ubicarse lo más lejos posible para evitar daños a la población y desde el punto de vista de la eficiencia operativa es necesario que estén lo suficientemente cerca de la población. Otro estudio tiene como objetivo la localización de un centro de reciclaje dentro de un área residencial, considerando los daños y costos en el transporte, mostrando si el modelo planteado toma en cuenta las molestias ocasionadas a los residentes; además, plantea que se busque un único objetivo a fin de maximizar la distancia que minimice los efectos nocivos en la demanda (Flahaut et al., 2002).

En fin, construir o ampliar instalaciones no deseadas se enfrenta a una gran resistencia por parte de la población afectada. A lo largo de los años, para referirse a

la oposición a dichos equipamientos, han surgido nuevos nombres para estudiar las instalaciones no deseadas, por ejemplo, NYMBY(not in my back yard), NIMNBY(not in my neighbor`s back yard), y NIABY(not in anyone`s back yard) (Song et al., 2013). Yong Gu et al. (2017), sostiene que los equipamientos NIMBY son fundamentales para el funcionamiento de la ciudad. Las comunidades necesitan equipamientos NIMBY, pero los ciudadanos cercanos se oponen a ellos. Aunque, prácticamente, todos los equipamientos NIMBY benefician a los pobladores, éstos esperan que no se desarrollen al lado de sus casas. Así pues, razones naturales, económicas y políticas, entre otras, influyen en el emplazamiento de las infraestructuras NIMBY.

Luego de lo expuesto, anteriormente, sobre los modelos de localización-asignación para las instalaciones deseadas y no deseadas, se abordarán los criterios de eficiencia y equidad en la solución encontrada con la implementación de los modelos.

#### 2.1.3.3 Eficiencia

Lograr la eficiencia en la localización de los servicios es uno de los principios de los MLA, pero está influenciada, por la naturaleza del tipo de equipamiento.

Desde el punto de vista de Stone (2012):

*La eficiencia es una concepción relativa. Ha llegado a implicar la relación entre entrada y salida, esfuerzo y resultados, gasto e ingreso, o coste y beneficio. Como criterio para juzgar la bondad, se ha aplicado a todo tipo de cosas. Las organizaciones eficientes son aquellas que consiguen hacer las cosas con un mínimo de desperdicio, duplicación y uso de recursos. Las personas eficientes son las que consiguen hacer mucho en poco tiempo. Los programas eficientes son los que producen el mayor beneficio por un coste determinado. Las distribuciones eficientes, por ejemplo, de tierras agrícolas o de derechos de perforación petrolífera, son las que aportan el máximo valor a la sociedad a partir de los recursos existentes.*

En opinión de Mcallister (1976), la eficiencia está indicada por la cantidad de servicios consumidos. Para Bosque et al. (2012), la eficiencia tiene como objetivo mantener los impactos de la localización de los servicios al mínimo. Por ejemplo, al ubicar un negocio de servicios, estar cerca de los clientes es una parte importante de su rendimiento. En el caso de un negocio de manufactura, la ubicación de la planta de

producción influye en el costo de los materiales, en el tiempo de entrega de los productos a los clientes y en la calidad del servicio que se les brinda (Maleki et al., 2016). Las instalaciones privadas suelen ubicarse donde pueden reducir los costes teniendo en cuenta en qué lugar el rendimiento o beneficio, es lo más rentable posible.

Para los equipamientos públicos, como un colegio, en los que no se suele buscar el beneficio económico, un modelo de ubicación eficiente permite ofrecer un nivel o volumen de servicio determinado a la sociedad con el menor coste total de funcionamiento y transporte (Morrill & Symons, 1977). En cambio, para una escuela privada lo que interesa es tener el máximo número de alumnos (con capacidad económica para pagar su matrícula) cerca de su centro educativo.

Como plantea Gordon (1991), la eficiencia guarda relación con aspectos que buscan minimizar los costes totales o medios, de los desplazamientos y aumentar el número de personas cubiertas por un determinado servicio. Existen diferentes formas de considerar la eficiencia y de acuerdo con McAllister (1976) y ReVelle & Swain (1970), reducir los costes de transporte es una de las más comunes.

Truelove (1993) sostiene que la métrica de eficiencia más utilizada en los modelos de localización-asignación es la distancia o el coste del transporte. Normalmente, se minimizan las distancias de transporte globales del sistema investigado. La accesibilidad es un fuerte factor de motivación para desarrollar una red de servicios descentralizados. Las pequeñas distancias agregadas entre los usuarios y las instalaciones mejoran la eficiencia al ahorrar tiempo y dinero en los desplazamientos.

Como señalan Lejeune & Prasad (2013), los problemas de localización más comunes consisten en encontrar la ubicación óptima que permita evaluar el rendimiento en aspectos relacionados con la distancia o el tiempo entre los lugares de demanda y las instalaciones más próximas. Por su parte, McAllister (1976) subraya que la eficiencia de las combinaciones de tamaño y espacio del servicio se evalúan en función de la cantidad que cada persona utiliza el mismo.

Existen formas variadas de evaluar la eficiencia de servicios de ocio y bibliotecas, por ejemplo, el número de horas que la gente pasa allí. Por su parte, DeVerteuil (2000) señala que, tanto la distancia (costes para los clientes) como el número y el coste de las instalaciones (costes para los proveedores gubernamentales) deben minimizarse.

Mientras que, la utilización de las instalaciones y el acceso de los usuarios deben maximizarse, con el fin de lograr una provisión y un consumo (eficiencia) óptimo.

De acuerdo con Morrill & Symons (1977), en atención a la teoría de la localización, los patrones de ubicación de todas las instalaciones serán eficientes u óptimos cuando los rendimientos sean máximos en un entorno de competencia. No obstante, para abordar el principio de eficiencia se plantea el caso de la ubicación de las instalaciones públicas como las escuelas, donde, normalmente, no se busca ningún lucro como tal. De esta forma tenemos que, un patrón de ubicación eficiente es, supuestamente, aquel donde se consigue algún nivel y cantidad de servicio predeterminado por la sociedad, con costes mínimos totales del plan de operaciones y desplazamientos. Otra posibilidad es que un patrón eficiente sea el que maximice el rendimiento del servicio dentro de una restricción presupuestaria predefinida (Morrill & Symons, 1977).

En el caso de los servicios de emergencias, Enayati et al. (2019) sugiere que para ubicar las estaciones de ambulancias, los dos criterios de eficiencia pueden ser: minimizar el tiempo de respuesta y maximizar la población cubierta en ese tiempo (maximizar cobertura). Además, este autor manifiesta que la mayor parte de la literatura sobre localización se centra en los criterios de eficiencia.

En fin, por mucho que tenga sentido pensar en la eficiencia de una solución, otros criterios, como el grado de equidad (o justicia) cobran importancia en otras situaciones, especialmente cuando hay instalaciones o recursos públicos implicados. En el siguiente apartado se desarrolla el criterio de equidad en la ubicación de las instalaciones.

#### *2.1.3.4 Equidad*

La planificación de los servicios públicos debe garantizar que todos los ciudadanos puedan acceder a ellos, sin importar dónde vivan o a que grupo social pertenezcan. Sin embargo, la mayoría de los modelos de localización se centran en criterios de eficiencia, sin pensar en la equidad (Li et al., 2022).

En los MLA tradicionales, la localización óptima de los equipamientos se define en términos de eficiencia. Sin embargo, cuando el servicio que se ofrece es público, lo más común es proponer la equidad espacial con miras a la asignación de los servicios de manera justa o en cantidades iguales a todos los ciudadanos. En estos casos, se

sugiere minimizar equivalentemente las distancias de desplazamiento del conjunto de los usuarios hasta las instalaciones (Crompton & Lamb, 1983).

En cualquier caso, la idea de equidad o justicia espacial, con respecto a la ubicación, es menos clara. La equidad espacial deriva de los conceptos de justicia social, en el espacio (Pirie, 1983), o justicia social facilitada por la dimensión espacial (Soja, 2013). Con una creciente conciencia del impacto del entorno geográfico en la vida cotidiana de las personas, hay acuerdo en que el espacio físico puede, tanto apoyar como impulsar el cumplimiento de la justicia social, a través de su influencia en la actividad social (Israel & Frenkel 2018). Sin embargo, la conceptualización de la equidad espacial (así como la justicia) varía según la disciplina y los contextos sociales, históricos y políticos (Fainstein, 2014; Pereira et al., 2017). La equidad es una cuestión importante y controvertida a la hora de asignar recursos públicos, y no existe una única forma consensuada de medir la equidad (Stone, 2012).

Mcallister (1976) define equidad como el grado de igualdad en la distribución de los servicios públicos. Marsh & Schilling (1994) destacan que el propósito de buscar la equidad radica en garantizar que los interesados reciban la parte que les corresponde de los beneficios de la decisión de ubicar la instalación. Para Alonso (1971) la equidad se refiere a la propiedad de ser igual o justo, y nuestra comprensión de lo que es justo cambia constantemente. La equidad indica un consenso social o político respecto a la justicia de la distribución de los costes y beneficios de una política o programa (Dear, 1978). Bennett (1983) considera que la equidad es una condición necesaria para que la sociedad perciba como justa y equitativa en la asignación de costes y beneficios asociados a los servicios públicos. En definitiva, la equidad espacial o territorial significa tratar a todos por igual, independientemente del lugar donde vivan.

Según Eiselt (1995) y Gordon (1991), una métrica de igualdad debe representar hasta qué punto una determinada disposición de instalaciones garantiza una distribución justa de las distancias entre los usuarios y las instalaciones que frecuentan. Para Marsh & Schilling (1994), un criterio esencial para tomar una buena decisión sobre dónde ubicar una instalación lo constituye el grado de equidad de cada grupo social, con respecto a los demás.

Desde los trabajos de Mumphrey et al. (1971), Mcallister (1976) y Savas (1978), se ha desarrollado una valiosa literatura que incorpora la equidad en los modelos de

localización de instalaciones. Por ejemplo, las revisiones de (Horst A Eiselt, 1995; Marsh & Schilling, 1994), resumen aspectos relacionados con el criterio de equidad.

La idea de valorar la equidad surge, solamente, si la sociedad siente que algunos de sus miembros no están disfrutando de bienes y servicios justos y aceptables (Morrill & Symons, 1977). Por ejemplo, se puede considerar que existe equidad espacial cuando los residentes estimen que el tiempo de viaje, desde casa al colegio, no debe sobrepasar los 10 minutos.

En la práctica, la equidad está limitada por las restricciones presupuestarias y el tamaño de la región. Es bien sabido que la distancia es un determinante importante en el uso de una instalación pública. Las personas que viven cerca de una instalación la utilizarán mucho más en comparación con otras que viven más lejos. En relación con la localización de las instalaciones, la distribución puede resultar equitativa, sí toda la población servida se encuentra a una distancia razonable; es decir, dentro de los umbrales, previamente, definidos. Así pues, ambos principios se refieren al mejoramiento del acceso al servicio, entre ellos: la distancia máxima recorrida, accesibilidad o diferencia entre los valores extremos. En definitiva, es difícil, ofrecer una definición de equidad que sea aplicable en todas las situaciones.

La preocupación por la relación entre eficiencia y equidad espacial puede desencadenar en una dicotomía donde, por un lado, el modelo es eficiente y equitativo o es eficiente pero no equitativo. Por ejemplo, a la hora de ubicar un centro sanitario, la eficiencia podría incluir la reducción de las distancias o tiempos totales de viaje a los centros. Por otro lado, la equidad garantizaría que todas las personas con derecho a recibir asistencia tengan un acceso mínimo al sistema similar; es decir, el acceso administrativo y a la ubicación (Truelove, 1993).

Así pues, la equidad y la eficiencia suelen estar en desacuerdo en un sistema de instalaciones públicas. La eficiencia suele equipararse a la maximización del beneficio en una empresa privada. Normalmente, tal propósito no se aplica al sector público (Truelove, 1993).

Morrill & Symons (1977) ofrecen dos explicaciones directas de la eficiencia, indicando cómo puede lograrse: (1) alcanzando un nivel o volumen de servicio social predeterminado con el menor coste total posible de funcionamiento y desplazamiento; y (2) maximizando el volumen de servicio (o el número de personas atendidas) dentro

de una restricción presupuestaria predeterminedada. Ambas explicaciones hacen hincapié en la eficiencia como técnica para generar el mayor rendimiento a partir de una cantidad finita de recursos.

En el caso de la equidad, los costes y beneficios de los servicios públicos resultan más complejos de medir (McAllister, 1976). Por ejemplo, la equidad sanitaria puede referirse a varios conceptos, tales como: la igualdad de resultados sanitarios, del uso y el acceso a los servicios sanitarios (Culyer & Wagstaff, 1993). La igualdad de acceso supone el objetivo de equidad, más apropiado, desde el punto de vista espacial y ha recibido una atención considerable por parte de los estudios geográficos.

En definitiva, la eficiencia y la equidad a menudo entran en conflicto: por ejemplo, una estrategia de localización eficiente, probablemente, minimizaría el número de instalaciones necesarias para atender al máximo número de usuarios. Esto daría lugar a un sistema centralizado de instalaciones más grandes. Mientras que una estrategia de localización equitativa implica, generalmente, la localización de instalaciones para maximizar la demanda de los clientes, lo que daría lugar a una disminución de las distancias totales necesarias para acceder al servicio y a un sistema más disperso y localizado con más instalaciones (Morrill & Symons, 1977). Por un lado, el modelo eficiente incomodaría, inevitablemente, a los clientes más distantes. Por otro lado, el patrón equitativo daría lugar a una reducción de los costes agregados de los desplazamientos, pero conduciría, inevitablemente, a un aumento de los costes de operación. Además, Morrill & Symons, (1977) señalan que la escala del estudio, la densidad de población y el nivel de ingreso, pueden afectar los resultados del modelo en aspectos relacionados con la eficiencia y equidad, en la ubicación de las instalaciones.

#### 2.1.4 Tipos de soluciones en los MLA

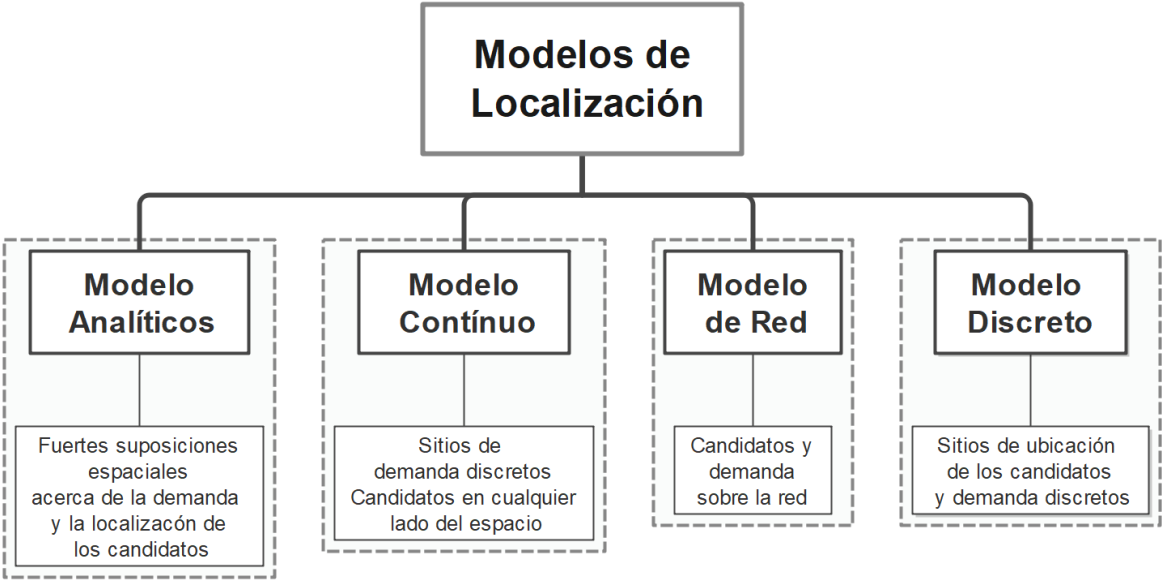
En los apartados anteriores, se desarrollaron las categorías de las instalaciones (deseables y no deseables) y los objetivos (eficiencia-equidad) perseguidos con los MLA. En esta sección se explican los tipos de soluciones que pueden ser empleadas para encontrar la ubicación óptima o ideal de diferentes instalaciones o servicios.

En la Figura 3, se ilustra la tipología de los modelos de localización. Daskin, en su libro *Network and Discrete Location Models, Algorithms, and Applications*, clasifica los

modelos de localización en: analíticos, continuos, de redes y discretos. Para ello toma en cuenta diversas formas de representar la demanda y la oferta.

Daskin (2011) manifiesta que los modelos analíticos suponen la distribución uniforme de la demanda sobre el espacio. Este tipo de modelo suele suponer que la demanda se distribuye uniformemente en una región. Al decir que está uniformemente distribuida, implica que la densidad de la demanda se mantiene constante a lo largo de la forma de la región. También, los sitios candidatos se pueden encontrar en cualquier lugar dentro de la región de servicio. Es obvio que los modelos analíticos se basan en unas premisas demasiado amplias.

Figura 3. Taxonomía alternativa de modelos de localización



Fuente: Elaboración propia a partir de Daskin 2010.

Por otro lado, los modelos de localización continua presuponen que la demanda está en lugares discretos. De acuerdo con estos modelos, el tamaño de la demanda en determinados lugares se conoce de antemano. Mientras, los candidatos pueden estar dispersos en cualquier lugar del territorio (Daskin, 2008; Plastria, 1995).

En cuanto a los modelos de localización en la red, la demanda y las instalaciones candidatas se tratan como si estuvieran situadas en una red formada por nodos y arcos. La demanda y las instalaciones deben conectarse a la red para que ocurran las interrelaciones entre ambos. En general, en estos modelos, la demanda se sitúa en los nodos, mientras que las instalaciones candidatas pueden situarse en los nodos o

en los arcos. En la presente tesis doctoral utilizaremos modelos de localización que toman en cuenta la demanda y los candidatos ubicados sobre la red de transporte.

Por último, los modelos de ubicación discreta no hacen ninguna suposición específica sobre la demanda y la ubicación de las instalaciones (Bahadori et al., 2021). Ellos, sencillamente, proporcionan las ubicaciones o coordenadas de los nodos de la demanda y las ubicaciones potenciales (Daskin, 2011).

Durante décadas, se han investigado numerosos tipos de modelos de localización. Aunque las situaciones donde se utilizan estos modelos varían; sin embargo, sus características fundamentales siguen siendo constantes. Los modelos, por ejemplo, requieren: 1) consumidores –cuya ubicación en el espacio analizado es conocida–, 2) instalaciones –cuya ubicación debe establecerse utilizando alguna función objetivo–, 3) y un espacio geográfico sobre el cual aplicar los modelos (ReVelle et al., 2008).

Como señalan Current & Schilling (2002), los MLA requieren alguna medida relacionada con la distancia para evaluar los resultados del modelo. Estas medidas pueden ser: la longitud, el tiempo o coste del viaje. En cambio, Hale & Moberg (2003) destacan que los modelos de localización de instalaciones pueden variar en cuanto a: su función objetivo, la métrica de la distancia utilizada, la cantidad y el tamaño de las instalaciones a encontrar y una variedad de otros índices de elección. En cuanto a la función de sus aplicaciones, se deben incorporar y considerar los múltiples índices usados en la formulación del problema, esto dará lugar a modelos de localización muy diferentes.

Por otro lado, Thomas (2002) sostiene que los problemas de localización deben abordar las siguientes interrogantes: 1. ¿Cuántas instalaciones deben construirse? 2. ¿Cuál es el mejor lugar para localizarla? Y 3. ¿Cuál debe ser el tamaño y la forma de la cobertura de esta nueva infraestructura de servicios? Estas cuestiones deben formularse para determinar si es necesario construir nuevas instalaciones que ofrezcan una mejor cobertura a los clientes potenciales o cerrar, las existentes, por falta de demanda.

La primera pregunta está condicionada por las restricciones presupuestarias y el tipo de solución que se busca con el modelo. Por ejemplo, si lo que se desea es dar servicio a toda la demanda, el número de instalaciones resulta indiferente. La segunda interrogante está relacionada con la correcta elección de los emplazamientos que

representan las posibles instalaciones a construir para dar un mejor servicio al consumidor. También se debe tomar en cuenta el territorio donde se suele concentrar la población a la que servirán las nuevas instalaciones. La tercera cuestión se refiere a la capacidad de los usuarios que pueden cubrir las instalaciones. La forma de cobertura guarda relación con el tipo de función objetivo a resolver, es decir, si se pretende minimizar las instalaciones, maximizar la cobertura o minimizar el tiempo de desplazamiento de los usuarios del servicio.

Esta tesis se enfoca en las funciones objetivo de las soluciones que están incorporadas en los programas SIG. Entre estas tenemos los modelos de máxima cobertura, maximizar cobertura con capacidad restringida, minimizar la impedancia, minimizar las instalaciones, maximizar la asistencia y maximizar cuota de mercado compartido. En los siguientes apartados se aborda en que consiste la función objetivo de estos modelos y la formulación matemática que los sustentan.

#### *2.1.4.1 Modelo de cobertura máxima*

Los modelos que buscan la máxima cobertura de la demanda han sido importantes enfoques espaciales, que apoyan la planificación estratégica, la gestión y la toma de decisiones en contextos del sector público y privado. El concepto de cobertura suele relacionarse con la prestación de servicios, reconociendo que los criterios de respuesta, como el acceso y la asequibilidad, son fundamentales (Xu et al., 2022). Por su parte, Church & Murray (2018) definen la cobertura como un criterio de distancia máxima o tiempo de viaje para que las personas –demanda o clientes– reaccionen a una solicitud de servicio.

La solución cuyo objetivo es maximizar la cobertura consiste en cubrir el máximo número de la demanda atendida, en una distancia o tiempo de viaje determinado (dado un número limitado de instalaciones) (Church & ReVelle, 1974). Para Bosque et al.(2012), esta solución se basa en dos supuestos: en primer lugar, que a partir de una determinada distancia, la prestación de servicios se reduce considerablemente y por consiguiente es imprescindible que la mayor parte de la demanda se localice dentro de ese límite; y en segundo lugar, que las restricciones presupuestarias permiten la creación de un número limitado de centros de servicios, que resultan insuficientes para atender toda la demanda dentro de la distancia dada.

Resulta que un sitio de demanda está cubierto si se encuentra dentro del umbral de tiempo o distancia impuesto para la elección de candidatos (Church & ReVelle, 1974; Cordeau et al., 2019). En la mayoría de los casos, la demanda se considera satisfecha cuando, al menos, un establecimiento puede alcanzarla dentro de un umbral de distancia predeterminado. Hale & Moberg (2003), explican que puede darse el caso de que, con el objetivo de máxima cobertura, algunos puntos de demanda de las instalaciones existentes puedan quedar insatisfechos –no cubiertos– por situarse fuera de los umbrales de tiempo o distancia.

La ecuación para esta solución, la presentan por primera vez (Church & ReVelle, 1974). En esta tesis mostramos la función objetivo encontrada en la obra de (Bosque et al., 2012):

Función objetivo:

$$\begin{aligned} \text{Maximizar } F = & d_1 t_{11} x_{11} + d_1 t_{12} x_{12} + \dots + d_1 t_{1n} x_{1n} + \\ & d_2 t_{21} x_{21} + d_2 t_{22} x_{22} + \dots + d_2 t_{2n} x_{2n} + \dots + \\ & d_i t_{i1} x_{i1} + d_i t_{i2} x_{i2} + \dots + d_i t_{in} x_{in} + \dots + \\ & d_m t_{m1} x_{m1} + d_m t_{m2} x_{m2} + \dots + d_m t_{mn} x_{mn} \end{aligned}$$

Esta función objetivo puede escribirse así:

$$\text{Maximizar } F = \sum_{i=1}^m \sum_{j=1}^n d_i t_{ij} x_{ij}$$

Donde,

$i = \text{sitios de demanda } (i = \{1, 2, 3, \dots, m\})$

$j = \text{sitios candidatos } (j = \{1, 2, 3, \dots, n\})$

$d_i = \text{demanda en el sitio } i$

$$t_{ij} = \begin{cases} 1 & \text{si } t_{ij} \leq R \\ 0 & \text{si } t_{ij} > R \end{cases}$$

$x_{ij} = \text{proporción de la demanda } i \text{ asignada al centro } j$

$m_i$  es el conjunto de sitios de demanda a ser cubiertos por los candidatos  $j$ ,  $n_j$  es el conjunto de sitios candidatos. El valor de  $R$  es el radio establecido que puede ser en términos de tiempo o distancia. En realidad  $t_{ij}$  lo que hace es considerar como no

cubierta la demanda de aquellos lugares localizados a una distancia superior que del centro más próximo. El objetivo es maximizar el número de personas servidas o cubiertas dentro de una distancia previamente establecida.

Farahani et al. (2012) afirman que los MLA con la función objetivo de maximizar la cobertura han sido, históricamente, bastante atractivos para la investigación. Esto se debe a que son aplicables en situaciones del mundo real, especialmente en el caso de los establecimientos de emergencia y de numerosos equipamientos privados. Ciertos problemas de cobertura requieren que un cliente sea atendido por al menos una instalación dentro de una determinada distancia crítica. En la mayoría de los problemas de cobertura, las instalaciones sirven a los clientes en función de su proximidad a la instalación. El consumidor puede obtener el servicio de cualquier instalación dentro de una distancia determinada. En el trabajo de Marianov & ReVelle (1995) se resumen investigaciones en las que se ha empleado la solución de máxima cobertura.

En síntesis, el modelo de máxima cobertura permite obtener resultados que contemplan la mayor área de demanda según ciertos criterios de distancia o tiempo transcurrido entre la oferta y la demanda (Rahman et al., 2021).

#### *2.1.4.2 Modelo P-mediano (minimizar impedancia)*

Es uno de los modelos más antiguos que se han concebido dentro de la teoría de la localización. La primera formulación explícita del problema p-mediano la realizó Hakimi (1964). Definió el problema en una red de nodos y arcos. Consideró cada nodo como una localización de demanda y una localización potencial de instalaciones. El objetivo del modelo es encontrar la mejor ubicación de instalaciones entre múltiples candidatos para minimizar la distancia total (o media) entre todas las demandas y sus instalaciones más cercanas.

Para Church & Sorensen (1996); Kotavaara (2018); Rahman et al.(2021) y Rodríguez et al. (2017) el modelo p-mediano da como resultado una distribución de alguna cantidad de instalaciones que minimizan la suma de las distancias entre los puntos de demanda y el equipamiento de suministro más cercano. Church & Sorensen (1996) argumentan que la accesibilidad se maximiza reduciendo la distancia ponderada y al minimizar la distancia ponderada, también se minimiza la distancia media recorrida por la demanda hasta el equipamiento más cercano.

El trabajo de Church & Sorensen (1996) presenta una revisión de la solución minimizar impedancia y las modificaciones que se han incorporado a lo largo del tiempo. Por otro lado, Karatas & Yakıcı (2019) revisan la literatura sobre los diferentes casos de estudio que utilizaron la solución minimizar impedancia (p-mediano). Existe una larga lista de aplicaciones de este modelo de localización-asignación a diversos servicios públicos y privados (véase, por ejemplo, la Tabla 1 del apartado 2.1.1 de esta tesis).

La función objetivo del problema p-mediano es la presentada por Hanjoul & Peeters, (1985):

$$\text{Minimizar } F = \sum_{i=1}^m \sum_{j=1}^n a_i d_{ij} x_{ij} \quad (1)$$

Sujeta a:

$$\sum_{j=1}^n x_{ij} = 1 \quad i = \{1, 2, \dots, m\} \quad (2)$$

$$\sum_{j=1}^n y_j = p \quad (3)$$

$$y_j \in \{0, 1\} \quad j = \{1, 2, \dots, n\} \quad (4)$$

$$0 \leq x_{ij} \leq y_j \quad i = \{1, 2, \dots, m\}, j = \{1, 2, \dots, n\} \quad (5)$$

Donde

$i = \text{sitios de demanda } (i = \{1, 2, 3, \dots, m\})$

$j = \text{sitios candidatos } (j = \{1, 2, 3, \dots, n\})$

$a_i = \text{demanda en el sitio } i$

$d_{ij} = \text{la distancia entre el sitio de demanda } i \text{ al sitio candidato } j$

$x_{ij} = \text{la variable de decisión}$

$y_j = \begin{cases} 1 & \text{si el sitio de demanda } i \text{ es asignado al sitio candidato } j \\ 0 & \text{en caso contrario} \end{cases}$

La restricción (2) significa que la demanda en  $i$  debe ser cubierta por alguna instalación  $j$ , la restricción (5) previene una asignación a instalaciones que no existen y la restricción (3) garantiza que se localicen exactamente  $p$  instalaciones.

El modelo  $p$ -mediano ubica simultáneamente  $p$  instalaciones de manera que la distancia media de los usuarios a su instalación más cercana sea mínima (restricción 1). Se trata de un conjunto de puntos de demanda (señalados como  $i$ ) y un conjunto (posiblemente idéntico) de ubicaciones candidatas (señaladas como  $j$ ). Se espera que cada punto de demanda sea atendido en su totalidad por el servicio situado más cerca de él (4). El número de instalaciones es una de las entradas del modelo (2).

Utilizar la solución de minimizar la impedancia implica la búsqueda del beneficio del ciudadano, asegurando que la distancia y el tiempo de viaje al servicio sea más corto (Bolori Arabani & Farahani, 2012; Fredriksson et al., 2019; Peeters & Thomas, 2000). Minimizando la impedancia se localizan las instalaciones dentro de un número de candidatos previamente establecidos, reduciendo la suma de los costes de viaje ponderados (Daskin, 2011; Huotari et al., 2020; Jia et al., 2007; Kotavaara, 2018). La distancia total de viaje entre las instalaciones y los sitios que representan la demanda es importante en diversas situaciones de planificación de las instalaciones públicas y privadas (Current & Schilling, 2002).

Por otro lado, Peeters & Thomas (2000), sostienen que la selección óptima de los emplazamientos de suministros y el valor de la distancia total no son las únicas características de la solución de un problema  $p$ -mediano, ya que el número de puntos de demanda asignados a un emplazamiento da el nivel de actividad de éste y, por consiguiente su tamaño en términos de recursos humanos y materiales que deben asignarse. Además, el área que debe ser atendida por un centro y la correspondiente distribución de distancias entre los puntos de demanda y el centro son otros dos aspectos importantes.

#### *2.1.4.3 Modelo minimizar instalaciones (Set Covering Model)*

Hakimi fue el primero en plantear el problema de minimización de instalaciones y, posteriormente, Toregas et al. (1971) añadieron algunas modificaciones a la ecuación inicial. Según estos autores, se trata de un problema de localización que consiste en definir el menor número de instalaciones y sus ubicaciones. Además, cada sitio de demanda está contenido dentro de un radio de distancia o tiempo preestablecido de

su instalación más cercana. En este mismo orden de ideas las investigaciones de Bosque et al., (2012); Lei et al., (2016); X. Li et al., (2011); Mete et al., (2018) afirman que la función objetivo de este modelo es determinar el menor número de instalaciones posible y asegurar que la demanda no se encuentre más allá de un umbral de distancia o tiempo predefinido del servicio.

Daskin (2011) define el problema de minimización de instalaciones en encontrar un conjunto de instalaciones de coste mínimo, en un conjunto finito de instalaciones candidatas de forma que cada nodo de la red esté cubierto por al menos una instalación. Özceylan et al. (2017) plantean que el problema de minimización de instalaciones pretende llegar a cada clúster de demanda, al menos una vez en un tiempo predeterminado, considerando el desplazamiento en la red. El objetivo que se persigue consiste en minimizar los costes (medidos por el número de puntos de servicio o instalaciones), pero está limitado por el ámbito espacial definido por los responsables de la toma de decisiones.

La función objetivo elaborada por Toregas & ReVelle (1972) para explicar el problema minimizar las instalaciones es la siguiente:

$$\text{Minimizar } Z = \sum_{j=1}^n x_j \quad (6)$$

Sujeta a:

$$\sum_{j \in N_i} x_j \geq 1 \quad i = \{1, 2, \dots, m\} \quad (7)$$

$$x_j = \{0, 1\} \quad j = \{1, 2, \dots, n\} \quad (8)$$

$$N_i = \{d_{ij} \leq S\} \quad i = \{1, 2, \dots, m\}, j = \{1, 2, \dots, n\} \quad (9)$$

Donde

$i = \text{sitios de demanda}$

$j = \text{sitios candidatos}$

$$x_j = \begin{cases} 1 & \text{si localizamos una instalación en el sitio candidato } j \\ 0 & \text{en caso contrario} \end{cases}$$

$d_{ij} = \text{distancia más corta desde un punto } j \text{ hasta el punto } i$

$S = \text{máximo tiempo o distancia que separa a un punto } i \text{ del punto } j \text{ más cercano}$

$N_i = \text{conjunto de instalaciones elegibles para cubrir un punto de demanda } i$

La función objetivo (6) minimiza el costo total de las instalaciones seleccionadas. La restricción (7) establece que cada punto de demanda debe ser cubierto por al menos una instalación. La restricción (9) supone que la cobertura del sitio  $j = \{1, 2, \dots, n\}$  está formada por todos los sitios candidatos  $N_i$  cuya distancia a  $i$  ( $d_{ij}$ ) es menor o igual a  $S$ .

En los trabajos de Caprara et al. (2000); Farahani et al. (2012); Li et al. (2011), se pueden encontrar algunos ejemplos de problemas cuyo objetivo consiste en minimizar las instalaciones. Existen ejemplos de soluciones de minimización de instalaciones aplicadas a la optimización de estaciones de bomberos (Han et al., 2020), sucursales bancarias (Miliotis et al., 2002), sitios de tratamiento de basura (Chukwuma, 2019), farmacias (Özceylan et al., 2017), entre otros.

En definitiva, el propósito de este modelo es buscar la cantidad mínima de instalaciones necesarias para abastecer todos los sitios de demanda (Suraraksa & Shin, 2019). En consecuencia, se requiere un criterio bastante estricto y es que cada usuario del servicio sea cubierto. En el caso hipotético donde la población se represente con una distribución muy dispersa en el territorio, la exigencia de cobertura total de la demanda puede llevar a soluciones inviables desde el punto de vista presupuestario (Revelle & Eiselt, 2005).

#### 2.1.4.4 Problema de maximizar cuota de mercado

Los MLA evalúan las posibles ubicaciones de las instalaciones de un tipo determinado y calculan su capacidad para cumplir objetivos predefinidos y satisfacer la demanda de un número determinado de instalaciones (Ribeiro & Antunes, 2002). La solución que se muestra en el apartado anterior propone, esencialmente, cubrir la totalidad de la demanda sin considerar el número mínimo de instalaciones necesarias para alcanzar este objetivo.

En el modelo de maximización de la cuota de mercado entra en juego una nueva instalación conocida como competidores. En los estudios de localización-asignación, este tipo de soluciones se ocupan de la ubicación de los establecimientos o instalaciones que operan en un mercado competidor. Estos establecimientos asignan su cuota de mercado para aumentar sus beneficios (Saidani et al., 2012).

En la literatura, el trabajo de Hotelling (1929), se considera el primer estudio que analiza la localización competitiva de los establecimientos. Posteriormente, Drezner (1982) y Hakimi, (1983) abordaron el tema considerando que cada consumidor frecuenta la instalación más cercana. El problema de localización en entornos competitivos se utiliza, generalmente, para la ubicación de instalaciones comerciales. En consecuencia, el objetivo de los empresarios es, primordialmente, obtener el mayor número de clientes para su negocio en una situación de competencia (Uno et al., 2009).

Esta solución supone la existencia de competidores establecidos en el área de estudio, además, de un conjunto de instalaciones abiertas por una empresa y varias ubicaciones candidatas donde la empresa desea abrir algunas sucursales para ofrecer el servicio a los clientes. El modelo busca maximizar la red de servicios de la empresa asignando la demanda al centro más cercano (Goodchild 1984). Según Serra et al. (1999), un modelo de localización con un escenario de competencia en la demanda se define como aquel donde "hay más de una empresa compitiendo en un mercado espacial, y existe una interacción entre ellas; la decisión de localización de una empresa afectará no sólo a su cuota de mercado, sino también a la de su competidor".

El modelo identifica las ubicaciones óptimas donde establecer una o varias instalaciones nuevas en competencia para maximizar la captación de cuota de mercado. En consecuencia, la instalación recién añadida debe competir con las instalaciones ya establecidas en el mercado (Yang & Yang, 2005; Plastria, 2001; Shan et al., 2019; Suárez-Vega et al., 2012). Una explicación de este tipo de modelo puede encontrarse en las revisiones de la literatura de (Eiselt et al., 1993; Hakimi, 1990; Plastria, 2001).

La cuota de mercado de cada establecimiento viene determinada por su proximidad a los clientes y otras características específicas de los establecimientos. Huff (1964); Nakanishi & Cooper (1974); Saidani et al.(2012) añaden características específicas

de los establecimientos que contribuyen a su mayor atractivo, como el tamaño, el espacio de aparcamiento, o la calidad del producto que ofrecen. Por tanto, un individuo se desplazará a un establecimiento más lejano sólo si es más atractivo (Peeters, 1996).

En todo caso, dado que una de las características más importantes del atractivo de las instalaciones es la distancia a las mismas (Drezner, 1996), surgen modelos gravitacionales que predicen el flujo de usuarios desde las zonas residenciales hacia determinados centros de servicios. Los modelos de este tipo tienen su origen en Huff (1964), quien propuso que la utilidad de una instalación está determinada por su tamaño sin tener en cuenta otras consideraciones.

En definitiva, los modelos en entornos competitivos consideran varios factores que afectan a los consumidores y a los proveedores de productos y servicios. Es necesario modelar el comportamiento de los usuarios, considerando aspectos como: el tipo de usuarios, el número de instalaciones, la calidad de los productos y la ubicación, que pueden influir en las decisiones de los usuarios finales (Suárez-Vega et al., 2012).

ReVelle (1986) formula la función objetivo del modelo. Su enunciado básico es el siguiente: dada la existencia de varios establecimientos en una ubicación conocida y fija, se busca entre los emplazamientos candidatos conocer cuál conjunto de ellos lograría la máxima demanda para la nueva empresa, en competencia con los existentes. Se utiliza para determinar la ubicación de nuevos establecimientos que buscan maximizar su cuota de mercado, en un escenario con presencia de otros competidores (Jun Yang & Yang, 2005).

La función objetivo del modelo es la siguiente:

$$\text{Maximizar } Z = \sum_{i=1}^m a_i y_i + \sum_{i=1}^m \left(\frac{a_i}{2}\right) z_i$$

Sujeta a:

$$y_i \leq \sum_{j \in N_i} x_j \quad i = \{1, 2, \dots, m\}; j = \{1, 2, \dots, n\} \quad (10)$$

$$z_i \leq \sum_{k \in K_i} x_k \quad i = \{1, 2, \dots, m\} \quad (11)$$

$$z_i + y_i \leq 1 \quad i = \{1, 2, \dots, m\} \quad (12)$$

$$\sum_{j \in J_0 \cup J_N} x_j = P \quad (13)$$

Siendo:

$i$  = sitios de demanda que están disponibles para la captura ;

$j$  = sitios candidatos para las instalaciones;

$J_0$  = conjunto instalaciones ocupadas;

$J_N$  = conjunto instalaciones no ocupadas y son elegibles ;

$a_i$  = la población en el nodo  $i$

$y_i = \begin{cases} 1 & \text{si el nodo } i \text{ consigue un nuevo servicio dentro de } S_i \text{ que esta más cercano a } i \\ 0 & \text{en caso contrario} \end{cases}$

$x_j = \begin{cases} 1 & \text{si la instalación está localizada en } j \\ 0 & \text{en caso contrario} \end{cases}$

$N_i = \{j \in J_N \mid d_{ij} < S_i\}$ ; conjunto de instalaciones que están estrictamente más cerca del nodo  $i$  que a su servicio más cercano.

$d_{ij}$  = distancia más corta entre el sitio  $i$  y el sitio  $j$  ;

$S_i$  = distancia desde el nodo  $i$  hasta el sitio  $j$  más cercano ;

$K_i$  = el conjunto de instalaciones ocupadas y desocupadas localizadas a igual distancia de  $i$  como el equipamiento  $i$  más cercano.

$z_i = \begin{cases} 1 & \text{si el nodo } i \text{ es captado por un servicio localizado dentro de } K_i \\ 0 & \text{en caso contrario} \end{cases}$

si el nodo  $i$  es capturado por un equipamiento localizado dentro de  $K_i$  es decir el equipamiento actualmente más cercano a  $i$  o a un equipamiento cuya distancia desde  $i$  es igual a la distancia desde  $i$  hasta el equipamiento más cercano actualmente, entonces  $z$  es 1 si es capturada y doblemente equipado.

Las restricciones (10) son la base de la formulación. Explica que un punto de demanda no es captado por un nuevo equipamiento a menos que un equipamiento esté situado en un lugar más cercano a  $i$  que su equipamiento actual más cercano.

Las restricciones (11) indican que un nodo de demanda  $i$  es captado, pero doblemente servido ( $z = 1$ ) sólo si un nuevo equipamiento está situado en una posición  $k \in K$ , el conjunto de posiciones, igualmente, distante de  $i$  como el proveedor actual más cercano actual al nodo  $i$ . Las restricciones (12) son utilizadas para prevenir que un sitio de demanda sea captado en más de una ubicación. Las restricciones (13) limitan el número de nuevos equipamientos. Lo que se expresa es que si el coste de desplazamiento desde el punto de demanda hasta el sitio donde se asentaría el competidor entrante es menor que el actual, entonces el nuevo establecimiento competidor captura la demanda, si el coste de desplazamiento es el mismo, entonces la demanda se reparte entre los dos (el establecimiento nuevo y el preexistente) y, finalmente, si el coste de desplazamiento respecto al sitio más próximo del competidor entrante es mayor, entonces este no captura dicha demanda (Bosque et al., 2012).

El modelo que se describe en esta sección ha sido aplicado, por varios autores, para localizar sitios de ventas al por menor (Saidani et al., 2012; Suárez-Vega et al., 2012), centros comerciales (Ahmad et al., 2017), estaciones de bicicletas (Banerjee et al., 2020) entre otras aplicaciones. Más adelante en el apartado 4.1.4 se sigue desarrollando la literatura relacionada al uso de los modelos de localización-asignación que consideran entornos de competencia.

En resumen, los MLA que implican competencia tratan de encontrar ubicaciones y costes que maximizan la captación de mercado –en términos de clientes o beneficios– de los competidores ya posicionados en el mercado. Por tanto, a la hora de ubicar la nueva instalación, es importante analizar características como el tamaño, el tipo de clientes, etc., que pueden afectar a su rendimiento. Por ejemplo, la proximidad al mercado es crucial para que una organización de servicios atraiga clientes con éxito. Al mismo tiempo, para una fábrica, la ubicación de sus instalaciones puede afectar a los costes de aprovisionamiento, el tiempo de entrega y los niveles de servicio (Saidani et al., 2012).

#### *2.1.4.5 Maximizar cobertura con capacidad en las instalaciones predeterminada*

Los problemas de minimización de instalaciones y maximización de la cobertura discutidos en las subsecciones anteriores han ganado una atención significativa en la literatura de localización de instalaciones, debido a su aplicación en varios casos del mundo real. Estos problemas han cambiado en numerosas ocasiones a medida que

se han aplicado a diversos escenarios de planificación de servicios públicos (Current & Storbeck, 1988).

Salari (2014) sostiene que, en los problemas de maximizar cobertura, el supuesto de partida consiste en que las instalaciones disponen de una capacidad ilimitada para satisfacer la demanda. En realidad, la mayoría de las instalaciones tienen límites en el número de usuarios que pueden atender (Murray & Gerrard, 1997). Por ello, algunos modelos de cobertura incorporan una restricción de capacidad a los establecimientos. Esta restricción da lugar al modelo de maximizar cobertura con capacidad predeterminada. Aunque, la posibilidad de adoptar esta restricción de capacidad en la formulación de los problemas de localización resulta sencilla, incrementa la complejidad computacional.

Current & Storbeck (1988) fueron pioneros en el planteamiento de modelos de localización con asignación de la demanda ajustada a un número preestablecido de clientes que pueden ser atendidos. En este modelo, se supone que el volumen de demanda asignado a cada instalación no supera los límites de capacidad predefinidos y la demanda se asigna, como máximo, a un solo equipamiento (Hashim et al., 2017). Es decir, existe una capacidad fija para el número de clientes o usuarios que cada instalación atiende (Elkady & Abdelsalam, 2015).

Los equipamientos son localizados en forma tal que el máximo número de sitios de demanda se otorgan a instalaciones de la solución que están situadas dentro del umbral de impedancia; además, la ponderación de la demanda asignada a un equipamiento no puede exceder la capacidad establecida para las instalaciones. Por consiguiente, el objetivo de este modelo consiste en ubicar un determinado número de instalaciones, de manera que se logre maximizar la demanda total cubierta, tomando en cuenta que a ninguna instalación se le asigne una demanda que exceda su capacidad (Current & Storbeck, 1988). Así pues, el modelo de maximizar cobertura con restricciones de capacidad –número de clientes atendidos– presupone la existencia de un mecanismo de racionamiento de servicios.

Tomando como referente a Current & Storbeck (1988), el modelo de maximizar cobertura con capacidad predeterminada tiene la siguiente función objetivo:

$$\text{Minimizar } Z = \sum_{i=1}^m a_i U_i \quad (14)$$

Sujeto a:

$$\sum_{j \in N_i} X_{ij} + U_i = 1 \quad i = \{1, 2, \dots, m\} \quad (15)$$

$$\sum_{i \in M_j} a_i X_{ij} - k_j Y_j \leq 0 \quad j = \{1, 2, \dots, n\} \quad (16)$$

$$\sum_{j=1}^n Y_j = p \quad (17)$$

$$Y_j \in \{0, 1\} \quad j = \{1, 2, \dots, n\} \quad (18)$$

Donde:

$i$  = sitios de demanda

$j$  = sitios candidatos

$a_i$  = es la demanda en el punto  $i$

$U_i$  es el porcentaje de demanda en el punto  $i$  que no está cubierto

$X_{ij}$  = es la fracción de demanda en la localización  $i$  asignada al punto  $j$

$N_i$  es el conjunto de sitios candidatos a los que se pueden asignar la demanda localizada en  $i$

$k_j$  = es la capacidad que cubre la instalación  $j$

$M_j$  es el conjunto de localizaciones de la demanda que pueden ser servidos por un candidato  $j$

La función objetivo (14) busca minimizar la demanda total que no está cubierta por ningún equipamiento. El conjunto de restricciones (15) mide el porcentaje de demanda en cada punto de demanda que se asigna a una instalación que lo cubre o que debe contarse como no cubierto. El conjunto de restricciones (16) asegura que la demanda total asignada a una instalación no exceda la capacidad de dicha instalación. Esta restricción también asegura que la demanda sólo se asignará a los emplazamientos de instalaciones potenciales que tengan instalaciones realmente ubicadas en ellos. La

restricción (17) asegura que se abran exactamente  $p$  instalaciones y el conjunto de restricciones (18) significa una variable de decisión según la cual un potencial sitio debe ser ubicado o no (Hu et al., 2019).

En la literatura académica, relativamente son pocos los trabajos que se apoyan en el modelo de maximizar cobertura con restricciones de capacidad (Yin & Mu, 2012). En cuanto a las aplicaciones del modelo, figuran su uso en la ubicación de sitios para dar refugio a víctimas de inundaciones (Hashim et al., 2017), estaciones de bicicletas (Hu et al., 2019) servicios de emergencias (Yin & Mu, 2012) centros médicos (Shariff et al., 2012) tratamiento de desechos sólidos (Erfani et al., 2018).

#### 2.1.4.6 Modelo maximizar asistencia

La gente considera más atractivos los bienes y servicios cuyos costes de desplazamiento son menores. Por tanto, el número de personas que utilizan o consumen el bien o servicio disminuye con la distancia, incluso cuando están dentro de un umbral de cobertura fijado. En esta solución se busca maximizar la demanda localizada dentro de un umbral de distancia, dando más importancia a la demanda que está más cerca de los puntos de servicio (Alonso, 2016). Según Algharib (2011) la solución permite optimizar la demanda con respecto a la distancia y el tiempo que se tarda en llegar al punto de atención. La solución tiene como objetivo cubrir una parte de la demanda y no proporciona una cobertura completa de la totalidad de la población usuaria del servicio. Por lo tanto, maximizar la asistencia implica que cuanto más lejos tenga que viajar la gente para emplear un centro, menor será la probabilidad de utilizarlo.

La función objetivo de la solución maximizar asistencia es la siguiente (Holmes et al., 1972)

$$\text{Maximizar } Z = \sum_{i=1}^m \sum_{j=i}^n p_i (S - d_{ij}) x_{ij}$$

$i = \text{sitios de demanda}$

$j = \text{sitios candidatos}$

$p_i = \text{población de la demanda } i$

$S = \text{umbral de distancia}$

$d_{ij}$  = distancia o tiempo de viaje entre el sitio de demanda  $i$  y la localización  $j$

$x_{ij}$  = variable de decisión que tomará en valor de 1 si la demanda  $i$  es cubierta por el sitio candidato  $j$  y 0 en caso contrario.

Nuevamente son pocos los trabajos que se han realizado utilizando el modelo de maximizar la asistencia en comparación con los modelos iniciales. Por ejemplo, Erfani (2018) y Alonso (2016) lo aplican para un sistema de gestión de residuos sólidos. El modelo elige las instalaciones candidatas de manera que se pueda asignar el mayor peso posible de la demanda a las estaciones de almacenamiento de residuos. Sin embargo, asume que cuanto más lejos tengan que caminar las personas para llegar a la estación, menos probable será que la utilicen. Por último, dado que la demanda de cada lugar sólo se da a la instalación más cercana, es importante señalar que los costes de desplazamiento representan el único atractivo que se tiene en cuenta para asignar la demanda correspondiente a cada instalación. Además, hay que tener en cuenta que los centros de servicio no compiten, sino que intentan atender al mayor número de personas posible.

#### 2.1.5 Campos de aplicación de los MLA en entornos SIG

Una vez explicados los fundamentos teóricos de los MLA, es el momento de indagar los diversos campos en los que se han aplicado, sobre todo aquellos, cuyas soluciones vienen integradas en los programas de Sistemas de Información Geográfica (SIG). Los SIG desempeñan un papel relevante para el desarrollo de los MLA en la tarea de recoger y organizar los datos espaciales, permiten mantener los atributos de las capas de datos que son partes necesarias de estos modelos y proporcionan las herramientas de procesamiento para que los interesados produzcan los datos en los formatos adecuados para el diseño del problema de localización (Forsey, 2014).

Debido a la diversidad de áreas del conocimiento donde se aplican los MLA, la Tabla 2 resume los casos de estudio de los MLA en entornos SIG, ordenándolos por autor, equipamiento, tema, lugar y el tipo de soluciones utilizadas.

Tabla 2. Resumen de casos de estudio aplicando MLA en SIG

Autores	Equipamiento	Tema	Lugar	Solución
(Namazian & Roghanian, 2019)	Banco	Comercio	Irán	Maximizar cobertura

(Roig-Tierno et al., 2013)	Supermercado	Comercio	España	Multicriterio
(Buzai & Baxandale, 1995)	Escuelas	Educación	Argentina	Minimizar la impedancia/maximizar la cobertura
(Wondwossen & Bedasa, 2019)	Escuelas	Educación	Etiopia	Minimizar la impedancia
(Malik & Shivamallu, 2017)	Estaciones de bomberos	Emergencia	India	Máxima cobertura
(Bolouri et al., 2018)	Estaciones de bomberos	Emergencia	Teherán	Maximizar cobertura
(Özceylan et al., 2017)	Almacenes de farmacia	Salud	Turquía	Minimizar la impedancia
(Chukwusa & Comber, 2018)	Centro de emergencias	Salud	Inglaterra	Minimizar la impedancia
(Ajebon & Asikhia, 2013)	Centros para dejar de fumar	Salud	Inglaterra	Minimizar la impedancia
(Alonso, 2016)	Desechos sólidos	Salud	España	Minimizar la impedancia
(Rosso, 2016)	Desechos sólidos	Salud	Argentina	Maximizar cobertura
(Erfani et al., 2018)	Desechos sólidos	Salud	Irán	Minimizar instalaciones, maximizar la cobertura capacitada, maximizar la asistencia
(El-Hallaq & Mosabeh, 2019)	Desechos sólidos	Salud	Palestina	Maximizar cobertura
(Kwon et al., 2017)	Desfibriladores	Salud	Corea del Sur	cuota de mercado objetivo
(Polo et al., 2015)	Esterilización de perros	Salud	Colombia	Máxima cobertura
(Ramírez & Bosque Sendra, 2001)	Centros de salud	Salud	Argentina	Minimizar la impedancia
(Ramírez, 2000)	Centro de salud	Salud	Argentina	Minimizar la impedancia
(Gutiérrez Puebla & Fernández Varone, 2013)	Centro de salud	Salud	España	Minimizar la impedancia/minimizar las instalaciones
(Abdelkarim, 2019)	Servicios de salud	Salud	Arabia Saudita	Máxima cobertura
(Murad, 2014)	Servicios de salud	Salud	Arabia Saudita	Máxima cobertura
(Buzai & Baxandale, 1995)	Servicios de salud	Salud	Argentina	Máxima cobertura
(Kiptenai & Hunja, 2013)	Servicios de salud	Salud	Kenia	Máxima cobertura
(Zhu et al., 2016)	Servicios de salud	Salud	China	Maximizar la cobertura capacitada

(Comber et al., 2015)	Digestores anaeróbicos	Salud	Inglaterra	Minimizar impedancia
(Vora et al., 2015)	Centro de Salud	Salud	India	Minimizar impedancia/Maximizar cobertura
(Fuenzalida & Moreno, 2010)	Centro de salud	Salud	Chile	Máxima cobertura
(Rodríguez, Sánchez et al., 2016)	Centro de Salud	Salud	Cuba	Minimizar la impedancia
(García-Palomares et al., 2012)	Bases de bicicletas	Servicio	España	Máxima cobertura, Minimizar la impedancia
(Yeh & Chow, 1996)	Espacios públicos	Servicio	Hong Kong	Minimizar la impedancia
(Palacios & Mora, 2012)	Módulos electorales	Servicio	México	Máxima cobertura
(Escobar Garcia et al., 2018)	Bases de bicicletas	Servicio	Colombia	Maximizar cobertura

Fuente: Elaboración propia.

Los MLA se han aplicado a temas relacionados al comercio, educación, emergencias, salud y servicios de emergencias por mencionar algunos. En lo referente al comercio encontramos los trabajos de Naazian & Roghanian, (2019) y Roig-Tierno et al., (2013), buscan encontrar la mejor ubicación a equipamientos como bancos y supermercados, utilizando la solución de maximizar la cobertura y las técnicas de análisis multicriterio.

En el ámbito educativo es común encontrar el uso de los MLA para ubicar escuelas (Buzai & Baxandale, 1995; Wondwossen & Bedasa 2019), cuya función objetivo fue minimizar la impedancia y maximizar la cobertura de la población estudiantil.

En cuanto al tema de emergencias se presentan casos en los que el objetivo era encontrar la mejor localización de estaciones de bomberos, donde se ofreciera la máxima cobertura a la población afectada, principalmente, por incendios (Bolouri et al., 2018; Malik & Shivamallu, 2017).

Existen muchos casos de aplicación de MLA a instalaciones relacionadas con la salud, dirigidos a encontrar la mejor ubicación de centros de salud, servicios de salud, manejo de desechos sólidos, desfibriladores, por mencionar algunos. Es importante acotar que, en la mayoría de estos casos, la función objetivo que se buscaba fueron las de minimizar la impedancia y maximizar la cobertura de la población atendida. Este aspecto se aprecia claramente en los trabajos de (Ajebon & Asikhia, 2013; Alonso,


2016; Chukwusa & Comber, 2018; El-Hallaq & Mosabeh, 2019; Erfani et al., 2018; Özceylan et al., 2017; Polo et al., 2015) entre otros.

Las aplicaciones de los MLA son usadas, además, para encontrar la mejor ubicación de las estaciones de un sistema de bicicletas compartidas, en ellas se aplicó las soluciones de minimizar la impedancia y maximizar la cobertura (Escobar Garcia, Zuluaga García, & Younes velosa, 2018; García-Palomares, Gutiérrez, & Latorre, 2012) También, se aprovechan los MLA para encontrar la mejor localización de equipamientos de servicios, tales como parques y módulos electorales (Palacios & Mora, 2012; Yeh & Chow, 1996).

En síntesis, los SIG son herramientas ampliamente utilizadas en los problemas de localización óptima debido a la facilidad que ofrecen para la administración de datos espaciales y no espaciales requeridos en los análisis. Integrar SIG y MLA en la planificación de las instalaciones es de gran apoyo para la administración pública al momento de ofrecer nuevas instalaciones o mejorar la eficiencia de las ya establecidas (Malik & Shivamallu, 2017).

Las soluciones más utilizadas son aquellas cuya función objetivo es maximizar la cobertura y minimizar la impedancia, además, el tema salud es donde más se aplican estos modelos (Figura 4).

Figura 4. Temática de los estudios de MLA aplicados en entornos SIG



Fuente: Elaboración propia.

Luego de examinar la diversidad de temas en los que se aplican los MLA, podemos vislumbrar los nuevos planteamientos que se pueden realizar al incorporar las nuevas fuentes de datos en la estimación de la demanda y con el uso de las nuevas redes de transporte. Se describen los trabajos que incorporan el Big Data en algunos de los datos de entrada requeridos para el planteamiento de los MLA.

## **2.2 Big Data y nuevas fuentes de datos**

A medida que entramos en la era del Big Data, tanto las empresas como las organizaciones obtienen un gran volumen de los datos de sus consumidores y socios, pero también de aquellos que obtienen a través de los sensores integrados en un gran número de dispositivos diferentes, que detectan y recogen datos de las personas (Manyika et al., 2011). El Big Data ofrece oportunidades para hacer nuestras ciudades más eficientes y sostenibles (más inteligentes). Los datos permiten a los gestores de las ciudades y a los residentes tomar decisiones más informadas y disfrutar de una mayor calidad de vida en sus ciudades (Wang, Zhenzhen 2018).

*Big Data* hace referencia a la gran cantidad de datos que, diariamente, se están generando a través de diversos medios. En este preciso instante, un sinnúmero de usuarios está navegando en internet a través de sus ordenadores, viendo programas por medio de sus smart tv o utilizando el teléfono móvil para realizar actividades en redes sociales como Facebook, Twitter Tiktok o Instagram. En consecuencia, los usuarios de estos dispositivos van dejando su huella digital, algunas veces involuntariamente. Además, una amplia red de sensores y cámaras ubicados en las ciudades también registran mucha información de sus habitantes, lo que ha dado lugar al internet de las cosas.

El *Big Data* implica la aglomeración de tendencias que se venían gestando desde la última década: social media, movilidad, aplicaciones, modernización de la velocidad del internet y la reducción del costo, interconexión de objetos a través de la red, el cloud computing. Todas ellas tienen un aspecto en común que consiste en la generación de datos para su posterior almacenamiento, procesamiento, análisis y visualización (Joyanes A., 2014).

El rápido desarrollo tecnológico que está viviendo la humanidad ha hecho posible que sigan apareciendo numerosos dispositivos capaces de generar datos para su posterior análisis. Todos estos medios y dispositivos han dado lugar a la producción de muchos

bytes (zettabytes<sup>3</sup>) de información que ofrecen la oportunidad para llevar a cabo análisis que antes eran imposibles de realizar. Todos estos millones de millones de bytes que se generan cada minuto trae consigo que los analistas de datos tengan que actualizar sus equipos por requerimientos de almacenamiento, procesamiento y capacitación del capital humano, para que puedan sacarles el mejor provecho.

Debido a la rápida popularidad que ha despertado el concepto, ha hecho posible que se le hayan otorgado características que muchos las resumen como las 3 V (tres uves): volumen, variedad, velocidad, (Fosso W. et al., 2015; García-Palomares et al., 2015; Gutiérrez Puebla, 2018; Nguyen et al., 2018). En otras ocasiones se otorgan 5 V (veracidad, valor) y otros le han otorgado dos características más, haciendo que se llegue hasta las 7 V (variabilidad y visualización).

La característica relacionada al volumen se refiere a la magnitud de los datos y los retos que implica como consecuencia, en materia de almacenamiento (Philip Chen & Zhang, 2014; Russom, 2011). En cambio, la variedad tiene que ver con la procedencia y tipo de estructura de los datos (Russom, 2011). La velocidad se refiere al atributo que se otorga al tiempo que transcurre entre la generación y la entrega de los datos (Nguyen et al., 2018). La veracidad se enfoca en la importancia de la calidad de los datos y el nivel de fiabilidad (Gandomi & Haider, 2015). El valor se caracteriza por la función de los productos y beneficios que se pueden conseguir a través del análisis de los datos (Fosso W. et al., 2015). La variabilidad se refiere al cambio constante de los datos (Ali et al., 2019). La visualización revela patrones ocultos en los datos. Es esencial para mejorar el rendimiento de los datos y los procesos relacionados con la toma de decisiones (Patgiri & Ahmed, 2017).

Brevemente, se presentan dos definiciones del concepto *Big Data*, tomando en cuenta la opinión de diferentes autores que intentan definir este concepto. De esta forma, Manyika et al. (2011) lo define como: “conjuntos de datos con un tamaño que está más allá de la capacidad de las herramientas típicas de software de base de datos para capturar, almacenar, administrar y analizar”. Del mismo modo, Joyanes A. (2014) define el concepto como: “Crecimiento exponencial de la creación de grandes volúmenes de datos origen o fuentes de datos y la necesidad de su captura, almacenamiento y análisis para conseguir el mayor beneficio para organizaciones y

---

<sup>3</sup> Según la RAE tamaño de los datos equivalente a 1024 exabytes (2<sup>70</sup> bytes). Símbolo: ZB

empresas junto con las oportunidades que ofrecen y los riesgos de su no adopción” (p.2).

En resumen, se trata de inmensos volúmenes de datos que requieren un gran espacio para el almacenamiento. En cuanto a los tipos de datos que provienen de las fuentes de *Big Data*, por lo general, estos se clasifican en estructurados y no estructurados. Joyanes A. (2014) define los datos estructurados como aquellos que poseen esquemas fijos y ordenados por campos, esto permite organizarlos en los sistemas gestores de bases de datos relacionales para su tratamiento, modificación o análisis. Así tenemos el uso que se le da en Excel, PowerBi, Sql, PostGis, entre otros.

En cambio, los datos no estructurados son aquellos que no tienen estructuras de datos relacionales predefinidas, éstos se almacenan como documentos, archivos de videos, audio, fotos, mensajes de texto, entre otros. Estos datos que no tienen una estructura fija y organizada por campos hacen difícil su análisis. Para hacer frente a esta situación se han creado nuevas herramientas para su manipulación, como Mapreduce, Hadoop y otras más.

En cuanto a la generación de datos, actualmente, son recabados de diversos sitios y dispositivos como los sensores que registran las condiciones meteorológicas, las imágenes de satélites, cámaras de videos, las transacciones bancarias que hacen uso de las tarjetas de crédito, las Smart Card utilizadas en el transporte, las tecnologías RFID<sup>4</sup>, los sistemas GPS, utilizados por los teléfonos celulares y, por los vehículos de transporte, y toda la información generada de nuestro uso de internet, como en las redes sociales.

### 2.2.1 Datos masivos geolocalizados

Cada día se generan 2,5 quintillones de bytes de datos, según la Iniciativa de las Naciones Unidas para la Gestión Mundial de la Información Geoespacial (UN-GGIM), y una parte considerable de esos datos tienen que ver con la localización. (Carpenter & Snell, 2013; Jo & Lee, 2018). Los datos geoespaciales se utilizan para describir objetos y acontecimientos en el espacio geográfico, y suelen estar asociados a coordenadas de posición en un sistema de referencia espacial (Loukili et al., 2020). Algunos estiman que "el 80% de los datos son geográficos" (Dempsey, 2012;

---

<sup>4</sup> Del inglés Radio Frequency Identification, es un sistema de almacenamiento y recuperación de datos remoto.

Hahmann et al., 2011) En definitiva, una gran parte de los datos pueden ser georreferenciados, lo que pone de manifiesto el carácter crítico de la gestión del Big Data geoespacial.

La recogida de datos geoespaciales, tradicionalmente, se realizaba a través de estudios terrestres, fotogrametría y teledetección. Actualmente podemos, además, recurrir al escaneado láser, los sensores geolocalizados, el contenido web geolocalizado, dispositivos móviles asociados a la red de telefonía, la información geográfica voluntaria (VGI), el sistema global de navegación por satélite (GNSS), entre otros dispositivos (Lee & Kang, 2015; Loukili et al., 2020).

Existen numerosos ejemplos de recogida de datos que podrían dar lugar a conjuntos de Big Data geoespacial, los cuales son útiles para captar la dinámica del entorno urbano. Desde un punto de vista social, por ejemplo, la última década ha sido testigo de la instrumentación de las ciudades, que ahora proporcionan grandes cantidades de datos en tiempo real a través de sistemas de transporte con tarjetas inteligentes, dispositivos de seguimiento de vehículos y otros sensores (Li et al., 2016). Al mismo tiempo, con el auge de las redes sociales, aparecen volúmenes masivos de datos (por ejemplo, los mensajes de Twitter) que se pueden geoetiquetar y utilizar para ayudar en la gestión de catástrofes y emergencias.


Li et al. (2016) consideran que la captura de datos geoespaciales está evolucionando de un paradigma de escasez de datos, a otro de riqueza. Hace algunos años la adquisición de datos geoespaciales dependía de dispositivos técnicamente exigentes, precisos, caros y complicados. Pero ahora la adquisición de datos geoespaciales es un producto básico implementado en dispositivos cotidianos utilizados por un gran número de personas. Los dispositivos son capaces de captar a un nivel sin precedentes, información geoespacial, en términos de precisión geométrica y temporal, así como de granularidad temática. Además, son compactos, fáciles de usar y capaces de adquirir datos incluso cuando no se utilizan conscientemente.

Por ejemplo, la información de geolocalización y temporal, recogida por los teléfonos inteligentes y los sistemas de posicionamiento global, se han convertido en una fuente creciente de datos. Los dispositivos de geolocalización y las diversas aplicaciones (Apps) se enfocan en el registro de la ubicación de los usuarios de teléfonos móviles en los diferentes momentos temporales en que se utilizan.

Las aplicaciones de geolocalización son numerosas. No obstante, hay que señalar que los datos de tiempo y ubicación constituyen una de las fuentes de macrodatos que traen asociados grandes riesgos para la confidencialidad de los usuarios (Joyanes A., 2014). En consecuencia, el *Big Data* geolocalizado proporciona, no sólo un nuevo tipo de fuentes de datos para los estudios geográficos, sino que, plantea un gran desafío sobre cómo administrarlos de manera eficiente y efectiva, específicamente, cómo desarrollar nuevos conocimientos (Jiang & Ren 2019).

El uso de Big Data geolocalizado es cada vez más frecuente en la literatura científica. Si tomamos, únicamente, como referencia los términos “Spatial Big Data” refinando la búsqueda por años y tipos de documentos en la base de datos científicos Scopus (Consulta TITLE-ABS-KEY ("Spatial Big Data" ) AND PUBYEAR > 2012 AND PUBYEAR < 2022 AND ( LIMIT-TO ( DOCTYPE , "ar" ) ) y Web of Science (Consulta "Spatial Big Data" (Topic) and 2013 or 2014 or 2015 or 2016 or 2017 or 2018 or 2019 or 2020 or 2021 or 2022 (Publication Years) and Article (Document Types) se obtiene como resultado 134 y 174 artículos relacionados al análisis espacial, para los últimos 10 años. La Figura 5 muestra la distribución de las investigaciones por área temática.

Figura 5. Resultados de búsqueda en Scopus y Web of Science



Fuente: Elaboración propia.

El Big Data geolocalizado (*Spatial Big Data*, *Geospatial Big Data*) constituye una valiosa materia prima para plantear estudios geográficos novedosos, ya que permite captar en tiempo real una gran cantidad de detalles del modo de vida de la población, tales como: ubicación geográfica, los patrones de movilidad, los patrones de consumo y muchas otras características que se pueden utilizar para llevar a la práctica diversos tipos de análisis espacio-temporales. Deng et al. (2019) manifiestan que el auge de

los Big Data geoespaciales ofrece nuevas formas de conocer el entorno urbano de una manera nunca vista hasta ahora. Hoy es posible recoger, compartir y analizar grandes volúmenes de datos sobre la ubicación de los usuarios durante el día, gracias al uso generalizado de sensores con GPS. Se puede pensar en las personas como *sensores*, y éstas pueden ayudar a recoger información sobre los sitios que frecuentan los ciudadanos y añadir atributos socioeconómicos a los datos geográficos (Goodchild, 2007; Li et al., 2016). Esto permite promover el desarrollo de nuevos conceptos y habilidades analíticas para las tecnologías de análisis espacial (Deng et al., 2019).

Cabe señalar que, el auge del Big Data geolocalizado se ha visto favorecido, en gran medida, por la amplia disponibilidad de dispositivos móviles con GPS, conexiones de teléfonos móviles a Internet y la potencia informática de alto rendimiento, todo lo cual ha facilitado el desarrollo de una serie de soluciones de servicios basados en la localización del cliente (McKittrick et al., 2022; Steiger et al., 2015). En consecuencia, los usuarios con sus dispositivos móviles generan, ahora, un enorme volumen de contenidos que son accesibles a terceros. Debido a la naturaleza geográfica de algunos de estos datos, se ha creado una oportunidad prometedora para que los investigadores de los SIG obtengan una visión de las pautas espaciales de la población (McKittrick et al., 2022).

Por otro lado, Hao et al. (2015) consideran que el Big Data geoespacial facilita que se transforme y revolucione la planificación territorial en cuanto a enfoques y metodologías. Por lo tanto, un sistema de planificación más humano, transparente, exacto, preciso, inteligente, eficiente y dinámico surge de manera progresiva debido al aumento del uso de Big Data geoespacial en las actividades de planificación.

Además, el Big Data geoespacial ha despertado el interés. De las empresas, pueden extraer información valiosa de sus clientes a partir de la gran cantidad de datos recolectados por los dispositivos móviles o los sensores en las ciudades. Todo este cúmulo de datos ha provocado el surgimiento de nuevas carreras, servicios, productos y líneas de investigación, que exigen la actualización de mejores equipos para el procesamiento y manejo de toda la información generada.

Cabe señalar, que, en función de la temática de la investigación a realizar, los requerimientos en cuanto a resolución espacial y temporal de los datos varía. Por

ejemplo, la resolución temporal debe ser alta cuando se quiere analizar la movilidad diaria de la población, pues requiere la identificación de los tiempos de permanencia de cada individuo en un área concreta y las horas en las que se llevan a cabo sus desplazamientos (Gutiérrez Puebla, 2018). Los datos con alta resolución espacial permiten una localización precisa de las actividades, los orígenes y destinos de los desplazamientos y las rutas seguidas por éstos (Gutiérrez Puebla et al., 2019). La alta resolución espacial, por ejemplo, de los datos geolocalizados almacenados por la red social Twitter permiten tener un aproximado de la densidad de población y de la estructura espacial de la ciudad durante el día. Los tuits geolocalizados resultan favorables para los estudios urbanos, al permitir el seguimiento espacio-temporal de los usuarios (Condeço-Melhorado et al., 2020). Por otro lado, la alta resolución espacial de los datos capturados por los proveedores de servicios de movilidad compartida permiten conocer las variaciones espaciotemporales de su uso en la ciudad (Arias-Molinares et al., 2021; Yang et al., 2020).

Las revisiones de Lee & Kang, (2015); Li et al., (2020); McKittrick et al., (2022) analizan los retos y las oportunidades que ofrece el Big Data geoespacial para abordar diferentes temáticas. Además, Hao et al. (2015) describen las aplicaciones en estudios urbanos y prácticas de planificación. Mientras que Stock (2018) realiza una revisión sistemática sobre los métodos de extracción de datos de las plataformas de redes sociales, y examina las tendencias generales de estas plataformas.

Por otro lado, cabe señalar que la abundancia de fuentes de datos permite obtener una "imagen completa" del fenómeno examinado, incluida su dinámica. Dicha imagen se acerca más a la realidad cuando se combinan y fusionan conjuntos de datos, lo que permite obtener diferentes aspectos o características de ese fenómeno (Ebert et al., 2009). En este sentido, hoy en día la aparición de diversos conjuntos de Big Data espacio-temporales, proporciona una infinidad de métodos de observación y percepción para los investigadores y los responsables políticos del medio ambiente urbano (Deng et al., 2019).

A la vez, el Big Data geoespacial se enfrenta a retos o problemas que van más allá de cómo almacenar, gestionar, procesar, analizar, visualizar y verificar la calidad de los datos (Jo & Lee, 2018; Li et al., 2016; Li et al., 2020). Con el crecimiento exponencial de los Big Data geoespaciales, la capacidad de computación de alta velocidad es más importante que nunca para el modelado y la simulación de contenidos geoespaciales

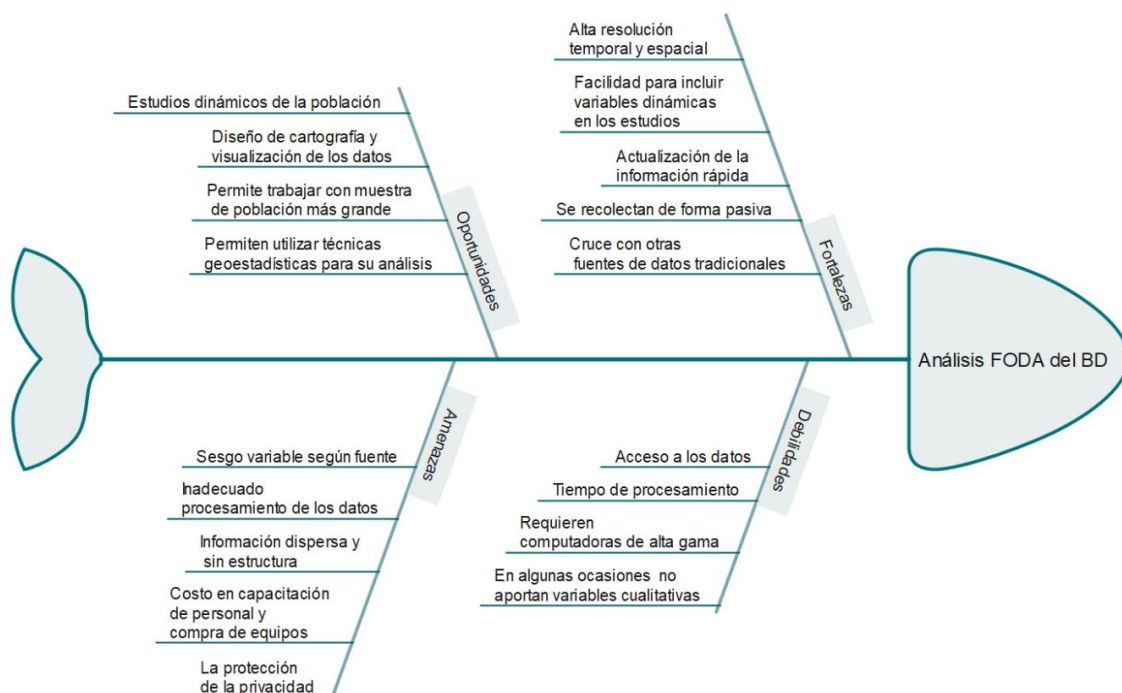
(Lee & Kang, 2015). Hay que afrontar además, retos como la privacidad, la confidencialidad o la seguridad de los datos. (Li et al., 2016).

### 2.2.2 Fortalezas e inconvenientes del uso del Big Data

El uso del Big Data en el ámbito de la Geografía presenta ciertas fortalezas, oportunidades, debilidades e inconvenientes que deben ser considerados al momento de plantear investigaciones de índole espacial y temporal. Entre las fortalezas resaltan el alto grado de resolución de los datos, la facilidad de incluir variables dinámicas en los estudios, la velocidad de actualización, entre otras. Estas fortalezas se constituyen en oportunidades para el desarrollo de estudios dinámicos de la población, diseño de una mejor visualización de los datos y la implementación de modelos estadísticos con la introducción de técnicas de *machine learning*.

Pero cabe destacar también la existencia de algunas debilidades y amenazas en el uso del Big Data. Entre las debilidades destacan, la dificultad de acceso a algunas fuentes de datos, el tiempo de procesamiento y poco nivel de datos cualitativos que proporcionan. Sin olvidar el sesgo que aportan algunas fuentes, la privacidad de los usuarios y el inadecuado tratamiento que se le puede dar a los datos. En la Figura 6 se resume un análisis foda relacionado al uso del *Big Data*.

Figura 6. Análisis foda del Big Data



Fuente. Elaboración propia en base a Osorio 2020.

### 2.2.3 Nuevas redes de transporte

El desarrollo tecnológico ha llevado a la creación de nuevas redes de transporte públicas y privadas. Destacan sobre todo las redes de transporte privado asociadas a las grandes empresas de navegadores o las compañías de servicios web como: Google Maps, TomTom, Here o Movileye, que han creado redes de transporte con enormes detalles que facilitan la conducción e incluso el desarrollo de los vehículos autónomos. Las nuevas redes de carreteras permiten conocer datos detallados de las condiciones del tráfico vehicular a lo largo de las diversas horas del día, conservando un registro histórico, y en tiempo real. Todo esto contribuye a producir información sobre mapas históricos de perfiles de velocidad, lo que resulta de gran importancia para las administraciones, constituyéndose en un apoyo valioso para la planificación del tránsito de los vehículos, con la finalidad de reducir los grandes problemas de tráfico existentes sobre todo en las metrópolis.

A la vez, las administraciones públicas y los gestores del transporte han desarrollado redes digitales de transporte público de enorme detalle, que incluyen información de los recorridos y también de las frecuencias de viaje.

#### 2.2.3.1 Archivos de transporte público GTFS

Las autoridades de transporte, a nivel mundial, organizan las redes digitales de transporte público en archivos según las conocidas Especificaciones Generales de Alimentación de Transporte Público, habitualmente identificados por sus siglas en inglés como archivos GTFS (General Transit Feed Specification). El origen de los archivos GTFS data del 2005, cuando *TriMet*, la agencia de transporte público de Portland, Oregón, se asoció con Google para integrar los horarios y las rutas del transporte público en Google Maps. *TriMet* y *Google* colaboraron en el desarrollo de un formato de datos de tránsito no patentado, que, finalmente, se denominó General Transit Feed Specification (GTFS), con el fin de estandarizar y agilizar la distribución de datos para que otros siguieran su ejemplo (Mehndiratta et al., 2014; Williams et al., 2015).

Los GTFS se han convertido en una referencia común para la información de los horarios del transporte público (Radzimski & Dzięcielski, 2021; Fayyaz S. et al., 2017). Un conjunto de datos GTFS, se compone de numerosos archivos de texto plano

estructurados como valores separados por comas (CSV) (Bok & Kwon, 2016; Fayyaz S. et al., 2017; Prommaharaj et al., 2020) Los ficheros GTFS incluyen todo lo relacionado con la información del funcionamiento de la red: rutas, paradas, horarios, frecuencias de viajes, tiempo de parada, calendario, entre otros (Stępniaak & Goliszek, 2017).

En la red de transporte público, las paradas funcionan como estaciones de tránsito, en ellas los vehículos recogen y dejan a las personas. Las rutas se constituyen en una serie de dos o más paradas a las que da servicio un vehículo de transporte público. Durante el día pueden producirse muchos viajes a lo largo de la misma ruta. Así, una ruta es una serie de dos o más paradas que se producen en un periodo concreto. (Fayyaz S. et al., 2017).

El objetivo de las autoridades del transporte público es facilitar al usuario toda la información sobre los servicios que brinda el transporte público. A través de los archivos GTFS se pueden implementar una serie de aplicaciones que ofrezcan información de interés para la planificación del viaje, la creación de horarios, la accesibilidad, las herramientas necesarias para la planificación en tiempo real o, los sistemas de voz interactivo (Antrim & Barbeau, 2013). En esta línea, Kim & Lee (2019) proponen un índice de accesibilidad al empleo basado en datos del transporte público donde se tienen en cuenta el número de rutas alternativas y su frecuencia, además de los tiempos de viaje.

Existen muchas aplicaciones (App), tanto para teléfonos móviles como para sitios web, que se crean a partir de los datos GTFS, donde se incluyen visualizaciones, indicaciones por voz, viajes compartidos (Antrim & Barbeau, 2013). Ualabee es un ejemplo de App que funciona en algunas ciudades de Argentina. Esta App ofrece información de costos, recorridos y tiempos de espera de transportes públicos. Otro ejemplo de App es Citymapper la cual permite al usuario definir la ruta óptima entre dos puntos y consultar en tiempo real los datos de los servicios del Metro, Cercanías y Renfe en España.

Entre los estudios que hacen uso de los archivos GTFS están Farber, Morang, & Widener (2014) quienes realizaron un análisis de la accesibilidad por medio de matrices de tiempos de viaje origen-destino desde las secciones censales a los supermercados en dos ciudades de los Estados Unidos calculando el tiempo de viaje

por medio del transporte público, seleccionando un día de la semana en particular, lo que les permitió evaluar el nivel de acceso a los supermercados de los diversos grupos sociales. Nassir et al. (2012), con el objetivo de determinar la movilidad, a lo largo del día, de los usuarios del sistema de transporte, utilizaron la información proveniente de los archivos GTFS en combinación con los registros de abordaje y el conteo de pasajeros dentro del bus. En este sentido, el trabajo de Stępnia, M., & Goliszek, (2017), utiliza los archivos GTFS para analizar el nivel de accesibilidad durante diversas horas del día; es decir que incorpora el componente temporal a este tipo de estudio para obtener resultados que le permiten apreciar, en mapas y gráficas, el nivel de equidad de las distintas secciones censales, apoyándose en indicadores como el índice de Gini, la desviación estándar, entre otros. En otro trabajo, Stępnia et al. (2019) examinan escenarios con diferente frecuencia y cobertura espacial del servicio de transporte público. Comparando diferentes medidas de accesibilidad, bien conocidas, (tiempo de viaje hasta la instalación más cercana, las oportunidades acumuladas y la accesibilidad potencial) con diferentes ajustes de los parámetros temporales. Dichas medidas fueron probadas con diferentes servicios públicos. Por otro lado, Tao et al.(2014) estudian la dinámica espaciotemporal del comportamiento de los usuarios de autobuses, utilizando datos GTFS y de las tarjetas de transporte. Para ello, procesaron los registros de las tarjetas de transporte con el fin de reconstruir las trayectorias de viaje con un nivel de precisión espacial de parada a parada. Finalmente, con las trayectorias de viajes confeccionan una serie de mapas de flujo para examinar los patrones espaciotemporales.

Es frecuente el uso de los archivos GTFS en la elaboración de medidas de accesibilidad a servicios y al trabajo (Bok & Kwon, 2016; Karner, 2018; Moyano et al., 2018; Slovic et al., 2019; Stępnia et al., 2019b), y el desarrollo de herramientas para planificar viajes y de visualización de los datos (Fayyaz S. et al., 2017; Jakimavičius et al., 2019).

Como se ha explicado en apartados anteriores, uno de los elementos claves de los MLA es la red de transporte. En esta tesis se incluye la información que contienen los archivos GTFS para simular los desplazamientos de la población al usar el servicio de transporte público. Se destaca que, luego de la revisión bibliográfica, hasta la fecha no se han encontrado estudios de MLA donde se implemente el uso de los archivos GTFS en la red.

### 2.2.3.2 Redes viarias de carreteras y datos de velocidades

La creación de nuevas redes de transporte viario se ha incrementado por el surgimiento de los grandes volúmenes de registros generados por los teléfonos, navegadores GPS y la aparición de empresas como TomTom, Navteq, etc. o proyectos colaborativos como OpenStreetMap (OSM) entre otros, que representan novedosas fuentes de datos que abren oportunidades para realizar innovadoras investigaciones que buscan incorporar en sus estudios variables espaciotemporales de gran nivel de resolución (Moya-Gómez et al. 2018).

Una de las redes que se ha usado con más frecuencia es la de TomTom. Se trata de una empresa especializada en tecnología de localización, que desarrolla productos cartográficos, programas de navegación, congestión vehicular histórico y en tiempo real. Administran grandes volúmenes de datos, capturando y almacenando registros de tráfico y velocidad. Además, proporciona información detallada de los niveles de flujo sobre las autovías en las principales ciudades del mundo.

Los dispositivos de navegación asistida por GPS, creados por la empresa TomTom, capturan y almacenan los detalles del recorrido realizado por los coches que tienen incorporados sus navegadores. Dichos archivos son almacenados en grandes sistemas gestores de bases de datos, que contienen información de las velocidades históricas y en tiempo real, sobre los arcos de la red de carreteras, produciendo escenarios de congestión para diferentes horas del día. Además, los perfiles históricos de velocidad están en permanente expansión y recolectan más de 6 billones de puntos con alrededor de 6 mil millones de registros que se añaden diariamente (TomTom, 2018).

Durante los últimos siete años se han publicado artículos que hacen uso de los datos que administra la empresa TomTom para incorporar variables espaciotemporales en sus trabajos. La mayoría de las investigaciones han hecho hincapié en el uso de los datos de TomTom con el propósito de evaluar temáticas relacionadas con la accesibilidad, tráfico y congestión vehicular en algunas ciudades del mundo. Ciertos autores coinciden en el uso de los perfiles históricos de velocidad (*Historical Speed Profile*), que es uno de los productos comerciales de la compañía. Muchos de estos trabajos han realizado modelos de accesibilidad con el objetivo de valorar el efecto que tiene el tráfico sobre las diferentes actividades desarrolladas a nivel urbano

(Moya-Gómez et al., 2018; Moya-Gómez & García-Palomares, 2017<sup>a</sup>; Pritchard et al., 2019). También se encuentran trabajos a partir de datos de TomTom para abordar temáticas relacionadas con patrones de circulación (Moyano et al., 2021; Tanveer et al., 2020), modelos de regresión (Dingil et al., 2018; Kellner, 2016) y para cartografiar resultados de modelos de congestión (Moya-Gómez & García-Palomares, 2017b).

Con respecto a los estudios que utilizan los datos de TomTom para abordar temas de accesibilidad, se hace referencia al trabajo realizado por Pritchard et al. (2019), que examina el potencial de la bicicleta como medio para reducir la desigualdad en la accesibilidad espaciotemporal en los viajes hacia el empleo. Para lograr su objetivo utilizaron los perfiles de velocidad de TomTom en la elaboración de los modelos de accesibilidad y comparan los resultados frente a datos de archivos GTFS. Por su parte, Moya-Gómez et al. (2018) proponen analizar la accesibilidad urbana, teniendo en cuenta el rendimiento de la red y el atractivo de los destinos, mediante un enfoque dinámico aprovechando datos de TomTom y Twitter. En otro trabajo Moya-Gómez & García-Palomares (2017) realizan una comparación de la congestión y la accesibilidad en ocho ciudades de Europa, aprovechando los datos de TomTom Speed Profiles. Mientras que Moyano et al. (2021) analizan el impacto de periodos de crisis económica sobre las variaciones diarias de la congestión del tráfico, comparando los resultados con periodos post crisis. Tanveer et al. (2020) se enfocan en estudiar patrones de circulación, para ello realiza monitoreos de las variaciones del flujo en las ciudades y utiliza los índices de tráfico de TomTom en la validación de su estudio.

También, los académicos, utilizan los datos de TomTom para plantear modelos de regresión a partir de los niveles de congestión de TomTom para comparar indicadores de transporte en diferentes áreas urbanas y valorar su grado de accesibilidad (Dingil et al. 2018), o para explorar el impacto de la congestión vehicular en la generación de CO<sub>2</sub> y mediciones GPS que dan cobertura para la observación del flujo de los coches.

Cabe señalar que junto a TomTom existen otras redes viarias que incluyen datos de velocidad y tráfico promedio e información de tráfico en tiempo real. Entre ellas se encuentran: Google Maps, Waze, Autonavi, Here, entre otras (Moyano et al., 2021).

Google Maps es la aplicación de planificación de rutas más completa para todos los modos de transporte. Los tiempos de viaje de los vehículos privados se calculan

mediante una combinación de datos históricos de las carreteras y patrones de tráfico en tiempo real extraídos de los registros de los teléfonos móviles. Los investigadores hacen uso de estos datos para crear matrices de tiempo de viaje de OD para múltiples horas y días de la semana utilizando los servicios de la API de Google (Dumbliauskas et al., 2017).

Waze proporciona la mejor ruta en coche, basándose en información, en tiempo real, sobre el estado de la red de carreteras, mediante una aplicación móvil y datos GPS. La aplicación se lanzó en Israel en 2008 y alcanzó algo más de 20.000 usuarios a finales de año. Google compró la plataforma y la incluyó en su aplicación Google Maps (Gutierrez-Puebla et al., 2020). Waze, es una App (aplicación) centrada en el transporte. Los usuarios pueden consultar información sobre el tráfico en tiempo real, como las mejores rutas, la velocidad del tráfico, los tiempos de viaje, los sitios de circulación reducida y mucho más. También es posible que las personas que utilizan esta aplicación informen de situaciones como atascos y accidentes de tráfico. Se puede descargar con la API de Waze todos estos datos y aprovecharlos en estudios específicos (Perez et al., 2018; Santos et al., 2017).

Por su parte, Santos et al. (2017) examinan los accidentes de tráfico en Belo Horizonte, Brasil. El estudio compara los datos de accidentes de Waze con los datos de fuentes oficiales. Los datos oficiales reflejan, con mayor precisión, los accidentes que involucran a las compañías de seguros, mientras que los datos de Waze se centran en los accidentes que causan congestión de tráfico, específicamente en las principales vías urbanas.

Otra investigación examina las posibilidades de los datos recolectados por la aplicación Waze. Se utiliza un algoritmo de agrupación dinámica que puede clusterizar los informes de los usuarios basados, en la localización, en tiempo real y averigua hasta dónde se extiende la congestión del tráfico en el tiempo y el espacio. El método propuesto se probó en 34 casos de atascos en Knoxville, Tennessee, en Estados Unidos. El algoritmo demostró ser bueno para averiguar la ubicación y la hora de los atascos, basándose en los clústeres de los informes de Waze.(Liu et al., 2021).

Otra fuente de datos de tráfico es *AutoNavi*, principal proveedor chino de mapas web, navegación y servicios de localización. Dispone de mapas digitales e información de tráfico en tiempo real. Hay estudios que afirman que los datos de tráfico y viajes de

los usuarios de los mapas de AutoNavi son una buena fuente de información que puede ayudar a las personas a averiguar dónde están los congestionamientos de tráfico (Li et al., 2019). El trabajo de Wang et al. (2021) emplea esta fuente de datos para obtener situaciones de tráfico durante el día e investigar la cobertura de las estaciones de bomberos en Pekín, China.

Es notorio decir que existen servidores de datos espaciales donde se pueden descargar, sin ningún costo, información de los callejeros de cualquier región del mundo. El ejemplo más conocido es OpenStreetMap (OSM). Aunque los callejeros descargados de este servidor no ofrecen información de historial de tráfico para la implementación de MLA dinámicos, resultan de gran utilidad para crear un dataset de red que incluye los nodos, arcos y la impedancia en tiempo o distancia. Por ejemplo, se utilizaron los datos de red procedentes de OSM para el análisis de un MLA que buscaba encontrar la mejor ubicación de servicios de ambulancias (Azizan et al., 2012). Otro trabajo utiliza los callejeros de OSM en modelos de localización comparando los resultados con la red de la empresa HERE (Cebecauer & Buzna, 2018).

En definitiva, gracias a las nuevas formas de captar y almacenar datos se puede conseguir información relacionada con las características de las redes de transporte público y privado, tales como: la frecuencia de viajes, la velocidad, el congestionamiento y la duración a diversas horas del día, lo que significa un valioso insumo para enfocar los estudios de MLA desde una perspectiva dinámica sobre los atributos de la red.

Cabe señalar que, tras la revisión de la literatura, no se han encontrado referencias sobre el uso de los datos de TomTom en el desarrollo de las redes de transporte a utilizar en los modelos de localización-asignación.

#### 2.2.4 Nuevas formas de localización de la demanda

De acuerdo con el planteamiento expresado anteriormente, el desarrollo e innovación tecnológica que se está gestando ha permitido el surgimiento de nuevos mecanismos para producir, captar y almacenar datos. Las mejoras en el servicio de dotación de internet, ofrecido por las compañías telefónicas, han incrementado la velocidad del internet, han disminuido el costo del servicio y se han modernizado en la transmisión

de datos, a través del cambio de tipo de banda, ya que ella permite que la información se produzca con mayor rapidez.

Además, en la actualidad, existe una cantidad considerable de plataformas móviles, pero las que predominan en el mercado son el software iOS de Apple y el Android de Google. Ambas plataformas permiten instalar un sinnúmero de aplicaciones que captan voluntaria o involuntariamente, una gran cantidad de datos de sus usuarios.

En cuanto a los dispositivos productores de *Big Data* podemos mencionar los teléfonos móviles, tarjetas de crédito, redes sociales, los sensores, RIFD y otros más. Estos dispositivos se analizan en los siguientes párrafos.

#### 2.2.4.1 Teléfonos móviles

Los teléfonos móviles son uno de los dispositivos generadores de *Big Data* y han hecho posible que numerosos estudios se apoyen en esta fuente de datos. El volumen de datos crece de forma exponencial con la proliferación de potentes smartphones e innovadoras aplicaciones móviles.

La utilización de los datos procedentes de teléfonos móviles permite el desarrollo de nuevas herramientas espaciotemporales para la planificación urbana y la mejora de la eficiencia de los sistemas urbanos actuales. Los datos de los teléfonos móviles, en principio destinados a la comunicación, se utilizan cada vez más como nuevas herramientas de investigación en geografía y ciencias sociales. La investigación empírica sobre sistemas urbanos complejos, desde un enfoque centrado en el ser humano y en la dinámica urbana, revela nuevas perspectivas que pueden utilizarse para diseñar aplicaciones innovadoras que apoyen las iniciativas de las ciudades inteligentes (Steenbruggen et al., 2015). Con la ayuda de la analítica y la visualización de los datos, la ciudad puede ser más inteligente y estar mejor informada. Esto se debe a que permiten encontrar patrones y relaciones, que pueden orientar la toma de decisiones y conocer mejor la ciudad.

Actualmente, la mayoría de las personas lleva consigo un teléfono móvil todo el tiempo, ya que vivimos en un mundo muy interconectado. Este aparato informa de los lugares que visitamos y del tiempo que pasamos en ellos. La actividad de cada móvil (llamadas, mensajes, sesiones de datos) queda captada por la antena más cercana al aparato, informando de nuestra ubicación. La geolocalización del teléfono puede

hacerse a partir de las áreas de influencia de las torres de comunicación o por triangulación de la señal. Esto aumenta la precisión de la localización de cada registro (Gutiérrez Puebla et al., 2019).

Por otro lado, la tecnología GPS de las numerosas aplicaciones que se pueden usar en los teléfonos móviles (por ejemplo, Twitter, Facebook, Instagram, etc.) proporcionan también información geolocalizada. Los teléfonos móviles permiten realizar tareas como: tomar fotos, videos, textos y audios. Gran parte de esta información puede ser georreferenciada a partir de las tecnologías GPS que integran los teléfonos inteligentes.

Los datos de los teléfonos móviles se han convertido, en los últimos años, en una fuente importante, que son utilizados, para realizar estudios de movilidad urbana, debido a su fina granularidad espacial y temporal. La gran popularidad de los dispositivos móviles y las aplicaciones que se pueden ejecutar brindan nuevas oportunidades para el estudio de las poblaciones. En este sentido, la utilización del móvil, por una gran parte de la población, proporciona una valiosa fuente de datos para recolectar información que permite estudiar el posicionamiento de las personas en el espacio y el tiempo (Liu et al., 2020).

Como expresa Deville et al. (2014), las poblaciones humanas son dinámicas, se mueven diariamente o lo hacen por temporadas, provocando cambios en la densidad de habitantes presentes en las diferentes zonas del espacio geográfico. A través de los datos almacenados por los dispositivos de telefonía móvil, se pueden analizar los patrones de movilidad humana y entender el funcionamiento de las ciudades. Los datos procedentes de las redes de la telefonía móvil permiten estudiar la movilidad humana a bajos costos, siempre que se pueda disponer de los datos, con mayor frecuencia y a escala global (Becker et al., 2013).

Con la geolocalización de los teléfonos es posible realizar estudios de presencia de usuarios y su distribución cambiante a lo largo del día. Interesante resulta la guía desarrollada por Gutiérrez Puebla et al., (2019) para el Banco Interamericano de Desarrollo (BID), donde explican la forma de analizar grandes volúmenes de datos, especialmente, aquellos capturados por los dispositivos de telefonía móvil y su aplicación a estudios de transporte e infraestructura urbana.

En esta línea, Laurila et al. (2013), a partir de un grupo de voluntarios, recabaron datos

que reflejaban patrones de movilidad humana, donde se establecen las categorías de lugares y la estimación de las características demográficas que tenían los usuarios. La información fue recolectada por medio de llamadas de voz y videos. En realidad, el uso de la telefonía móvil se ha generalizado en los estudios actuales, por ejemplo con la pandemia Covid-19 han sido muchos los trabajos que han usado estos datos (Lison et al., 2022; Pan & He, 2022; Romanillos et al., 2021).

Existen algunas revisiones de literatura que abordan el uso de los datos procedentes de los teléfonos móviles con diferentes enfoques de investigación (Steenbruggen et al., 2015; Z. Wang et al., 2018). En la misma dirección, Steenbruggen et al. (2015) presentan una revisión exhaustiva y una tipología de los estudios espaciales realizados con datos de teléfonos móviles, y destacan su potencial para desarrollar aplicaciones innovadoras encaminadas a mejorar la gestión urbana a partir de estos datos digitales.

Por su parte la revisión de literatura que realizan Wang et al. (2018) examina los estudios que han utilizado los datos de los teléfonos móviles para analizar el comportamiento de los desplazamientos de las personas y muestra los avances logrados. Además, se menciona cómo los datos del teléfono móvil pueden mejorar la investigación del comportamiento en los viajes y se plantean algunas cuestiones que deben resolverse en este proceso.

Se encuentran otras investigaciones que ofrecen una revisión del reconocimiento de las actividades humanas (Choujaa & Dulay, 2009). Calabrese et al. (2014) recogen una síntesis de los trabajos que utilizan datos de teléfonos móviles para el monitoreo de la dinámica urbana. Yue et al. (2014) revisan cómo se han aplicado diferentes tipos de datos de trayectoria a los estudios de comportamiento de viaje, incluidos los datos de teléfonos móviles. Wang et al. (2020) enfoca su revisión en trabajos relacionados a la gestión de emergencias. El trabajo de Ghahramani et al. (2020) revisa los métodos y técnicas que se han aplicado para producir conocimiento a partir de los datos de los teléfonos móviles. A su vez, clasifican los métodos existentes y presentan una taxonomía de los trabajos relacionados discutiendo sus pros y sus contras.

En otro artículo de revisión se ofrece un resumen exhaustivo de los principales estudios y proyectos que abordan los datos de la red de telefonía móvil para estimar la posición de las personas y el tráfico, y servir de punto de partida para futuras

investigaciones sobre la gestión de incidentes y del tráfico. Además, se discuten los pros y los contras de la obtención de parámetros de localización y transporte a partir de los teléfonos móviles (Steenbruggen et al., 2013).

La Tabla 3 resume algunos estudios que han utilizado los datos de telefonía móvil y se presenta el autor, objetivo perseguido, el método utilizado, procedencia, enfoque y la escala geográfica de agregación.

Tabla 3. Resumen de investigaciones con telefonía móvil

Autores	Objetivo	Método	Lugar	Enfoque	Escala geográfica
(Deville et al., 2014)	Examinar el uso de datos telefónicos para cartografiar la distribución de la población.	Polígonos de Voronoi	Francia	Cartografía	100*100
(Järv et al., 2017)	Proponer un enfoque de interpolación dasimétrica para mejorar la precisión espacial de los datos de telefonía móvil.	Polígonos de Voronoi, interpolación, mapas dasimétricos	Estonia	Densidad de población	500 m 100m
(X. Zhou et al., 2018)	Utilizar los datos de teléfonos celulares para estudiar la variación espacial del empleo.	Modelo relacional	China	Movilidad	2km
(X. Gao et al., 2019)	Examinar los patrones de actividad diaria de las residencias rurales a través de datos de teléfono.	OLS	China	Movilidad	1000*1000
(Y. Chen et al., 2019)	Explorar los patrones de movilidad basados en la zona de análisis del tráfico (TAZ) y las relaciones correspondientes con características locales de uso de la tierra.	Análisis clúster	Corea	Patrones de movilidad	Zonas de transporte
(S. Liu et al., 2019)	Proponer la extracción de áreas de vitalidad y la integración de agrupaciones de características espacio temporales.	Análisis clúster	China	Vitalidad de la ciudad	Voronoi
(Lingbo Liu et al., 2018)	Definir una relación distancia-decrecimiento oferta-demanda entre la población de usuarios de teléfonos móviles de la estación base cuadrículada y sus zonas circundantes.	Modelo de regresión	China	Mapa dasimétrico	1 km
(Y. Chen et al., 2020)	Analizar las diferencias en el impacto de los usos de suelo en la población trabajadora.	GWR	China	Usos suelo	Zonas de transporte
(Guan et al., 2020)	Usar datos de telefonía móvil para delimitar el área de cobertura de los parques urbanos.	Densidad de Kernel	Japón	Movilidad	Parques

(Wu et al., 2020)	Trazar un perfil de las diferentes pautas de movilidad de los típicos subgrupos de la población real de la ciudad y luego cuantificar las diferencias entre los subgrupos.	Intensidad de visitas de usos del suelo	China	movilidad	2500m
-------------------	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------	-----------------------------------------	-------	-----------	-------

Fuente: Elaboración propia.

En definitiva, los datos que pueden ofrecer los teléfonos móviles constituyen una alternativa distinta de las fuentes tradicionales, provenientes de instituciones gubernamentales, donde se ofrecen las estadísticas oficiales, puesto que permiten obtener datos actualizados, con mayor nivel de detalle, tanto espacial como temporal. Estas características permiten hacer estudios de movilidad urbana para detectar patrones de desplazamiento de los ciudadanos. La investigación en diversos sectores, como la planificación urbana, el transporte, la asistencia sanitaria y el marketing corporativo, puede beneficiarse del análisis de datos procedentes de teléfonos móviles. Además, pueden ayudar a las organizaciones en la toma de decisiones, la aplicación de políticas, el seguimiento y la evaluación (Ghahramani et al., 2020).

Una de las desventajas de trabajar con esta fuente de datos es lo difícil de conseguirlas, ya que las empresas de telecomunicaciones deben mantener en el anonimato los detalles de los datos de cada usuario. Esto se hace por las medidas y legislaciones vigentes que versan sobre la protección de datos. En vista de esta situación, se encuentran pocos estudios que utilicen datos generados con registros de llamadas y localización del dispositivo.

#### 2.2.4.2 Tarjetas de crédito

Las tarjetas de crédito generan una valiosa información geolocalizada, que puede ser utilizada para el desarrollo de investigaciones relacionadas con los hábitos de consumo que practican los usuarios. Las transacciones con tarjetas bancarias contienen mucha información. Incluye todos los pagos realizados por los clientes del banco con sus tarjetas y los pagos realizados en los terminales de punto de venta de propiedad y operados por el banco. Como mínimo, el importe y la hora de la transacción, el identificador anónimo del titular de la tarjeta y el código postal se almacenan automáticamente cuando el propietario de una tarjeta bancaria paga en un punto de venta (Aparicio et al., 2021).

Esto permite detectar las zonas donde se registra la mayor cantidad de compras o el

impacto económico de un evento turístico (Gutiérrez , 2018). De esta forma podemos conocer otros datos como el momento del día en que fue utilizada, las coordenadas del comercio y el tipo de bien o servicio que fue pagado con dicha tarjeta.

Un ejemplo de investigación a partir de tarjetas de crédito lo presenta Aparicio et al., (2021), quienes proponen estudiar cómo los turistas gastan su dinero en diferentes partes de la ciudad a partir de los registros de transacciones con tarjetas bancarias. En este caso, se utilizan herramientas de estadística espacial para encontrar puntos calientes, separar a los turistas nacionales de los internacionales, observar sus tendencias de gasto y compararlas con las de los locales. Del análisis de los datos se desprende que el gasto de los turistas, en particular los internacionales, se concentra mucho más en el centro de la ciudad.

Por su parte Lenormand et al. (2015) utilizan los datos de las tarjetas bancarias para evaluar la influencia de las características sociodemográficas en la forma en que las personas se mueven y gastan su dinero. Ponen de manifiesto las diferencias en los hábitos de consumo y las pautas de movilidad de los clientes de los bancos en función de su sexo, edad y ocupación.

La publicación de Carpio-Pinedo et al. (2022) analiza la distribución espacio temporal del gasto realizado con tarjetas de crédito en la ciudad de Madrid. Emplean herramientas de autocorrelación espacial, de agrupamiento k-means y series temporales para obtener la distribución de los puntos calientes donde se registran la mayor cantidad de gastos por sector comercial dentro de la ciudad.

Toda esta riqueza de información presenta muchos inconvenientes por la metadata sensitiva que conlleva, pudiendo violentar las normas de privacidad a la que tienen derecho los portadores de las tarjetas. Esta es una de las razones por las que existe una gran dificultad para conseguir información proveniente de este tipo de fuente.

#### *2.2.4.3 Datos GPS (Servicios de movilidad compartida y emergencias)*

En las grandes ciudades existen numerosas redes de sensores que recogen datos geolocalizados por medio de dispositivos que tienen instalados algunos de los sistemas de posicionamiento global, aunque el más utilizado es el denominado Sistema de Posicionamiento Global (GPS, del inglés Global Positioning System) de propiedad estadounidense.

Evidentemente, con estos datos se pueden diseñar mapas que muestren dónde se moviliza o concentra la población a determinadas horas del día, debido a que los registros GPS almacenan el momento temporal y la ubicación geoespacial de los usuarios. Los registros GPS han sido utilizados como fuente de datos en investigaciones científicas. Gutiérrez-Puebla et al. (2020) presentan una recopilación de fuentes que incluyen información GPS, las características de estos datos y ejemplos de estudios de caso donde utiliza la información GPS para estudiar la presencia de población y su distribución horaria, estudios de accesibilidad, análisis de eventos y las metodologías aplicadas para obtener información que puede resultar útil para estudiar la movilidad urbana.

En este apartado, se aborda en un primer bloque los estudios realizados con datos GPS recolectados por los servicios de movilidad compartida urbana, por ejemplo, los servicios de patinetes, motos y bicicletas compartidas. En un segundo bloque se hace referencia a investigaciones que utilizan fuentes de datos GPS almacenados por los servicios de emergencias (Bomberos y urgencias médicas). Estas son dos de las fuentes que serán usadas después en el bloque empírico de la tesis.

En todas nuestras ciudades están apareciendo nuevas modalidades de transporte, denominados vehículos de movilidad compartida. Entre ellos están: las bicicletas (bikesharing), motocicletas (motosharing), patinetes eléctricos (E-scooter) y otros. Estos se encuentran desplegados por algunos sectores de la ciudad, y pueden hacerlos en modelos con estaciones de aparcamiento fijo o sin contar con bases fijas para el anclaje (sistemas dockless).

Los usuarios pueden utilizar los vehículos descargando, en sus teléfonos móviles, las App que las empresas de movilidad han desarrollado para indicar donde hay vehículos disponibles, de esta forma pueden desbloquearlo y efectuar el viaje y pagar por medio de tarjetas de crédito. Este tipo de vehículos de movilidad compartida tienen instalados dispositivos GPS que permiten a las empresas operadoras registrar y almacenar datos de los viajes realizados por los usuarios. También, a partir de la tarjeta bancaria utilizada para pagar el alquiler del vehículo se puede saber la cantidad del gasto realizado y algunos datos sociodemográficos del usuario (por ejemplo, edad, sexo, nacionalidad).

Los datos almacenados por los dispositivos GPS, que portan los vehículos resultan de interés para el desarrollo de investigaciones donde se requiere conocer la distribución de la población o su movilidad diaria. Los aparatos GPS integrados en estos vehículos de movilidad compartida capturan: el identificador del usuario, identificador del vehículo, fecha, hora, duración, distancia recorrida y las coordenadas de inicio y fin del viaje. Tomando en cuenta estos registros es posible predecir o detectar pautas de desplazamiento de los clientes.

Los datos derivados de GPS instalados en los vehículos de movilidad compartida han sido utilizados en investigaciones enfocadas en modelos para predecir la demanda (Archer et al., 2019; Hua et al., 2020; Riu et al., 2020), patrones espaciotemporales de uso (Arias-Molinares et al., 2021; McKenzie, 2019b; G. McKenzie, 2019; Noland, 2019; Shen et al., 2018), y MLA (Sun et al., 2019; Yang et al., 2020; Zhang et al., 2019).

En cuanto a los estudios que utilizan los datos capturados por el GPS instalado en los vehículos de movilidad compartida, para predecir la demanda de uso está el caso de Riu et al. (2020), que realizan un análisis comparativo del uso de las bicicletas compartidas y los patinetes eléctricos. En su investigación encuentran que la demanda se asocia con lugares atractivos como el metro y las residencias. Además, construyen matrices de origen destino enriquecidas con el número de viajes. También, incluyen cartografía de usos de suelo y clima a fin de valorar el efecto sobre la utilización de los dos tipos de vehículos.

Otro estudio interesante es el de Hua et al. (2020), donde se estima la demanda de estacionamiento de algunas compañías en Nanjing, China, para conseguir su propósito utilizaron tres métodos diferentes de clúster, arrojando los mejores resultados el método k-mediano. Por su parte, Archer et al. (2019), examinan las estrategias de despliegue de los principales proveedores de patinetes en Austin Estados Unidos, buscando encontrar las zonas de la ciudad con pobre cobertura de transporte.

Con respecto a las investigaciones orientadas hacia estudios de patrones espaciotemporales, Shen et al. (2018), desarrollan un análisis descriptivo de la distribución espaciotemporal de las bicicletas, e implementan modelos de regresión donde exploran el impacto de las condiciones climáticas en el uso de las bicicletas y en el acceso al transporte, encontrando que las cambiantes temperaturas y la

precipitación tienen influencia negativa. En su publicación, Arias-Molinares et al., (2021) a partir de los registros GPS de las motos compartidas de un operador presente en siete ciudades españolas proponen una metodología para identificar los orígenes y destinos durante el día de los viajes realizados. Su objetivo es analizar y visualizar la huella espacio-temporal de los ciclomotores y comparar su dinámica en diferentes ciudades. Por su parte McKenzie (2019) evalúa las pautas de desplazamiento de los usuarios de patinetes y bicicletas eléctricas. Plantea un análisis multitemporal en tres ciudades con los orígenes y destinos de los viajes, además, presenta mapas de densidad a nivel viario y clúster para identificar los sitios de mayor concentración. En otro estudio McKenzie (2019a) investiga dos aspectos claves de la micromovilidad. Primero, identifica las diferencias espaciales y temporales entre las empresas de movilidad. Segundo, compara el uso de estos nuevos servicios en las ciudades de Berlín, Los Ángeles y Montreal. En lo que respecta al tiempo de viaje dentro de la ciudad McKenzie (2019) compara los patrones espacio temporales del uso de scooter con las bicicletas compartidas. De igual forma, otras investigaciones examinan los patrones de uso y el efecto de las variables climáticas, aplicando modelos mínimos cuadrados ordinarios (Noland, 2019).

En relación con las investigaciones que utilizan datos GPS de vehículos de movilidad compartida para plantear modelos de localización asignación (MLA) está el trabajo de Zhang et al. (2019) que proponen un MLA que busca establecer la ubicación de las estaciones de bicicletas. Para ello utilizan un conjunto de datos con los orígenes y destinos de los viajes generados por el sistema de bicicletas. En la misma línea Yang et al. (2020) utilizan los datos del servicio de bicicletas flotantes, sin base fija (*free-floating bike-sharing*) de la ciudad de Wuhan, China. Para ello, utilizan los datos correspondientes a un periodo de 30 días con el fin de extraer el uso histórico de la bicicleta. Por su parte, Sun et al. (2019) buscan optimizar la asignación de la ubicación de las estaciones virtuales (no requieren de infraestructuras físicas de aparcamiento fijas) que pueden satisfacer la creciente demanda de los usuarios mediante el análisis de los datos de uso de las bicicletas compartidas.

Por otro lado, las nuevas formas de movilidad compartida enfrentan retos y desafíos en la gestión de sus flotas debido al vandalismo y la cantidad exagerada de vehículos. Hay que mencionar -sobre todo- los conflictos por el espacio disponible para los peatones, ya que la rápida expansión de este tipo de vehículos deja una mala

impresión debido a que se abandonan en sitios no permitidos y muchas veces se convierten en un obstáculo para el libre desplazamiento de los transeúntes. Por lo tanto, estos retos pueden abordarse con la ayuda de los datos del GPS que almacenan las empresas de movilidad compartida, haciendo posible una planificación más eficaz, incluida la gestión del aparcamiento y la reducción de las emisiones (Hua et al., 2020). Además, la existencia de archivos GPS puede beneficiar a los operadores, permitiéndoles reequilibrar la distribución de su flota y a los clientes les facilitan localizar áreas donde existe disponibilidad del servicio, entre otros aspectos (Shen et al., 2018).

Tomando en cuenta que los registros de GPS ofrecen la posibilidad de localizar a los usuarios de los vehículos de la micromovilidad, en esta tesis se utilizarán los datos recabados por un sistema de motos eléctricas que opera en la ciudad de Madrid, y que permite descubrir los lugares con mayor demanda durante las diferentes horas del día. Con esta información se puede conocer la concentración de la oferta y la demanda del sistema, dado que se tienen las coordenadas de inicio y fin, además, de la fecha del viaje. Lo anterior permite distinguir patrones de movilidad o la localización puntual del usuario en los diversos momentos del día. Se debe agregar que estos datos están en manos de las empresas operadoras, y por lo general es complicado tener acceso a los mismos.

Se puede afirmar que las nuevas fuentes GPS de los vehículos de movilidad compartida constituyen un insumo valioso para realizar estudios que requieran incluir variables dinámicas en sus planteamientos que permiten conocer la presencia poblacional en las diversas zonas de la ciudad a cualquier hora del día. Además, permiten desarrollar modelos predictivos de disponibilidad de la demanda, modelos de accesibilidad y la descripción de pautas espaciotemporales de los usuarios.

En el caso particular de los MLA es factible utilizar los datos provenientes de las motos eléctricas a fin de ubicarlas en los sitios de mayor concentración de la demanda, en un momento dado, o proponer lugares donde colocar las bases. Con ello se pretende mejorar el problema del estacionamiento no regulado, lo que implica tener una ciudad con espacios peatonales libres de la aglomeración de vehículos de movilidad compartida ubicados en zonas prohibidas.

En cuanto a las investigaciones realizadas con datos GPS almacenados por los servicios de emergencia, se abordan los trabajos realizados con datos históricos que contienen la localización de incendios y emergencias médicas. A partir de estos datos, los estudiosos proponen diferentes enfoques. Por ejemplo, el análisis espacio-temporal (Azimi et al., 2021), el análisis de accesibilidad (Xiong et al., 2022), y los modelos de localización de estaciones de bomberos y ambulancias (Bolouri et al., 2018; Dibene et al., 2017; Han et al., 2020; Yu et al., 2020).

En el caso del análisis espacio-temporal, Azimi et al. (2021) visualizan la distribución de las llamadas al servicio de emergencias, relacionadas con enfermedades cardiovasculares. Para ello, hacen un análisis de autocorrelación espacial con la finalidad de determinar la ubicación de las secciones censales con mayor concentración de llamadas.

Por su parte, Xiong et al. (2022) utilizan un conjunto de datos que contiene más de 100 mil registros de llamadas realizadas al centro de emergencias de Wuhan, China. El conjunto de datos incluye información anonimizada del paciente, categoría del incidente, hora de la llamada, dirección del incidente, etc. Basándose en las condiciones dinámicas del tráfico y en la demanda real obtenida a partir de los registros GPS históricos de los incidentes, realizan un análisis de accesibilidad espacio-temporal.

Con respecto a los trabajos que utilizan registros GPS históricos de incendios para desarrollar modelos de localización de estaciones de bomberos, cabe citar a Bolouri et al. (2018). Ellos evalúan la localización de estaciones de bomberos, considerando objetivos como la minimización de la distancia y el tiempo. Además, plantean la maximización de la cobertura de la demanda.

Han et al. (2020) proponen un método de selección de sitios que logre la llegada oportuna de los bomberos a todos los lugares de incendio. Los autores diseñan el flujo de trabajo basado en la solución de cobertura de conjuntos. Este estudio evalúa con precisión la distribución de los riesgos de incendio urbano, las condiciones del tráfico rodado y otras situaciones mediante el análisis de los datos espaciales. Además, emplean el método de agrupación de K-means para describir y simular cuantitativamente la demanda de incendios basándose en datos reales. Para ello,

utilizan datos espacio-temporales obtenidos a partir de registros GPS de incendios desde el 1 de junio de 2014 hasta el 1 de junio de 2018 en la ciudad de Nanjing.


Por otro lado, Dibene et al. (2017) utilizan datos históricos de GPS que almacenan la ubicación de los eventos atendidos por el servicio de emergencias de Tijuana, México. A partir de estos datos, proponen un modelo de localización de ambulancias. Hacen uso de herramientas de clustering jerárquico para agrupar los eventos y luego extraer el centroide de cada uno de los grupos, que emplean como demanda en su modelo.

#### *2.2.4.4 Redes sociales*

Las redes sociales son “servicios basados en la web que permiten a las personas las siguientes actividades: construir un perfil público o semipúblico dentro de un sistema determinado, articular una lista de otros usuarios con los que comparten una conexión para ver y recorrer su lista de conexiones y las realizadas por otros dentro del sistema” (Boyd & Ellison, 2007). De acuerdo con esta definición, las redes sociales permiten el intercambio, entre usuarios, de información multimedia. Además, se dan prácticas donde se comparten videos, audios y textos.

En la literatura científica abundan trabajos que exponen las generalidades de las redes sociales, haciendo énfasis en la definición, evolución, cantidad de seguidores, específicamente en las funciones de éstas y los problemas derivados de los asuntos legales de la privacidad de los datos. Ejemplo de ello es la investigación de Wildman, (2018). Las redes sociales, como explica Joyanes A. (2014), transforman un proceso de comunicación en un diálogo interactivo y en ellas se comparte información, haciendo comentarios, uniéndose a grupos y chats. Ejemplo de estas redes tenemos a: Twitter, Flickr, Facebook, LinkedIn, Instagram, Foursquare, entre otras. De toda esta lista de plataformas, la que posee el mayor número de usuario es, Facebook seguido de YouTube (ver Figura 7).

Figura 7. Usuarios de diferentes redes sociales (octubre 2022)



Fuente: <https://datareportal.com/social-media-users?rq=twitter%20users> .

El uso de los datos geocalizados de las redes sociales para analizar el comportamiento de las personas ha despertado el interés en la investigación geográfica (Steiger et al., 2015). Con millones de usuarios en todo el mundo, las redes sociales se han convertido en una de las plataformas de comunicación más utilizadas. Estas plataformas producen contenidos masivos, generados por los usuarios, que pueden ser descargados por terceros. Dado que algunos de estos datos están referenciados espacialmente, surgen oportunidades prometedoras para que los investigadores de la geografía infieran los patrones y relaciones espaciales producidos por los usuarios de las redes sociales (McKittrick et al., 2022).

En este estudio nos referiremos, específicamente, a la red social Twitter, la cual desarrolló una API que permite descargar datos de modo gratuito. Estos datos son de gran utilidad para el desarrollo de investigaciones. Esta red registra, a nivel mundial 321 millones de usuarios, donde, en promedio se envían 6000 tweets por segundo, y más de 500 millones por día<sup>5</sup> (consulta realizada el 11 de noviembre de 2022). Esto

<sup>5</sup> Información obtenida del sitio <http://www.internetlivestats.com/twitter-statistics/#sources>

nos permite visualizar el gran potencial de la red por la enorme cantidad de datos generada, diariamente, por los usuarios al momento de compartir mensajes, retwittear o compartir su ubicación, audios y otros datos.

Desde el punto de vista de la Geografía, Twitter ha presentado la oportunidad de poder realizar innovadores estudios, puesto que, los datos generados por los usuarios de esta red social contienen características que siempre fueron estudiadas por esta disciplina. De esta forma se pueden derivar estudios de la procedencia de usuarios, de los patrones de movilización a través de la superficie terrestre y la ubicación geográfica, fundamentalmente pueden contener la geolocalización desde la que el usuario reacciona en la red (coordenadas desde donde se envían los mensajes, el tweet).

Steiger et al. (2015) presentan una revisión de literatura donde sintetizan las aplicaciones y métodos para realizar análisis temporales a partir de datos de la red social Twitter. Muestran la utilidad de los datos de Twitter para realizar estudios de detección de eventos, desastres, emergencias y la inferencia de la localización de los usuarios. En su publicación, McKittrick et al. (2022) realiza una revisión bibliográfica en la que recopila los métodos utilizados por los investigadores de Sistemas de Información Geográfica para analizar y visualizar espacialmente, a través de mapas, los datos geolocalizados de las redes sociales, incluido Twitter. Por su parte, Niu & Silva, 2020 presentan una publicación en la que examinan las diferentes fuentes de datos colaborativas (aquellas que son generadas voluntariamente por los usuarios). Además, muestran ejemplos de aplicaciones y métodos que pueden implementarse con datos procedentes de redes sociales (entre ellas Twitter), puntos de interés y otras fuentes. Exponen ejemplos de aplicaciones para el análisis espacio-temporal de patrones de movilidad, la detección de eventos y el análisis de sentimientos a partir de redes sociales.

En base a lo anterior, la Tabla 4, presenta algunas investigaciones que han utilizado datos de Twitter o la similar China de Weibo, pero nos enfocaremos, específicamente, en aquellas realizadas desde un punto de vista geográfico. Además, se muestra el objetivo perseguido, el método utilizado, la aplicación y la escala geográfica en que se agregaron los datos para su análisis.

Tabla 4. Investigaciones que utilizaron redes sociales

Autores	Objetivo	Método/Aplicación	Lugar	Red social	Escala geográfica
(Lansley & Longley, 2016)	Discriminar los principales patrones de comportamiento de los usuarios de Twitter en Londres.	Algoritmos no supervisados de aprendizaje/patrones de comportamiento.	Londres	Twitter	Celda 200 m
(Chua et al., 2016)	Saber la trayectoria y la nacionalidad de los turistas en la región de Cilento.	Observacional y no observacional/ Turismo	Italia	Twitter	Celda 200 m
(Jiang et al., 2016)	Examinar la distribución espacial de los tweets y la densidad dentro de las ciudades	Densidad de Kernel/Patrones de comportamiento	Londres, Paris y Berlín	Twitter	Manzanas
(Huang & Wong, 2016)	Determinar la ubicación de las residencias y los sitios de trabajo de los usuarios de la red social	Clústeres espaciales density-based spatial clustering of applications with noise (DBSCAN) /Patrones de movilidad	Washington	Twitter	Parcelas de usos de suelo
(Li et al., 2017)	Analizar los patrones espaciales y temporales de los tweets geoetiquetados por varios métodos de minería espacial.	Estadísticas descriptivas/Patrones de comportamiento.	E.U.	Twitter	Celdas 20-30-100m
(García-Palomares et al., 2018)	Uso de datos de la red social Twitter para analizar el dinamismo de la ciudad a través del día y su relación con los usos de suelo.	OLS estadística descriptiva/Patrones de comportamiento	Madrid	Twitter	Zonas de transporte
(Salas-Olmedo et al., 2018)	Seguir las actividades de los turistas comparando diferentes redes sociales	OLS y estadística espacial/Turismo	Madrid	Twitter y otras	Secciones censales
(Gallego & Carrasco, 2018)	Proponer una metodología para el tratamiento y explotación de los datos de Twitter, para detectar la residencia de los usuarios	Análisis exploratorio de los datos, regresión lineal/Movilidad	Valencia	Twitter	Municipio
(Osorio-Arjona & García-Palomares, 2019)	Utilización de datos de Twitter para obtener matrices de viajes	Matrices de origen destino/Movilidad	Madrid	Twitter	Municipios
(Joaquín Osorio Arjona & García-Palomares, 2019)	Uso de Twitter para detectar el nivel de demanda de las principales universidades de Madrid.	Modelo de Huff/ Movilidad	Madrid	Twitter	Parcelas
(Peng et al., 2020)	Proponer un nuevo marco de percepción de la imagen de la ciudad	Agrupamiento espacial Bosques	China	Weibo	Puntos

	aprovechando los datos de los medios sociales geoetiquetados.	aleatorios/Patrones de comportamiento.			
(Heikinheimo et al., 2020)	Examinar qué tipos de información sobre la utilización y los valores de los espacios verdes urbanos pueden extraerse de los diferentes tipos de información geográfica generada por los usuarios y aplicarse a la planificación de los espacios verdes urbanos.	Índice de Jackard, patrones espaciotemporales/Patrones de comportamiento	Finlandia	Twitter, Flickr	Celdas 250x250m
(B. Huang & Wang, 2020)	Utilizar el BD espacial para proponer un nuevo método para delinear la estructura urbana con ayuda de imágenes de satélite propuesto en tres ciudades chinas.	Índice de vitalidad urbana, Moran's I, GWR/Patrones de comportamiento.	China	Weibo	Celdas 500 m
(Tu et al., 2020)	Estimar las relaciones que existen entre las fuentes BD y los factores de actividad urbana para determinar el nivel de vitalidad de las ciudades.	OLS, GWR, índice de vitalidad urbana/Patrones de comportamiento.	China	Weibo	Zonas económicas
(Osorio-Arjona, 2020a)	Estudiar el impacto que ha tenido la World Pride en la ciudad de Madrid.	Estadística espacial/Eventos	Madrid	Twitter	Barrios y secciones censales
(Condeço-Melhorado et al., 2020)	Analizar los patrones de actividad de los usuarios de Twitter antes y durante las Olimpiadas de Río, Brasil	Autocorrelación espacial Moran's y densidad/Eventos	Brasil	Twitter	Hexágonos de 400 metros de lado
(Yubero et al., 2021)	Probar la viabilidad de Twitter para ilustrar el comportamiento de los turistas	Autocorrelación espacial Moran's/Turismo	Portugal	Twitter	Hexágonos de 400 metros de lado

Fuente: Elaboración propia.

Los datos de Twitter y otras redes sociales se han utilizado para conocer aspectos relacionados con la movilidad turística, el dinamismo y los patrones espaciales del comportamiento de los ciudadanos y el impacto de eventos culturales o deportivos en las grandes metrópolis. Además, para realizar estos análisis se apoyan en métodos de estadística espacial, algoritmos supervisados, clústeres espaciales, índices de vitalidad urbana, a diferentes niveles de agregaciones espaciales que van desde las parcelas hasta dividir el espacio geográfico en celdas o hexágonos de diferentes dimensiones.

Entre los trabajos que analizan patrones de comportamiento de los usuarios, por ejemplo, (Moya-Gómez et al., 2018) utilizan los datos provenientes de la red social, en mención, para obtener un aproximado de los usuarios, se basan en su grado de atracción a las distintas zonas de transporte de la ciudad de Madrid, para inferir el nivel de accesibilidad a través de la red. Otra investigación pretendía conocer el dinamismo de la ciudad en diversos períodos y horarios a lo largo del día. Para lograr su objetivo utilizaron los datos geolocalizados de Twitter y así saber el momento del día donde se ubicaban los usuarios y la información obtenida se debía cruzar con los datos de usos de suelo con la finalidad de dictaminar cuales son los usos del suelo donde se ubica la población (García-Palomares et al., 2018).

Por su parte, Longley & Adnan (2016), realizaron un estudio con los datos de Twitter, donde extrajeron información de los tweets geolocalizados para hacer un análisis de la distribución socio espacial de los usuarios. Además, se desarrolla un análisis espacio-temporal en diversas horas y días de la semana, utilizando variables sociodemográficas de los usuarios. Estudios recientes, realizados con la red social China Weibo, se orientan a detectar las zonas de la ciudad de mayor dinamismo, para ello se apoyan en índices, como por ejemplo: el índice de vitalidad, Moran I y regresión geográficamente ponderada (B. Huang & Wang, 2020; Tu et al., 2020).

Se encuentran investigaciones que, por medio de los tweets geolocalizados, pueden caracterizar aspectos espaciales, temporales y demográficos de los turistas. En su publicación Chua et al. (2016) demuestran como el análisis de los tweets geotiquetados presentan con más detalle el movimiento espacial y temporal de los turistas en la ciudad de Cilento en Italia. Por su parte, Salas-Olmedo et al. (2018) analizan la huella digital del turista en la ciudad de Madrid comparando tres redes sociales, entre las que se encuentra Twitter. Para ello agregan en secciones censales los usuarios de las redes sociales utilizadas, presentan la densidad de turistas, análisis de autocorrelación espacial y análisis de regresión (Ordinary Least Squares-OLS). La publicación de Yubero et al. (2021) analiza la distribución espacio-temporal de los turistas y residentes en el barrio de Alfama, Lisboa (Portugal). Para poder hacerlo agregan los usuarios de Twitter en hexágonos de 400 metros. Utilizan herramientas de autocorrelación espacial con el propósito de conocer la distribución espacial de los usuarios tanto en días laborables como fines de semana.

Además, se encuentran trabajos que, a partir de los datos de Twitter, generan matrices de origen-destino, que permiten inferir patrones de movilidad de la población urbana. (Gallego & Carrasco, 2018; Osorio-Arjona & García-Palomares, 2019; Osorio Arjona & García Palomares, 2019). En su trabajo, Gallego & Carrasco (2018) proponen una metodología para detectar la localización de la residencia de los usuarios, con este fin se apoyan en los datos de la red social en cuestión. Para validar los resultados, realizan un test de correlación de Pearson que compara los usuarios con el número de habitantes a nivel de municipio. Por su parte, Osorio et. al. 2019 investigan con ayuda de matrices de origen-destino la movilidad a los campos universitarios del Área Metropolitana de Madrid, estimando el área de influencia de cada universidad, apoyándose; además, en datos de transporte público y nivel de renta. En otra publicación, Osorio-Arjona et. al. (2019) analizan la movilidad de los usuarios de Twitter entre sus lugares de residencia y trabajo. Para ello utilizan nuevamente las matrices de origen-destino y comparan los resultados con datos oficiales que provee el Consorcio Regional de Transportes de Madrid.

También se encuentran trabajos que utilizan los datos de Twitter para analizar el impacto de eventos culturales o deportivos. Por ejemplo, Osorio-Arjona (2020) estudia el impacto del festival del orgullo gay en la ciudad de Madrid. En su análisis agrega los datos según sección censal y barrios con el propósito de conocer la distribución espacial de los usuarios antes y durante la celebración del festival. Por otro lado, Condeço-Melhorado et al. (2020) proponen comparar el impacto en la ciudad de las olimpiadas de Río, Brasil. En su estudio se apoyan en técnicas de análisis de autocorrelación espacial para conocer la distribución de los usuarios de Twitter antes y durante las olimpiadas.

En definitiva, los datos provenientes de la red social Twitter constituyen uno de los más utilizados para hacer estudios de *Big Data*, tal como demuestra la gran cantidad de investigaciones que se pueden encontrar en el ámbito científico con enfoques diversos tales como: el flujo turístico, la movilidad urbana, patrones de consumo, cantidad de usuarios; en consecuencia, se han constituido en una fuente de datos muy importante debido a la cantidad de información que se puede generar.

La geolocalización ha llevado a los navegadores de internet como: Google Chrome y Firefox, ha incluir en sus lenguajes de programación algoritmos para detectar la posición geográfica de los usuarios de internet. Todos estos avances en tecnología

brindan un valioso apoyo para poner en marcha estudios, donde el geoposicionamiento representa una de las variables a tomar en cuenta y por medio del uso de herramientas como los SIG, poder analizar, manipular y visualizar la información que permite deducir cambios, patrones, tendencias y relaciones en el comportamiento del ser humano.

La implementación de los modelos de localización-asignación necesita contar con una población que se constituya en la demanda de la infraestructura que se pretende ofertar, por consiguiente, en este trabajo se utilizarán los datos GPS provenientes de los registros históricos de viajes realizados por las motos eléctricas compartidas y los datos almacenados por el SAMUR-PC de Madrid.

Se destaca que, tradicionalmente, los modelos de localización-asignación se han ejecutado haciendo uso de una demanda estática, proveniente, por lo general, de los datos del censo poblacional. En este caso se pretende dar dinamismo a la demanda que se logrará por medio de los datos geolocalizados y en base a la literatura revisada, nos permiten conocer la movilidad y el comportamiento de los habitantes sobre el espacio geográfico.

### **2.3 Oportunidades de investigación**

En este capítulo se han estado explicando los aspectos conceptuales, los tipos de soluciones y los temas donde se han utilizado los MLA, así como las oportunidades que ofrecen las nuevas fuentes de información geolocalizada en la aplicación de estos modelos. Los MLA representan un gran apoyo para los encargados en la toma de decisiones sobre los distintos servicios o empresas a ubicar, pensando, la mayoría de las veces, en el bienestar de la población.

Los modelos de localización, desde hace muchos años, se han utilizado por geógrafos y planificadores interesados en encontrar la mejor localización de equipamientos. En la actualidad se sigue investigando intensamente sobre esta temática, creando modelos que incluyan nuevas variables o modificando las soluciones existentes que fueron planteadas, desde sus inicios, por investigadores como Louis Hakimi, León Copper, Michael Goochild y muchos otros investigadores.

Los MLA aprovechan los grandes cambios en la tecnología informática, que permiten mejorar el tiempo de cálculo en la realización de los modelos. Estos cambios se

producen en los ordenadores, sobre todo en lo que respecta a la velocidad de procesamiento, seguido de los programas informáticos que permiten una mayor velocidad de ejecución de los MLA. También han aparecido mejoras sustanciales en los softwares utilizados para los SIG. Estos programas incorporan en sus funcionalidades los distintos tipos de soluciones que se han explicado en páginas anteriores, en donde se integran aplicaciones de programación informática que ayudan a automatizar muchos procesos que tardarían en realizarse.

Inicialmente, los modelos de localización se realizaban utilizando datos de oferta y demanda proveniente, principalmente, de fuentes gubernamentales, tales como los censos o por medio de encuestas de opinión que se constituían en las fuentes de los insumos con los que se contaba para llevar a cabo los modelos. De esta manera, los modelos de localización se desarrollaron de forma estática, es decir, los problemas de localización se planteaban para periodo de tiempo fijo.

Sin embargo, la mayoría de los elementos que intervienen en los modelos son dinámicos y, por tanto, dependen de la componente temporal. Como señala Daskin (2011), con los modelos dinámicos es factible capturar los cambios en los patrones espacio-temporales de la distribución de la demanda, ya sean diferencias horarias, entre días laborales o fines de semana o estaciones y otros periodos temporales. Al plantear los MLA dinámicos se busca dar respuesta a cuestiones del dónde y cuándo invertir en la oferta de nuevos servicios.

Luego de revisar los estudios sobre MLA, en los últimos cinco años, se puede afirmar que son pocas las investigaciones que incorporan el dinamismo de las nuevas fuentes de datos en alguno de los elementos de los modelos de localización óptima. Ya sea en la demanda, en la oferta o en el funcionamiento de la red. Lo anterior demuestra que existen oportunidades para dar nuevos enfoques en los planteamientos de los MLA, incorporando, por ejemplo, el uso de redes sociales, los registros GPS de los viajes realizados por las motos y patinetes, recabados por las empresas que ofrecen servicios de micromovilidad.

La Tabla 5 resume publicaciones que han escrito sobre los MLA en los últimos años, destacando los objetivos perseguidos en sus investigaciones y, sobre todo, si incorporaron o no el dinamismo que aporta el BD en alguno de los elementos de los MLA. Cabe señalar que la información resumida en la Tabla 5 tiene dos propósitos.

En primer lugar, mostrar que la investigación sobre los MLA sigue en vigor, aunque la mayoría de los estudios continúan utilizando datos de entrada estáticos –oferta, demanda y red– procedentes de fuentes tradicionales. En segundo lugar, recoger aquellos estudios que incorporan el dinamismo en algunos de los elementos de los MLA a partir de Big Data geolocalizada.

Estos estudios se marcan en la Tabla 5 con un gancho (✓) para distinguir si han incorporado un análisis dinámico en el desarrollo de los modelos. Mientras que los marcados con x indican que no tuvieron en cuenta las nuevas fuentes de datos en ninguno de los elementos del modelo.

Tabla 5. Estudios realizados en los últimos cinco años

Autores	Objetivo	Incorporación del dinamismo a través de nuevas fuentes de datos		
		Oferta	Demanda	Red
(Polo et al., 2015)	Integrar los modelos de accesibilidad y localización en los Sistemas de Información Geográfica como estrategia propuesta para mejorar la planificación espacial de los servicios de salud pública.	x	x	x
(Beheshtifar & Alimoahmmadi, 2015).	Aplicar un modelo de localización óptima multiobjetivo que combina GIS con algoritmos genéticos.	x	x	x
(Vora et al., 2015).	Analizar la disponibilidad actual de servicios de salud en tres distritos de Gujarat e identificar las mejores ubicaciones para centros de servicios adicionales a fin de optimizar el acceso a los servicios gratuitos de cesárea utilizando la tecnología del Sistema de Información Geográfica.	x	x	x
(Tu et al., 2016)	Desarrollar un enfoque de cobertura de la demanda espacio-temporal utilizando BD espacio-temporal para facilitar la ubicación de la estación de carga eléctrica de taxis.	x	✓	x
(Zhu et al., 2016)	Analizar la distribución espacial de la demanda y las ubicaciones candidatas de los centros de trauma en base a un análisis espacial y presentó un modelo de ubicación-asignación jerárquica para centros de trauma de bajo y alto nivel en Shenzhen.	x	✓	x
(Giménez-Gaydou et al., 2016)	Determinar la ubicación óptima de las estaciones de carga pública en las zonas urbanas en las que se tengan en cuenta las particularidades del proceso de recarga de los vehículos eléctricos.	x	x	x
(Park & Young Sohn, 2017)	Proponer un nuevo marco, basado en los datos de la trayectoria de los taxis, para localizar las estaciones de bicicletas compartidas de la manera	✓	✓	x

	más eficiente para reemplazar los viajes cortos en automóvil.			
(Özceylan et al., 2017)	Investigar las ubicaciones actuales y los potenciales almacenes de farmacia en Gaziantep para lograr una distribución óptima de los hospitales y las farmacias.	x	x	x
(Malik & Shivamallu, 2017).	Evaluar los lugares adecuados para establecer nuevas estaciones de bomberos y la localización de las existentes utilizando los SIG.	x	x	x
(Dibene et al., 2017)	Modelar la demanda de servicios médicos de emergencia, para optimizar la ubicación de las ambulancias de la Cruz Roja de Tijuana.	x	✓	x
(Metz et al., 2018)	Encontrar las localizaciones posibles para las estaciones de bicicletas en el campus universitario de Gaziantep.	x	x	x
(Erfani et al., 2018)	Encontrar la mejor distribución de los contenedores de basura utilizando modelos de localización óptima.	x	x	x
(Bolouri et al., 2018)	Evaluar el problema de localización óptima multiobjetivo para la ubicación de las estaciones de bomberos, utilizando un recocido simulado (simulated annealing) y un algoritmo genético, con el fin de minimizar la distancia y el tiempo, así como maximizar la cobertura.	x	x	x
(Chukwusa & Comber, 2018)	Explorar el impacto de la población residente y no residente en los modelos de localización óptima de un servicio de emergencia médica, comparando los resultados generados en cada tipo de demanda.	x	x	x
(Kotavaara, 2018)	Encontrar nuevos lugares óptimos para los servicios de atención primaria de salud teniendo en cuenta los posibles viajes en transporte público, además de los viajes en automóvil.	x	✓	✓
(Rathore et al., 2019)	Determinar el número total de contenedores necesarios teniendo en cuenta diferentes factores como los múltiples tipos de fuentes, los contenedores de desechos y los tipos de residuos junto con la seguridad y la recogida de desechos.	x	x	x
(Laasasenaho et al., 2019).	Desarrollar y evaluar la viabilidad de una solución basada en el SIG para seleccionar la ubicación óptima de las plantas de biogás y las terminales madereras en una zona rural, basada en la minimización de las necesidades de transporte de las diferentes biomásas.	x	x	x
(Fredriksson et al., 2019)	Desarrollar e ilustrar un método para evaluar si otros factores que están relacionados con la demanda de los ciudadanos afectan a la asignación espacial de los servicios públicos, y evaluar las consecuencias para el bienestar de estos.	x	x	x
(Wondwossen & Bedasa, 2019)	Aumentar el nivel de cobertura de las escuelas primarias para mejorar el acceso de todas las personas en edad escolar.	x	x	x

(Acar & Kaya, 2019)	Proponer un modelo de optimización estocástica en dos etapas que determina las ubicaciones y capacidades de los hospitales móviles para las fases previas y posteriores al desastre.	x	x	x
(Namazian & Roghanian, 2019).	Presentar un modelo basado en Sistemas de Información Geográfica (SIG) para localizar los sitios adecuados para establecer nuevas sucursales mediante el uso de fuentes de datos.	x	x	x
(Abdelkarim, 2019)	Determinar la eficiencia de la distribución espacial de los servicios de salud y su compatibilidad con la distribución de los distritos residenciales en Al-Madinah Al-Munawwarah.	x	x	x
(Yongping Zhang et al., 2019)	Proponer un marco metodológico para apoyar la planificación de cercas eléctricas virtuales para los servicios de bicicletas compartidas sin muelle.	✓	✓	x
(Zhou et al., 2020)	Mejorar los problemas en el estudio de la disposición espacial de las instalaciones médicas de emergencia existentes y considerar el tiempo, el tráfico, la población y otros factores para estudiar la disposición espacial de las instalaciones médicas de emergencia urbanas.	x	x	✓
(Han et al., 2020)	Aplicar el modelo de localización cobertura de conjuntos integrando el big data espacio-temporal a la planificación urbana, basándose en los datos de incendios.	x	✓	✓
(Yu et al., 2020)	Optimizar la disposición de los parques de bomberos bajo el escenario de rescate de incendios simulado.	x	✓	✓
(L. Yang et al., 2020)	Proponer un modelo de demanda espacio-temporal para representar y capturar las variaciones espacio-temporales de la demanda de bicicletas utilizando un gran conjunto de datos GPS de bicicletas compartidas	x	✓	x
(Banerjee et al., 2020)	Identificar las ubicaciones más apropiadas para tres nuevas estaciones de bicicletas en la ciudad de Baltimore, basándose en múltiples factores identificados a través de un análisis espacial de las trayectorias del GPS de las bicicletas compartidas	x	✓	x
(W. Wang et al., 2021)	Investigar la cobertura real del cuerpo de bomberos en el centro de Pekín bajo diferentes situaciones de tráfico	x	x	✓

Fuente: Elaboración propia.

Únicamente doce de los estudios mostrados en la Tabla 5 consideran el dinamismo en los MLA empleando Big Data para representar ya sea la oferta, la demanda o la red.

Con respecto a los trabajos que utilizan fuentes de Big Data para representar la localización de los candidatos (oferta) en los modelos, se encuentra (Park & Young Sohn, 2017; Zhang et al., 2019). En su investigación, Park & Young Sohn (2017) proponen un modelo de optimización para la colocación de estaciones de bicicletas compartidas en la ciudad de Seúl-Corea. Para obtener las ubicaciones candidatas, utilizan los registros GPS de los lugares de abordaje y descenso a los taxis, cuyos viajes reflejan patrones similares a los del uso de la bicicleta, en términos de tiempo y distancia recorrida. A partir de estos datos, calculan la frecuencia de uso de los taxis e identifican las ubicaciones más útiles para las estaciones de bicicletas. Utilizan la información de los taxis, por considerarlos sensores que aportan una valiosa información sobre la dinámica de la movilidad y las condiciones del tráfico.

Por su parte, Zhang et al. (2019), presentan un enfoque metodológico para planificar lo que se conoce como "*electric fence*" (valla eléctrica). Se refiere a un perímetro virtual para un área geográfica real donde estacionar las bicicletas de un sistema de movilidad compartida sin estaciones fijas. El sistema de valla eléctrica utiliza sistemas de posicionamiento global (GPS), dispositivos de identificación por radiofrecuencia o sensores bluetooth para determinar la proximidad entre las bicicletas y las zonas designadas. Para plantear el problema utilizan un conjunto de datos GPS (que almacenan el origen y el destino de los viajes realizados por los usuarios de bicicletas). Estos datos se agregan en celdas de 50 metros, y las que contenían más de cinco orígenes y destinos se tomaron como lugares candidatos para el desarrollo del MLA.

En cuanto a los estudios que utilizan fuentes de Big Data para obtener los sitios que representan la demanda utilizada en los modelos se refiere los trabajos de (Dibene et al., 2017; Han et al., 2020; Park & Young Sohn, 2017; Tu et al., 2016; Yang et al., 2020; Yu et al., 2020; Zhang et al., 2019; Zhu et al., 2016).

Zhu et al. (2016) presentó un modelo de localización-asignación jerárquica para centros sanitarios (atención a traumatología) en Shenzhen, China. Para ello, obtienen la demanda a partir de las ubicaciones de los traumas atendidos por el sistema de salud, que contienen, además información temporal, tiempo de respuesta, género y diagnóstico del caso atendido. Su modelo lo planean utilizando las soluciones maximizar cobertura y minimizar impedancia. Además, consideran factores de respuesta, cobertura y coste de la localización de las instalaciones.

Tu et al. (2016) presentan un modelo de localización desde una perspectiva espacio-temporal. Proponen ubicar estaciones de carga para taxis eléctricos, utilizando datos GPS recogidos por dispositivos colocados en los taxis para representar las ubicaciones de la demanda. Los resultados demuestran que la localización optimizada de las estaciones de carga puede mejorar, tanto el servicio de taxis eléctricos en carretera, como el de las estaciones de carga.

El trabajo de Dibene et al. (2017) plantea optimizar la localización de ambulancias en Tijuana, México. Para ello, utiliza datos históricos de llamadas de servicios de emergencia. Estos registros (GPS) contienen el origen y la prioridad de la emergencia. Con el campo de fecha de los datos, propuso escenarios para los días de semana y los fines de semana, considerando dos franjas horarias. Para simplificar el modelo, la demanda se agrupó mediante técnicas de clustering. Sus resultados muestran que la cobertura de la demanda y los tiempos de respuesta pueden mejorarse sustancialmente con una simple reubicación de las bases actuales, sin necesidad de recursos adicionales.

Otros trabajos aplican modelos de localización integrando Big Data espacio-temporal a la planificación urbana basada en datos históricos de incendios (Han et al., 2020). Dividen el área de estudio en hexágonos espaciales de 500 metros, y se asignan pesos a cada celda para obtener el valor del riesgo de incendio. El conjunto de datos almacena la ubicación y la causa del incendio registrado por el centro de llamadas al 911. Para desarrollar su modelo utilizan la solución maximizar cobertura con capacidad restringida.

Por otra parte, se están utilizando los modelos de localización para identificar la mejor ubicación para sistemas de bicicletas compartidas, empleando –como demanda– los registros que almacenan los dispositivos GPS que están instalados en las bicicletas (Park & Young Sohn, 2017; Yang et al., 2020; Zhang et al., 2019). En particular, Yang et al.(2020), proponen un modelo para representar y capturar las variaciones espacio-temporales de la demanda de bicicletas. Para ello, utilizan un gran conjunto de datos GPS que registran información de los viajes realizados por los usuarios de las bicicletas compartidas. Estos datos se recogen a lo largo de treinta días para extraer la demanda histórica y dinámica de bicicletas en el espacio y el tiempo. Estos registros GPS se agregan en celdas de 100 metros. La solución de su trabajo se basa en maximizar la cobertura y minimizar la distancia media entre los puntos de demanda y

la estación más cercana. El planteamiento de estos autores se fundamenta en un análisis de cubos espacio-temporales donde consideran que la variación y el número de viajes cambian a lo largo del día.

Otro trabajo que utiliza los datos de los viajes almacenados por los dispositivos GPS, instalados en las bicicletas, es el que realizan Zhang et al.(2019). Estos autores utilizan dichos datos para representar la demanda de aparcamiento de las bicicletas compartidas sin base fija. Para ello, agregan los orígenes y destinos de los viajes realizados por los usuarios de bicicletas (en celdas de 50 metros) y cuentan el número de viajes contenidos en cada celda para obtener de este modo la demanda de aparcamiento. Los autores utilizaron la solución de maximizar cobertura para realizar el modelo de localización. Los resultados muestran que el 91,8 % de la demanda total de aparcamiento puede satisfacerse con las ubicaciones previstas. Además, se garantiza que al menos el 95,8 % de todas las bicicletas pueden aparcarse en una de las ubicaciones planificadas y puede ayudar a determinar de forma eficiente y fiable las ubicaciones adecuadas para el aparcamiento de bicicletas. Park & Young Sohn (2017) utilizan las soluciones de máxima cobertura y minimizar impedancia para diseñar un sistema de bicicletas compartidas con bases fijas para el anclaje. La demanda se extrae de datos telefónicos que permiten considerar la población flotante con una resolución de 50 metros. Estos datos se cruzaron con las áreas de influencia de algunos puntos de interés, como: estaciones del metro, residencias, parques y centros comerciales.

Otro dato de entrada para el MLA es la red de transporte. La red es un conjunto interconectado de entidades lineales que forman una estructura espacial por la que se mueven los recursos, ya sean vehículos, personas, energía o información (Comas & Ruiz, 1993). Es necesario determinar varias reglas de conectividad entre los diferentes componentes de la red, para facilitar el acceso entre los sitios de oferta y demanda. Se suelen considerar algunos tipos de límites de impedancia (funciones de coste): distancia de viaje (km) y tiempo de viaje (minutos) (Rahman et al., 2021). En la optimización de las ubicaciones de los servicios o equipos, el tiempo de viaje o cualquier otro coste de desplazamiento a través de la red es un parámetro de vital importancia. En comparación con la distancia euclidiana, el uso de la distancia de la red, considerando la velocidad correspondiente a cada arco es más razonable y preciso (Zhu et al., 2016).

Asimismo, la congestión del tráfico es un factor importante que influye en las diferencias temporales y espaciales de la accesibilidad hacia los servicios cuando los desplazamientos son por carretera. En consecuencia, al modelar las redes de carreteras resulta esencial tener en cuenta las condiciones del tráfico en diferentes momentos (Zhou et al., 2020). En este sentido los trabajos de Han et al. (2020); Wang et al. (2021); Zhou et al. (2020) abordan situaciones de condiciones de tráfico en la red al momento de plantear sus modelos de localización-asignación.

En particular, Wang et al. (2021) incluyen las condiciones de tráfico en la red de transporte durante unas horas específicas. Utilizan información de la velocidad de los diferentes segmentos de la red durante una semana. Dichos datos los descargan de la aplicación "AutoNavi", plataforma China que ofrece servicios de localización. En el conjunto de datos de la red, la información sobre la velocidad se convierte en el coste del tiempo empleado en cada arco de carretera. Para ello, se divide la longitud del arco entre la velocidad media de conducción. Los autores, emplean estos datos para evaluar la cobertura actual de las estaciones de bomberos en Beijing, China, bajo diferentes situaciones de tráfico.

En el caso de la investigación de Han et al. (2020) también se emplean datos de congestión de la red para analizar la cobertura de la demanda por parte de los parques de bomberos. La información obtenida procede de los datos de velocidad del tráfico en tiempo real y del estado de la congestión que presenta la red de carreteras de Nanjing (China), proporcionados por la aplicación Amap Maps durante trece días de 2018. El enfoque del problema de localización utiliza las soluciones del modelo de máxima cobertura con capacidad restringida y minimizar impedancia.

Zhou et al.(2020) agregan datos de tráfico en la red que utiliza en los MLA para simular condiciones de congestión durante el día. Obtienen los datos de tráfico de la plataforma Open Maps (<http://lbs.amap.com/>). Los datos de tráfico se utilizaron, principalmente, para obtener la información sobre la velocidad en situaciones de congestión. Recogen los datos, una semana continua, para distinguir las condiciones del tráfico en diferentes momentos de los fines de semana y los días laborables. Para ello, seleccionan algunas horas específicas con el fin de representar la congestión diaria. En su trabajo analizan la disposición espacial de las instalaciones de emergencias médicas existentes en Pekín, China. En el planteamiento del modelo utilizan dos soluciones. En primer lugar, emplean la solución maximizar cobertura con

el objetivo de calcular la cobertura de las ambulancias en un umbral de quince minutos. Mientras que la solución minimizar impedancia la utilizan para cubrir posibles sitios de demanda no cubiertos.

Cabe señalar que, con el surgimiento del Big Data, aparecen oportunidades de plantear los MLA tomando en cuenta los datos geolocalizados registrados por algunas redes sociales, dispositivos de telefonía móvil y la diversidad de sensores instalados en la ciudad. En comparación con los datos tradicionales, el Big Data se caracteriza por ofrecer mayor nivel de resolución temporal y espacial. Estas características constituyen nuevas oportunidades para incorporar una perspectiva dinámica en la aplicación de MLA. De esta forma se pueden resumir las siguientes ventajas: 1) Permite conocer la distribución cambiante de la demanda a partir de los patrones de movilidad de la población. 2) Con la información que almacenan las nuevas redes de transporte públicas y privadas se pueden implementar MLA que simulan el desplazamiento de la población en coche o en el servicio de transporte público de la ciudad. En definitiva, la utilización de estas fuentes de datos permite incorporar una perspectiva espacio-temporal en los elementos de entrada del MLA (demanda, red de calles y oferta) y analizarlos de forma más realista.

La siguiente sección presenta el área de estudio elegida para el planteamiento de los modelos de localización-asignación. También se describen los datos de oferta, demanda y red utilizados para el desarrollo de los MLA. Por último, se explica la metodología utilizada en esta tesis.

# **3 AREA DE ESTUDIO, DATOS Y METODOLOGÍA**

### 3.1 Área de estudio

Para realizar la investigación se ha elegido Madrid como escenario para la aplicación empírica de los modelos de localización-asignación. Se trabaja con diferentes modelos a distintas escalas territoriales. En uno de los casos, se trabaja a escala metropolitana, en otro el análisis se realiza a escala urbana, utilizando el municipio de Madrid. Por último, se opta por una escala de mayor detalle, trabajando con los distritos centrales de Madrid (Almendra Central). Se ha elegido Madrid por la disponibilidad de los datos que se han utilizado para el desarrollo de los modelos de localización asignación. Además, la ciudad de Madrid se destaca por ser una ciudad dinámica, con un espacio metropolitano donde abundan diferentes tipos de servicios y equipamientos. Se trata de una ciudad multicultural que ofrece un entorno propicio para la ubicación de servicios y negocios.

#### 3.1.1 Área metropolitana de Madrid

El área metropolitana de Madrid está localizada en la parte central de España y forma parte de la Comunidad de Madrid, donde se localiza la ciudad capital del país. La importancia del área metropolitana de Madrid se refleja en las diferentes clasificaciones y ranking globales. Según el *Global Power Cities Index 2019*, que clasifica 48 ciudades del mundo por su magnetismo para atraer personas, capitales y empresas, Madrid figura como la decimotercera ciudad del mundo y la quinta de Europa, en un ranking liderado por Londres, Nueva York, Tokio y París<sup>6</sup>.

En el *Índice de Ciudades Globales (GCI)*, Madrid resulta ser la decimoquinta ciudad con mayor influencia del mundo<sup>7</sup>. *Eurostat* (Oficina de Estadística de la Comisión Europea) compara la esperanza de vida en las diferentes ciudades de la Unión Europea y posiciona a Madrid como la primera región. Por otro lado, el informe *Quality of Life Survey 2019* califica a Madrid como la octava ciudad del mundo con mejor calidad de vida, por encima de Ámsterdam, Estocolmo, París y Singapur.

Como expresa García-Palomares (2007), el magnetismo que ejerce la centralidad de la metrópoli madrileña, a nivel nacional, ya sea sobre el sector financiero o de servicios a empresas y también sobre una buena parte del comercio y los servicios más

---

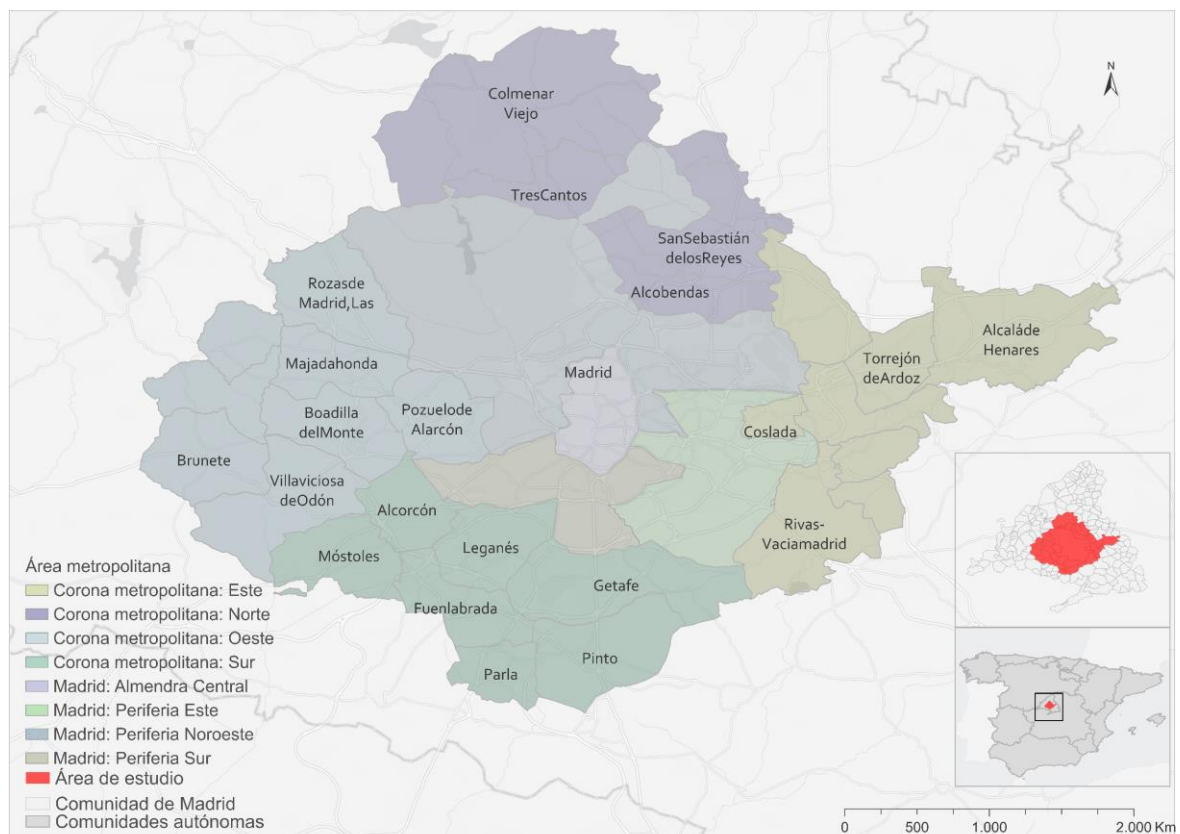
<sup>6</sup> Mori – Global Power Cities Index 2019 y 2018

<sup>7</sup> Kearney – Global Cities Report 2019/18

especializados, crea una metrópoli en constante crecimiento, constituyéndose en una notable región urbana, en lo que respecta al peso demográfico y económico.

El área metropolitana de Madrid cuenta con la mayor concentración de población y servicios de España. Incluye 28 municipios (Figura 8) donde viven alrededor de 6.780.000 de habitantes, de acuerdo con el Padrón de población del 2020. Es la principal área metropolitana de España, superando a Barcelona, donde viven 5,5 millones de personas (Ayuntamiento de Madrid, 2020a). La Figura 9 muestra la densidad de población y la renta por municipio. En ella se observa que el único municipio con alta densidad de población y renta es el municipio de Madrid, aunque con importantes diferencias internas. Por su parte, los grandes municipios del sur y este metropolitano, como Móstoles, Torrejón de Ardoz, Leganés, Parla, entre otros, registran una alta densidad de población y una renta menores.

Figura 8. Zonificación del área metropolitana



Fuente: Elaboración propia.

Figura 9. Densidad de habitantes y renta a nivel de municipio



Fuente: Elaboración propia a partir de datos del Instituto de Estadística de la Comunidad de Madrid y del Portal de Datos Abiertos del Ayuntamiento de Madrid. Año 2018

En la metrópolis confluyen las principales infraestructuras de comunicación, esto la posiciona como el principal centro logístico de España y del sur de Europa. Cuenta con una importante red de autopistas y carreteras, tanto radiales como de circunvalación y constituye el núcleo del transporte ferroviario nacional, lo que facilita una conexión eficaz con otras comunidades autónomas y con Europa. Resalta en los ámbitos de la ciencia y la tecnología, con un alto nivel de inversión en I+D, que sobrepasa la media nacional en el porcentaje del PIB. También, alberga reconocidos centros universitarios, incluidos los de carácter tecnológico, y centros de investigación tanto públicos como privados (Ayuntamiento de Madrid, 2020a).

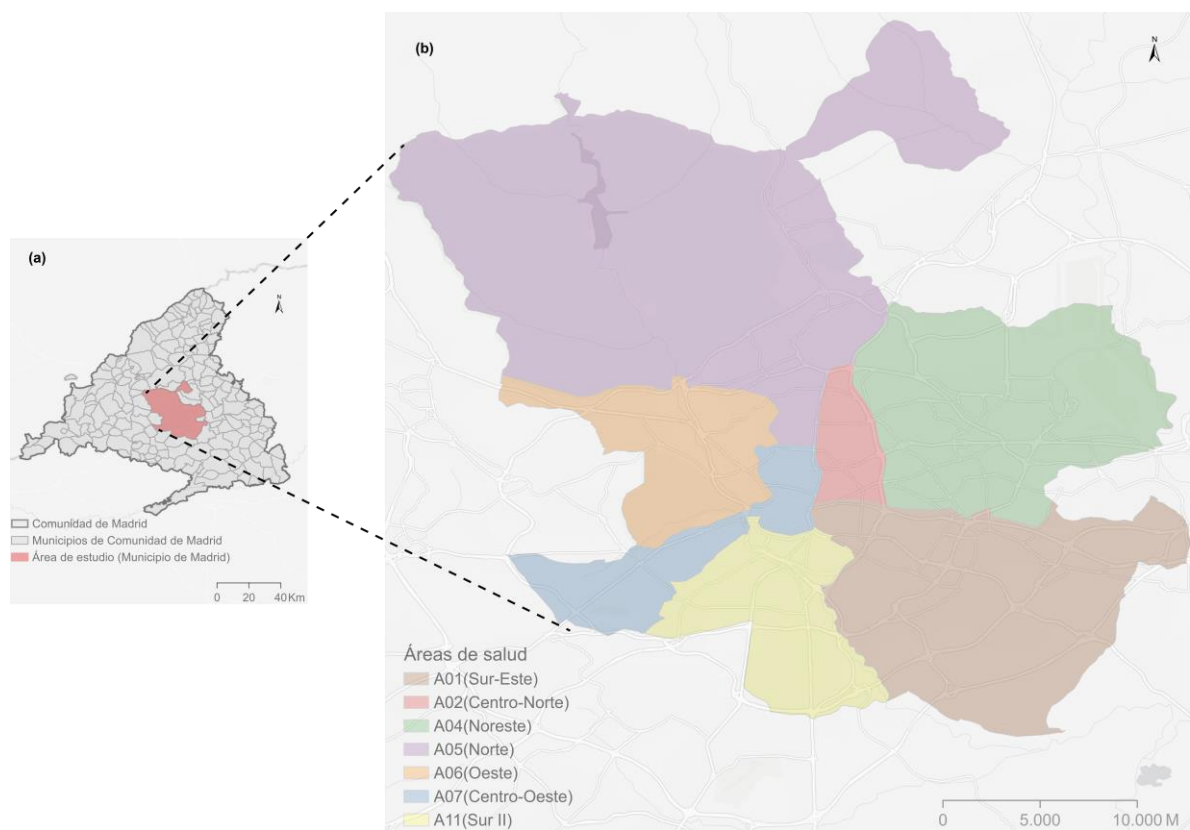
En la tesis se utiliza el conjunto del área metropolitana de Madrid para implementar modelos de localización asignación dinámicos aplicados a la localización de centros comerciales.

### 3.1.2 Municipio de Madrid

El área seleccionada para desarrollar una parte del estudio ha sido el municipio de Madrid, caracterizado por concentrar el mayor desarrollo económico de la comunidad. Su administración territorial la conforman 21 distritos y siete áreas de salud (Figura 10).

De acuerdo con el Padrón Municipal de Población 2020, el municipio de Madrid contaba con 3.334.730 habitantes (el 50 % de la población de la Comunidad de Madrid) presentando una distribución por sexo de 46,6% hombres y 53,4% mujeres. El municipio cubre una superficie de 60.445,52 Ha, con una densidad de población aproximada de 55 habitantes por hectárea. Dentro del municipio, los distritos más poblados son: Carabanchel, Fuencarral, Latina y Puente de Vallecas (Figura 11).

Figura 10. Municipio de Madrid y áreas de salud




(a) Comunidad de Madrid dividida en municipios y el área de estudio (b) Áreas de salud dentro del área de estudio. Fuente: Elaboración propia.

En el ámbito económico, el producto interior bruto (PIB) de la Ciudad de Madrid ascendió a 152.576 millones de euros en 2019, equivalente al 63,2% del conjunto de

la Comunidad de Madrid y al 12,3% de España en ese año, rebasando, ampliamente, el peso de su población en cada uno de los dos territorios (Ayuntamiento de Madrid, 2020a). El sector servicios representa algo más del 83% del mercado laboral. La oferta de equipamientos sanitarios públicos y privados la componen 49 hospitales con disponibilidad de 12.645 camas. El municipio de Madrid cuenta con valiosas infraestructuras de comunicación que permiten la interconexión eficaz con el resto del país y Europa. La diversidad de atracciones turísticas e instalaciones de servicio y ocio atraen todos los años millones de visitantes nacionales y extranjeros.

Figura 11. Población de los Distritos del municipio de Madrid 2020



Fuente: Elaboración propia a partir de datos del Instituto de Estadística de la Comunidad de Madrid y del Portal de Datos Abiertos del Ayuntamiento de Madrid.

El municipio de Madrid ha sido utilizado como caso de estudio en dos de los modelos planteados en la tesis, para la localización de hospitales y para la localización de bases de ambulancias de un servicio de urgencias.

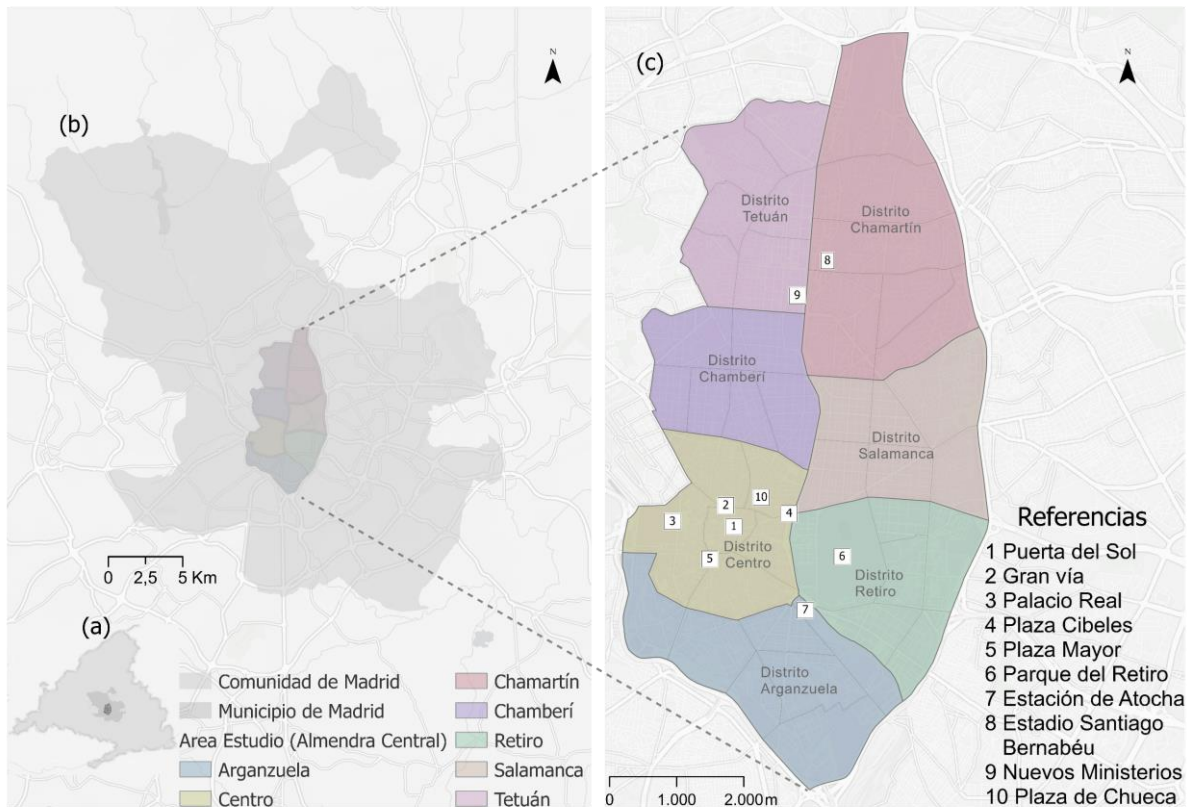
### 3.1.3 La Almendra central

Uno de los casos de estudio se realiza en la Almendra Central de Madrid. El área la componen los siguientes distritos de la ciudad: Centro, Arganzuela, Retiro, Salamanca, Chamartín, Tetuán, Chamberí (Figura 12). La zona se destaca por la variedad de negocios, tiendas, bancos y establecimientos de servicios especializados, lo que genera una alta densidad de empleos. Abarca una población, en torno a un millón de habitantes (el 30,4% de la población del municipio de Madrid) según el censo municipal de 2020. Los distritos Tetuán, Arganzuela y Salamanca concentran la mayor cantidad de habitantes.

Dentro de los límites de la Almendra Central, el área de mayor actividad corresponde al distrito Centro, corazón y principal atractivo turístico del municipio. Este distrito resulta ser el más activo de toda la zona, ya que agrupa los principales lugares de interés de la ciudad (Puerta del Sol, Plaza Mayor, Gran Vía, Palacio Real, etc.). Además, lo integran barrios con reconocida identidad propia (barrios de Malasaña, Chueca, Lavapiés o Letras) que atraen a la joven población local, así como a los visitantes y turistas (Osorio-Arjona, 2020).

En esta escala de análisis en la tesis se aplican MLA para la localización de plazas de aparcamiento de un sistema de micromovilidad. Cabe señalar que en la ciudad de Madrid han aparecido una gran diversidad de vehículos de movilidad compartida y la mayoría operan en el área central (Almendra Central) (ver Arias-Molinares & García-Palomares, 2020).

Figura 12. Distritos de la Almendra Central de Madrid



Fuente: Elaboración propia.

### 3.2 Fuentes de datos utilizadas

Para el desarrollo de la metodología a seguir, se requiere el uso de variadas fuentes de datos con delimitación espacial en la metrópolis de Madrid.

Para el desarrollo de los modelos que incorporaban el dinamismo de las redes se utilizaron dos redes que permiten conocer su distinto rendimiento a lo largo del día. Por un lado, una red de transporte público de Madrid, construida a partir de los archivos GTFS, descargados del sitio web del Consorcio Regional de Transportes de Madrid. Por el otro, se empleó la red de transporte privada TomTom, y el producto Speed Profile. Los modelos de localización-asignación con demanda dinámica y redes estáticas (modelo de estacionamientos para motos), se realizaron con datos proporcionados por la empresa Muving, que ofrece el servicio de motos compartidas en el municipio de Madrid.

En otro de los modelos se recurrió a los registros GPS del servicio de urgencias de Madrid para obtener la demanda y los datos de TomTom, para confeccionar la red. En

este modelo se incorpora el dinamismo en la demanda y en la red de transporte. A continuación, se detalla cada una de las fuentes de datos utilizadas en el desarrollo de los modelos.

### 3.2.1 Datos sobre la oferta de equipamientos

Los MLA requieren de puntos candidatos a los que se les asigna la demanda a cubrir. Para el desarrollo de los MLA propuestos en esta tesis se han utilizado diversas fuentes de datos para representar los lugares que se van a tomar como oferta. Por ejemplo, se emplean hospitales y centros comerciales para implementar el modelo de localización que incluye el dinamismo solo en la red de transporte. En el caso del MLA con ambulancias, se emplean, como oferta, las estaciones actuales de este servicio de emergencias. A continuación, se describen las fuentes de datos adoptadas para realizar las diferentes aplicaciones prácticas desarrolladas en este trabajo.

#### 3.2.1.1 Estaciones de SAMUR-PC

En este caso se utiliza una capa vectorial de puntos que representan las 22 estaciones actuales del SAMUR-PC. Estos datos proceden de OpenStreetMap (OSM) y fueron descargados por el autor desde el servidor OSM. La descarga se realizó con la herramienta *Overpass turbo* (<https://overpass-turbo.eu/>), en la que se utilizó el asistente de consulta donde se tecleó la expresión “*emergency=ambulance\_station in Madrid*”. La descarga se realizó el día 29 de marzo del 2021. Dicho archivo tiene la latitud y la longitud de los sitios en los que se encuentran las estaciones. Esta capa se corroboró con la que aparece en el servicio de datos de la Comunidad de Madrid<sup>8</sup>.

#### 3.2.1.2 Hospitales y centros comerciales

En los modelos con red dinámica y demanda estática, se emplea como puntos de oferta una capa con las coordenadas de hospitales públicos y los centros comerciales. Las dos capas, en formato *shapefile*, se descargaron del portal de datos abiertos de la Comunidad de Madrid (<http://www.madrid.org/nomecalles/Descarga>). La descarga se efectuó en febrero y los datos representan la situación en el 2019.

---

<sup>8</sup> <http://www.madrid.org/nomecalles/DescargaBDTCorte.icm>

En total se trabaja con 35 hospitales públicos, ubicados dentro de los límites del municipio de Madrid. La información temática recogida se refiere al nombre de los hospitales públicos y sus coordenadas geográficas. En el caso de los centros comerciales, se ha trabajado con 91 centros, que se localizan en el área metropolitana de Madrid. Este archivo contiene las coordenadas geográficas, el nombre de los centros comerciales y su superficie bruta alquilable<sup>9</sup>.

### 3.2.2 Datos sobre la distribución de la demanda

En el marco de investigación, se experimentó con los componentes que requieren los modelos de localización y asignación. Un primer modelo incorpora el dinamismo a la red, mientras que la oferta y la demanda permanecen estáticas. En este caso (modelo aplicado a la localización óptima de hospitales y centros comerciales), los datos de población del censo representan la demanda. En un segundo modelo de localización (aparcamientos de motocicletas), la red permanece estática y el dinamismo de la oferta y la demanda se incorpora a partir de los registros GPS de una modalidad de vehículos de micromovilidad. Por último, se experimentó con un modelo, donde la oferta, la demanda y la red incluyen el dinamismo (caso de las estaciones de ambulancias). Para este caso, el dinamismo de la demanda se obtuvo a partir de los registros GPS de los eventos atendidos por SAMUR-PC.

#### 3.2.2.1 Datos de población

Para la ejecución de algunos de los MLA, donde la demanda es estática, se emplearon los datos censales a nivel de sección censal, descargados del Padrón Continuo de Población del año 2020 y disponibles en el servidor de datos del Instituto Nacional de Estadística de España (INE). Para la georreferenciación de los datos de población se usó la cartografía de las secciones censales descargadas del servidor de datos de la Comunidad de Madrid. Posteriormente, a cada sección censal se le calculó el centroide, y estos se emplearon como puntos de demanda del servicio.

---

<sup>9</sup> <https://www.modaes.es/equipamiento/la-ruta-de-los-malls-madrid-la-plata-de-los-centros-comerciales.html#:~:text=Tras%20la%20apertura%20de%20X,total%20de%20superficie%20en%20Espa%C3%B1a.>

### *3.2.2.2 Datos GPS de motos compartidas de la empresa Muving*

En la aplicación del modelo que busca la localización de estacionamientos para un sistema de micromovilidad, los datos utilizados para representar la demanda provienen de la propia información del uso del sistema. En concreto, se han considerado los puntos geolocalizados del origen y destino de los viajes realizados con las motos eléctricas de la empresa Muving.

Los registros de los viajes fueron recabados por dispositivos GPS integrados en las motos. Estos registros contenían información del uso del sistema, durante los meses de febrero a diciembre 2019, cubriendo, en total, un período de 11 meses. Cada uno de los registros cuenta con los siguientes datos: identificador de cliente, identificador del vehículo, duración del viaje, distancia recorrida, hora de salida, hora de llegada y las coordenadas de origen-destino. En total, la base de datos inicial alcanzaba los 242.000 viajes dentro del área de estudio.

### *3.2.2.3 Registro GPS de sucesos atendidos por SAMUR-PC*

En cuanto al caso del estudio de la ubicación de estaciones para las ambulancias, la localización GPS de los sucesos ocurridos en el área de estudio fue facilitada por las oficinas del SAMUR-PC (Servicio de Asistencia Municipal de Urgencia y Rescate Protección Civil). Este servicio cubre las emergencias sanitarias que ocurren en locales o en la vía pública dentro del municipio de Madrid. Se utilizaron los sucesos de emergencias atendidos en los años 2019 y 2020.

El fichero tiene un formato CSV, que registra datos relativos a la localización del suceso, fecha y hora de la comunicación del suceso y el tipo de suceso. Se hace en grandes grupos por: enfermedad, por accidente de tráfico, por accidente no relacionado con el tráfico, por psiquiátrico, a petición del servicio de bomberos, y miscelánea. El fichero contenía un total de 214.489 sucesos atendidos así 124.619 en el 2019 y 89.870 en el 2020.

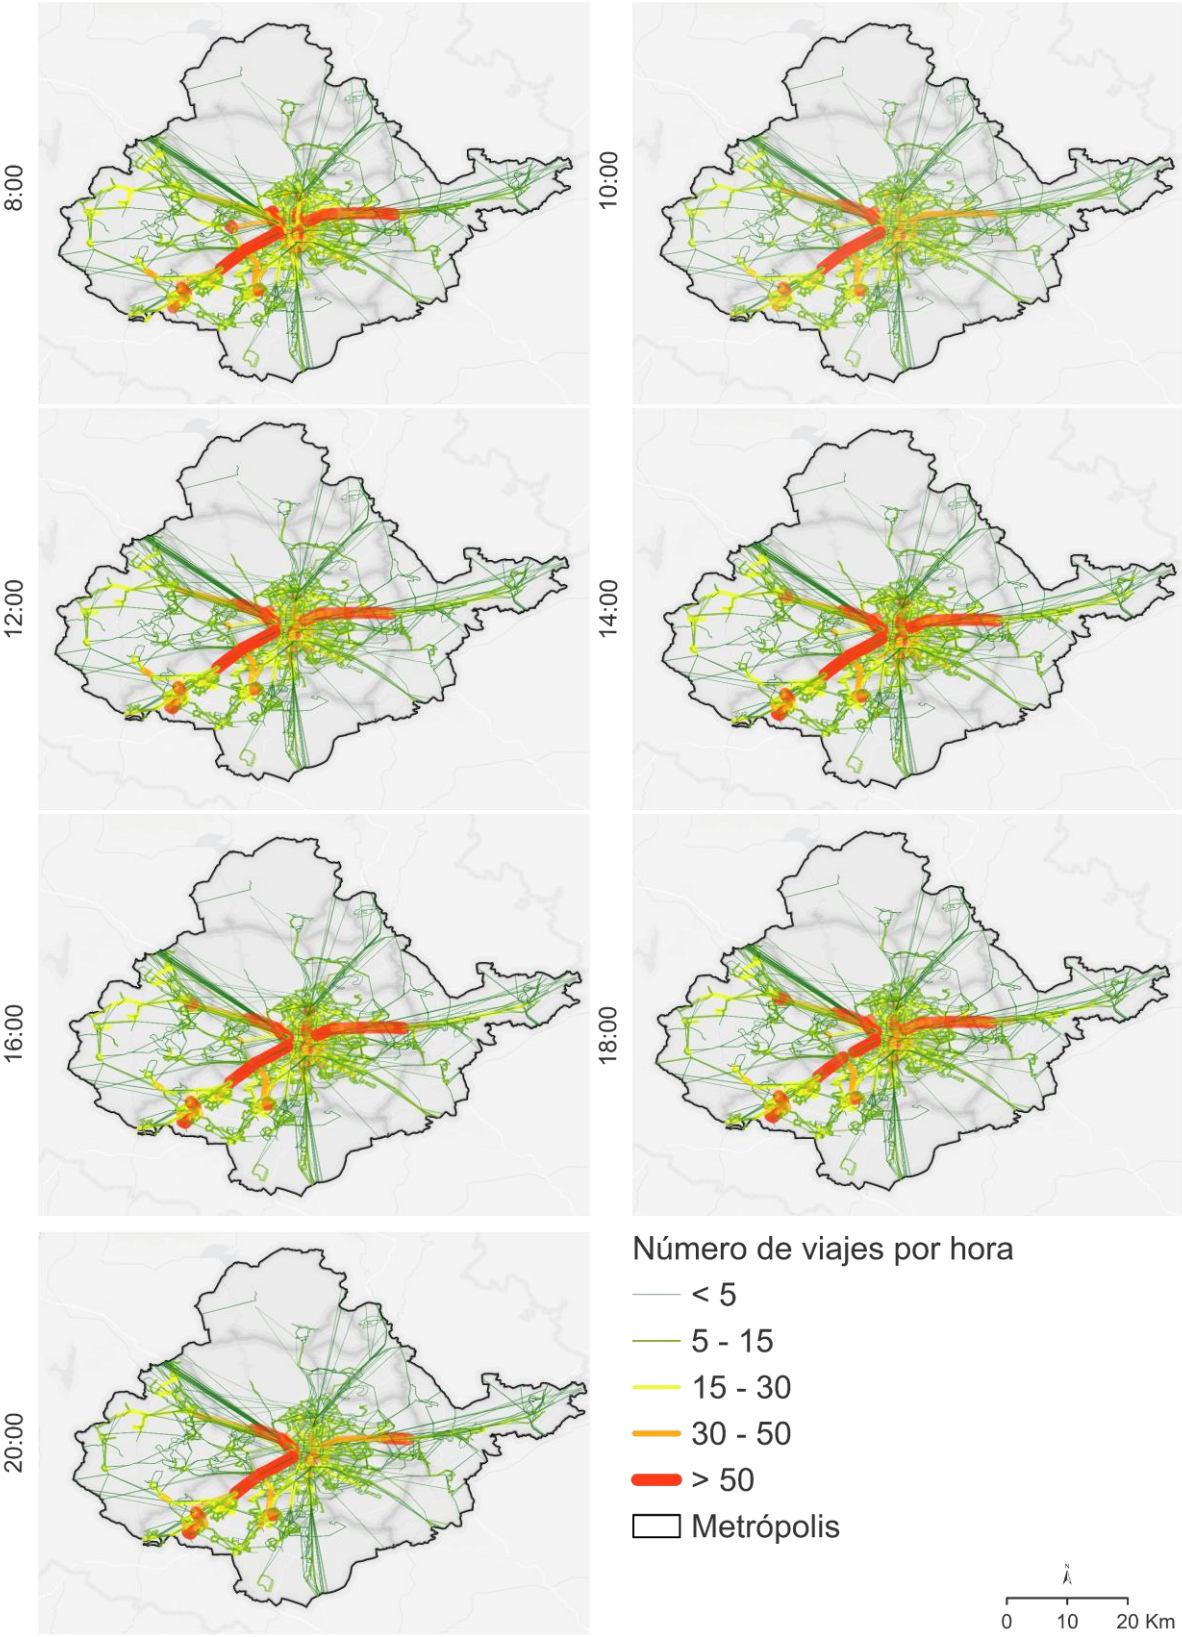
## 3.2.3 Redes de transporte

Se usaron los archivos GTFS para incorporar la componente dinámica a la red de calles descargada, del Centro Nacional de Información Geográfica (<http://centrodedescargas.cnig.es/CentroDescargas/catalogo.do?Serie=CAANE>) en

formato Shapefile. Los ficheros GTFS se obtuvieron del portal de datos del Consorcio Regional de Transportes de Madrid (CRTM). Con dichos datos se construyó la red que permitió simular el desplazamiento de la población en transporte público (Figura 13 y Figura 14). Por otro lado, se utilizaron los perfiles históricos de tráfico (producto *Historical Speed Profiles*) recabados por la empresa TomTom para diseñar la red que simula el desplazamiento en coche privado (Figura 15 y Figura 16).

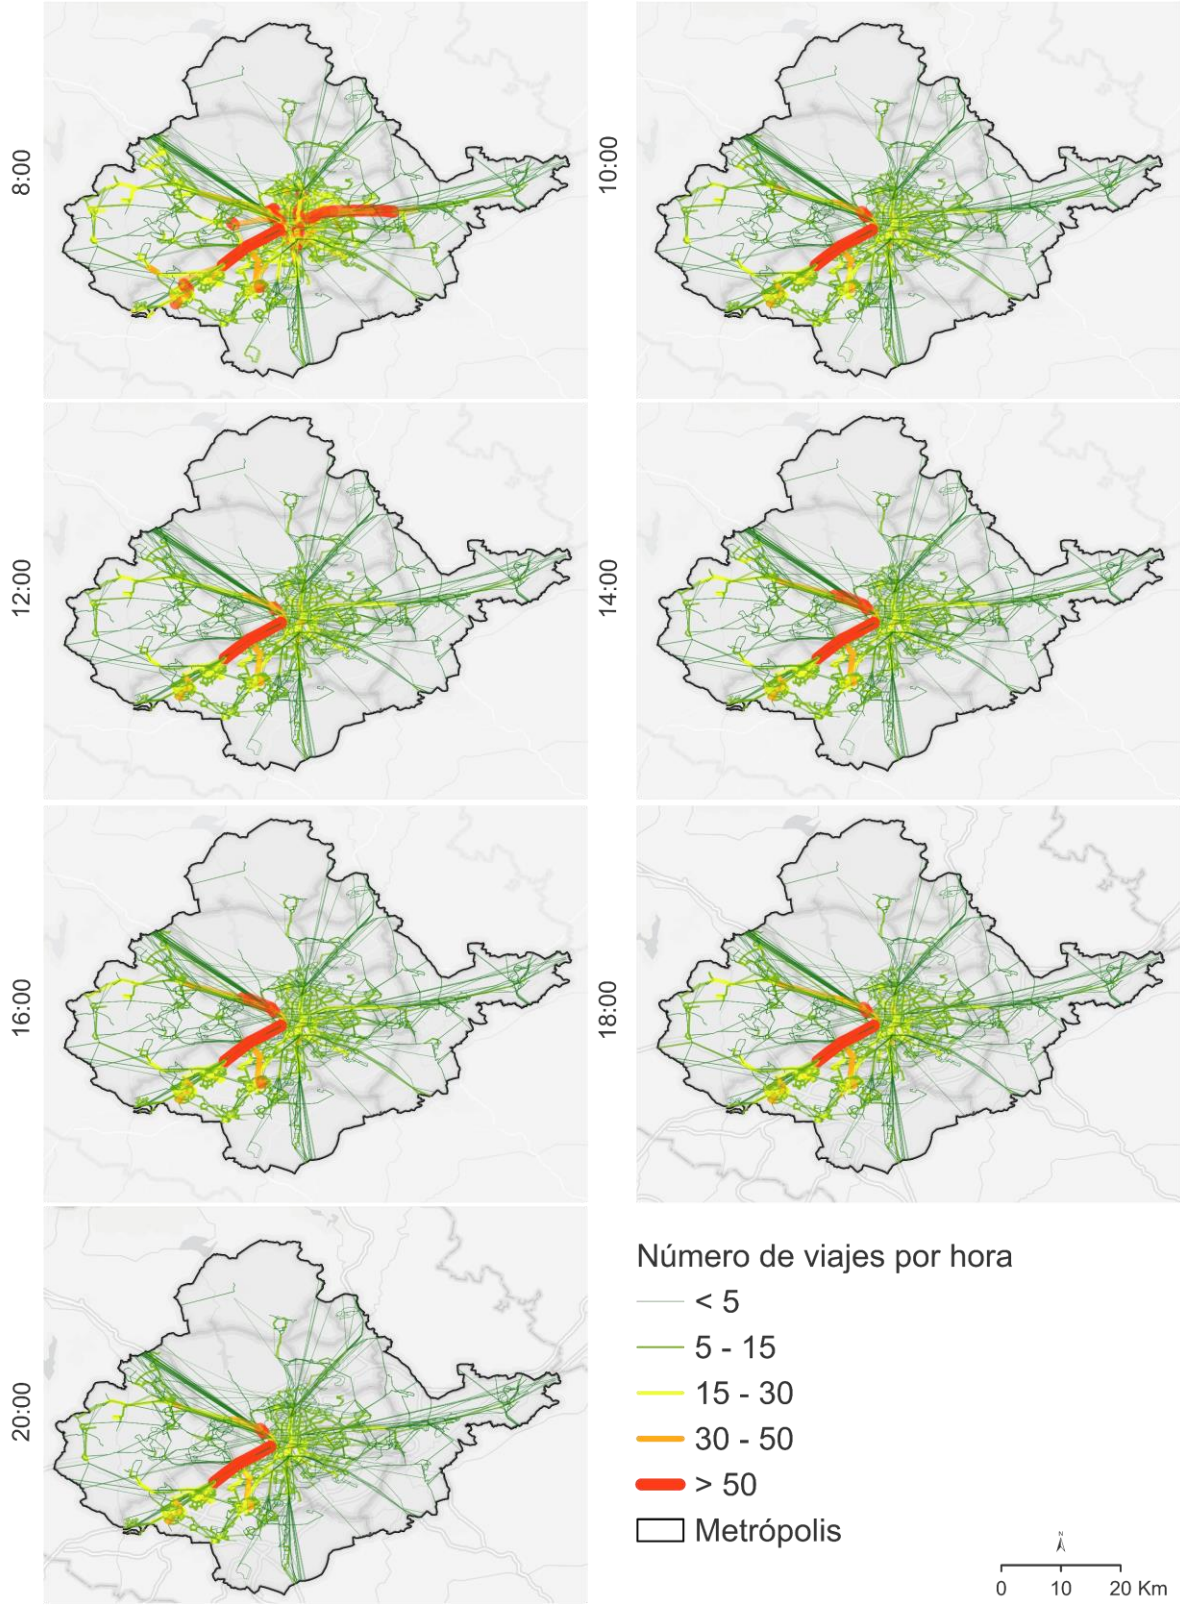
Con ambas redes se ejecutaron los MLA que permitieron analizar los patrones de movilidad de la demanda por días y horas. Por consiguiente, para desarrollar los modelos con red estática se tomó en cuenta el sistema de red vial sin incluirle variables temporales.

Figura 13. Frecuencias de viajes en un día laborable (jueves) en la red GTFS



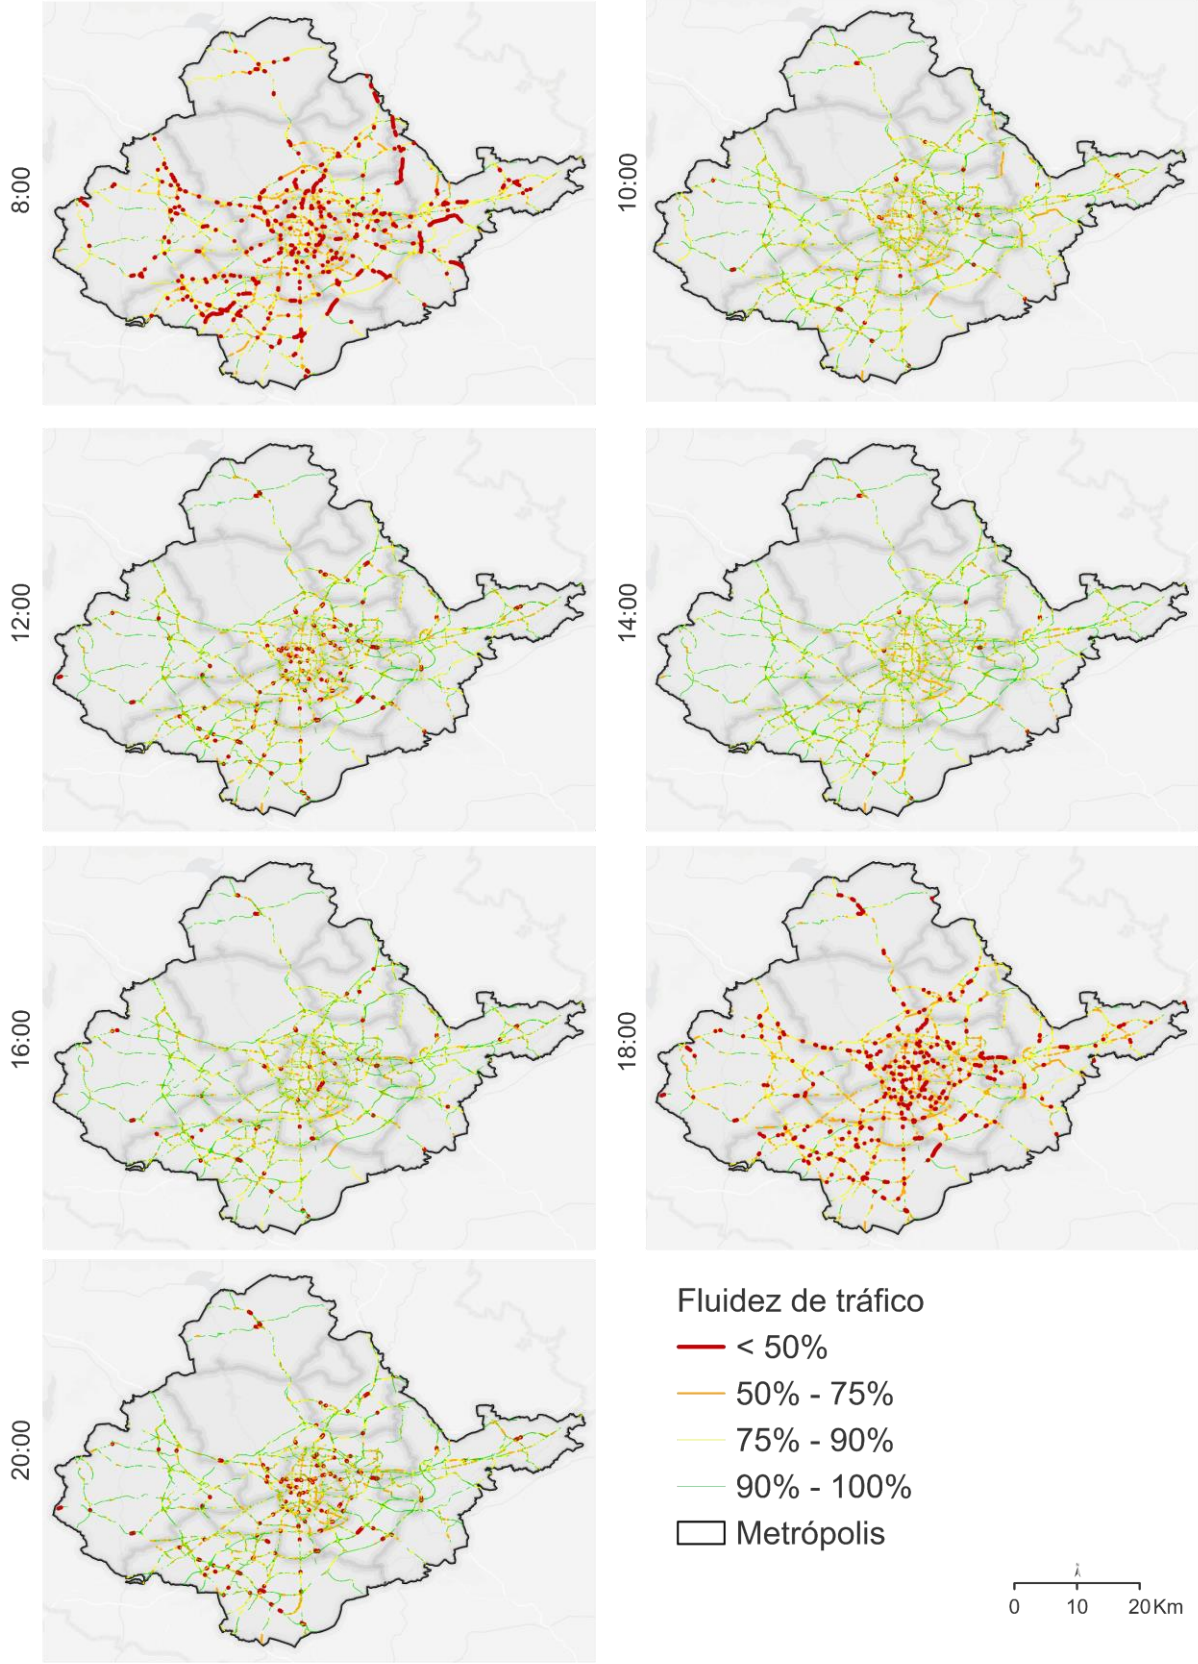
Fuente: Elaboración propia.

Figura 14. Frecuencias de viajes en fin de semana (sábado) en la red GTFS



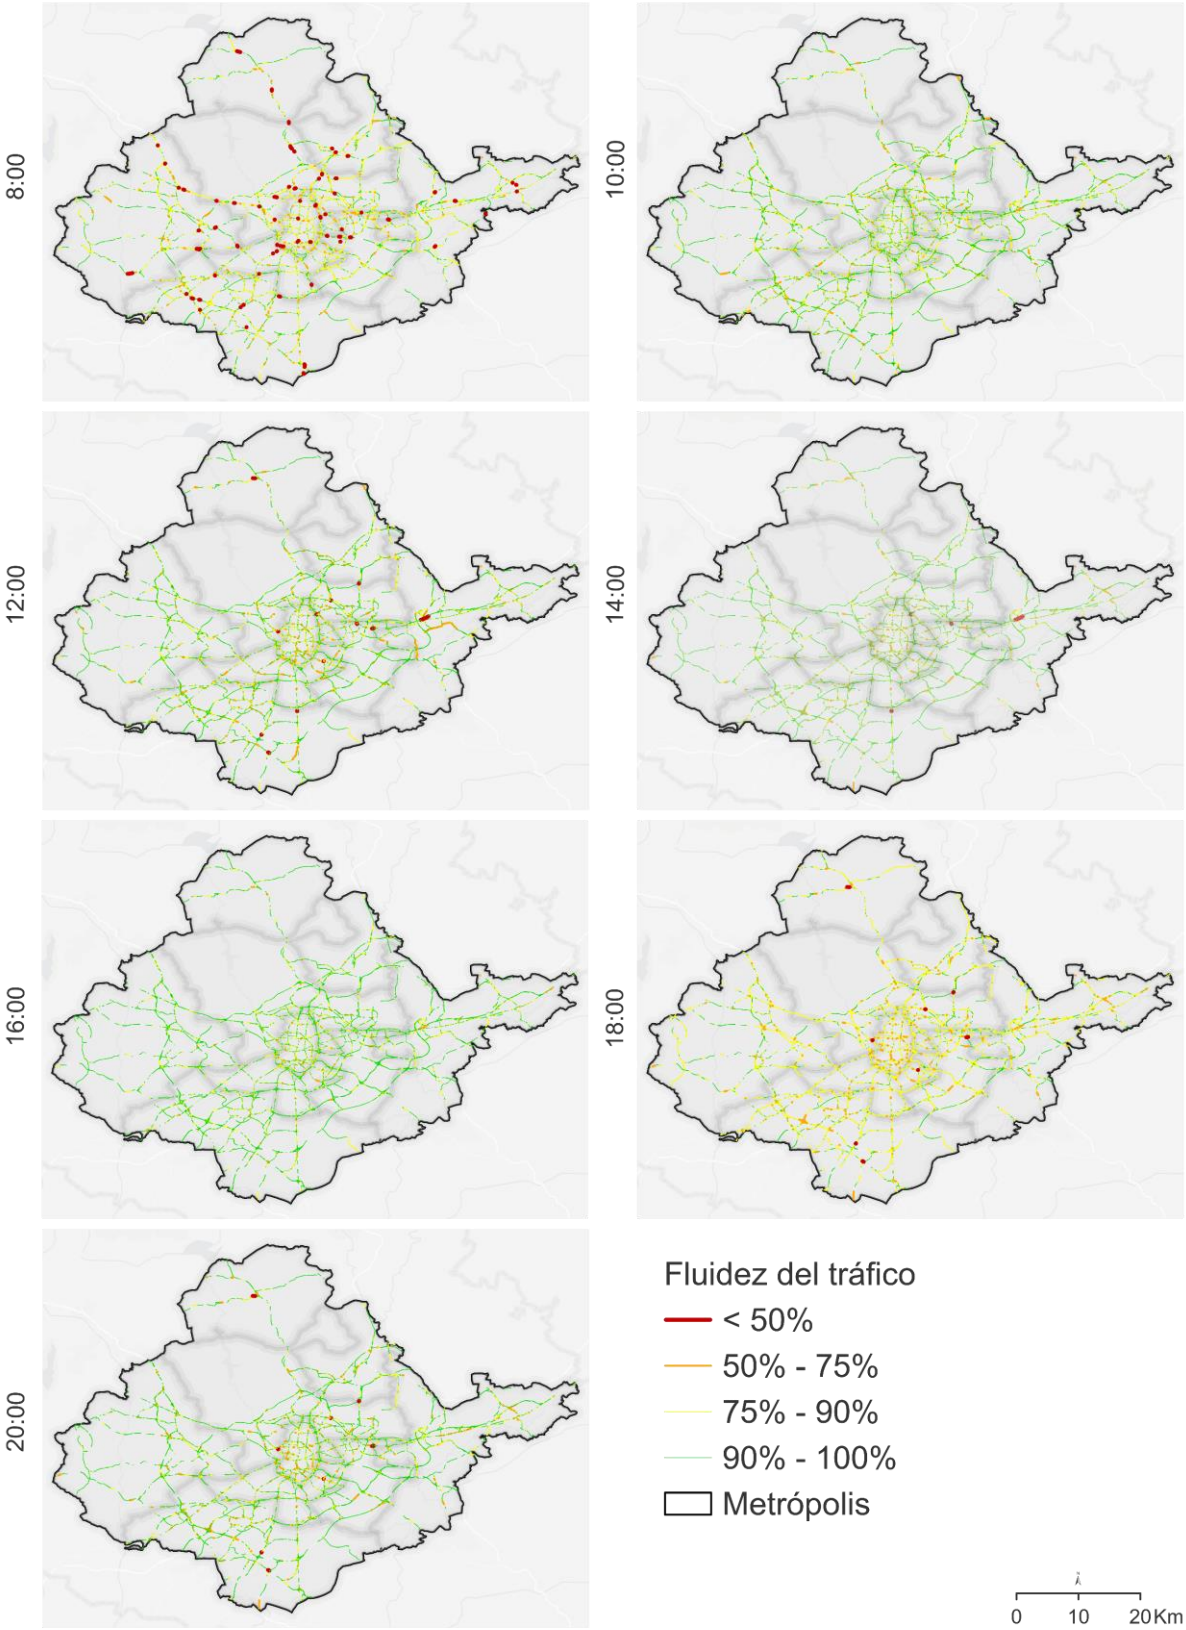
Fuente: elaboración propia

Figura 15. Congestión del tráfico en día laborable (los jueves) según TomTom



Fuente: Elaboración propia

Figura 16. Congestión del tráfico en fin de semana (sábados) según TomTom



Fuente: Elaboración propia.

### 3.3 Metodología

Como hemos visto, en el marco teórico de la tesis, se han efectuado múltiples planteamientos teóricos y prácticos para el desarrollo de MLA, que condujeron a la creación de diversos tipos de soluciones como la maximización de la cobertura y la maximización de la atención en tiempo o distancia a recorrer por la población objetivo. Sin embargo, como hemos visto, la mayoría de los modelos de localización-asignación aplicados hasta ahora, no han tomado en cuenta que existe un dinamismo temporal de los componentes de los modelos. Esto se debe a lo difícil que resultaba obtener datos con un alto nivel de resolución temporal, algo que, afortunadamente, ahora podemos tener gracias a las fuentes de Big Data.

En este sentido, la tesis incorpora el dinamismo en los diferentes datos de entrada requeridos en los MLA. Con la aparición de nuevas fuentes de datos o Big Data, se explora la implementación de MLA en diferentes horas del día, semanas o meses. En cuanto a la demanda nos permite conocer su comportamiento a lo largo del tiempo. Mientras que, en la red de transporte público y privado, nos permite valorar cómo afectan los desplazamientos en autobús y coche privado.

En esta sección se presenta la metodología general seguida en la tesis. En la sección 4 (aplicaciones prácticas) se detallan los pasos para desarrollar los MLA propuestos en este trabajo.

#### 3.3.1 Limpieza y agregación de datos

Por su propia naturaleza, los datos procedentes de Big Data requieren un arduo proceso de limpieza y preparación antes de su utilización en cualquier estudio territorial o de transporte (ver Gutierrez-Puebla et al., 2020; Gutiérrez Puebla et al., 2019). Este proceso implica trabajos como la corrección de datos nulos o la transformación de formatos.

A menudo, los datos nos llegan con errores de captura debido a fallas en los dispositivos que los almacenan. Por ejemplo, los dispositivos GPS pueden perder la receptibilidad de la señal en determinadas condiciones en el lugar donde se encuentra el terminal, provocando que falten valores en los registros. Además, los archivos de Big Data pueden tener, a veces, formatos y estructuras que complican su manipulación en un programa SIG. Así pues, conviene prepararlos para su

manipulación, almacenamiento, análisis y visualización en estos programas. Por lo tanto, es necesaria una etapa inicial de limpieza y preprocesamiento de los diferentes datos utilizados como entrada a los MLA.

### 3.3.1.1 Datos GPS de motos eléctricas compartidas

En el caso de los datos proporcionados por una de las empresas Muving de motos compartidas en Madrid, se realizaron las siguientes tareas previas de limpieza y preparación de los datos. El conjunto de datos iniciales contenía los registros de viajes (242.027) ellos se han depurado para eliminar los datos atípicos (en total 4.995), quedando la base final con 237.062 viajes.

Para esta limpieza de datos atípicos se hizo un análisis estadístico de la distribución de los viajes, según la distancia recorrida. Se usaron gráficos de cajas y bigotes (box-plot) para detectar los registros atípicos. Se eliminaron aquellos datos que son clasificados como atípicos (se encuentran por encima o por debajo de los extremos del gráfico). Estos viajes incluyen aquellos con distancias superiores a las esperadas dada la autonomía de las motos. Así de acuerdo con las características de las motos de Muving y la distribución estadística de los viajes se han eliminado aquellos superiores a 70 km.

Una vez completado el proceso de limpieza, se procede a agregar los datos en celdas de 50x50 metros. Estos datos son divididos a su vez en tres franjas horarias –mañana: de 7:00 a 13:59; tarde: de 14:00 a 18:59 y noche: de 19:00 a 00:00– para estudiar la variación de la demanda. La Tabla 6, resume las estadísticas del conjunto de datos totales y los divide en franjas temporales. Contiene valores referidos al número de celdas y los viajes realizados en cada franja horaria estudiada.

Tabla 6. Estadísticas del conjunto de datos

Datos	Estadísticas
Viajes dentro de área de estudio sin limpiar	242.027
Viajes totales luego de la limpieza	237.062
Viajes por celdas a las (00:00-6:00)	26.231
Viajes por celdas en la mañana (7:00-13:59)	59.442
Viajes por celdas en la tarde (14:00-18:59)	69.592
Viajes por celdas en la noche (19:00-00:00)	81.797
Celdas totales	16.739
Celdas con por lo menos 1 viaje	11.133
Candidatos viajes (celdas > 5 viajes)	7.735

Celdas en la mañana (7:00-13:59)	9.092
Celdas en la tarde (14:00-18:59)	9.250
Celdas en la noche (19:00-00:00)	9.389
Media de viajes totales por celda	21,3
Media de viajes en la mañana por celda	6,5
Media de viajes en la tarde por celda	7,5
Media de viajes en la noche por celda	8,7

Fuente: Elaboración propia.

### 3.3.1.2 Datos GPS de sucesos atendidos por el SAMUR-PC

En el caso de los datos del Servicio de Asistencia Municipal de Urgencias, Rescate y Protección Civil (SAMUR-PC), no ha sido necesaria la depuración, ya que las oficinas de SAMUR-PC nos han facilitado los datos depurados en un fichero Excel. Este archivo fue convertido, con ayuda del programa ArcGIS Pro 2.8, en una capa vectorial de puntos.

A continuación, estos puntos se agregaron en hexágonos de 200 metros, construidos con la herramienta *Generate Tessellation-Hexagon*. Para la agregación de los sucesos, utilizamos la herramienta *Summarize Within* del programa SIG ArcGIS Pro para contar el número de puntos que caen dentro de cada unidad espacial. Posteriormente, dividimos los datos con la ayuda de otras herramientas (*Select Layer By Date And Time* y *Summarize Within*) en tres franjas horarias (09:00-17:59, 18:00-00:00, 00:00-08:59) que nos permitieron analizar el número de sucesos ocurridos a lo largo del día, durante los días laborables y los fines de semana de 2019 y 2020.

El área de estudio está cubierta por 5.821 hexágonos, pero de ellos, solo 2.821 tenían información sobre sucesos. La Tabla 7 muestra el número de hexágonos que disponían de datos en las diferentes franjas horarias analizadas durante los días laborables y los fines de semana. En el apartado 4.3.3.2 (Tabla 37 - Tabla 38) se presentan las estadísticas descriptivas de este conjunto de datos para el año 2019 y 2020.

Tabla 7. Cantidad de hexágonos con sucesos recogidos por el SAMUR totales y por franjas temporales

Datos	Cantidades
Hexágonos totales en el área de estudio	5.821
Hexágonos en el área de estudio con sucesos	2.810
Sucesos en toda el área 2019-2020	214.489

Media de sucesos de sucesos 2019-2020	76,3
Hexágonos con sucesos 2019	2.625
Hexágonos con sucesos 2020	2.546
Día laborable	
Hexágonos 09:00-17:59 (2019)	2.309
Hexágonos 09:00-17:59 (2020)	2.194
Hexágonos 18:00-00:00 (2019)	2.051
Hexágonos 18:00-00:00 (2020)	2.011
Hexágonos 00:00-08:59 (2019)	1.812
Hexágonos 00:00-08:59 (2020)	1.637
Fin de semana	
Hexágonos 09:00-17:59 (2019)	1.948
Hexágonos 09:00-17:59 (2020)	1.754
Hexágonos 18:00-00:00 (2019)	1.669
Hexágonos 18:00-00:00 (2020)	1.592
Hexágonos 00:00-08:59 (2019)	1.403
Hexágonos 00:00-08:59 (2020)	1.270

Fuente: Elaboración propia.

### 3.3.2 Construcción de las redes digitales de transporte

Para incluir el dinamismo en las redes utilizadas hemos empleado archivos GTFS y datos de TomTom. Las características de ambas redes las describimos con más detalle a continuación.

#### 3.3.2.1 Ficheros GTFS

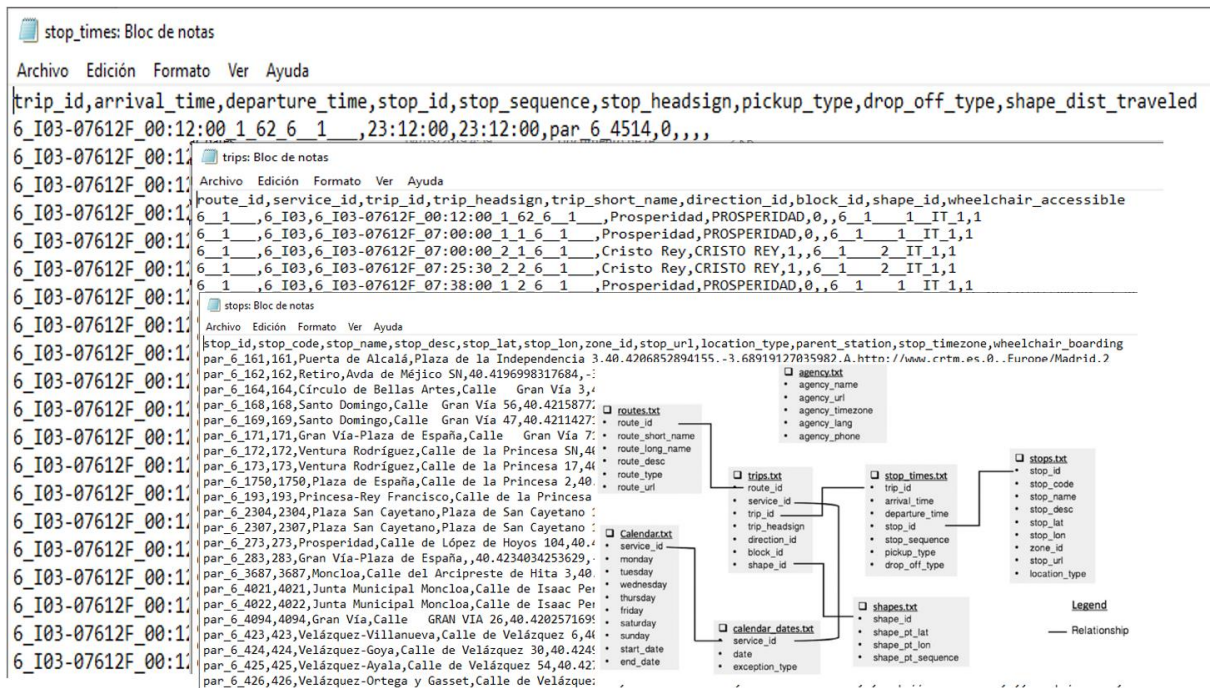
Para el diseño de los MLA que incorporaban dinamismo, en la red de transporte público se utilizaron los archivos GTFS (General Transit Feed Specification) descargados de la página del Consorcio Regional de Transportes de Madrid. Los datos descargados cubren desde el 25/09/2017 hasta el 25/09/2018.

Los archivos, en formato de texto (.txt), contienen información relativa a las frecuencias, horarios, fechas, rutas, horas de llegada y salida, tiempo de viaje y calendario del servicio de transporte público en Madrid. En ellos se incluye el servicio ofrecido por la EMT (Empresa Metropolitana de Transporte), Metro, trenes de Cercanías y autobuses interurbanos. La Figura 17 muestra la estructura de tablas que conforman el GTFS utilizado.

Para la construcción de la red se utilizó, además de los ficheros GTFS, la red de carreteras de la Comunidad de Madrid descargada del Centro Nacional de Información

Geográfica de España,<sup>10</sup> el día 7 de octubre del 2019. El entramado vial se compone de 292.834 arcos. Contiene atributos como: tipo de vía, nombre, clase, tipo de tramo, sentido, número de carriles, entre otros.

Figura 17. Estructura de las tablas del fichero GTFS utilizado



Fuente: Consorcio Regional de Transportes de Madrid.

Con los datos descargados, se construyó la red de transporte público empleando las herramientas *DisplayGTFS*, *AddGTFS* y *Network Analyst* del programa *ArcMap* 10.6 de la casa comercial ESRI (Environmental Systems Research Institute). La Figura 18 explica los procedimientos seguidos para elaborar la red usando las herramientas mencionadas.

Una vez construida la red de transporte público se ejecutaron los modelos de localización-asignación para evaluar el efecto de los cambios en las frecuencias del transporte público sobre la demanda cubierta por los hospitales y centros comerciales de Madrid.

<sup>10</sup> <http://centrodedescargas.cnig.es/CentroDescargas/catalogo.do?Serie=CAANE>

Figura 18. Herramientas utilizadas para construir la red GTFS

**Herramienta**

Display GTFS in ArcGIS

Use Display GTFS in ArcGIS to visualize your GTFS stops and route shapes in ArcMap.

The *Display GTFS Stops* tool makes a feature class of stops using information from the GTFS stops.txt file.

Crear una clase de entidad en una geodatabase

Cargar los ficheros GTFS para que se almacenen en la clase de entidad creada

**Herramienta**

Add GTFS to a Network Dataset

Use Add GTFS to a Network Dataset to incorporate transit data into a network dataset so you can perform schedule aware analyses using the Network Analyst tools in ArcMap.

After creating your network dataset, you can use the ArcGIS

Generar las líneas de las rutas y paradas

Generar conectores de las paradas a las calles

Creación del Network dataset

Source	Connectivity Policy	1	2	3
LineVariantElements	End Point	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>
StopConnectors	End Point	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>
Streets	Any Vertex	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
Stops	Honor	<input type="checkbox"/>	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>
StopsOnStreets	Override	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	<input type="checkbox"/>

A partir de este paso se configuran los parámetros deseados en la red por ejemplo: Restricciones, impedancias en tiempo de viaje, giros en u, por mencionar algunos.

Fuente: Elaboración propia

### 3.3.2.2 Datos de tráfico de la empresa TomTom

La información, sobre los aspectos relacionados con el tráfico, se obtuvo a partir de los datos recogidos por los receptores de navegación, por satélite, de la empresa TomTom®. Esta empresa proporciona dos valiosos productos que se utilizaron en la tesis.

En primer lugar, el producto MultiNet® proporciona la geometría y los atributos de distintos elementos del territorio en diferentes zonas geográficas, incluidas las redes de transporte. Este producto contiene 50 atributos que definen cada uno de los arcos de la red. Ejemplos de algunos de ellos son el ID de los arcos, el FEATTYP (indica si el arco corresponde a un *ferry* o a una ruta apta para vehículos), METROS (longitud de los arcos), FRC (indica el tipo de vía que es), KPH (velocidad media por arco), MINUTOS (tiempo de viaje calculado dividiendo el campo METROS por KPH), entre otros.

En segundo lugar, el producto *Historical Speed Profile*® (HSP) proporciona datos sobre las velocidades medias de la red de carreteras. Las velocidades están agregadas en períodos de tiempo de 5 minutos para cada día de la semana, en aquellos arcos con suficientes observaciones y en caso contrario un valor medio según tipo de día. A partir de estos atributos, se adjuntan perfiles de velocidad a los diferentes arcos de la red. La Tabla 8 muestra algunas de las principales características del producto *Historical Speed Profile*. Con esta información podemos incluir situaciones de congestión en la red utilizada en los MLA.

Tabla 8. Atributos y descripción del producto *Historical Speed Profile*

Atributo	Descripción
<i>NETWORK_ID</i>	Campo ID de la Feature Class de geometrías de la red
<i>VAL_DIR</i>	Sentido del arco para el que es válido los datos del registro
<i>SPFREEFLOW</i>	Velocidad observada en situaciones de flujo libre en km/h.
<i>SPWEEKDAY</i>	Velocidad media observada en los días laborables en km/h.
<i>SPWEEKEND</i>	Velocidad media observada en km/h en los días de la semana
<i>PROFILE_1</i> , <i>PROFILE_2...</i> <i>PROFILE_7</i>	Número del perfil de velocidad para los días de la semana

Fuente: Empresa TomTom.

Sobre la base de los dos productos gestionados por TomTom (MultiNet® e Historical Speed Profile), se construye la red de transporte privado que se usa para calcular los MLA con un componente dinámico durante el día. Entre los parámetros establecidos están las conexiones de arcos a través de los end points, giros prohibidos, sentidos de circulación y la jerarquía de cada tramo.

Como impedancias se definen las siguientes:

- Tiempo medio de viaje (tiempos con velocidades medias),
- kilómetros (longitud de los arcos de red),
- Minutos (tiempos obtenidos con las velocidades calculadas en el producto MultiNet),
- TravelTime (variación de la velocidad de los arcos).

Una vez construidas la red de transporte público y la red de transporte privado se ejecutaron los modelos de localización-asignación, utilizando el módulo Location-Allocation, de Network Analyst para encontrar la ubicación óptima de los hospitales y centros comerciales. Al mismo tiempo se evaluó el efecto de las variaciones en las condiciones de la red sobre la cobertura de la demanda de estos servicios. Para ello, se examinaron los cambios en las condiciones de tráfico del transporte privado y las frecuencias del transporte público durante el día.

Por otra parte, en uno de los modelos de localización-asignación (estaciones SAMUR-PC), solo se empleó la red TomTom para simular la congestión en diferentes franjas horarias. Se consideraron situaciones de tráfico en los periodos 09:00-17:59, 18:00-00:00 y 00:00-08:59. Los procedimientos seguidos para el desarrollo de este MLA se explican con más detalle en la sección 4.3.2.

### 3.3.3 Modelos de localización dinámicos en entornos *SIG*

El interés principal de esta tesis radica en incorporar variables dinámicas a los modelos de localización-asignación que incluye el programa de sistemas de información geográfica ArcGIS Pro 2.8. Se trata de la extensión del análisis de las redes y su módulo Location-Allocation.

De las soluciones que ofrece el módulo, se han utilizado prácticamente todas las propuestas en el software: maximizar la cobertura, maximizar la asistencia, maximizar la cuota de mercado compartido y maximizar la cuota de mercado objetivo. Estas

soluciones se han considerado en función de los objetivos de cada una de las aplicaciones desarrolladas en este trabajo.

Dentro de cada caso de estudio, se incorporó el dinamismo de los diferentes datos de entrada de los modelos. Por ejemplo, en el análisis para la evaluación y localización óptima de hospitales y centros comerciales, se simularon los desplazamientos de la red en transporte público y privado en distintos momentos. Para el análisis de las plazas de aparcamiento de motocicletas y las bases del SAMUR-PC, se incluyó la movilidad de la demanda, gracias al campo de fecha y hora contenido en el conjunto de datos. Además, se probó con el desplazamiento de los puntos de oferta y el uso de redes estáticas. La justificación de cambiar los distintos parámetros (demanda y red de transporte) en cada una de las aplicaciones prácticas de los modelos de localización-asignación para realizar el análisis dinámico, obedece a la disponibilidad y a las facilidades que ofreció cada conjunto de datos utilizados. Además, variar la dinámica en la red o en la demanda y dejar fija una de ellas permite evaluar los efectos de una u otra o de las dos combinadas sobre la cantidad de demanda asignada a los servicios estudiados en esta tesis.

Por ejemplo, se eligieron los hospitales como caso de estudio porque son servicios sanitarios muy utilizados por la población y existe un interés por analizar el impacto de los cambios en las frecuencias del transporte público y de la congestión provocada por el transporte privado sobre la población atendida por estos servicios sanitarios. Además, este tipo de modelos pueden ser de utilidad a la hora de decidir la localización de los centros hospitalarios o clínicos, la dotación de personal y equipos médicos y la asignación de los pacientes a los centros sanitarios.

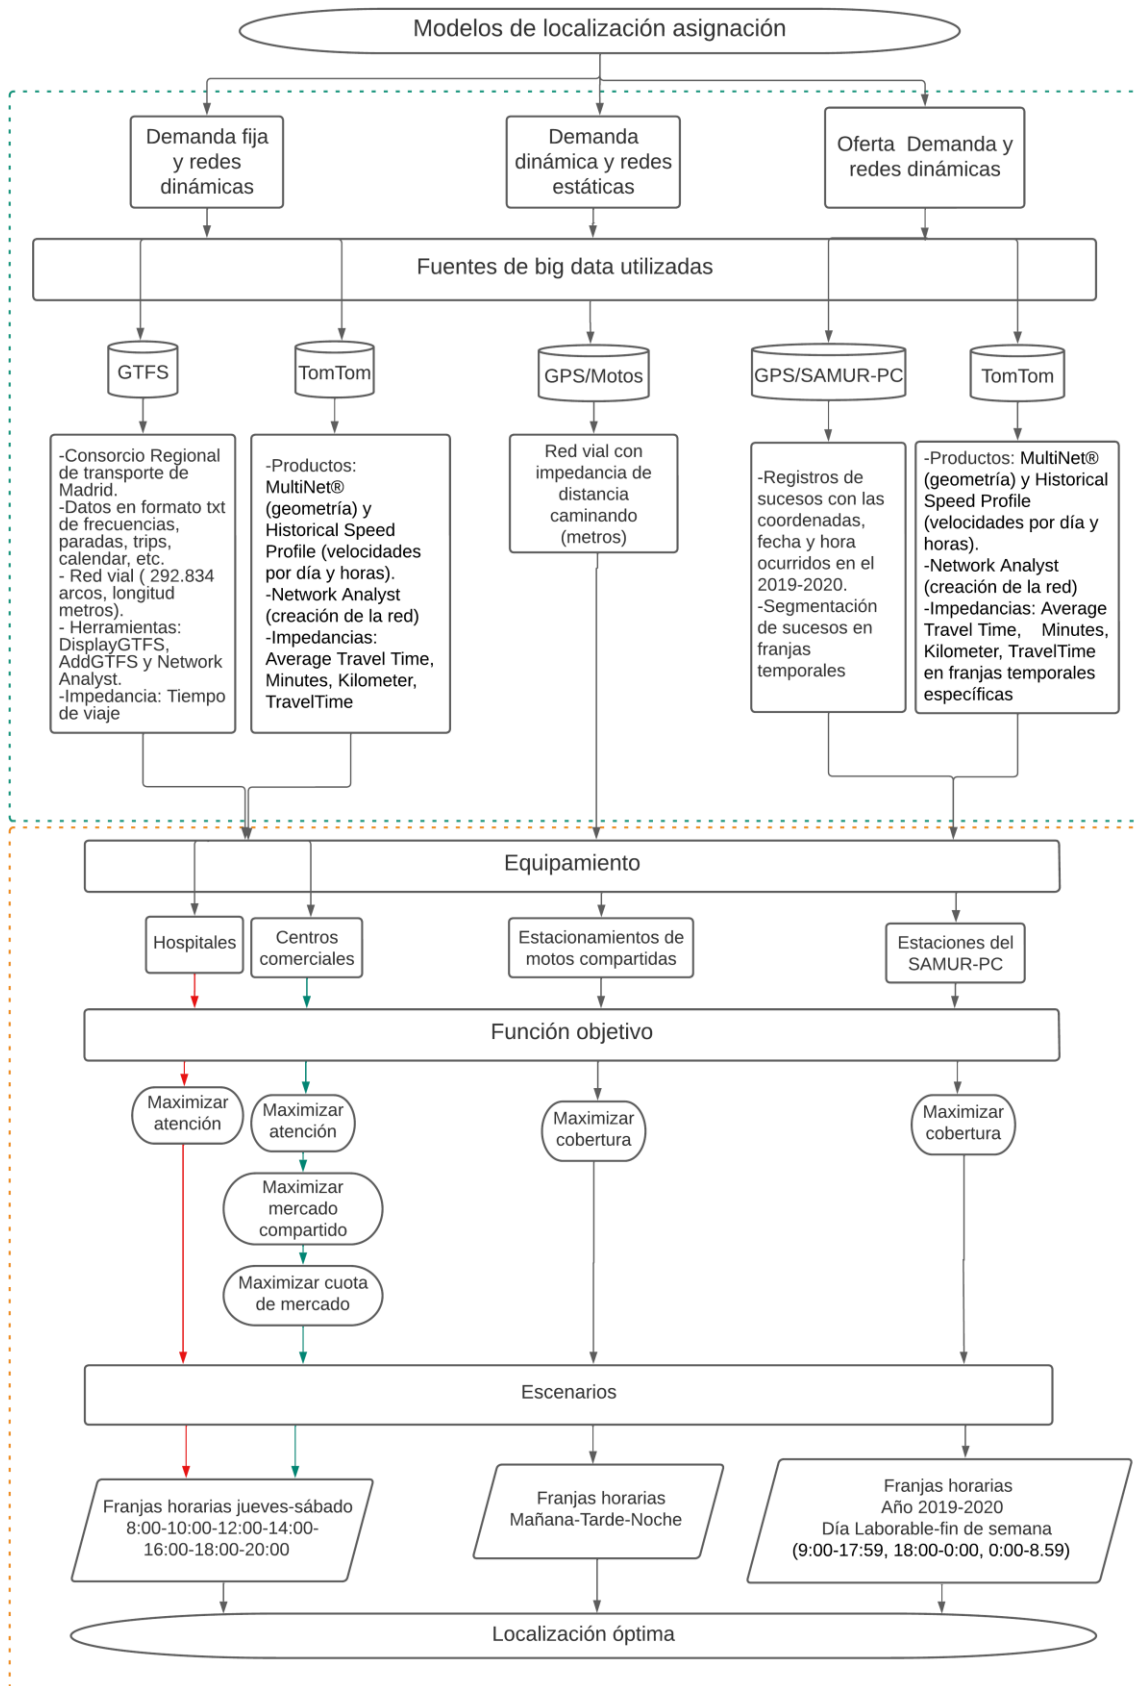
En lo referente al modelo de localización-asignación con centros comerciales, la decisión de elegir este servicio se debe a que dentro del programa SIG existen soluciones orientadas a equipamientos donde entra en juego un entorno de competencia por el mercado. También, porque estas instalaciones comerciales atraen un alto flujo de usuarios que hacen uso del servicio de transporte público o de la red de calles, para llegar hasta ellos. El análisis del dinamismo de la red puede resultar de utilidad para los administradores de este tipo de negocios, permitiéndoles identificar patrones de congestión y comportamiento de los usuarios en diferentes horas del día.

En lo que respecta al caso de los aparcamientos de motos, la impedancia en la red fue la distancia caminando, por lo cual no se requerían variables de congestión en la red de calles, mientras que con los datos GPS que contienen los registros de los viajes realizados por los usuarios se pudo agregar variables temporales gracias a que este conjunto de datos cuenta con la hora y día en que se realiza el viaje. Además, se elige desarrollar este MLA con las motos eléctricas compartidas, debido a la problemática que ha originado este tipo de servicio de micromovilidad en las ciudades en materia de estacionamiento.

Por otro lado, se elige al caso para encontrar lugares donde ubicar las estaciones de ambulancias, incluyendo el dinamismo en dos de los parámetros (demanda y red), ya que el tipo de servicio y los datos obtenidos lo permitía. Al utilizar los datos de TomTom que cuentan con información sobre el tráfico histórico y los registros GPS de los sucesos atendidos por el servicio de emergencias pueden ayudar a planificar las rutas de las ambulancias y mejorar el tiempo de respuesta en los lugares donde se requiera prestar los primeros auxilios. Además, los MLA con este tipo de servicio puede ayudar a identificar sitios donde la cobertura es ineficiente, optimizando de esta manera la gestión de los recursos.

En la Figura 19 se presenta la aplicación de los MLA a los distintos casos de estudio, identificando desde las fuentes usadas a las soluciones implementadas.

Figura 19. Metodología general de los diversos modelos desarrollados



Fuente. Elaboración propia.

### 3.3.4 Análisis y visualización de los datos

Una de las etapas trascendentales, en una investigación, de carácter territorial, es la visualización de los resultados y para ello se contó con el uso de programas de Sistemas de Información Geográfica, entre ellos, el software ArcGIS Pro 2.8 de la casa comercial de ESRI.

Las herramientas Display GTFS y Add GTFS to Network Dataset permiten gestionar los datos GTFS. La primera, ayuda a convertir los datos de los archivos GTFS, routes.txt y shapes.txt, en una clase de entidad que puede mostrarse en ArcGIS, permitiéndole ver sus líneas de tránsito en un mapa. En el caso de la herramienta Add GTFS to Network Dataset (Añadir GTFS a un conjunto de datos de red), permite añadir archivos GTFS a un conjunto de datos de la red de carreteras y así poder realizar análisis con las herramientas de Network Analyst.

En particular, la herramienta Network Analyst se utiliza para crear el Network Dataset. Dentro del paquete de herramientas de Network Analyst, en esta tesis, empleamos, específicamente, el módulo Location-Allocation especializado en los modelos de localización-asignación.

Para visualizar los resultados obtenidos con el uso de los ficheros GTFS en los modelos de localización-asignación, se usa el programa ArcGIS Pro 2.8 y Excel. Con el primero, se confeccionan los mapas de arañas y símbolos proporcionales. Con el segundo, se diseñan las gráficas y cuadros que resumen los resultados.

Por otro lado, para la creación de la red a partir de los datos de TomTom también se ha utilizado la herramienta Network Analyst, que permite configurar los diferentes parámetros e impedancias establecidos en la red que simula los desplazamientos en coche bajo condiciones de congestión. Además, se aprovecha el módulo de localización-asignación y algunas de las soluciones disponibles en él para la localización de hospitales, centros comerciales y puestos de ambulancia.

En el caso de los MLA con los hospitales y centros comerciales, los resultados se visualizan con las herramientas cartográficas disponibles en el programa SIG ArcGIS Pro 2.8. Con ellas se producen mapas de símbolos proporcionales que muestran la demanda cubierta por los servicios hospitalarios y los centros comerciales. Además, con el programa Excel se resumen los resultados y se elaboran los diferentes gráficos.

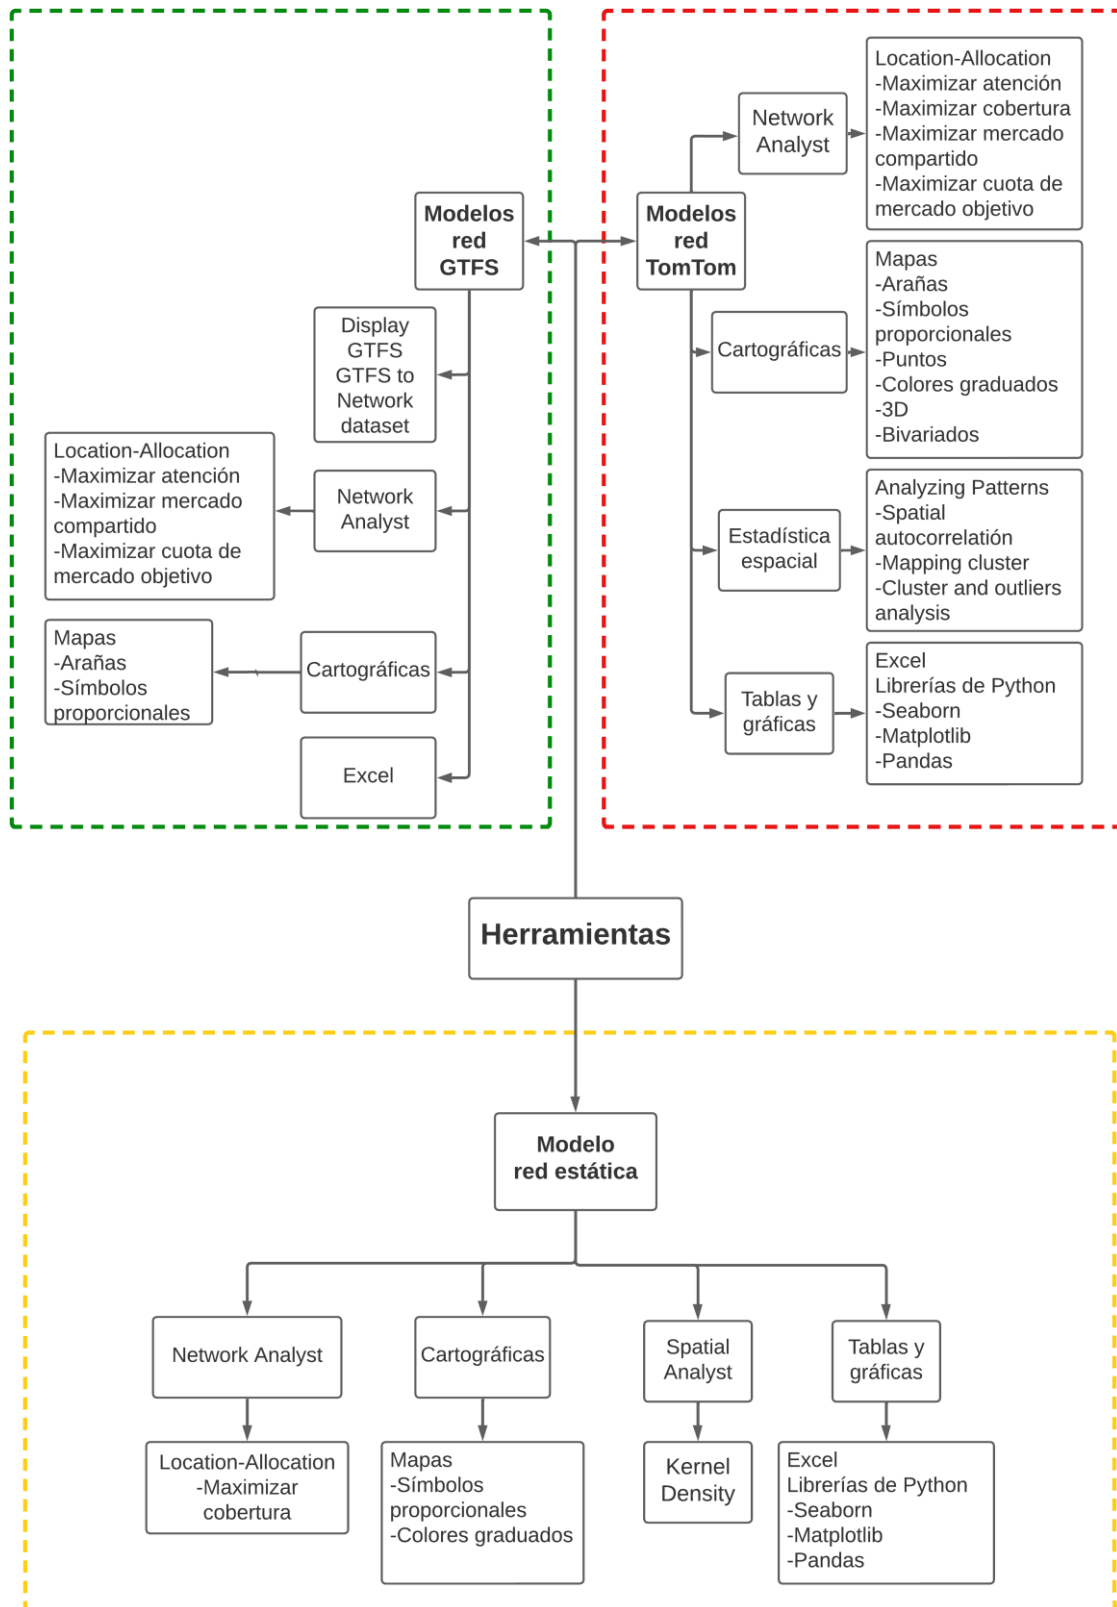
Para visualizar los datos y los resultados obtenidos con el MLA que busca la mejor ubicación de las estaciones de ambulancia, teniendo en cuenta la congestión (red TomTom), se utilizan las herramientas de estadística espacial y de cartografía disponibles en ArcGIS Pro 2.8. En el caso de las herramientas de estadística espacial se utiliza Analyzing Patterns (análisis de patrones espaciales), especialmente la herramienta Spatial Autocorrelation (Global Moran's I). También se ha utilizado la herramienta Mapping Cluster, en particular el Cluster and Outlier Analysis (Anselin Local Moran's I).

En cuanto a las herramientas cartográficas, se han elegido mapas de símbolos proporcionales, puntos, colores graduados, mapas 3D, mapas bivariados, mapas de araña y mapas gráficos. Estos mapas representan la demanda cubierta y la distribución de los datos GPS recogidos por el SAMUR-PC.

Además, en este modelo de localización de ambulancias, se utilizaron programas como Excel y Jupyter Notebook (librerías de Python: Matplotlib, Pandas, Seaborn). El programa Excel se usó para resumir los resultados en forma de tabla. Mientras que las librerías de Python mencionadas, anteriormente, se aprovecharon para el diseño de los gráficos.

En el caso del MLA con redes estáticas (aparcamientos de motocicletas), también se utilizan las herramientas de análisis de redes (módulo de localización-asignación), en concreto, la solución maximizar cobertura. Para visualizar los datos y resultados de este modelo, se ocupa la extensión Spatial Analyst (Kernel density) de ArcGIS Pro 2.8 para representar la distribución de la demanda potencial del servicio. Mientras que, la cartografía de los resultados se realiza con los mapas de símbolos proporcionales y colores graduados. Al igual que con el modelo de ambulancias, Excel y las librerías de Python (Seaborn, Matplotlib) permitieron presentar los resultados mediante tablas y gráficos. La Figura 20 resume las herramientas empleadas en el conjunto de la tesis.

Figura 20. Herramientas utilizadas en el desarrollo de la tesis



Fuente: Elaboración propia

# **4 APLICACIONES PRÁCTICAS**

Definida la metodología y los datos a utilizar, se implementaron MLA donde se ensayaron diversos escenarios y se incorporó el dinamismo en la oferta, en la demanda y otros en la red. Es decir, se combinan posibles alternativas entre fuentes dinámicas y estáticas, ya sea en la red, en la oferta o en la demanda para analizar el efecto de estas en los resultados de los modelos.

#### **4.1 Modelos con demanda fija en el tiempo y redes dinámicas de transporte público y privado: aplicaciones a la localización de servicios sanitarios y equipamientos comerciales**

Se proponen modelos que buscan evaluar la situación de acceso a los hospitales del Municipio de Madrid y a los centros comerciales ubicados dentro del área metropolitana de Madrid. Para su realización se incorporó el dinamismo en el nivel de servicio que ofrece la red de transporte público, construida a partir de los archivos GTFS y la red de transporte privado. En este caso, como consecuencia de la congestión a lo largo del día, se utilizó una red elaborada con información proporcionada por los archivos de tráfico de la empresa TomTom.

Los modelos de localización-asignación se desarrollaron para dos tipos de servicios: hospitales (diferenciando los hospitales de referencia de las áreas de salud y el resto de los hospitales) y centros comerciales. Con estos modelos se plantean dos objetivos. En primer lugar, proponer MLA incorporando el dinamismo en el funcionamiento, tanto de la red de carreteras como del transporte público, para evaluar el impacto en la cobertura de la demanda asignada a los hospitales, a los hospitales de referencia y a los centros comerciales. En segundo lugar, analizar la ubicación óptima de un nuevo servicio (hospital y centro comercial) tomando en cuenta el comportamiento de la red de transporte público y privado durante el día.

Para ello se toman, como sitios candidatos, la localización actual de cada uno de los servicios analizados. Mientras que la demanda la obtuvimos a partir de los centroides de las secciones censales. Se evaluó la asignación de la población (demanda) considerando la variación de las frecuencias del servicio de transporte público y la congestión de las calles.

Además, se investigó si algún punto de demanda (centroide de sección censal) cambia su asignación de centro hospitalario o centro comercial como resultado de los

cambios en el funcionamiento de las redes. También se compara la asignación de la demanda obtenida en los resultados de los modelos con la demanda asignada en la actualidad a las áreas de referencia sanitaria en que está dividido Madrid.

#### 4.1.1 Análisis de la asignación de la demanda a hospitales y hospitales de referencia

Los hospitales son uno de los servicios esenciales para la atención de la población. En efecto, la elección del lugar donde se ubican los hospitales es un aspecto esencial que se plantea en todas las ciudades y la asignación de la población a estos centros se incluye entre las cuestiones de optimización más importantes que se deben tomar en cuenta en la gestión urbanística (Kaveh et al., 2020).

Las instalaciones médicas como: hospitales, centros de salud, clínicas y puestos de salud, en general, deben responder a los principios de equidad espacial si se considera que la salud es un derecho al que toda la ciudadanía debe tener igual acceso. En este sentido, la localización y distribución adecuada de los establecimientos de salud desempeñan un papel de vital importancia (Ledesma & Zurita, 1995). Por lo tanto, una ubicación de los servicios sanitarios sin planificación, puede incidir en una mala accesibilidad espacial y en mayores costes de las instalaciones (Beheshtifar & Alimoahmmadi, 2015).

Tomando en cuenta lo anterior, los MLA permiten evaluar la asignación de la población a los centros sanitarios y encontrar ubicaciones óptimas para ellos. Como hemos visto a lo largo de la tesis, los MLA permiten la selección simultánea de un conjunto de emplazamientos para los centros y la asignación de las demandas repartidas entre los establecimientos para optimizar algún criterio específico y medible (Rahman & Smith, 2000). Como expresan Buzai & Baxandale (1995), los modelos de localización-asignación intentan que los centros de servicios se ubiquen de acuerdo con la disposición de la demanda y facilitan soluciones para que la distribución espacial sea más eficiente y equitativa. En este sentido, recurren a la localización óptima y a determinar las mejores alternativas de conexión. Daskin & Dean (2004) plantean que los MLA incorporados en los *SIG* a menudo funcionan como herramienta de apoyo en la toma de decisiones para la ubicación de instalaciones sanitarias.

En la literatura científica abundan los trabajos que han utilizado MLA para la localización de instalaciones hospitalarias. Para el desarrollo de esta investigación nos interesan aquellos trabajos que implementan MLA en entornos *SIG*. En este sentido,

la revisión analiza, en primer lugar, las diferentes soluciones que ofrecen los MLA para ubicar y distribuir los equipamientos sanitarios, entre ellas están: maximizar cobertura, minimizar instalaciones y maximizar la asistencia. En segundo lugar, revisamos aquellos estudios que incluyen algunas fuentes de *Big Data* en los elementos de los modelos (oferta, demanda o red).

Es interesante la aportación de Rahman & Smith (2000), que describe una recopilación de los tipos de soluciones aplicadas a la búsqueda de la localización óptima de los hospitales, presentando un análisis detallado de los objetivos que persigue cada modelo. Una de las soluciones más habituales para la ubicación de las instalaciones hospitalarias es la solución de maximizar la cobertura. Esta solución, presentada en un principio por Church & ReVelle (1974) es una de las más empleadas en la planificación de la sanidad pública debido a las limitaciones presupuestarias. La función objetivo busca maximizar la cobertura de la población a partir de un número limitado de equipamientos fijos (Shariff et al., 2012).

Otras investigaciones determinan la eficiencia de la distribución espacial de los servicios sanitarios, para ello utilizan los centroides de las secciones censales a fin de obtener las localizaciones de la demanda (Abdelkarim, 2019). En la misma línea, Polo et al. (2015), proponen la planificación de los equipamientos públicos a partir de MLA y modelos de accesibilidad. Para ello, recurren a las escuelas, las iglesias y los centros médicos como candidatos. En otra investigación se emplean en conjunto modelos de localización-asignación y de accesibilidad. Los cuales son aplicados a hospitales, farmacias y bomberos (El Karim & Awawdeh, 2020).

También los investigadores han recurrido a la solución p-mediana o minimización de la impedancia en los MLA de hospitales. Es decir que, para una distancia determinada, el modelo de minimización de la impedancia reduce al mínimo la distancia total ponderada por la demanda de viaje o el tiempo de acceso a un centro hospitalario (Mishra et al., 2019). Un ejemplo es el trabajo de Huotari et al. (2020), donde proponen varios escenarios para evaluar el impacto potencial en la accesibilidad de los hospitales en el caso de reducir el número de estos. En su estudio, aprovechan la ubicación de los hospitales actuales y una malla ráster de distribución de la población descargada de <https://www.worldpop.org.uk/>.

Por su parte, Clemence et al. (2020) plantean un modelo donde se aplica la solución de maximizar la asistencia para encontrar farmacias y centros de salud, para ello eligen como demanda los datos de población de las secciones censales.

El otro aspecto que nos interesa abordar se refiere a las investigaciones que utilizaron alguna fuente de *Big Data* en sus planteamientos para obtener la oferta, la demanda o el dinamismo de la red de transporte. En el caso de la oferta y la demanda, la mayoría de los trabajos utilizan datos hospitalarios y censales. Cabe resaltar que, al momento de la revisión de la literatura, se encontraron pocos trabajos que utilizan modelos de localización-asignación que incorporen Big Data para representar la oferta y la demanda.

Con respecto a la red de transporte, el trabajo de Kotavaara (2018), utiliza archivos GTFS para la construcción de la red e incorpora información de frecuencia del transporte público. En particular, no se han encontrado trabajos que integren el tráfico histórico en la red de transporte a partir de datos de TomTom o de otras redes. Esta investigación pone de manifiesto la posibilidad de introducir la dimensión temporal en las velocidades de la red, utilizado en las variables del MLA para lograr una más adecuada aproximación a la realidad y mejorar la medición de la equidad en el acceso a los hospitales.

Para concluir este apartado, la Tabla 9 resume algunos estudios que emplean MLA aplicados para encontrar la mejor ubicación de hospitales, donde se presentan los autores, el objetivo del artículo, la metodología y los datos utilizados.

Tabla 9. Modelos de localización aplicados a hospitales

Autor	Objetivo	Datos	Solución	Entorno
(Polo et al., 2015)	Proponer una estrategia integral para ayudar a la planificación espacial de los servicios de salud pública y para facilitar la accesibilidad de la población a las diferentes intervenciones de salud pública.	Candidatos: escuelas, iglesias, parques, centros médicos públicos	Maximizar cobertura y minimizar impedancia	GIS
(Ledesma & Zurita, 1995)	Demostrar si la actual localización de hospitales públicos en la Provincia del Chaco -Argentina-responde al criterio de justicia espacial. Saber cuál es la localización	Demanda: Centroides de áreas de salud. Candidatos: Los hospitales	Maximizar cobertura	GIS

	más apropiada para nuevos equipamientos hospitalarios manteniendo fijos los actuales establecimientos.			
(Amato et al., 2021)	Determinar cuál de los 14 hospitales comunitarios existentes en Vermont debe ser actualizado para que sea un centro de traumatismos para optimizar el acceso de la población a la atención traumatológica.	Reportes de incidentes, Centros hospitalarios red,	Maximizar cobertura	GIS
(Rahman & Smith, 2000)	Examinar la idoneidad de los MLA para el diseño de sistemas sanitarios y su relevancia para los problemas generales producidos en los países en desarrollo.		Review	
(Beheshtifar & Alimoahmadi, 2015)	Aplicar un modelo multiobjetivo que combinaba el análisis del sistema de información geográfica (SIG) con un algoritmo genético multiobjetivo.	Centroides de parcelas y las clínicas actuales	p-mediano maximizar cobertura	Algoritmos genéticos
(Shariff et al., 2012)	Examinar el porcentaje de cobertura de las instalaciones existentes dentro de la distancia permitida especificada/objetivada por el gobierno de Malasia.	Hospitales y centroides	Maximizar cobertura	Algoritmos genéticos
(Zhu et al., 2016)	Presentar un modelo jerárquico de asignación de ubicaciones para los centros de traumatismos de bajo y alto nivel en Shenzhen.	Registro de sucesos Hospitales	Maximizar cobertura p-mediano	Ant colony optimización
(Ngowi & William, 2020)	Determinar la accesibilidad a los centros de salud en las zonas suburbanas más desfavorecidas con respecto a las instalaciones sanitarias periurbanas de la ciudad de Mbeya, mostrando la distribución geográfica de los centros de salud y proponer las ubicaciones óptimas donde deberían construirse los próximos centros de salud.	Secciones censales centros de salud	Maximizar cobertura	GIS
(Fuenzalida & Moreno, 2010)	Proponer la localización óptima de hospitales en Valparaíso	Hospitales y centroides de celdas de 1km	Maximizar cobertura	GIS
(Vora et al., 2015)	Analizar la disponibilidad actual de estos servicios en tres distritos de Gujarat e identificar las mejores ubicaciones para los centros de servicios adicionales con el fin de optimizar el acceso a los servicios gratuitos de	Secciones censales centros de salud número de camas	Maximizar cobertura	GIS

	cesárea utilizando la tecnología del Sistema de Información Geográfica.			
(Kotavaara, 2018)	Encontrar nuevos lugares óptimos para los servicios de atención primaria de salud teniendo en cuenta los posibles viajes en transporte público, además de los viajes en automóvil.	Archivos GTFS Centros de salud, población	P-mediano	GIS
(Abdelkarim, 2019)	Determinar la eficiencia de la distribución espacial de los servicios de salud y su compatibilidad con la distribución de los distritos residenciales en Al-Madinah Al-Munawwarah.	Demanda=Secciones censales red de calles Oferta servicios de salud	Maximizar cobertura	GIS
(Pu et al., 2020)	Proponer un enfoque sistemático para mejorar la accesibilidad espacial de los servicios sanitarios mediante la identificación de las ubicaciones óptimas para las nuevas instalaciones sanitarias.	The gridded population 100 m from worldpop calles OMS land use and land cover	Maximizar cobertura	Algoritmos genéticos
(Huotari et al., 2020)	Emplear un conjunto de métodos de localización-asignación para evaluar el impacto potencial sobre la accesibilidad, en caso de que el número de hospitales de maternidad se reduzca de 22 a 16.	Hospitales celdas de población	P-mediano	GIS

Fuente: Elaboración propia.

En nuestra propuesta se pretende aprovechar dos fuentes nuevas de *datos* para incorporar dinamismo en la elaboración de la red. Así, la red que permite simular el movimiento de la población en el transporte público se crea a partir de ficheros GTFS, que contienen todos los detalles de horarios, frecuencias, paradas y fechas de los viajes. Otra de las fuentes utilizadas son los perfiles históricos de tráfico de TomTom. Con ellos se diseñó la red de carreteras para recrear el grado de congestión de las calles durante las diferentes horas del día. En consecuencia, este MLA tiene doble propósito. En primer lugar, plantear modelos de localización-asignación incorporando el dinamismo en el funcionamiento tanto de la red de carreteras como del transporte público, para evaluar el impacto en la cobertura de la demanda de los hospitales actuales de Madrid, producto de los cambios en las frecuencias del transporte público y la congestión en el transporte privado. En segundo lugar, analizar la ubicación

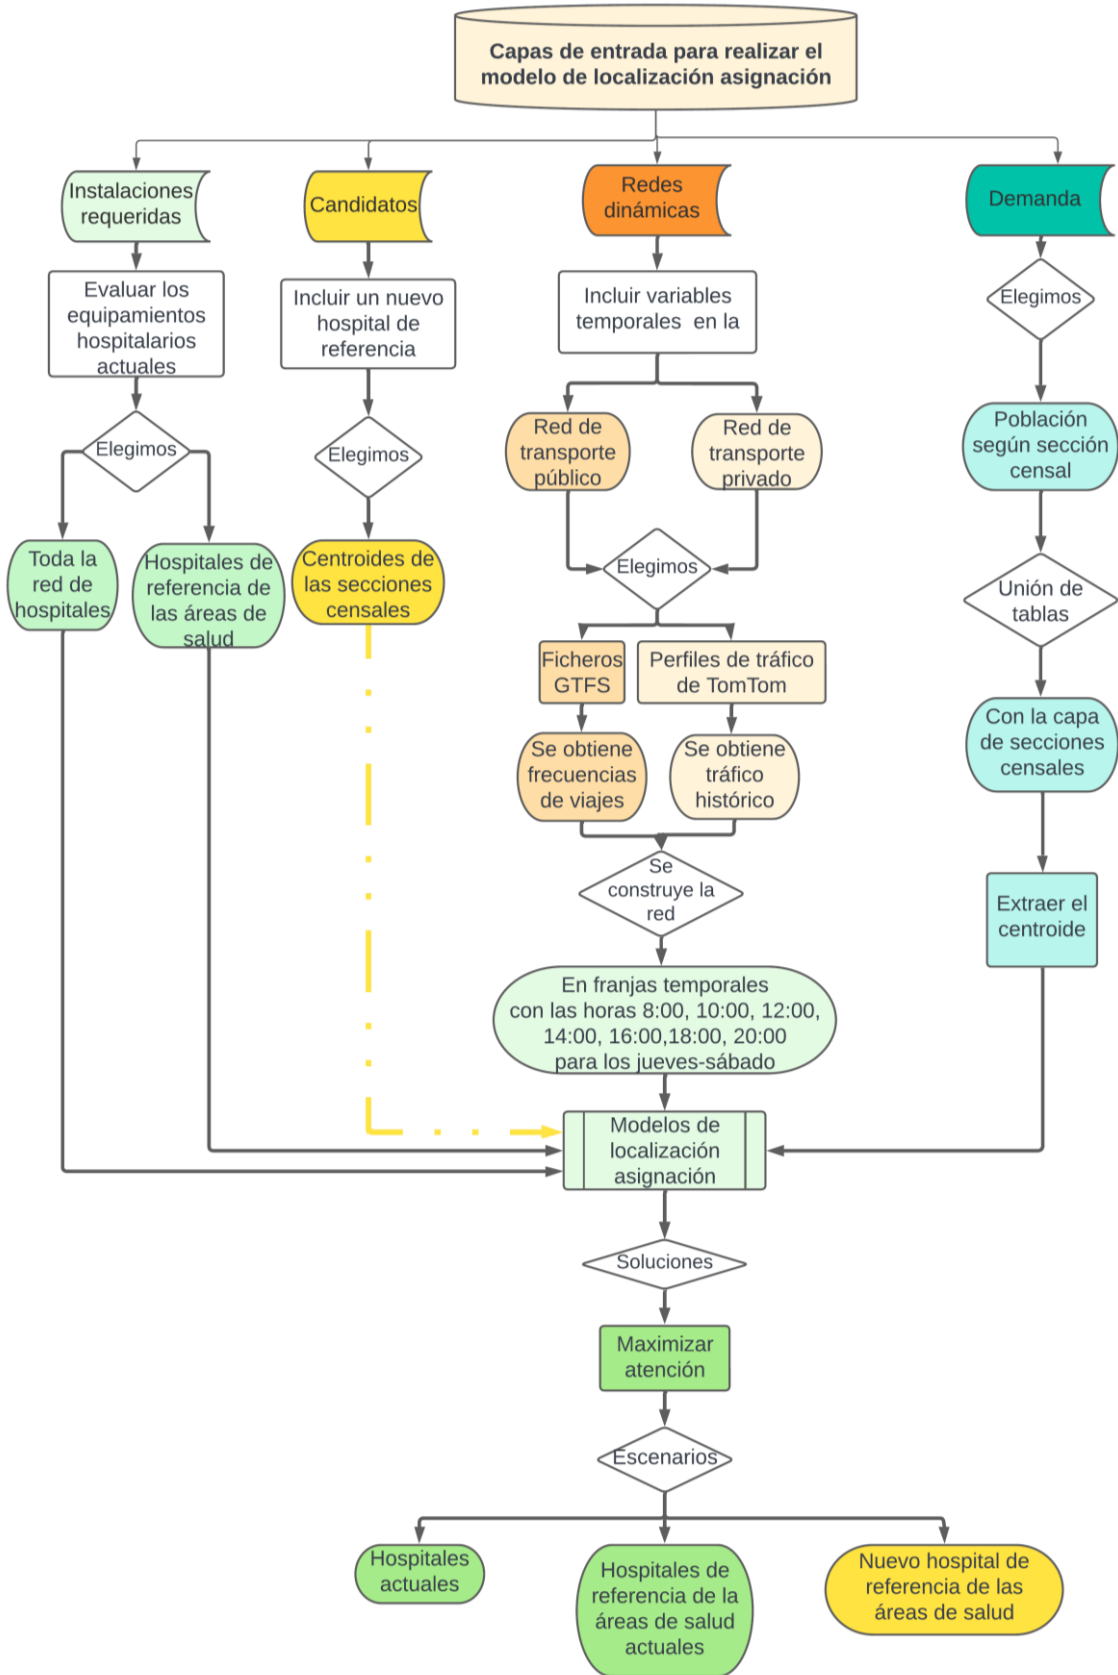
óptima de un nuevo hospital, considerando el comportamiento durante el día de la red del transporte público y privado.

#### 4.1.2 Metodología utilizada para el desarrollo del modelo de hospitales y hospitales de referencia

Los modelos con redes dinámicas y demanda estática se aplicaron a los hospitales públicos y a los hospitales específicos de las áreas de salud. Se tomaron en cuenta tres etapas para realizar el planteamiento de los modelos de localización. En primer lugar, se requiere tener sitios candidatos y sitios que representen la demanda. Luego, para lograr la conectividad de estos sitios se necesitó la creación de una red. Por último, se implementó una de las soluciones que ofrece el programa ArcMap 10.6.

Para el cálculo de la asignación óptima de la población a los hospitales y a los hospitales de referencia a las áreas de salud y la búsqueda de nuevas localizaciones se utiliza la solución maximizar asistencia. En primer lugar, aplicamos la solución maximizar asistencia a toda la red de hospitales y luego a los hospitales de referencia. Por último, utilizamos la solución maximizar asistencia para encontrar la mejor localización de un nuevo hospital de referencia de las áreas de salud (Figura 21).

Figura 21. Metodología para el desarrollo del modelo de hospitales y hospitales de referencia



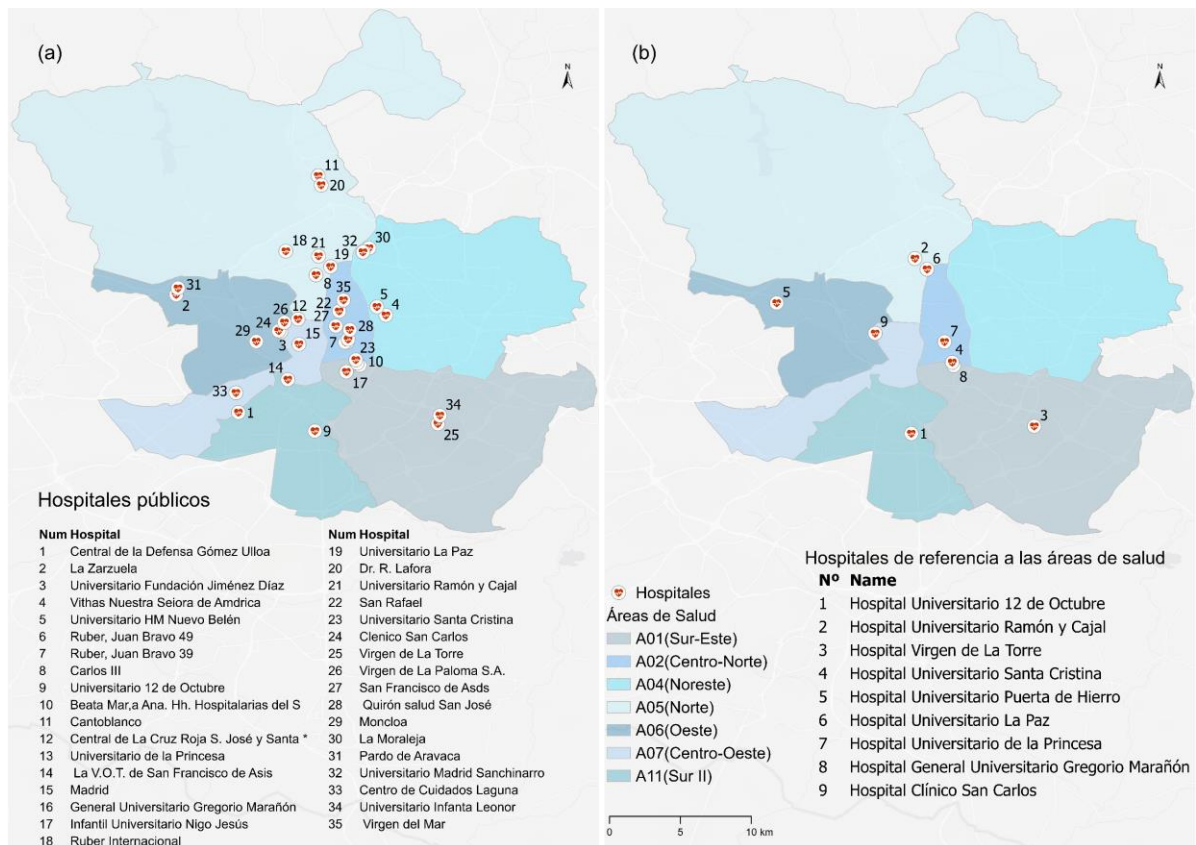
Fuente: Elaboración propia.

#### 4.1.2.1 Selección de candidatos y población a asignar

Se eligió la red de hospitales públicos como sitios candidatos obligatorios para la ejecución del modelo de localización-asignación (Figura 22a). Además, se realizó un modelo utilizando como candidatos los hospitales asignados a las áreas de salud que ofrecen el servicio médico a los habitantes del municipio de Madrid (Figura 22b).

A efectos de la gestión de la sanidad, la Comunidad de Madrid se organiza en áreas de salud. Se trata del área geográfica de zonificación sanitaria que agrupa los recursos de atención primaria y especializada, tomando en cuenta factores geográficos, culturales, epidemiológicos y las infraestructuras existentes. Las áreas están conformadas por la agregación de varios distritos sanitarios.

Figura 22. Hospitales públicos, hospitales de referencia y áreas de salud



Nota: (a) Red de hospitales públicos (b) Hospitales de referencia a las áreas de salud.

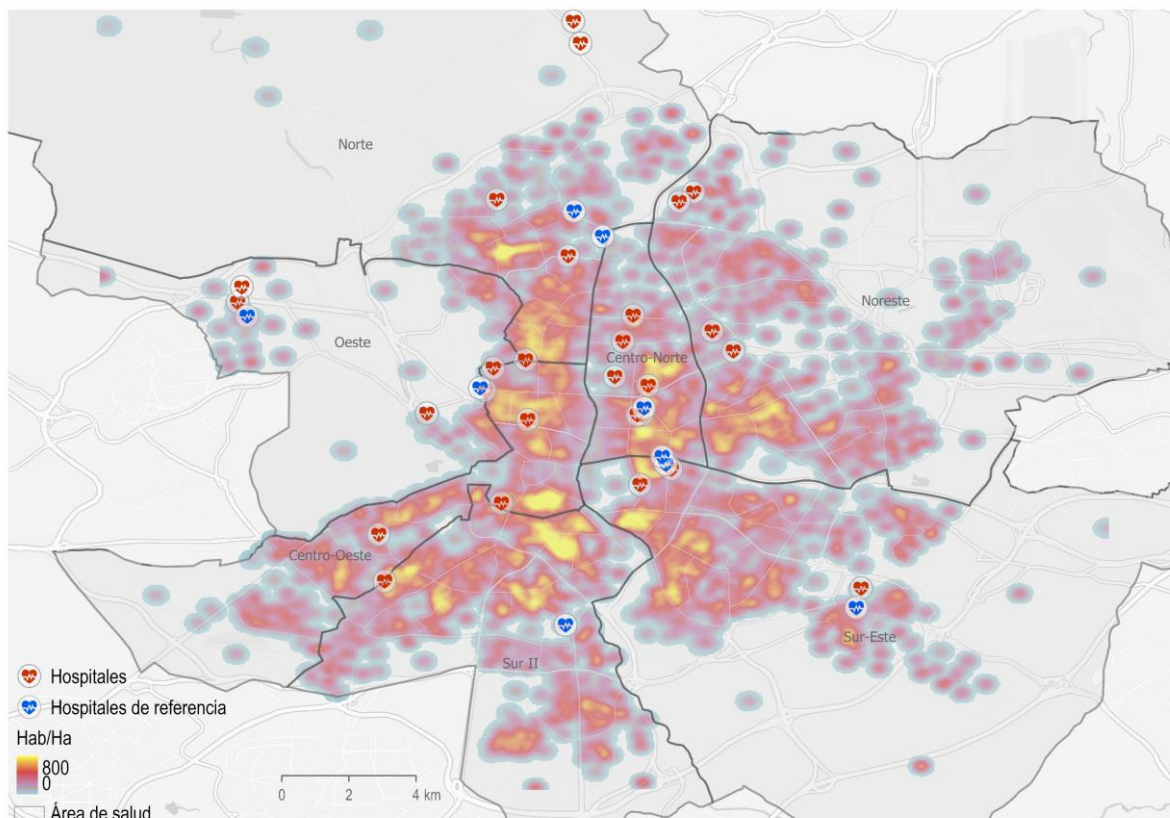
Fuente: Elaboración propia.

Por otro lado, los puntos de demanda se tomaron a partir de los centroides de las secciones censales, las cuales contienen un campo que incluye la población, que se utilizó para ponderar la cantidad de habitantes que cubrirá cada hospital. Además, se

ejecutó un modelo de localización-asignación que incluye un nuevo hospital de referencia, utilizando los hospitales de referencia de las áreas de salud actuales como puntos requeridos, mientras que los candidatos para la localización del nuevo centro se obtienen de los centroides de las secciones censales.

La Figura 23 muestra los hospitales y los puntos de calor donde se concentra la demanda que será asignada a los mismos. El color amarillo representa las zonas con densidades de población más altas. Se evidencia una concentración de la población en la zona central del área estudiada. Marcando valores altos las áreas de salud: Centro-Norte, Sur II y Centro-Oeste.

Figura 23. Localización de hospitales y densidad de población a partir de los centroides de secciones censales



Fuente: Elaboración propia.

#### 4.1.2.2 Redes de carreteras para el transporte público y privado

Para incorporar el dinamismo en el funcionamiento de las redes, se construyeron dos redes que simulan el desplazamiento de la población en transporte público y en transporte privado. La red de transporte público se confeccionó a partir de los datos

GTFS. Estos ficheros contienen información relacionada a las frecuencias de viajes, tiempo, calendario del servicio de bus urbano (EMT), metro, cercanías y autobuses interurbanos. Para construir la red se emplearon las herramientas DisplayGTFS y Network Analyst del programa ArcMap 10.6, de la casa comercial ESRI (Environmental Systems Research Institute). Como atributo de impedancia se estableció el tiempo de viaje en transporte público.

Por otro lado, la red que simula el desplazamiento en transporte privado se diseñó con la extensión Network Analyst, utilizando los datos de la empresa TomTom, específicamente, el producto perfiles de velocidad, donde registra el tiempo promedio de los viajes efectuados por los usuarios de los navegadores TomTom. Esta empresa almacena los registros históricos de velocidad, con los cuales se obtuvieron los perfiles de tráfico en los diferentes ejes que componen la red de calles.

En los mapas de la Figura 13 (apartado 3.2.3) se muestra la frecuencia de viajes en el transporte público en un día laborable (jueves). Se observa que las horas 8 y 18 h tienen mayor frecuencia de viaje por hora. En cambio, en las horas 10 y 20 h disminuye la frecuencia de viajes. Por otro lado, la Figura 15 (apartado 3.2.3) muestra el nivel de tráfico en la red, utilizando los datos de perfiles históricos de velocidad de la empresa TomTom. Se observa que la fluidez del tráfico es menor, sobre todo, en las horas 8 y 18 h. El resto de las franjas horarias no presentaron cambios significativos en los distintos ejes de calles.

#### *4.1.2.3 Modelos de localización asignación: solución maximizar asistencia*

Con la red de transporte público y privado construida se procedió a ejecutar los modelos de localización-asignación, utilizando el módulo Location Allocation de Network Analyst de ArcMap 10.6 (ESRI) con la finalidad de evaluar en qué momento del día los hospitales captan mayor cobertura de población. Se seleccionó la solución de maximizar la asistencia. Dicha solución plantea que las instalaciones se eligen asignando el máximo peso de demanda posible a los equipamientos, asumiendo que el peso de la demanda disminuye en relación con la distancia entre los sitios candidatos y los puntos de demanda potencial.

Según Alonso (2016) se maximiza la demanda localizada dentro de un umbral de distancia, dando más importancia a la demanda cercana a los puntos de oferta. Maximizar la asistencia supone que cuanto más lejos tengan que desplazarse las

personas para hacer uso de un equipamiento, la probabilidad de que sea utilizada es menor (Erfani et al. 2018, Rahman et al. 2021).

Para el desarrollo del modelo se consideró un umbral de 30 minutos de viaje (se tomaron 30 minutos en base a los estudios de accesibilidad a hospitales, desarrollados por Asare-Akuffo et al., 2020; Reshadat et al., 2019; Sommerhalter et al., 2017). Se plantearon escenarios para dos días de la semana (jueves y sábados). Los modelos se ejecutaron con la red GTFS (transporte público) y la red de TomTom (transporte privado) en diferentes franjas horarias: 8, 10, 12, 14, 16, 18 y 20 horas; con el propósito de valorar el efecto de la fluctuación en las frecuencias del transporte público y de los niveles de congestión de la red de transporte privado sobre la cantidad de población cubierta.

Elegimos los jueves y sábados para representar un día típico de los días laborables y de los fines de semana, respectivamente. Mientras que las franjas utilizadas las tomamos considerando abarcar las horas punta del inicio de la mañana (8 h) y de la tarde (18 h) (Moya-Gómez & García-Palomares, 2015). También nos interesó el comportamiento de la red en las horas valle donde ocurren las menores frecuencias del transporte público y de la congestión en las carreteras de Madrid (10 h, 12 h, 14 h, 16 h, 20 h) (Moya-Gómez & García-Palomares, 2015). Estas franjas nos permitieron comparar escenarios donde las frecuencias del transporte público y la congestión cambian a lo largo del día.

Además, se ejecutó otro MLA utilizando como candidatos, solamente, los hospitales de referencia que cubren las áreas de salud del municipio de Madrid, el resto de los parámetros del modelo son los mismos que se aplicaron a toda la red de hospitales (Figura 22).

Por último, se propuso un modelo de localización-asignación que incluyó un nuevo hospital. Como instalaciones requeridas se empleó la ubicación de los hospitales actuales, mientras que los candidatos procedían de los centroides extraídos de las secciones censales. Los otros parámetros fueron similares a los propuestos en los modelos anteriores (iguales redes, días, franjas horarias, demanda y umbral de 30 minutos).

#### 4.1.3 Resultados de los modelos

En este aspecto se presentan los resultados para el desarrollo del MLA con los hospitales y los hospitales de referencia. En primer lugar, se exponen los resultados obtenidos al aplicar la solución de maximizar asistencia a toda la red de hospitales públicos y a los hospitales de referencia de las áreas de salud. En segundo lugar, se muestran los resultados obtenidos con la ejecución de la solución maximizar asistencia aplicada, para localizar un nuevo hospital de referencia de las áreas de salud.

##### 4.1.3.1 Modelo con toda la red de hospitales

Los resultados de la Tabla 10 muestran el cambio en la población cubierta por los hospitales en un tiempo de 30 minutos, en el transcurso del día, utilizando la red GTFS. La primera columna muestra las horas utilizadas para ejecutar los modelos de localización-asignación. Las columnas segunda y sexta contienen la cantidad de población asignada los jueves y los sábados. En la tercera y séptima columna aparece el porcentaje de población asignada respecto a la población total obtenida del padrón de población 2020 (3.223.334 habitantes). La cuarta, quinta, octava y novena columnas, recogen los incrementos absolutos y porcentuales, tomando como hora de referencia las 8 de la mañana para comparar las diferentes franjas temporales. Para ello, se ha tomado en cuenta el tráfico y la disponibilidad del transporte público a primera hora de la mañana.

Los jueves a las 12 horas es cuando se registra el mayor descenso porcentual de población asignada en un tiempo de 30 minutos (-3,4%). Mientras que a las 8 de la mañana es el momento donde se cubre una mayor cantidad de población (el 45,6% de la población). Esto se debe a la alta frecuencia del transporte público en esa hora.

El comportamiento de la demanda del sábado es lo contrario, registrando a las 8 horas la menor población cubierta (42,6%) y se incrementa a las 14 y 20 horas. Al comparar la hora 8 en ambos días, notamos que los sábados se cubre un 3% menos de población que en jueves. Este comportamiento, en la cobertura de la demanda, se debe a los ajustes en la frecuencia de los viajes de la red de transporte público. Para realizar tales ajustes toma en cuenta que los fines de semana a las 8 horas la actividad

de la población ocupada disminuye; por lo tanto, hay menos personas que utilizan el transporte público (Toledo, 2013).

Tabla 10. Población cubierta por hospitales a diferentes horas del día utilizando la red GTFS

Horas	Maximizar la asistencia							
	Jueves 30 minutos				Sábado 30 minutos			
	Total	%	**Inc.	Inc%	Total	%	Inc.	Inc%
<b>8:00*</b>	1.469.888	45,6			1.371.781	42,6		
10:00	1.430.688	44,4	-39.200	-2,7	1.383.042	42,9	1.1261	0,8
12:00	1.419.672	44,0	-50.216	-3,4	1.401.828	43,5	30.047	2,2
14:00	1.438.650	44,6	-31.238	-2,1	1.413.210	43,8	41.429	3,0
16:00	1.437.526	44,6	-32.362	-2,2	1.400.802	43,5	29.021	2,1
18:00	1.446.992	44,9	-22.896	-1,6	1.405.833	43,6	34.052	2,5
20:00	1.430.474	44,4	-39.414	-2,7	1.416.392	43,9	44.611	3,3

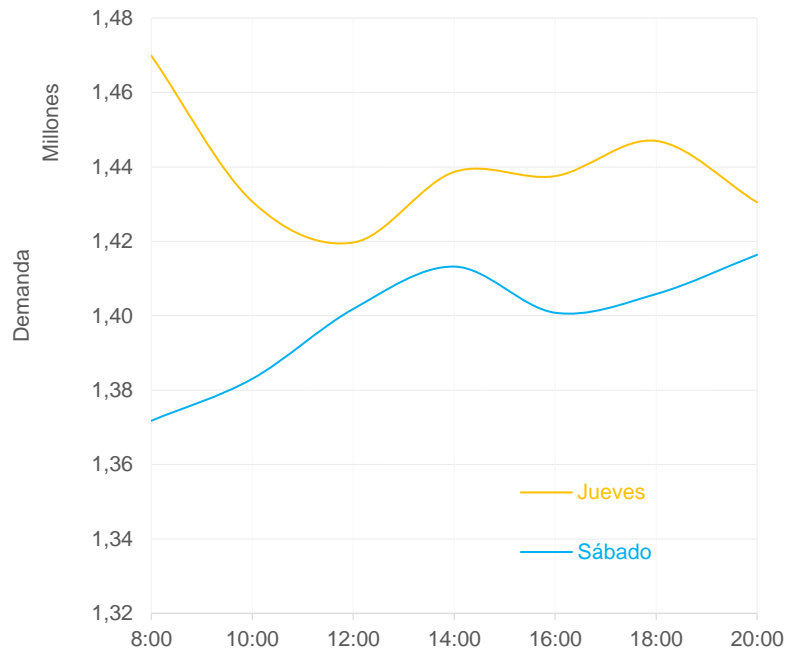
\*En negrita hora de comparación (8:00). \*\*Inc = incremento.

Fuente: Elaboración propia.

La Figura 24 representa la demanda asignada a cada hospital utilizando la red de transporte público. En el eje horizontal se muestran las horas elegidas para el desarrollo de la investigación. El eje vertical resume la cantidad de población asignada en unidades de millones. La línea color naranja indica los valores alcanzados los jueves mientras que la línea color turquesa representa los sábados. Se infiere que los jueves existe una mejor cobertura de la demanda, alcanzando valores más altos a las 8 y 18 horas. Los jueves tienen una demanda cubierta superior al sábado. Este comportamiento es producto de las frecuencias del transporte público, siendo más altas en las primeras horas de la mañana de los días laborables (jueves) y más bajas en las horas valle y el fin de semana (Plaza et al., 2019).

Los resultados obtenidos cuando las asignaciones se hacen usando la red de carreteras de TomTom (Tabla 11) reflejan una mayor cobertura en el porcentaje de población, pues contienen registros que presentan variaciones entre el 75% y 80% de la población cubierta en un tiempo de 30 minutos. Si tomamos como referencia la demanda cubierta a las 8 horas, vemos como ese es el peor momento para el acceso a los hospitales, con una situación muy similar a las 18 horas.

Figura 24. Población cubierta por hospital según red GTFS



Fuente: Elaboración propia.

Los sábados la situación es la contraria. El mejor momento de acceso a los hospitales es a las 8 de la mañana, cuando la congestión es prácticamente inexistente. Además, en general, la situación se mantiene muy estable, con ligeros cambios, a lo largo del resto de las horas. Al comparar la situación en ambos días en el promedio de población cubierta, notamos que los sábados se logra cubrir un 2,5% más.

La Figura 25 se ha elaborado a partir de la población asignada en cada franja horaria, tomando en cuenta los resultados obtenidos al aplicar el MLA con la red de transporte privado (TomTom). La representación gráfica muestra que el sábado se logra cubrir una mayor demanda que el jueves, debido a la escasa congestión vial que existe los fines de semana, producto de la disminución del volumen de población desplazándose hacia los puestos de trabajo.


Al estudiar el comportamiento de la demanda en las distintas franjas horarias, como señalábamos, se observa que las horas donde se presentan los valores mínimos son las 8 y las 18 (los jueves). Este comportamiento se relaciona con los momentos de mayor congestión en la ciudad. Se produce una situación contraria al transporte público, mejores accesos en las horas valle y el fin de semana.

Tabla 11. Población cubierta por los hospitales a diferentes horas del día utilizando la red TomTom

Horas	Maximizar asistencia							
	Jueves 30 minutos				Sábado 30 minutos			
	Total	%	Inc.	Inc%	Total	%	Inc.	Inc%
<b>8:00</b>	2.441.791	75,8			2.578.802	80,0		
10:00	2.489.449	77,2	47.658	2,0	2.567.446	79,7	-11.356	-0,5
12:00	2.487.195	77,2	45.404	1,9	2.554.535	79,3	-24.267	-1,2
14:00	2.510.085	77,9	68.294	2,8	2.56.1413	79,5	-17.389	-0,7
16:00	2.501.574	77,6	59.783	2,4	2.572.141	79,8	-6.661	-0,3
18:00	2.445.007	75,9	3.216	0,1	2.548.658	79,1	-30.144	-1,2
20:00	2.495.596	77,4	53.805	2,2	2.548.456	79,1	-30.346	-1,2

Fuente: Elaboración propia.

Figura 25. Población cubierta por hospital según red TomTom



Fuente: Elaboración propia.

Al comparar los resultados obtenidos por ambas redes, se observa que los cambios porcentuales son mayores en el transporte público que en el privado: el transporte público es más sensible a los cambios en las frecuencias que el coche a la congestión. Durante los sábados los perfiles en ambas redes son más estables, producto de una menor frecuencia del servicio de transporte, pero más homogénea a lo largo del día, y unos niveles de congestión más bajos. Además, el perfil cambia porque en coche desaparece la congestión de la mañana, y en el transporte público; la mejor accesibilidad se da al final de la mañana.

En la Tabla 12 se muestran las diferencias entre día laborable y fin de semana, donde la accesibilidad en coche es mejor el sábado que el jueves, y lo contrario para el transporte público (mejor jueves que sábado).

Tabla 12. Diferencias entre la población cubierta el sábado y jueves (resta de la demanda del sábado menos el jueves)

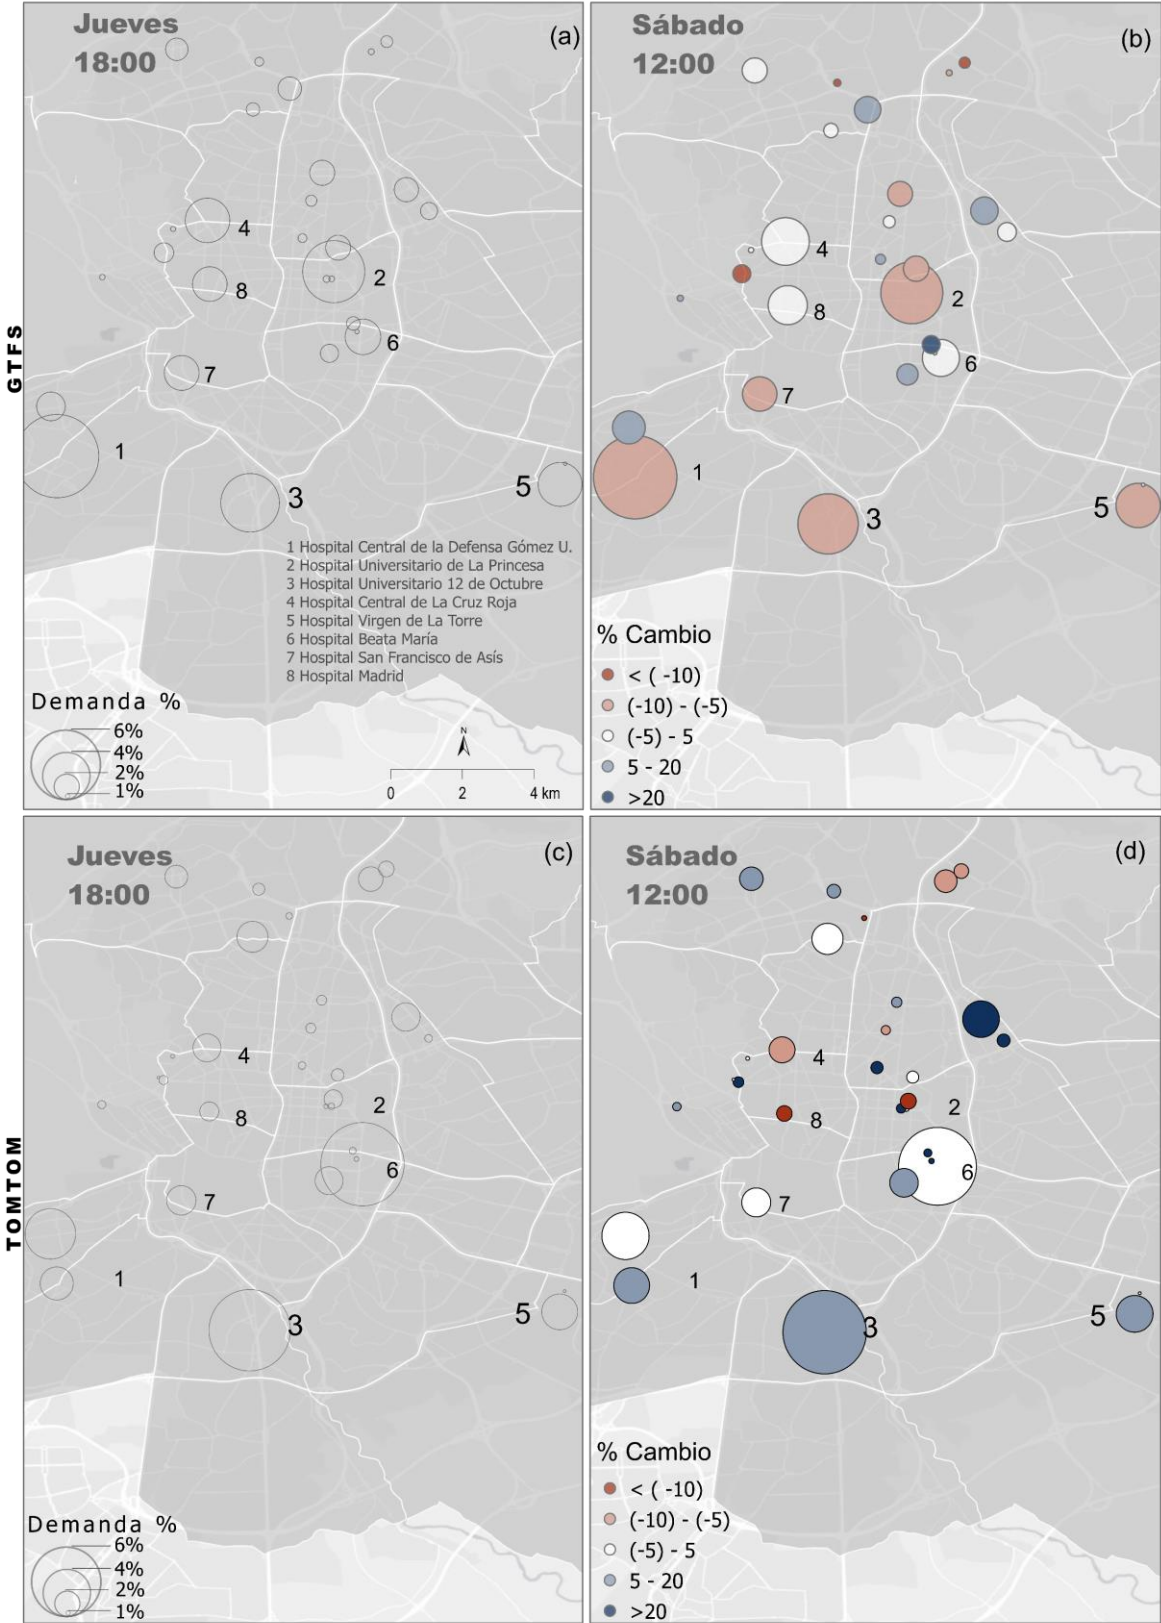
Horas	GTFS		TomTom	
	Total	%	Total	%
<b>8:00</b>	-98.107	-6,7	137.011	5,6
10:00	-47.646	-3,3	77.997	3,1
12:00	-17.844	-1,3	67.340	2,7
14:00	-25.440	-1,8	51.328	2,0
16:00	-36.724	-2,6	70.567	2,8
18:00	-41.159	-2,8	103.651	4,2
20:00	-14.082	-1,0	52.860	2,1

Fuente: Elaboración propia.

Los mapas de la Figura 26 representan la comparación del comportamiento de la demanda asignada, a cada hospital, para los dos días en estudio en ambas redes de transporte. Se han elaborado a partir del porcentaje de la población asignada a los diferentes hospitales. Tomamos en cuenta solo dos horas para representar momentos de alta (a las 18 h) y baja (a las 12 h) frecuencia del transporte público y congestión vehicular, tanto los jueves como los sábados. El tamaño de los círculos representa el porcentaje de población asignada a cada hospital. Mientras que los tonos azules y rojos indican; respectivamente, el cambio entre el jueves y sábado.

La Figura 26 a y b, muestra que los centros hospitalarios con mayor demanda asignada por el modelo utilizando GTFS, tanto el jueves como el sábado, son: el Hospital Central de la Defensa Gómez de Ulloa, Universitario de La Princesa, Universitario 12 de Octubre y Central de la Cruz Roja, con valores que oscilan entre los 70.000 y 180.000 habitantes. Analizando el porcentaje de cambio del sábado, en comparación con el jueves y en el caso de trabajar con asignaciones por la red GTFS, se aprecia que, la mayoría, presentan porcentajes negativos que indican una pérdida de población asignada durante los fines de semana (Figura 26b). Mientras que los resultados obtenidos, utilizando la red TomTom, indican que muchos hospitales cubren más demanda los fines de semana, situación que se puede explicar debido a los bajos niveles de congestión vehicular (Figura 26c). Además, el porcentaje de cambio indicó una mayor cobertura los sábados (Figura 26d).

Figura 26. Población cubierta y porcentaje de cambio entre jueves y sábado según hospitales



Fuente: Elaboración propia.

#### 4.1.3.2 Modelo con hospitales de referencia

En este modelo se utilizaron los mismos parámetros adoptados en el modelo anterior (demanda a partir de secciones censales, tiempo de 30 minutos, los mismos días y franjas horarias), el único cambio realizado, en este caso, radica en que ahora se utiliza como candidatos obligatorios los hospitales de referencia de las áreas de salud en lugar de toda la red de hospitales.

La Tabla 13 muestra la demanda cubierta por los hospitales de referencia asignados a las áreas de salud en el municipio de Madrid, utilizando la red de transporte público (GTFS). En general, los datos reflejan que, en ambos días, se cubre un valor cercano al 30% de la población y los jueves la demanda cubierta es mayor en comparación con los sábados.

Tabla 13. Población cubierta por hospitales asignados a las áreas de salud (GTFS)

Horas	Jueves				Sábado			
	Total	%	Inc.	Inc%	Total	%	Inc.	Inc%
<b>8:00</b>	1.020.219	31,7			870.994	27,0		
10:00	959.175	29,8	-61.044	-6,0	908.506	28,2	37.512	4,3
12:00	941.792	29,2	-78.427	-7,7	909.967	28,2	38.973	4,5
14:00	949.047	29,4	-71.172	-7,0	945.624	29,3	74.630	8,6
16:00	982.274	30,5	-37.945	-3,7	917.829	28,5	46.835	5,4
18:00	979.949	30,4	-40.270	-3,9	924.243	28,7	53.249	6,1
20:00	979.475	30,4	-40.744	-4,0	947.332	29,4	76.338	8,8

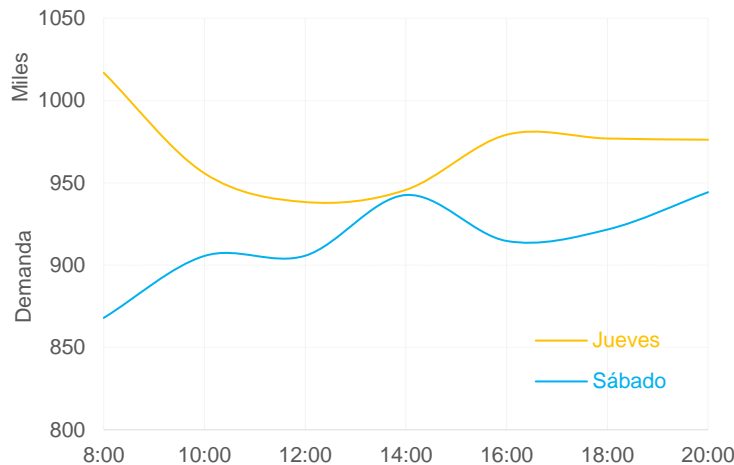
Fuente: Elaboración propia.

Al comparar la primera franja horaria (8 h) con el resto de las horas se observa que el jueves los porcentajes de cambio son negativos (producto de los ajustes de la frecuencia del transporte público) a medida que avanza el día, mostrando los valores más bajos a las 12 y 14. horas. En cambio, el sábado el porcentaje de cobertura que se alcanza es algo menor a los valores obtenidos los jueves. Esto se explica por la disminución en las frecuencias de viajes del transporte público durante los fines de semana.

La Figura 27 muestra una mayor cobertura de la demanda los jueves en comparación con los sábados, siendo las franjas horarias de las 8 y las 16 horas las que presentan los valores más altos de población asignada. En cambio, el sábado es a las 14 y 20,

cuando la cobertura es mayor. En general, la demanda cubierta en ambos días muestra valores cambiantes en las distintas franjas horarias analizadas.

Figura 27. Población cubierta por los hospitales asignados a las áreas de salud (GTFS)

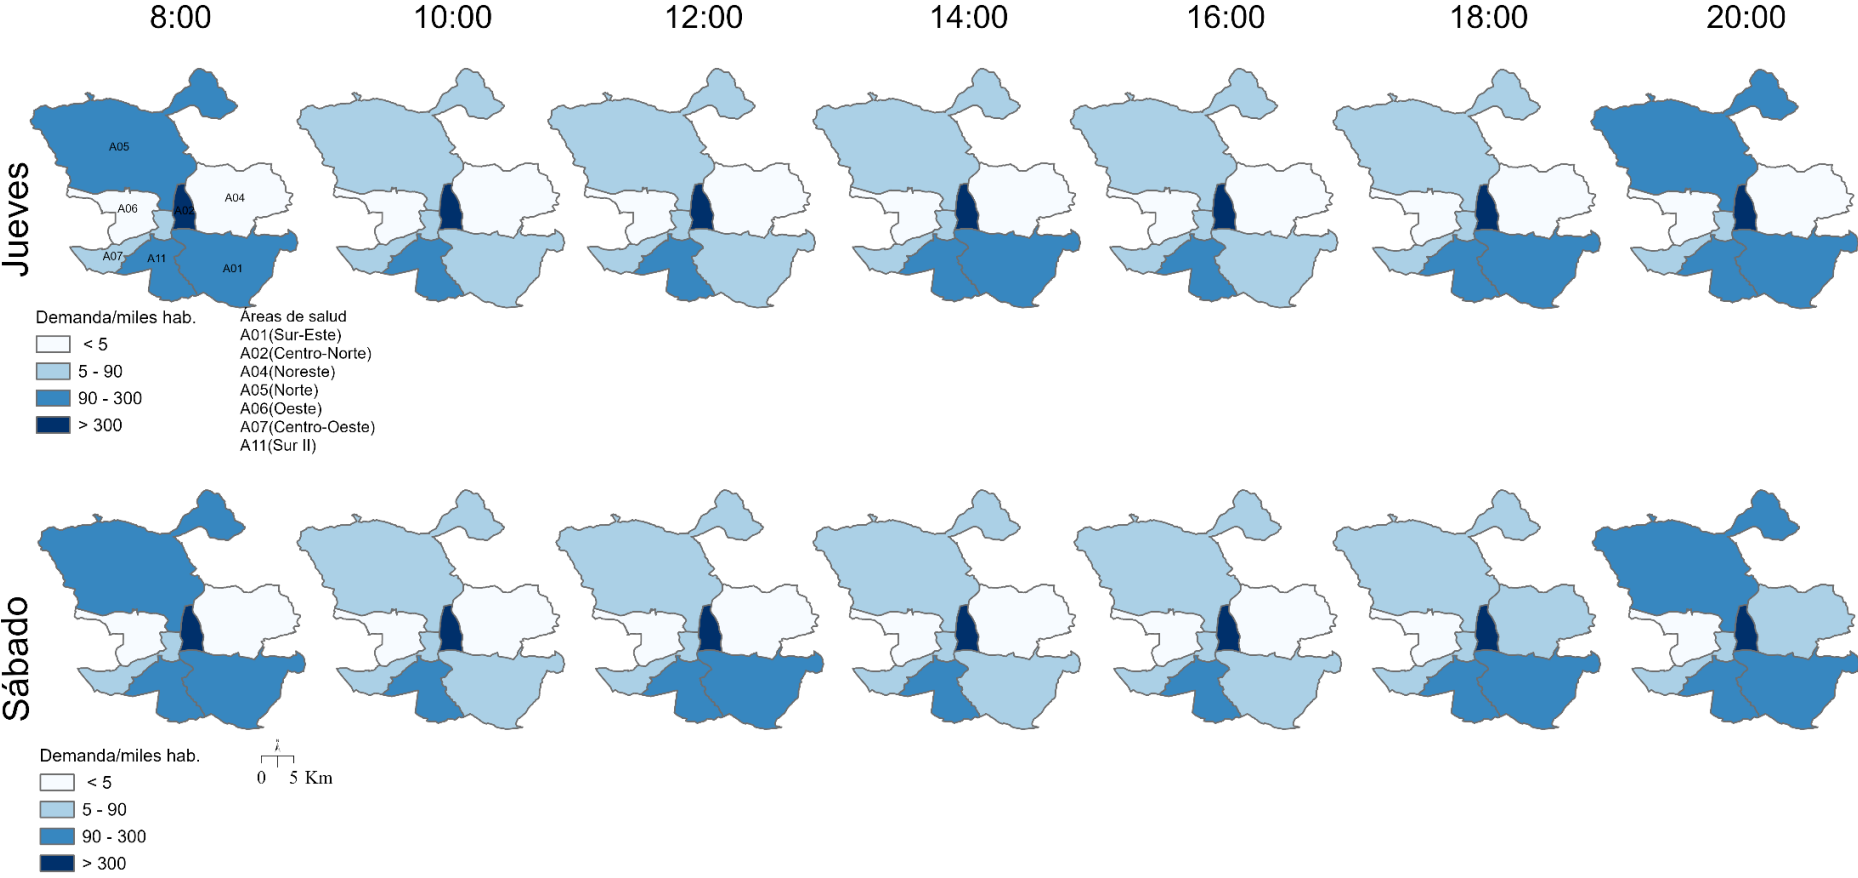


Fuente: Elaboración propia.

Los mapas de la Figura 28. Población cubierta por área de salud ilustran la variación de la demanda en las distintas áreas de salud por franja horaria, utilizando la red GTFS. Estos mapas se han diseñado en base a la población asignada a cada área de salud para los jueves y sábados en las distintas franjas horarias estudiadas. Se observa que los jueves y sábados el área de salud Centro-Norte (A02) es la que capta la mayor cantidad de demanda en todas las franjas analizadas. Además, en las áreas Sur-Este (A01) y Sur II (A11), la demanda cambia en las diversas horas del día, sobre todo, en las horas 10, 12 y 16, tal comportamiento puede ser producto de la disminución de las frecuencias de los autobuses en pasar por las paradas.

La Tabla 14 y la Figura 29 ilustran los resultados obtenidos al aplicar el MLA en los hospitales de referencia de las áreas de salud, utilizando la red TomTom. Se distingue que la demanda cubierta oscila entre el 66% y 72% en ambos días, quedando aproximadamente un tercio de la población del área de estudio sin cobertura en un tiempo de 30 minutos de viaje. En el caso de los jueves, la mayor cobertura de población se produjo a las 14 horas (69% de la población cubierta) y a las 20 horas (68,9%). Estos porcentajes pueden estar relacionados con el hecho de que hay menos congestión de tráfico en la red de carreteras durante esas horas (TomTom, 2020).

Figura 28. Población cubierta por área de salud (GTFS)



Fuente: Elaboración propia

Tabla 14. Población cubierta por hospitales asignados a las áreas de salud (TomTom)

Horas	Jueves				Sábado			
	Total	%	Inc.	Inc%	Total	%	Inc.	Inc%
<b>8:00</b>	2.130.358	66,1			2.341.011	72,6		
10:00	2.186.890	67,8	56.532	2,7	2.327.256	72,2	-13.755	-0,6
12:00	2.186.532	67,8	56.174	2,6	2.311.181	71,7	-29.830	-1,3
14:00	2.222.736	69,0	92.378	4,3	2.318.585	71,9	-22.426	-1,0
16:00	2.206.448	68,5	76.090	3,6	2.332.406	72,4	-8.605	-0,4
18:00	2.130.549	66,1	191	0,0	2.302.108	71,4	-38.903	-1,7
20:00	2.220.235	68,9	89.877	4,2	2.300.514	71,4	-40.497	-1,7


Fuente: Elaboración propia.

La Tabla 14 resume el incremento porcentual de la demanda asignada a los hospitales de las áreas de salud en cada franja horaria. Como hora de referencia (para comparar los porcentajes de incremento en la demanda cubierta durante el día) se ha elegido las 8 de la mañana. Se observa que los jueves presentan cambios porcentuales positivos en las diferentes franjas horarias estudiadas, mostrándose, nuevamente, el mayor incremento porcentual en las horas 14 y 20 (4,3% y 4,2% respectivamente). Estos incrementos porcentuales se explican debido a la mayor fluidez del tráfico a medida que avanza la mañana.

Por otro lado, la información obtenida para el sábado muestra que los porcentajes de demanda cubierta son muy similares entre las distintas horas del sábado, siendo, no obstante, algo mayores a las 18 y 20 horas.

La Figura 29 muestra en el eje vertical, en millones, la cantidad de población cubierta en un tiempo máximo de viaje de 30 minutos en transporte privado, mientras que el eje horizontal muestra las franjas horarias seleccionadas para el estudio. Con el uso de la red TomTom durante los sábados, se observa que se consigue una mayor cobertura de población en comparación con los jueves y muestra un perfil con pocos cambios en las diferentes franjas horarias. Los jueves, se observa que el perfil presenta variaciones en las distintas franjas horarias, destacando las horas 8 y las 18, con los valores de cobertura menores.


Figura 29. Población cubierta por los hospitales asignados a las áreas de salud (TomTom)



Fuente: Elaboración propia.

La Figura 30 recoge la demanda asignada por área de salud en cada franja temporal, utilizando la red TomTom, notándose que los jueves y sábados el área Sur II es la que capta la demanda asignada más elevada en las diferentes franjas horarias. Se observa que los jueves la demanda asignada por las áreas de salud Centro-Norte y Sur-Este es diferente a lo largo del día. Mientras que los sábados las áreas de salud Norte (A05), Oeste (A06) y Centro-Oeste (A07) son las que capturan la menor cantidad de población. En cuanto a la variación en las diversas franjas horarias la Figura 30, ilustra que solo el área Centro-Norte disminuye la demanda, específicamente, a las 12.

Figura 30. Población cubierta por área de salud (TomTom)



Fuente: Elaboración propia.

La diferencia de demanda captada por los hospitales de referencia a las áreas de salud del municipio de Madrid se muestra en la Tabla 15. En términos generales, se refleja una menor cobertura de la demanda con la red GTFS los sábados que los jueves. En todas las franjas horarias, las variaciones negativas indican una disminución de la población atendida. Al utilizar la red TomTom, ocurre lo contrario, existe una mayor demanda los sábados, como lo indican las variaciones porcentuales positivas, siendo las franjas horarias de las 8 y las 18 h las que presentan los valores más altos.

Tabla 15. Diferencias entre la población cubierta el sábado y jueves (sábados menos jueves)

Horas	GTFS		TomTom	
	Total	%	Total	%
<b>8:00</b>	-149.225	-14,6	210.653	9,9
10:00	-50.669	-5,3	140.366	6,4
12:00	-31.825	-3,4	124.649	5,7
14:00	-3.423	-0,4	95.849	4,3
16:00	-64.445	-6,6	125.958	5,7
18:00	-55.706	-5,7	171.559	8,1
20:00	-32.143	-3,3	80.279	3,6


Fuente: Elaboración propia.

La Figura 31 muestra los resultados obtenidos por los hospitales de referencia de las áreas de salud (los jueves), utilizando la red GTFS. Los valores representados son los porcentajes de cambios calculados en relación con la población cubierta a las 8 h (hora que se ha tomado en cuenta para comparar los cambios en la población asignada en las demás franjas horarias). El eje vertical muestra los porcentajes de cambios, mientras que el eje horizontal presenta las diferentes franjas horarias analizadas; la gama de colores de las barras destaca a cada uno de los hospitales de referencia de las áreas de salud.

Las fluctuaciones en el tamaño de las barras de la gráfica (Figura 31), nos llevan a distinguir que los jueves, en todas las franjas horarias, en la mayoría de los hospitales (cerca al 80%) presentaban cambios negativos en la población cubierta, respecto a las 8 h exceptuando los hospitales Gregorio Marañón (HUGMV) y Ramón y Cajal (HRC), que en la franja 18 h, tienen incrementos por encima del 20% en su población cubierta.

En el caso de las franjas horarias de las 10 y 12 horas, los hospitales más afectados por las diferentes frecuencias de los autobuses de transporte público son el Hospital Universitario Santa Cristina (HUSC) y el Hospital Ramón y Cajal a las 10 horas. Mientras que, a las 12 mediodía, los más afectados por las fluctuaciones de las frecuencias del transporte público son el Hospital Universitario Gregorio Marañón (HUGM) y el Hospital Ramón y Cajal (HRC). Lo planteado anteriormente puede tener su origen en las horas, cuando los autobuses aumentan el tiempo entre un viaje y el siguiente; además, estos hospitales se localizan alejados de las zonas que presentan mayor frecuencia de viajes del transporte público.

Figura 31. Porcentaje de cambio los jueves (GTFS) respecto a las 8 horas según hospitales de referencia



Nota. HUPSA (Hospital Universitario Princesa)-HU120-(Hospital Universitario 12 de Octubre)-HLP (Hospital Universitario de La Paz)- HVT (Hospital Virgen de la Torre)-HCSC (Hospital Clínico San Carlos)-HUGM (Hospital Universitario Gregorio Marañón)-HRC (Hospital Ramón y Cajal)- HUSC (Hospital Universitario Santa Cristina)-HPH (Hospital Puerta de Hierro).

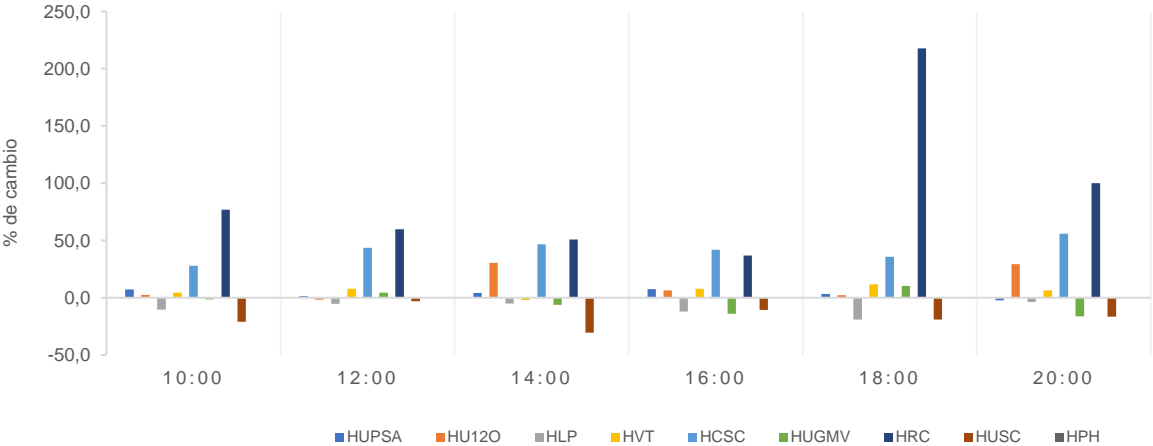
Fuente: Elaboración propia.

Por otro lado, los sábados, muestran una tendencia opuesta a la registrada los jueves (Figura 32), observándose cambios porcentuales positivos en los hospitales de referencia. Sobre todo, destaca el hospital Ramón y Cajal, con un porcentaje de cambios muy superior al resto de los hospitales.

Los cambios porcentuales positivos tienen su explicación en el hecho de que los sábados por la mañana a las 8 h (hora utilizada para la comparación con el resto de las franjas horarias), se ralentizan las frecuencias del transporte público. Por otro lado,

se observa que, en todas las franjas horarias, dos hospitales presentan cambios negativos, concretamente, el Hospital Santa Cristina (HUSC) y el Hospital Universitario de La Paz (HLP).

Figura 32. Porcentaje de cambio los sábados (GTFS) respecto a las 8 horas según hospitales de referencia

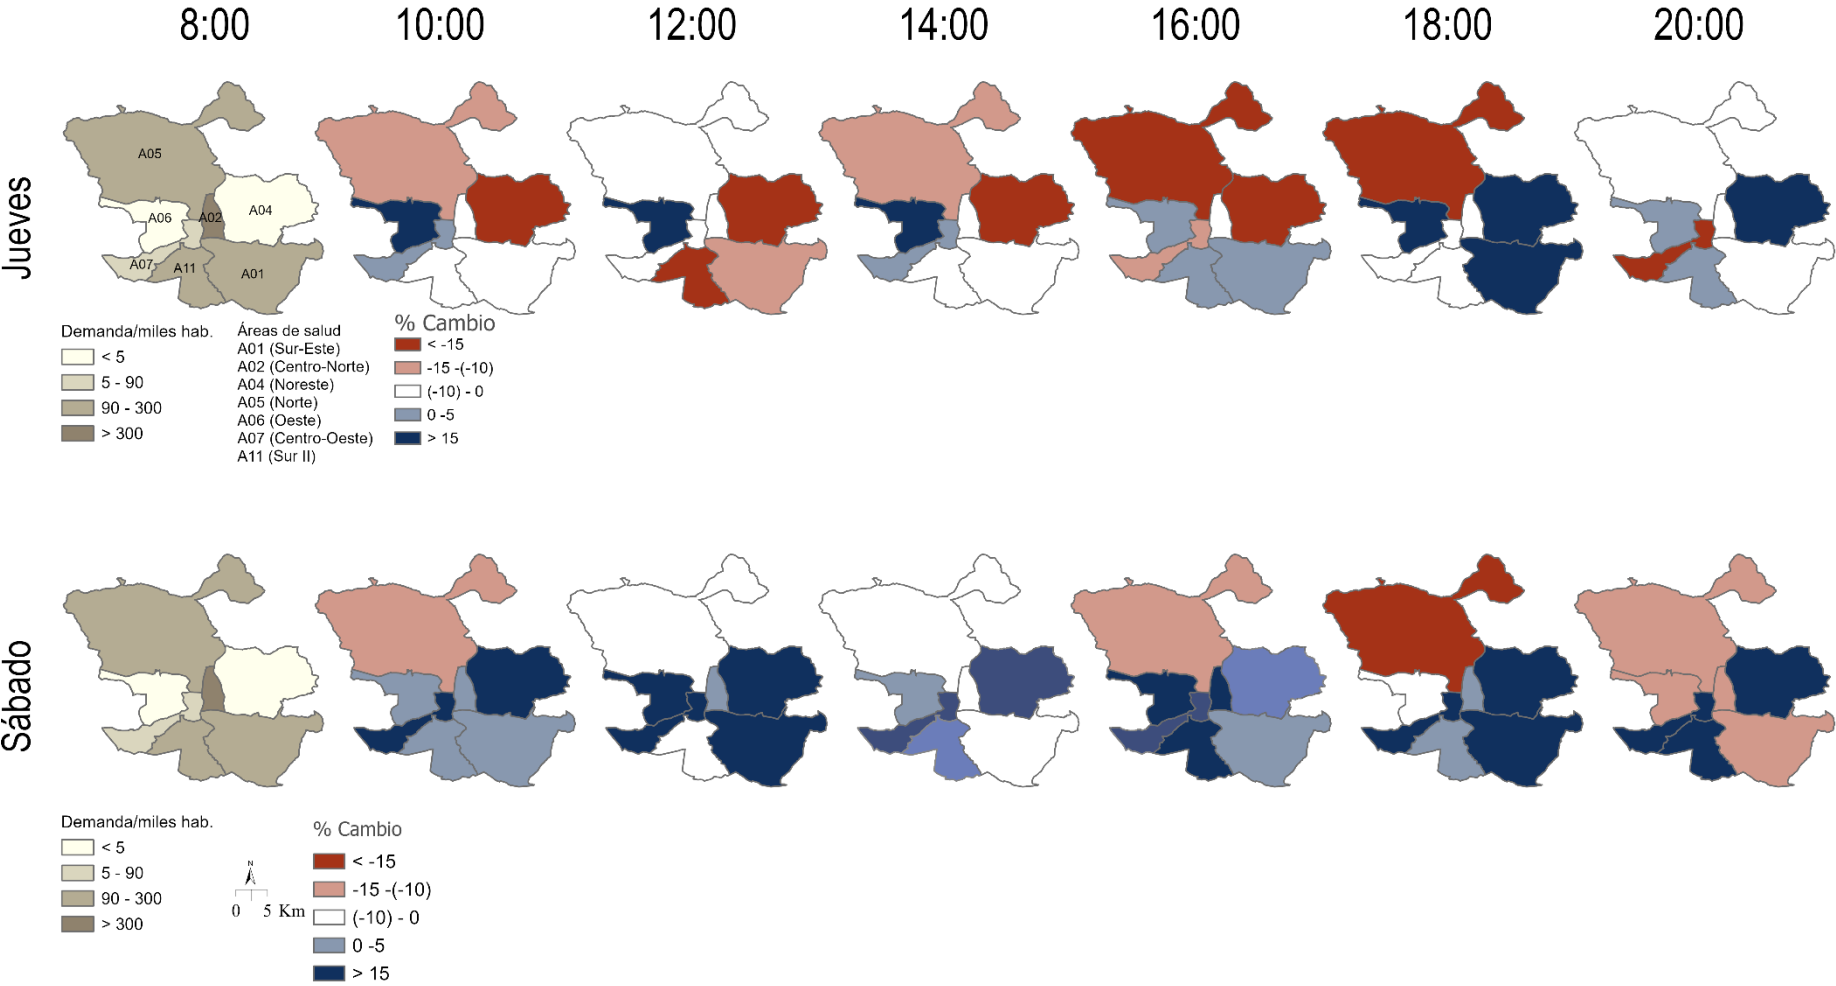


Fuente: Elaboración propia.

La Figura 33 ilustra los cambios porcentuales de la población cubierta por las áreas de salud utilizando la red GTFS los jueves y los sábados. Para el cálculo de los cambios porcentuales se ha tomado como base de comparación las 8 horas, con la finalidad de evaluar el cambio espacial de la demanda cubierta a medida que avanza el día. El mapa de las 8 horas solo muestra la cantidad de población cubierta. Los demás mapas muestran los cambios porcentuales registrados en cada franja horaria. La escala de colores indica que los tonos rojos son las áreas sanitarias que muestran cambios negativos y los tonos azules indican cambios positivos.

Centrándonos en los jueves, se observan cambios negativos en la mayoría de las áreas de salud, excepto en las áreas de salud A 01 (horas 16 y 18), A 04 (horas 18 y 20), y el área de salud A 11 (horas 16 y 20), que en algunas franjas horarias presentan valores positivos. Cabe destacar que el área de salud A 05 es la única que presenta porcentajes negativos de cambios, lo que se explica por la lejanía de esta área de salud del centro de la ciudad. En el centro de la ciudad el transporte público es más eficiente debido al mayor número de rutas.

Figura 33. Porcentaje de cambio respecto a las 8 horas por área de salud (GTFS)




Fuente: Elaboración propia.

Los sábados ocurre lo contrario a lo presentado el jueves (Figura 33), la mayoría de las áreas de salud tienen incrementos en la población cubierta en las diferentes franjas horarias; solo se destaca el área Norte (A05) con números negativos durante todo el día. Limitando el análisis a las 20 horas del sábado, se observa que el 57 % de las áreas de salud presentan cifras negativas de población cubierta respecto a las 8.

Los resultados obtenidos en los hospitales designados a las áreas de salud, utilizando la red TomTom, ilustran de manera general un comportamiento completamente distinto a la red GTFS. Los jueves, la mayoría de los hospitales registran cambios positivos respecto a las 8 h. Solo tienen una tendencia contraria el hospital de La Princesa y el hospital de la Virgen de La Torre (Figura 34).

Figura 34. Porcentaje de cambio los jueves (TomTom) respecto a las 8 horas según hospitales de referencia




Nota. HUPSA (Hospital Universitario Princesa)-HU120-(Hospital Universitario 12 de Octubre)-HLP (Hospital Universitario de La Paz)- HVT (Hospital Virgen de la Torre)-HCSC (Hospital Clínico San Carlos)-HUGM (Hospital Universitario Gregorio Marañón)-HRC (Hospital Ramón y Cajal)- HUSC (Hospital Universitario Santa Cristina)-HPH (Hospital Puerta de Hierro).

Fuente: Elaboración propia.

Por otra parte, los sábados (Figura 35) un gran número de hospitales muestran cambios negativos, registrando los valores más significativos los hospitales Gregorio Marañón y el Clínico San Carlos. La explicación de estos cambios negativos puede

atribuirse al hecho que durante las 8 horas (hora de comparación) de los fines de semana, el flujo de tráfico vehicular es rápido debido a la baja congestión. Por lo tanto, a esa hora más población puede acceder a los hospitales.

Figura 35. Porcentaje de cambio los sábados (TomTom) respecto a las 8 horas según hospitales de referencia



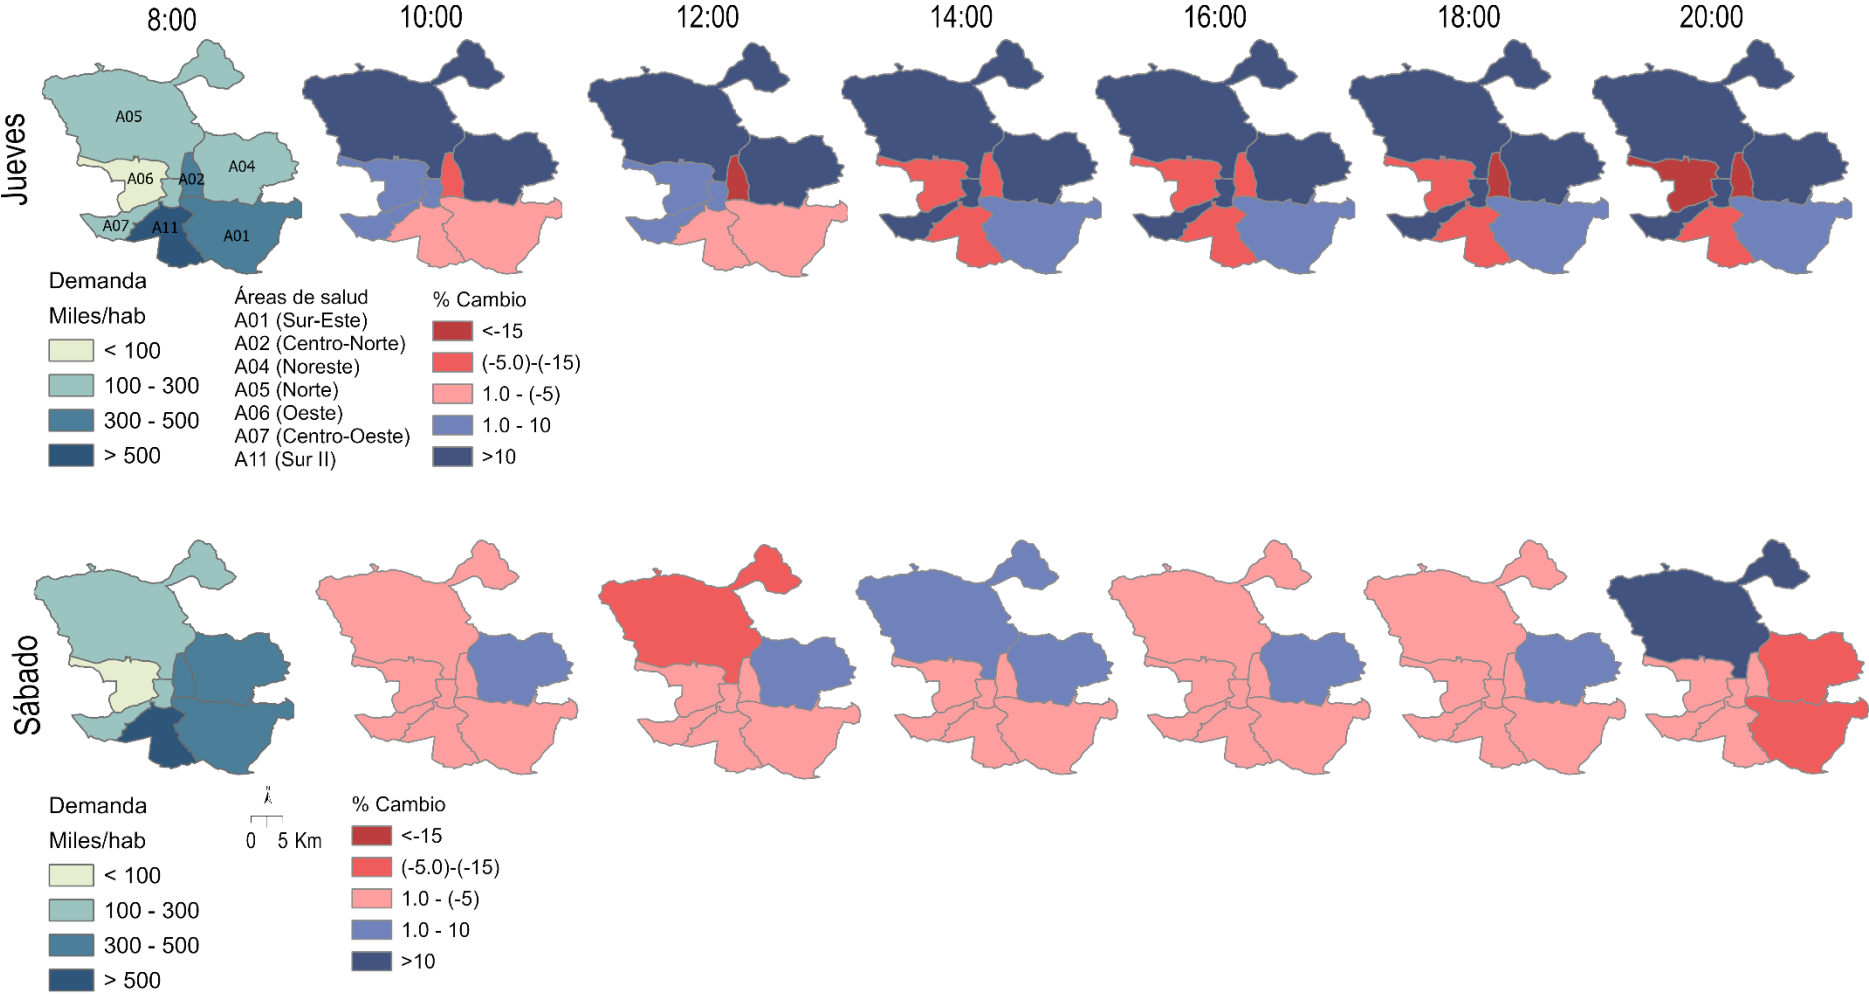
Nota. HUPSA (Hospital Universitario Princesa)-HU12O-(Hospital Universitario 12 de Octubre)-HLP (Hospital Universitario de La Paz)- HVT (Hospital Virgen de la Torre)-HCSC (Hospital Clínico San Carlos)-HUGM (Hospital Universitario Gregorio Marañón)-HRC (Hospital Ramón y Cajal)- HUSC (Hospital Universitario Santa Cristina)-HPH (Hospital Puerta de Hierro).

Fuente: Elaboración propia.

En la Figura 36 se observa que los jueves los porcentajes de cambios en la cobertura de la demanda de las áreas de salud, utilizando la red TomTom, muestran incrementos porcentuales respecto a la franja de referencia (8 h), destacando las áreas Norte (A05) y Noreste (A04) en todas las franjas horarias. También se observa que existen áreas de salud afectadas por la congestión de las carreteras, en todas las franjas horarias (áreas de salud Sur II y Centro-Norte).

La explicación de este comportamiento puede estar relacionada con la mayor congestión existente en las calles de Madrid en las primeras horas de la mañana. Por otro lado, los sábados, la mayor parte de la población asignada disminuye debido a que la hora tomada como referencia para obtener los cambios porcentuales (hora 8) registra los niveles de congestión más bajos (los fines de semana).

Figura 36. Porcentaje de cambio respecto a las 8 horas por áreas de salud (TomTom)



Fuente: Elaboración propia.

En resumen, los resultados obtenidos con las dos redes utilizadas (GTFS y TomTom), muestran comportamientos diferentes entre los días laborables y el fin de semana y según franjas horarias indicando que la accesibilidad a las áreas de salud se ve afectada, ya sea por la disminución en la frecuencia del transporte público o por los niveles de congestión vehicular en las diversas horas del día.

La población cubierta por los hospitales de referencia asignados a las áreas de salud en que se divide el Municipio de Madrid, utilizando la red de transporte público (GTFS) se resumen en la Tabla 16 y Tabla 17. Con estas tablas pretendemos mostrar qué porcentaje de la población que está dentro de los límites de cada área de salud, es cubierta por los hospitales de referencia. De manera general, los datos reflejan que en ambos días y utilizando la red GTFS sólo el hospital de La Princesa y Santa Cristina (HLPSC) cubren un volumen superior de población al que vive dentro de los límites de su respectiva área de salud (área Centro-Norte). Mientras que los hospitales de referencia más afectados por el comportamiento de las frecuencias del transporte público son Puerta de Hierro (HPH) y Ramón y Cajal (HRC), que no alcanzan a cubrir el 5% de la población que vive dentro de los límites del área de salud.

En el caso de los resultados conseguidos con el uso de la red TomTom, la mayoría de los hospitales no logran cubrir la población de su respectiva área de salud, excepto nuevamente el hospital de La Princesa y Santa Cristina (HLPSC) (Tabla 18 y Tabla 19). En cuanto al hospital de referencia más afectado por los cambios de la congestión en la red de transporte privado, tanto en día laborable como el fin de semana, es el hospital San Carlos (HSCA), que presenta valores que oscilan entre el 25% y 35% de la población de su área cubierta.

La diferencia entre el día laborable y el fin de semana en la población cubierta por los hospitales de referencia se muestra en la Tabla 20 y Tabla 21. En términos generales, con el uso de la red GTFS, los jueves se cubre mayor población que los sábados, ya que la mayoría de los hospitales presentaron cambios porcentuales negativos, excluyendo el hospital Ramón y Cajal que registró mayor población cubierta el fin de semana, sobre todo, en las últimas horas del día. En el caso de la red TomTom ocurrió lo contrario, pues existe mayor población cubierta los sábados, tal como lo indican los cambios porcentuales positivos. Solo el hospital La Paz (HLP) y el hospital 12 de Octubre (H12O) presentan menor demanda el fin de semana que el día laborable (Tabla 21).

Tabla 16. Población cubierta por los hospitales de referencia de las áreas de salud (jueves - GTFS)

Hospital de referencia	Población dentro del área de salud	8:00		10:00		12:00		14:00		16:00		18:00		20:00	
		Total	%	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%
HGMVT	622.597	134.007	21,5	125.840	20,2	119.421	19,2	139.531	22,4	139.976	22,5	141.660	22,8	127.809	20,5
HLPSC	290.181	428.380	147,6	409.624	141,2	411.853	141,9	389.450	134,2	420.767	145,0	424.986	146,5	419.399	144,5
HRC	602.501	27.100	4,5	22.868	3,8	19.748	3,3	26.582	4,4	22.309	3,7	33.917	5,6	301.94	5,0
HLP	399.128	138.603	34,7	119.468	29,9	127.642	32,0	121.314	30,4	115.603	29,0	111.044	27,8	124.787	31,3
HPH	117.873	3.513	3,0	3.865	3,3	3.714	3,2	3.720	3,2	3.531	3,0	3.742	3,2	3.531	3,0
HSCA	506.873	92.000	18,2	9.3875	18,5	90.876	17,9	90.369	17,8	80.064	15,8	83.576	16,5	71.824	14,2
H12O	684.181	196.617	28,7	183.635	26,8	168.537	24,6	178.080	26,0	200.024	29,2	181.024	26,5	201.929	29,5

GMMT (Gregorio Marañón y Virgen de La Torre) LPSC (La Princesa y Santa Cristina) RC (Ramón y Cajal) LP (La Paz) PH (Puerta de Hierro) SCA (San Carlos) 12OCT (12 de Octubre)

Fuente: Elaboración propia.

Tabla 17. Población cubierta por los hospitales de referencia de las áreas de salud (sábados – GTFS)

Hospital	Población dentro del área de salud	8:00		10:00		12:00		14:00		16:00		18:00		20:00	
		Total	%	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%
HGMVT	622.597	125.048	20,1	128.183	20,6	133.363	21,4	120.681	19,4	125.385	20,1	139.136	22,3	123.392	19,8
HLPSC	290.181	380.289	131,1	394.087	135,8	383.455	132,1	379.180	130,7	400.039	137,9	382.098	131,7	364.460	125,6
HRC	602.501	16.727	2,8	29.594	4,9	26.725	4,4	25.245	4,2	22.909	3,8	53.132	8,8	33.466	5,6
HLP	399.128	120.767	30,3	108.245	27,1	114.227	28,6	114.500	28,7	106.368	26,6	97.628	24,5	116.404	29,2
HPH	117.873	3.120	2,6	3.077	2,6	4.248	3,6	3.166	2,7	3.166	2,7	3.077	2,6	3.049	2,6
HSCA	506.873	58.337	11,5	74.552	14,7	83.943	16,6	85.529	16,9	82.801	16,3	78.797	15,5	91.090	18,0
H12O	684.181	166.705	24,4	170.768	25,0	164.005	24,0	217.323	31,8	177.162	25,9	170.374	24,9	215.473	31,5

Fuente: Elaboración propia.

Tabla 18. Población cubierta por los hospitales de referencia de las áreas de salud (jueves - TomTom)

Hospital	Población dentro del área de salud	8:00		10:00		12:00		14:00		16:00		18:00		20:00	
		Total	%	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%
HGMVT	622.597	380.208	61,1	391.414	62,9	378.937	60,9	413.233	66,4	411.098	66,0	401.042	64,4	418.310	67,2
HLPSC	290.181	380.542	131,1	422.380	145,6	338.670	116,7	381.166	131,4	350.244	120,7	313.365	108,0	335.573	115,6
HRC	602.501	273.476	45,4	196.223	32,6	286.004	47,5	284.844	47,3	275.198	45,7	271.790	45,1	321.415	53,3
HLP	399.128	211.497	53,0	181.497	45,5	247.293	62,0	217.327	54,5	243.831	61,1	247.250	61,9	234.888	58,9
HPH	117.873	92.964	78,9	45.815	38,9	104.746	88,9	101.680	86,3	101.348	86,0	103.261	87,6	106.955	90,7
HSCA	506.873	135.582	26,7	139.473	27,5	141.635	27,9	156.586	30,9	157.541	31,1	151.842	30,0	163.635	32,3
H12O	684.181	712.622	104,2	753.556	110,1	689.247	100,7	667.900	97,6	667.189	97,5	641.998	93,8	639.458	93,5

Fuente: Elaboración propia.

Tabla 19. Población cubierta por los hospitales de referencia de las áreas de salud (sábado - TomTom)

Hospital	Población dentro del área de salud	8:00		10:00		12:00		14:00		16:00		18:00		20:00	
		Total	%	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%
HGMVT	622.597	447.035	71,8	445.071	71,5	439.639	70,6	441.701	70,9	445.842	71,6	437.851	70,3	424.527	68,2
HLPSC	290.181	458.243	157,9	453.485	156,3	447.741	154,3	441.031	152,0	445.665	153,6	436.903	150,6	439.703	151,5
HRC	602.501	338.165	56,1	341.854	56,7	354.336	58,8	344.305	57,1	343.958	57,1	346.335	57,5	309.481	51,4
HLP	399.128	158.808	39,8	153.468	38,5	143.859	36,0	160.533	40,2	158.455	39,7	154.756	38,8	192.449	48,2
HPH	117.873	108.809	92,3	108.748	92,3	114.430	97,1	116.093	98,5	108.489	92,0	113.909	96,6	117.056	99,3
HSCA	506.873	162.937	32,1	162.181	32,0	156.259	30,8	158.923	31,4	163.472	32,3	158.796	31,3	155.377	30,7
H12O	684.181	667.014	97,5	662.449	96,8	654.918	95,7	656.000	95,9	666.527	97,4	653.558	95,5	661.921	96,7

Fuente: Elaboración propia.

Tabla 20. Diferencias en la población cubierta por los hospitales de referencia entre día laborable y fin de semana (sábados-jueves GTFS)

Hospital de referencia	8:00		10:00		12:00		14:00		16:00		18:00		20:00	
	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%
HGMVT	-8.959	-6,7	2.343	1,9	13.941	11,7	-18.850	-13,5	-14.591	-10,4	-2524	-1,8	-4.417	-3,5
HLPSC	-48.091	-11,2	-15.536	-3,8	-28.398	-6,9	-10.270	-2,6	-20.729	-4,9	-42.888	-10,1	-54.940	-13,1
HRC	-10.373	-38,3	6.726	29,4	6.977	35,3	-1.337	-5,0	600	2,7	19.215	56,7	3.271	10,8
HLP	-17.836	-12,9	-11.224	-9,4	-13.415	-10,5	-6.815	-5,6	-9.235	-8,0	-13.416	-12,1	-8.383	-6,7
HPH	-393	-11,2	-788	-20,4	534	14,4	-554	-14,9	-365	-10,3	-665	-17,8	-482	-13,7
HSCA	-33.663	-36,6	19.323	20,6	-6.933	-7,6	-4.840	-5,4	2.737	3,4	-4.779	-5,7	19.266	26,8
H12O	-29.913	-15,2	12.867	7,0	-4.532	-2,7	39.243	22,0	-22.861	-11,4	-10.649	-5,9	13.544	6,7

Fuente: Elaboración propia.

Tabla 21. Diferencias en la población cubierta por los hospitales de referencia entre día laborable y fin de semana (sábados-jueves TomTom)

Hospital	8:00		10:00		12:00		14:00		16:00		18:00		20:00	
	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%
HGMVT	66.827	17,6	53.657	13,7	60.701	16,0	28.467	6,9	34.744	8,5	36.809	9,2	6.217	1,5
HLPSC	77.701	20,4	31.105	7,4	109.071	32,2	59.865	15,7	95.422	27,2	123.538	39,4	104.130	31,0
HRC	64.689	23,7	145.631	74,2	68.332	23,9	59.461	20,9	68.759	25,0	74.545	27,4	-11.934	-3,7
HLP	-52.689	-24,9	-28.030	-15,4	-103.434	-41,8	-56.794	-26,1	-85.377	-35,0	-92.494	-37,4	-42.440	-18,1
HPH	15.845	17,0	62.933	137,4	9.684	9,2	14.413	14,2	7.141	7,0	10.648	10,3	10.102	9,4
HSCA	27.355	20,2	22.708	16,3	14.623	10,3	2.337	1,5	5.931	3,8	6.954	4,6	-8.258	-5,0
H12O	-45.607	-6,4	-91.107	-12,1	-34.329	-5,0	-11.900	-1,8	-662	-0,1	11.560	1,8	22.463	3,5

Fuente: Elaboración propia.

#### *4.1.3.3 Localización óptima de un nuevo hospital*

El modelo propuesto incluye un nuevo hospital de referencia para las áreas de salud. En este caso, hemos elegido los actuales hospitales de referencia como ubicaciones requeridas. Los candidatos utilizados a la localización del nuevo hospital han sido los centroides de las secciones censales. En el desarrollo del modelo se han utilizado los mismos parámetros del caso implementado para toda la red hospitalaria (iguales días, demanda, franjas horarias, redes, solución y tiempo).

Obviamente, la ubicación de un nuevo hospital mejora la cobertura proporcionada por los hospitales existentes. El incremento que se produce en el caso de la red GTFS fluctúa entre un 17% y el 23%. Con la red de TomTom, los incrementos obtenidos se sitúan en torno a 5% más (Tabla 22 y Tabla 23).

La población cubierta, según la red de transporte utilizada, muestra que, tanto en día laborable como el fin de semana, con la red de transporte privado se alcanzan valores en torno al 70%, cifra que se reduce, aproximadamente, al 35% con el transporte público. Esta reducción puede deberse a que algunos hospitales de referencia de las áreas de salud están alejados del tejido urbano y, en consecuencia, tienen una menor frecuencia de viajes en el transporte público.

Centrando el análisis en la red GTFS (Tabla 22), con un nuevo hospital los jueves queda cubierta una media del 35,8%. Esa cifra desciende al 34% en sábado. En cambio, los valores medios obtenidos para los hospitales de referencia actuales muestran una media del 30% de la población asignada los jueves y del 28% los sábados. Con el nuevo hospital, se logra cubrir, en promedio, un 6% más de población tanto en día laborable como en fin de semana.

Por su parte, con la red de transporte privado (Tabla 23), los jueves se cubre una media del 70,4% de la población. Los sábados, con el nuevo hospital de referencia se alcanza una media del 74,2%. Estas cifras comparadas con la media de demanda cubierta con los hospitales de referencia actuales, los jueves (67,5%) y los sábados (71,2%), reflejan un incremento medio, en ambos días, cercano al 3%.

Tabla 22. Población cubierta por hospitales de referencia actuales y con el nuevo hospital (Red GTFS)

Horas	Jueves					Sábado				
	Hospitales actuales		Con nuevo hospital			Hospitales actuales		Con nuevo hospital		
	Total	%	Total	%	Inc. %	Total	%	Total	%	Inc. %
<b>8:00</b>	1.016.852	31,5	1.194.455	37,1	17,5	867.947	26,9	1.064.720	33,0	22,7
10:00	955.799	29,7	1.143.571	35,5	19,6	905.577	28,1	1.074.488	33,3	18,7
12:00	938.328	29,1	1.130.135	35,1	20,4	905.718	28,1	1.111.903	34,5	22,8
14:00	945.720	29,3	1.140.874	35,4	20,6	942.585	29,2	1.119.795	34,7	18,8
16:00	979.203	30,4	1.156.255	35,9	18,1	914.683	28,4	1.097.980	34,1	20,0
18:00	976.903	30,3	1.166.165	36,2	19,4	921.602	28,6	1.109.648	34,4	20,4
20:00	976.169	30,3	1.159.040	36,0	18,7	944.284	29,3	1.123.623	34,9	19,0

Fuente: Elaboración propia.

Tabla 23. Población cubierta por hospitales de referencia actuales y con el nuevo hospital (Red TomTom)

Horas	Jueves					Sábado				
	Hospitales actuales		Con nuevo hospital			Hospitales actuales		Con nuevo hospital		
	Total	%	Total	%	Inc. %	Total	%	Total	%	Inc. %
<b>8:00</b>	2.128.474	66,0	2.231.957	69,2	4,9	2.334.512	72,4	2.414.716	74,9	3,4
10:00	2.182.031	67,7	2.271.915	70,5	4,1	2.320.608	72,0	2.400.964	74,5	3,5
12:00	2.180.984	67,7	2.272.187	70,5	4,2	2.304.307	71,5	2.384.997	74,0	3,5
14:00	2.217.936	68,8	2.304.962	71,5	3,9	2.311.864	71,7	2.392.607	74,2	3,5
16:00	2.201.700	68,3	2.290.408	71,1	4,0	2.325.907	72,2	2.406.635	74,7	3,5
18:00	2.125.254	65,9	2.216.679	68,8	4,3	2.294.923	71,2	2.377.281	73,8	3,6
20:00	2.214.585	68,7	2.299.592	71,3	3,8	2.293.204	71,1	2.375.600	73,7	3,6

Fuente: Elaboración propia.

La Figura 37 muestra la ubicación del nuevo hospital y los hospitales actuales, en el modelo obtenido con la red GTFS. El color gris del círculo representa los hospitales de las áreas de salud actuales, mientras que el color chocolate muestra la ubicación del nuevo hospital. El tamaño de los círculos indica la cantidad de la población asignada a cada hospital.

Limitando el análisis a la ubicación del nuevo hospital (círculo marrón), se observan cambios en su ubicación durante las horas 16 y 20 h (Figura 37). Los cambios en la ubicación óptima del nuevo hospital con la red GTFS son mínimos. En general, se

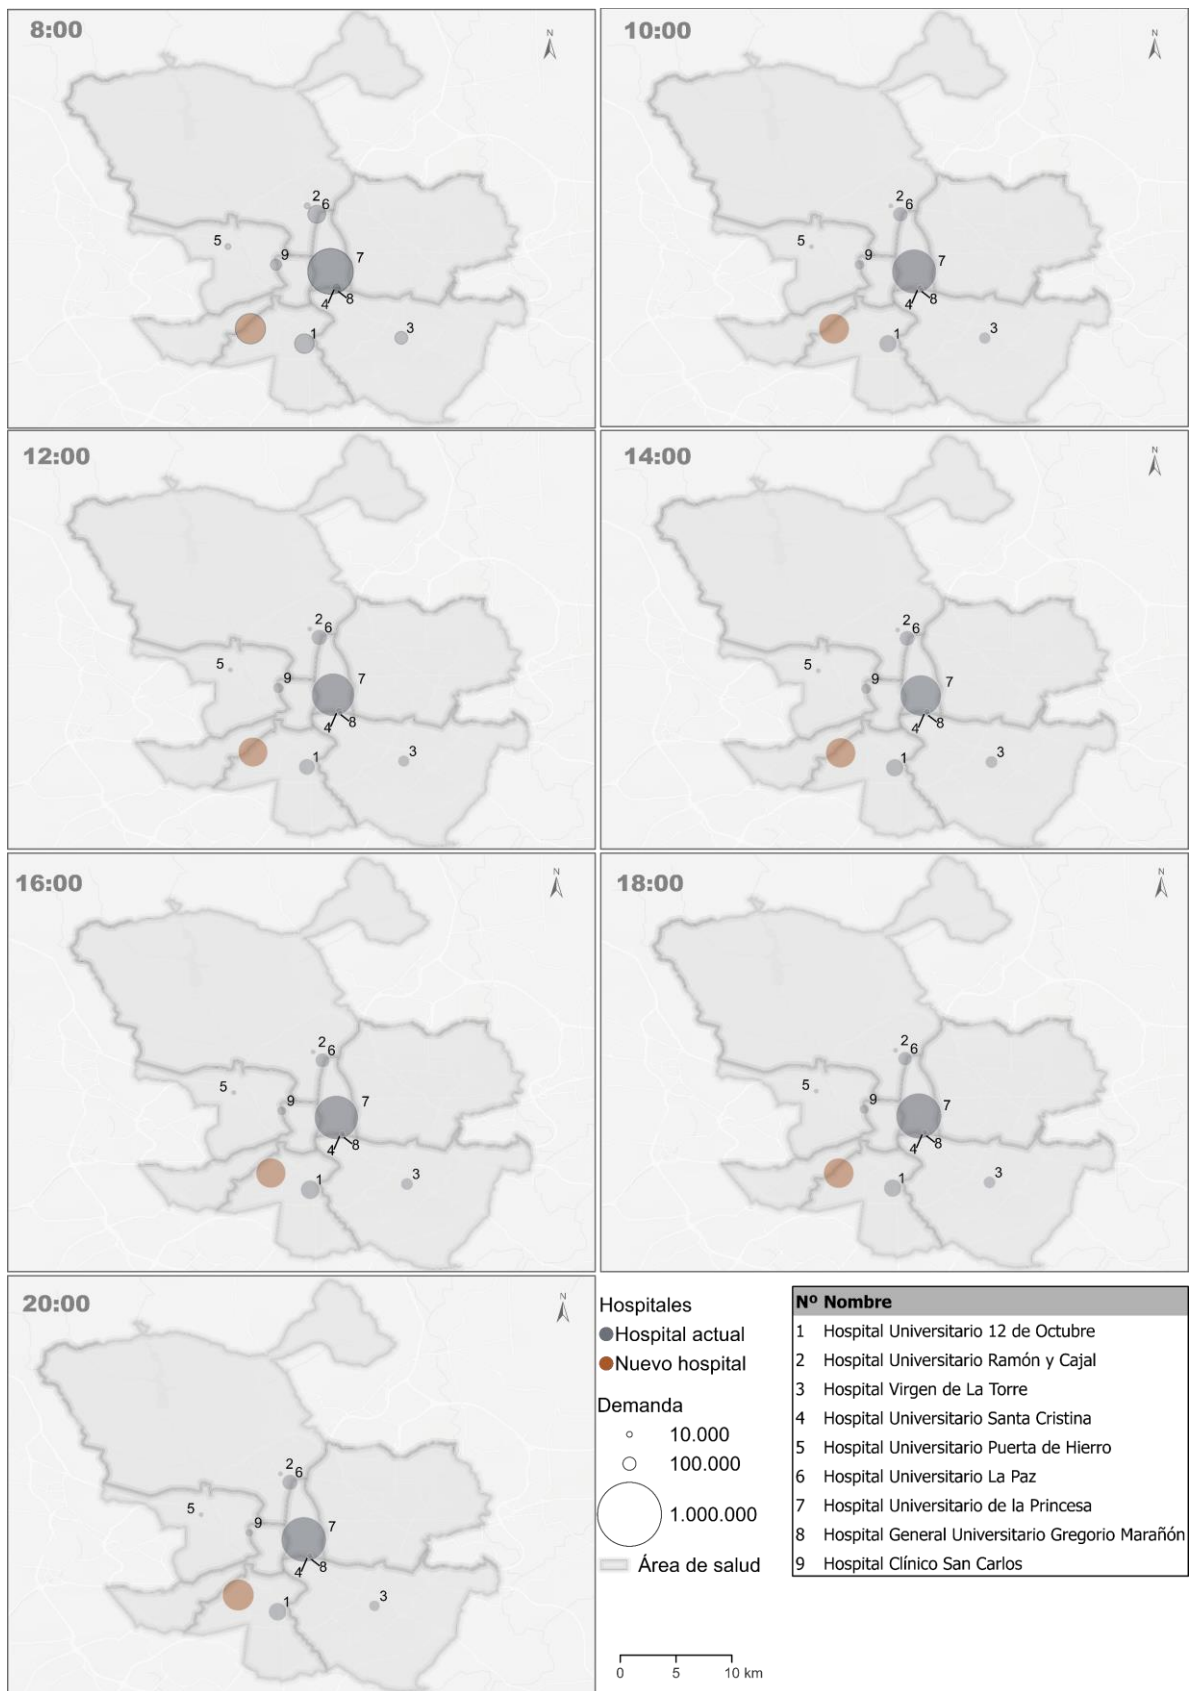
sitúa en el límite de las áreas de salud Sur II (A 11) y Centro-Oeste (A 07), una zona de alta densidad de población. En términos de demanda asignada, el nuevo hospital cubre más población que la mayoría de los hospitales actuales. Además, compite con el hospital de La Paz, restándole un porcentaje importante en su demanda. En todas las franjas horarias, el Hospital Universitario de La Princesa presenta los mejores niveles de cobertura debido a la mayor prestación del servicio de transporte en esta zona.

En el caso del modelo que utiliza la red TomTom, el nuevo hospital cambia de posición a las 8 y a las 12 h (Figura 38). Con la red de transporte privado, los cambios de ubicación del nuevo hospital son llamativos, pasando del área sanitaria Sur II (A 11) a las 8 h, cambiando de nuevo a las 12 h, esta vez al área sanitaria Centro-Norte (A 02). En el resto de las franjas horarias, el nuevo hospital se encuentra siempre en el área de salud Centro-Oeste (A 07). En el mapa de las 12 h se observa que el nuevo hospital resta demanda a casi todos los demás hospitales de referencia, cubriendo, prácticamente, la misma población que el Hospital Universitario 12 de Octubre. Este patrón puede estar relacionado con un mejor flujo vehicular hacia las áreas de salud Centro-Norte (A 02) y Sur II (A 11) durante esta franja horaria.

Al comparar los resultados de los modelos según la red usada (Figura 37 y Figura 38), se muestra la mejor accesibilidad a los hospitales en coche privado. Es llamativo el cambio en la demanda asignada al hospital Universitario 12 de Octubre, que multiplica por 10 la población cubierta en coche ya que con el transporte público tiene cubiertos unos 100.000 habitantes; y con la red de transporte privado alcanza el millón de habitantes en todas las franjas horarias.

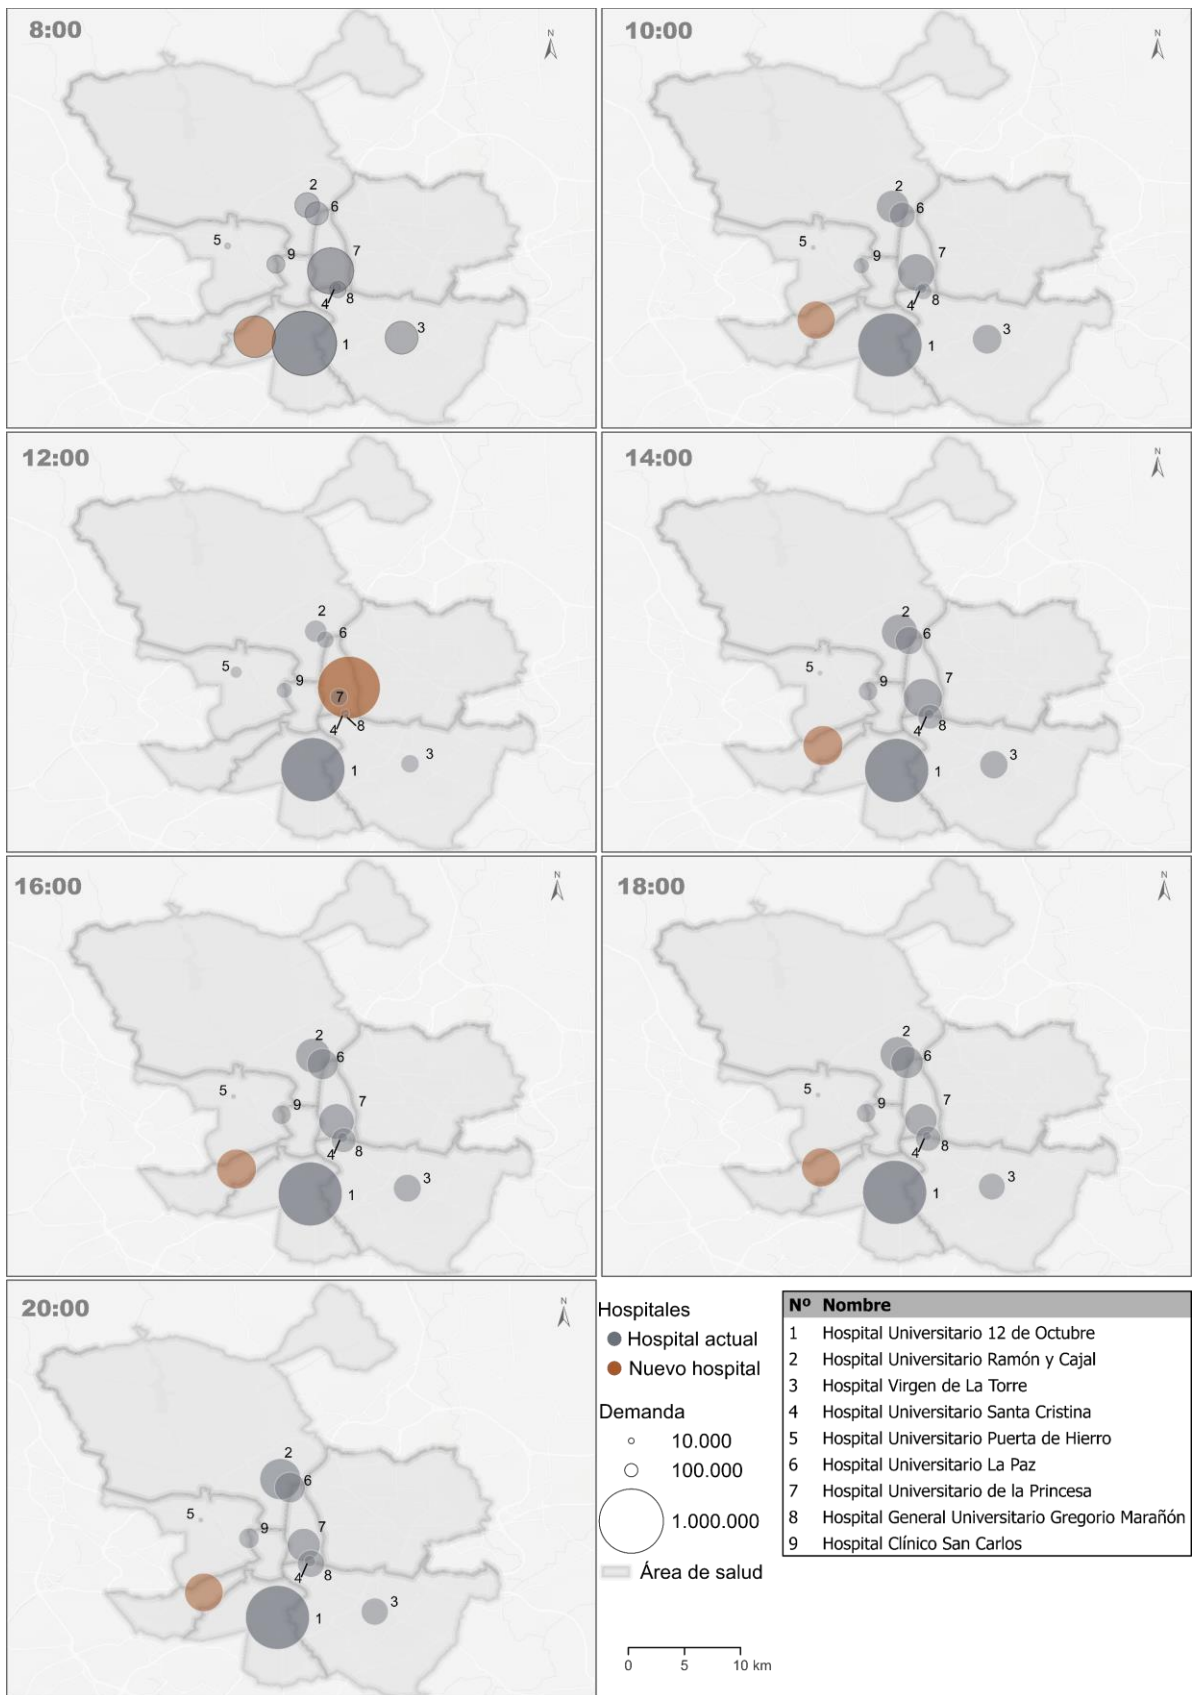
En cuanto a la ubicación del nuevo hospital, se observa como con ambas redes se sitúa casi siempre en el entorno de la zona Sur II y Centro-Oeste, excepto a las 12 horas que se localiza en el área sanitaria Centro-Norte cuando se utiliza la red TomTom.

Figura 37. Población cubierta por los hospitales de referencia y localización y cobertura del nuevo hospital (jueves - red GTFS)



Fuente: Elaboración propia.

Figura 38. Población cubierta por los hospitales de referencia y localización y cobertura del nuevo hospital (jueves - red TomTom)



Fuente: Elaboración propia.

#### 4.1.4 Aplicación a la localización de centros comerciales

Con la adopción de modernos estilos de vida, el mercado de las compras al por menor pasó de las pequeñas tiendas independientes a las grandes superficies (Cheng et al., 2007). Los centros comerciales reciben un considerable volumen de clientes, simultáneamente, generan empleos y producen divisas para los distintos negocios que albergan dentro de sus instalaciones. El área metropolitana de Madrid cuenta con una oferta variada de centros comerciales. La facilidad de acceso a estos comercios es fundamental para lograr que mucha gente acuda a sus tiendas y utilicen sus servicios.

Los centros comerciales requieren atraer más clientes ubicando, estratégicamente, sus establecimientos. De ahí que la facilidad de acceso en todos los modos de transporte público y privado se considere una de sus prioridades. Así, una mala selección de la localización de los centros comerciales acarrea consecuencias negativas a largo plazo, cuya rectificación no puede llevarse a cabo sin graves repercusiones financieras (Graig, 1984). La selección de ubicaciones adecuadas para los centros comerciales contribuye, significativamente, al éxito del negocio. Sin embargo, la presencia de negocios competidores, también, debe ser prevista.

En este sentido, Serra & ReVelle (1994), explican que los modelos de localización-asignación que implican instalaciones competidoras son aquellos en los que hay más de una empresa compitiendo por un mercado compartido, por lo que la localización de la nueva instalación afecta, no sólo a su cuota de clientes captada, sino también a la de su competidor.

El problema de la localización de las instalaciones que se reparten los clientes contempla la posibilidad de la competencia. Así, la nueva instalación a ubicar debe rivalizar con las ya existentes en el mercado (Shan et al., 2019). Al incorporarse otros establecimientos, se condiciona la cuota de negocio y los beneficios de los que ya conviven en el mercado (Lai et al., 2020). Los modelos de localización de puntos de venta en competencia buscan la mejor ubicación para uno o varios centros nuevos que compiten y maximicen la porción de clientes captados por los competidores.

Luego de la revisión de la literatura, nos encontramos con pocos estudios cuyos planteamientos tomen en consideración la competencia entre centros comerciales al momento de ubicarse en el mercado. Estos modelos de localización con presencia de competidores fueron introducidos por Hotelling (1929), quien consideró la ubicación

de dos tiendas competidoras en un mercado lineal. Según este trabajo, los usuarios acuden al local comercial más cercano. Por otro lado, Huff (1964), propone un modelo donde la probabilidad de que un usuario recurra a una instalación es proporcional a su atractivo e inversamente condicionada por la distancia a la misma. Considera características como el tamaño de la instalación y el tiempo de viaje. En esta línea, Nakanishi & Cooper (1974), desarrollaron un modelo gravitacional complejo, que agregaba la importancia de la instalación junto con el tamaño, la disponibilidad de estacionamientos y otras cualidades como indicadores de su atractivo.

Los modelos de localización basados en la competencia se extendieron a problemas prácticos. Por ejemplo, en la búsqueda de la ubicación óptima de tiendas de muebles y ropa (Huff, 1964), centros comerciales (T. Drezner & Drezner, 2002) y para la hostelería (Drezner, 2010). Encontramos estudios que implementaron los modelos competitivos para localizar comercios de comestibles (Bell et al., 1998).

Por otro lado, existen trabajos que utilizan el modelo de maximización de la cuota de mercado compartido aplicado a encontrar la mejor localización de centros comerciales en presencia de competidores (Ahmad et al., 2017; Ahmadi & Ghezavati, 2020; Lai et al., 2020). Asimismo, Banerjee et al., (2020) emplean la solución de maximizar el mercado compartido para identificar la ubicación óptima de las estaciones en un sistema de bicicletas compartidas. En su trabajo, recurren a los datos registrados por los dispositivos GPS instalados en las bicicletas, la red de calles, la población y los puntos de interés.

Cabe resaltar que, hasta el momento de la revisión de la literatura, no logramos encontrar estudios de localización de centros comerciales donde se utilicen fuentes de *Big Data* para analizar el dinamismo de la demanda y de la red de transporte.

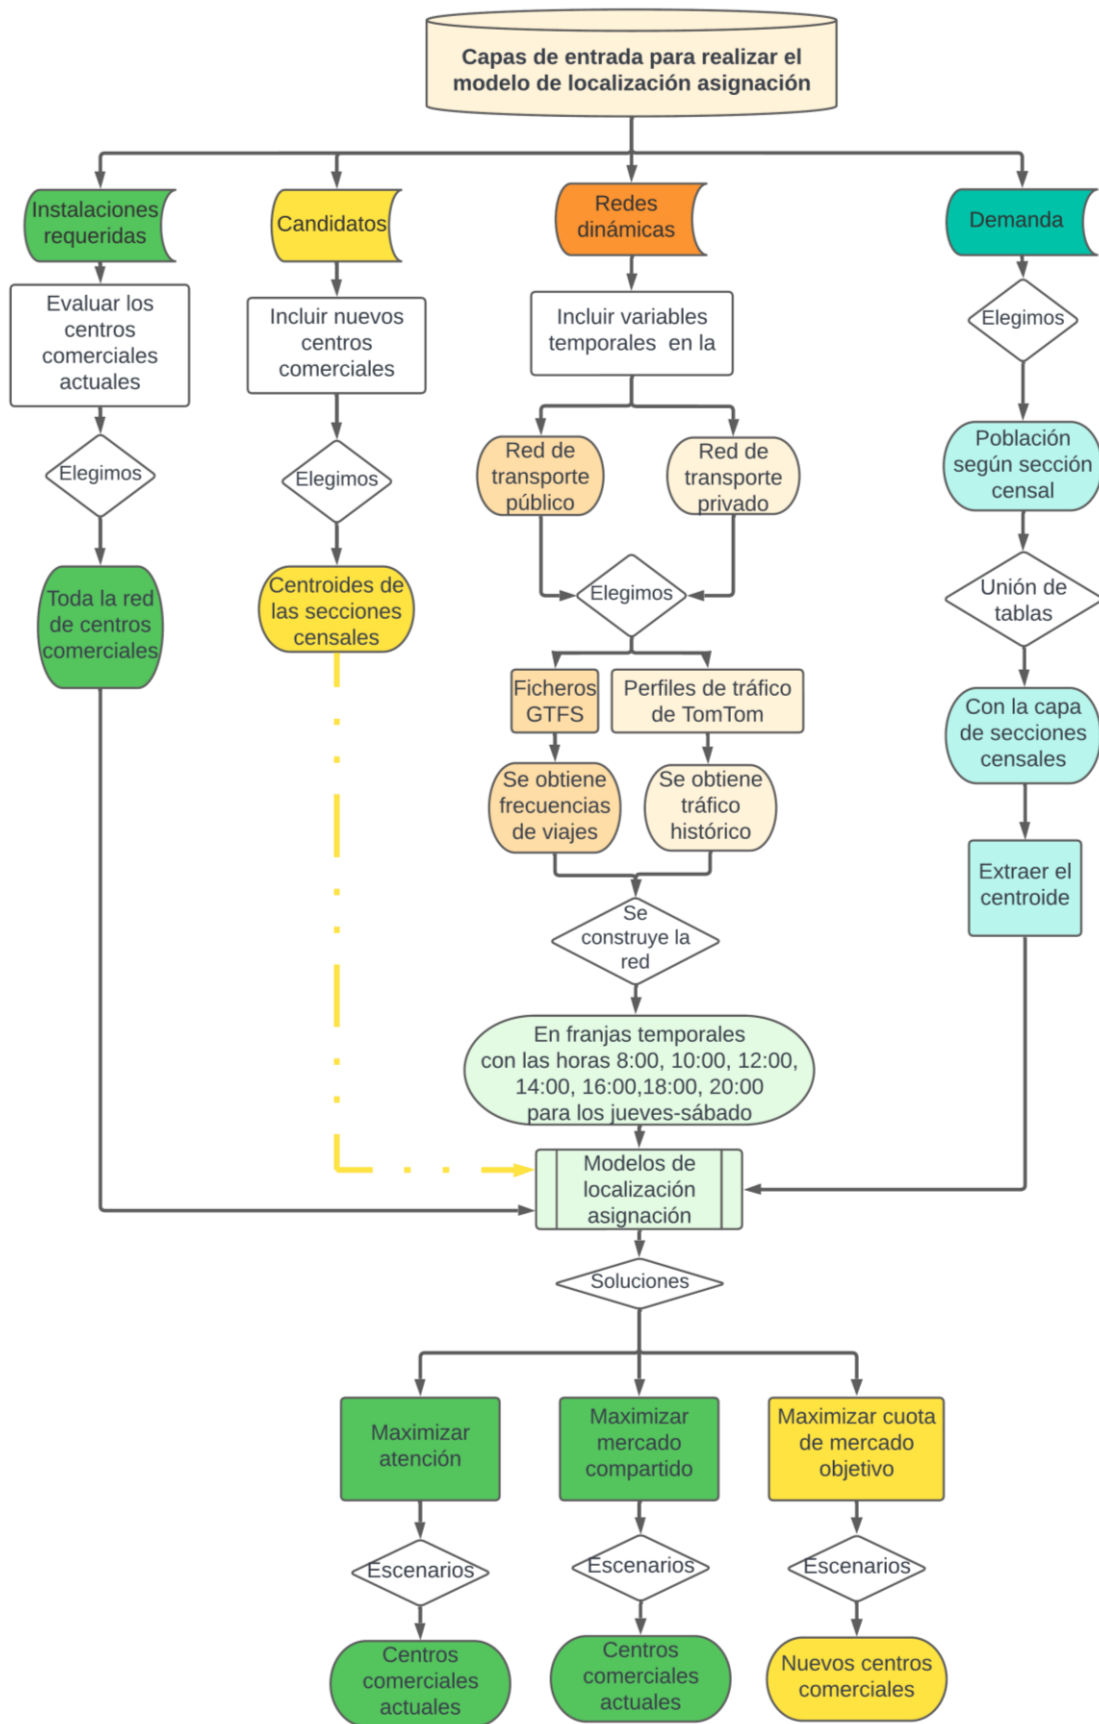
Para el desarrollo de este caso de estudio utilizamos la solución maximizar la asistencia, con el objetivo de evaluar el efecto de los cambios en la frecuencia del transporte público y los niveles de congestión sobre la cantidad de demanda que pueden cubrir los centros comerciales. Además, implementamos las soluciones maximizar mercado compartido y maximizar cuota de mercado objetivo, con el fin de analizar la cobertura de la demanda en presencia de competidores, incorporando nuevos centros comerciales a los existentes.

#### 4.1.5 Metodología utilizada para el desarrollo del modelo de evaluación de la localización de centros comerciales

En esta investigación también realizamos MLA para evaluar el efecto de los cambios en las frecuencias del transporte público y la congestión sobre la demanda atendida por los centros comerciales actuales del área metropolitana de Madrid. Además, proponemos encontrar la mejor ubicación para los nuevos centros comerciales utilizando las redes de transporte público y privado (Figura 39). Empleamos los centros comerciales actuales del área metropolitana de Madrid como instalaciones requeridas y su superficie bruta alquilable (SBA) como parámetro de atracción. En el caso del modelo para añadir nuevos centros comerciales, se toman como candidatos los centroides de las secciones censales.

Los puntos de demanda se obtienen a partir de los centroides correspondientes a las secciones censales. Estas secciones incluyen un campo que contiene la población empleada para ponderar el peso de la demanda. El límite de tiempo de viaje usado en los modelos fue de 10 minutos desde los puntos de demanda hasta los sitios candidatos. Para la elección de este tiempo se toma como referencia un estudio de Gutiérrez Puebla & Chicharro Fernández, (2003). Según estos autores, el tiempo medio de acceso hacia algunos centros comerciales es de 11 minutos. Las soluciones aplicadas fueron maximizar la asistencia, maximizar cuota de mercado compartido y maximizar cuota de mercado objetivo. Las dos últimas son soluciones muy empleadas para encontrar instalaciones donde es necesario considerar las características de los competidores (Banerjee et al., 2020; T. Drezner, 2011).

Figura 39. Metodología para el desarrollo del modelo de centros comerciales



Fuente: Elaboración propia.

El modelo con centros comerciales se desarrolló en tres fases. En primer lugar, implementamos la solución de maximizar la asistencia para dos días específicos (jueves y sábado) en varias franjas horarias: 8, 10, 12, 14, 16, 18 y 20 h (en el modelo con los hospitales, se explica por qué elegimos esos días y horas) para evaluar el impacto, de las diferentes frecuencias del transporte público y de la congestión vehicular sobre la población asignada a cada centro comercial en varios momentos del día.

En segundo lugar, se utilizó la solución maximizar cuota de mercado compartido, utilizando parámetros similares a los empleados en el modelo anterior (los mismos candidatos, demanda, días, horas, redes y umbral de 10 minutos). El único parámetro utilizado distinto con la solución de maximizar cuota de mercado compartido fue la superficie bruta alquilable de cada centro comercial. Dicha superficie representa el criterio de atracción utilizado en el modelo.

En tercer lugar, la solución de cuota de mercado objetivo se aplica para los jueves y sábados, pero solo en la franja horaria de las 18 horas. Se ha elegido la hora de las 18 h porque, según los gráficos de Google Maps realizados a partir de las visitas a los centros comerciales es el momento donde la población tiene la costumbre de acudir a estos establecimientos comerciales.

Para ejecutar el modelo de cuota de mercado objetivo se han utilizado los centros comerciales actuales como sitios requeridos y los centroides de las secciones censales como candidatos. Los puntos de demanda y el umbral de tiempo de viaje (10 minutos) empleados son los mismos que adoptamos con la solución de maximizar cuota de mercado.

La solución de cuota de mercado objetivo se utilizó para analizar el número mínimo de centros comerciales necesarios en el área metropolitana de Madrid, para cubrir un cuatro por ciento adicional del conseguido con la solución de maximizar cuota de mercado compartido. Además, se ejecutó utilizando la red en transporte público y privado.

#### 4.1.6 Resultados

En este apartado se resumen los resultados derivados del MLA con los centros comerciales del área metropolitana de Madrid. Para empezar, se presentan los

resultados obtenidos al aplicar la solución de maximizar la asistencia. Después, se muestran los resultados derivados de la solución de maximizar la cuota de mercado. Por último, se detallan los resultados conseguidos mediante la solución de maximizar la cuota de mercado objetivo.

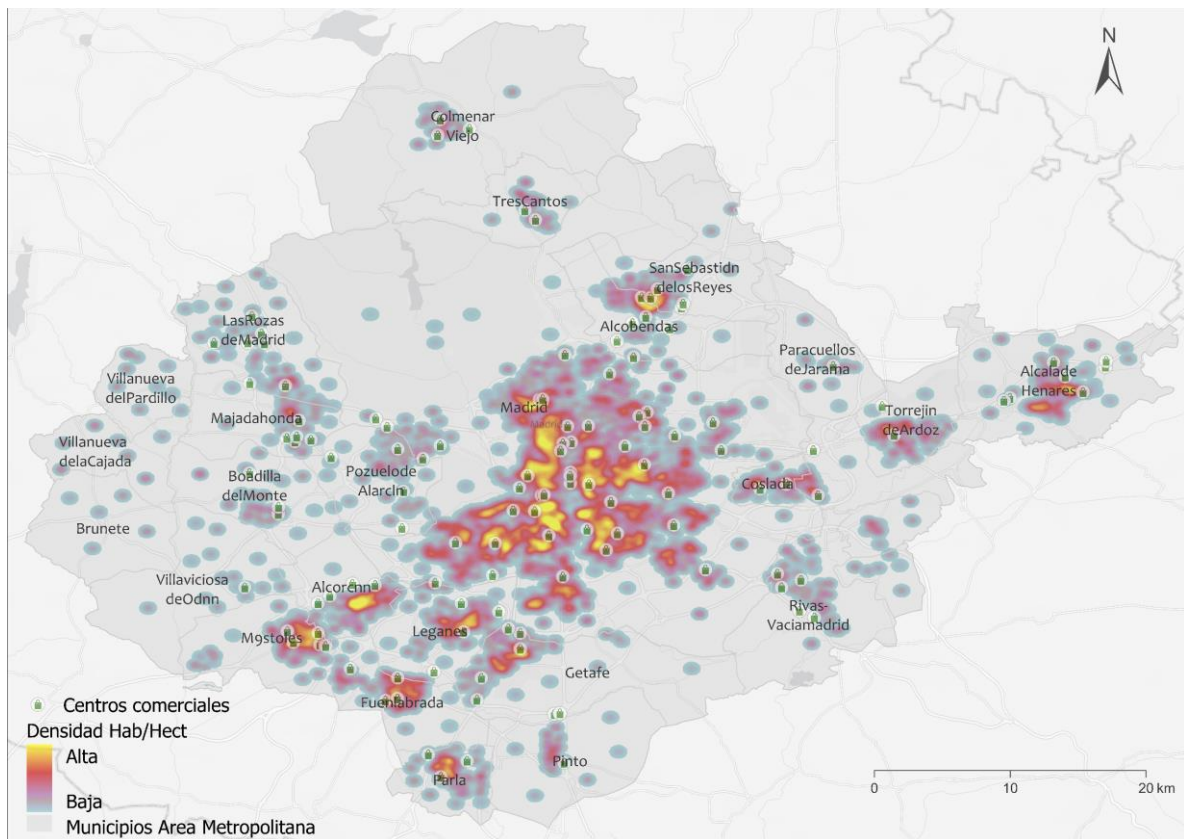
#### *4.1.6.1 Demanda cubierta por los centros comerciales*

Se implementa un MLA para evaluar la ubicación de los centros comerciales dentro del área metropolitana de Madrid. Este modelo incluye el dinamismo de la red del transporte público creada a partir de archivos GTFS y la red de transporte privado creada con los datos que se obtienen de la empresa TomTom.

La Figura 40 ilustra la distribución de los centros comerciales y la densidad de población derivada de los centroides de las secciones censales. Los puntos de mayor concentración de la demanda están localizados, sobre todo, en la parte central de municipio de Madrid, específicamente, en los distritos de: Arganzuela (Barrios Chopera, Delicias, Acacias), Centro (Barrios Embajadores y Universidad), Chamberí (Barrios Trafalgar, Arapiles, Gaztambide), Ciudad Lineal (Barrios Ventas y Pueblo Nuevo), Salamanca (Barrios Goya, Lista, Fuente del Berro) y Tetuán (Barrios Cuatro Caminos, Bellas Vistas y Berruguete). También se observan otros focos de concentración de la población en Alcalá de Henares, al sur y sur-oeste del área metropolitana de Madrid en Móstoles, Alcorcón, Leganés, Fuenlabrada y Parla.

La Tabla 24 contiene la demanda cubierta por la red de centros comerciales del área metropolitana de Madrid en las diversas franjas horarias, utilizando la red GTFS de transporte público. Se observa que la población asignada alcanza apenas el 5%, los jueves y los sábados en un tiempo de viaje de 10 minutos. Los datos indican una baja cobertura de los centros comerciales en el acceso en transporte público, debido a que cerca del 95% de la población queda sin asignar a ningún centro comercial. En general, los resultados muestran diferencias mínimas entre los días y las franjas horarias estudiadas.

Figura 40. Densidad de población a partir de los centroides de secciones censales



Fuente: Elaboración propia.

Tabla 24. Población cubierta por los centros comerciales (GTFS)

Horas	Jueves 10 minutos				Sábado 10 minutos			
	Total	%	Inc.	Inc%	Total	%	Inc.	Inc%
8:00	296.797	5,1	3.185	1,1	276.739	4,8	-6.305	-2,2
10:00	292.228	5,1	-1.385	-0,5	282.897	4,9	-147	-0,1
12:00	293.645	5,1	32	0,0	280.014	4,8	-3.031	-1,1
14:00	288.254	5,0	-5.358	-1,8	286.619	5,0	3.575	1,3
16:00	290.517	5,0	-3.096	-1,1	286.474	5,0	3.429	1,2
<b>18:00*</b>	293.613	5,1	0	0,0	283.044	4,9	0	0,0
20:00	291.766	5,0	-1.847	-0,6	284.812	4,9	1.767	0,6

\*Hora de referencia. Fuente: Elaboración propia.


Para explicar los cambios en la población cubierta según franjas horarias (Tabla 24), hemos utilizado la franja horaria de las 18 horas como referencia de comparación. Hemos elegido esta hora de referencia basándonos en los gráficos de Google Maps que muestran las horas más populares de visita a los centros comerciales. Al analizar los jueves, notamos que se produce un ligero descenso en casi todas las franjas

horarias, destacando el valor más bajo a las 14, con un - 1,8%. Mientras que los sábados se muestran aumentos en algunas de las franjas horarias, siendo el valor más alto, nuevamente, a las 14 h (1,3%).

La causa de los valores tan bajos en la población asignada y las pocas diferencias mostradas por los datos puede guardar relación con lo alejado que están los centros comerciales de las principales rutas del transporte público, y a que con frecuencia los centros están desvinculados del tejido urbano (Gutierrez Puebla & Chicharro Fernandez, 2003).

La Figura 41 muestra los perfiles de distribución de la demanda, los jueves y sábados, en las diferentes franjas horarias usando la red GTFS. El eje horizontal representa las diferentes franjas horarias estudiadas, mientras que el eje vertical indica la cantidad de población asignada a los centros comerciales. Se deduce que los jueves hay una mayor cobertura de la demanda en las primeras horas del día (mayor frecuencia de viajes en transporte público, aunque a las 8 h los centros comerciales están cerrados). Después, la cobertura desciende a las 10 h, recuperándose en las horas 12 y 18, lo que coincide con una hora popular de visita a los centros comerciales. Los sábados, la cobertura es menor en las primeras horas del día (debido a la baja frecuencia de viajes en transporte público), con los valores más altos a las 14, 16 y 18 horas. Estas horas coinciden con los horarios en los que la población de Madrid acostumbra a visitar los centros comerciales los fines de semana. En general, con el uso del transporte público (red GTFS) los jueves la población asignada a los centros comerciales es mayor en comparación a los sábados.

Figura 41. Población cubierta por la red de centros comerciales según red GTFS



Fuente: Elaboración propia.

Al explorar los resultados obtenidos con la red TomTom (Tabla 25) observamos que la demanda cubierta los jueves y sábados es superior al 40% en todas las horas estudiadas. Los jueves, a las 14 horas, los centros comerciales cubren el 45,2% de la población. Este mayor porcentaje está relacionado con una menor congestión en esta hora. Los sábados la mejor cobertura se produce a las 8 horas con, aproximadamente, el 50% de la población asignada.

Esta cifra alcanzada los fines de semana se debe a la baja congestión del tráfico en las primeras horas de los sábados. Por otro lado, el porcentaje promedio de la población asignada los jueves es del 43,5%, mientras que los sábados la media es del 47,1%. Si comparamos la media de ambos días, podemos manifestar que los sábados se recibe un 3,6% más de personas (211.860 clientes).

Tabla 25. Población cubierta por la red de centros comerciales (TomTom)

Horas	Jueves 10 minutos				Sábado 10 minutos			
	Total	%	Inc.	Inc%	Total	%	Inc.	Inc%
8:00	2545710	44,0	187903	8,0	2854740	49,4	147822	5,5
10:00	2561573	44,3	203766	8,6	2792994	48,3	86076	3,2
12:00	2511807	43,5	154000	6,5	2723667	47,1	16749	0,6
14:00	2609816	45,2	252008	10,7	2768109	47,9	61192	2,3
16:00	2607240	45,1	249432	10,6	2826189	48,9	119271	4,4
<b>18:00</b>	2357807	40,8	0	0,0	2706918	46,8	0	0,0
20:00	2508156	43,4	150349	6,4	2693500	46,6	-13418	-0,5

Fuente: Elaboración propia.

Para comparar la evolución en la cobertura de la población a lo largo del día (Tabla 25), se ha elegido la franja horaria de las 18 horas como valor de referencia, observándose que los jueves, a las 14 y a las 16 horas, se produce el incremento más significativo en el número de población atendida (10,7% y 10,6%, respectivamente). Centrándonos en los datos del sábado, el incremento porcentual es más significativo (5,5% en la población asignada) y se produce en la franja horaria de las 8 horas. Por otra parte, la hora 16 registra un aumento de más del 4% en la cobertura, una hora de la tarde donde la población frecuenta los centros comerciales durante los fines de semana.


La Figura 42 muestra los perfiles de población asignada, los jueves y los sábados, en las diferentes franjas horarias empleando la red TomTom. Los sábados existe una

mayor cobertura en comparación con los jueves. Los sábados, en las franjas horarias de las 8 y las 16 h, hay la mayor población cubierta, mientras a las 18 h, la congestión aumenta y provoca una disminución de la población asignada a los centros comerciales en esa franja de 10 minutos.

Por otro lado, los jueves, los valores más destacados se encuentran a las 14 y a las 16 h (Figura 42), lo que indica un menor tráfico de vehículos en esas franjas horarias. Mientras tanto, se produce un valle a las 18 h, es un momento de considerable volumen de tráfico en la ciudad de Madrid, según los datos de tráfico almacenados por la empresa TomTom.

De forma global, comparando GTFS y TomTom, se evidencian grandes diferencias en la población cubierta. Nótese que, con el transporte público, los fines de semana se tiene menor cobertura de la demanda. En cambio, con la red TomTom sucede todo lo contrario, pues los sábados se siente menos el efecto de la congestión vehicular, y la demanda se incrementa con respecto al jueves. (Tabla 26). Además, la baja congestión vehicular existente los fines de semana, sobre todo a las horas 14 y 16 h, puede ser aprovechada por la población para visitar los centros comerciales para comprar o hacer uso de los restaurantes.

Figura 42. Población cubierta por la red de centros comerciales según red TomTom



Fuente: Elaboración propia.

Tabla 26. Diferencias en la población cubierta entre el sábado y jueves (sábado-jueves)

Horas	GTFS		TomTom	
	Total	%	Total	%
8:00	-20.058	-6,8	309.030	12,1
10:00	-9.331	-3,2	231.421	9,0
12:00	-13.631	-4,6	211.860	8,4
14:00	-1.635	-0,6	158.294	6,1
16:00	-4.043	-1,4	218.949	8,4
<b>18:00</b>	-10.568	-3,6	349.111	14,8
20:00	-6.954	-2,4	185.344	7,4

Fuente: Elaboración propia.

Los mapas (Figura 43 y Figura 44) muestran los resultados de la población cubierta por centro comercial, en las diferentes franjas horarias y sus cambios porcentuales. Estos porcentajes resultan al tomar como referencia la demanda existente en la franja horaria de las 18 horas y así analizar el aumento o disminución porcentual de las asignaciones horarias de los jueves y sábados con las dos redes utilizadas.

Para presentar una mejor visualización, solo representamos las 18 y las 12 horas de los sábados. El tamaño de los círculos refleja la cantidad de población asignada a cada centro comercial a las 18 h, mientras que los tonos rojos indican cambios entre las 12 y las 18 h.

La Figura 43 revela que, al utilizar la red GTFS, la mayoría de los centros comerciales presentan cambios al compararlos con la hora de referencia (18 h). La franja de las 18 nos muestra algunos centros comerciales que cubren grandes volúmenes de población, ejemplos de ellos son, el centro comercial Dos de Mayo, Arenal 9, El Jardín de Serrano, y otros más. Los sábados se observa que, al mediodía, muchos de los centros comerciales presentan pérdidas en la demanda captada, en comparación con las 18 h, especialmente, los centros comerciales ubicados en la periferia y el centro del área metropolitana. Ejemplos de centros comerciales afectados por las variaciones en la frecuencia del transporte público al mediodía, son: Ecomóstoles Centro, Arenal 9 y El Jardín de Serrano.

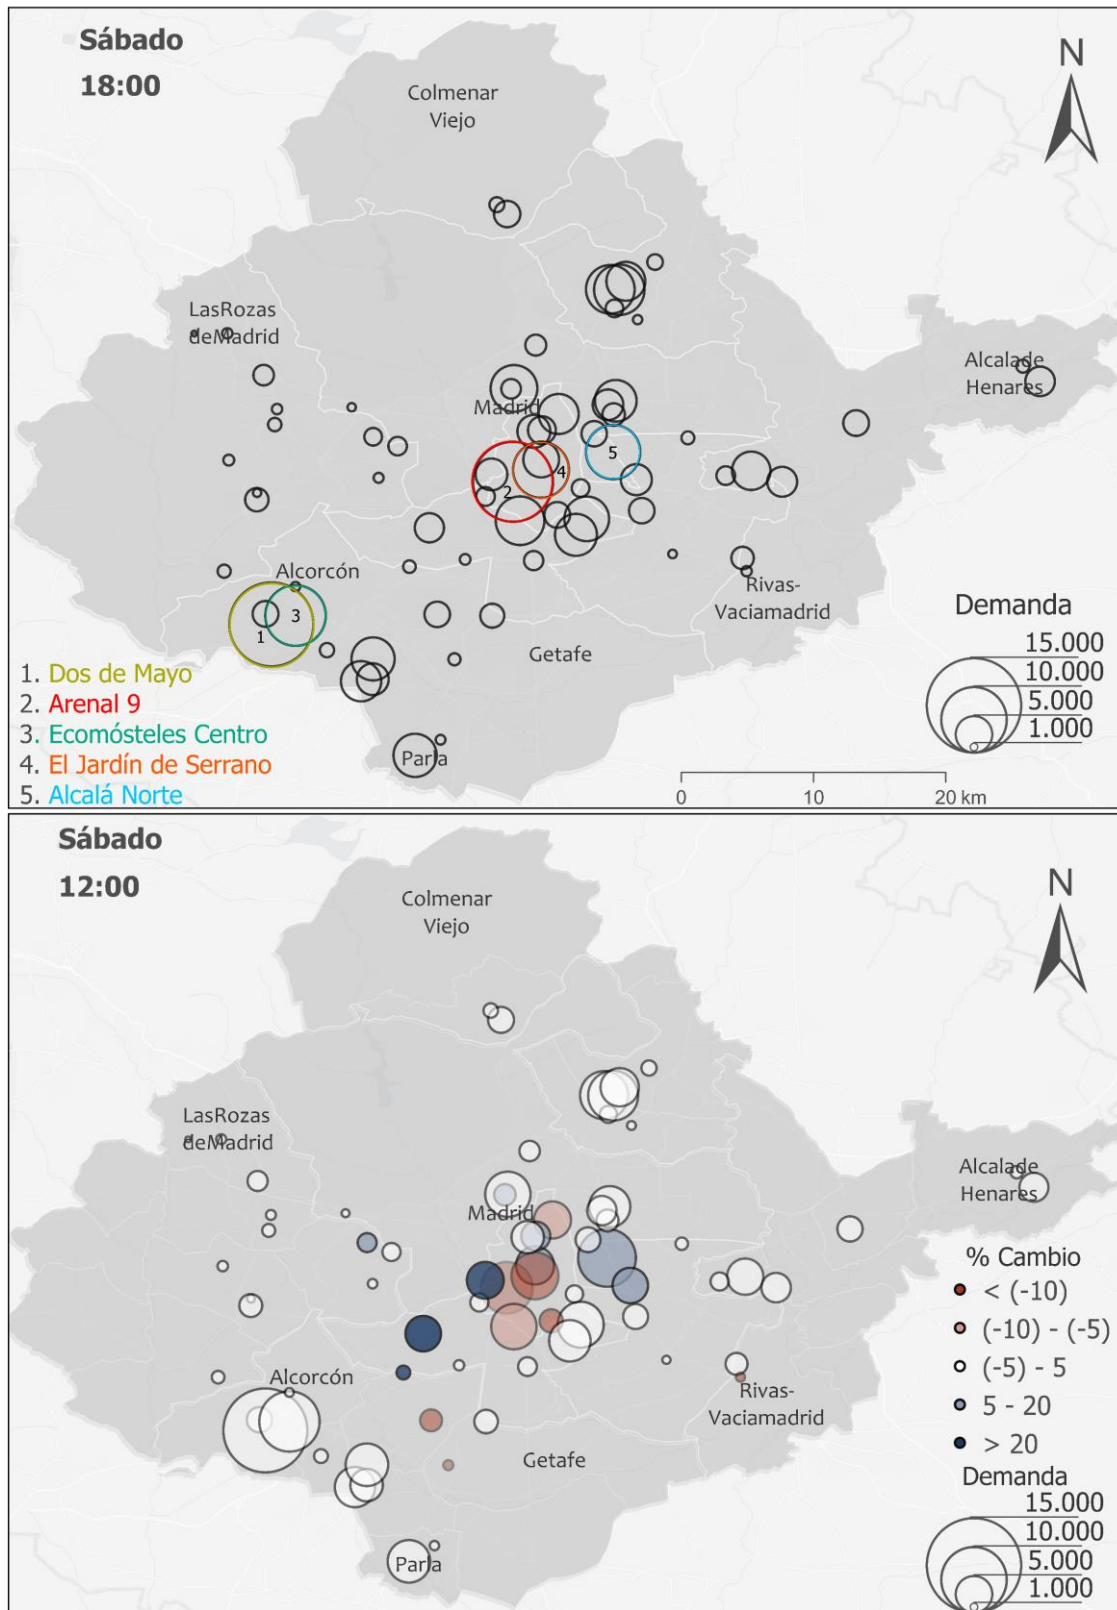
Los sábados, los centros comerciales que consiguen una mayor asignación de población, son: el Dos de Mayo, Arenal 9, Ecomóstoles Centro, El Jardín de Serrano y Alcalá Norte. Este comportamiento puede estar relacionado con la buena

conectividad con el transporte público (mayor frecuencia de viajes y rutas) entre los lugares de demanda y los centros comerciales.

También se analiza el comportamiento de la demanda del transporte privado (red TomTom), tomando como referencia nuevamente la franja horaria de las 18 horas para estudiar el porcentaje de cambio en la demanda que se cubre en las otras franjas horarias. La Figura 44 muestra que los sábados, al mediodía, muchos centros comerciales registran variaciones porcentuales positivas. Estos porcentajes obedecen a que la población asignada es mayor los fines de semana y al momento en que la población visita con más frecuencia los centros comerciales. Además, debido a la ubicación de los centros comerciales (fuera de las zonas centrales), estos sufren más los efectos de la congestión que experimenta la ciudad en días laborables durante las horas punta de la tarde.

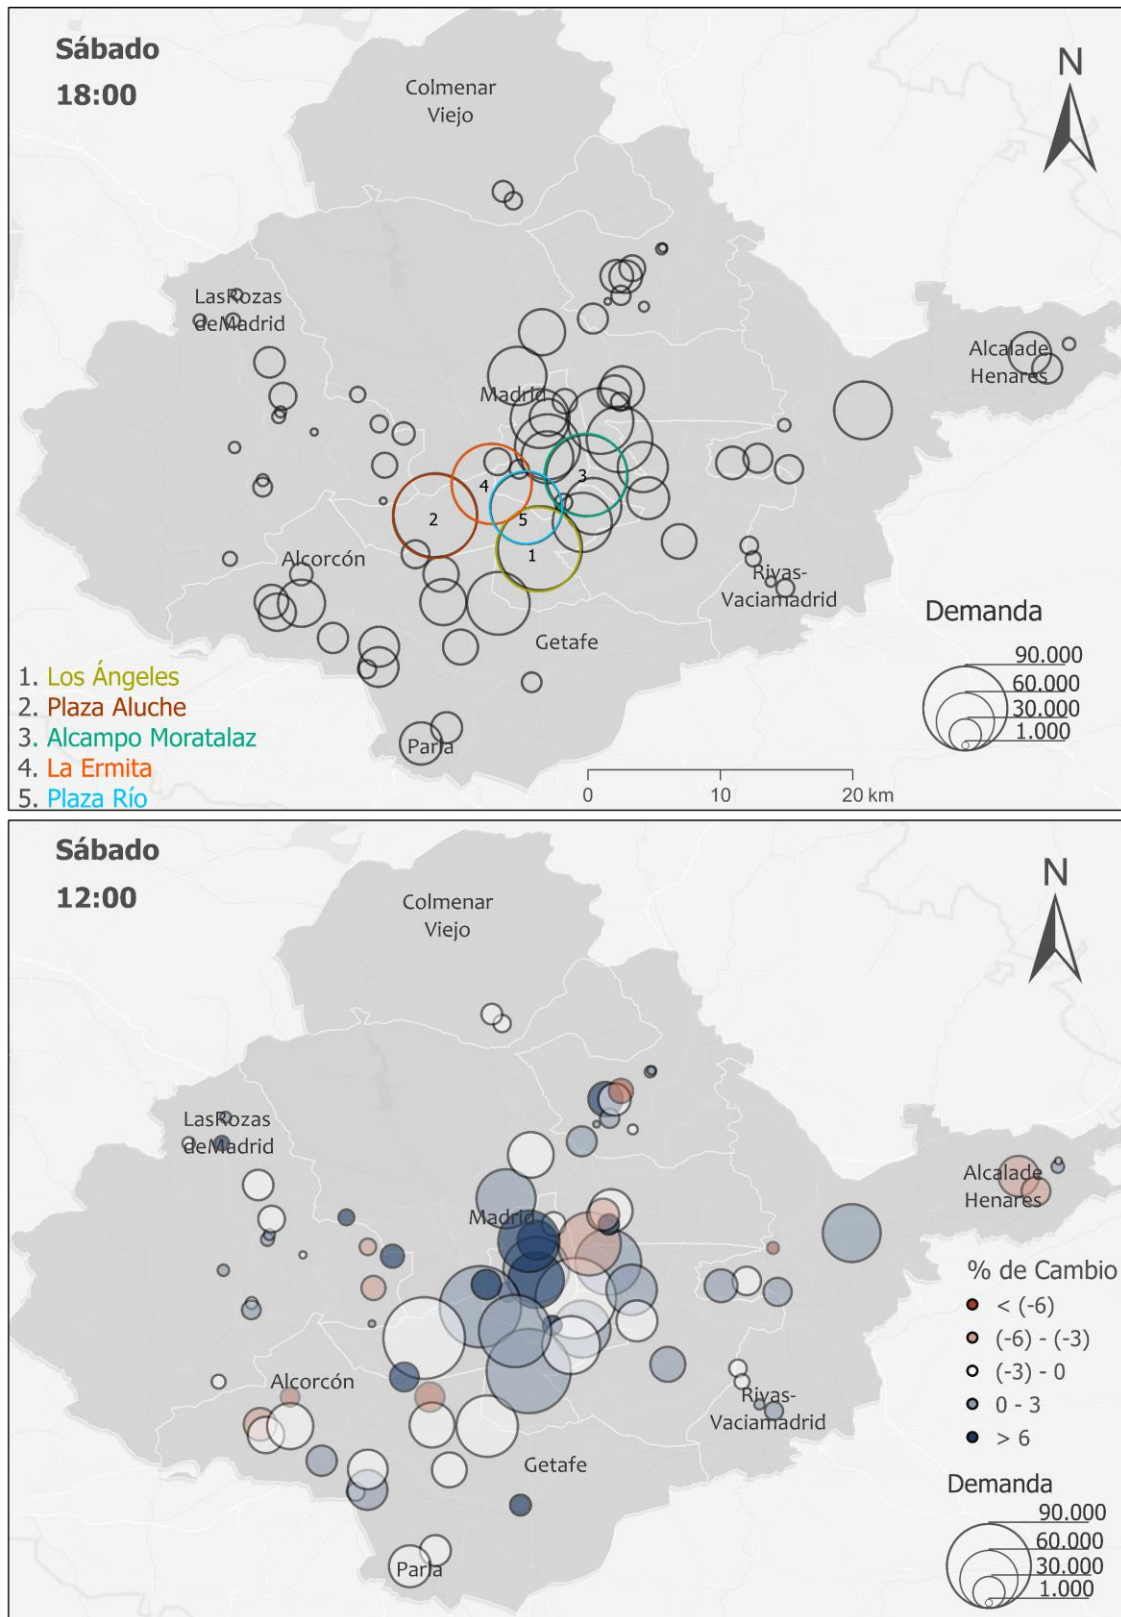
En relación con la demanda cubierta, los centros comerciales más favorecidos en ambas franjas horarias son: Los Ángeles, Plaza Aluche, Alcampo-Moratalaz, La Ermita y Plaza Río (Figura 44). Estos centros comerciales están rodeados por los distritos de Arganzuela, Usera, Retiro, Moratalaz, Villaverde y Carabanchel, donde existe una alta densidad de población. Cabe añadir que estos centros comerciales, con mayor población asignada, presentan las siguientes particularidades: se sitúan en la periferia de la Almendra Central del Municipio de Madrid, están muy próximos a la autopista M30 y se encuentran alejados de las zonas de alta congestión de tráfico de los distritos Centro y Salamanca. Estas particularidades pueden guardar relación con la gran cobertura que tienen estos centros comerciales los sábados a las 18 horas, coincidiendo con una franja horaria en la que un volumen considerable de la población acude a los centros comerciales madrileños.

Figura 43. Población cubierta y porcentaje de cambio entre las 12 y las 18 horas (GTFS)



Fuente: Elaboración propia.


Figura 44. Población cubierta y porcentaje de cambio entre las 12 y las 18 horas (TomTom)



Fuente: Elaboración propia.

En la Figura 45 se muestra la demanda media por día, hora y red. Al comparar la red GTFS con la red TomTom, se observan diferencias en la cobertura media de la población asignada. Por ejemplo, con la red de transporte público, los jueves, existe más población asignada que los sábados, aunque la demanda media resulta similar en todas las franjas. En cambio, con la red TomTom ocurre lo contrario, pues, los sábados se asigna más población que los jueves, cubriendo una media de casi 30.000 habitantes en los distintos momentos. Si comparamos los resultados obtenidos con ambas redes, se observa que la media de población asignada a los centros comerciales es mucho mayor con el transporte privado.

Figura 45. Promedio de población cubierta según horas



Fuente: Elaboración propia.

4.1.6.2 Población asignada a los centros comerciales usando la solución “Maximizar cuota de mercado compartido”

Empleamos la solución “maximizar cuota de mercado compartido” con el objetivo de evaluar el impacto de los cambios, en las frecuencias del transporte público y de la congestión del transporte privado, en la cuota de demanda asignada a los centros comerciales en presencia de competidores.

La solución maximizar cuota de mercado compartido busca captar la máxima porción de mercado a partir de un conjunto determinado de instalaciones. En este sentido, la cuota de mercado total es la suma de todo el peso de la demanda para los puntos de

demanda válidos. La solución cuota de mercado es un modelo gravitatorio que para asignar la demanda a cada localización necesita información tanto de la importancia (peso) de las instalaciones propias de la empresa, como el peso de las instalaciones de los competidores (ESRI). De acuerdo con esta solución, la población de una sección censal no se asigna a un único centro, lo que hace es repartir la población de las secciones entre los centros cercanos en función de la distancia a los mismos y de su tamaño.

La solución cuota de mercado compartido la desarrollamos con los centros comerciales existentes (candidatos obligatorios) y los centroides de las secciones censales del área metropolitana de Madrid (demanda). El modelo de localización-asignación se realizó con la red de transporte público (GTFS) y transporte privado (TomTom).

Nuevamente, se formulan escenarios dinámicos en el tiempo, seleccionando dos días de la semana (jueves y sábados) y varias franjas horarias (8, 10, 12, 14, 16, 18, 20 h). Se establece como parámetro de impedancia un tiempo de 10 minutos de recorrido. La ponderación de atracción de los centros comerciales utilizada fue la superficie bruta alquilable (SBA), que es un indicador habitual del tamaño de los centros comerciales, mientras que para la demanda el peso lo otorga la cantidad de población de cada sección censal.

La Tabla 27 resume los resultados del modelo haciendo uso de la red GTFS. A efectos de claridad explicamos el significado de cada una de las columnas de la tabla. La primera columna muestra las horas utilizadas para correr los modelos de localización-asignación. La segunda y sexta columna contiene la cantidad de población asignada los jueves y sábados. La tercera y séptima columna muestra el porcentaje de población asignada con respecto a la población total obtenida del padrón del año 2020 (5.779.974 habitantes). Por último, la cuarta, quinta, octava y novena columnas indican el incremento absoluto y el incremento porcentual respecto a la hora de referencia (18 h).

Se notó que los jueves la población asignada es mayor en comparación a los sábados. Se observó que las horas 16 y 20 son las que registraron menores valores respecto a la hora de referencia; mientras que, el resto de las horas se capta mayor demanda. Al

poner el foco sobre el sábado, se observa que los porcentajes de incremento en todas las horas fueron valores negativos, salvo a las 14 h.

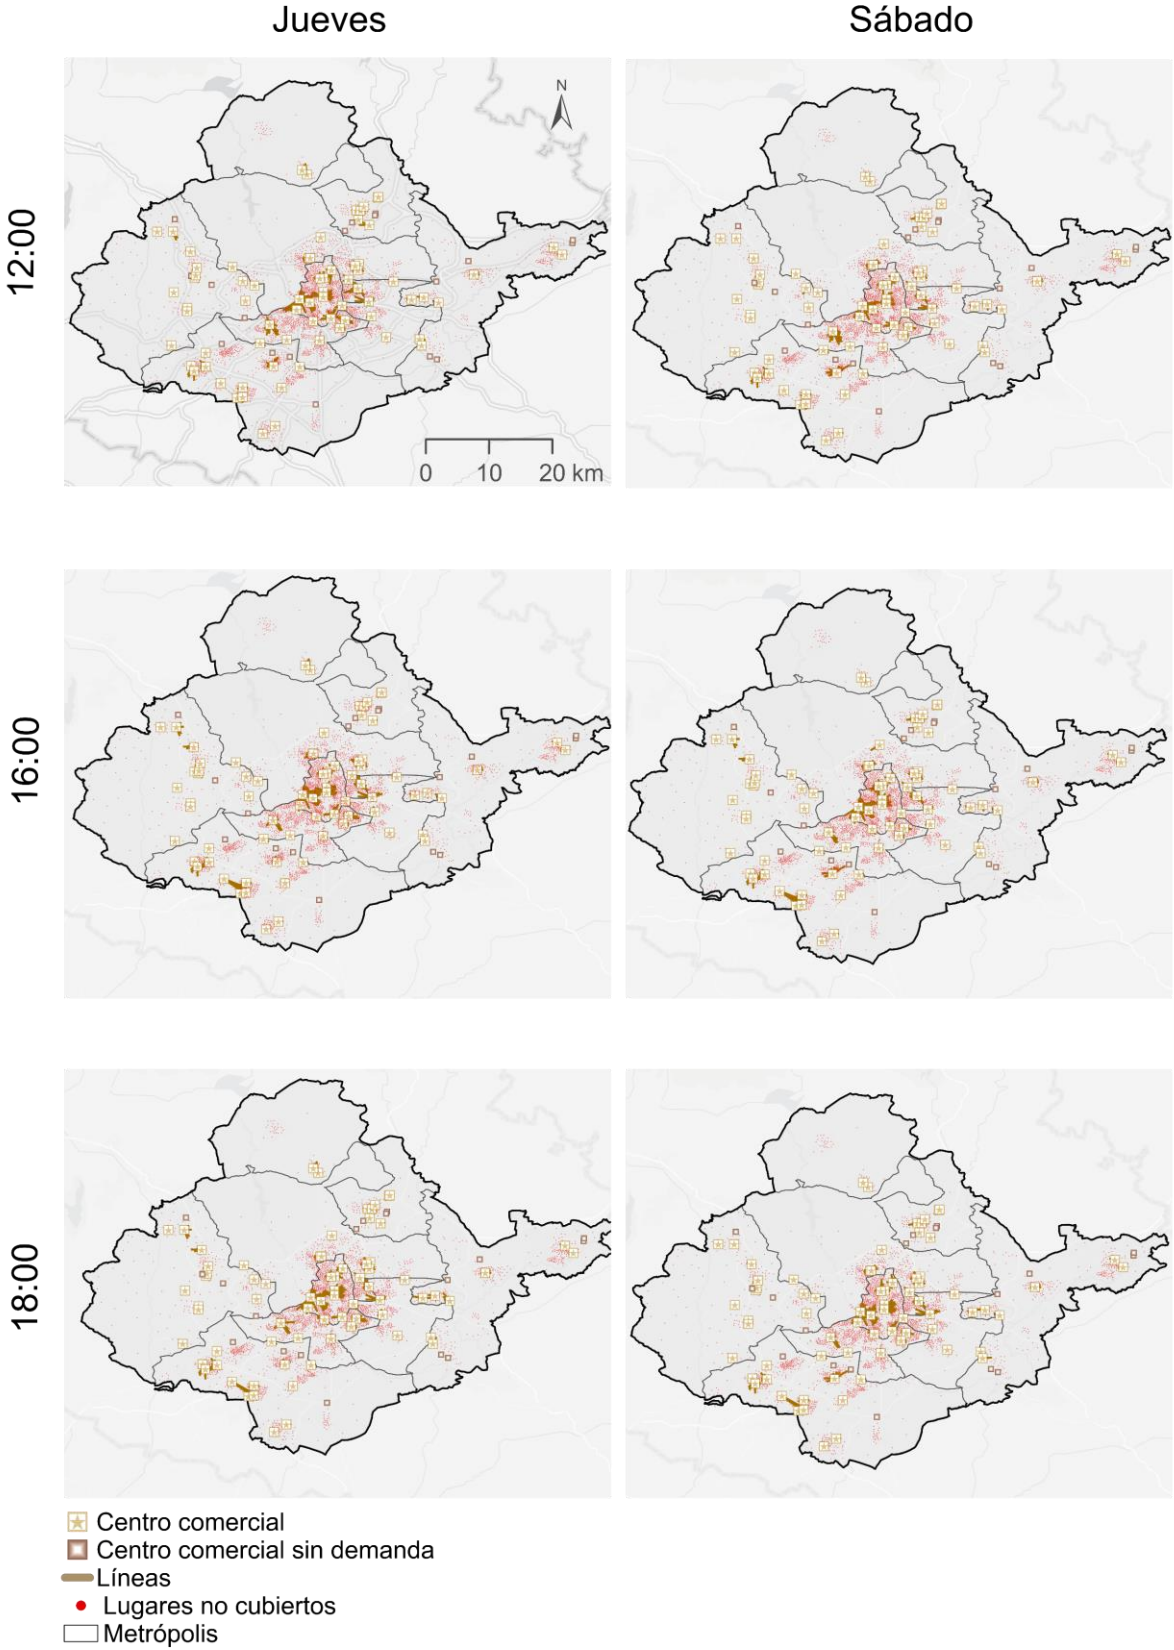
La Figura 46 ilustra los resultados del modelo cuando se utiliza la red GTFS. Las estrellas de color chocolate representan la ubicación de los centros comerciales reales; el recuadro de color chocolate indica los centros comerciales sin demanda asignada. Los puntos grises se refieren a las ubicaciones no asignadas. En cambio, las líneas de color chocolate indican el centro comercial al que se desplazan los lugares de demanda. Se observa que en ambos días (jueves y sábado), muchas de las secciones censales (puntos grises) quedan sin asignar a los centros comerciales, especialmente, en la parte central de la zona de estudio. Además, hay centros comerciales que no consiguen obtener ningún emplazamiento de demanda asignado (cuadrados de color chocolate).

Tabla 27. Población asignada a los centros comerciales a diferentes horas del día utilizando la red GTFS

Horas	Jueves 10 minutos				Sábado 10 minutos			
	Total	%	Inc.	Inc%	Total	%	Inc.	Inc%
8:00	1.129.561	19,5	87.119	8,4	972.942	16,8	-35.650	-3,5
10:00	1.087.069	18,8	44.627	4,3	958.090	16,6	-50.502	-5,0
12:00	1.071.123	18,5	28.681	2,8	937.018	16,2	-71.574	-7,1
14:00	1.050.334	18,2	7.892	0,8	1.033.056	17,9	24.464	2,4
16:00	1.029.206	17,8	-13.236	-1,3	981.320	17,0	-27.272	-2,7
<b>18:00</b>	<b>1.042.442</b>	<b>18,0</b>	<b>0</b>	<b>0,0</b>	<b>1.008.592</b>	<b>17,4</b>	<b>0</b>	<b>0,0</b>
20:00	1.007.033	17,4	-35.409	-3,4	996.535	17,2	-12.057	-1,2

\*En negrita hora de comparación (18:00). Fuente: Elaboración propia.

Figura 46. Asignación de la población a los centros comerciales usando la red GTFS



Fuente: Elaboración propia.

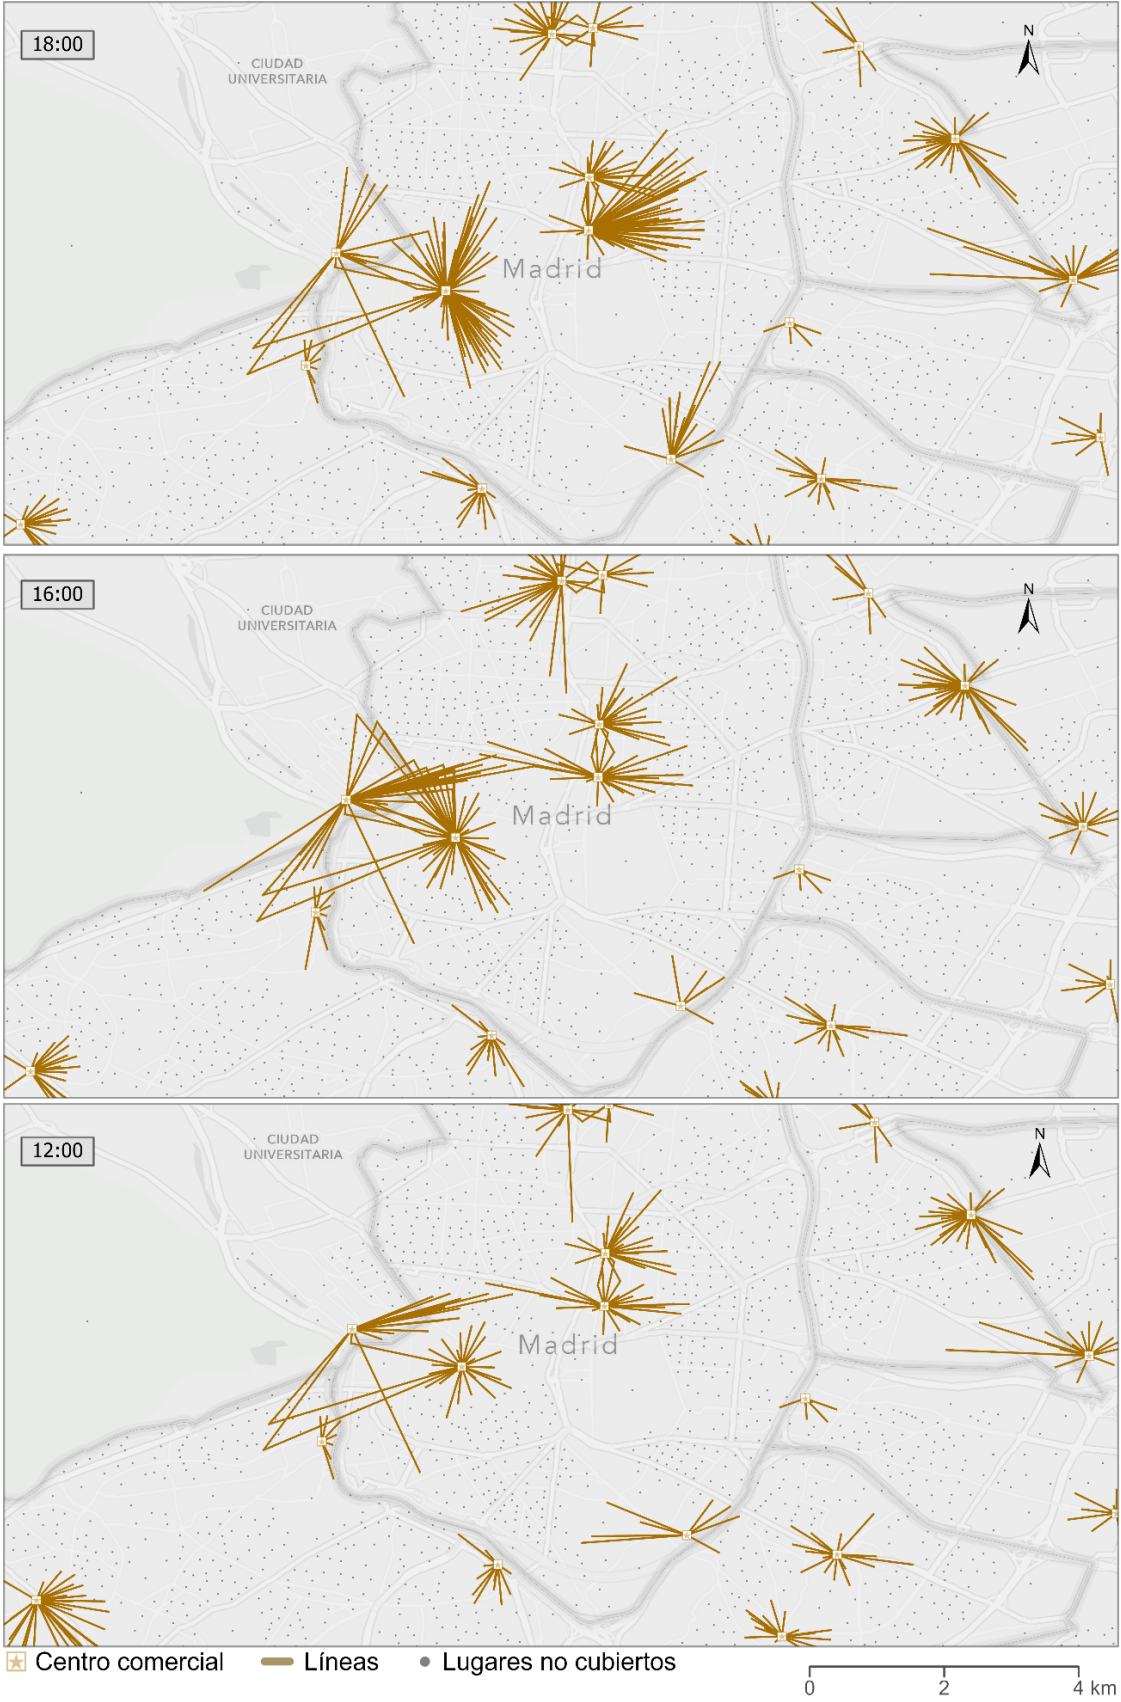
La Figura 47 amplía zonas de los mapas en las diferentes franjas horarias y días; para observar algunos de los cambios en la población asignada.

Figura 47. Detalle de la asignación de la población a los centros comerciales (GTFS y jueves)



Fuente: Elaboración propia.

Figura 48. Detalle de la asignación de la población a los centros comerciales (GTFS y sábado)



Fuente: Elaboración propia.

Se observa que, en las tres horas, las formas de las arañas son diferentes, debido a las variaciones de las frecuencias del transporte público a lo largo del día. También se puede observar el gran número de lugares de demanda que no están cubiertos por ningún centro comercial. Los mapas de araña de los sábados reflejan el mismo comportamiento (Figura 48).

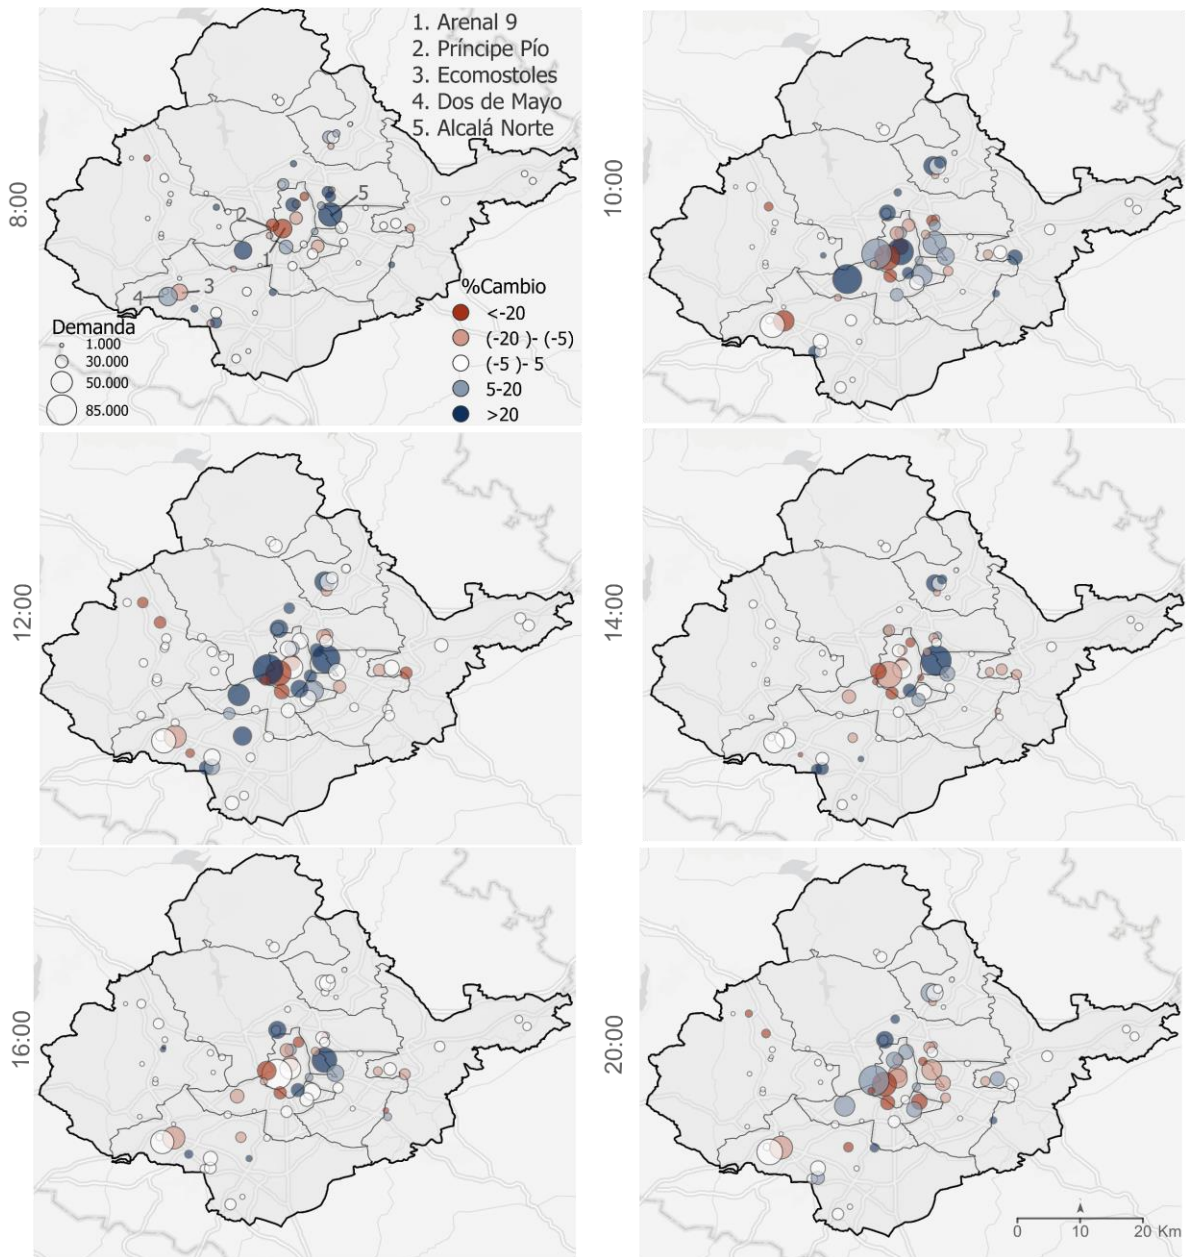
Para evaluar el efecto de la variación en las frecuencias de viajes del transporte público sobre la demanda cubierta por los centros comerciales, la Figura 49 muestra los cambios porcentuales para cada hora en comparación con la hora de referencia (18h).

El azul significa que se ha ganado la demanda asignada, mientras que el rojo indica pérdidas. Se observa que son pocos los centros comerciales con un incremento superior al 20% en todas las horas, excepto a mediodía donde unos 12 establecimientos alcanzan este porcentaje. Entre ellos se encuentran: Alcalá Norte, Alcampo, Moratalaz, Arturo Soria, Plaza Aluche y otros. Por el contrario, las horas donde se registra un descenso más significativo de la demanda son las 14 y las 16 h.

La Figura 49 muestra, también, la población asignada a cada centro comercial durante el día (véase el tamaño del círculo y el gráfico adjunto). Podemos observar que los centros comerciales Arenal 9, Alcalá Norte, Dos de Mayo y otros son los que alcanzan una mayor asignación de población. Ellos superan los 40.000 habitantes en casi todas las horas. Parece posible que la cobertura de estos centros comerciales se deba a que están situados en zonas densamente pobladas, con una buena cobertura de servicios de transporte.

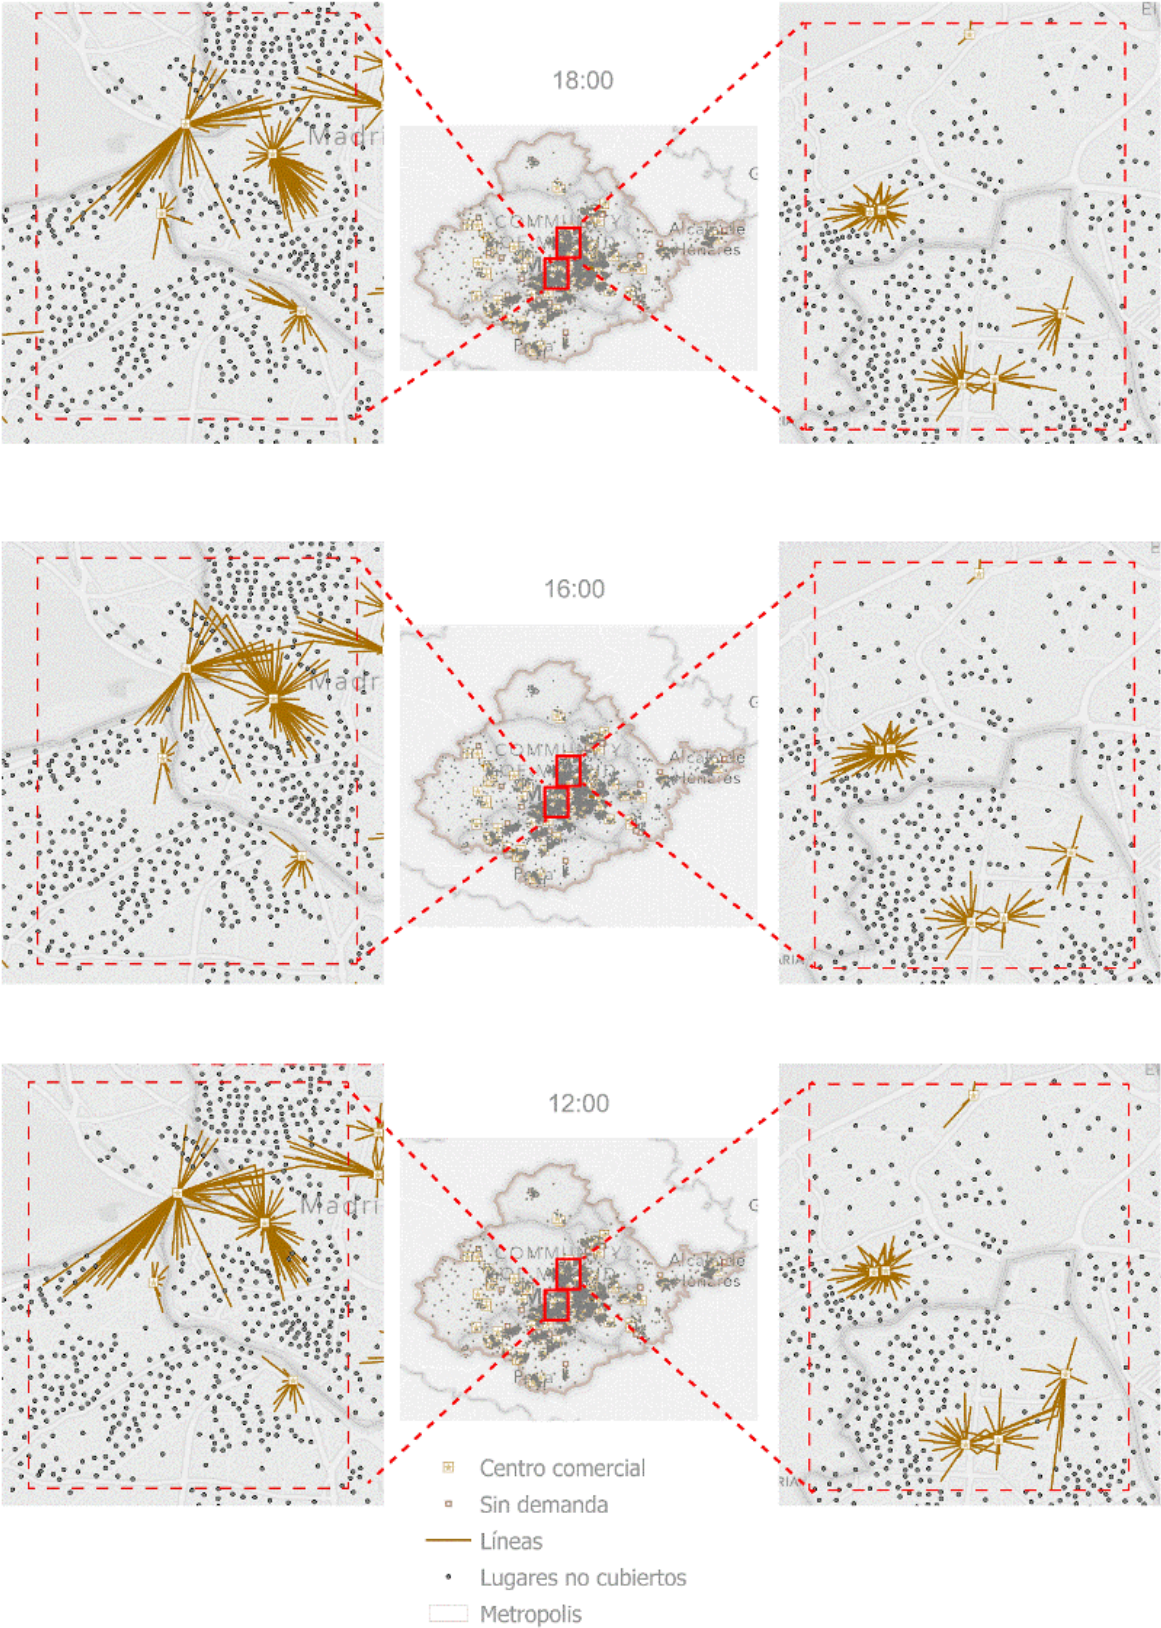
La Figura 50 y la Figura 51 muestran el detalle de aquellas zonas que dejan de estar asignadas a un centro comercial, por encontrarse a más de 10 minutos, por medio del transporte público y los cambios que ocurren en las diversas horas. También aparecen otros casos donde los puntos de demanda asignados son captados por un centro comercial a la hora de referencia 18 h, pero a las 16 h esa misma sección se asigna a otro.

Figura 49. Población cubierta y cambios horarios respecto a las 18 horas (jueves - GTFS)



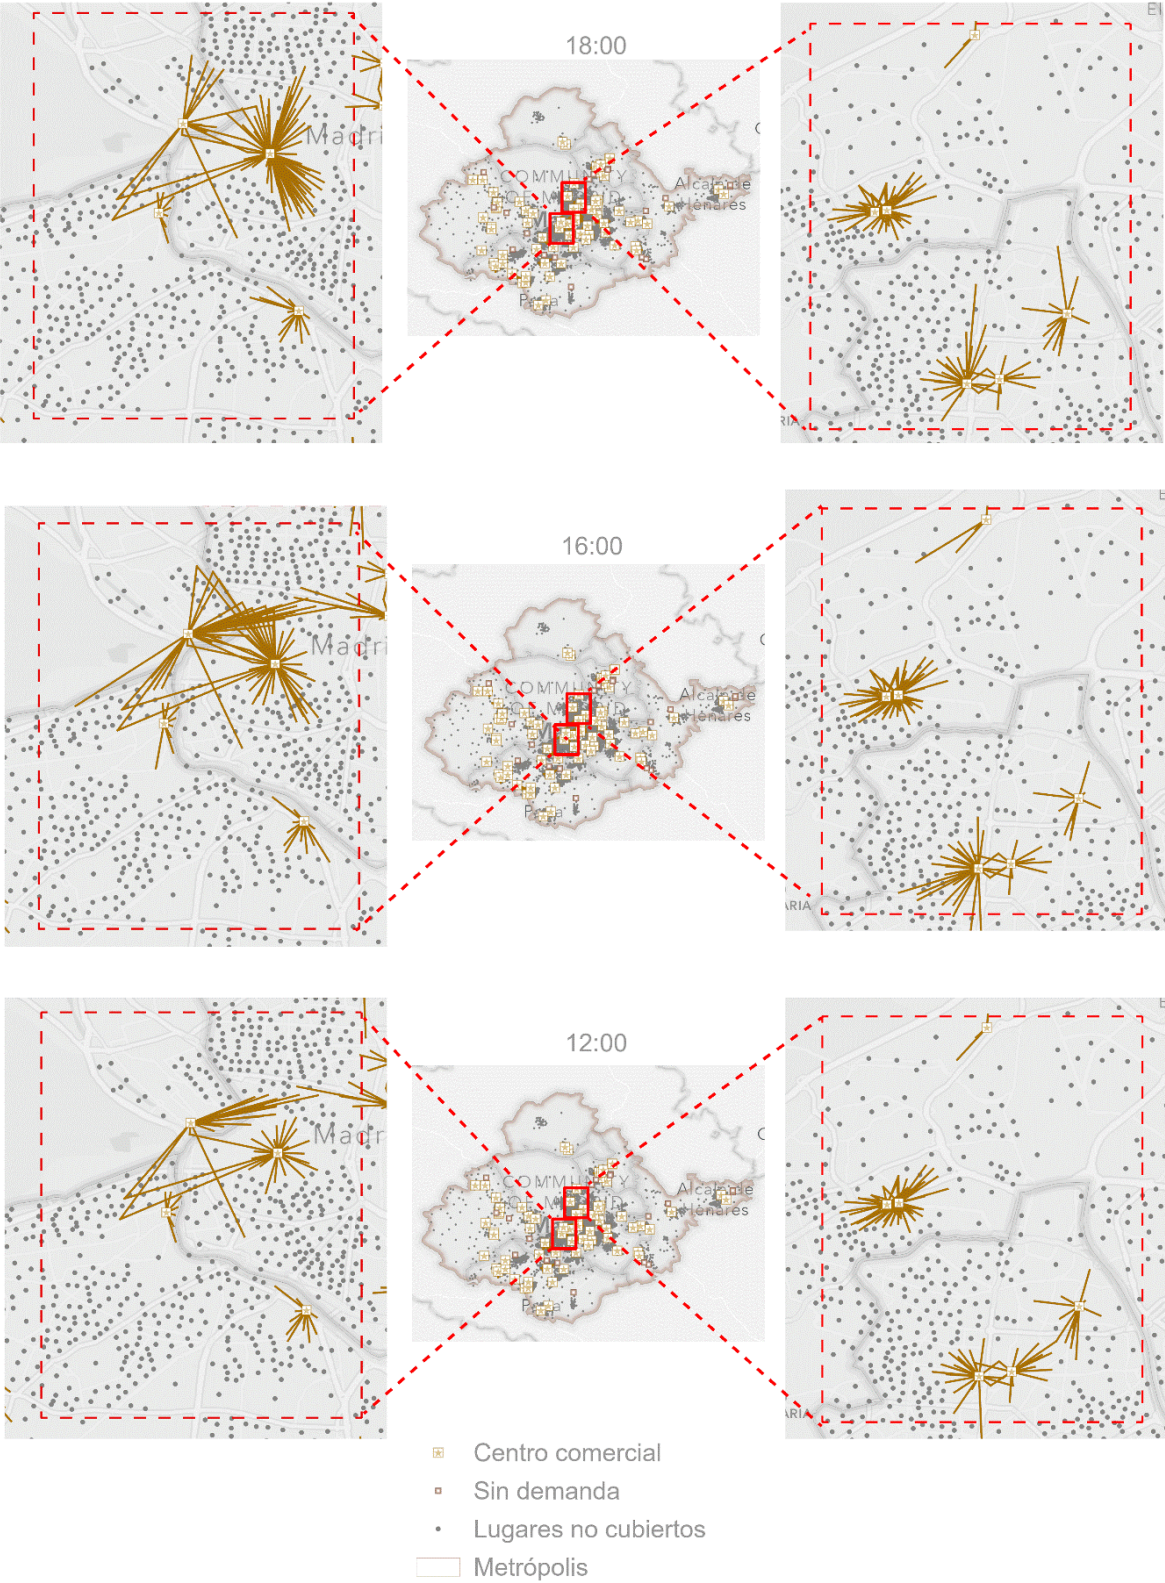
Fuente: Elaboración propia.

Figura 50. Detalle de las secciones censales no asignadas para un jueves, usando GTFS



Fuente: Elaboración propia.

Figura 51. Detalle de las secciones censales no asignadas para un sábado, usando GTFS



Fuente: Elaboración propia.

Por otro lado, con la red de TomTom se obtuvieron resultados diferentes. En primer lugar, se asignó una demanda por encima del 92%, en ambos días; además, los jueves se registró un incremento, en todas las horas al compararse con la hora de referencia 18 h; por último, se notó que los sábados se dieron pocos cambios entre las diferentes horas estudiadas (Tabla 28). Estos pocos cambios pueden explicarse, en parte, porque los fines de semana se ralentiza el ritmo de actividad en la ciudad, provocando que el tráfico sea fluido durante el día.

Tabla 28. Población asignada a los centros comerciales a diferentes horas del día utilizando la red TomTom

Horas	Jueves 10 minutos				Sábado 10 minutos			
	Total	%	Inc.	Inc%	Total	%	Inc.	Inc%
8:00	5.453.046	94,3	1.171.55	2,2	5.548.412	96,0	27.820	0,5
10:00	5.466.652	94,6	130.761	2,5	5.538.004	95,8	17.412	0,3
12:00	5.422.638	93,8	86.747	1,6	5.529.474	95,7	8.882	0,2
14:00	5.484.225	94,9	148.334	2,8	5.537.742	95,8	17.150	0,3
16:00	5.485.009	94,9	149.118	2,8	5.545.828	95,9	25.236	0,5
<b>18:00</b>	<b>5.335.891</b>	<b>92,3</b>	<b>0</b>	<b>0,0</b>	<b>5.520.592</b>	<b>95,5</b>	<b>0</b>	<b>0,0</b>
20:00	5.433.244	94,0	97.353	1,8	5.508.003	95,3	-12.589	-0,2

Fuente: Elaboración propia.

Para terminar este apartado, la Tabla 29 resume las diferencias entre los días y las redes analizadas. Se observa que el transporte público los sábados es menos eficiente que los jueves, lo que se manifiesta en los porcentajes negativos en las distintas horas. En promedio, los fines de semana se deja un 7% menos de personas sin asignar en comparación con los jueves, siendo más significativo el impacto en la hora de las 8, donde se registra una disminución de alrededor del -14 %. Por el contrario, ocurre lo opuesto con la red de transporte privado que tiene una mayor cobertura los sábados. De media, con la red de transporte privado, se atiende a unos 92.478 habitantes más (2 %) los sábados que los jueves. El impacto más significativo se registra a las 18 horas, que coincide con el momento en que la población madrileña acostumbra a visitar los centros comerciales los fines de semana.

Tabla 29. Diferencias entre la población asignada (sábado - jueves)

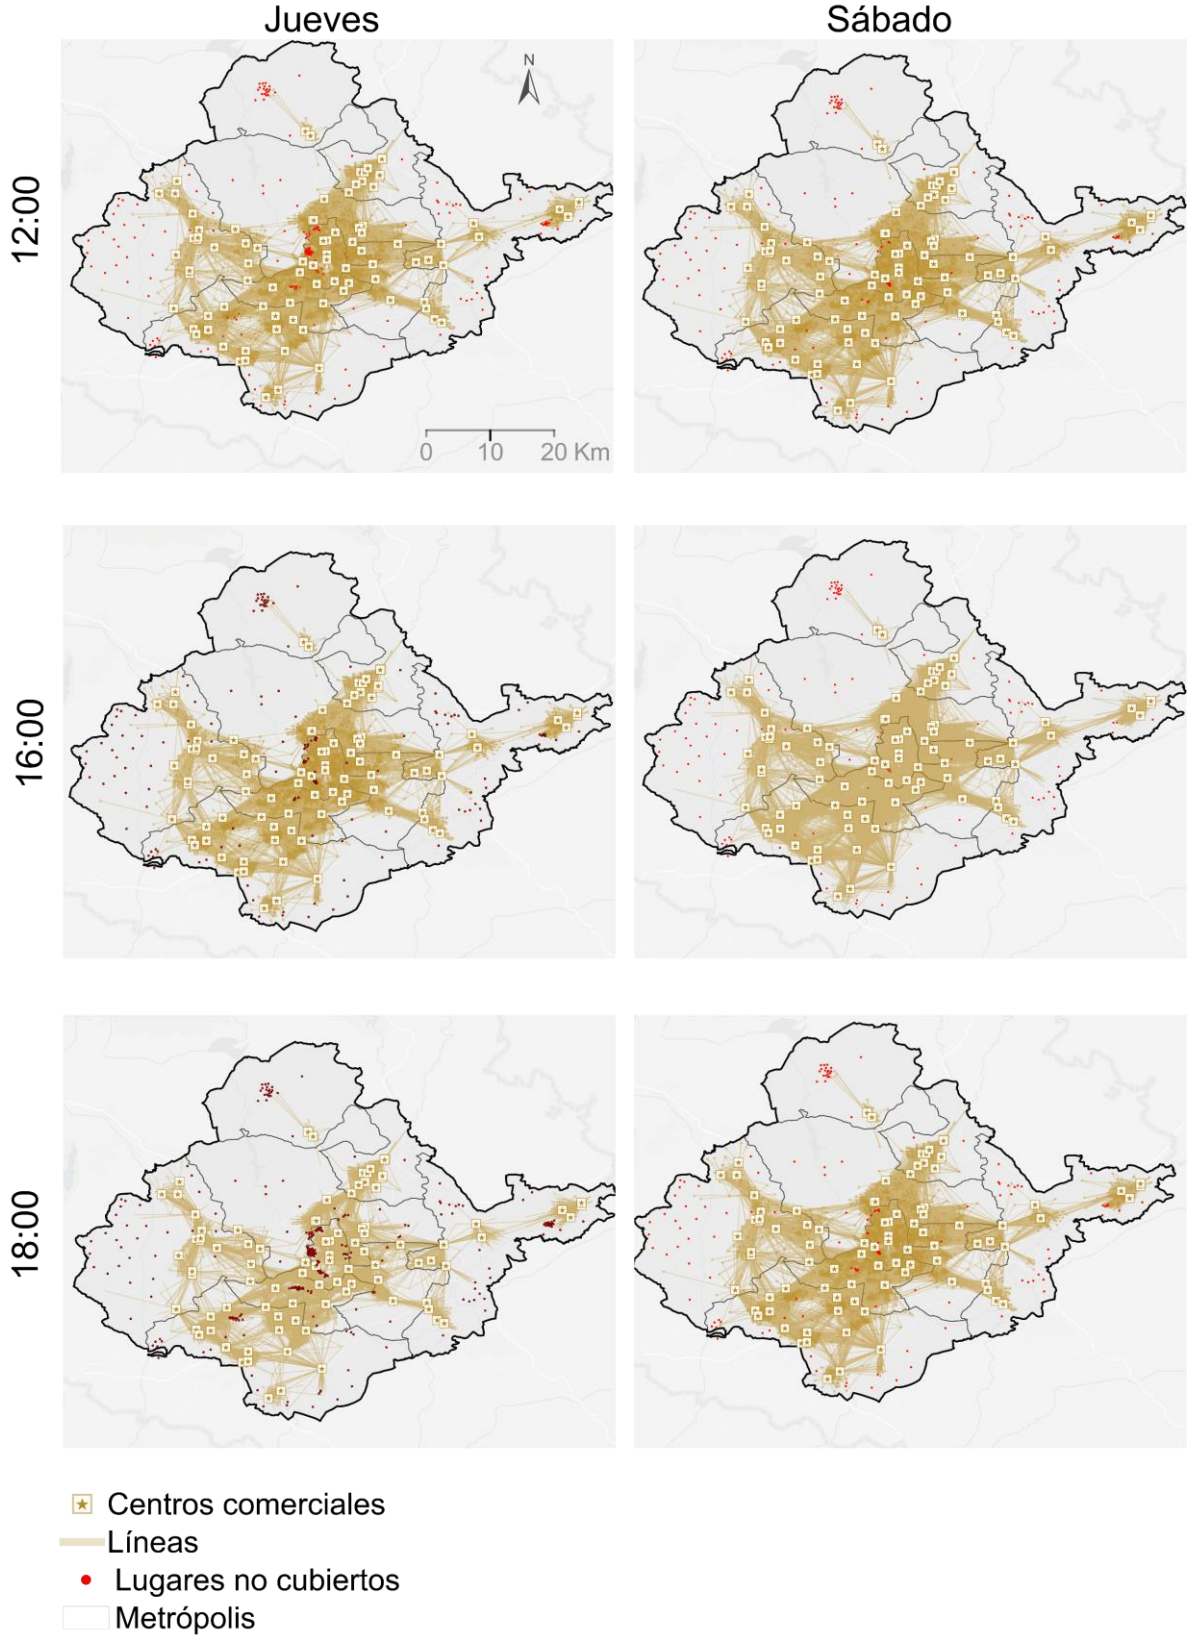
Horas	GTFS		TomTom	
	Total	%	Total	%
8:00	-156.619	-13,9	95.366	1,7
10:00	-128.979	-11,9	71.352	1,3
12:00	-134.105	-12,5	106.836	2,0
14:00	-17.278	-1,6	53.517	1,0
16:00	-47.886	-4,7	60.819	1,1
<b>18:00</b>	<b>-33.850</b>	<b>-3,2</b>	<b>184.701</b>	<b>3,5</b>
20:00	-10.498	-1,0	74.759	1,4

Fuente: Elaboración propia.

Por otro lado, utilizando la red TomTom (transporte privado) se registra una mejor cobertura que con el transporte público. Sin embargo, se observan ciertas zonas no cubiertas (puntos rojos), especialmente, a las 18 horas de los jueves (Figura 52), ya que se les hace difícil llegar a un centro comercial en 10 minutos. La explicación de este comportamiento puede estar relacionada con el hecho de que las 18 es una hora de cierta congestión en Madrid. Al comparar los jueves y los sábados, se observa que el número de sitios sin cobertura disminuye los sábados en todas las horas debido a una mayor asignación de población.

La Figura 53 muestra el porcentaje de cambios entre franjas horarias y la población asignada a cada centro comercial, calculados a partir de los resultados obtenidos al utilizar la red TomTom. Para obtener estos porcentajes, se ha tomado las 18 h como referencia para la comparación. Los tonos azules indican una población cubierta superior con respecto a la asignada a las 18 h. Los tonos rojos representan menor población asignada. El tamaño de los círculos indica la cantidad de la población cubierta en esa franja horaria en unidades de miles.

Figura 52. Asignación de la población a los centros comerciales usando la red TomTom



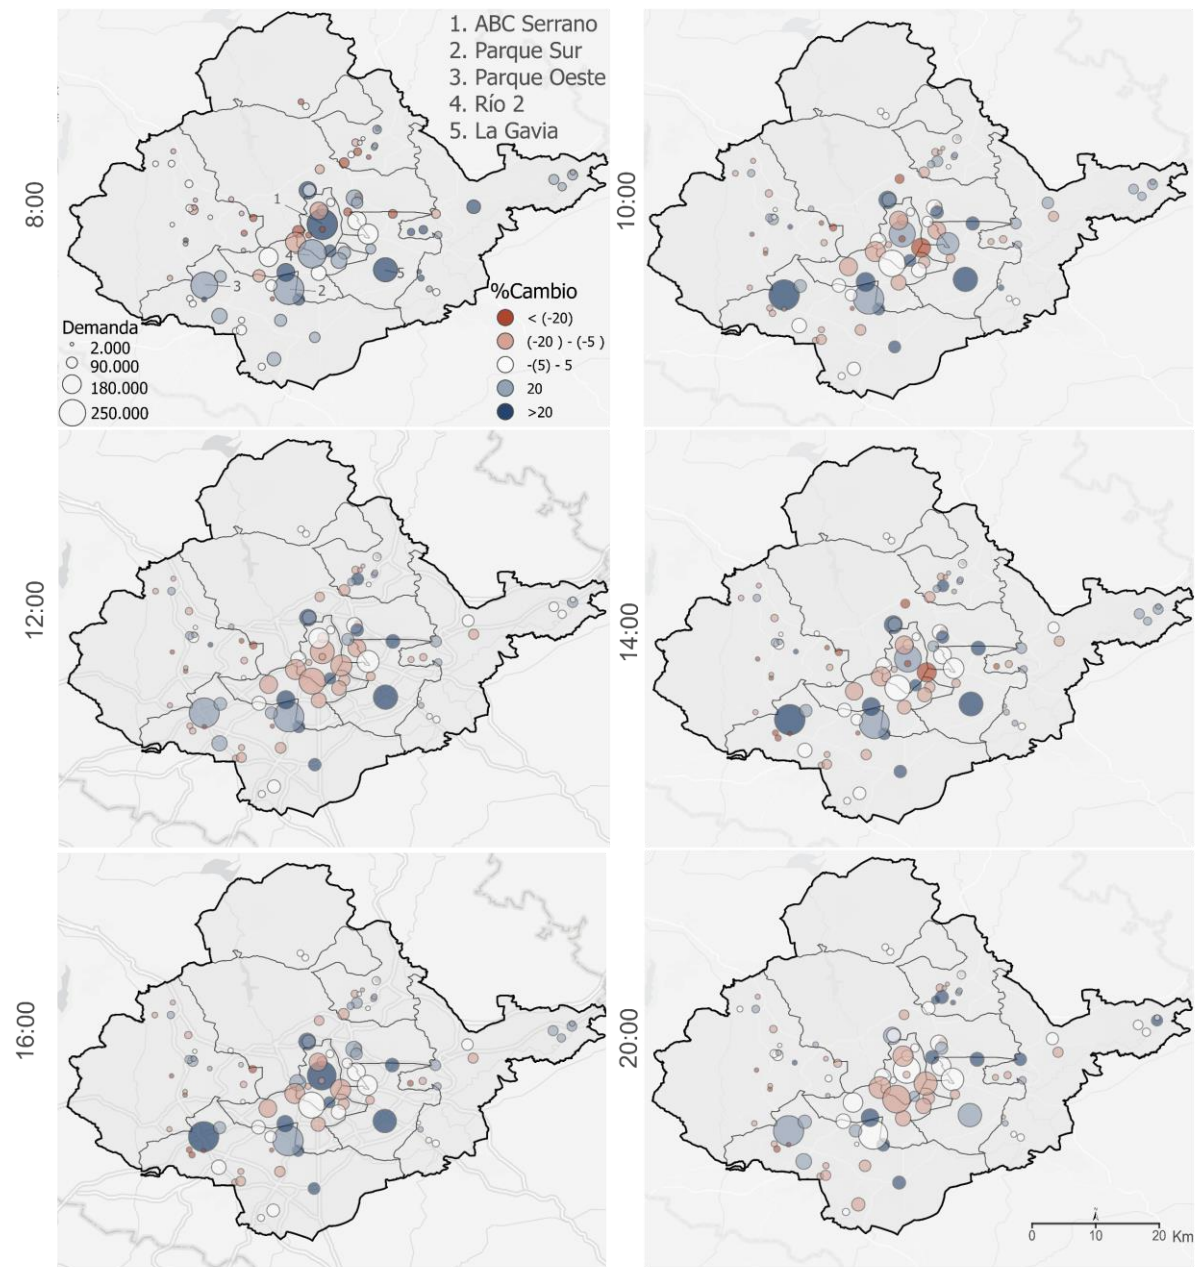
Fuente: Elaboración propia.

La Figura 53 muestra que el aumento, durante todas las horas, supera el 20% en muy pocos centros comerciales (4 de 91). Entre ellos destacan los centros comerciales de Islazul, Getafe, San Sebastián y La Vaguada. Por otro lado, los centros comerciales de las zonas centro y oeste registran menores asignaciones que a las 18 h en casi todas las horas, las pérdidas oscilan entre -5% y -20%. Ejemplos de ello son los centros comerciales Alcampo-Moratalaz, Mercacentro en Leganés, Zielo Shopping, Zoco-Boadilla, entre otros. El gráfico inferior representa el top 10 de los centros comerciales con mayor población asignada, cada uno de ellos alcanzan una asignación media de 180.000 habitantes. Se destacan los centros comerciales ABC Serrano, Parque Sur, Plaza Río 2 y Parque Oeste, con más de 200.000 habitantes.


Las Figura 54 y Figura 55 representan las secciones censales que no están asignadas a los centros comerciales en ninguna franja horaria (ver puntos rojos). En lo que respecta a los jueves (Figura 54), se observa que algunos puntos con demanda no están cubiertos a las 18 horas. Sin embargo, a las 16 o a las 12, esos mismos puntos no cubiertos son asignados a centros comerciales. El mismo comportamiento se produce los sábados. Al comparar los jueves y los sábados, observamos que las secciones no asignadas disminuyen durante el fin de semana en todas las franjas horarias debido a una mayor asignación de la población en los fines de semana.

Por otro lado, al comparar los resultados obtenidos con las soluciones de maximizar la cuota de mercado compartido y maximizar la asistencia, encontramos que el impacto del dinamismo de las redes GTFS y TomTom es significativo. La Figura 56 resume los porcentajes de asignación obtenidos con ambas soluciones. El eje vertical indica el porcentaje de población asignada. El eje horizontal muestra las horas utilizadas en la elaboración de los modelos. Al mismo tiempo, los colores de las barras representan los días y las redes empleadas.

Figura 53. Población asignada y cambios horarios con respecto a las 18 horas (jueves - TomTom)

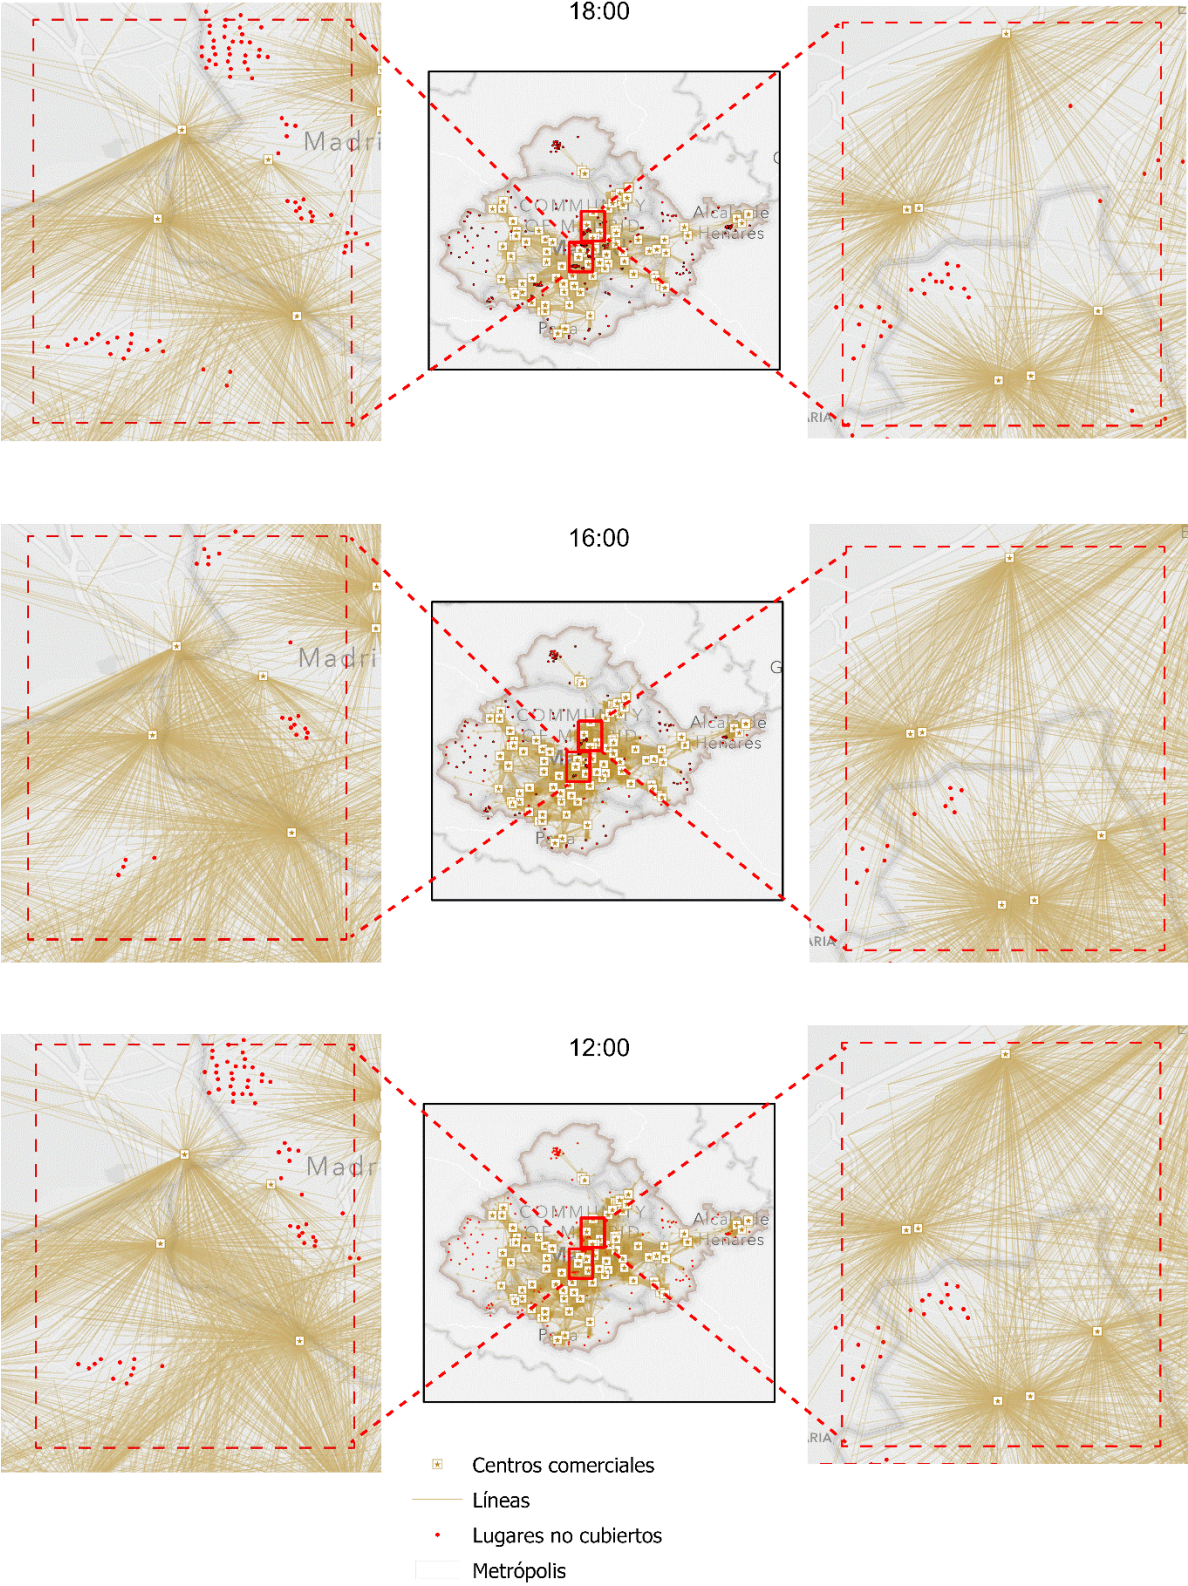


Centros comerciales con mayor asignación según hora



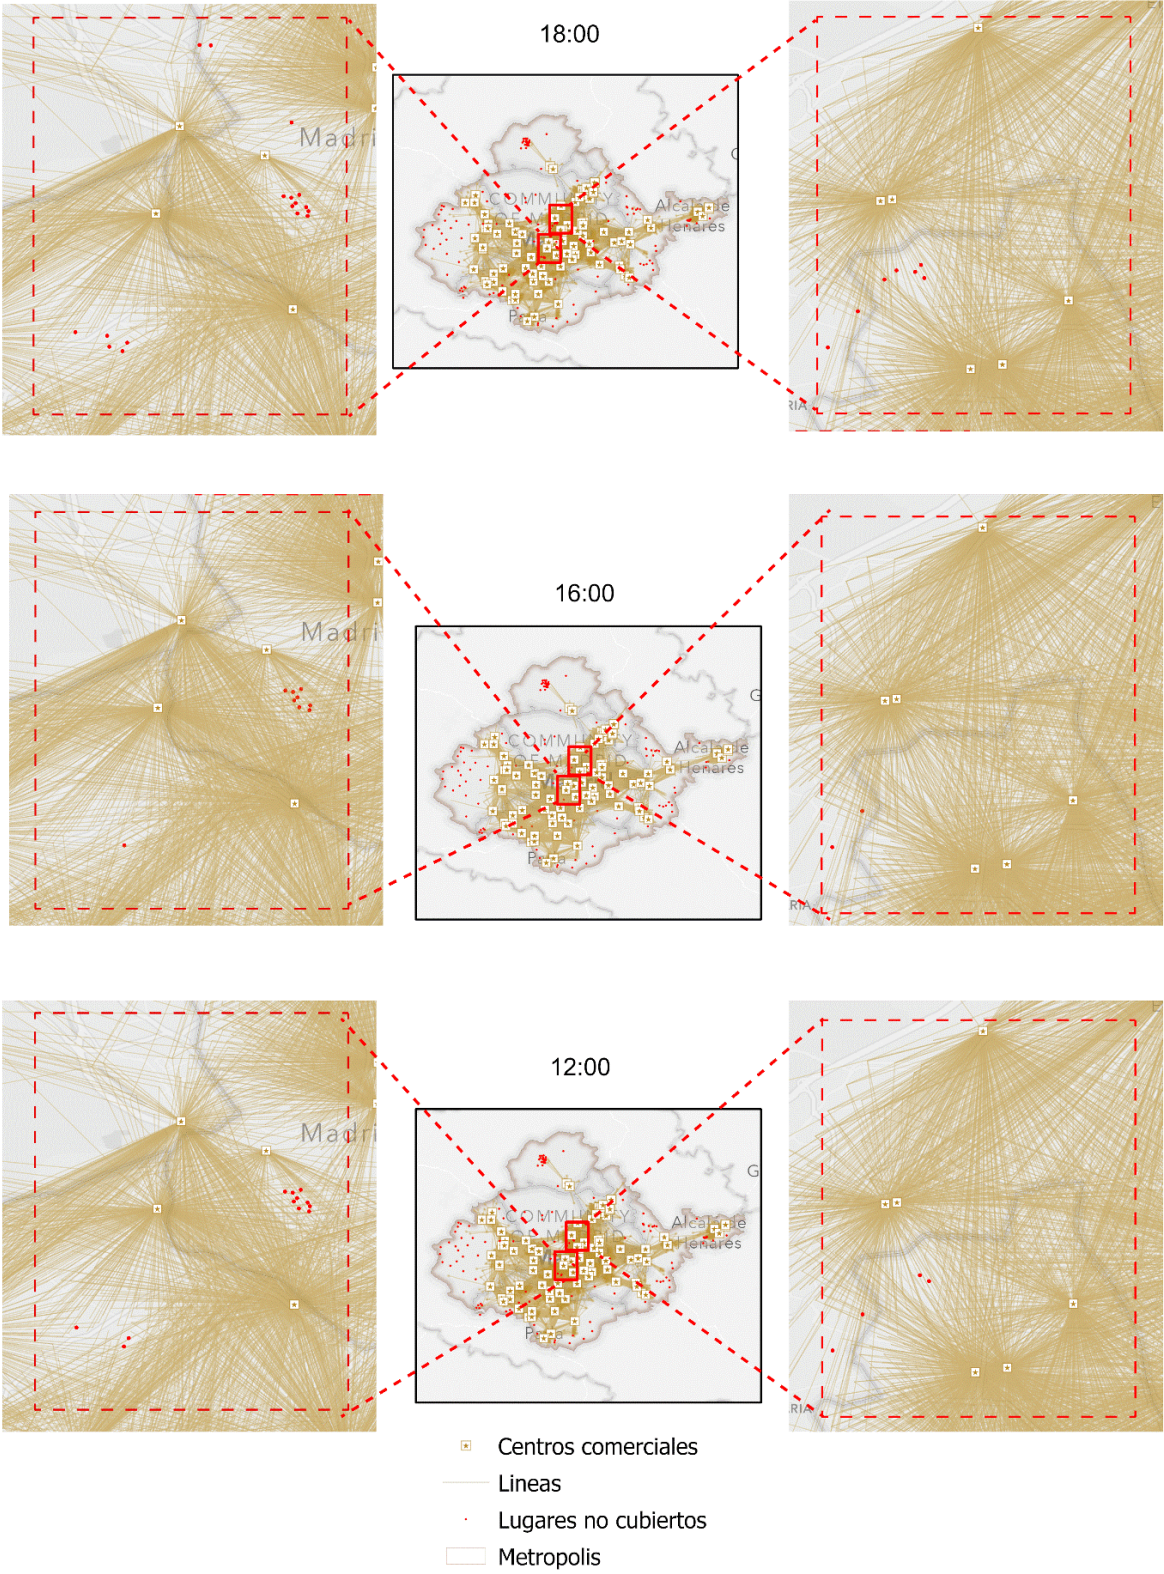
Fuente: Elaboración propia.

Figura 54. Detalle de las secciones censales no asignadas para un jueves, usando TomTom



Fuente: Elaboración propia.


Figura 55. Detalle de las secciones censales no asignadas para un sábado, usando TomTom



Fuente: Elaboración propia.

Observamos que con la solución de maximizar la cuota de mercado se asigna mucha más demanda que con la solución de maximizar la asistencia. Por ejemplo, con la red GTFS, se asigna una media del 12% más de población para ambos días. En comparación con la red TomTom, la cifra se eleva a casi el 50%. También observamos que con la solución maximizar la asistencia se alcanzan valores superiores al 40% de la población asignada en todas las franjas horarias con la red TomTom. Mientras que, con la solución de maximización de la cuota de mercado, esta cifra supera el 90%.

Figura 56. Porcentaje de población asignada según la solución empleada (red GTFS y TomTom)



Fuente: Elaboración propia.

Las diferencias entre los resultados obtenidos con las dos soluciones tienen varias explicaciones posibles. En primer lugar, la función objetivo del algoritmo de la solución maximizar la asistencia y de la solución maximizar mercado compartido son totalmente diferentes. En concreto, la solución maximizar la asistencia busca asignar la mayor población en un tiempo determinado. Esta población asignada disminuye a medida que aumenta la distancia entre las instalaciones y las ubicaciones de los usuarios. Además, la solución asigna la demanda a un único centro comercial (el más cercano). En cambio, la solución de maximizar el mercado compartido utiliza otra variable que influye en los resultados del modelo. Para el desarrollo de esta solución se requiere toda la información posible de los competidores. Por ejemplo, en esta investigación, se empleó la superficie bruta alquilable de cada centro comercial (una variable que suele usarse en los modelos en los que existen competidores) para atraer puntos de demanda. Por otra parte, un punto de demanda dentro del umbral temporal establecido se asigna, en su totalidad, a uno o varios centros comerciales. Al mismo tiempo, la población se asigna en proporción al atractivo de cada centro comercial.

En segundo lugar, también es notable el impacto de las redes de transporte público y privado. Sobre todo, debido a las diferentes frecuencias de viaje durante el día, la red de transporte público puede estar influyendo en los resultados obtenidos. El algoritmo de la solución maximizar la asistencia afecta al porcentaje de población asignada porque solo una parte de la demanda se distribuye a un centro comercial. En cambio, con la solución de maximizar el mercado compartido, la población se distribuye entre varios establecimientos. En cambio, con la red de transporte privado, hay más libertad para visitar un centro comercial. La solución de maximizar asistencia resulta más afectada por la congestión de vehículos, debido a que la asignación de la demanda se dirige al centro comercial más cercano; mientras que, en la solución de maximizar cuota de mercado, puede asignarse entre uno o varios centros.

#### *4.1.6.3 Añadiendo nuevos centros comerciales: Cantidad de centros comerciales que se requieren para lograr una demanda objetivo (solución “Maximizar cuota de mercado objetivo”)*

Con la solución maximizar mercado compartido se logró cubrir el 94% de la demanda con la red TomTom y 18% con la red GTFS. A continuación, realizamos un ejercicio que pretende utilizar los MLA para encontrar localizaciones a nuevos centros comerciales, tratando de evaluar cuántos centros se requieren para cubrir un 4% más de la demanda. Es decir, una cuota del 98% cuando trabajamos con la red de transporte privado y el 22% en transporte público. La razón para usar este incremento del 4% es simplemente poner una cifra que nos permita evaluar los cambios en el funcionamiento de las redes en este tipo de soluciones.

Como centros requeridos se toma la oferta actual, ponderando su atracción por la superficie bruta alquilable (SBA) y los candidatos a las nuevas localizaciones han sido los centroides de aquellas secciones censales con más de 2000 habitantes. Nuevamente, la demanda se obtuvo de las secciones censales ponderadas por un campo de población.

Los resultados obtenidos indican que con la red GTFS se requiere de ocho nuevos centros comerciales para asignar ese 22% de la población a la red de centros comerciales en un tiempo de 10 minutos. Mientras que utilizando la red TomTom, para alcanzar el 98% de la población asignada los jueves se necesitan hasta 18 centros más y para los sábados 8 (Figura 57 y Figura 58).

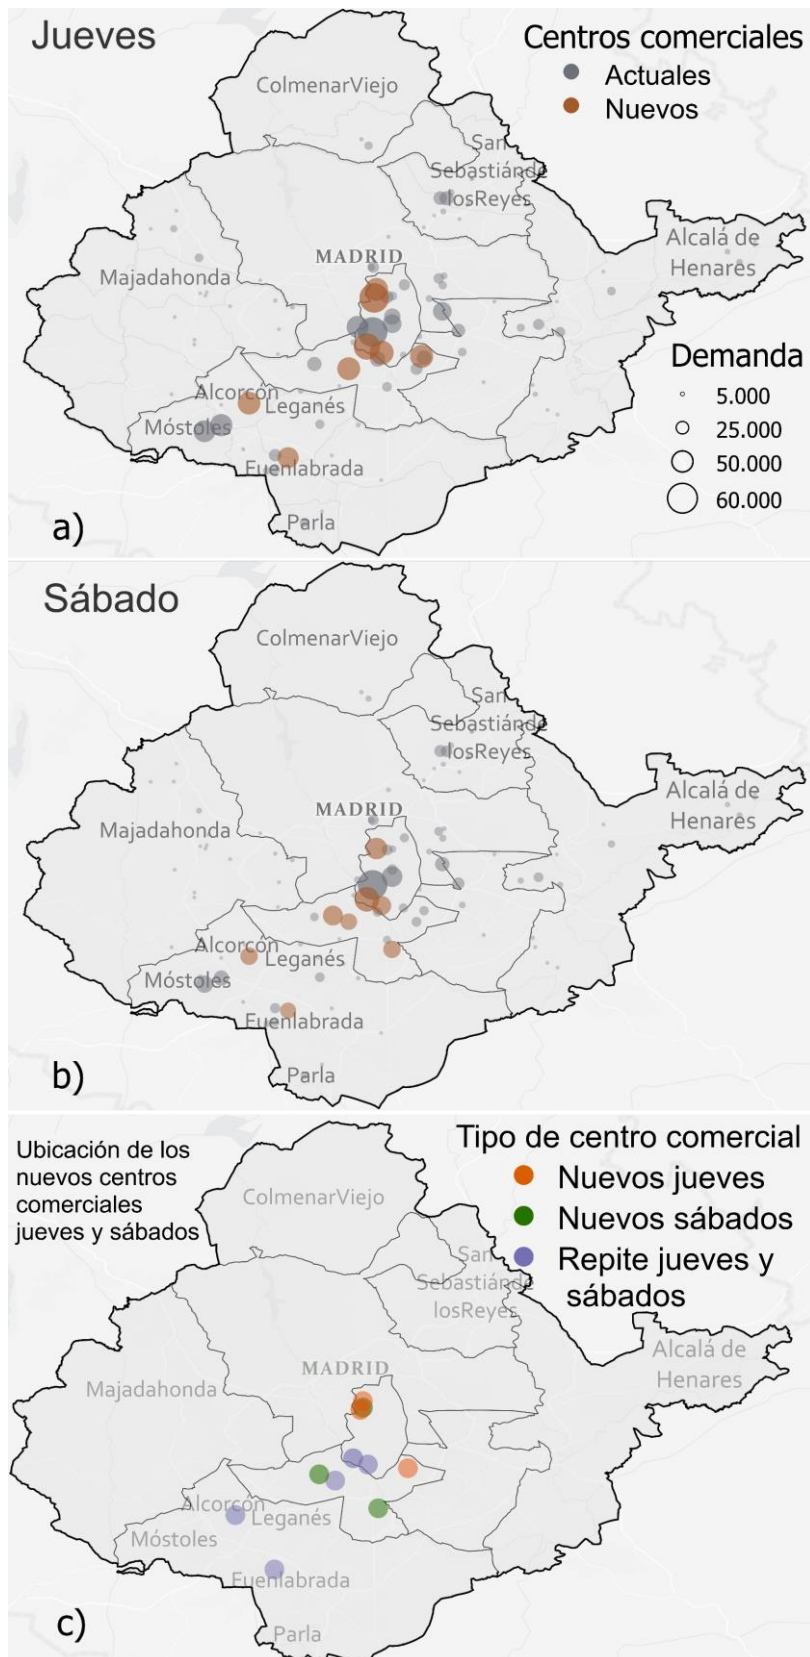
Los círculos en tonos grises representan las ubicaciones de los centros comerciales existentes. El color chocolate oscuro indica la ubicación de los nuevos centros comerciales. El tamaño de los círculos muestra la cantidad de población asignada a los centros comerciales, demostrando que, en algunos casos, los nuevos centros comerciales captan más demanda que los existentes (Figura 57a y b).

La Figura 57c compara la ubicación de los nuevos centros comerciales para los jueves y los sábados. Los círculos naranja y verde representan los nuevos centros que no repiten ubicación en ninguno de los días analizados. Por el contrario, el círculo morado indica los nuevos centros comerciales con la misma ubicación tanto en día laborable como fin de semana.

Utilizando la red GTFS podemos observar que, tanto jueves como sábados, los nuevos centros comerciales se sitúan, sobre todo, dentro de los límites del municipio de Madrid. Estos se localizan cerca de los distritos de Chamberí, Carabanchel y Tetuán. En la Figura 57c podemos notar que cinco nuevos centros comerciales tienen la misma ubicación los jueves y los sábados. De ellos, dos están muy cerca de Leganés y Alcorcón. La explicación de la ubicación de los nuevos centros comerciales está relacionada con el hecho de que los lugares elegidos tienen una alta densidad de población y una buena conectividad en transporte público.

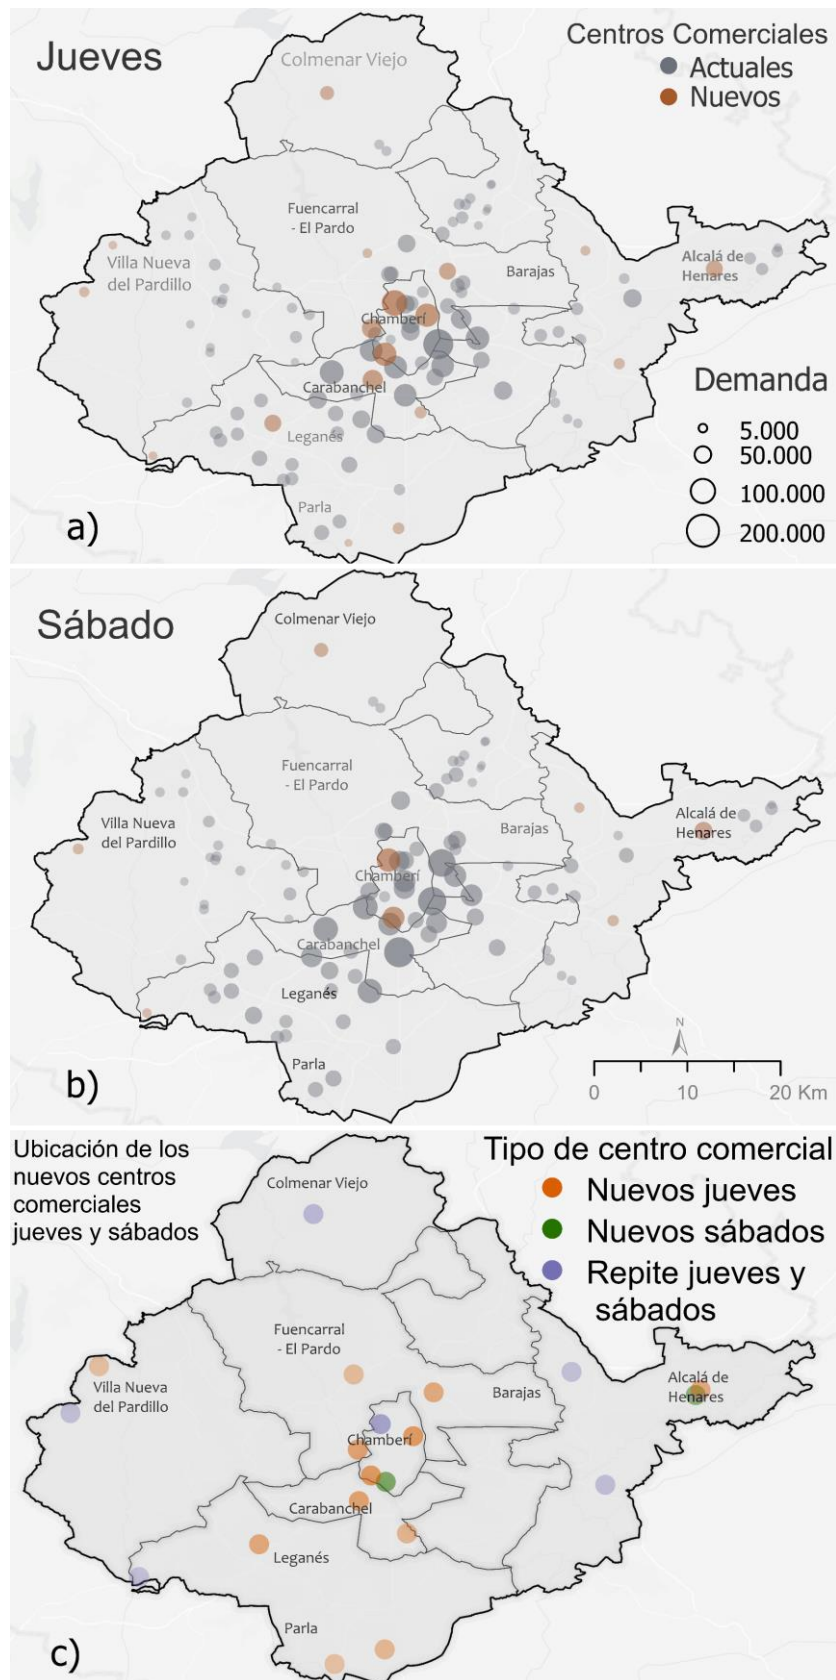
En el caso del modelo que utiliza la red TomTom (Figura 58a y b) se observa que, los jueves, los nuevos centros comerciales se sitúan en la zona central del área de estudio. En cambio, los sábados se sitúan en la periferia. Al comparar la ubicación de los centros comerciales los jueves y los sábados, se observa que los de la zona central no repiten posición, en ninguno de los dos días. Lo mismo ocurre con los de la zona sur, este y oeste. En cambio, los que repiten ambos días se sitúan en la periferia del área metropolitana (Figura 58c). Este resultado puede estar relacionado con la escasa congestión del tráfico en estas zonas alejadas del centro de la ciudad.

Figura 57. Centros comerciales actuales y nuevos en la solución maximizar cuota de mercado objetivo (incremento al 22%) (GTFS)



Fuente: Elaboración propia.

Figura 58. Centros comerciales actuales y nuevos en la solución maximizar cuota de mercado objetivo (incremento al 98%) (TomTom)



Fuente: Elaboración propia.

## 4.2 Modelos con demanda variable en el tiempo y redes estáticas: aplicación a la localización de estacionamientos para servicios de movilidad compartida

### 4.2.1 Descripción del caso de estudio: Aparcamientos para servicios de motos eléctricas en Madrid

En los últimos años, en la mayor parte de las ciudades han surgido modos de desplazamiento alternativos a los sistemas de transporte tradicionales, basados en el uso compartido de vehículos eléctricos de micromovilidad (Banerjee et al., 2020; Heinen et al., 2010; Zhu et al., 2020). La popularidad de los servicios de movilidad compartida (en inglés *shared micro-mobility services*) se ha generalizado, utilizándose en viajes en los centros urbanos o como alternativa para recorrer la primera y última milla de los viajes metropolitanos (Baek et al., 2021). Estos sistemas de movilidad incluyen modalidades de servicio como el uso compartido de bicicletas, motos, patinetes u otros modos de baja velocidad, en sistemas de servicio *docked* (con estaciones donde se toman y depositan los vehículos) or *dockless* (sin estaciones). En ambos casos, pero en especial en *dockless services*, el sistema se apoya en un uso intensivo de la geolocalización, a través de los teléfonos inteligentes, con aplicaciones que permiten a los usuarios localizar y desbloquear los vehículos y dejarlos en cualquier lugar cuando un viaje termina (Hua et al., 2020; Lazarus et al., 2020; Riu et al., 2020; Zhang et al., 2019).

Uno de los modos de micromovilidad que mayor implantación tiene es el de las motos eléctricas (en inglés *moped-style scooter*). En este sistema es el que se pone en foco en esta investigación. Desde su aparición, a principios de la década de 2010, ha presentado un crecimiento acelerado año tras año. Así, aunque la pandemia de COVID-19 ha reestructurado en parte este sector, afectando a muchas empresas y ciudades, en la actualidad existen casi ochenta operadores a nivel mundial, con alrededor de 9 millones de usuarios registrados en más de 120 ciudades (Howe & Jakobsen, 2020). El rápido crecimiento de estos sistemas de micromovilidad tiene importantes implicaciones para las decisiones políticas y de planificación urbana relacionadas con la movilidad y la elección del modo de transporte (Younes et al., 2020).

Los servicios de movilidad compartida tienen beneficios para la ciudad. En la mayoría de los casos se trata de bicicletas o vehículos eléctricos, favoreciendo así formas de movilidad amigables con el ambiente, cuya flexibilidad permite esquivar la congestión que caracteriza a muchos de los centros urbanos de las metrópolis donde operan. De esta manera, estos sistemas contribuyen a una disminución del uso del automóvil, favoreciendo la reducción de las emisiones de gases de efecto invernadero y tiene beneficios para la salud de los usuarios y el resto de la población. Pero, además, favorecen la mayor movilidad en los centros urbanos y por tanto, contribuyen al propio desarrollo económico (Shaheen & Cohen, 2019).

Sin embargo, junto a los beneficios señalados, el acelerado proceso de crecimiento de los vehículos de movilidad compartida sin bases fijas, también ocasionan problemas, que provocan importantes tensiones en la gobernanza urbana (Ma et al., 2018; Roukouni & Correia, 2020). Estos problemas tienen que ver, por ejemplo, con el exceso de oferta, el mal comportamiento de los usuarios o el uso incorrecto de los espacios públicos para la circulación y, sobre todo, el inadecuado aparcamiento.

Efectivamente, uno de los mayores conflictos de las nuevas formas de movilidad compartida es el aparcamiento de los vehículos. Con frecuencia los patinetes, las bicicletas y también las motocicletas aparecen en las aceras, muchas veces, mal colocadas o tiradas, ocupando un espacio dedicado a la movilidad peatonal. En las vías donde el espacio, para el peatón, es reducido estas molestias se acrecientan, y afectan, además, a grupos, especialmente, vulnerables como la población con movilidad reducida (Xu et al., 2019).

Varias medidas se están llevando a cabo, por ejemplo, a través de incentivos a los propios usuarios ( Gao et al., 2020), pero es necesario establecer otras medidas que permitan regular las zonas de aparcamiento. Una solución, de bajo coste, es reservar ciertos espacios para estos vehículos de movilidad compartida. Estos espacios de aparcamiento pueden ser, simplemente, algunas de las plazas hoy dedicadas al vehículo privado. Para encontrar espacios adecuados a esas zonas de aparcamiento o bases de vehículos compartidos, en este caso de estudio, se ha testado la utilidad de los modelos de localización-asignación en *S/G*.

Para el desarrollo del MLA se tiene la ventaja de contar con los datos generados por los propios sistemas de movilidad compartida, que permiten localizar, con un alto

grado de detalle espacial y temporal, la demanda de los vehículos. Así, las aplicaciones de gestión de estos sistemas almacenan datos GPS del origen y el destino del viaje. Estos datos permiten conocer los lugares de demanda del sistema, a partir de los propios viajes que se han realizado.

En efecto, la investigación en servicios de movilidad compartida en las ciudades se ha convertido en un tema importante en la literatura internacional, específicamente, sobre la movilidad urbana, con publicaciones recientes donde se analizan los patrones espacio-temporales en el uso de los vehículos (Arias-Molinares et al., 2021). Estos trabajos han explotado los registros GPS que generan sus propios sistemas, que almacenan el historial de los orígenes y destinos de los viajes realizados por los usuarios.

Los datos derivados de los GPS instalados en los vehículos de movilidad compartida han sido utilizados para analizar la accesibilidad que ofrecen estos nuevos sistemas (Mooney et al., 2019), los patrones espaciotemporales de uso (McKenzie, 2019, 2020) o los modelos para predecir la demanda y segmentación de clientes (Degele et al., 2018; Ji et al., 2020). Varios estudios han utilizado los datos derivados de los GPS de los vehículos de movilidad compartida para analizar las pautas de distribución espacial de los viajes realizados en estos sistemas de micromovilidad, centrándose, especialmente, en el caso de los sistemas de *patinetes compartidos (scooter-share)* y sistemas de bicicletas compartidas sin base de anclaje (*dockless bike-share systems*) o comparando el uso de los diferentes tipos o la competencia con algunos de los modos tradicionales. Es el caso del trabajo de McKenzie (2019a), que analiza el uso espacio-temporal de los patinetes y bicicletas utilizando los datos GPS de la empresa Lime, para comparar los patrones de uso de los vehículos de Lime con el sistema de bicicletas públicas en Washington, D.C.

En un trabajo posterior, McKenzie (2020) amplía el análisis al conjunto de empresas de micromovilidad y evalúa la competencia en términos de tiempo de viaje entre la micromovilidad y el automóvil. Reck et al. (2020) modelizan también la competencia entre diferentes modos de micromovilidad. Otros trabajos, han usado los patrones de movilidad para identificar diferencias entre usuarios, por ejemplo, entre la movilidad de los usuarios habituales y los usuarios ocasionales (Degele et al., 2018; Ji et al., 2020), o para relacionar las pautas de viaje con las condiciones del espacio construido (Bai & Jiao, 2020; Chen & Ye, 2021; Yang et al., 2019).

Los datos de los patrones espaciales, en el uso de servicios de micromovilidad, han sido utilizados también para buscar soluciones a los problemas de aparcamiento de los vehículos. Hua et al. (2020), han estimado la demanda de estacionamiento de tres compañías de *free-floating bike sharing*, utilizando datos GPS de la empresa *Mobike* y técnicas de clúster espaciales, con la finalidad de estimar la demanda de estacionamientos y establecer la ubicación de esos estacionamientos. Estas técnicas de clúster espaciales han sido usadas para buscar zonas de aparcamiento para bicicletas compartidas sin muelle utilizando un punto de vista de multiescala geográfica (Liu & Tian, 2021) o incluyendo una aproximación temporal (Xu et al., 2019). Sin embargo, estos trabajos se han centrado, mayoritariamente, en servicios de bicicletas de estacionamientos sin base fija.

Para estos sistemas de bicicletas compartidas, sin bases fijas, algunos trabajos han usado modelos de localización-asignación en *SIG*, siguiendo la metodología empleada, previamente, para las estaciones de bicicletas compartidas (García-Palomares et al., 2012), pero apoyándose ahora en los nuevos datos recogidos con GPS. Zhang et al., (2019), proponen una metodología con el propósito de ubicar cercas eléctricas o geovallas virtuales, para indicar donde estacionar las bicicletas sin bases fijas. En el desarrollo de la investigación se usaron datos GPS de los viajes recabados por la empresa *Mobike* y la solución de maximizar cobertura. Park & Sohn (2017) formulan un modelo con la finalidad de localizar las estaciones de bicicletas, utilizando datos GPS de la trayectoria de los taxis como sitios candidatos.

Por su parte Yang et al. (2020), formularon una metodología de cubos espaciotemporales para captar la demanda de bicicletas. Ellos utilizaron datos GPS del sistema de bicicletas con el objetivo de estudiar la distribución de la demanda y aplicaron las soluciones de minimizar impedancia y maximizar cobertura.

Otros trabajos plantean ubicar nuevas estaciones empleando la solución de maximizar cuota de mercado, incluyendo variables de proximidad a restaurantes, pubs, atracciones y las coordenadas de los viajes realizados por los usuarios del sistema de bicicletas compartidas de la ciudad de Baltimore (Banerjee et al., 2020).

Menos trabajos han puesto la mirada en los sistemas de motocicletas compartidas (en inglés *moped-style scooter sharing*) y son escasos aquellos que estimen las localizaciones óptimas, de algún tipo de servicio, para ellas, ya sean puntos de carga

para las baterías o estacionamientos. Entre los que han aparecido, algunos usan, nuevamente, métodos de clúster espaciales, como en el caso de Hua et al. (2020), quienes estiman la demanda de estacionamiento de algunas compañías en Nanjing (China) a partir de los datos GPS de los orígenes y destinos realizados por las motos eléctricas de la empresa Muving. Chen et al., (2018) aplican soluciones de minimizar impedancia y maximizar cobertura para ubicar estaciones de recarga de las baterías utilizadas por los patinetes eléctricos (*E-scooters*). Sin embargo, ninguno de ellos ha aprovechado la información temporal de los datos para considerar el componente dinámico del uso del sistema en los modelos de localización-asignación.

Por lo tanto, el objetivo, de este estudio de caso, es encontrar estacionamientos para los servicios de motocicletas compartidas a partir de modelos de localización-asignación SIG y datos GPS. Se ha tomado como área de estudio el centro de la ciudad de Madrid y los datos de la compañía Muving, que es uno de los principales operadores de la ciudad. Además, de la búsqueda de las localizaciones de estacionamientos para las motos, se pone interés en analizar cómo afectan los cambios en la distribución de la demanda, a lo largo del día, a la demanda asignada a los estacionamientos. Para ello se utilizan los datos del día y la hora en que se realizó el viaje y las coordenadas de origen-destino captados por los dispositivos GPS integrados en las motos eléctricas. Estos datos se han segmentado en tres franjas horarias (mañana, tarde y noche).

Los resultados de este trabajo permiten detectar los mejores lugares para ubicar los sitios donde estacionar las motos eléctricas, dependiendo de la distribución temporal de la demanda a lo largo del día. Esta información resulta de interés para la empresa de movilidad compartida y a la administración pública, que tendrán espacios reservados donde estacionar las motocicletas, dando (en parte) respuesta a los problemas y conflictos que genera su aparcamiento.

#### 4.2.2 Metodología utilizada para encontrar los aparcamientos de las motos compartidas.

Como venimos viendo a lo largo de la tesis, los MLA, en SIG trabajan a partir de la distribución de la demanda del servicio a desarrollar (en este caso usaremos el propio uso del servicio de micromovilidad), una distribución de localizaciones candidatas a la ubicación del servicio y la red para la simulación del movimiento, desde la localización

de la demanda a los puntos candidatos. Para la red utilizaremos, en este momento, una red estática que refleja el callejero de los distritos centrales de la ciudad de Madrid. Esta información es incorporada al SIG en formato vectorial, a través de capas de puntos para la demanda y las localizaciones candidatas, y de líneas para la red.

A partir de esta información existen diferentes soluciones para la búsqueda de las localizaciones óptimas y la asignación de la demanda a las mismas.

En este ejercicio se utiliza una solución para maximizar la demanda cubierta en un determinado umbral de distancia, ya que consideramos que cuando la distancia sea superior a ese umbral el servicio de motocicleta no sería usado por los usuarios.

En las siguientes líneas presentamos los detalles de la metodología propuesta para este caso concreto de estudio.

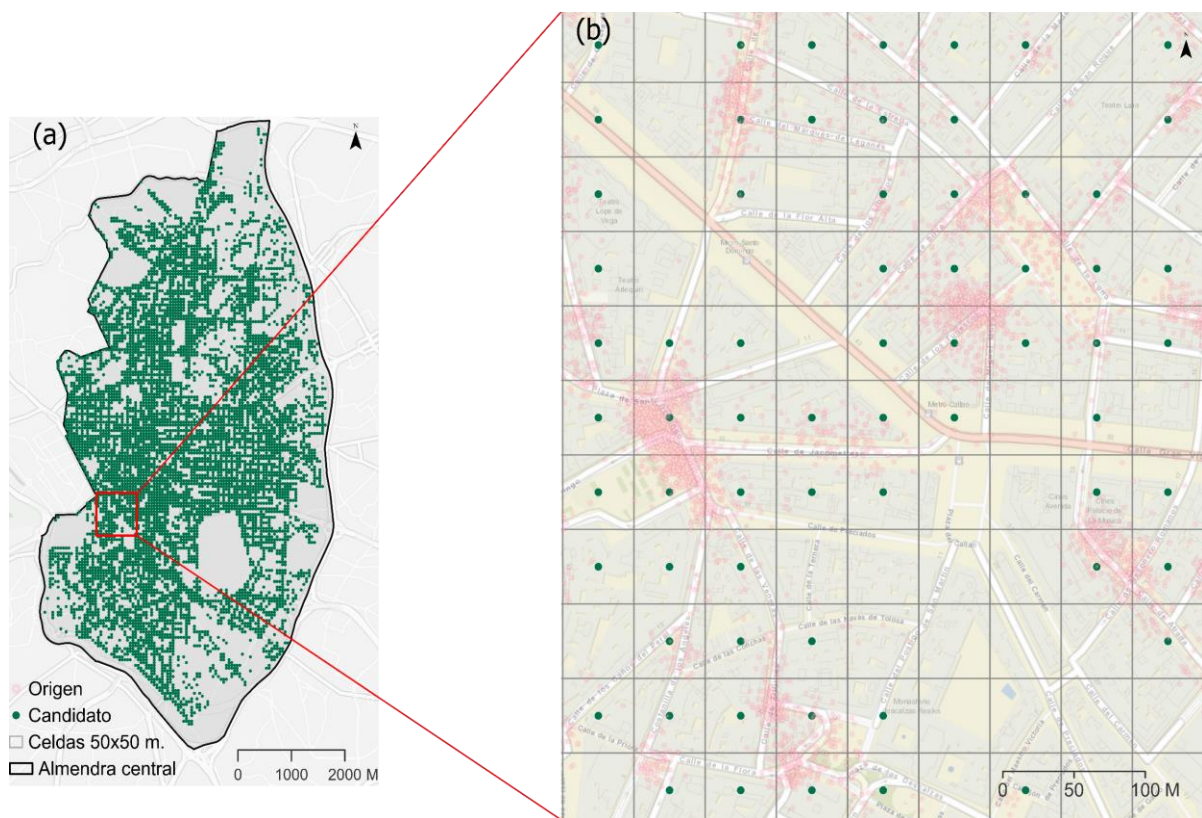
#### *4.2.2.1 Agregación de los datos*

Una vez depurados los datos, estos se agregaron, espacialmente, en una malla regular de celdas de 50 × 50 metros. La definición de la localización de la demanda en los modelos tomó el centroide de cada una de las celdas y el total de viajes con origen en las mismas. Los viajes se agruparon, temporalmente, en tres franjas horarias: mañana (7:00-13:59), tarde (14:00-18:59) y noche (19:00-00:00).

#### *4.2.2.2 Definición de los candidatos*

Se tomaron como localizaciones candidatas, a la localización de estacionamientos a aquellas celdas que suman más de cinco orígenes de viajes. En total se trata de 7.735 localizaciones candidatas, que cubren el área de estudio con un alto nivel espacial (Figura 59).

Figura 59. Localizaciones consideradas como candidatas MLA



(a) Total de localizaciones (b) detalle del centro de la ciudad. Fuente: Elaboración propia.

#### 4.2.2.3 Propuesta del modelo de localización-asignación

El número de estacionamientos a ubicar se estimó, inicialmente, en 200, teniendo en cuenta que la flota media de motocicletas de las empresas que están operando en la ciudad es de unos 800 vehículos. De esta manera, la capacidad promedio que tendrían esos estacionamientos sería de 4 vehículos. Escenarios semejantes, con el mismo número de estaciones han sido investigados para el sistema de bicicletas compartidas dentro del área de estudio (García-Palomares et al., 2012).

Por otro lado, se consideraron cuatro escenarios temporales. El escenario de referencia toma en cuenta la distribución total de la demanda a lo largo del día, considerando así la demanda de cada celda como la suma de todos los orígenes producidos desde ella. Este escenario se ha comparado con tres escenarios temporales parciales, se considera la distribución de la demanda en cada una de las tres franjas horarias en las que fueron agrupados los datos: mañana (7-13:59), tarde (14-18:59) y noche (19-00:00).

El resto de los parámetros del modelo se refieren al tipo de solución y a la distancia a recorrer por el usuario. En cuanto al tipo de solución se utilizó, maximizar cobertura, tomando como distancia límite que estaría dispuesto a caminar un usuario, hasta la motocicleta, la de 200 metros. Este tipo de modelo permite obtener ubicaciones que garantizan que, el máximo de usuarios está dentro de ese umbral de distancia o coste de desplazamiento definido (200 metros), asignando, siempre, la demanda al centro más próximo (Church & ReVelle, 1974). Esta solución y esta distancia han sido usada, en estudios previos, sobre localización óptima de estaciones de bicicletas públicas en la propia ciudad de Madrid en García-Palomares et al. (2012). En la sección 2.1.4 se mostró la función objetivo utilizada por esta solución.

A partir de los resultados de los modelos de ubicación óptima de los tres momentos temporales de mañana, tarde y noche, se ha desarrollado un proceso para obtener una quinta solución en la que se combinan esas localizaciones de la siguiente forma:

1. Se parte de los estacionamientos que aparecen en los tres momentos temporales, eliminando el de menor demanda captada en el caso de que aparezcan estacionamientos a menos de 200 metros entre ellos.
2. A esos estacionamientos se añaden aquellos que están activos en los dos momentos de tarde y noche, salvo que estén a 200 metros de una de las localizaciones incluidas en el punto 1 y eliminando la de menor demanda asignada en el caso de estar a 200 metros de otra activa en esos dos momentos.
3. Se añaden los estacionamientos que aparecen conjuntamente en la mañana y la noche, salvo que estén a 200 metros de una de las incluidas en los puntos 1 y 2, y eliminando la de menor demanda asignada, en el caso de estar a 200 metros de otra activa, en esos dos momentos.
4. Se añaden los estacionamientos que aparecen conjuntamente en la mañana y la tarde, salvo que estén a 200 metros de una de las incluidas en tres puntos anteriores, y eliminando la de menor demanda asignada, en el caso de estar a 200 metros de otra activa, en esos dos momentos.
5. Se añaden los estacionamientos que aparecen en la noche, salvo que estén a 200 metros de una de las incluidas en los puntos anteriores, y eliminando la de menor demanda asignada, en el caso de estar a 200 metros de otra activa, en la noche.

6. Se añaden los estacionamientos que aparecen en la tarde, salvo que estén a 200 metros de una de las incluidas en los puntos anteriores, y eliminando la de menor demanda asignada, en el caso de estar a 200 metros de otra activa, en la tarde.
7. Se añaden los estacionamientos que aparecen en la mañana, salvo que estén a 200 metros de una de las incluidas en los puntos anteriores, y eliminando la de menor demanda asignada en el caso de estar a 200 metros de otra activa en la mañana.
8. Este proceso se automatizó utilizando la herramienta de construcción de modelos (*Model Builder*) del programa ArcGIS Pro.

En síntesis, el estudio de caso considera cinco escenarios: (1) Escenario de referencia: utilizando la distribución de la demanda total durante el día; (2) Escenario parcial en la mañana; (3) Escenario parcial en la tarde (4) Escenario parcial en la noche; (5) Escenario optimizado: combinando las soluciones de los escenarios parciales.

Finalmente, se ha calculado un indicador para conocer la importancia de cada uno de los estacionamientos seleccionados en cada franja temporal (mañana, tarde o noche), comparando la cantidad de la demanda asignada a cada estacionamiento en ese momento temporal sobre el total de demanda de ese momento temporal con la demanda asignada para el total de demanda sobre el total de demanda, siguiendo la siguiente ecuación:

$$IE_{im} = \frac{\frac{D_{im}}{D_{tm}}}{\frac{D_{iT}}{D_{tT}}}$$

donde:

$IE_{im}$  es el Índice de especialización al estacionamiento  $i$  en la franja temporal  $m$

$D_{im}$  es la demanda asignada a la estación  $i$  en la franja temporal  $m$

$D_{tm}$  es la demanda total en la franja temporal  $m$

$D_{iT}$  es la demanda asignada a la estación  $i$  en la situación de referencia con la demanda total.

$D_{tT}$  es la demanda total.

Antes de efectuar el modelo se desarrolla un análisis temporal de los datos de viajes de la empresa Muving que serán utilizados como variable de la demanda en los

modelos presentando una serie de cuadros y figuras que describen el comportamiento espacio-temporal de los datos.


### 4.2.3 Resultados

Esta sección muestra, en primer lugar, el análisis de los patrones de los viajes realizados por los usuarios del sistema de motocicletas de Muving. Luego, presenta la distribución de la demanda según el origen y destino de los viajes. Por último, se exponen los resultados derivados de los escenarios propuestos en el desarrollo de los MLA.

#### 4.2.3.1 Características de los viajes realizados por los usuarios

La Figura 60 representa el promedio de viajes por hora y día de semana, revelando de esta forma que todos los días, en horas de 17 a 20, se presenta la media de viaje más alta (60 viajes), en cambio, todos los días en las horas de la madrugada los valores promedio son más bajos, mostrando valores menores a 10 viajes por hora. Se aprecia que a partir de las 8, empiezan a incrementar la cantidad promedio de viajes en la mayoría de los días.

Figura 60. Promedio de viajes por día y hora




Fuente: Elaboración propia.

La Figura 61 muestra la distancia media, por hora, del recorrido hecho por los usuarios de las motos Muving. Las distancias oscilan entre 3,0 y 3,6 km. Resulta curioso que el periodo de la 1 a las 3 h de la madrugada presenta los valores más altos, esto se explica porque a esas horas el metro de Madrid deja de funcionar y los usuarios

prefieren utilizar las motos, en lugar de los taxis, porque el costo es más bajo. Otro patrón observable está en las horas de las 9 hasta las 15 h, donde se presentan los valores más bajos, que tiene que ver, posiblemente, con viajes al trabajo, donde se usan estos sistemas, en la última milla del viaje o en ocasiones como una alternativa en un viaje urgente o imprevisto. A partir de las 16 las distancias son superiores.

Figura 61. Distancia media recorrida por horas




Fuente: Elaboración propia.

El análisis de la duración media de los viajes por hora se representa en la Figura 62, que revela valores medios entre 9 y 11 minutos, obsérvese que en las 18 y las 19 h se da la duración media más alta. Los menores tiempos son a primera hora de la mañana (a las 6 h). Se puede concluir que la mayoría de los viajes son relativamente cortos, no superan los 11 minutos.


El análisis de los patrones de viajes por días de la semana muestra como los viajes, tienen mayor duración al inicio del fin de semana, momento donde la población se dedica a las actividades de ocio (Figura 63).

Figura 62. Duración media de los viajes por horas



Fuente: Elaboración propia

Figura 63. Duración media de los viajes según días de la semana




Fuente: Elaboración propia.

Mientras que la distancia media recorrida por horas y por día, muestra que, en las horas de la 1 a las 3 h y de las 17 a las 23 h, los viajes tienen mayor distancia media

recorrida, mientras que se observa valores menores desde las 9 hasta las 13 h (Figura 64), reflejando, nuevamente, las diferencias entre los viajes por ocio y los vinculados al horario de trabajo.

Figura 64. Distancia media de los viajes por hora y día

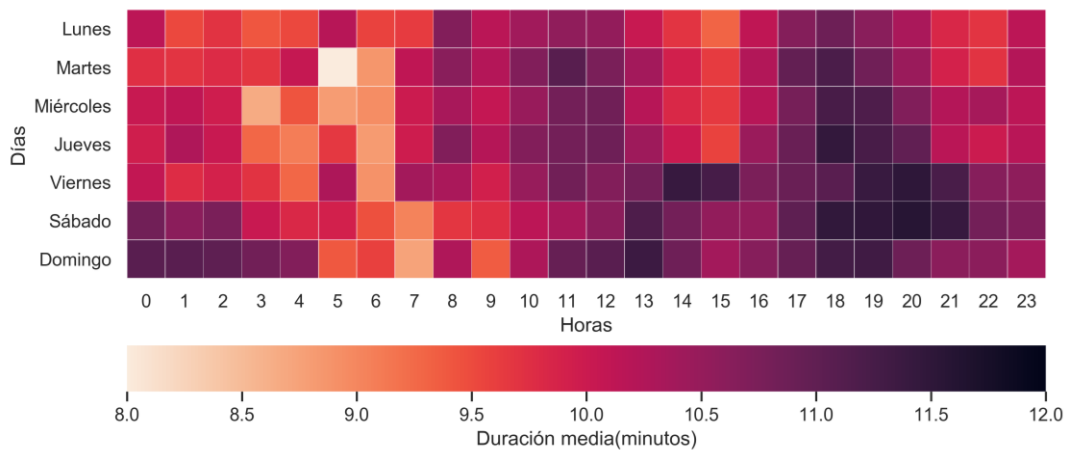


Fuente: Elaboración propia.

Para entender los patrones en la duración de los viajes, la explicación se apoya en la Figura 65, que ilustra la duración media, en minutos, en las diferentes horas y días de la semana. Se concluye que todos los días de la semana, la duración media de los viajes presenta valores más elevados en las horas 17 a 21, período donde la población vuelve a sus hogares o sale en busca de ocio que caracteriza la vida nocturna de Madrid, en cambio, la duración media menor se da en las horas de la madrugada, con excepción de los días sábado y domingo.

Al comparar la Figura 64 y Figura 65, se observa que los tiempos de viajes son mayores en la tarde que en la noche. Mientras que en las distancias es lo contrario. Eso significa que las velocidades son mayores en la noche porque hay menos tráfico y por el tipo de actividad que realiza la población (ocio nocturno).


Figura 65. Duración media en minutos de los viajes por hora y día



Fuente: Elaboración propia.

La Figura 66 muestra la distribución de viajes horarios según los meses. En la mayoría de los meses se producen más viajes entre las 13 y las 22 h, con excepción de los meses de noviembre y diciembre, que pueden estar vinculados al hecho de que esos son los meses de invierno en Madrid, mientras que la menor cantidad de viajes por hora se observa en las horas de la madrugada.

Figura 66. Viajes mensuales por horas



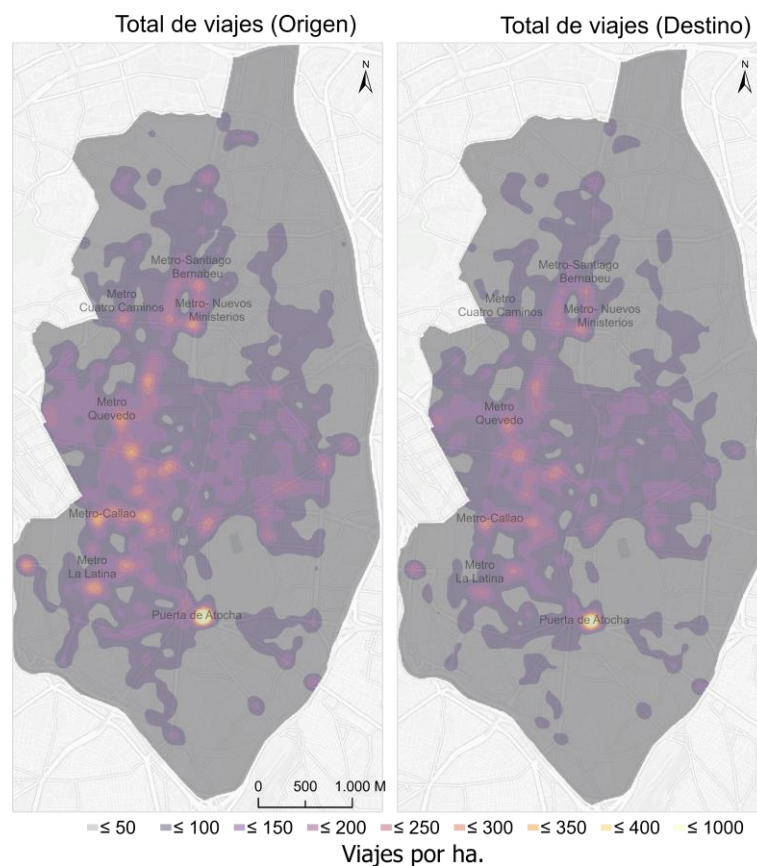
Fuente: Elaboración propia.

El análisis previo de los datos aporta ideas acerca de los patrones del comportamiento de los usuarios del servicio de motos compartidas. Esto es de gran importancia para el desarrollo del modelo de localización de los estacionamientos para las motos de la empresa Muving, ya que, tanto los candidatos como la demanda se extrae de este conjunto de datos.

#### 4.2.3.2 Distribución de la demanda: origen y destino de los viajes

Los modelos parten de la distribución de la demanda de viajes, que será considerada como distribución de la demanda. La Figura 67 presenta la densidad de viajes por hectárea, según origen y destino. Se observa, tanto en orígenes y destinos, una concentración en las zonas centrales y el eje de Nuevos Ministerios-Castellana. Cerca de la Estación de Puerta de Atocha se registró una gran concentración de viajes. Las estadísticas descriptivas de los viajes según origen y destino por hectárea tienen un promedio de 46,8 y 56,1 de viajes por hectárea, respectivamente, con distribuciones, relativamente, similares tal como muestran los coeficientes de variación (Tabla 30).

Figura 67. Densidad de viajes por hectáreas según origen y destino del viaje



Fuente: Elaboración propia.

La principal diferencia estriba en la mayor concentración de viajes con origen en los entornos de las estaciones de tren y metro, particularmente, en la estación de Atocha, donde se marca un máximo de 687 orígenes de viajes por hectárea frente a los 564 destinos.


Tabla 30. Estadísticas descriptivas de la densidad de orígenes y destinos de viajes por hectárea

Viajes	Media	Std.dev.	Coefficiente de variación	Máx.	Min.
Origen	56,1	52,5	93,6	687	0
Destino	46,8	44,0	94,0	564	0

Fuente: Elaboración propia.

La Figura 68 muestra la distribución de la demanda agrupada en las tres franjas temporales consideradas. El mayor uso del sistema se produce en la noche, con densidades medias por encima de los 19 orígenes por hectárea y valores que superan los 200 orígenes por hectárea en muchas zonas del centro de la ciudad (Tabla 31). Al contrario, el uso del sistema es mucho menor en la franja de la mañana, incluso a pesar de contar con dos horas más.

Figura 68. Densidad de viajes (orígenes) por hectáreas según franjas horarias



Fuente: Elaboración propia.

La tarde presenta una situación intermedia entre las dos anteriores. Además, de las diferencias en la cantidad de viajes, también aparecen diferencias en la concentración espacial de los mismos. Así, en la mañana la distribución espacial es más homogénea y las zonas más residenciales tienen intensidades similares a los espacios de actividades, tal como muestran los mapas y los menores coeficientes de variación en esta franja temporal (Tabla 31). En la tarde las mayores densidades se concentran en áreas de actividad, como la zona de oficinas de Azca. Mientras que, en la noche la distribución es más desigual, con densidades de orígenes de viajes muy altas en los espacios de ocio y restauración del distrito centro.

Tabla 31. Estadísticas descriptivas de la densidad de orígenes por hectárea y franja temporal

Viajes	Media	Std.dev.	Coefficiente de variación	Máx.	Min.
Mañana	14,0	12,2	87,1	172,8	0,0
Tarde	16,4	15,3	93,3	206,5	0,0
Noche	19,3	19,5	101,0	250,2	0,0

Fuente: Elaboración propia.

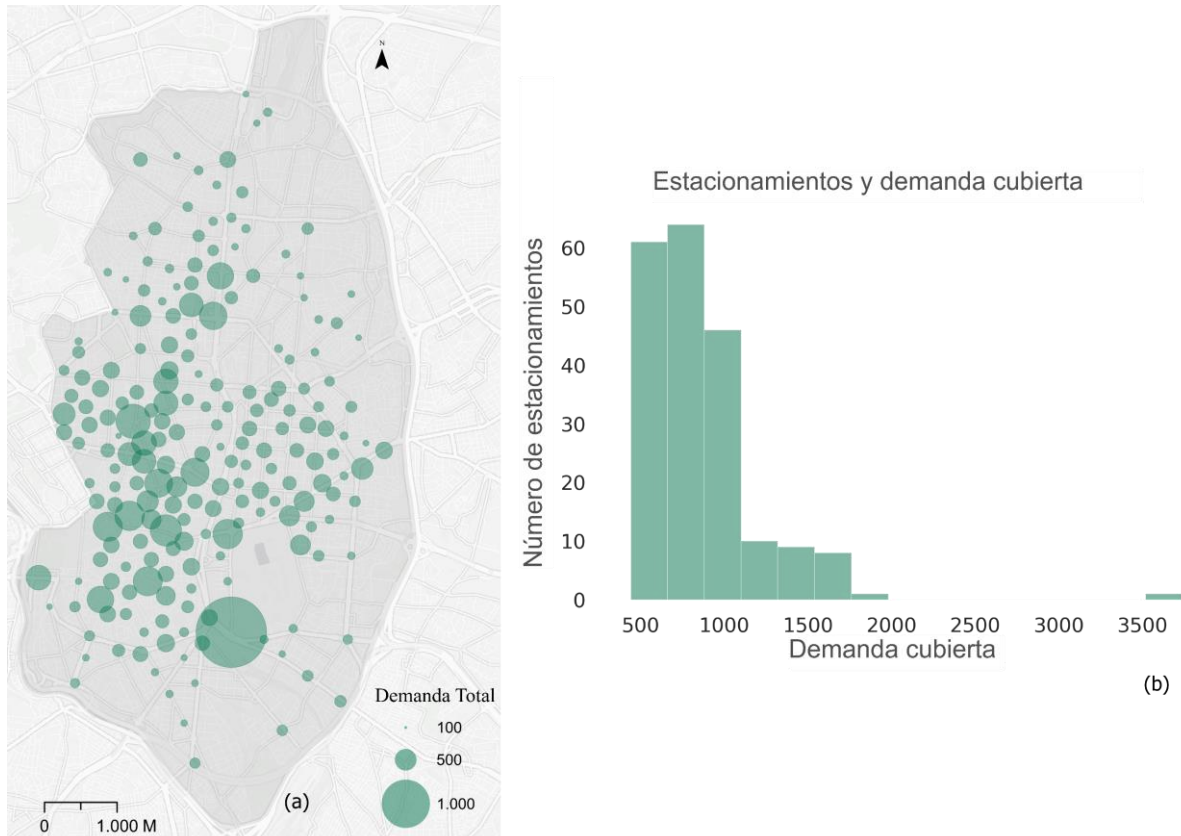
#### 4.2.3.3 Propuesta de localización óptima de estacionamientos para la distribución de la demanda total

La Figura 69 contiene los resultados obtenidos considerando el total de viajes diario, según orígenes (escenario de referencia). El tamaño del símbolo muestra el total de demanda asignada a cada uno de los estacionamientos. Con esta distribución de 200 estacionamientos, quedarían cubiertos a una distancia de 200 metros algo más de 170.000 de los orígenes de los viajes, un 72 % del total (Tabla 32).

El mayor número de estacionamientos se localiza en las zonas del distrito Centro, en relación con los espacios de consumo, ocio y empleo, además, de las estaciones de tren e intercambiadores de transporte (como Atocha y Nuevos Ministerios). La media de la demanda asignada por estacionamiento es de 850 viajes, pero, además, el histograma de frecuencias de estacionamientos, según demanda asignada, evidencia una distribución asimétrica sesgada hacia la derecha, donde la mayor parte de los estacionamientos tienen demandas asignadas menores a 1000 viajes para ese periodo de 11 meses (unos 90 viajes mensuales). Alrededor de 30 estacionamientos,

únicamente, superarían los 1.000 orígenes asignados y, en un solo caso, en el entorno de la Estación de Atocha, se superan los 2.000 orígenes, alcanzando un total de 3.300 (300 orígenes de viajes mensuales).

Figura 69. Escenario de referencia: localización óptima de los estacionamientos a partir del total de los orígenes de los viajes.



(a) Escenario de referencia: localización óptima de los estacionamientos basados en el total de orígenes de viajes. (b) Distribución de la demanda cubierta por estacionamiento. Fuente: Elaboración propia.

Tabla 32. Estadística descriptiva de la demanda cubierta en el escenario de referencia según estacionamiento.

Demanda	Media	Mediana	Std. dev.	Min.	Max
170.426	852,3	784	357	441	3.739

Fuentes: Elaboración propia.

#### 4.2.3.4 Impacto de los cambios en la distribución de la demanda a lo largo del día

Con el fin de conocer, los efectos de la distribución espacial cambiante de la demanda a lo largo del día en la cobertura de la propuesta de ubicaciones obtenida en el escenario de referencia, a continuación, se ha calculado la demanda cubierta por esos estacionamientos en cada una de las tres franjas temporales.

La Tabla 33 muestra como el porcentaje de cobertura oscila entre 69,1% en la mañana y 73,1% en la franja de la noche. La mayor demanda de la noche y su mayor concentración en los espacios centrales hace que la eficiencia de la red de estacionamientos sea superior en esa franja que, en el conjunto del día, capturando un 1,2% más de demanda, en ese momento, que en la situación con el total de demanda. Al contrario, la mayor dispersión en los viajes en la mañana repercute en la eficiencia de los estacionamientos en esta franja horaria, que captan un 2,8% menos de orígenes de los viajes en esta franja.

Tabla 33. Escenario de referencia: demanda cubierta por franjas horarias

Mañana (7:00-13:59)		Tarde (14:00-18:59)		Noche (19:00-00:00)	
Total	%	Total	%	Total	%
41.056	69,1	49.331	70,9	59.769	73,1

Fuente: elaboración propia.

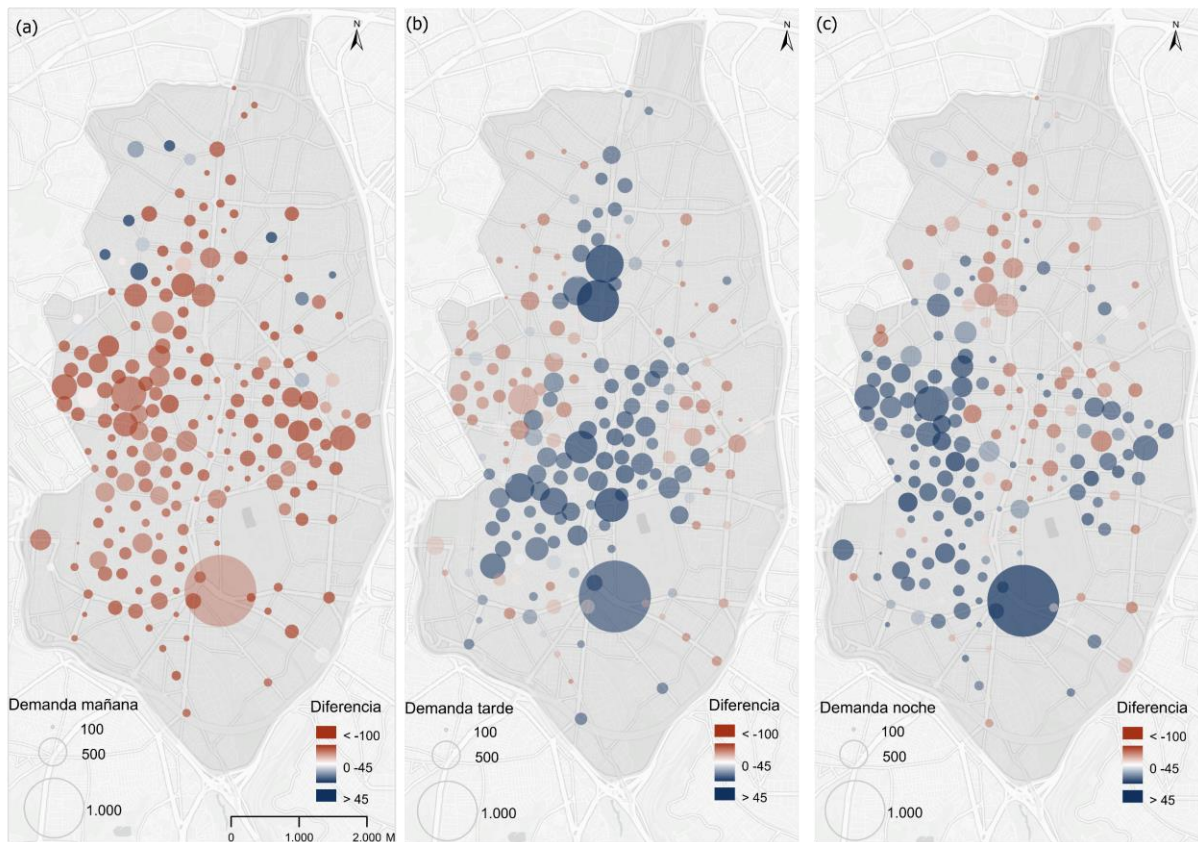
La Figura 70 muestra las demandas asignadas a cada estacionamiento, según franjas temporales (tamaño de los símbolos) y las diferencias entre la demanda asignada a cada una de las ubicaciones de estacionamientos entre las franjas horarias. La demanda asignada a los estacionamientos, en la mañana (Figura 70a), es mucho más homogénea que en la tarde (Figura 70b) y en la noche (Figura 70c), de manera que, aunque los estacionamientos más centrales tengan demandas asignadas mayores, las diferencias con los estacionamientos más periféricos se reducen y, únicamente, destaca con fuerza el estacionamiento en el entorno de la Estación de Atocha (que lo hace en las tres franjas).

En cambio, en la tarde la demanda de estacionamientos en espacios del centro y de áreas de actividad, especialmente del eje Prado-Recoletos-Castellana, se incrementa con fuerza, mientras se reduce la demanda asignada a los estacionamientos en espacios residenciales más periféricos. En la noche, esos estacionamientos del eje

Prado-Recoletos-Castellana pierden, nuevamente, demanda asignada, mientras se incrementa en los espacios de consumo y ocio de distritos como Centro, Chamberí o Salamanca.

En consecuencia, si nos fijamos en las diferencias entre franjas temporales, la mayor demanda en la noche hace que la mayor parte de los estacionamientos tengan más viajes asignados en la noche que en la mañana, aunque en algunas zonas residenciales de Tetuán o Salamanca existen algunos estacionamientos con más viajes en la mañana. Estas diferencias se muestran, también, entre la mañana y la tarde, donde las zonas más residenciales tienen más viajes en la mañana y las de mayor actividad captan más en la tarde. Entre la tarde y la noche la diferencia se da entre los espacios de actividad de áreas en el entorno de la Castellana, con una mayor demanda en la tarde, y las zonas de consumo y ocio de espacios como Chamberí o Centro, que destacan por la demanda captada en la noche.

Figura 70. Escenario de referencia: Demanda cubierta por cada estacionamiento y diferencias en la demanda cubierta total entre franjas horarias.

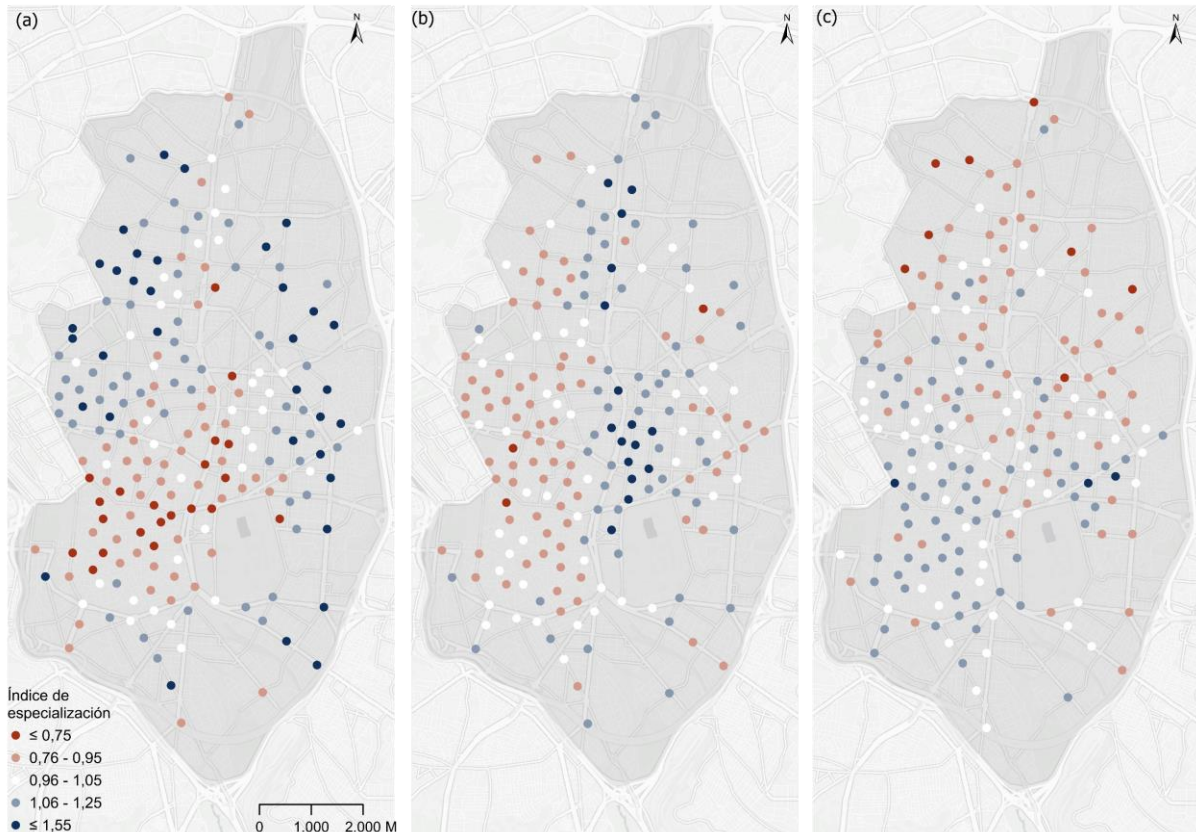


(a) Mañana-noche. (b) Tarde-mañana. (c) Noche-tarde. Fuente. Elaboración propia.

Con el fin de analizar el grado de importancia de la demanda captada en cada estacionamiento y en cada franja temporal, en relación con la que captan en el escenario de referencia (con la demanda total), se han calculado índices de especialización (Figura 71). De esta forma, los colores azules muestran estaciones con un mayor peso en ese momento temporal concreto y los rojos estaciones con un peso menor respecto a la situación en el escenario de referencia. En blanco quedan las estaciones que en ese momento tienen un comportamiento similar al escenario de referencia. Una situación óptima del sistema sería aquella donde los estacionamientos tuvieran demandas asignadas similares (círculos de tamaños similares en la figura anterior) y que se mantuvieran homogéneas a lo largo del día (primando ahora los colores blancos en las tres situaciones temporales).

Los resultados muestran, con mayor claridad, las diferencias en la especialización de las estaciones, en función de si se sitúan en zonas eminentemente residenciales (colores azules en la franja de la mañana), zonas de empleo, de oficinas (azules en la tarde), de ocio y restauración (azules en la noche). La situación en la noche, que al ser la que mayor demanda tiene, es la que más influye en el escenario de referencia y muestra los niveles de especialización menores (valores en torno a 1 y colores claros). Mientras en la mañana aparecen estacionamientos que tienen mucha importancia en ese momento (los residenciales, en azules intensos) o mucho menor (áreas de actividad, en rojos).

Figura 71. Escenario de referencia: Nivel de especialización de los estacionamientos según franja temporal.



(a) Mañana. (b) Tarde. (c) Noche. Fuente: Elaboración propia.

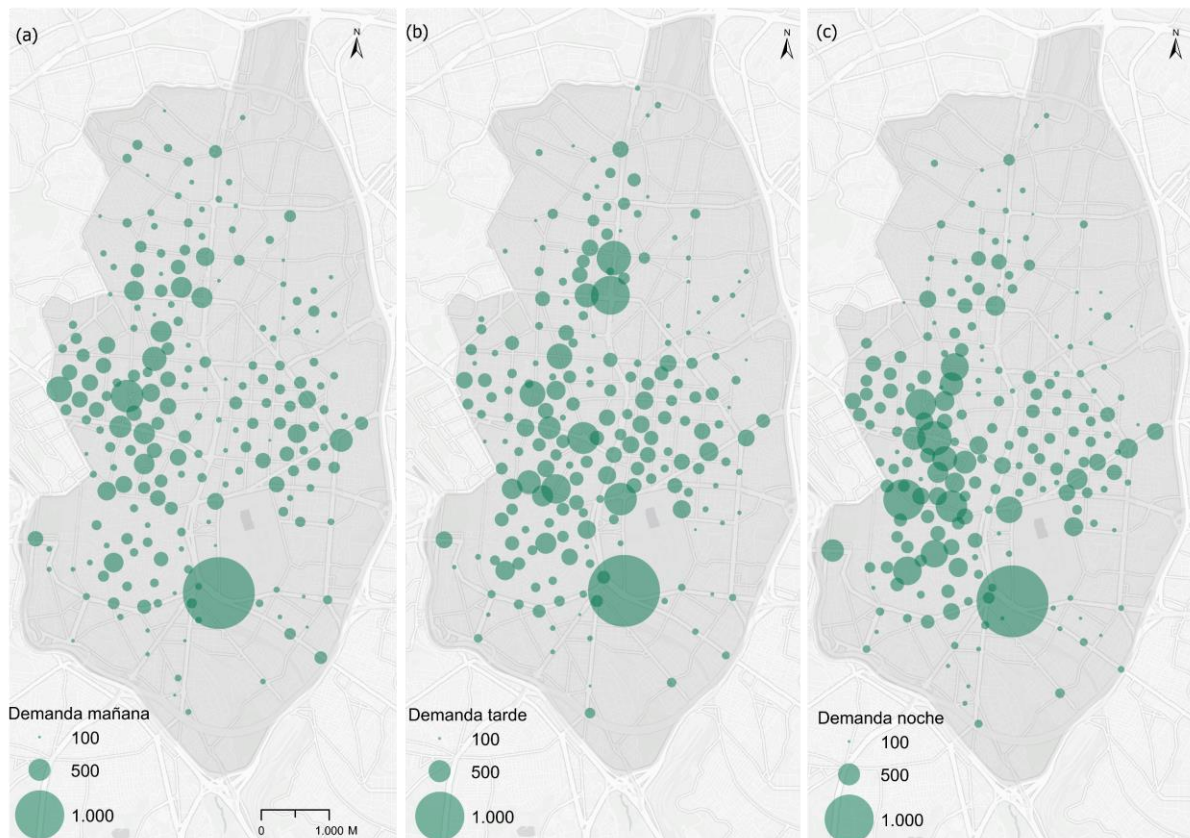
#### 4.2.3.5 Modelos adaptados a los cambios en la distribución de la demanda

Se ha calculado un modelo de localización de las plazas de aparcamiento para cada una de las franjas horarias (escenarios parciales), para evaluar las mejoras en la cobertura de posibles modelos que consideren, la activación o no de una plaza de aparcamiento en función de la hora. Esta solución sería algo similar a las plazas de aparcamiento reservadas para la entrega de mercancías o determinados servicios, como, por ejemplo, las farmacias, en las que se reserva el aparcamiento para estas actividades dentro de una franja horaria determinada. No obstante, tendría la limitación de que algunos vehículos podrían permanecer en la plaza de aparcamiento fuera de la franja horaria asignada, lo que podría aumentar los costes si la empresa tuviera que redistribuir los vehículos.

La Figura 72 muestra las ubicaciones de estacionamientos óptimas para cada uno de los escenarios temporales y el total de orígenes de viajes asignados a cada uno de

los estacionamientos (a partir del tamaño de los símbolos). Como puede apreciarse, las distribuciones son, relativamente, similares, aunque con una mayor dispersión de estacionamientos en la mañana, donde aparecen más estacionamientos, en los espacios residenciales de los bordes del área de estudio, y un reparto más homogéneo total de viajes asignados. Por el contrario, la distribución de estacionamientos en la tarde y, fundamentalmente, en la noche, se concentra con más fuerza en los espacios centrales, con mayores diferencias en el total de viajes asignados entre estas estaciones y las más periféricas.

Figura 72. Escenarios parciales: Ubicación óptima de estacionamientos con modelos dinámicos adaptados a la demanda en cada una de las franjas temporales



(a) Mañana. (b) Tarde. (c) Noche. Fuente: Elaboración propia.

En todo caso, la Tabla 34 muestra que las ganancias de demanda cubierta en los tres casos sobre el escenario de referencia son muy pequeñas. En la mañana el modelo capta un 1% más de los orígenes de los viajes en esa franja que el escenario de referencia, mientras en la tarde y la noche apenas se alcanza un 0,5% más.

Tabla 34. Demanda cubierta por los estacionamientos en cada uno de los momentos temporales

Escenario	Mañana (7:00-13:59)			Tarde (14:00-18:59)			Noche (19:00-00:00)		
	Total	%	Dif. %	Total	%	Dif. %	Total	%	Dif. %
Escenario referencia	41.056	69,1		49.331	70,9		59.769	73,1	
Escenario parcial	41.650	70,1	1,0	49.577	71,2	0,4	60.162	73,6	0,5

Fuente: Elaboración propia.

Aunque las distribuciones son, relativamente similares, únicamente 35 estacionamientos aparecen activos en las tres franjas temporales. Esto es poco más del 15% de los 200 que se localizan en cada caso (Tabla 35). Por el contrario, más del 50% de los establecidos en cada franja temporal no aparecían en los otros dos periodos.

Tabla 35. Escenarios parciales: Número de estacionamientos según la franja temporal en la que aparecen activos

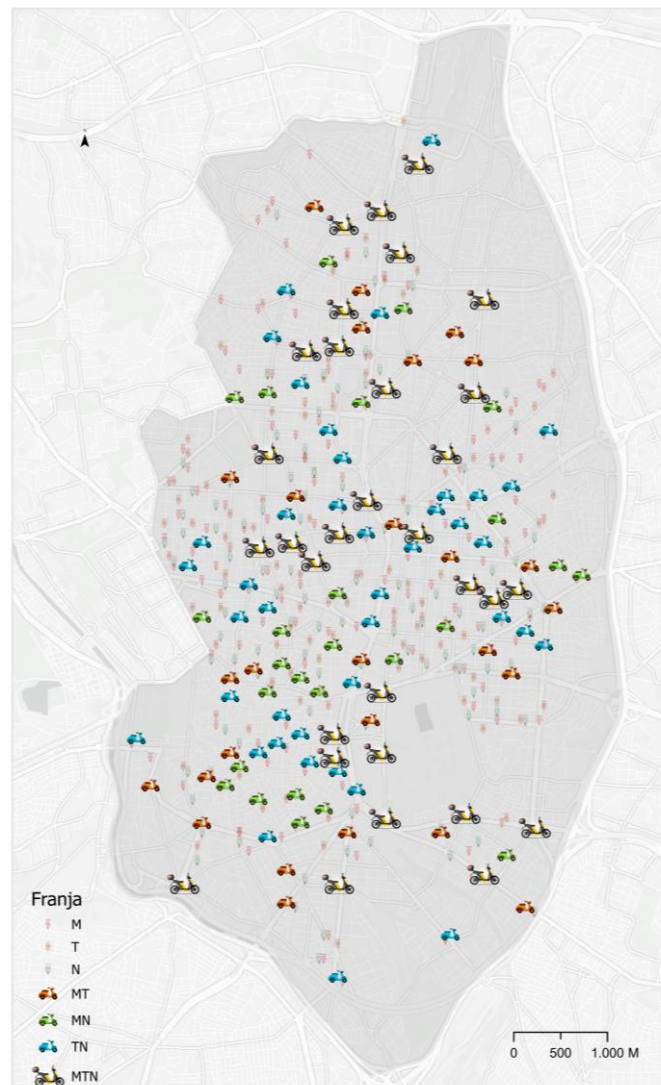
Franja	Total	%
Mañana	116	58,0
Tarde	101	50,5
Noche	102	51,0
Mañana Tarde	27	13,5
Mañana Noche	26	13,0
Tarde Noche	41	20,5
Mañana Tarde Noche	31	15,5

Fuente: Elaboración propia.

Las mayores coincidencias se dan entre la tarde y la noche, que tienen 41 estacionamientos comunes, mientras entre la mañana y la tarde hay 27 y entre la mañana y la noche hay 26 estacionamientos comunes. La Figura 73 muestra la distribución espacial de estos estacionamientos según el momento temporal en el que aparecen. En cualquier caso, como se muestra en la figura, en muchas ocasiones los estacionamientos de diferentes momentos temporales están muy próximos entre ellos.

A partir del mapa expuesto, y siguiendo la metodología explicada anteriormente, se ha obtenido un último modelo de localización de plazas de aparcamiento. Este escenario optimizado cuenta con un total de 229 plazas de aparcamiento, lo que supone un 14,5% más que en el escenario inicial de referencia. Con estas plazas de aparcamiento, el número total de orígenes cubiertos sería de 178.982, un 75,5%, lo que representa un 3,6% más, que en el escenario de referencia con 200 plazas de aparcamiento. Este modelo no sólo tiene una mayor cobertura en todas las franjas horarias, sino que tiene la ventaja de reducir las diferencias en la demanda cubierta entre las franjas horarias, produciendo un modelo más equilibrado en el tiempo (Tabla 36 y Figura 74).

Figura 73. Escenario optimizado: Número de estacionamientos por franja temporal



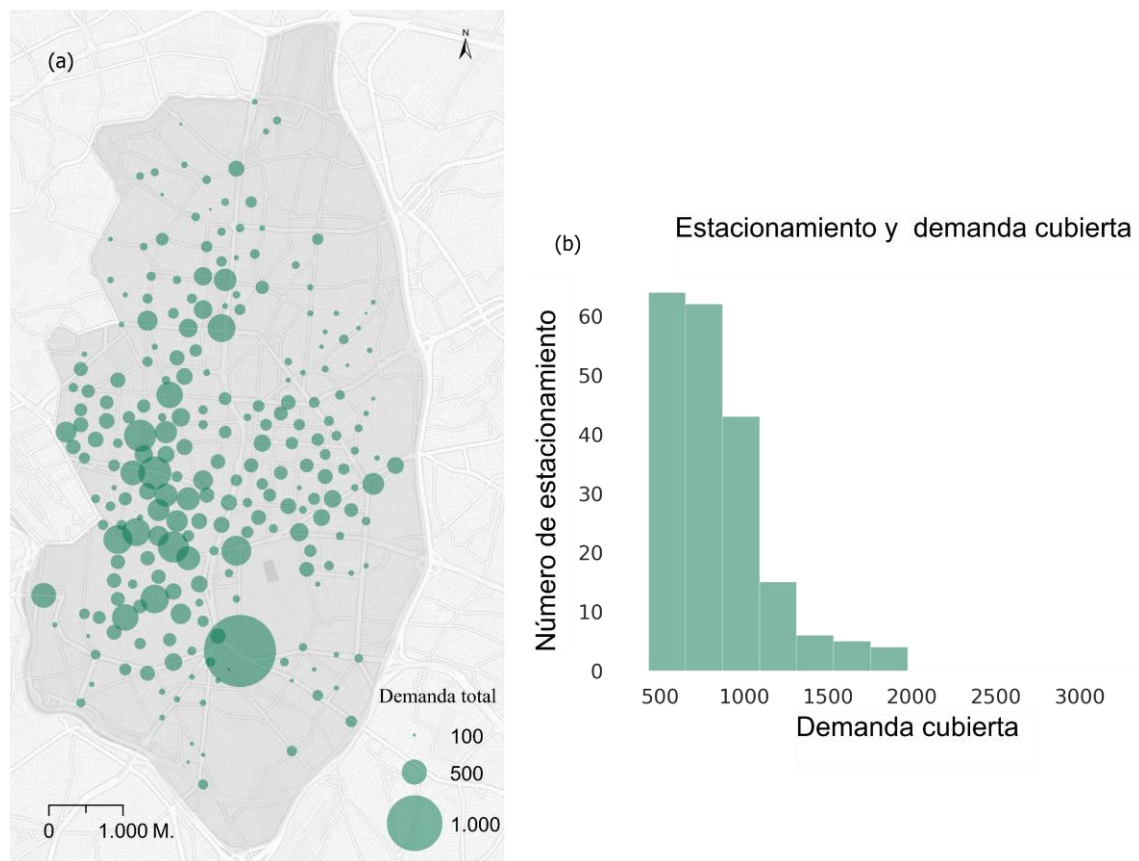
(M = Mañana, T = Tarde, N = Noche, MT = Mañana tarde, MN = Mañana noche, TN = tarde noche, MTN = Mañana tarde noche). Fuente: Elaboración propia.

Tabla 36. Demanda cubierta por los estacionamientos en cada uno de los momentos temporales según modelos.

Modelo	Mañana		Tarde		Noche	
	Total	%	Total	%	Total	%
Modelo referencia	41056	69,1	49331	70,9	59769	73,1
Escenario optimizado	43509	73,2	51865	74,5	62649	76,6

Fuente: Elaboración propia.

Figura 74. Escenario optimizado



(a) Distribución final de los estacionamientos y demanda asignada. (b) Distribución de la demanda cubierta por estacionamiento. Fuente: Elaboración propia.

### **4.3 Modelos con demanda variable en el tiempo y redes dinámicas de transporte privado: aplicaciones a la localización de estaciones para un servicio de emergencias médicas**

#### 4.3.1 Caso de estudio: localización de estaciones del Servicio de Asistencia Municipal de Urgencia y Rescate de Madrid (SAMUR-PC)

Cada día, más personas, en zonas urbanas de todo el mundo sufren, algún tipo de suceso, tales como: accidentes de tráfico, otros accidentes no relacionados con el tráfico y otro tipo de sucesos que requieren de la rápida intervención de los Servicios Médicos de Emergencia (SME). Es crucial que los SME puedan llegar lo antes posible al lugar del suceso y con los medios necesarios para el rescate de los afectados (Strohmandl et al., 2021). Por un lado, puede suponer un alivio psicológico del afectado y otras personas que están en el mismo lugar del suceso, al estar, rápidamente, en manos de los profesionales sanitarios. Además, se pueden tomar decisiones a tiempo que reduzcan la lesividad derivada del suceso e, incluso, incrementen la posibilidad de supervivencia en los casos de mayor gravedad (Pons et al., 2005). La rapidez con la que los SME pueden atender sucesos que requieren de atención médica, una vez activado el recurso, depende de la accesibilidad del recurso al suceso. Esta accesibilidad está condicionada, en gran medida, por la ubicación inicial del recurso activado, principalmente, en las bases del SME, y por el estado del tráfico de la ruta que lo une al lugar del suceso (Zhou et al., 2020). Esto varía según horas y días.

Generalmente, el dimensionamiento del SME (el número de bases, distribución espacio-temporal y dotación de recursos asignada, entre otros) debe responder, adecuadamente, a una variedad de escenarios probables, en los que concurren un conjunto de sucesos al mismo tiempo; ellos activan una serie de recursos de los cuales, un porcentaje predeterminado debe ser atendido sin superar tiempos máximos determinados (Schmid, 2012). Estos tiempos suelen estar establecidos por normativas en base a estudios y recomendaciones que son recogidos bajo el concepto de accesibilidad normativa (Páez et al., 2012). Para asistir a la toma de decisión en el dimensionamiento de dichos servicios, los Sistemas de Información Geográfica (SIG) y, en particular, aquellos que permiten generar diversas soluciones, ateniendo, a diferentes Modelos de Localización-Asignación (MLA), son herramientas de especial

interés. El resultado de estos modelos ofrece, como mínimo, propuestas de ubicaciones óptimas o cercanas al óptimo de entre el conjunto de localizaciones candidatas, según el tipo de función objetivo y restricciones operativas (Bolouri et al., 2020). De la misma manera, se puede usar dichos modelos para evaluar situaciones actuales.

Parte de la creación de escenarios posibles para el dimensionamiento de los SME, pueden estar estrechamente ligados con la distribución espacio-temporal de la población, que, también, cambia a lo largo del día y depende, en cierta medida, de la especialización del suelo. Sin embargo, estos patrones relativos, expresión de la vida cotidiana, fueron alterados por la aparición de la pandemia de la COVID-19 que obligó, a muchos gobiernos, a tomar medidas drásticas que limitaban la actividad y movilidad permitida, especialmente, durante las primeras olas de la pandemia en 2020 (Hunter et al., 2020). En esta situación se daban varios fenómenos opuestos que podían afectar al rendimiento del dimensionamiento de SME. Por un lado, la limitación de movilidad implicaba una red viaria sin apenas congestión, con lo que los tiempos de acceso a los sucesos podían ser semejantes a los observados durante la noche, cuando se suele circular en velocidad de flujo libre. Por el otro, la distribución espacial de la población era diferente a la prevista y, por ende, la distribución de los sucesos no era la habitual, pues limitar la movilidad y las actividades también podía limitar el número de sucesos a los que los servicios de SME debían atender.

Un caso que se puede considerar excepcional del cambio de actividad, por la COVID-19, es la ciudad de Madrid (España). España ha sido uno de los países más afectados por la pandemia. A lo largo del 2020 se registraron 50.837 muertes y 1.928.265 contagios (Ministerio de Sanidad, 2020). Ante el rápido aumento del número de casos confirmados, el Gobierno español se vio obligado a declarar el estado de alarma sanitario, el 14 de marzo de 2020; estableciendo medidas de confinamiento a los ciudadanos, como alternativa para frenar el creciente contagio de la población. Esta situación provocó que la ciudad de Madrid cambiase el ritmo de su actividad, la ciudad se paró (Romanillos et al., 2021). El transporte público de Madrid registró una reducción del 82,5% en la cantidad de usuarios (Moovit, 2020), y el tráfico cayó un 66% en los meses del confinamiento, según datos de TomTom (TomTom, 2020). En consecuencia, la actividad de los SME de la ciudad también sufrió cambios.

El SME de la ciudad de Madrid es el Servicio de Asistencia Municipal de Urgencias y Rescate – Protección Civil, más conocido por su acrónimo SAMUR-PC. El SAMUR-PC sólo atiende los sucesos que ocurren en vía pública y en los locales abiertos al público. Disponía de un total de 218 vehículos, en diciembre de 2019, repartidos en 22 bases permanentes, de los cuales 88 vehículos estaban destinados para el traslado de afectados (ambulancias con personal sanitario cualificado) y 50 vehículos se destinaron para facilitar el acceso del personal sanitario a localizaciones de los sucesos (SAMUR, 2020). En esta institución trabajan 901 personas en diferentes puestos, entre los que se encuentran: personal técnico, médicos, enfermeros, psicólogos, administrativos y farmacéuticos. Durante 25 años han prestado 2,5 millones de servicios de asistencia, con un tiempo medio de llegada de ocho minutos. Mientras que el SAMUR-PC atendió una media de 340 sucesos/día en 2019, este valor bajó casi un 30% para 2020.

El presente caso de estudio tiene dos objetivos principales. El primero es el estudio de cuál fue el desempeño teórico, según el número de sucesos que podrían ser atendidos dentro de unos tiempos máximos, del SAMUR-PC, para la ciudad de Madrid para los años 2019 y 2020, año anterior a la pandemia de la COVID-19 y año de dicha pandemia respectivamente. El segundo consiste en proponer posibles cambios y aumento del número de estaciones, en ambos años, con el fin de mejorar las prestaciones del servicio. Para conseguir los dos objetivos, se usan los datos reales de los sucesos atendidos por el SAMUR en ambos años, los cuales se segmentaron por tipo de día (laborable o de fin de semana) y para tres franjas horarias. A su vez, se usaron redes viarias que están definidas con las velocidades medias observadas para dichas franjas horarias y tipos de días. Hay que señalar que el resto de los servicios SME, como, por ejemplo, el atender urgencias médicas en domicilios, son competencia del Servicio de Urgencias Médicas de Madrid (SUMMA) y que, por falta de acceso a datos, no se han incluido en este trabajo.

Según el conocimiento del autor son pocos los trabajos que, hasta la fecha, han incluido, de manera simultánea, en MLA el dinamismo observado en los sucesos reportados por el SME con la variación de las velocidades de la red vial. Del mismo modo, no se conoce ningún estudio donde se hayan evaluado dos escenarios reales tan dispares como el del año de la pandemia de la COVID-19 y el anterior, pudiendo ofrecer una valoración del grado de resiliencia del SME en casos extremos.

Finalmente, hay que destacar que los resultados del presente estudio pueden ser de interés para la administración pública a la hora de plantear y diseñar cambios en los SME, con el fin de ofrecer un mejor servicio de emergencias a los ciudadanos.

El caso de los MLA para servicios médicos de urgencia se han estudiado durante años, probando diversos algoritmos y soluciones (Dibene et al., 2017). Entre los métodos empleados la solución para maximizar la cobertura del servicio es el más utilizado para formular problemas de localización de ambulancias (Jia et al., 2007). En el trabajo de Eaton et al. (1985) se propone el uso del modelo de cobertura máxima para planificar un servicio de emergencias médicas, buscando reducir el tiempo de respuesta.

Otros trabajos buscan maximizar el peso de la demanda cubierta y simultáneamente minimizar la distancia media a la población no cubierta (Yin & Mu, 2012). Por otro lado, Azizan et al. (2012) utilizan la solución de máxima cobertura con algoritmos genéticos y redes de OpenStreetMap. Strohmmandl et al. (2021) evalúan la situación actual de un servicio médico de urgencia y proponen el número óptimo de estaciones para atender con éxito las emergencias en la Región Autónoma de Žilina (Eslovaquia). En su planteamiento, utilizan las soluciones de maximizar la cobertura y minimizar las instalaciones.

En la actualidad, producto del surgimiento de nuevas fuentes de datos, se han desarrollado MLA de ambulancias que incorporan el tráfico histórico en la red y registros GPS con las coordenadas de los sucesos atendidos. Zhou et al. (2020) proponen un modelo de localización, utilizando datos de velocidad en la red, considerando el tiempo, la población y los puntos de interés. El flujo vehicular se obtuvo de la aplicación *Gaode* y aplicaron la solución maximizar cobertura. Sun et al. (2020) formularon un modelo dinámico para la selección de estaciones de ambulancias móviles. En su enfoque utilizaron las bases actuales como candidatas, mientras que la demanda se extrae a partir de registros históricos de las coordenadas de los sucesos asistidos.

Por otro lado, existen estudios que utilizan los propios registros GPS con la localización de sucesos atendidos por los proveedores de servicios médicos de urgencia. Por ejemplo, Dibene et al. (2017) consideran la ubicación de ambulancias en Tijuana, México, mediante la clasificación de la demanda de acuerdo con su

comportamiento a lo largo del día, y evalúa los días de semana y los fines de semana, utilizando, para ello, el sitio de las llamadas de emergencia. El trabajo de Rajagopalan et al. (2008) realiza un modelo para determinar el número mínimo de ambulancias y su distribución para cada momento del día cuando se produzcan cambios significativos en el patrón de la demanda, al tiempo que se cumple con el requisito de cobertura con una fiabilidad predeterminada.

Por su parte, Zhu et al. (2016) analizan las características de la distribución de la demanda y las ubicaciones candidatas de los centros de traumatología basándose en el análisis espacial. Presentan un modelo jerárquico de localización-asignación de los servicios sanitarios con un bajo y alto nivel de cobertura en Shenzhen, utilizando los registros GPS de los traumas atendidos. Emplean las soluciones de cobertura máxima y minimización de la impedancia. Otra investigación propone utilizar datos históricos de sucesos (incendios) para reflejar la variabilidad de los sucesos. Los autores realizaron el estudio en Nanjing, China. Para lograr su objetivo, emplean la solución maximizar cobertura con algoritmos genéticos (Yu et al., 2020).

En resumen, ninguno de los trabajos anteriores utilizó los datos de tráfico de TomTom para la construcción de la red. En el caso particular de los estudios que utilizan registros GPS de los sucesos atendidos por los servicios médicos de urgencia, se encuentra que no aprovechan la información temporal para considerar la variación de la demanda, durante el día, al ejecutar los MLA.

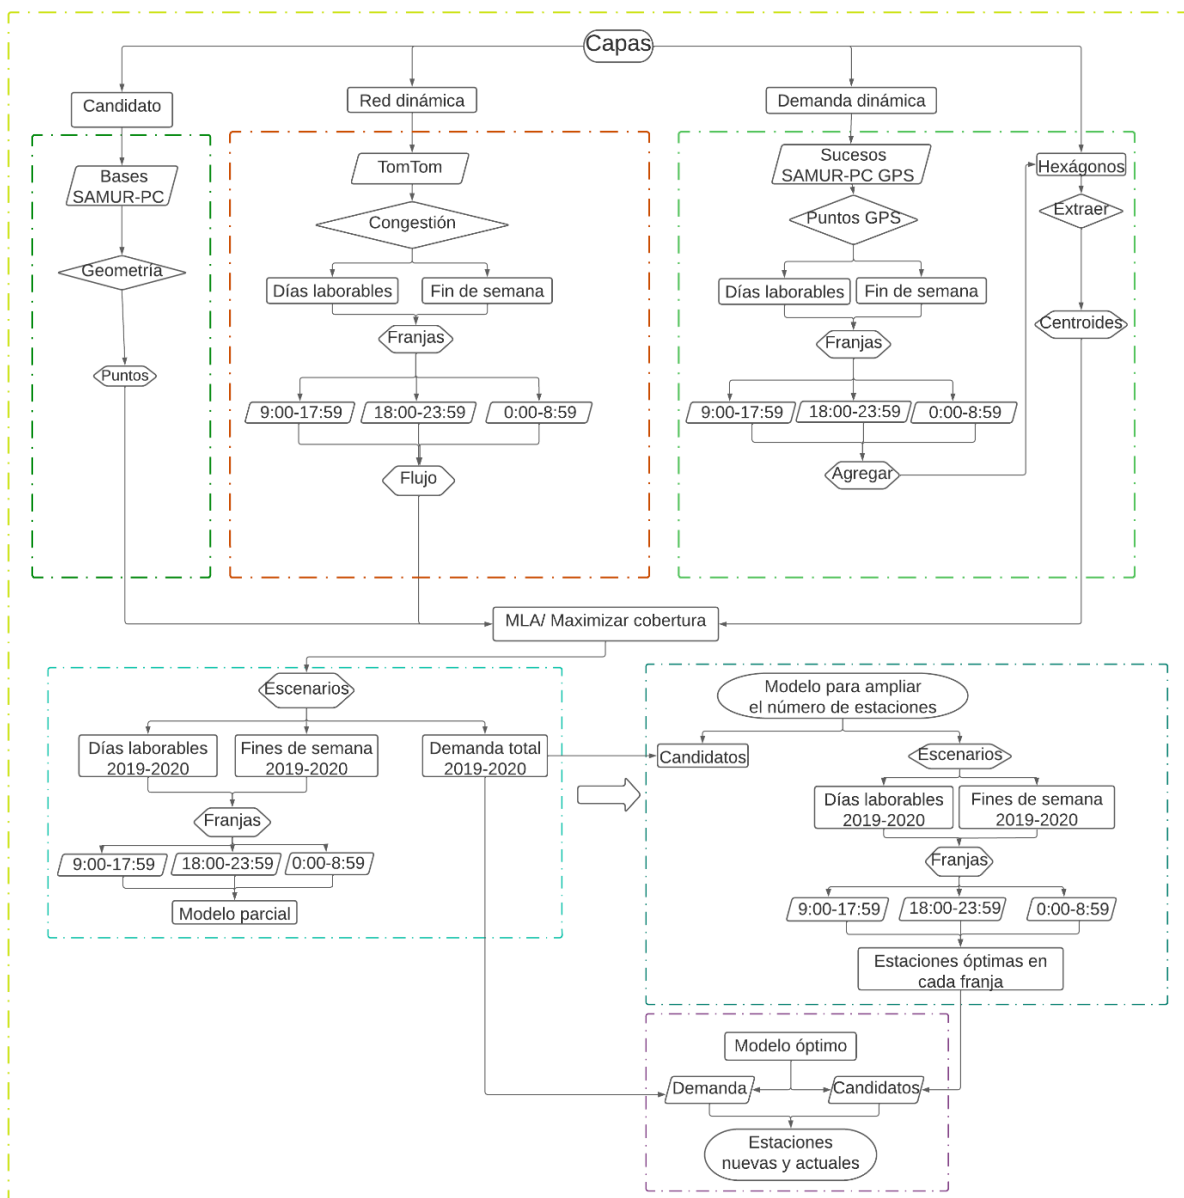
#### 4.3.2 Metodología para la ubicación de las estaciones SAMUR-PC

El estudio del rendimiento del SME de Madrid se ha desarrollado en las siguientes fases: en primer lugar, se realiza un análisis descriptivo de los datos. Luego, se evalúa el nivel de rendimiento del servicio mediante el conteo de sucesos que pueden ser atendidos, en un tiempo determinado, para 2019 y 2020. Por último, y con el fin de mejorar el sistema, se proponen diferentes escenarios en los que se evalúa el efecto de localizar nuevas bases en localizaciones óptimas para ser añadidas a las existentes, y el efecto de cambiar los tiempos permitidos para atender los sucesos desde las bases actuales (Figura 75).

#### 4.3.2.1 Análisis descriptivo de la distribución espacio-temporal de los sucesos

En esta etapa se presenta un análisis espacio-temporal de los sucesos atendidos por el SAMUR-PC durante el año 2019 y 2020. La Figura 76 muestra la distribución geográfica de los eventos ocurridos. Además, la base de datos de 2019 y de 2020 la dividimos en las siguientes franjas temporales: 00 a 08:59, de 9 a 17:59, y de 18 a 23:59 h, para días laborables y fines de semana. Se eligen estas franjas con el objetivo de conocer la distribución de los sucesos durante las horas aproximadas del horario residencial, laboral y de ocio.

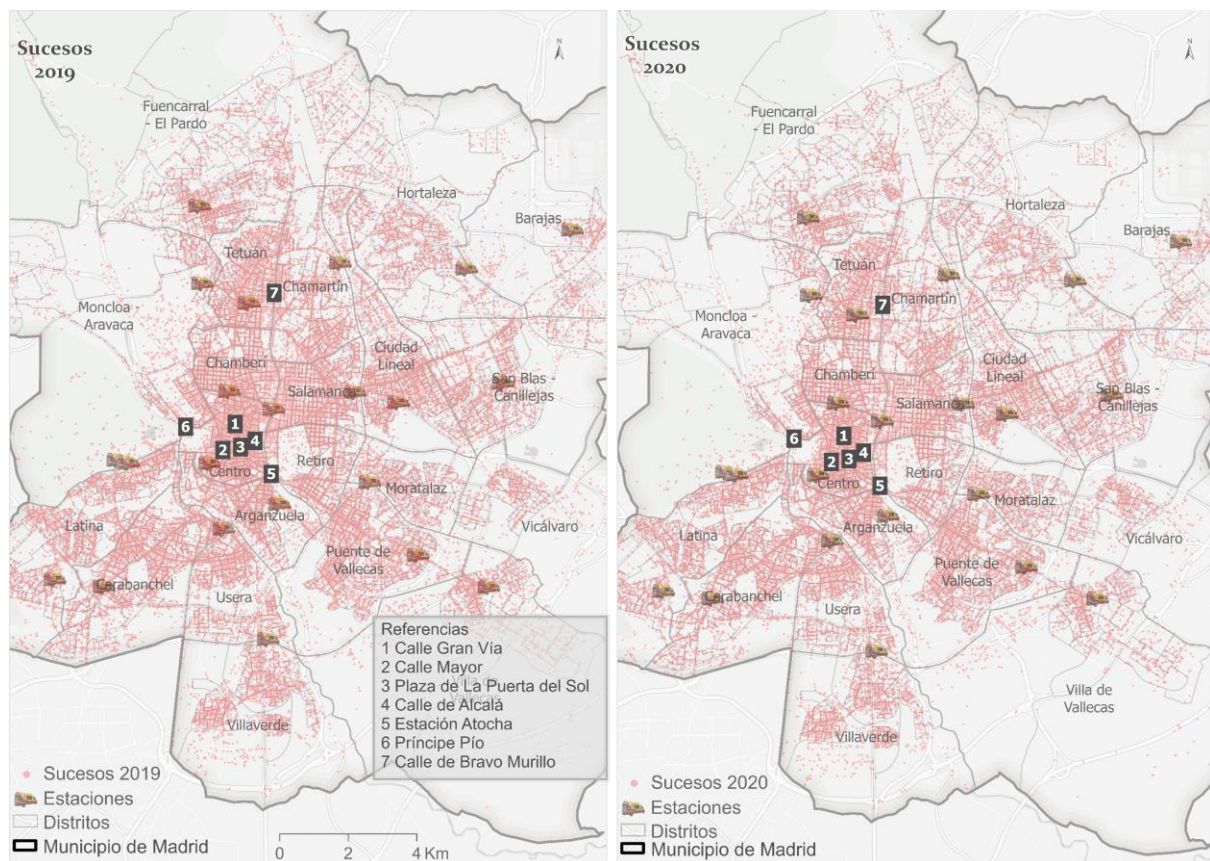
Figura 75. Metodología para el modelo de localización



Fuente: Elaboración propia.

Los datos fueron agregados en hexágonos de 200 metros de lado. Se ha elegido hexágonos frente a otras figuras geométricas porque ofrecen las siguientes ventajas: la distancia entre el centroide de un hexágono y los centroides vecinos es la misma en todas las direcciones, todos los hexágonos vecinos tienen la misma relación espacial con el hexágono central, su forma más suavizada ayuda a visualizar mejor los cambios espaciales graduales, (H. McKenzie, 2022). Además, diversos autores han utilizado los hexágonos para la agregación de datos puntuales y su análisis espacio temporal. (Arias-Molinares et al., 2021; Condeço-Melhorado et al., 2020; García-Palomares et al., 2015). Por otro lado, para la elección de la dimensión de los lados de los hexágonos, se ha elegido 200 metros, siguiendo la metodología empleada por Barros et al., (2019). De esta manera se probó los hexágonos con dimensiones de 100, 200, 300 y 400 metros de lado, arrojando el índice de Moran más alto los 200 metros. Una vez los datos se agregaron en hexágonos procedimos a realizar el análisis espacial empleando herramientas de autocorrelación espacial para identificar la localización de los puntos de concentración de sucesos. En particular, se ocupa el análisis de Anselin Local Moran (LISA) para detectar los patrones de agrupamiento de los datos en el año 2019-2020, y en las diferentes franjas temporales de los días entre semana y fines de semana. Además, se confeccionan mapas coropléticos para describir la distribución de la cantidad de sucesos por año. Los datos recabados contienen información completa de los dos años, lo que permite comparar la situación pre y post-COVID. También, a partir de la información sobre los tipos de sucesos, se analiza el comportamiento temporal de los datos en ambos años.

Figura 76. Sucesos atendidos por el SAMUR-PC en 2019 y 2020



Fuente: Elaboración propia.

#### 4.3.2.2 Estudio del rendimiento del servicio real y en escenarios alternativos

Con el fin de evaluar el rendimiento del servicio SAMUR-PC en los años de estudio y analizar los efectos de posibles cambios, se procede a usar un MLA de maximización de la cobertura del servicio. Se ha elegido la solución maximizar cobertura ya que es una de las más empleadas para formular problemas de localización de ambulancias (Dibene et al., 2017; Eaton et al., 1985; Jia et al., 2007). Con el fin de evaluar la situación anterior y posterior al COVID-19 se realizaron modelos para 2019 y 2020. Se parte de un MLA en el que se utiliza los sucesos segmentados en tres franjas horarias (de 00 a 08:59, de 9 a 17:59, y de 18 a 23:59) y se evalúa la cantidad de sucesos cubiertos en cada estación durante el día. Como candidatos requeridos, se eligen las 22 estaciones actuales del servicio SAMUR-PC. El modelo se ejecutó, aplicando umbrales de respuesta de 5, 8 y 10 minutos, considerando que el tiempo medio de respuesta según el SAMUR-PC es de 8 minutos. Además, justificamos la elección de este umbral con los estándares de la OMS que establecen que 8 minutos

es el tiempo ideal para que los servicios de emergencias lleguen a dar atención (Nogueira et al., 2016; OMS, 2008). Trabajamos también con 5 minutos debido a que los pacientes de paro cardiaco tienen mayor probabilidad de vida cuando la reanimación cardiopulmonar se aplica antes de que transcurra ese tiempo (EMSWorld, 2004; Pons & Markovchick, 2002; Shahparvari et al., 2020; Sladjana et al., 2011). Mientras que utilizamos 10 minutos como tiempo máximo, porque ronda el promedio del tiempo máximo de los servicios de emergencia en las principales ciudades europeas (Cabral et al., 2018).

También se ha tomado en cuenta las condiciones de tráfico en la red para días de semana y los fines de semana y las mismas franjas horarias en que están segmentados los datos de los sucesos. Finalmente, se ejecuta otro modelo con la demanda diaria total sin segmentar en franjas horarias (sucesos 2019 - 2020) para analizar el grado de cobertura general de las estaciones. En este caso, los parámetros utilizados toman en cuenta 8 minutos de reacción y las condiciones de la red los días laborables y fines de semana.

#### *4.3.2.3 Modelo incrementando la cantidad de estaciones*

Con este modelo de localización-asignación testeamos el efecto de aumentar el número de estaciones de las 22 actuales a 25 (se añadieron tres nuevas), es decir, un aumento del 15 %. Para ello, se ensayó aumentando, progresivamente, el número de bases (testeamos con una, dos y tres bases), hasta obtener la cantidad mínima para alcanzar un porcentaje de cobertura por encima de 95% en la mayoría de las franjas horarias. El modelo se ejecutó utilizando las ubicaciones de las 22 estaciones existentes como instalaciones requeridas. Mientras que los sitios candidatos se obtienen a partir de los centroides de los hexágonos donde ocurrieron sucesos en el año 2019 y 2020. La demanda se tomó de los centroides de cada franja temporal en que se dividen los datos. Al plantear este modelo se estableció un umbral de respuesta de 8 minutos. Además, se considera las condiciones del tráfico durante las franjas temporales estudiadas.

#### **4.3.3 Resultados**


Esta sección presenta los resultados obtenidos para este caso de estudio. Primero se muestra el análisis temporal, las estadísticas descriptivas y el comportamiento

espacial de los sucesos atendidos por el SAMUR-PC. Por último, los resultados obtenidos de los modelos de localización donde se probaron diferentes tiempos de reacción y aquellos que proponen aumentar el número de estaciones. Todos estos resultados se presentan de forma comparativa para el año 2019 y 2020.

#### 4.3.3.1 Análisis temporal de los sucesos.

La Figura 77 presenta la evolución de los sucesos ocurridos durante 2019 y 2020. En 2019, el mes de mayo registró más de 2000 sucesos. De igual manera, se presenta otro pico en diciembre, donde se registraron también más de 2000 sucesos. Este repunte guarda relación con el alto volumen de peatones y vehículos que circulan por las principales arterias comerciales de la ciudad debido a las vacaciones de fin de año (Ayuntamiento de Madrid, 2020a; Revistainforetail, 2020). Se muestran dos descensos de sucesos (abril y agosto), coincidiendo con los periodos vacacionales (semana santa y verano) cuando la población sale de la ciudad para desplazarse a otras zonas del país (Instituto Nacional de Estadística de España, 2020). Para el año 2020 se observó una fuerte caída en el número de sucesos a partir de los meses en los que se decretó el confinamiento en España (marzo y abril). Se recupera de nuevo a partir de junio, cuando finalizó el confinamiento domiciliario generalizado, volviendo a caer en otoño como consecuencia de la segunda ola y la vuelta de las restricciones.

Figura 77. Evolución de los sucesos ocurridos en 2019 y 2020




Fuente: Elaboración propia.

La evolución de los tipos de sucesos en 2019 y 2020 mostró, también, un cambio drástico (Figura 78). En ambos años, el mayor número de registros se produjo en enfermedades y accidentes no de tráfico. Durante el año 2019, hay dos momentos de caída en enfermedades, accidentes no de tráfico y accidentes de tráfico, registrados en el mes de abril y agosto. Mientras que los picos de atención de estos sucesos se

dieron en enero y junio (enfermedad), junio (accidente no de tráfico), junio y noviembre (accidentes de tráfico). Por último, cabe destacar que, en los meses del confinamiento, entre abril y mayo de 2020, los sucesos catalogados como “misceláneos” fueron la segunda causa más común de los servicios SAMUR-PC.


Figura 78. Evolución de los tipos de sucesos 2019-2020



Fuente: Elaboración propia.

El número de sucesos atendidos en 2019-2020 por hora y día de la semana se muestra en la Figura 79. Para 2019, los sábados y domingos registraron los máximos de sucesos. Mientras que, en 2020, la situación cambia y fueron los jueves y viernes los que presentaron los valores más altos. En cuanto a las horas, en ambos años, la mayor ocurrencia de sucesos se registró en las horas de la mañana (de 11 a 13 h) y de la tarde (18 a 20 h). Este comportamiento puede obedecer al considerable número de accidentes de tráfico que se producen en esas horas (Ayuntamiento de Madrid, 2020b). Mientras que las horas con menor cantidad de sucesos se presentan en las franjas de 00 a 6 h y de 7 a 10 h. Sin embargo, durante el año 2020 el peso de los sucesos de tarde se redujo significativamente. Tal como lo demuestra la intensidad de los colores.

Figura 79. Sucesos por hora y día 2019-2020




Fuente: Elaboración propia.

La Figura 80 representa la distribución del promedio de los tipos de sucesos ocurridos durante los años 2019 y 2020 por horas y días de la semana. De forma general, se observa que durante el año 2020 los diferentes tipos de sucesos disminuyeron en todas las horas del día. Como consecuencia de las medidas de restricción a la movilidad impuesta por el Gobierno español para hacer frente a la ola de contagios de COVID-19.

En el caso de los accidentes de tráfico registrados en 2019, la mayor incidencia se presenta en las horas 8, 9, 14, 15, y en la franja de 18 a 20 h de todos los días, mostrando los valores más altos los viernes y sábados. Una explicación tentativa a lo anterior puede relacionarse con que son las horas de mayor volumen de tráfico de la mañana y la tarde (TomTom, 2020) donde por lo general se registran muchos accidentes de tráfico (Dirección General de tráfico, 2020). Al comparar con 2020, como es lógico por la situación de la pandemia y el confinamiento, se nota una drástica disminución de los sucesos de accidentes atendidos por el SAMUR-PC.

Por otro lado, los sucesos relacionados con accidentes no de tráfico, en 2019, son comunes en las franjas horarias de 11 a 14 y de las 18 a las 20 en todos los días. Mientras que en 2020 se mantienen las mismas horas, pero con una cantidad promedio de sucesos mucho menor.

Figura 80. Tipos de sucesos por hora y día año 2019 - 2020



Fuente: Elaboración propia.

#### 4.3.3.2 Análisis espacial de los sucesos (agregación malla de hexágonos)

La Tabla 37 resume las estadísticas descriptivas de los sucesos a los que SAMUR-PC ofreció sus servicios según la agregación espacial por hexágonos. En 2019 se asistió a un total de 124.619 sucesos, lo que supone una media de algo más de 20

sucesos por hexágono. Para analizar el nivel de dispersión espacial de los datos, se utiliza el coeficiente de variación. Según éste, el horario laboral (9 a 18 h) presenta una mayor concentración espacial de los eventos. Mientras que los incidentes producidos en horario nocturno 00 a 9 h están más dispersos en la ciudad.

Tabla 37. Estadísticas de la distribución de los sucesos según hexágonos durante 2019

Franja temporal		Media	Desviación estándar	Coeficiente de variación	Mínimo	Máximo	Suma
Sucesos totales		21,4	67,1	313,6	0	2.124	124.619
Semana	09:00-17:59	10,8	31,3	289,8	0	926	62.974
	18:00-00:00	6,3	20,7	327,0	0	718	36.825
	00:00-08:59	4,3	17,4	408,5	0	480	24.820
Día laboral	09:00-17:59	7,9	22,5	284,8	0	625	45.997
	18:00-00:00	4,5	14,3	320,6	0	474	25.976
	00:00-08:59	2,7	10,7	397,8	0	293	15.673
Fin de semana	09:00-17:59	2,9	9,1	310,6	0	301	16.977
	18:00-00:00	1,9	6,6	353,2	0	244	10.849
	00:00-08:59	1,6	7,0	447,8	0	187	9.147

Fuente: Elaboración propia.

A lo largo de 2020, el SAMUR-PC atendió casi 90.000 incidentes, con una media de 15 sucesos por hexágono (Tabla 38). Desde el punto de vista de franja horaria, el periodo 09:00-17:59, registró el mayor número de casos atendidos (45.522 ó 50%). Según el coeficiente de variación, los sucesos ocurridos en el periodo de 09:00-17:59 están más concentrados (289,0).

Tabla 38. Estadísticas de la distribución de los sucesos según hexágonos durante 2020

Franja temporal		Media	Desviación estándar	Coeficiente de variación	Mínimo	Máximo	Suma
Sucesos totales		15,4	46,8	303,9	0	1.192	89.870
Semana	09:00-17:59	7,8	22,6	289,0	0	499	45.522
	18:00-00:00	4,9	15,1	306,9	0	377	28.620
	00:00-08:59	2,7	10,5	388,9	0	348	15.728
Día laboral	09:00-17:59	5,8	16,6	284,2	0	342	34.005
	18:00-00:00	3,5	10,7	308,4	0	273	20.222
	00:00-08:59	1,69	6,71	219,0	0	219	9.859
Fin de semana	09:00-17:59	2,0	6,3	318,2	0	157	11.517
	18:00-00:00	1,4	4,7	325,7	0	128	8.398
	00:00-08:59	1,0	4,1	405,0	0	129	5.869

Fuente: Elaboración propia.

En el caso de los tipos de sucesos atendidos por el SAMUR-PC, las cifras mostradas en la Tabla 39 revelan que las enfermedades fueron los casos que predominaron en 2019, lo que representó cerca del 50% de los sucesos (57.587) con una media de 10 incidentes por hexágono, seguido de los accidentes no de tráfico que registraron el 30% y con un promedio de 6,2 por hexágono. El coeficiente de variación muestra que los sucesos relacionados con accidentes de tráfico estuvieron más concentrados espacialmente.

Tabla 39. Estadísticas de la distribución por hexágonos por tipo de sucesos año 2019

Tipo	Media	Desviación estándar	Coeficiente de variación	Mínimo	Máximo	Suma
Accidente de tráfico	2,6	6,2	235,4	0	75	15.298
Accidente no de tráfico	6,2	21,3	346,3	0	742	35.793
Enfermedad	9,9	35,3	356,9	0	1129	57.587
Bomberos	0,8	3,4	417,2	0	206	4.746
Psicológicos	1,1	4,9	453,7	0	184	6.304
Misceláneos	0,8	6,5	772,9	0	167	4.897

Fuente: Elaboración propia.

Al considerar la estadística de los tipos de sucesos atendidos para el año 2020 se observa que los dos que vuelven a predominar son las enfermedades con un 41% de los casos (37.059), presentando una media superior a 6,0 por hexágono y los accidentes clasificados, en la categoría de no tráfico, con casi un 30% de los sucesos (25.923). Por otro lado, los accidentes de tráfico se concentraron más en el área de estudio, como lo revela el coeficiente de variación (Tabla 40).


Tabla 40. Estadísticas de la distribución por hexágonos por tipo de sucesos año 2020

Tipo	Media	Desviación estándar	Coeficiente de variación	Mínimo	Máximo	Suma
Accidente de tráfico	1,8	4,1	230,5	0	46	10.321
Accidente no de tráfico	4,5	14,9	334,8	0	425	25.923
Enfermedad	6,4	21,4	335,9	0	525	37.059
Bomberos	0,8	4,2	498,8	0	244	4.879
Psicológicos	1,0	4,8	487,7	0	166	5.671
Misceláneos	1,0	7,9	768,0	0	256	6.017

Fuente: Elaboración propia.

Si se observa el promedio de sucesos por hexágonos ocurridos durante 2020, en comparación con el año anterior, el número disminuyó en todas las franjas horarias, como se muestra en la Figura 81 y en la Tabla 41. Asimismo, se produjo un descenso en la cantidad total de sucesos (-28,0 %). Los datos indican que en el horario nocturno ocurrió la reducción más significativa de casos. La explicación al descenso de sucesos presentados en 2020 guarda relación con la disminución de la movilidad de la población hacia los sitios de ocio, supermercados, farmacias, estaciones de transporte público y de trabajo, como consecuencia del COVID-19 (Google COVID-19 Community Mobility Report, 2020).

Figura 81. Promedio de sucesos por hexágono según horario año 2019 vs 2020



Fuente: Elaboración propia.


Tabla 41. Promedio de sucesos por hexágono y porcentaje de cambio 2019-2020

Franja temporal	2019	2020	Cambio%	
Sucesos total	21,40	15,40	-28,0	
Semana	09:00-17:59	10,80	7,82	-27,6
	18:00-00:00	6,33	4,92	-22,3
	00:00-08:59	4,26	2,70	-36,6
Día laboral	09:00-17:59	7,90	5,84	-26,1
	18:00-00:00	4,46	3,47	-22,2
	00:00-08:59	2,69	1,69	-37,2
Fin de semana	09:00-17:59	2,92	1,98	-32,2
	18:00-00:00	1,86	1,44	-22,6
	00:00-08:59	1,57	1,01	-35,7

Fuente: Elaboración propia.

Salvo los sucesos relacionados con los bomberos y los clasificados como misceláneos, todos los demás tipos sufrieron descensos en el periodo 2019-2020. La Figura 82 y la Tabla 42 muestran que las enfermedades y los accidentes de tráfico presentaron la reducción más significativa.

Figura 82. Promedio por hexágono según tipo de suceso 2019-2020



Fuente: Elaboración propia.

Tabla 42. Promedio por hexágono según tipo de suceso y porcentaje de cambio 2019-2020

Tipo de sucesos	2019	2020	Cambio%
Accidente de tráfico	2,6	1,8	-32,7
Accidente no de tráfico	6,2	4,5	-27,6
Enfermedad	9,9	6,4	-35,6
Bomberos	0,8	0,8	2,8
Psicológicos	1,1	1,0	-9,8
Misceláneos	0,8	1,0	22,5

Fuente: Elaboración propia.

En cuanto a la distribución espacial, la Figura 83a refleja que el número de sucesos ocurridos durante el año 2019 fue mayor en comparación con el año 2020. Esto se debe a que tras el confinamiento aún la ciudad no recuperaba el ritmo de movilidad que mantenía en el año previo a la pandemia (Google COVID-19 Community Mobility Report, 2020; Talavera-García & Pérez-Campaña, 2021). Se observa una alta concentración de sucesos en el distrito Centro, sobre todo en las calles: Gran Vía, Alcalá, plaza de La Puerta del Sol y Atocha. Estas zonas se caracterizan por ser

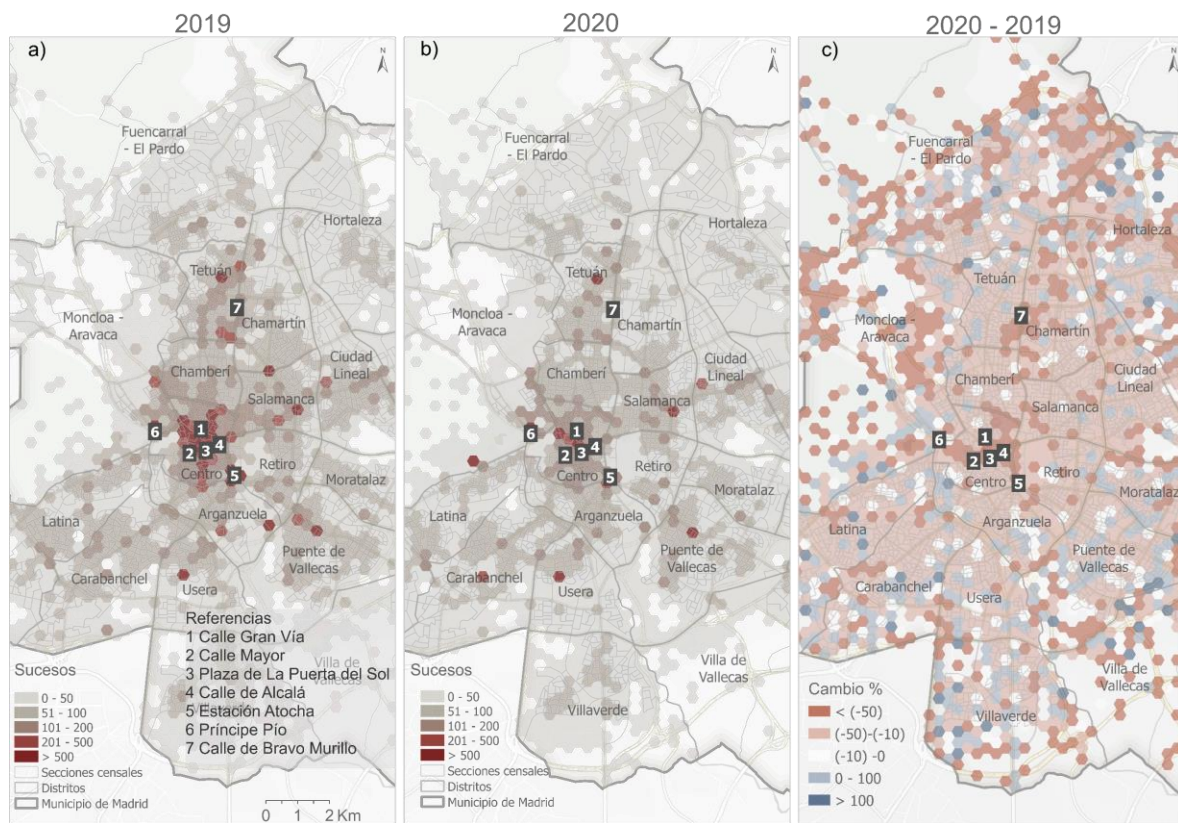
espacios muy transitados por los habitantes de la ciudad y los turistas (TC Group Solutions, 2021). Representan las principales arterias comerciales de Madrid, ya que cuentan con una variada oferta de locales. También, encontramos otros focos de concentración de sucesos en los barrios de Salamanca y Tetuán. En cambio, en la periferia la ocurrencia de sucesos es menor, por tratarse de zonas residenciales. En el caso del año 2020 (Figura 83b), la mayor concentración también se produjo en el centro. Concretamente, en las zonas próximas a la calle Gran Vía y la plaza de La Puerta del Sol.

La Figura 83c presenta la variación porcentual 2020-2019. Cabe destacar que gran parte del área de estudio presentó una disminución en el número de sucesos cubiertos por el SAMUR-PC (tonos rojos). Esta situación se debe a que los servicios ofrecidos por el SAMUR-PC atienden los sucesos que se producen en la calle. Sin embargo, debido al confinamiento en 2020, como consecuencia de la pandemia, el número de personas en la calle descendió (Talavera-García & Pérez-Campaña, 2021). Esto provocó una disminución en el número de sucesos atendidos especialmente, en aquellos espacios más céntricos.

Por otro lado, los barrios Tetuán, Latina, Puente de Vallecas, registraron un incremento porcentual positivo respecto a 2019. Ello puede estar relacionado con el temor de la población a contagiarse (Lasa N, Gomez J, Padilla J, Garcia J, Gorosiaga A, 2020) al frecuentar sitios de gran aglomeración como es el centro de Madrid, y en consecuencia, las personas preferían movilizarse en los alrededores de sus barrios y realizar actividades al aire libre en ellos (Mayo Clinic, 2022).

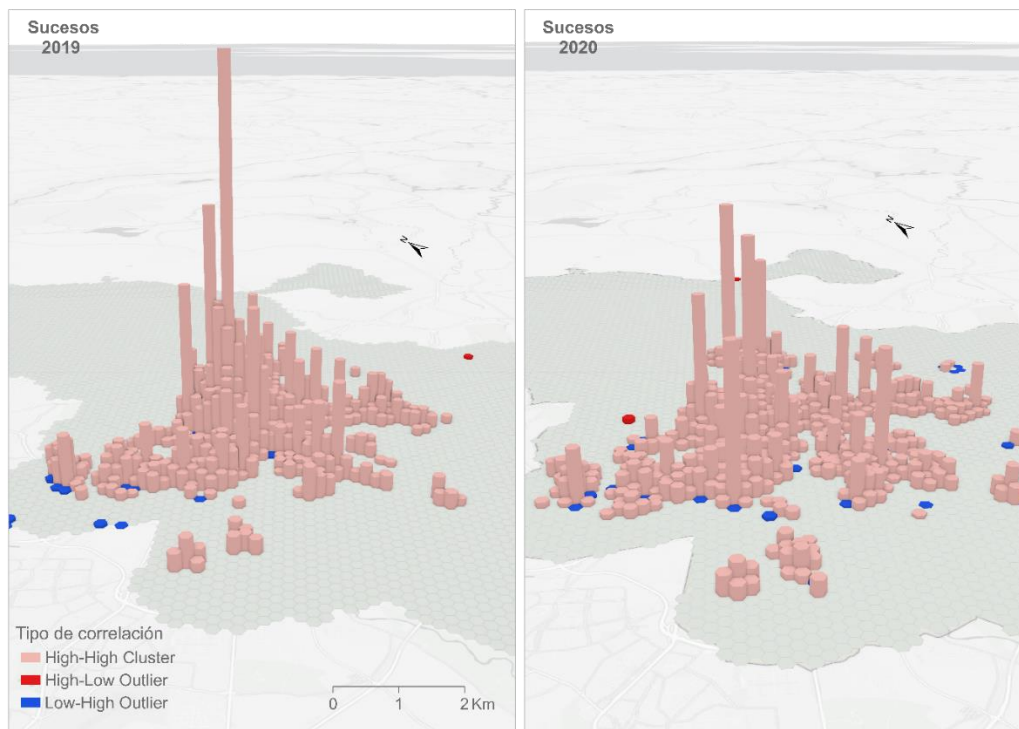
La Figura 84 ilustra los resultados del análisis de Moran local (LISA). Se refleja una alta concentración de sucesos en el centro (clúster alto-alto, H-H). La altura de los hexágonos indica que se registraron más eventos en 2019, en comparación con 2020, lo que muestra el efecto del confinamiento realizado durante la pandemia (año 2020). Las pautas son parecidas, aunque la situación de 2020 muestra una mayor expansión de los sucesos a zonas más periféricas y residenciales.

Figura 83. Sucesos atendidos en 2019-2020 y porcentaje de cambio



Fuente: Elaboración propia.

Figura 84. Análisis de Moran 1 año 2019-2020



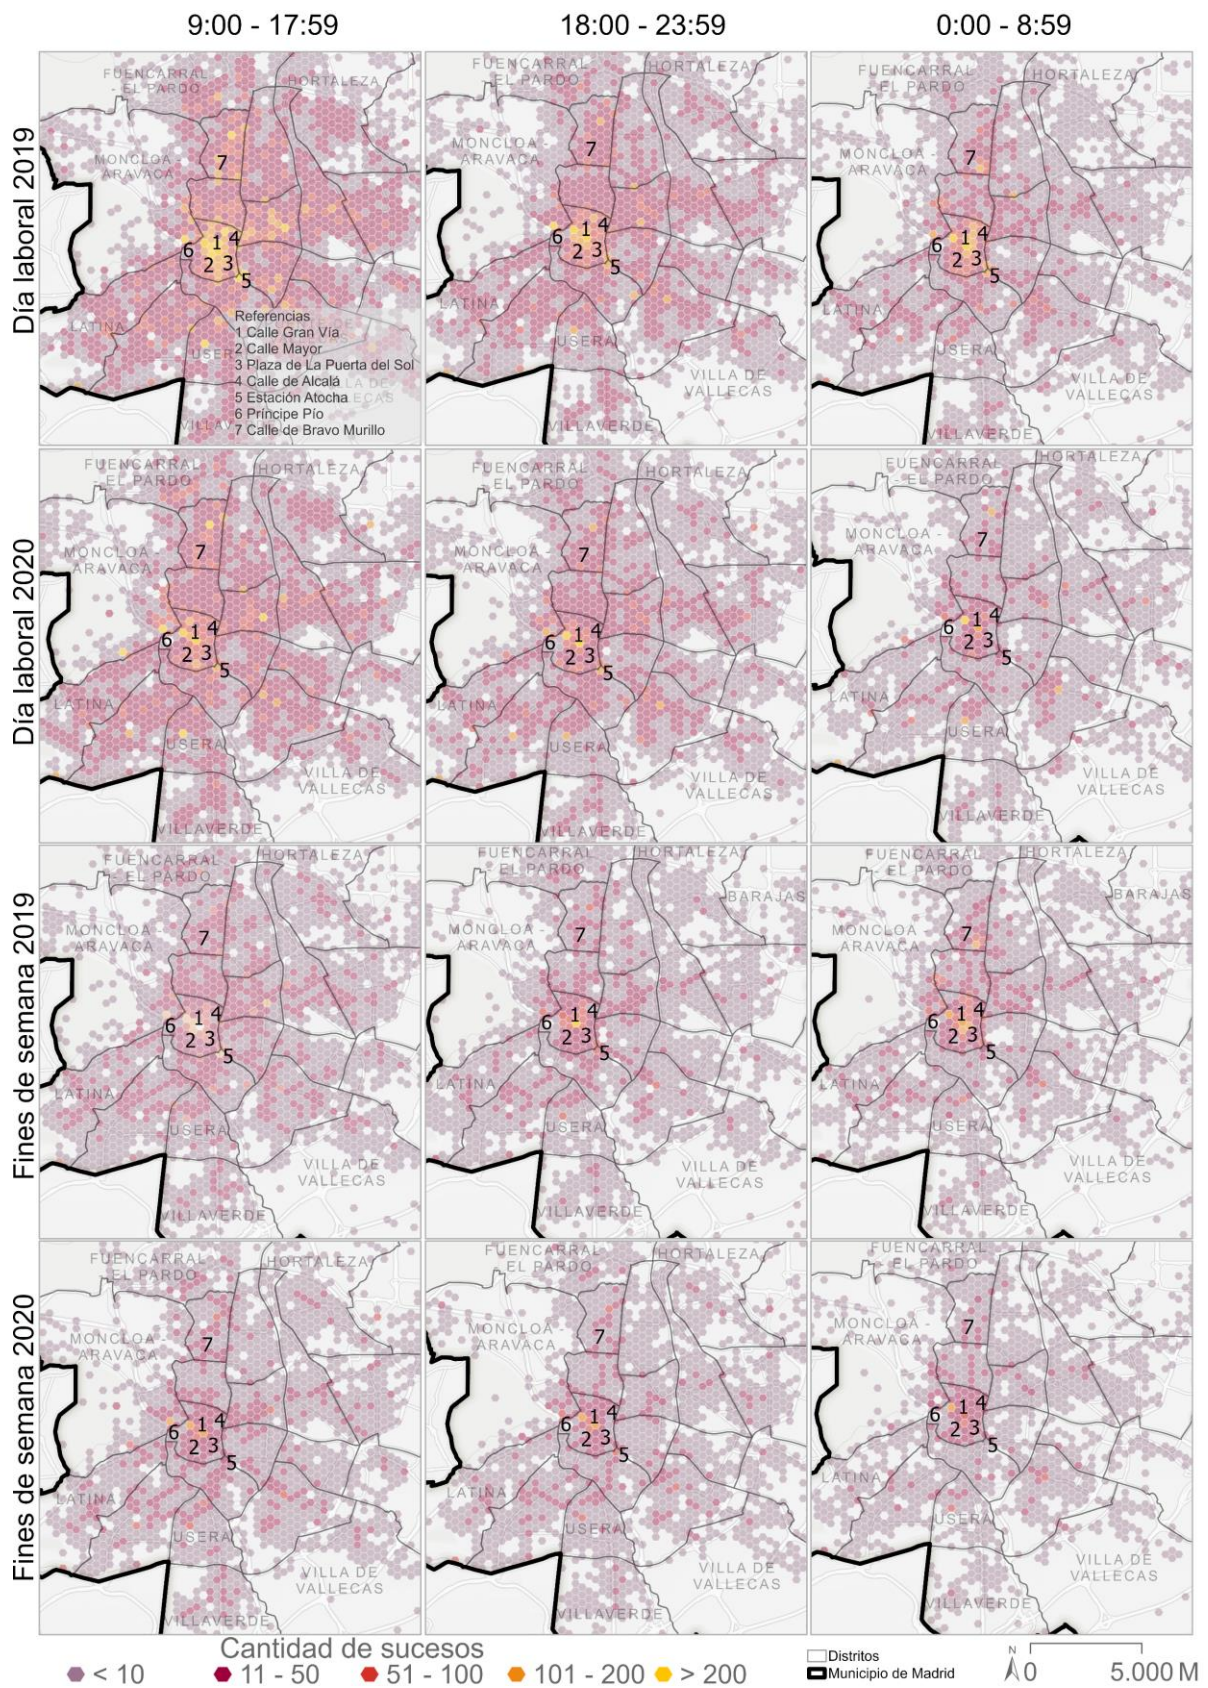
Fuente: Elaboración propia.

Los distritos que muestran la mayor concentración de sucesos en todas las franjas son el distrito Centro, Salamanca, Retiro, Puente de Vallecas y otros. Algunos de ellos están caracterizados por un alto volumen de actividades comerciales y de ocio. (Ayuntamiento de Madrid, 2020c). En general, toda la zona conocida como la Almendra Central presenta una gran cantidad de sucesos tanto en los días laborables de 2019 como en 2020. Destacan las calles Gran Vía, Mayor, Plaza de la Puerta del Sol, entre otras. Estas calles y plazas son íconos turísticos de la ciudad, en consecuencia, atraen un gran volumen de visitantes nacionales y extranjeros durante la mayor parte del año (Figura 85).

En los fines de semana de 2020, respecto a 2019, el número de sucesos a los que asistió el SAMUR-PC descendió. En las distintas franjas horarias del 2019, los sucesos se concentraron en la zona central del área de estudio, en las proximidades de importantes calles donde circula una gran cantidad de peatones y vehículos (calle Gran Vía, Mayor, Plaza de La Puerta del sol, estación de Atocha, entre otras). Mientras en 2020, la distribución de los sucesos muestra las mismas zonas que en 2019, pero con una cantidad mucho menor de sucesos atendidos, reflejándose nuevamente, el impacto de las medidas de confinamiento que restringieron la movilidad de los ciudadanos de Madrid.

Por otra parte, se observa que los fines de semana de 2020, los sucesos presentan una distribución más dispersa sobre el área de estudio. Este patrón espacial puede explicarse en parte porque la población todavía se sentía insegura y con temor a ser objeto de contagio (Lasa N, Gomez J, Padilla J, Garcia J, Gorosiaga A, 2020), por ello evitaban aquellos sitios de gran presencia de población circulante como suele ser la zona centro de la ciudad.

Figura 85. Cantidad de sucesos según días y franjas horarias



Fuente: Elaboración propia.

La Figura 86 muestra un análisis de autocorrelación espacial Local de Moran (LISA) agrupando los sucesos en tres franjas horarias para días laborables y los fines de semana. Se observa la formación del clúster HH (autocorrelación positiva de valores altos) en la parte central del municipio de Madrid en todas las franjas horarias, presentando una distribución similar. En este clúster destacan los siguientes distritos: Retiro, Centro, Puente de Vallecas, Chamberí, Salamanca, Tetuán, Arganzuela, entre otros. Lo que debería relacionarse, por un lado, con el alto número de accidentes de tráfico que ocurren en estos distritos (Ayuntamiento de Madrid, 2022) y por el otro, porque cuentan con una densidad de población y de comercios, considerablemente, alta.

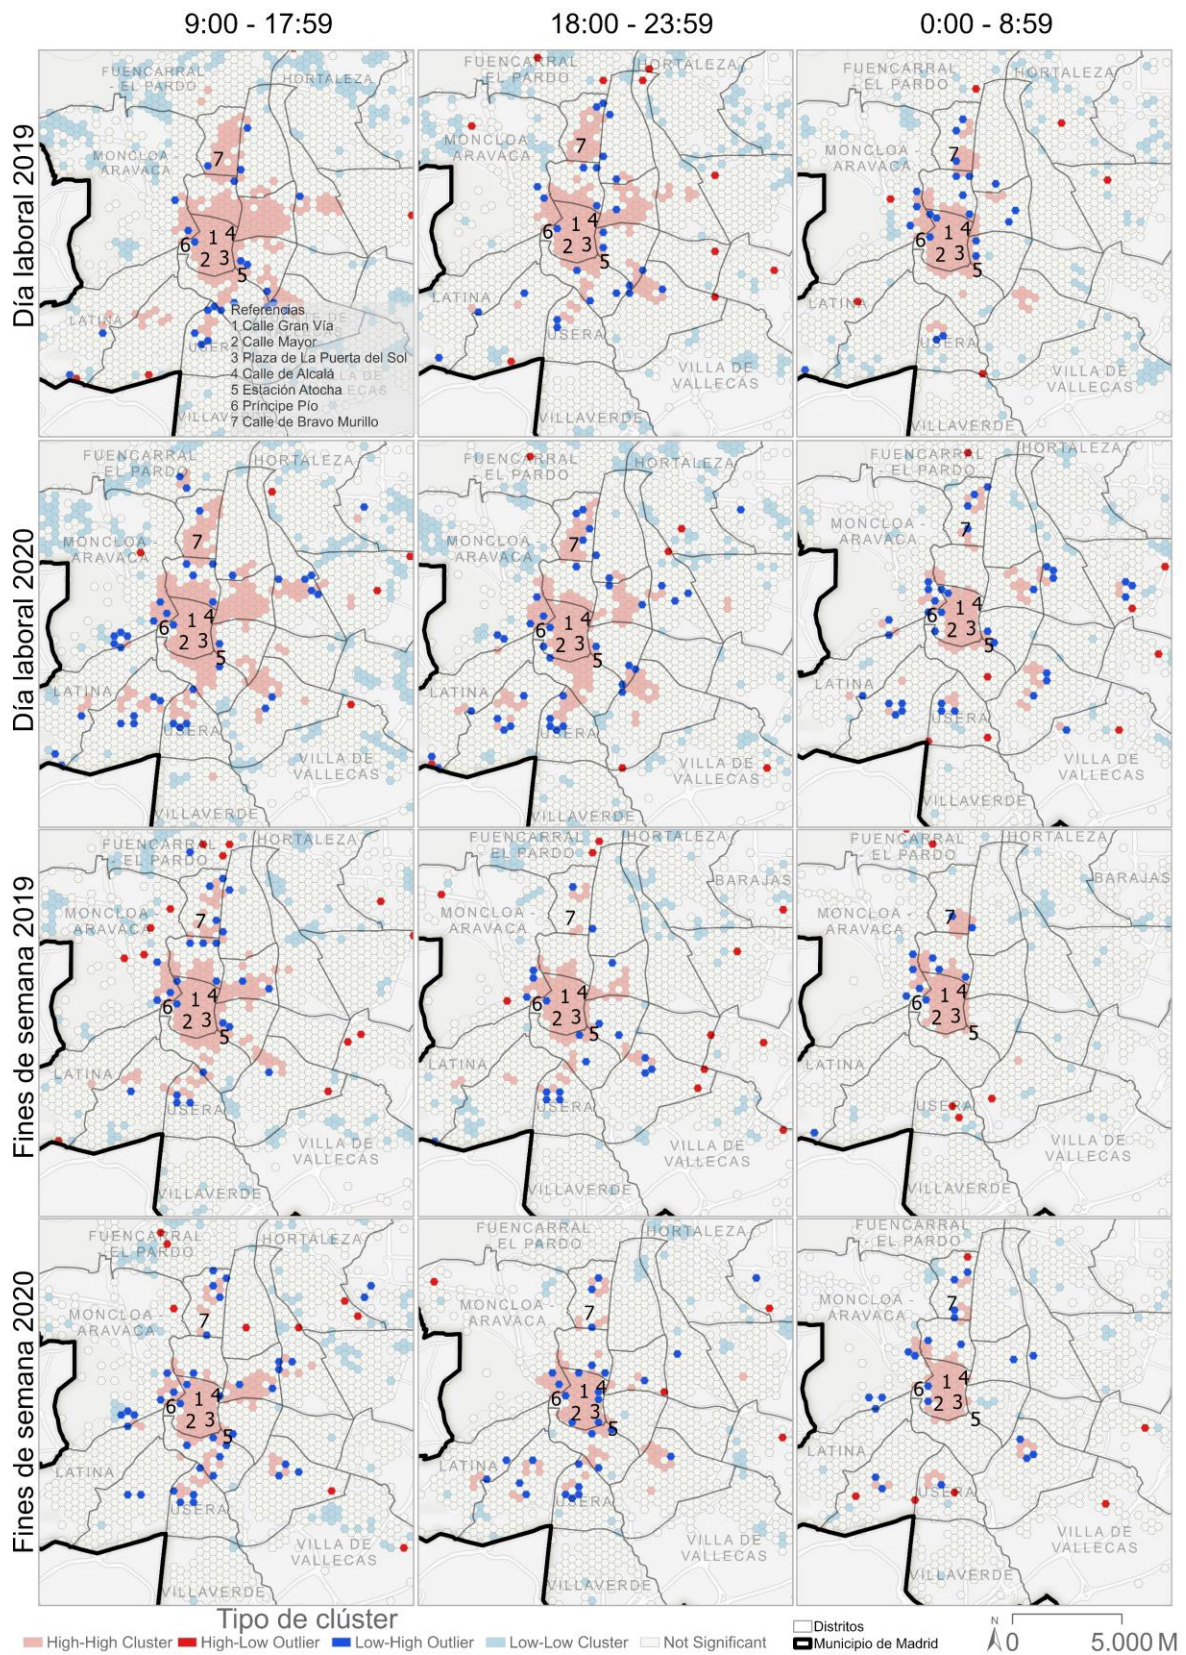
En ambos años existe una mayor concentración en la franja horaria de 9 a 18 h en comparación con el resto de las franjas analizadas. Este comportamiento puede explicarse por el hecho de que la jornada laboral se desarrolla en esta franja horaria. En consecuencia, la presencia de personas en la calle es mayor, sobre todo, al entrar o salir de los centros de trabajo y pueden sufrir algún tipo de percance durante su desplazamiento.

La franja 18 a 00 h, presenta también un clúster en las zonas de ocio. Además, muestra algunos valores atípicos en zonas de ocio concretas situadas en las afueras de la ciudad. Mientras que en la franja 00 a 9 h, la agrupación se reduce a las zonas de ocio nocturno del centro de la ciudad.

Comparando los clústeres en cada año, se observa que, durante el año 2020, el tamaño del clúster es menor, lo que indica que hubo una disminución en el número de sucesos a los que asistió el SAMUR. Estos patrones se repiten durante los días de la semana y los fines de semana.

En general, hemos identificado que, en todas las franjas, se forma un gran clúster en torno a las calles Gran Vía, Mayor, Alcalá, Bravo Murillo, plaza de La Puerta del Sol, Príncipe Pío y estación de Atocha. Estas calles y estaciones son zonas de alto movimiento de peatones y vehículos durante el día (TC Group Solutions, 2021).

Figura 86. Análisis LISA de la distribución de sucesos atendidos en 2019 y 2020 según franjas temporales



Fuente: Elaboración propia.

La Tabla 43 resume el número de hexágonos según tipos de clústeres en cada una de las franjas temporales estudiadas. El clúster LL es el predominante en las diferentes ventanas temporales, seguido del HH. La Figura 87 resume el clúster alto-alto en las distintas clases de eventos. Se observa que los accidentes de enfermedad, de tráfico y no de tráfico; forman un gran clúster en la parte central del área de estudio en ambos años. Mientras que los hexágonos de HH con accidentes de tráfico se localizan en la parte noreste, y los accidentes no de tráfico están dispersos en la zona sur y sureste.

Tabla 43. Número de hexágonos según clústeres por año y franja temporal

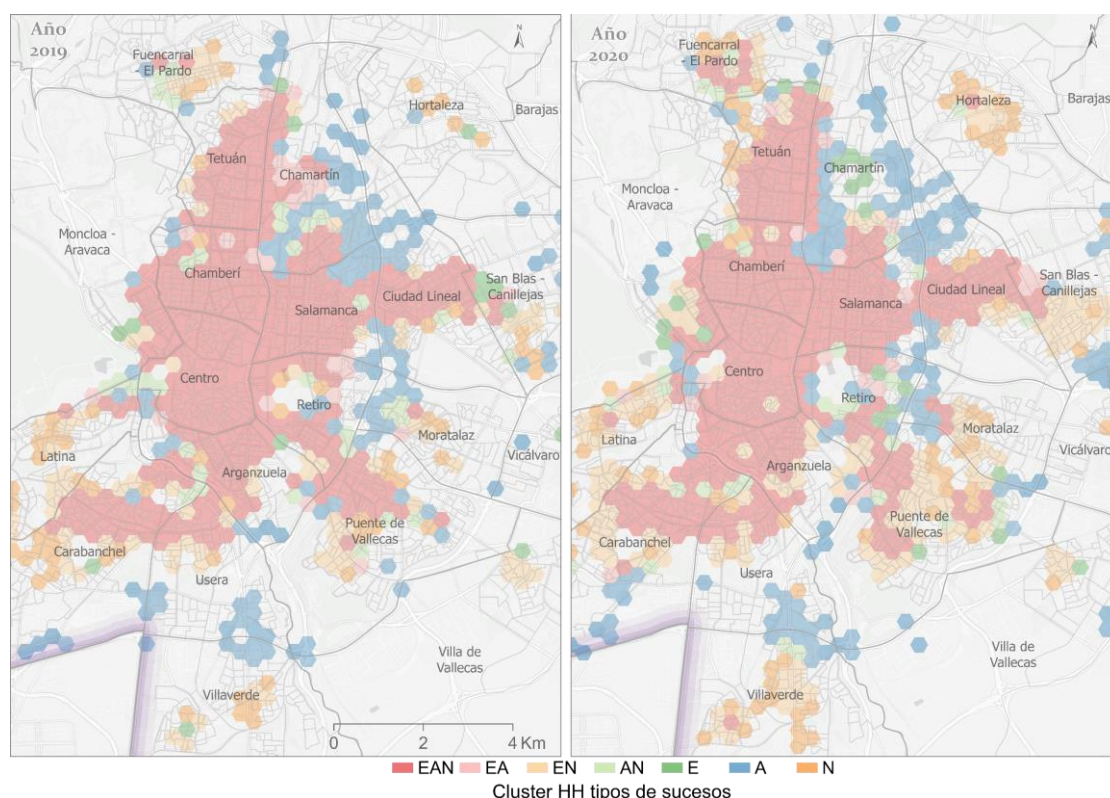
Tipo de correlación	Día laboral											
	2019						2020					
	Mañana		Tarde		Noche		Mañana		Tarde		Noche	
	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%
HH	218	3,75	166	2,85	103	1,77	229	3,93	170	2,92	94	1,61
LL	350	6,01	235	4,04	133	2,28	330	5,67	231	3,97	77	1,32
HL	6	0,10	10	0,17	6	0,10	7	0,12	6	0,10	9	0,15
LH	23	0,40	26	0,45	21	0,36	39	0,67	32	0,55	35	0,60

Tipo de correlación	Fin de semana											
	2019						2020					
	Mañana		Tarde		Noche		Mañana		Tarde		Noche	
	Total	%	Total	%	Total	%	Total	%	Total	%	Total	%
HH	153	2,63	106	1,82	72	1,24	111	1,91	99	1,70	68	1,17
LL	204	3,50	122	2,10	56	0,96	130	2,23	87	1,49	40	0,69
HL	17	0,29	13	0,22	6	0,10	11	0,19	6	0,10	7	0,12
LH	25	0,43	19	0,33	11	0,19	39	0,67	30	0,52	21	0,36

Fuente: Elaboración propia.

Figura 87. Combinación del clúster HH de los tipos de eventos



Nota: EAN: enfermedad, accidente de tráfico, accidente no de tráfico. EA: enfermedad, accidente de tráfico. AN: accidente no de tráfico. E: enfermedad. A: accidente de tráfico. N: Accidente no de tráfico.

Fuente: Elaboración propia.

#### 4.3.3.3 MLA con los sucesos totales y solución maximizar cobertura

En 2019, con un tiempo de 8 minutos, las estaciones alcanzaron una cobertura que oscilaba entre el 88% y el 96% de los sucesos totales ocurridos (124.619) presentando los valores más altos los fines de semana (Tabla 44). Este comportamiento se explica por los menores niveles de congestión en la red, en comparación con los días laborables. Mientras tanto, en 2020, con un menor número de sucesos, pero más dispersos, sólo se cubrieron entre el 86% y el 95% (total de sucesos ocurridos 89.870), registrándose los valores más altos en los fines de semana.

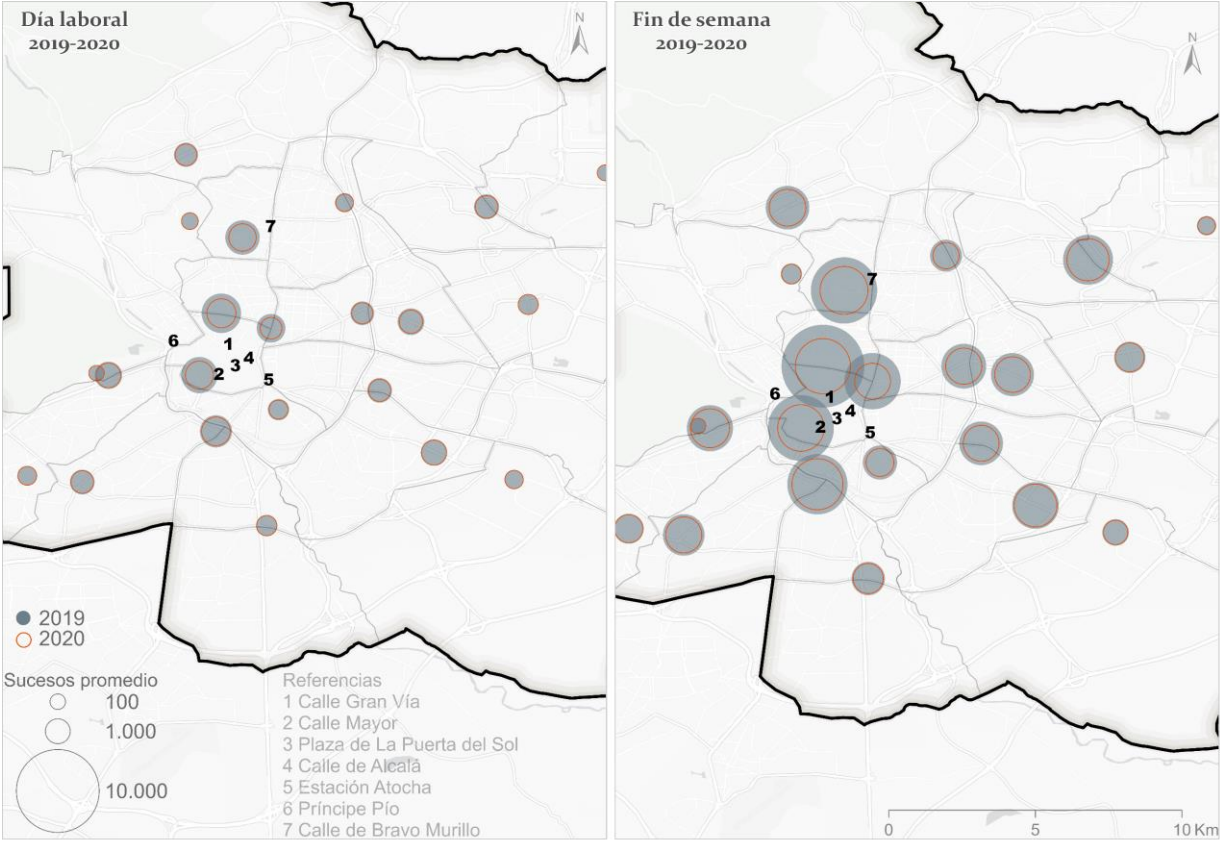
Tabla 44. Cobertura de la red de SAMUR: sucesos cubiertos con el modelo maximizar cobertura (tiempo de respuesta 8 minutos)

Escenario	2019		2020	
	Total	%	Total	%
Día laboral	109.314	88,16	77.739	86,50
Fin de semana	119.113	96,06	85.142	94,73

Fuente: Elaboración propia.

La Figura 88 muestra los sucesos cubiertos por los distintos centros de ambulancias los días laborables y los fines de semana, además, en los dos años estudiados. El color del círculo indica el año, mientras que el tamaño representa la cantidad de sucesos cubiertos en promedio. Se observa que, tanto los días laborables como los fines de semana, se cubren un número de sucesos mayor durante 2019. Además, se nota que los fines de semana las estaciones atienden, en promedio, un mayor número de sucesos. Existen cuatro estaciones localizadas en la parte central de la zona estudiada, que en ambos años y franjas tendrían asignadas el mayor número de sucesos. Las estaciones periféricas conservan un volumen de sucesos asignados similar en los dos años, y son las centrales en las que aparece la mayor caída en 2020, en especial los fines de semana.

Figura 88. Cobertura de sucesos por estaciones según día de la semana y año 2019-2020



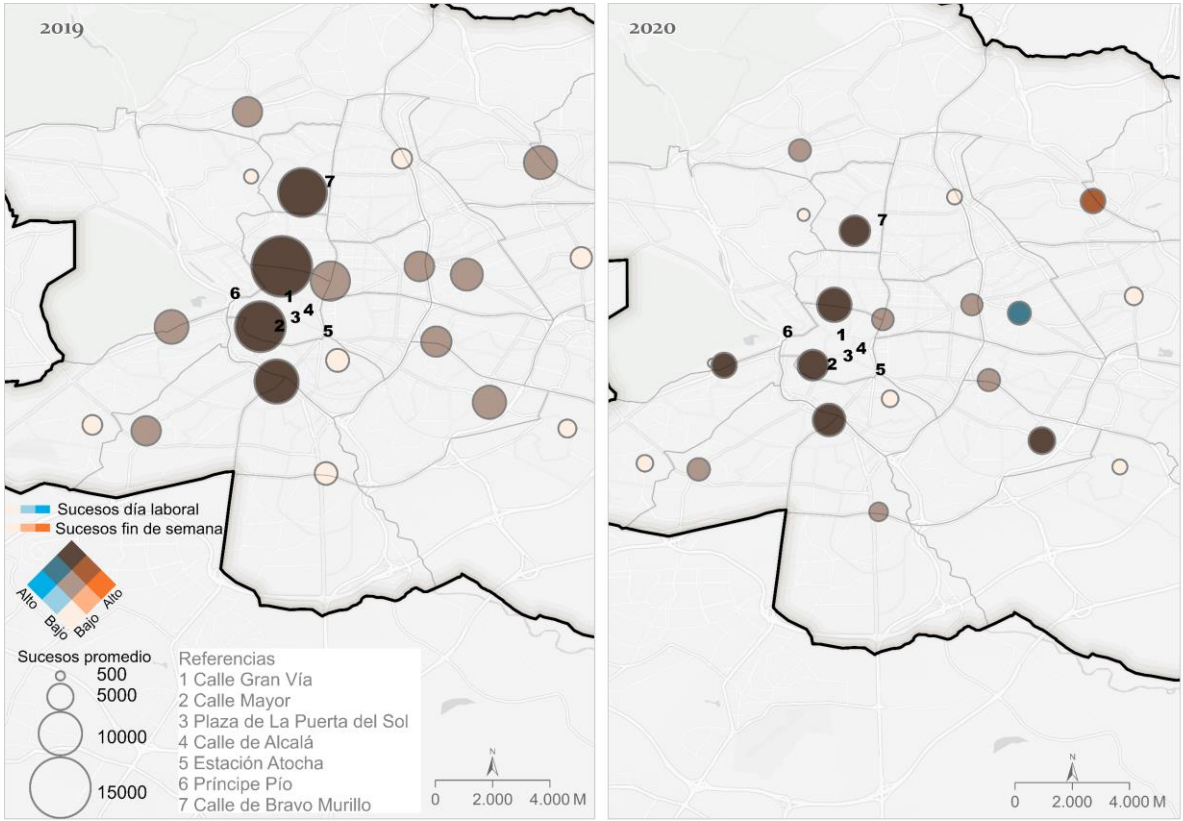
Fuente: Elaboración propia.

La Figura 89 compara la cantidad de sucesos cubiertos por año, ya sea en día laborable o fin de semana. Los colores indican para cada estación si el día en el que predominan los casos atendidos es laborable o fin de semana. Las estaciones en color

azulado atienden casos, fundamentalmente, durante la semana, mientras que las más anaranjadas muestran una mayor prevalencia de casos en fin de semana.

En el año 2019, se observa, normalmente, que las estaciones tienen una distribución homogénea entre los días laborables y el fin de semana, con estaciones del centro de la ciudad que tienen una demanda muy alta, tanto los días laborables como los fines de semana. En 2020 las estaciones tienen menos demanda que la cubierta en el año 2019 y se observa como algunas tienen demanda alta los días laborables y otras los fines de semana.

Figura 89. Sucesos cubiertos por estación en día laborable y fin de semana en los años 2019 y 2020.



Fuente: Elaboración propia.

La Figura 90 ilustra el promedio de sucesos cubiertos por las estaciones actuales. Comprende los casos cubiertos por el servicio de urgencias, según el tipo de sucesos atendidos en 2019 y 2020. En el caso de 2019, se observa que los fines de semana se cubre una mayor cantidad de incidentes. Un comportamiento similar se presentó en 2020. En ambos años, se nota un predominio de los casos vinculados con enfermedades, así como de los accidentes no relacionados con el tráfico.

Figura 90. Promedio del tipo de sucesos atendidos por las estaciones actuales



Fuente: Elaboración propia.

#### 4.3.3.4 Diferencias en la asignación a estaciones de SAMUR según franjas horarias

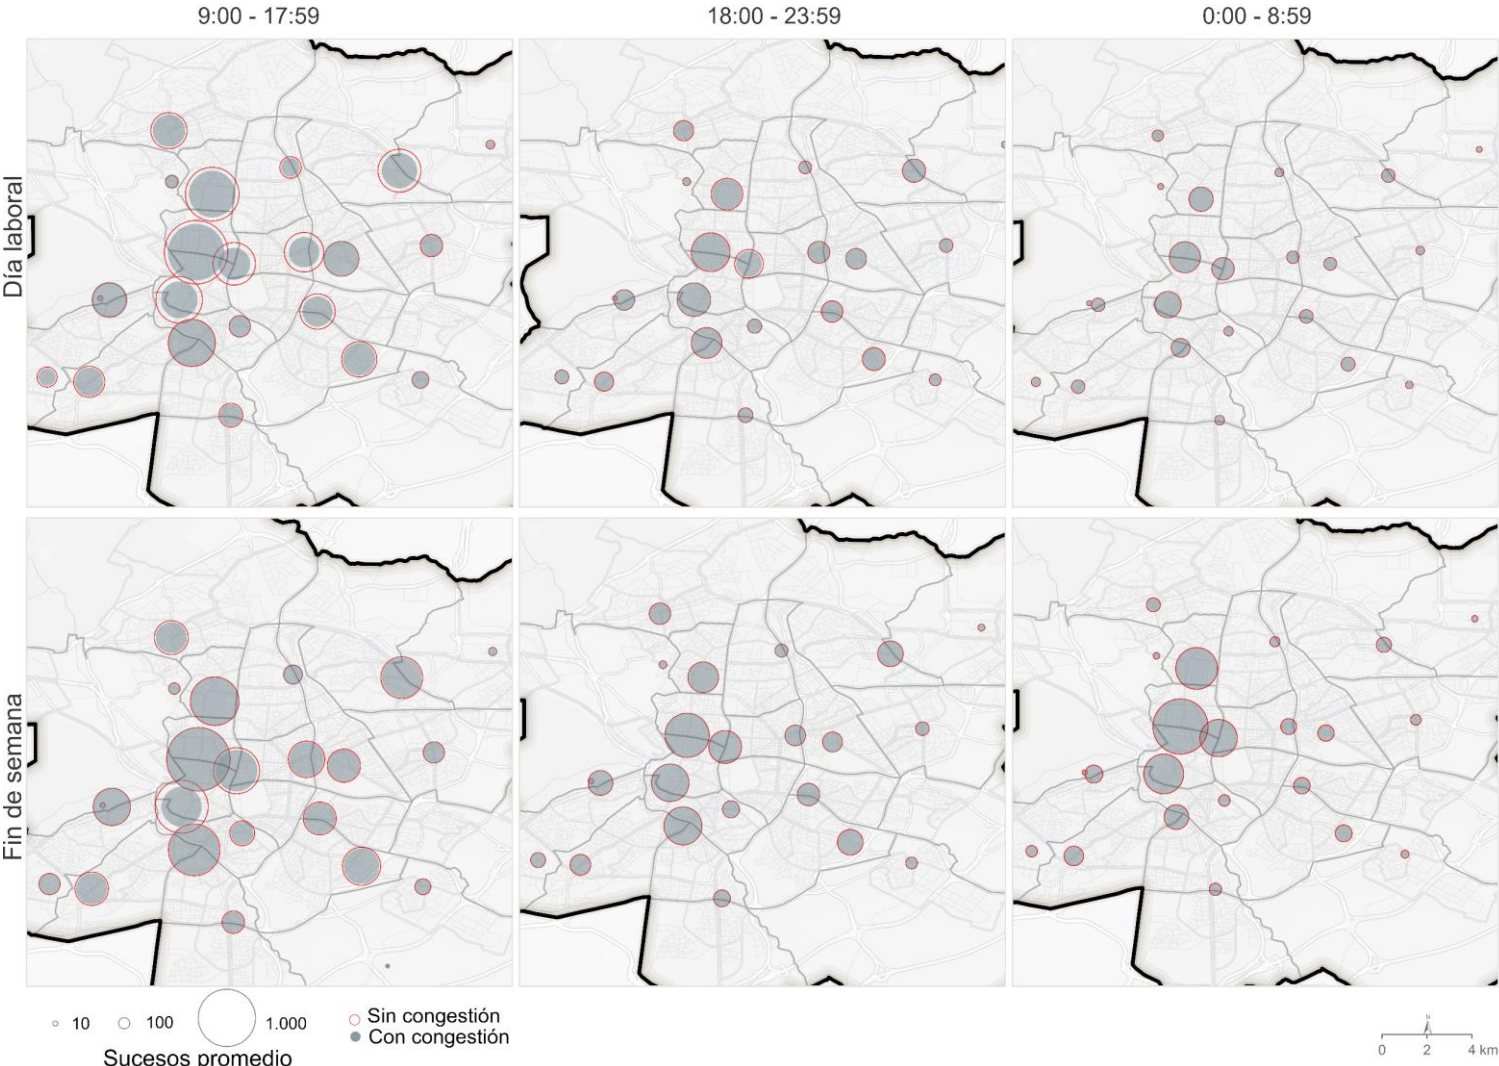
Las Figura 91 y Figura 92 muestran que los sucesos asignados a las estaciones SAMUR-PC cambia en cada momento del día y entre los días laborables y los fines de semana. El tamaño del símbolo representa el promedio de sucesos asignados por los MLA a cada una de las estaciones del SAMUR según la franja horaria. En ambos años se observa que muchas de las estaciones cubren una demanda similar a lo largo del día, tanto en días laborables como en fines de semana, con la excepción de la franja horaria 00 a 9 h, momento en el que las estaciones situadas en el centro de la ciudad cubren mayor número de sucesos en los fines de semana, con marcadas diferencias en 2019 (Figura 91). Las diferencias horarias reflejan el efecto de los cambios en la distribución espacial de los sucesos y también del nivel de congestión de la red viaria.

En el periodo 9 a 18 h, la demanda cubierta supera a los otros dos periodos analizados. Esto se debe a la mayor movilidad de la población desde las residencias

a los puestos de trabajo y zonas de ocio ubicados en importantes arterias comerciales de la ciudad (De Cáceres & De la Hoz, 2009; Lobo, 1984). Este comportamiento es similar en ambos años. Además, hay cuatro estaciones situadas en el centro que en todas las franjas horarias muestran un mayor número de sucesos cubiertos. Esto coincide con los patrones de distribución espacial mostrados en la Figura 85 y Figura 86. En ellas se observa una concentración de sucesos en calles y plazas cercanas a las estaciones del SAMUR más activas durante el día (calles Gran Vía, Mayor, Alcalá y Puerta del Sol).

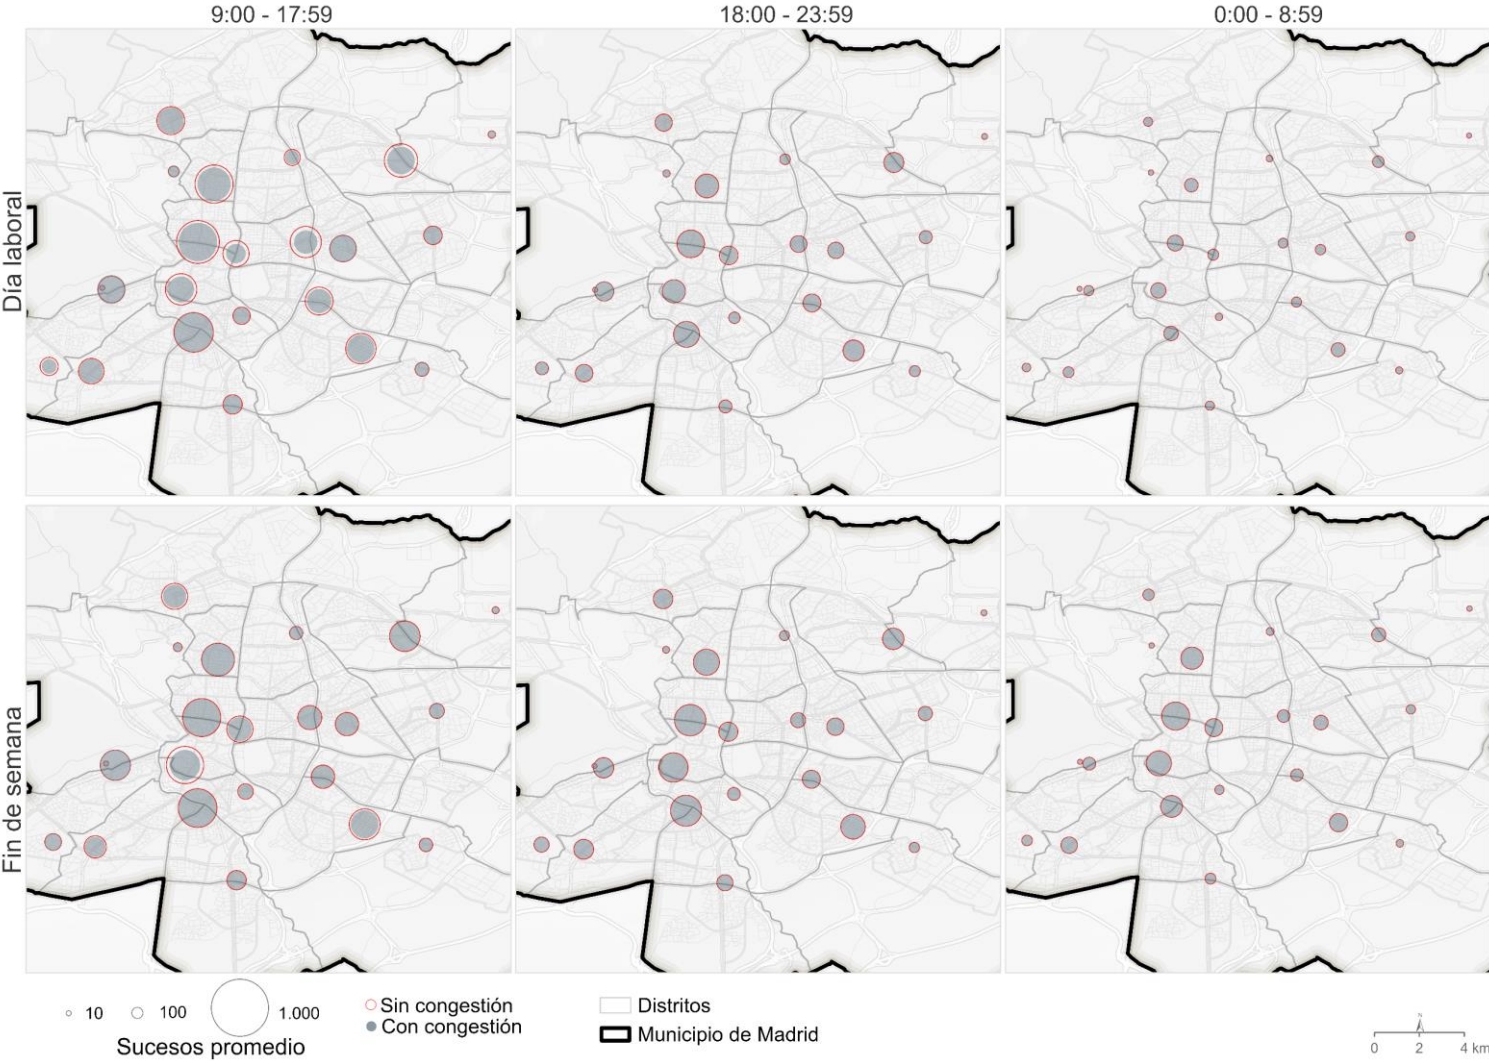
A su vez, la Figura 91 y la Figura 92 ilustran los resultados obtenidos al correr los modelos, considerando las condiciones del tráfico (círculo gris) o en flujo libre (círculo rojo), observándose que la franja horaria de 9 a las 18 h, es la más afectada por la congestión de la red viaria. Esto se debe a que las horas punta de tráfico, en la ciudad de Madrid, son a primera hora de la mañana, cuando los trabajadores se desplazan a sus puestos de trabajo, y por la tarde, cuando los trabajadores regresan a sus hogares. Los efectos del tráfico en los niveles de cobertura de la red de SAMUR fueron menores en 2020, con una distribución de los casos más dispersa en el conjunto de la ciudad.

Figura 91. Sucesos cubiertos por las estaciones actuales en año 2019



Fuente: Elaboración propia.

Figura 92. Sucesos cubiertos por las estaciones actuales en año 2020



Fuente: Elaboración propia.

La Tabla 45 contiene los resultados del modelo desarrollado para las dos condiciones de la red (con tráfico y flujo libre), en días laborables y fines de semana y para tres franjas horarias. Con el fin de facilitar la comparación entre los escenarios de tráfico o flujo libre, se calcularon los porcentajes de sucesos cubiertos en cada franja horaria. El porcentaje de los sucesos cubiertos por las bases del SAMUR en el lapso de 8 minutos fue superior al 95% en todas las franjas horarias en situaciones en flujo libre, pero cuando se incluyeron escenarios con congestión, los porcentajes disminuyeron, encontrándose los valores más bajos en la franja horaria 9 a 18 h. Al analizar los resultados del 2020, estos valores son, ligeramente, menores (Tabla 45), debido al cambio del ritmo de la ciudad por las medidas de contención de la COVID-19 (Romanillos et al., 2021), que provocó un desvío de los patrones espaciales habituales de los sucesos. También se observa que, en ambos años, durante los fines de semana, los porcentajes de cobertura son un poco más altos que durante los días laborables producto de menores niveles de congestión.

Tabla 45. Variaciones de la distribución de los sucesos y tráfico (TomTom) en la red según franjas horarias

Escenario		Estaciones actuales							
		2019				2020			
		Flujo libre		Con tráfico		Flujo libre		Con tráfico	
		Sucesos	%	Sucesos	%	Sucesos	%	Sucesos	%
Día laborable	09:00-17:59	43.964	95,6	38.996	84,8	32.316	95,0	28.837	84,8
	18:00-00:00	24.923	95,9	24.427	94,0	19.257	95,2	18.867	93,3
	00:00-08:59	14.999	95,7	14.999	95,7	9.298	94,3	9.298	94,3
Fin de semana	09:00-17:59	16.301	96,0	15.729	92,6	10.943	95,0	10.573	91,8
	18:00-00:00	10.438	96,2	10.375	95,6	8.022	95,5	7.961	94,8
	00:00-08:59	8.834	96,6	8.834	96,6	5.585	95,2	5.585	95,2

Fuente: Elaboración propia.

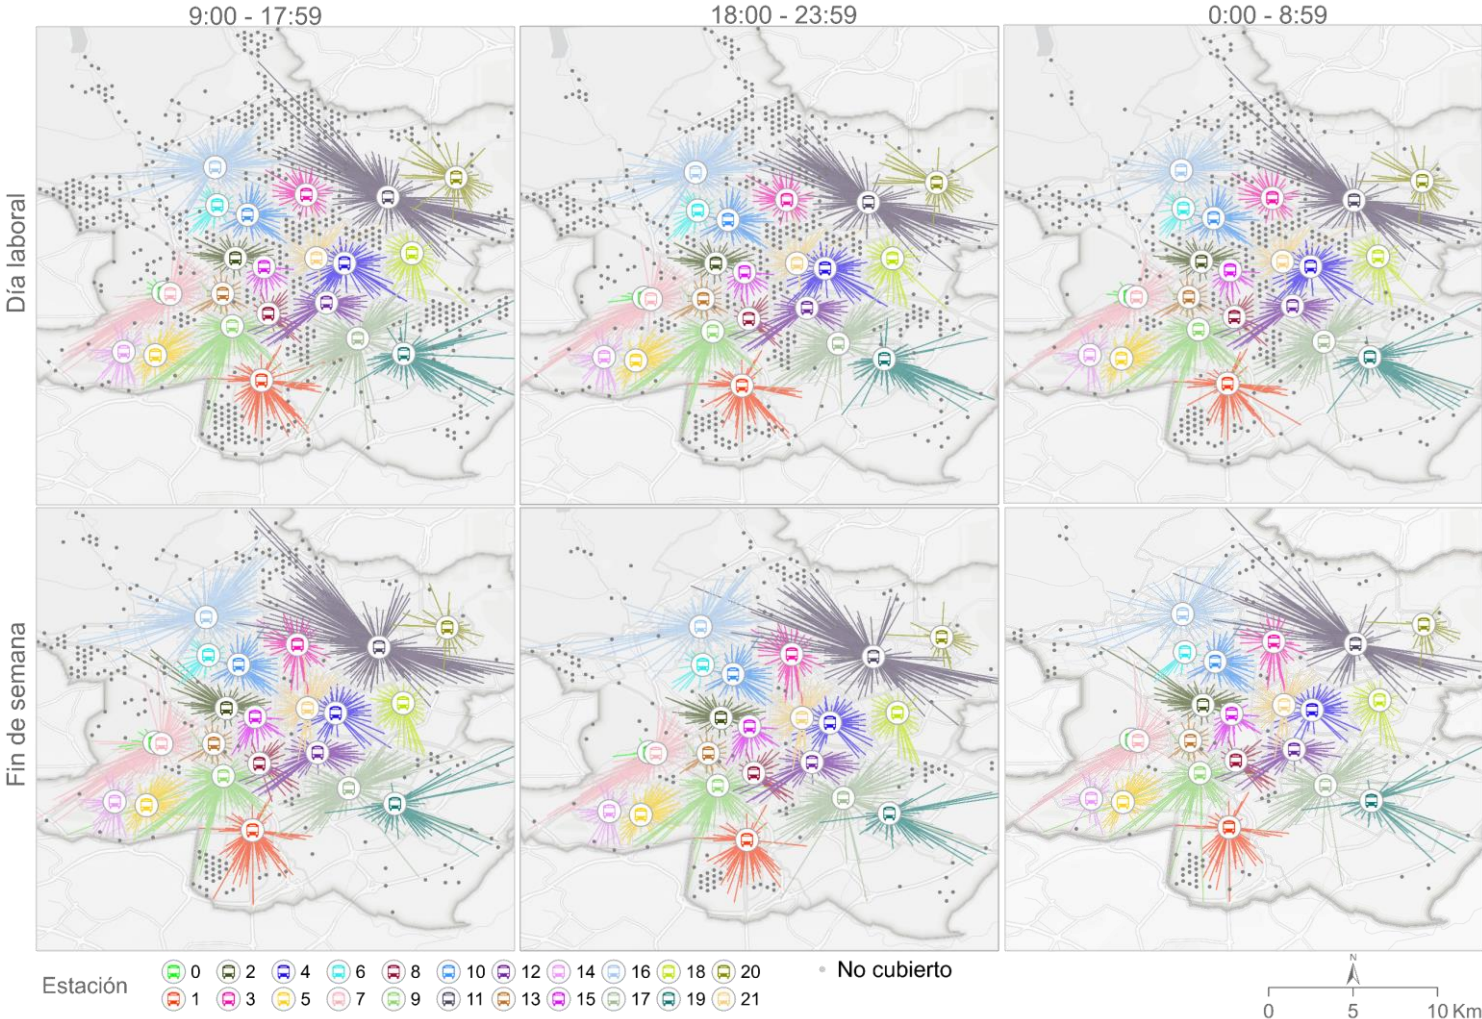
Los sucesos no cubiertos se sitúan en la periferia y en el centro del municipio, específicamente, en los días laborables (Figura 93 y Figura 94). Por el contrario, los

fin de semana hay menos zonas sin cobertura. Este comportamiento se debe a un menor nivel de congestión vehicular el fin de semana. En cuanto a las franjas horarias, entre las 9 y 18 h se presenta el mayor porcentaje de sucesos sin cubrir por las estaciones existentes. Mientras, para el año 2020, se repite el patrón anterior.

El análisis de los cambios en las formas de las arañas, para cada estación actual del SAMUR, (Figura 93 y Figura 94) reflejan patrones de comportamiento significativos. Se observa que, en los días laborables y fines de semana, de ambos años, las formas de las arañas son desiguales como consecuencia de los cambios en el comportamiento del tráfico vehicular durante el día. Estos cambios provocan que los sitios de demanda se reasignen entre las estaciones. Los cambios en la reasignación de los sucesos son más notables en la franja 9 a 18, específicamente, las localizadas hacia el centro este del área de estudio (identificador 11, 15, 20). Lo que debería relacionarse con mejores condiciones de tráfico y con una mayor incidencia de sucesos hacia esas áreas en horas de la tarde.

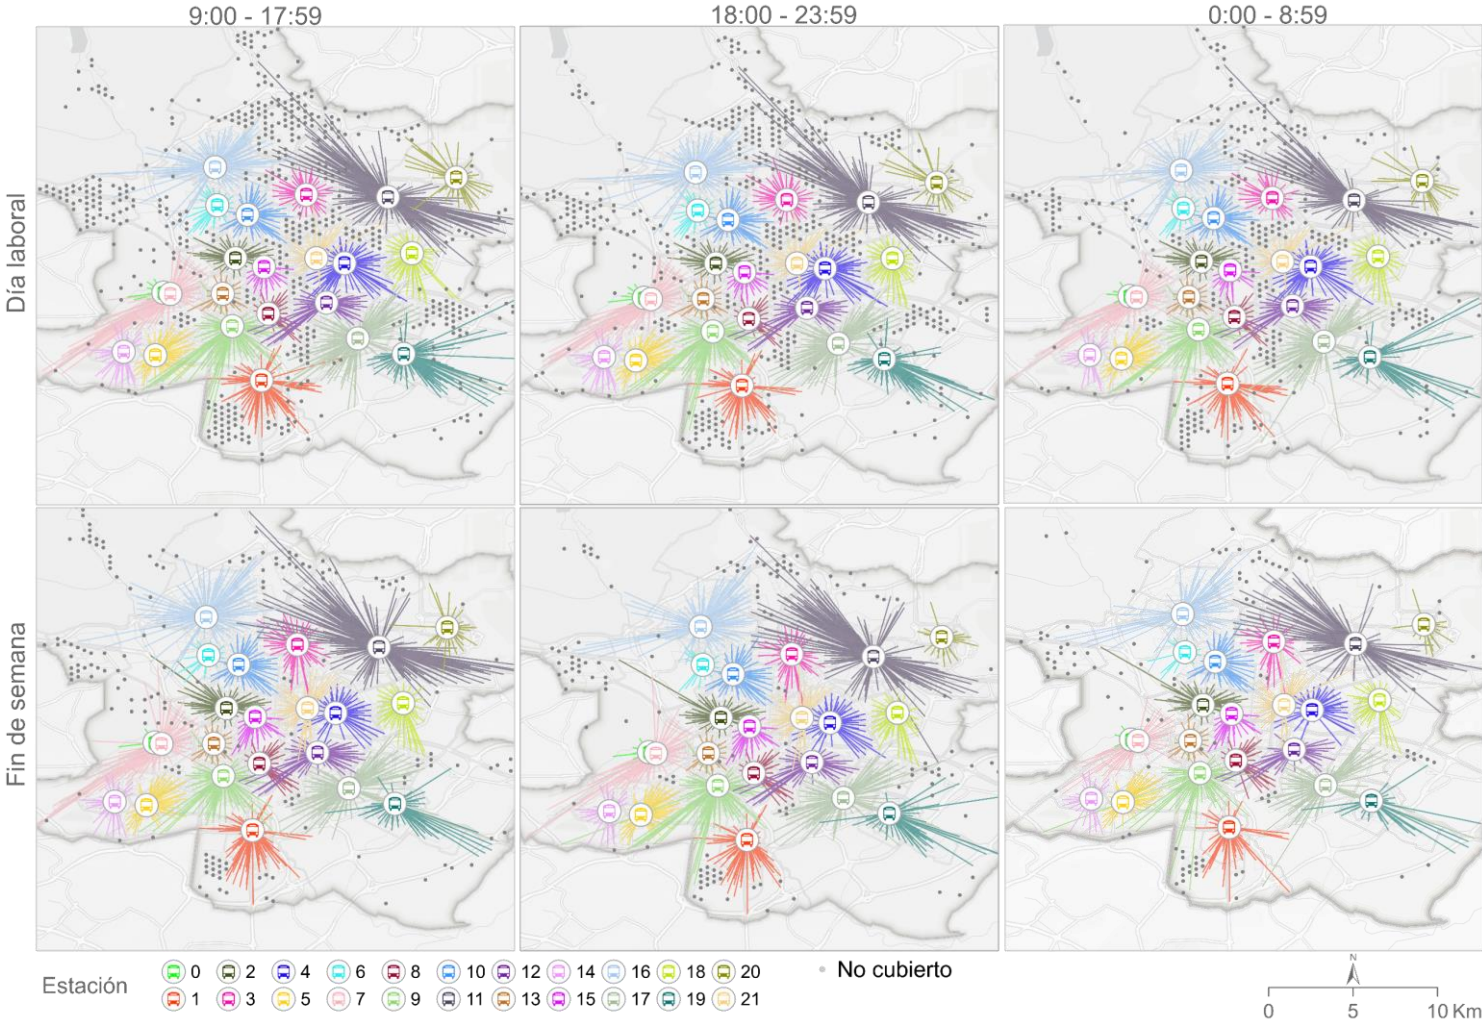
Al enfocarnos en las bases ubicadas en el distrito Centro (identificador 3, 8 y 13), se observa que la dimensión de las líneas es muy pequeña en todas las franjas temporales. Esto indica que a partir de la ubicación de estas bases las distancias recorridas en 8 minutos son muy cortas. En estos espacios la congestión vehicular es muy alta durante el día. En cambio, en las bases localizadas en la periferia de la ciudad, notamos que las líneas tienen una mayor longitud, lo que indican que las distancias recorridas en 8 minutos son más largas.

Figura 93. Asignaciones de los MLA a las estaciones actuales año 2019



Fuente: Elaboración propia.

Figura 94. Asignaciones de los MLA a las estaciones actuales año 2020



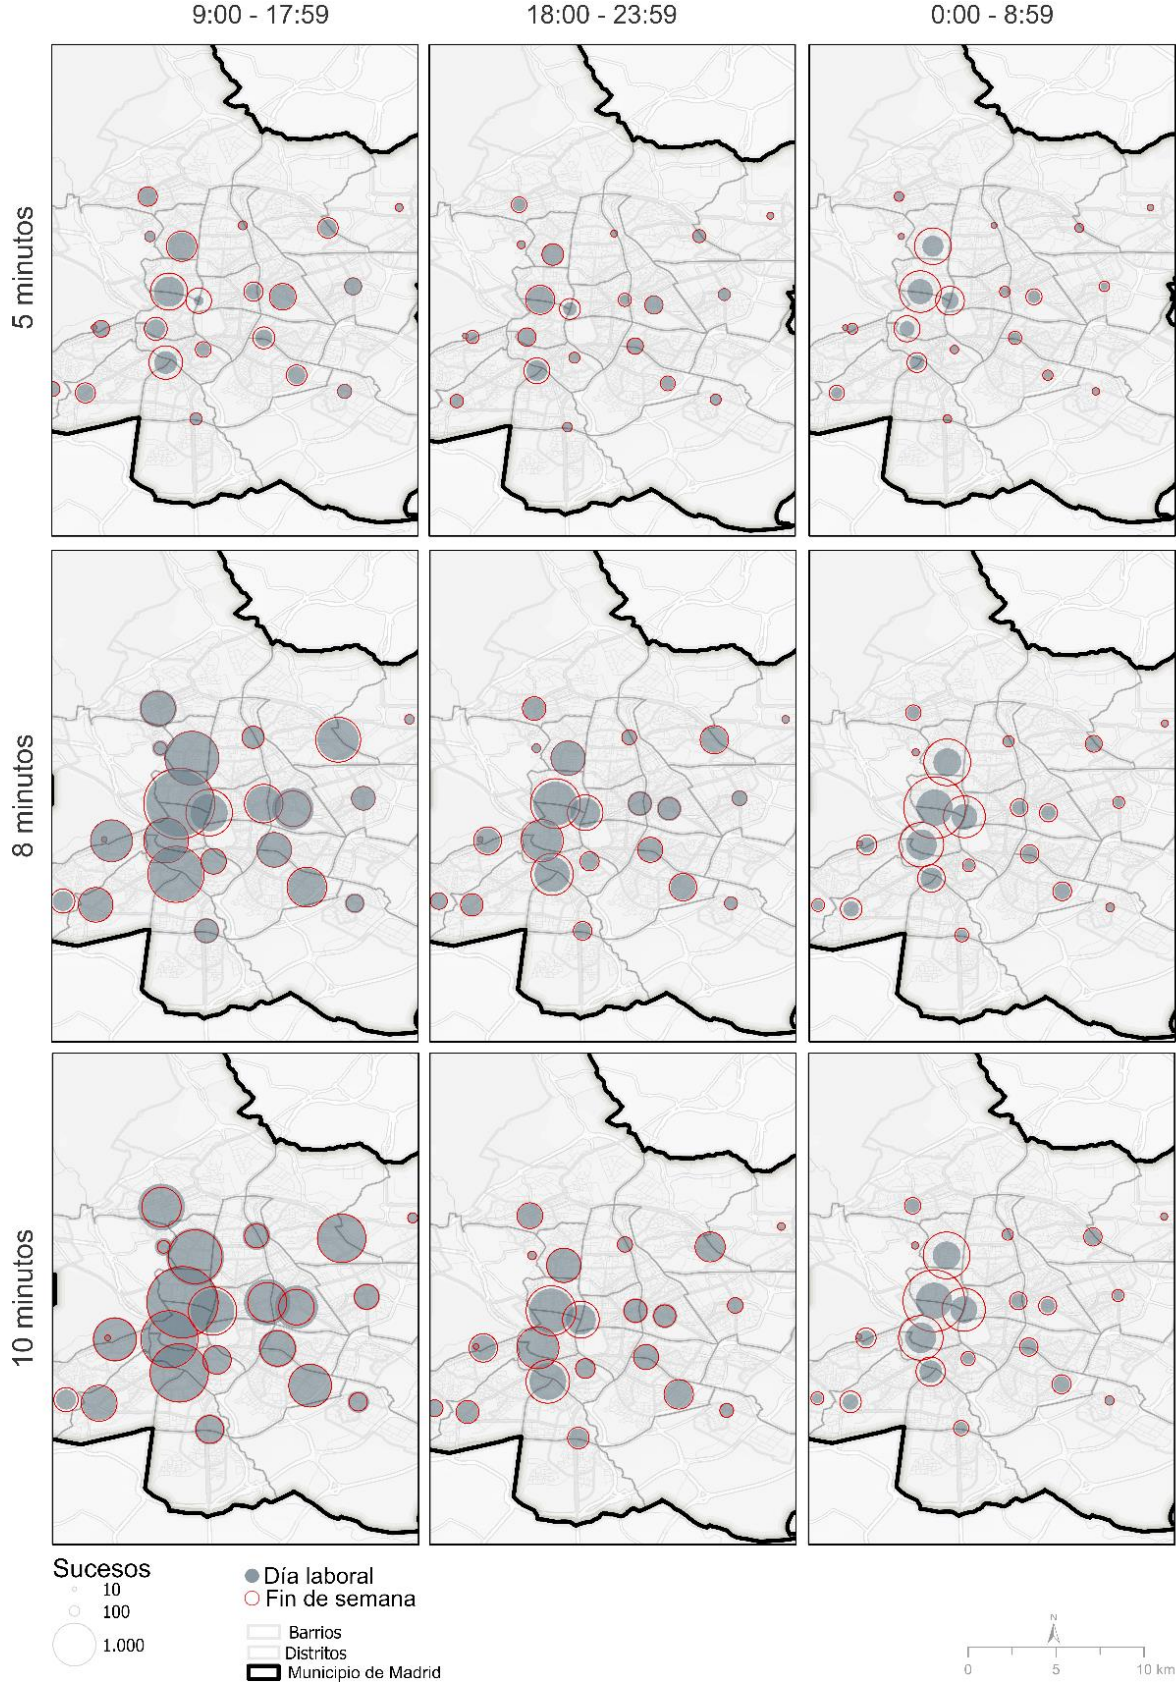
Fuente: Elaboración propia.

#### 4.3.3.5 *MLA con escenario para varios tiempos de reacción*

En la Figura 95 y la Figura 96, se comparan los resultados obtenidos al ejecutar el modelo considerando umbrales de tiempos de 5, 8 y 10 minutos para evaluar el efecto del tiempo de respuesta en las diferentes franjas horarias analizadas. Tomando 5 minutos como tiempo de respuesta, se observa que, en la franja horaria de 9 a 18 h, los fines de semana muestran una mejor cobertura del sistema de emergencias, especialmente, en las estaciones situadas en el centro de la zona de estudio, tal como indican los círculos rojos. Mientras que la franja de 18 a 00 h muestra pocas diferencias entre los días laborables y los fines de semana. Por otro lado, la banda de 00 a 9 h, presenta una mayor cobertura los fines de semana en comparación con las otras dos franjas analizadas. Este patrón se explica por el hecho de que los fines de semana los ciudadanos se desplazan a las zonas de ocio y restauración, situadas en el distrito Centro. Además, el movimiento de vehículos es más fluido que en días laborables. En el caso del modelo de ocho minutos, los círculos indican que, durante la franja horaria de 9 a 18 h, se vuelve a presentar la mayor cobertura, lo que está relacionado con el hecho de que es, en esta franja horaria, cuando el SAMUR atendió el mayor número de incidentes. Una vez más, los fines de semana prevalecen sobre los días laborables.

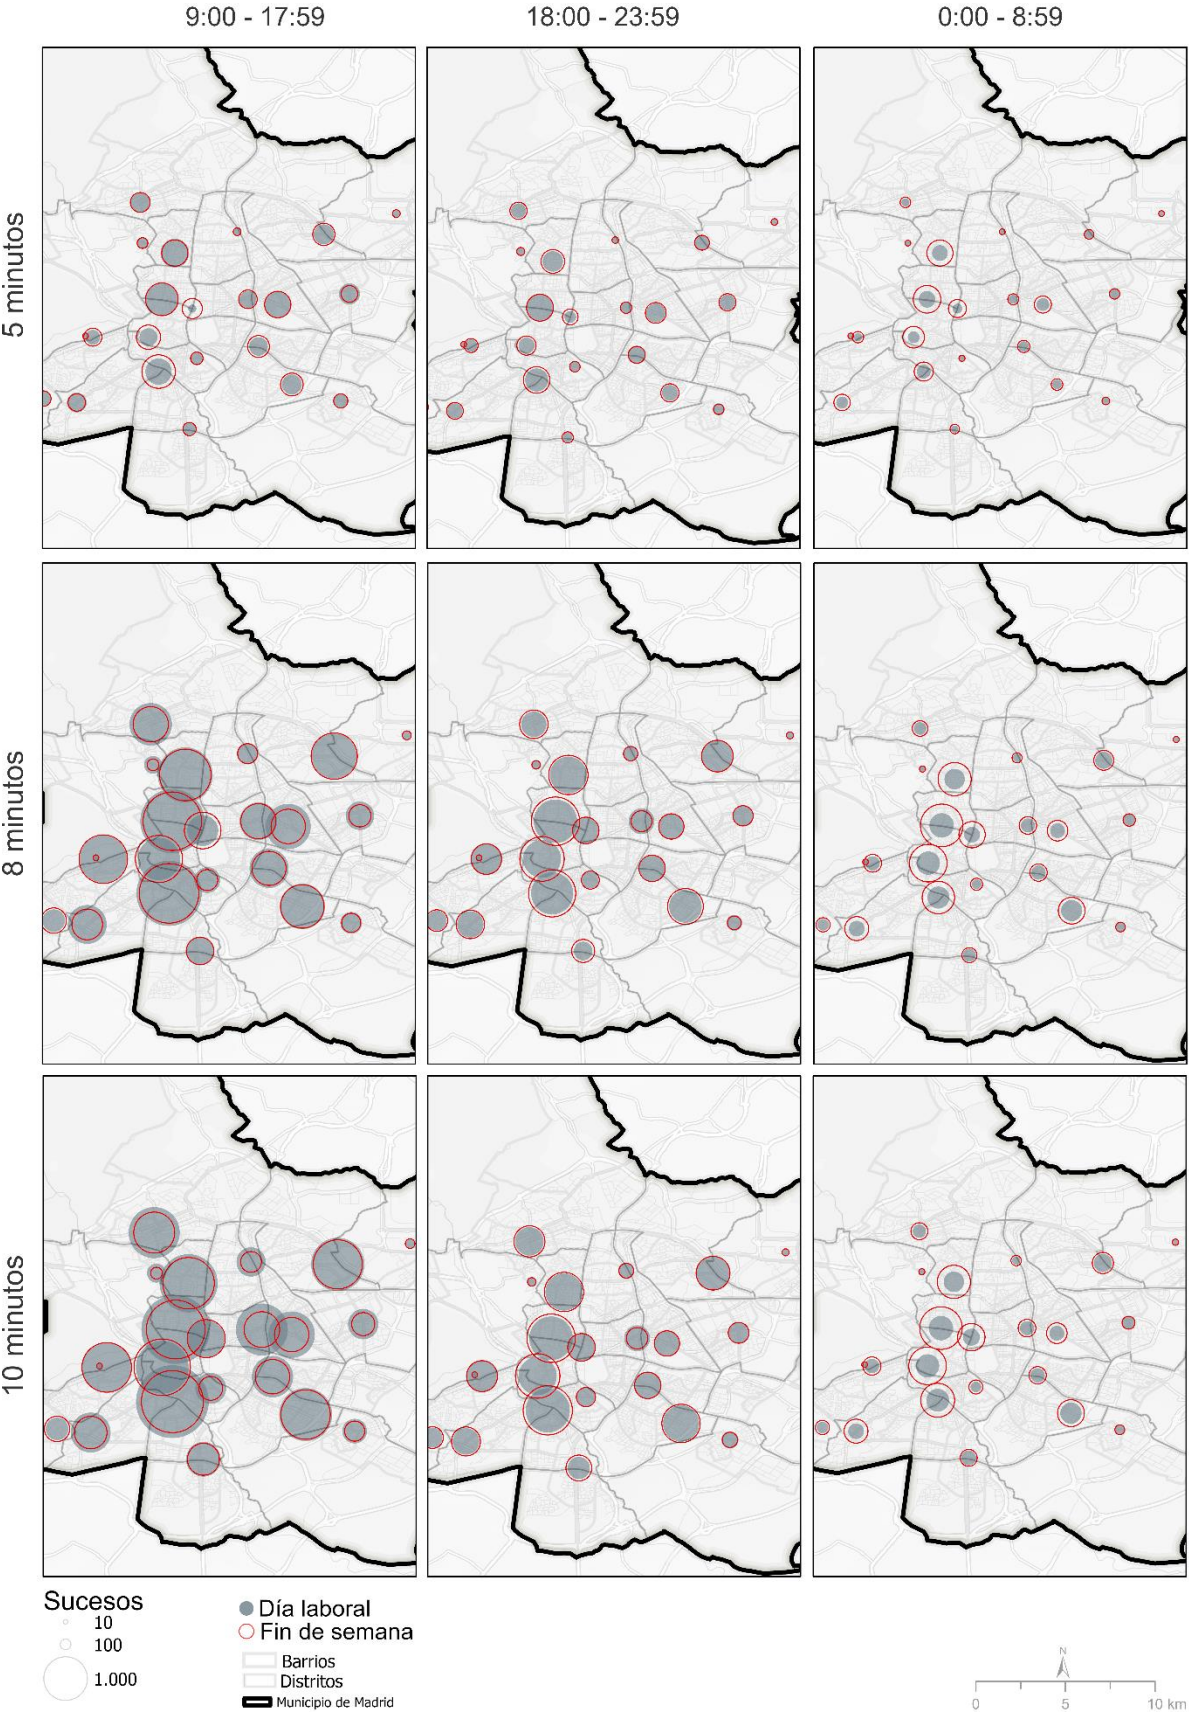
La Figura 95 y la Figura 96 muestran los sucesos cubiertos para un tiempo de respuesta de 10 minutos. Sin embargo, estos incrementos no son significativos respecto a un tiempo de respuesta de 8 minutos, dado el alto porcentaje de sucesos cubiertos ya con ese tiempo de respuesta. En el caso de la franja horaria 0 a 9 h, se aprecia que con los tres umbrales temporales (5, 8, y 10 minutos) las estaciones registran más actividad los fines de semana, debido a la presencia de habitantes en los espacios de ocio, propios de la zona centro de la ciudad de Madrid. También, influye el hecho de que en esta franja horaria hay pocos coches circulando por las carreteras, generando una red viaria en condiciones de casi flujo libre. Además, destaca que en los tres umbrales temporales (5, 8, 10 minutos) algunas de las estaciones situadas al noreste de la zona de estudio aumentan su cobertura, siendo este comportamiento más marcado en la franja horaria de 9 y 18 h.

Figura 95. Sucesos cubiertos por las estaciones en 5-8-10 minutos año 2019



Fuente: Elaboración propia.

Figura 96. Sucesos cubiertos por las estaciones en 5-8-10 minutos año 2020



Fuente: Elaboración propia.

La Tabla 46 resume el total y el porcentaje de demanda asignada a las estaciones, tomando en cuenta la congestión de la red y la distribución de los sucesos según, las franjas horarias, demostrando que en cinco minutos se cubre algo más de la mitad de los sucesos. Con 10 minutos de tiempo de respuesta la cobertura es muy cercana al 100% en todas las franjas horarias. La franja horaria de 9 a 18 h, a pesar de tener el mayor número de sucesos, presenta el menor porcentaje de cobertura. Este comportamiento se repite en los umbrales de 8 y 10 minutos tanto en días laborables como en fines de semana. Además, se corrobora el impacto de la congestión en los resultados del modelo.

Tabla 46. Modelos con los sucesos y congestión de la red según franjas horarias 2019-2020

Escenario		Estaciones actuales															
		8 minutos (escenario base)				5 minutos (-3 minutos respecto a escenario base)						10 minutos (+2 minutos respecto a escenario base)					
		2019		2020		2019		2020		2019			2020				
		*Suc.	%	Suc.	%	Suc.	%	**Inc.	Suc.	%	Inc.	Suc.	%	Inc.	Suc.	%	Inc.
Día laboral	09:00-17:59	38.996	84,8	28.837	84,8	15.970	34,7	-50,1	12.228	36,0	-48,8	44.957	97,7	12,9	33.077	97,3	12,5
	18:00-23:59	24.427	94,0	18.867	93,3	11.550	44,5	-49,5	8.962	44,3	-49,0	25.589	98,5	4,5	19.834	98,1	4,8
	00:00-08:59	14.999	95,7	9.298	94,3	8.316	53,1	-42,6	4.912	49,8	-44,5	15.485	98,8	3,1	9.659	98,0	3,7
Fin de semana	09:00-17:59	15.729	92,6	10.573	91,8	7.923	46,7	-45,9	5.335	46,3	-45,5	16.766	98,8	6,2	11.276	97,9	6,1
	18:00-23:59	10.375	95,6	7.961	94,8	5.327	49,1	-46,5	4.077	48,5	-46,3	10.743	99,0	3,4	8.266	98,4	3,6
	00:00-08:59	8.834	96,6	5.585	95,2	5.320	58,2	-38,4	3.169	54,0	-41,2	9.074	99,2	2,6	5.757	98,1	2,9

Nota: \*Suc = sucesos \*\* Inc. = incremento

Fuente: Elaboración propia a partir de registros del SAMUR-PC

En síntesis, estos resultados sugieren que en la franja horaria de 9 a 18 h sería bueno reforzar el sistema para mejorar los niveles de cobertura, ya que con ocho minutos quedaría sin cubrir cerca del 15% de los sucesos. En cambio, al utilizar 10 minutos como tiempo de respuesta máxima permitida, se alcanza cerca del 100% de los sucesos en todas las franjas horarias.

Por otro lado, al comparar los resultados obtenidos para 2019, frente a 2020 (año de la pandemia de COVID-19), se observa que durante 2020 los porcentajes de cobertura

fueron, ligeramente, inferiores en comparación con el año 2019, a pesar de producirse menos sucesos atendidos por el SAMUR-PC.

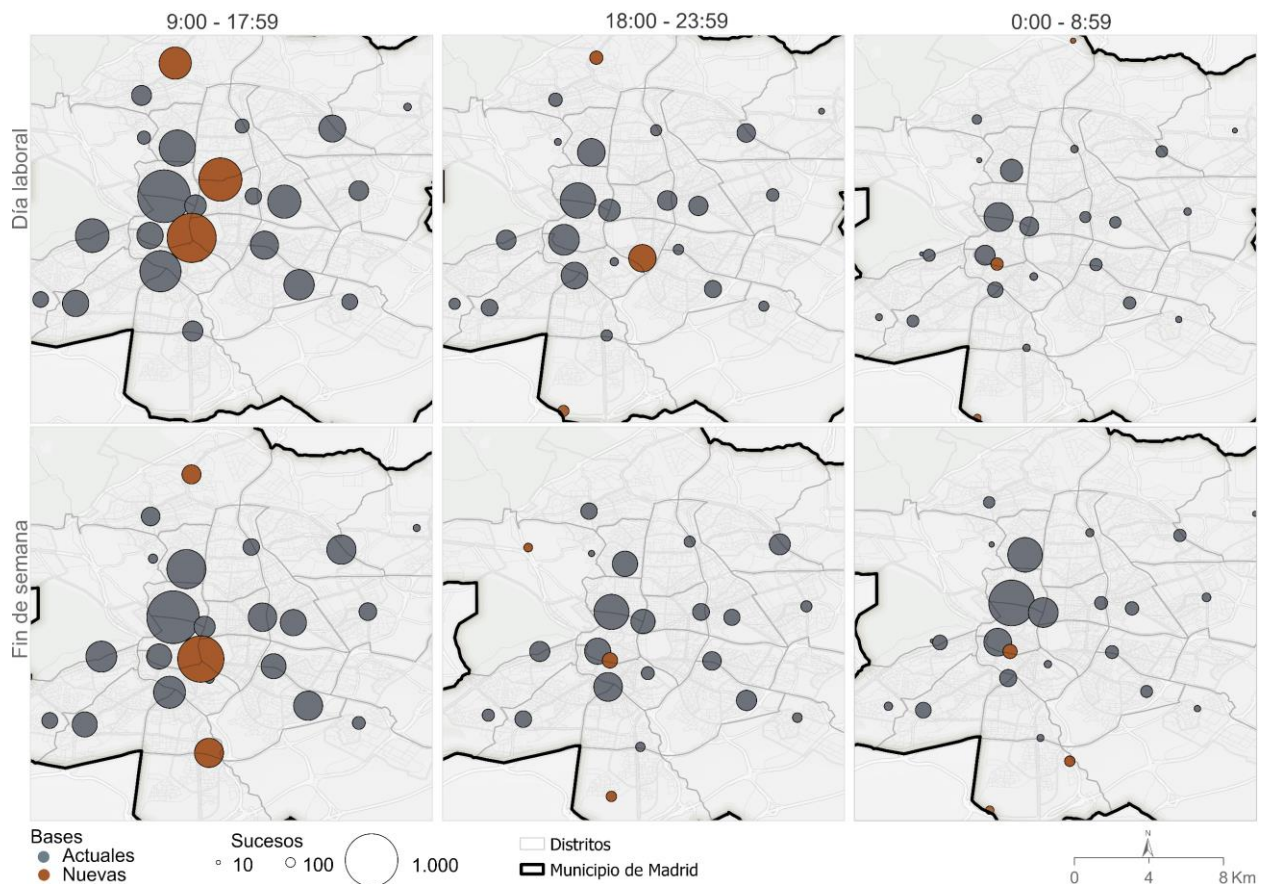
Al tomarse como escenario base de comparación, los resultados obtenidos con el modelo de ocho minutos, se observa que, con tres minutos menos, se produce una disminución que oscila entre el -38,4 y -50,1, siendo más notable en la franja horaria de 9 a 18 h y en días laborables. Por otro lado, el escenario de 10 minutos presenta incrementos de más de 3,1 mostrando la franja horaria de 9 a 18 h los valores más altos.

#### *4.3.3.6 Escenario con un incremento del número de estaciones*

Con el objetivo de mejorar el porcentaje de demanda cubierta se probó incluir tres nuevas estaciones. La Figura 97 y la Figura 98 muestran la ubicación de las estaciones SAMUR actuales (círculo gris) y las tres nuevas estaciones (círculo chocolate) incluidas en el modelo.

En todas las franjas horarias se visualiza que las estaciones del centro de la ciudad son las que cubren mayor número de sucesos (Figura 97 y Figura 98). Por su parte, las nuevas estaciones cambian de posición en función del comportamiento de los sucesos que se producen en cada una de las franjas horarias, tanto en días laborables como en los fines de semana. En particular, las nuevas estaciones en la franja de 9 a 18 h de los días laborables están situadas en las zonas del centro y del norte, que son espacios de ocio y de oficinas. A su vez, estas nuevas estaciones pueden atender más demanda que algunas de las estaciones existentes, tal como indica el tamaño de los círculos chocolate.

Figura 97. Sucesos cubiertos por las estaciones actuales y nuevas 2019

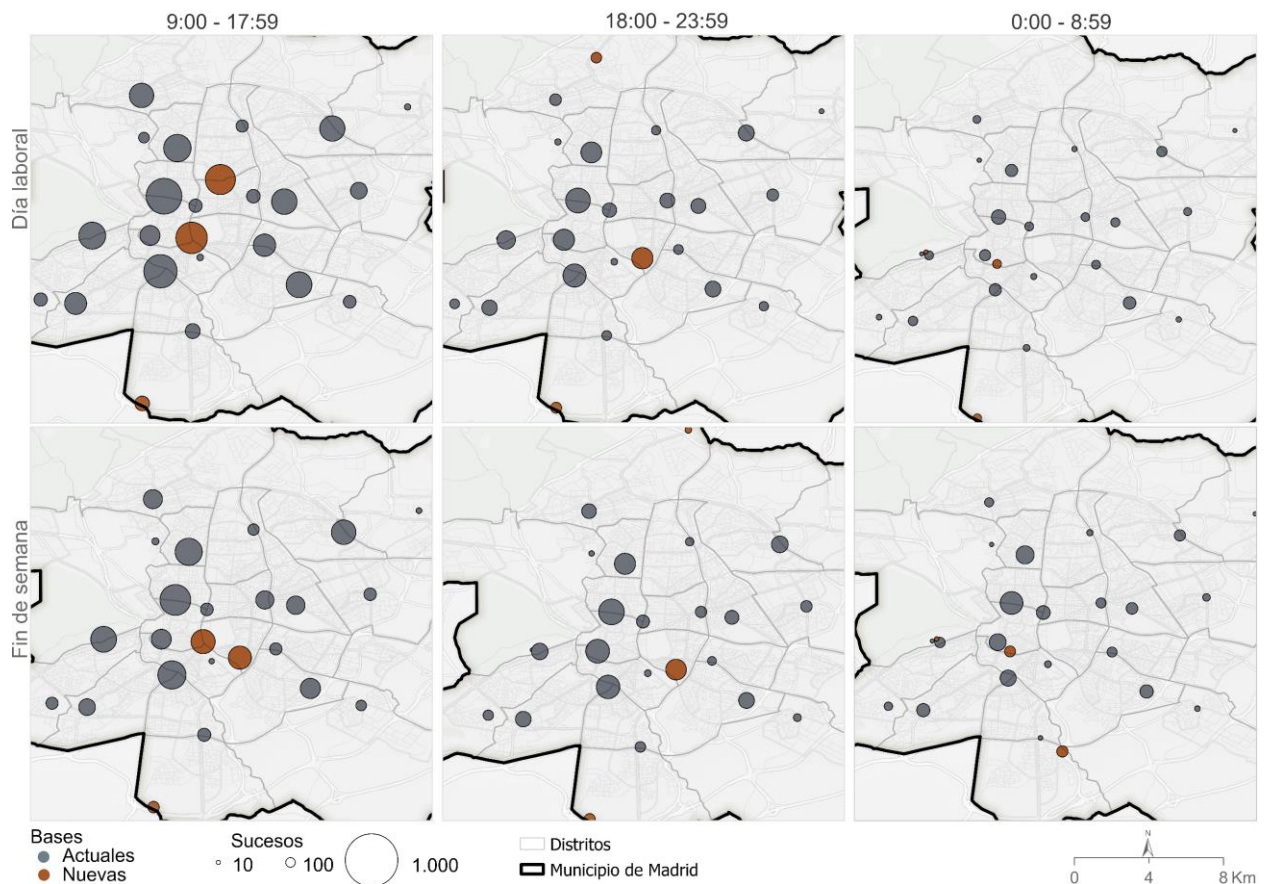


Fuente: Elaboración propia.

Los fines de semana solo se repite la localización de una de las estaciones de los días laborables. La explicación de estos resultados puede radicar en los cambios que se producen en la distribución de los sucesos a lo largo del día. En las franjas horarias 18 a 00 h y 00 a 9 h se observa que las tres nuevas estaciones están localizadas en la periferia, repitiendo ubicación la estación situada al sur de la zona de estudio.

Durante el año 2020, las nuevas estaciones también cambian de ubicación a medida que avanza el día (Figura 98). Una vez más, las nuevas estaciones de la franja 9 a 18 h absorben el mayor número de sucesos. Al comparar los resultados de ambos años, se observa que las estaciones en 2020 cubrieron menos demanda que en 2019.

Figura 98. Sucesos cubiertos por las estaciones actuales y nuevas 2020



Fuente: Elaboración propia.

La Tabla 47 presenta los sucesos cubiertos implementando el modelo donde se incluyen tres nuevas estaciones en el sistema de emergencias. Al incorporar tres estaciones a las 22 actuales, la cobertura del SAMUR-PC mejora notablemente en todas las franjas horarias. En 2019 se cubrirían entre el 92% y el 98% de los sucesos en el tiempo de respuesta de 8 minutos, destacando la franja horaria 00 a 9 h de los fines de semana con los valores más elevados. Una posible explicación a este comportamiento radica en que, durante esas horas los sucesos se concentran en las zonas de ocio nocturno y la congestión del tráfico de vehículos resulta casi inexistente. En cuanto a la franja de 9 a 18 h, durante los días laborables, se observa que sufre el mayor impacto del tráfico, pues registra los menores porcentajes de cobertura. Esta situación varía los fines de semana, cuando la cobertura aumenta un 5%. La explicación de tales diferencias se deben, en parte, a los cambios en el comportamiento de la red de carreteras, que presentan un tráfico más fluido en sábados y domingos (TomTom, 2020). Por otro lado, con la situación excepcional de 2020, los porcentajes serían, ligeramente, inferiores (entre el 91% y el 97%). En

cualquier caso, la adición de tres nuevas estaciones alcanza valores muy cercanos al 100% de la demanda.

Al comparar los datos de las Tabla 45 y Tabla 47 en todas las franjas se logran incrementos que oscilan entre el 2% y el 7%. El máximo valor se encuentra en la franja de 9 a 18 h de los días laborables.

Tabla 47. Demanda cubierta por las actuales y nuevas estaciones

Escenario		Escenario base (22 bases)				Escenario 25 bases					
		2019		2020		2019			2020		
		Sucesos	%	Sucesos	%	Sucesos	%	Inc.	Sucesos	%	Inc.
Día laboral	09:00-17:59	38 996	84,8	28 837	84,8	42 351	92,1	7,3	31 163	91,6	6,8
	18:00-00:00	24 427	94,0	18 867	93,3	25 203	97,0	3,0	19 520	96,5	3,2
	00:00-08:59	14 999	95,7	9298	94,3	15 320	97,7	2,0	9577	97,1	2,8
Fin de semana	09:00-17:59	15 729	92,6	10 573	91,8	16 409	96,7	4,1	10 996	95,5	3,7
	18:00-00:00	10 375	95,6	7961	94,8	10 597	97,7	2,1	8149	97,0	2,2
	00:00-08:59	8834	96,6	5585	95,2	9018	98,6	2,0	5737	97,8	2,6

Fuente: Elaboración propia.

## **5 CONCLUSIONES**

La última sección de la tesis presenta las conclusiones de la investigación. Con ellas se responde a las preguntas planteadas al inicio de la misma. También se evalúa el logro del objetivo principal y se extraen conclusiones generales. Para finalizar, se proponen futuras líneas de investigación relacionadas con el estudio de los modelos de localización-asignación dinámicos, a partir del uso de Big Data en los datos de entrada.

## **5.1 Aportaciones en relación con las preguntas de investigación planteadas al inicio**

*P.1. ¿Qué trabajos previos se han realizado en relación con la aplicación de MLA en SIG que integren una perspectiva dinámica?*

Con este interrogante pretendíamos abordar los fundamentos de los modelos de localización-asignación e identificar los diferentes trabajos que incorporan el dinamismo en los datos de entrada de los MLA a partir del Big Data. El objetivo previsto para responder a la pregunta de investigación consistió en revisar las fuentes bibliográficas asociadas al tema de interés para el desarrollo de la tesis. Se ha buscado establecer un marco teórico conceptual que sustente la investigación. La revisión bibliográfica realizada se presenta en dos bloques temáticos.

En el primer bloque se ha examinado los documentos existentes sobre los aspectos conceptuales y teóricos de los modelos de localización y asignación en SIG. En el inicio de la tesis se presenta en qué consiste un modelo de localización y asignación de servicios y equipamientos; además, se presentan las modificaciones introducidas en los mismos desde el trabajo seminal de Hakimi en 1964. La revisión e interpretación de la bibliografía ha permitido determinar qué elementos deben contemplarse a la hora de elaborar un MLA. Al mismo tiempo, se describe la función objetivo de los distintos tipos de soluciones presentes en los MLA disponibles y se conocen los fundamentos de cada una de las soluciones. Además, se analizan las áreas del conocimiento donde los investigadores utilizan los MLA para resolver los diferentes problemas relacionados con la localización de los servicios y la asignación de la demanda. Este conocimiento teórico ha sido fundamental para poder incorporar después fuentes de datos dinámicas en los MLA y realizar aplicaciones en las que testar los efectos del dinamismo urbano en los resultados de MLA a determinadas problemáticas.

En el ámbito del Big Data, el segundo bloque, recoge información de las fuentes que incluyen atributos de geolocalización espacial y temporal. La revisión de los datos geolocalizados se ha enfocado desde dos puntos de vista. Primero, se revisaron los trabajos desarrollados con fuentes que permiten identificar las localizaciones espaciales y temporales de la demanda de servicios o equipamientos a lo largo del día. Para la tesis han resultado de interés los trabajos que utilizan algunos datos geolocalizados con componente temporal, para tener un aproximado del comportamiento de la oferta o demanda. Luego, se examinan también los trabajos realizados con datos que contemplen la introducción de variables dinámicas en la construcción de las redes de transporte utilizadas para plantear los MLA. Nos centramos en las investigaciones que emplean redes que incluyan el papel de la congestión en los modelos y las que se apoyan en ficheros GTFS, para incorporar las frecuencias del servicio de transporte público.

Producto de la revisión bibliográfica, se presenta una panorámica de los trabajos realizados con nuevas fuentes de datos (Big Data). El Big Data permite conocer la posición geográfica de la demanda, la oferta y el comportamiento de la red. Estos datos pueden usarse como insumos de entrada para el desarrollo de modelos de localización-asignación. En definitiva, como consecuencia de la revisión bibliográfica, podemos responder al interrogante planteado señalando que las nuevas fuentes de datos permiten plantear los modelos tradicionales de localización-asignación desde una perspectiva dinámica. Es decir, incorporar la componente temporal, tanto en la distribución de la demanda como en las redes de transporte. En el pasado, debido a la escasa cantidad de datos disponibles, los modelos de localización trataban de resolver los problemas de la ubicación, basándose en una demanda estática durante el día, y lo mismo ocurría con las redes de transporte. Sin embargo, los resultados de la revisión nos muestran la poca existencia de trabajos que enfoquen los modelos de localización a partir de las nuevas fuentes de datos con el propósito de determinar la distribución cambiante, tanto de la demanda como de la oferta, e incorporar los cambios que se producen en el comportamiento de la red de transporte público y privado. Entre los escasos ejemplos de trabajos que incorporan una perspectiva dinámica, figuran los que utilizan datos GPS y de telefonía móvil para conocer la distribución de la demanda o de la oferta. Mientras que, hasta el momento de la revisión, ningún trabajo ha utilizado los datos de TomTom y GTFS al construir la red

utilizada en los MLA, para incluir el impacto de la congestión y las frecuencias del transporte público en el desarrollo de estos modelos.

En síntesis, los modelos de localización-asignación se pueden enriquecer utilizando las nuevas formas de localización de la demanda, la oferta y el funcionamiento de la red durante el día, pero estas potencialidades han sido muy poco explotadas hasta ahora, existiendo la oportunidad de aportar a la investigación en esta línea de trabajo y ofrecer resultados un poco más cercanos a la realidad del comportamiento de la ciudad.

*P.2. ¿Qué importancia tiene analizar la distribución cambiante de la población a lo largo del día para la localización de nuevos equipamientos y servicios urbanos?*

El análisis de la dinámica de la población, en el espacio urbano, es de interés para los responsables de la toma de decisiones porque proporciona información relevante, que puede tenerse en cuenta, a la hora de planificar y gestionar los equipamientos públicos o privados. Los cambios en la distribución temporal de la población, como consecuencia de las actividades realizadas (por ocio, trabajo, educación, etc.) ocasionan el aumento o disminución de la densidad que puede provocar la escasez de oferta de servicios o la reducción del número de la población atendida en los lugares de menor concentración. Estos cambios generan por tanto dificultades para la prestación del servicio o un desequilibrio en el número de personas atendidas como resultado de las fluctuaciones de la demanda a lo largo del tiempo. Estos inconvenientes pueden paliarse, incluyendo en los MLA la variabilidad de la distribución temporal de la población.

Con el desarrollo de las tecnologías de la información y la comunicación resulta factible conseguir nuevas fuentes de datos para estudiar las ciudades con mayor detalle espacio-temporal. El surgimiento del Big Data ofrece oportunidades para analizar la distribución dinámica de la población y supone una valiosa materia prima para el estudio del comportamiento humano. Estos datos ayudan a medir los patrones de distribución espacial y temporal de los ciudadanos. Además, permiten pasar de un estudio de la población, desde una perspectiva estática a una dinámica. Dispositivos como: los teléfonos móviles, el GPS, las tarjetas inteligentes y las redes sociales, por citar algunos, permiten registrar el dinamismo de las interacciones entre la población

y su entorno urbano, así como detectar patrones espaciales de localización de los ciudadanos durante el día.

Como hemos visto con el desarrollo de la tesis, este dinamismo es importante, ya que si se ignora el cambio en la distribución temporal de la población es posible que las asignaciones en los modelos de localización de los servicios y las localizaciones para nuevos servicios no sean las óptimas. Como consecuencia de la ubicación de los servicios, en zonas de la ciudad, donde la presencia de población es escasa en una buena parte del día o, por el contrario, sobrecargar otras instalaciones en zonas donde hay una alta densidad de población en ciertos momentos temporales. Analizar la distribución cambiante de la demanda, como insumos de entrada en los MLA puede tener aplicaciones para ubicar los servicios o equipamientos, tanto, en el sector público como el privado. Sirviendo de apoyo en la toma de decisiones para definir políticas o acuerdos con las empresas en la búsqueda de la mejor gestión de los servicios en la ciudad. En el mundo de los negocios, cuando una empresa quiere crecer es importante acertar con la ubicación de las nuevas tiendas y oficinas para asegurarse de que resistan y produzcan ingresos durante mucho tiempo. En consecuencia, incorporar las variaciones de la población, incluyendo la información, que permita el análisis de la demanda que se utiliza en los MLA puede ayudar a tomar decisiones comerciales relacionadas con la distribución de las instalaciones, los horarios de apertura y la disponibilidad de empleados, entre otros aspectos.

Los resultados alcanzados en la tesis permiten responder a este interrogante señalando lo conveniente de investigar la influencia de la dinámica de la población en la localización de los servicios. Conocer la ubicación física de los usuarios ha permitido detectar picos de mayor y menor demanda de los servicios en determinados momentos del día. Esto permite un reparto más adecuado de la oferta, que tome en cuenta, en qué parte de la ciudad hay más personas que utilizan un determinado servicio durante cada momento del día. No obstante, como se ha visto, la intensidad en los cambios en los resultados de los modelos depende del tipo de aplicación y de las soluciones empleadas.

En definitiva, analizar cómo cambia la población a lo largo del tiempo ayuda a ubicar los servicios de forma más eficiente. Esto permite analizar las instalaciones infrautilizadas y pensar en cómo trasladar a los clientes a nuevos lugares que

satisfagan sus necesidades. Con ello es posible modificar los horarios de apertura y cierre de las instalaciones poco utilizadas para reducir costes y mejorar la calidad y eficacia del servicio. Además, se pueden programar distintos miembros del personal para diferentes momentos del día, en función de la carga de trabajo.

*P.3. ¿Es factible utilizar las nuevas fuentes de datos para determinar la localización cambiante de la demanda y la oferta de servicios como uno de los elementos de los modelos de localización-asignación?*

Los grandes volúmenes de datos que se producen hoy en día han dado lugar al término Big Data. Estos nuevos datos, recogidos mediante sensores y dispositivos diversos, reciben numerosos usos. En el ámbito académico, la Geografía ha sido una importante beneficiaria de todas estas nuevas fuentes de datos; en particular, de aquellas que registran las referencias espaciales y temporales de las actividades realizadas por la población. En definitiva, el Big Data nos permite retomar métodos y técnicas clásicas para proponer investigaciones novedosas.

La respuesta a la pregunta de la investigación se presenta en función de los objetivos específicos dos y tres, expuestos en el apartado 1.3 de la tesis. En primer lugar, se han identificado y seleccionado fuentes de datos que permiten estimar la distribución de la demanda a lo largo del día. Estas fuentes han sido usadas para evaluar los puntos de mayor demanda de servicios de movilidad y de servicios de atención de emergencias, con ayuda de los datos provenientes de fuentes *Big Data*. En concreto, se han utilizado registros GPS de un servicio de motocicletas de movilidad compartida y la geolocalización de los sucesos atendidos por el servicio de emergencias de la ciudad de Madrid (SAMUR-PC). Por último, se selecciona la oferta de servicios que utilizamos para el diseño de los modelos de localización.

Ante todo, en la tesis ha interesado obtener datos geolocalizados, con atributos de coordenadas geográficas, pero también con información temporal. Tales atributos facilitan identificar los lugares donde se concentra la población (demanda o clientes) durante el día.

En definitiva, podemos responder afirmativamente a esta pregunta, de manera que no solo es factible usar nuevas fuentes de datos para incorporar la componente temporal en la distribución de la demanda en los modelos de localización-asignación en

entornos SIG, sino que es necesario para obtener unos resultados que permitan optimizar la prestación del servicio.

*P.4. ¿Es posible incorporar la información de redes dinámicas de transporte (de redes de carreteras o de transporte público) en la aplicación de modelos de localización-asignación de servicios en un SIG y cuál es su importancia en los resultados de los modelos?*

Las redes de transporte representan uno de los elementos esenciales en el planteamiento de los modelos de localización-asignación. Constituyen la base para interconectar los emplazamientos candidatos a la localización del servicio con los puntos de demanda. En efecto, estas redes contienen información sobre el tipo de calle, la longitud, pero también la velocidad y el tráfico, entre otros atributos. A partir de estos atributos, se proponen los parámetros que intervienen en la elaboración de los modelos.

Para responder a la actual pregunta, se formuló el objetivo de identificar y seleccionar fuentes de datos que permitieran incorporar el dinamismo de la red en la aplicación de los modelos de localización-asignación. Entre las nuevas fuentes de datos se eligieron los archivos GTFS y los perfiles de tráfico históricos almacenados por los navegadores TomTom. Con la primera fuente, se creó una red para simular el desplazamiento de la población hacia las instalaciones y servicios empleando el transporte público. Con los datos de TomTom, la red diseñada pretende simular los desplazamientos de la población en coche, considerando la congestión diaria de la ciudad.

Los trabajos anteriores en la literatura sobre modelos de localización-asignación de lugares utilizan redes estáticas, contando únicamente con datos sobre los límites de velocidad (normalmente velocidades tipo) y la longitud de los diferentes segmentos de las calles. Más escasos son aún los trabajos donde se utilizan redes de transporte público. Por eso, hasta ahora, resultaba difícil aplicar variables temporales, como los niveles de congestión y la velocidad en diferentes momentos del día o las frecuencias de los servicios de transporte público. Gracias a la aparición de nuevas fuentes de datos, en concreto, los archivos GTFS (General Transit Feed Specification) y los perfiles de velocidad de redes vinculadas a navegadores (como Google Maps, TomTom u otras), se puede alimentar la red con atributos que permiten una

aproximación más adecuada de los viajes realizados en la ciudad. En definitiva, se concluye que los archivos GTFS y los datos de redes de carreteras y perfiles de velocidades, como los de TomTom, permiten confeccionar nuevas redes de transporte dinámicas que alimenten modelos de localización-asignación más eficientes.

La incorporación de la información de las redes dinámicas a los modelos es fundamental, puesto que los resultados obtenidos pueden ser útiles para la gestión de políticas y soluciones relacionadas con la eficiencia de los servicios. Por ejemplo, en el sector público, los responsables de la toma de decisiones pueden gestionar mejoras en la frecuencia de los horarios del transporte público para satisfacer la demanda del servicio por parte de los usuarios. En el sector privado, se pueden gestionar los horarios de apertura y cierre de los negocios, teniendo en cuenta la escasa movilidad de la población en transporte público o privado a determinadas horas del día. Los resultados de los modelos aplicados en la tesis muestran la variabilidad como consecuencia de la dinámica de las redes. En las diferentes aplicaciones a la localización de los centros comerciales o a los hospitales se ha podido medir la importancia que tiene el uso de estas redes en los resultados, que es nuevamente variable según el tipo de aplicación y las soluciones empleadas. De las aplicaciones presentadas en la tesis, la más afectada por el dinamismo de las redes es el modelo con las estaciones de ambulancias, tal como lo indican las notables diferencias en la cobertura entre las diferentes franjas horarias.

*P. 5. ¿Qué aplicaciones prácticas se le pueden dar a las nuevas fuentes de datos, como insumos dinámicos, de la oferta, la demanda y la red para los análisis realizados en los modelos de localización-asignación de servicios?*

Esta pregunta pretende averiguar cómo pueden aprovecharse las nuevas fuentes de datos en los modelos de localización-asignación. Las nuevas fuentes de datos incluyen registros que facilitan el trabajo con variables temporales por su alto nivel de resolución. Por ejemplo, como hemos visto, los datos de TomTom y GTFS ayudan a introducir dinamismo en las redes utilizadas en los modelos. Los registros GPS almacenados por las motocicletas de un sistema de movilidad compartida, permiten conocer el momento de los desplazamientos que realizan los usuarios. Por su parte, los registros de sucesos atendidos por SAMUR-PC sirven para obtener las coordenadas y horas en las que se producen los mismos.

Para utilizar las fuentes de datos mencionadas en el párrafo anterior, se plantean varios objetivos específicos. Primero, se explora la herramienta SIG para elegir aquellas que resulten útiles en el desarrollo de los MLA y para presentar los resultados obtenidos. Luego, se usa la herramienta adecuada para la depuración y tratamiento de los datos de entrada. Por último, se implementan MLA en diferentes aplicaciones prácticas que incorporen el componente temporal en los datos de entrada de los modelos (oferta, demanda, red). En este sentido, para dar respuesta a este interrogante, en la tesis se han propuesto aplicaciones a casos reales donde se alternan los tres datos de entrada.

En primer lugar, se han usado los modelos de localización-asignación, incluyendo el dinamismo en la red de transporte público y privado, tomando en cuenta la oferta y la demanda de manera estática. En una segunda aplicación práctica, aplicamos modelos de localización-asignación, que incorporan variables dinámicas en la demanda e incluyan información estática en la oferta y la red. Para terminar, se presenta un ejemplo de aplicación que pretende incorporar, simultáneamente, el carácter dinámico que tienen la oferta, la demanda y la red de calles.

Con respecto a la primera aplicación, en esta tesis, se utilizaron los datos de *GTFS* y *TomTom* para incorporar variables temporales sobre la red de transporte empleada en el planteamiento de los MLA. Utilizamos los modelos de localización con los siguientes servicios e instalaciones: en primer lugar, con todos los hospitales del área metropolitana de Madrid, luego con los hospitales de referencia a las áreas de salud y por último con los centros comerciales. Estos modelos permiten evaluar los cambios en la cobertura de la demanda de los hospitales y los centros comerciales producidos por las variaciones en las frecuencias del transporte público y los niveles de congestión. Para ello, los modelos de localización se han ejecutado en diferentes franjas horarias de jueves y sábado con la red de transporte público y privado.

En el caso de los hospitales públicos, se utiliza la solución de maximizar la asistencia. Con esta solución se busca cubrir la mayor cantidad de demanda, con un umbral temporal de 30 minutos. Por otro lado, la solución de maximizar cuota de mercado compartido y de maximizar cuota de mercado objetivo es utilizada para el análisis con los centros comerciales. El propósito de estos modelos consistió en evaluar el efecto

de las frecuencias del transporte público y de los niveles de congestión, sobre la cobertura de la demanda a lo largo de diferentes franjas horarias.

Los resultados de los casos de estudio mencionados, anteriormente, demuestran que la cantidad de demanda a captar por un servicio puede aumentar o disminuir, dependiendo de la variación en las frecuencias del transporte público o de las condiciones del tráfico de las calles en las diversas franjas horarias del día. La demanda atendida por los hospitales se vio afectada, de acuerdo con las condiciones de las redes. En el caso de la MLA con todos los hospitales, los resultados indican una mejor cobertura de la demanda los jueves en comparación con los sábados, este comportamiento obedece a la menor frecuencia del transporte público los fines de semana. Por otro lado, lo contrario ocurre con la red TomTom, con una mejor cobertura los sábados, a causa de los menores niveles de congestión vehicular los fines de semana. La cobertura es notablemente superior en los modelos realizados con la red TomTom, que con las redes de GTFS. El funcionamiento de las redes afecta también los resultados en la localización de un nuevo hospital, que varía su localización óptima según franjas horarias y redes utilizadas, al igual que la mejora que implica en los porcentajes de cobertura, llegando a superar el 50% en los modelos con la red TomTom y coberturas muy inferiores en los modelos con redes de transporte público.

Estos modelos con redes dinámicas tienen varias utilidades prácticas. En primer lugar, las instalaciones de servicio pueden ajustar su nivel de atención, por ejemplo, dosificando la mano de obra, tomando como referencia las horas donde existe mayor cobertura de la demanda. Segundo, porque es posible modificar los horarios de apertura o cierre de los negocios, a la demanda y el nivel de servicio de las redes. A diferencia de estudios previos, donde los resultados obtenidos solo eran representativos de un momento fijo, con la incorporación de ficheros GTFS y datos de TomTom es posible analizar la variabilidad por horas, días o el periodo temporal de interés.

El segundo caso de aplicación de la tesis plantea un modelo de localización-asignación con el fin de encontrar las mejores ubicaciones para aparcar los vehículos del sistema de micromovilidad. A diferencia de trabajos anteriores que han implementado la misma metodología para el uso compartido de bicicletas flotantes

(Park & Young Sohn, 2017; Zhang et al., 2019), en esta investigación se ha trabajado con motos compartidas e incorpora una perspectiva dinámica con respecto a la oferta y la demanda. Nuestra propuesta utilizó un conjunto de datos proporcionados por la empresa Muving, que se recogen a partir de los registros GPS de los viajes realizados por los usuarios.

El uso de datos del propio sistema, tomados como variable de localización de la demanda dentro de los modelos, permitió trabajar con información de gran detalle espacio-temporal. Frente a trabajos anteriores, en donde la demanda se trata desde una perspectiva estática, aquí se ha considerado la distribución de la demanda en diferentes franjas horarias a lo largo del día. A partir de un modelo calculado con la distribución de la demanda total (escenario de referencia), se evaluaron cómo los cambios en la distribución diaria de la demanda de viajes influyen en la ubicación de las plazas de aparcamiento. Esta perspectiva dinámica permite evaluar la eficiencia del sistema y ver cómo las variaciones, en la distribución de la demanda, afectan a la cobertura del servicio a lo largo del día. Además, es posible identificar la importancia de cada plaza de aparcamiento en función de la hora del día, identificando aquellas con mayor uso, en un momento determinado u otras que tienen un uso más continuado a lo largo del día. Por último, se ha evaluado la eficiencia de un modelo adaptado a estas variaciones horarias de la demanda.

Los resultados muestran que este tipo de modelos permite obtener una distribución eficiente de estacionamientos. Con 200 estacionamientos se capta el 72% de los viajes, en una distancia de 200 metros. Se trata de una solución óptima, que tendría un coste muy bajo de implementación, ya que podrían ser plazas, actualmente, dedicadas al coche. Esta eficiencia se mantiene en el transcurso del día, aunque la mayor dispersión de los viajes, en la franja de la mañana, hace que la cobertura se reduzca, ligeramente, en este momento, el descenso es pequeño, mientras que durante la noche la demanda está más concentrada, y la eficiencia de las plazas de aparcamiento aumenta.

Además, cuando buscamos ubicaciones óptimas para las plazas de aparcamiento que se adapten a los cambios en la demanda, se encontraron pequeñas ganancias en la demanda cubierta, que apenas permiten cubrir un 1% más de la demanda en la franja de mañana y menos de un 1% en la de tarde y noche. Aunque no hay una reducción

brusca de la cobertura total del sistema entre franjas horarias, parece haber una marcada especialización de las plazas de aparcamiento, a lo largo del tiempo. La mayor especialización residencial, en la periferia del área central de Madrid, hace que las plazas de aparcamiento de la periferia tengan una mayor actividad en las franjas de mañana, mientras que las plazas más céntricas (zonas comerciales y de ocio) tienen una mayor actividad por la tarde, y sobre todo por la noche.

Por último, en este caso de estudio, también se ha propuesto una solución para adaptar las ubicaciones de las plazas de aparcamiento a la distribución cambiante de la demanda a lo largo del día. Se trata de una solución sencilla, que combina las mejores ubicaciones en cada una de las franjas horarias, buscando plazas de aparcamiento que puedan mantener una alta cobertura y eficiencia a lo largo del día.

La metodología propuesta aquí puede ser interesante para los planificadores y gestores, que se enfrentan al reto de anticipar el impacto de los nuevos servicios de micromovilidad en los centros urbanos. Es necesario diseñar políticas y actuaciones capaces de regular la nueva demanda de estos sistemas, y en particular los problemas y conflictos generados por el estacionamiento de los vehículos. También, es fundamental que las empresas de micromovilidad implementen acciones conjuntas con los planificadores que permitan ofrecer un mejor servicio y evitar los conflictos con otras formas de transporte o con los peatones, que generan una imagen negativa del sistema. En la búsqueda de estas soluciones, las empresas tienen la ventaja de disponer de información espacial y temporal muy precisa, así como de la oferta y la demanda de viajes. Estos datos pueden utilizarse en un *SIG* para buscar las mejores ubicaciones de las plazas de aparcamiento y evaluar posibles escenarios futuros.

El tercer ejemplo de aplicación práctica se desarrolla con los datos GPS de los eventos atendidos por el SAMUR-PC, aplicando un modelo de localización-asignación para encontrar la ubicación óptima de las estaciones donde permanecen las ambulancias. Esto con el fin de atender a la población en caso de emergencias causadas por accidentes de tráfico, accidentes no relacionados con el tráfico, enfermedades, entre otros.

En el planteamiento del modelo con los datos ofrecidos por el servicio de emergencias; primero, se presenta un análisis espacio-temporal de los sucesos asistidos por el SAMUR-PC, antes y durante la pandemia producida por la COVID-19. Al mismo

tiempo, se evalúa la localización de las actuales bases del sistema de emergencias de Madrid y se propone aumentar el número de estaciones mediante modelos de localización-asignación. A diferencia de trabajos anteriores, se han incorporado las condiciones del tráfico en la red utilizando datos históricos de TomTom y se toman en cuenta los cambios en la distribución de la demanda a lo largo del día. Para ello se ha contado con datos recogidos de GPS, que registran la fecha y hora en que se produjeron los sucesos atendidos por el SAMUR-PC.

El uso de los datos recogidos por SAMUR-PC permitió evaluar la cobertura de las estaciones de la red de SAMUR-PC entre los años 2019 – 2020, y contrastar la funcionalidad del servicio antes y durante la COVID-19. A diferencia de otros estudios, esta investigación propone una perspectiva dinámica analizando las diferencias entre días laborables y fines de semana y fraccionando la demanda en franjas horarias para analizar la distribución en diferentes momentos de los días laborables y los fines de semana del 2019, frente a 2020.

SAMUR-PC dispone de información precisa, desde el punto de vista espacial y temporal, sobre la fecha, la hora y la distribución de los sucesos atendidos. Con estos datos es posible entender la potencial distribución futura de los sucesos y, por lo tanto, proponer modelos de localización-asignación para encontrar la ubicación de nuevas estaciones que respondan a la futura demanda. La metodología propuesta es de interés para la administración pública y los gestores de los servicios médicos de emergencia, pues permite proponer ampliaciones en el número de puestos y ofrecer un mejor servicio a los ciudadanos. Además, ha permitido evaluar el funcionamiento del servicio en momentos de crisis epidémicas o ambientales.

Por otra parte, aunque no han sido usadas en la tesis, es importante señalar la existencia de otras fuentes de *datos* útiles para estimar la distribución de la demanda durante el día. Figuran entre ellas los datos de los teléfonos móviles, las tarjetas de crédito, registros GPS procedentes de las redes sociales, de recogida y entrega de pasajeros de los taxis, de los sistemas de reparto y un largo etcétera. También existen algunos datos que permiten incluir el dinamismo en la red, como por ejemplo Waze, Google Map y Here. En consecuencia, esto puede dar lugar a nuevas líneas de investigación y aplicación de MLA con componente temporal. Son muchas las aplicaciones prácticas que se pueden realizar con el uso de *Big Data*, en actividades de geomarketing y la localización de servicios públicos y privados.

En definitiva, la integración de *las nuevas fuentes de datos* con los SIG da lugar a que surjan nuevas perspectivas dinámicas sobre los insumos utilizados en los modelos tradicionales de localización-asignación, que se apoyaban en una demanda y una red estática. Con la aparición del Big Data, podemos aprovechar su alta resolución temporal y espacial para proponer modelos que consideren el dinamismo de la oferta, la demanda y la red.

## **5.2 Conclusiones en relación con la pregunta principal de la tesis**

*¿Es posible incorporar la dinámica urbana a los modelos de localización-asignación de los servicios a partir de fuentes Big Data?*

Dentro de las ciudades se producen interacciones entre los habitantes y las distintas instalaciones y servicios. Estas interacciones permiten identificar las zonas con una vitalidad más notable durante el día, es decir, aquellas con una presencia humana más intensa. Esta presencia permite inferir la localización de la demanda potencial de nuevos servicios y equipamientos. Los MLA deben servir para encontrar la mejor ubicación de instalaciones requeridas por la población considerando también esos cambios en la distribución diaria de la demanda.

En el desarrollo de esta tesis hemos propuesto incorporar la dinámica urbana a los modelos de localización-asignación, utilizando fuentes de *Big Data*. Estas fuentes permiten proponer modelos en los que se incluyen variables temporales, en la demanda y en la red de transporte, para determinar sus variaciones a lo largo del día. Los modelos de localización-asignación han sido implementados durante años. Sin embargo, raramente han considerado, entre sus parámetros, el uso de datos que permitieran incluir los cambios que experimenta la población durante el día y lo mismo ocurría con la red de transporte. Estas limitaciones se debían a la escasa disponibilidad de datos, ya que solo se contaba con los datos procedentes de las estadísticas oficiales, que carecían de una alta resolución temporal y espacial.

Los modelos de localización-asignación presentados en la tesis han permitido proponer este nuevo enfoque temporal. Ese es el principal aporte de esta tesis. En primer lugar, se consideró el uso de nuevas fuentes de datos para conocer la localización aproximada de la demanda y sus cambios a lo largo del día. En segundo lugar, se contemplan las redes de transporte público y privado con información que permite entender su comportamiento temporal y espacial. En consecuencia, el interés

del presente trabajo radica en aprovechar las oportunidades que ofrecen las fuentes de *Big Data* para desarrollar modelos de localización-asignación que contemplen el hecho de que la demanda y la red cambian en el tiempo y en el espacio geográfico. Esta metodología ha permitido lograr una aproximación, más realista, en función del comportamiento de la población y sus modos de desplazamiento en transporte público y coche privado.

A diferencia de otros estudios, en los que utilizaban como demanda la población de fuentes oficiales como los censos, que representan la localización residencial de la población, en nuestra propuesta ajustamos los cambios en el emplazamiento de la población durante el día. Además, los modelos anteriores utilizaban redes estáticas, empleando los datos de longitud de los ejes de las calles o de tiempos medios o en flujo libre de desplazamiento para el coche. Muy pocas veces se ha trabajado con redes de transporte público. Actualmente, gracias al *Big Data*, se pueden construir redes de transporte público que contengan el detalle de las frecuencias de los distintos medios de transporte.

El objetivo general que se planteaba al inicio de la tesis, de incorporar *nuevos datos* geolocalizados en los modelos de localización óptima de servicios de entornos SIG, para realizar análisis dinámicos de la localización de la demanda y funcionamiento de las redes de transporte podemos señalar que se ha cumplido. Para localizar la presencia cambiante de la demanda de determinados servicios durante el día se han utilizado los datos GPS de los desplazamientos realizados por los usuarios de las motocicletas pertenecientes a la empresa Muving y las coordenadas de los sucesos a los que ha atendido el SAMUR-PC durante 2019-2020. Por otro lado, utilizamos archivos GTFS y perfiles de tráfico históricos almacenados por navegadores pertenecientes a la empresa TomTom para implementar el dinamismo de las redes. Definitivamente, las fuentes de datos procedentes del llamado *Big Data* Geolocalizado tiene un enorme potencial para desarrollar investigaciones innovadoras en el campo de la Geografía, ya que permite obtener un alto nivel de detalle espacial y temporal, que ayuda a conocer en qué parte de la ciudad se concentra, habitualmente, la población durante el día.

Sin embargo, los registros procedentes del *Big Data* tienen limitaciones y problemas, también en la incorporación a los modelos de localización-asignación. Estas limitaciones han sido identificadas en la literatura previa. Tienen que ver, en primer

lugar, muchas de estas fuentes están en manos de empresas privadas, lo que dificulta su acceso. En segundo lugar, estos datos vienen en diferentes formatos y estructuras, presentando problemas como la pérdida de datos por fallos en los dispositivos de captura. Además, debido al gran volumen de datos, se requieren técnicas de programación para limpiar los datos correctamente. Cabe destacar que, con la aparición del *Big Data*, surgen nuevos retos que los estudiosos de la Geografía deben afrontar. Por ejemplo, necesitan aprender otras técnicas y habilidades para manipular, procesar y analizar correctamente los datos.

Los resultados obtenidos en los casos de estudio planteados en la tesis, concluyen que el uso de las nuevas fuentes de datos permite una mejor aproximación al comportamiento de la demanda y su desplazamiento por la red de transporte público y privado. De este modo se da respuesta a la pregunta de investigación planteada en este trabajo, que consistía en incorporar la dinámica urbana de la población en los modelos de localización a partir de fuentes *Big Data*.

### **5.3 Futuras líneas de investigación**

El uso de nuevas fuentes de datos, asociadas al desarrollo del *Big Data*, para el análisis de la demanda y el comportamiento de la red como parámetros de los modelos de localización-asignación resulta un campo poco explorado todavía. Durante el desarrollo de la tesis, nos hemos encontrado con ciertas limitaciones, además del surgimiento de nuevas líneas de investigación que no estaban previstas dentro del estudio. En este sentido, se comienza a explicar las líneas de investigación que puedan surgir a partir de cada uno de los casos de estudio que desarrollamos en el trabajo de investigación.

En el caso de los hospitales y centros comerciales, se pueden diseñar modelos a partir de otro tipo de redes de transporte como Here, Google Map y Waze para establecer comparaciones con los resultados de los modelos desarrollados en esta tesis a partir de archivos TomTom y GTFS. El modelo de localización-asignación realizado con hospitales puede incluir información sobre el número de pacientes atendidos o la disponibilidad de camas por centro hospitalario, lo que permitiría ajustar la demanda, en función de la capacidad de atención que tengan los hospitales. En el caso de los centros comerciales, las nuevas investigaciones pueden incluir datos sobre el consumo, la clientela, el número de aparcamientos y utilizarlos como atributos para

ponderar el grado de atractivo y capacidad de atracción de los centros. Además, la metodología utilizada, en este modelo, puede replicarse a otro tipo de negocios como: restaurantes, todo tipo de tiendas, farmacias, etc. Un elemento no explorado en la tesis fue la dinámica temporal en los horarios de apertura del servicio. De esta manera, sería de gran interés estudiar cómo afecta a la demanda atendida diferentes propuestas de horarios de apertura y cierre, y como adaptar los mismos a la demanda asignada en los modelos.

Por otro lado, el modelo de localización-asignación para encontrar plazas de aparcamiento, puede enriquecerse con la introducción de otras variables espaciales y socioeconómicas que permitan conocer la distribución de la demanda más ajustada a la realidad. Además, se pueden utilizar datos de otras empresas de movilidad compartida para establecer comparaciones con los resultados presentados en la tesis. También, se puede investigar con otros servicios de movilidad como patinetes eléctricos, las bicicletas compartidas sin base permanente y los puntos de recarga eléctrica para estos vehículos. Otro estudio interesante podría ser la construcción de modelos predictivos con técnicas de *machine learning* que permitan predecir la demanda futura de servicios de movilidad.

En particular, el caso de las estaciones de SAMUR-PC puede dar lugar a nuevas investigaciones, con otros tipos de servicios de emergencia y seguridad, como las estaciones de bomberos o de policía. Asimismo, proponer modelos predictivos empleando series espacio-temporales para hacer una aproximación a la distribución de los eventos atendidos por el servicio de emergencias. Es posible complementar este modelo, con otras fuentes de datos, para determinar la localización de la demanda durante el día, por ejemplo, el uso de redes sociales geolocalizadas, telefonía móvil, tarjetas de crédito y transporte, entre otras.

Por último, durante el desarrollo de la tesis se presentaron algunas limitaciones, especialmente, en la obtención de los datos. Al ser propiedad de empresas que, por lo general no los comparten con el público, por la información sensible que contienen sobre los usuarios, la cual podría violar la normativa de protección de datos en España. Dada esta circunstancia, los datos se agregaron a nivel de polígono para evitar revelar el comportamiento de cada usuario.

En resumen, las nuevas fuentes de datos asociadas al *Big Data* abren un abanico de oportunidades de investigación para incorporar variables dinámicas espacio-temporales en los cambios que experimenta la distribución diaria de la población y el comportamiento de la red de transporte público y privado. Estas variables dinámicas han permitido el desarrollo de modelos de localización-asignación donde se probaron diversas alternativas en los parámetros de los modelos. Así, se han desarrollado modelos, donde la demanda era estática y la red era dinámica (caso de hospitales y centros comerciales). En otros casos, la demanda era dinámica y la red, estática (caso de motos). También realizamos un modelo en el que los tres elementos (oferta, demanda y red) eran dinámicos durante el día (caso SAMUR\_PC).

# REFERENCIAS

- Abdelkarim, A. (2019). Integration of location-allocation and accessibility models in GIS to improve urban planning for health services in Al-Madinah Al-Munawwarah , Saudi Arabia. *Journal of Geographic Information System*, 11, 633-662. <https://doi.org/10.4236/jgis.2019.116039>
- Acar, M., & Kaya, O. (2019). A healthcare network design model with mobile hospitals for disaster preparedness : A case study for Istanbul earthquake. *Transportation Research Part E*, 130, 273-292. <https://doi.org/10.1016/j.tre.2019.09.007>
- Ahmad, A., Elsamen, A., & Ibrahim, R. (2017). Beyond the random location of shopping malls: A GIS perspective in Amman, Jordan Amjad. *Journal of Retailing and Consumer Services*, 34, 30-37. <https://doi.org/10.1016/j.jretconser.2016.09.006>
- Ahmadi, Z., & Ghezavati, V. (2020). Developing a new model for a competitive facility location problem considering sustainability using Markov chains. *Journal of Cleaner Production*, 273, 122971. <https://doi.org/10.1016/j.jclepro.2020.122971>
- Ajebon, M. O., & Asikhia, M. O. (2013). Geographical Analysis of Smoking in Leeds: A GIS-Based Location-Allocation Technique for the Optimal Location of Smoking Cessation Services. *Journal of Geographic Information System*, 5(3), 269-280. <https://doi.org/10.4236/jgis.2013.53026>
- Al-Sabbagh, T. A. (2020). GIS location-allocation models in improving accessibility to primary schools in Mansura city-Egypt. *GeoJournal*, 5. <https://doi.org/10.1007/s10708-020-10290-5>
- Algharib, S. (2011). *Distance and coverage: un assessment of location-allocation models for fire stations in Kuwait* [Kent State University]. [http://rave.ohiolink.edu/etdc/view?acc\\_num=kent1310950444](http://rave.ohiolink.edu/etdc/view?acc_num=kent1310950444)
- Alhothali, A., Alwated, B., Faisal, K., Alshammari, S., Alotaibi, R., Alghanmi, N., Bamasag, O., & Bin Yamin, M. (2022). Location-Allocation Model to Improve the Distribution of COVID-19 Vaccine Centers in Jeddah City, Saudi Arabia. *International journal of environmental research and public health*, 19(14), 1-21. <https://doi.org/10.3390/ijerph19148755>

- Ali, H. M. S., Arshad, M. J., & Sumra, I. A. (2019). 7 , Vs of Big Data : A Survey. *Engineering Science and Technology International Research Journal*, 3(4), 74-79. <http://www.estirj.com/Volume.3/No.4/12Sohaib34.pdf>
- Alonso, A. B. (2016). Optimal Location of Solid Waste Containers in Alcala De Henares. *M+a-Revista Electronica De Medio Ambiente*, 17(1), 1-23. <https://doi.org/10.5209/MARE..53155>
- Alonso, W. (1971). Equity and Its Relation to Efficiency in Urbanization. En J. F. Kain & J. R. Meyer (Eds.), *Essays in Regional Economics* (pp. 40-57). Harvard University Press. <https://doi.org/doi:10.4159/harvard.9780674593107.c4>
- Amato, S. S., Benson, J. S., Murphy, S., Osler, T. M., Hosmer, D., Cook, A. D., Wolfson, D. L., Erb, A., Malhotra, A., & An, G. (2021). Geographic Coverage and Verification of Trauma Centers in a Rural State: Highlighting the Utility of Location Allocation for Trauma System Planning. *Journal of the American College of Surgeons*, 232(1), 1-7. <https://doi.org/10.1016/j.jamcollsurg.2020.08.765>
- Antrim, A., & Barbeau, S. J. (2013). The Many Uses of GTFS Data - Opening the Door Transit and Multimodal Application. *Location-Aware Information Systems Laboratory at the University of South Florida*, 1-24. <https://doi.org/10.1.1.391.5421>
- Aparicio, D., Hernández Martín-Caro, M. S., García-Palomares, J. C., & Gutiérrez, J. (2021). Exploring the spatial patterns of visitor expenditure in cities using bank card transactions data. *Current Issues in Tourism*, 25(17), 2770-2788. <https://doi.org/https://doi.org/10.1080/13683500.2021.1991898>
- Archer, J., Hennessey, D., Hirsch, M., & Goff, A. (2019). Beyond Transit Deserts : Using Public Data to Inform Dockless Scooter Deployment and Reduce the Access Barrier. *TexITE Technical Paper Award*. [https://www.texite.org/wp-content/uploads/papers/Tech\\_Paper\\_Jackson\\_Archer.pdf](https://www.texite.org/wp-content/uploads/papers/Tech_Paper_Jackson_Archer.pdf)
- Arias-Molinares, D., & Carlos García-Palomares, J. (2020). Shared mobility development as key for prompting mobility as a service (MaaS) in urban areas: The case of Madrid. *Case Studies on Transport Policy*, 8(3), 846-859. <https://doi.org/10.1016/j.cstp.2020.05.017>
- Arias-Molinares, D., Romanillos, G., García-Palomares, J. C., & Gutiérrez, J. (2021). Exploring the spatio-temporal dynamics of moped-style scooter sharing services

- in urban areas. *Journal of Transport Geography*, 96.  
<https://doi.org/10.1016/j.jtrangeo.2021.103193>
- Arroub, A., Zahi, B., Sabir, E., & Sadik, M. (2016). A literature review on Smart Cities: Paradigms, opportunities and open problems. *Proceedings - 2016 International Conference on Wireless Networks and Mobile Communications, WINCOM 2016: Green Communications and Networking, October*, 180-186.  
<https://doi.org/10.1109/WINCOM.2016.7777211>
- Arturo Blanco, A. (2016). Optimal Location of Solid Waste Containers in Alcala De Henares. *M+a-Revista Electronica De Medio Ambiente*, 17(1), 1-23.  
<https://doi.org/10.5209/MARE..53155>
- Asare-Akuffo, F., Twumasi-Boakye, R., Appiah-Opoku, S., & Sobanjo, J. O. (2020). Spatial accessibility to hospital facilities: the case of Kumasi, Ghana. *African Geographical Review*, 39(2), 120-133.  
<https://doi.org/10.1080/19376812.2019.1636667>
- Austin, C. M. (1974). The Evaluation of Urban Public Facility Location: An Alternative to Benefit-Cost Analysis. *Geographical Analysis*, 6(2), 135-145.  
<https://doi.org/10.1111/j.1538-4632.1974.tb00503.x>
- Ayuntamiento de Madrid. (2020a). *Madrid economía 2020: análisis socio-económico*.  
<https://www.madrid.es/UnidadesDescentralizadas/UDCObservEconomico/009MadridEconomia/Ficheros/002FicherosMadridEconomía2020/MadridEconomía2020.pdf>
- Ayuntamiento de Madrid. (2020b). *Oficina de apoyo a las áreas de actividad económica*.  
[https://economia.madrid.es/FWProjects/economia/contenidos/Ficheros/UR5463-SR-UR-Distritos\\_20200428.pdf](https://economia.madrid.es/FWProjects/economia/contenidos/Ficheros/UR5463-SR-UR-Distritos_20200428.pdf)
- Ayuntamiento de Madrid. (2020c, septiembre 2). *Estado de la movilidad de la ciudad de Madrid*.  
<https://transparencia.madrid.es/FWProjects/transparencia/Movilidad/Trafico/InformesMovilidad/Ficheros/InformeMovilidad2020.pdf>
- Ayuntamiento de Madrid. (2020d, septiembre 5). *Accidentes de tráfico*. Accidentes y víctimas de tráfico urbano por Día de la semana y Hora de ocurrencia.

<https://www.madrid.es/portales/munimadrid/es/Inicio/El-Ayuntamiento/Estadistica/Areas-de-informacion-estadistica/Trafico-transportes-y-comunicaciones/Accidentes-de-trafico/Accidentes-de-trafico/?vgnnextfmt=default&vgnnextoid=d3a67e6f34969210VgnVCM2000000c20>

Ayuntamiento de Madrid. (2022, septiembre 1). *Accidentes de tráfico*. Distritos en cifras. <https://www.madrid.es/portales/munimadrid/es/Inicio/El-Ayuntamiento/Estadistica/Distritos-en-cifras/Distritos-en-cifras-Informacion-de-Barrios>

Azarmand, Z., & Neishabouri, E. (2009). Location allocation problem. En Hekmatfar H. & R. Farahani (Eds.), *Facility Location: Concepts, Models, Algorithms and Case Studies, Contributions to Management Science* (Número 2001, p. 464). <https://doi.org/10.1007/978-3-7908-2151-2>

Azimi, A., Bagheri, N., Mostafavi, S. M., Furst, M. A., Hashtarkhani, S., Amin, F. H., Eslami, S., Kiani, F., VafaeiNezhad, R., Akbari, T., Golabpour, A., & Kiani, B. (2021). Spatial-time analysis of cardiovascular emergency medical requests: enlightening policy and practice. *BMC Public Health*, 21(1), 1-12. <https://doi.org/10.1186/s12889-020-10064-1>

Azizan, M. H., Lim, C. S., Hatta, W. A., Lutfi, W. M., & Gan, L. C. (2012). Application of OpenStreetMap data in ambulance location problem. *Proceedings - 2012 4th International Conference on Computational Intelligence, Communication Systems and Networks, CICSyN 2012*, 321-325. <https://doi.org/10.1109/CICSyN.2012.66>

Baek, K., Lee, H., Chung, J. H., & Kim, J. (2021). Electric scooter sharing: How do people value it as a last-mile transportation mode? *Transportation Research Part D: Transport and Environment*, 90, 102642. <https://doi.org/10.1016/j.trd.2020.102642>

Bahadori, M. S., Gonçalves, A. B., & Moura, F. (2021). A systematic review of station location techniques for bicycle-sharing systems planning and operation. *ISPRS International Journal of Geo-Information*, 10(8), 554. <https://doi.org/10.3390/ijgi10080554>

Bai, S., & Jiao, J. (2020). Dockless E-scooter usage patterns and urban built Environments: A comparison study of Austin, TX, and Minneapolis, MN. *Travel Behaviour and Society*, 20, 264-272. <https://doi.org/10.1016/j.tbs.2020.04.005>

- Banerjee, S., Kabir, M. M., Khadem, N. K., & Chavis, C. (2020). Optimal locations for bikeshare stations: A new GIS based spatial approach. *Transportation Research Interdisciplinary Perspectives*, 4, 100101. <https://doi.org/10.1016/j.trip.2020.100101>
- Barros, C., Moya-Gómez, B., & Gutiérrez, J. (2019). Using geotagged photographs and GPS tracks from social networks to analyse visitor behaviour in national parks. *Current Issues in Tourism*, 23(10), 1291-1310. <https://doi.org/10.1080/13683500.2019.1619674>
- Batty, M. (2013). Big data, smart cities and city planning. *Dialogues in human geography*, 3(3), 274-279. <https://doi.org/10.1177/2043820613513390>
- Becker, R. A., Cáceres, R., Hanson, K. J., Isaacman, S., Loh, J. M., Martonosi, M., Rowland, J., Urbanek, S., Varshavsky, A., & Volinsky, C. (2013). Human mobility characterization from cellular network data. *Communications of the ACM*, 56(1), 74. <https://doi.org/10.1145/2398356.2398375>
- Beheshtifar, S., & Alimoahmadi, A. (2015). A multiobjective optimization approach for location-allocation of clinics. *International Transactions in Operational Research*, 22(2), 313-328. <https://doi.org/10.1111/itor.12088>
- Bell, D., Ho, T., & Tang, C. (1998). Determining where to Shop: fixed and Variable Costs of Shopping. *Journal of Marketing Research*, 35(3), 352-369. <https://doi.org/https://doi.org/10.1177/002224379803500>
- Bennett, R. J. (1983). Individual and Territorial Equity. *Geographical Analysis*, 15(1), 50-57. <https://doi.org/10.1111/j.1538-4632.1983.tb00763.x>
- Berman, O., Hajizadeh, I., Krass, D., & Rahimi-Vahed, A. (2018). Reconfiguring a set of coverage-providing facilities under travel time uncertainty. *Socio-Economic Planning Sciences*, 62, 1-12. <https://doi.org/10.1016/j.seps.2017.05.002>
- Berry, J., Hart, W. E., Phillips, C. A., Uber, J. G., & Watson, J. P. (2016). Sensor Placement in Municipal Water Networks with Temporal Integer Programming Models. *Water Resources Planning and Management*, 132(4), 218-224. [https://doi.org/10.1061/\(ASCE\)0733-9496\(2006\)132](https://doi.org/10.1061/(ASCE)0733-9496(2006)132)
- Bok, J., & Kwon, Y. (2016). Comparable measures of accessibility to public transport using the general transit feed specification. *Sustainability (Switzerland)*, 8(3).

<https://doi.org/10.3390/su8030224>

- Bolouri Arabani, A., & Farahani, R. Z. (2012). Facility location dynamics: An overview of classifications and applications. *Computers and Industrial Engineering*, 62(1), 408-420. <https://doi.org/10.1016/j.cie.2011.09.018>
- Bolouri, S., Vafaeinejad, A., Alesheikh, A. A., & Aghamohammadi, H. (2018). The ordered capacitated multi-objective location-allocation problem for fire stations using spatial optimization. *ISPRS International Journal of Geo-Information*, 7(2). <https://doi.org/10.3390/ijgi7020044>
- Bolouri, S., Vafaeinejad, A., Alesheikh, A., & Aghamohammadi, H. (2020). Minimizing response time to accidents in big cities: a two ranked level model for allocating fire stations. *Arabian Journal of Geosciences*, 13(16). <https://doi.org/10.1007/s12517-020-05728-6>
- Bose, P., & Wang, Q. (2002). Facility location constrained to a polygonal domain. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2286, 153-164. [https://doi.org/10.1007/3-540-45995-2\\_18](https://doi.org/10.1007/3-540-45995-2_18)
- Bosque, J., Moreno, A., Fuenzalida, M., & Gómez, M. G. (2012). *Sistemas de información geográfica y localización óptima de instalaciones y equipamientos* (2da ed.). Ra-Ma S.A.
- Bosque Sendra, J., & Franco Maass, S. (1995). Modelos de localización-asignación y evaluación multicriterio para la localización de instalaciones no deseables. *Serie Geográfica*, 5(1), 97-112. [www.researchgate.net/profile/Joaquin-Bosque-Sendra/publication](http://www.researchgate.net/profile/Joaquin-Bosque-Sendra/publication)
- Bosque Sendra, J., Gómez Delgado, M., Moreno Jiménez, A., & dal Pozzo, F. (2000). Hacia un sistema de ayuda a la decisión espacial para la localización de equipamientos. *Estudios Geograficos*, 241, 567-598. <https://doi.org/10.3989/egeogr.2000.i241.542>
- Boyd, D. M., & Ellison, N. B. (2007). Social network sites: Definition, history, and scholarship. *Journal of Computer-Mediated Communication*, 13(1), 210-230. <https://doi.org/10.1111/j.1083-6101.2007.00393.x>
- Brandeau, M. ., & Chiu, S. S. . (1989). An Overview of Representative Problems in

Location Research. *Management Science*, 35(6), 645-674.  
<https://doi.org/https://doi.org/10.1287/mnsc.35.6.645>

Brimberg, J., & Juel, H. (1998). A bicriteria model for locating a semi-desirable facility in the plane. *European Journal of Operational Research*, 106(1), 144-151.  
[https://doi.org/10.1016/S0377-2217\(97\)00251-8](https://doi.org/10.1016/S0377-2217(97)00251-8)

Buzai, G., & Baxandale, C. (1995). Modelos de localización-asignación aplicados a servicios públicos urbanos: análisis espacial de centros de atención primaria de Salud (CAPS) en la ciudad e Luján, Argentina. *Cuadernos De Geografía | Revista Colombiana De Geografía*, 20(2), 109-123.  
<https://doi.org/http://www.uacm.kirj.redalyc.redalyc.org/articulo.oa?id=281821988009>

Cabral, E. L. D. S., Castro, W. R. S., Florentino, D. R. de M., Viana, D. de A., da Costa Junior, J. F., de Souza, R. P., Rêgo, A. C. M., Araújo-Filho, I., & Medeiros, A. C. (2018). Response time in the emergency services. Systematic review. *Acta Cirurgica Brasileira*, 33(12), 1110-1121. <https://doi.org/10.1590/s0102-865020180120000009>

Calabrese, F., Ferrari, L., & Blondel, V. D. (2014). Urban Sensing Using Mobile Phone Network Data: A Survey of Research. *ACM Computing Surveys*, 47(2).  
<https://doi.org/10.1145/2655691>

Cao, K., Li, W., & Church, R. (2020). Big data, spatial optimization, and planning. *Environment and Planning B: Urban Analytics and City Science*, 47(6), 941-947.  
<https://doi.org/10.1177/2399808320935269>

Caprara, A., Toth, P., & Fischetti, M. (2000). Algorithms for the Set Covering Problem. *Annals of Operations Research*, 98(1-4), 353-371.  
<https://doi.org/10.1023/a:1019225027893>

Carpenter, J., & Snell, J. (2013). Future trends in geospatial information management: the five to ten year vision. En *United Nations Initiative on Global Geospatial information Management*. <https://ggim.un.org/documents/Future-trends.pdf>

Carpio-Pinedo, J., Romanillos, G., Aparicio, D., Martín-Caro, M. S. H., García-Palomares, J. C., & Gutiérrez, J. (2022). Towards a new urban geography of expenditure: Using bank card transactions data to analyze multi-sector

spatiotemporal distributions. *Cities*, 131.  
<https://doi.org/10.1016/j.cities.2022.103894>

Cebecauer, M., & Buzna, L. (2018). Large-scale test data set for location problems. *Data in Brief*, 17, 267-274. <https://doi.org/10.1016/j.dib.2018.01.008>

Chen, B. Y., Yuan, H., Li, Q., Shaw, S. L., Lam, W. H. K., & Chen, X. (2016). Spatiotemporal data model for network time geographic analysis in the era of big data. *International Journal of Geographical Information Science*, 30(6), 1041-1071. <https://doi.org/10.1080/13658816.2015.1104317>

Chen, E., & Ye, Z. (2021). Identifying the nonlinear relationship between free-floating bike sharing usage and built environment. *Journal of Cleaner Production*, 280, 124281. <https://doi.org/10.1016/j.jclepro.2020.124281>

Chen, Y., Qian, H., & Wang, Y. (2020). Analysis of Beijing's working population based on geographically weighted regression model. *Sustainability (Switzerland)*, 12(12), 5018. <https://doi.org/10.3390/su12125018>

Chen, Y. W., Cheng, C. Y., Li, S. F., & Yu, C. H. (2018). Location optimization for multiple types of charging stations for electric scooters. *Applied Soft Computing Journal*, 67, 519-528. <https://doi.org/10.1016/j.asoc.2018.02.038>

Chen, Y., Zhang, Z., & Liang, T. (2019). Assessing urban travel patterns: An analysis of traffic analysis zone-based mobility patterns. *Sustainability (Switzerland)*, 11(19). <https://doi.org/10.3390/su11195452>

Cheng, E. W. L., Li, H., & Yu, L. (2007). A GIS approach to shopping mall location selection. *Building and Environment*, 42(2), 884-892. <https://doi.org/10.1016/j.buildenv.2005.10.010>

Choujaa, D., & Dulay, N. (2009). Activity Recognition from Mobile Phone Data: State of the Art, Prospects and Open Problems. *Imperial College London*, V, 1-32. [www.cityware.org.uk](http://www.cityware.org.uk)

Chua, A., Servillo, L., Marcheggiani, E., & Moere, A. Vande. (2016). Mapping Cilento: Using geotagged social media data to characterize tourist flows in southern Italy. *Tourism Management*, 57, 295-310. <https://doi.org/10.1016/j.tourman.2016.06.013>

Chuang, C. L., & Lin, R. H. (2007). A maximum expected covering model for an

- ambulance location problem. *Journal of the Chinese Institute of Industrial Engineers*, 24(6), 468-474. <https://doi.org/10.1080/10170660709509061>
- Chukwuma, E. C. (2019). Facility location allocation modelling for bio-energy system in Anambra State of Nigeria: Integration of GIS and location model. *Renewable Energy*, 141, 460-467. <https://doi.org/10.1016/j.renene.2019.04.022>
- Chukwusa, E., & Comber, A. (2018). The Impact of Residential and Non-Residential Demand on Location-Allocation Decision-Making: A Case Study of Modelling Suitable Locations for EMS in Leicester and Leicestershire, England UK. *Journal of Geographic Information System*, 10(04), 381-397. <https://doi.org/10.4236/jgis.2018.104020>
- Chung, C. H., Schilling, D. A., & Carbone, R. (1983). The capacitated maximal covering problem: a heuristic solution. *Modeling and Simulation*, 14, 1383-1388.
- Church, R. (1999). Location modelling and GIS. En *Geographical Information Systems 2nd Edition*. [https://www.geos.ed.ac.uk/~gisteac/gis\\_book\\_abridged/files/ch20.pdf](https://www.geos.ed.ac.uk/~gisteac/gis_book_abridged/files/ch20.pdf)
- Church, R. L., & Drezner, Z. (2022). Review of obnoxious facilities location problems. *Computers and Operations Research*, 138, 105468. <https://doi.org/10.1016/j.cor.2021.105468>
- Church, R. L., & Murray, A. T. (2009). *Business Site Selection Location analysis, and GIS* (pp. 209-233). Hoboken, NJ: John Wiley & Sons.
- Church, R. L., & Murray, Aja. (2018). Location Covering Models. *Advances in Spatial Science*, 271. <https://doi.org/https://doi.org/10.1007/978-3-319-99846-6>
- Church, R. L., & Sorensen, P. (1996). Integrating normative location models into GIS: problems and prospects with the p-median model. En *Spatial Analysis: Modelling in a GIS Environment* (pp. 168-183).
- Church, R., & ReVelle, C. (1974). The maximal covering location problem. *Papers of the Regional Science Association*, 32(1), 101-118. <https://doi.org/10.1007/BF01942293>
- Clemence, V., Malcolm, C., & Simon, K. (2020). Pathways to urban health and well-being: measuring and modelling of community services in a medium size city. *Geospatial Health*, 15(808).

- Comas, D., & Ruiz, E. (1993). *Fundamentos de los sistemas de información geográfica*. Ariel.
- Comber, A., Dickie, J., Jarvis, C., Phillips, M., & Tansey, K. (2015). Locating bioenergy facilities using a modified GIS-based location-allocation-algorithm: Considering the spatial distribution of resource supply. *Applied Energy*, *154*, 309-316. <https://doi.org/10.1016/j.apenergy.2015.04.128>
- Condeço-Melhorado, A., Mohino, I., Moya-Gómez, B., & Palomares-García, J. C. (2020). The Rio Olympic Games : A Look into City Dynamics through the Lens of Twitter Data. *Sustainability*, *12*(7003), 16. <https://doi.org/10.3390/su12177003>
- Cooper, L. (1963). Location-Allocation Problems. *Operations Research*. <https://doi.org/10.1287/opre.11.3.331>
- Cordeau, J. F., Furini, F., & Ljubić, I. (2019). Benders decomposition for very large scale partial set covering and maximal covering location problems. *European Journal of Operational Research*, *275*(3), 882-896. <https://doi.org/10.1016/j.ejor.2018.12.021>
- Crompton, J., & Lamb, C. (1983). The Importance of the Equity Concept in the Allocation of Public Services. *The ANNALS of the American Academy of Political and Social Science*, *503*(1), 122-136.
- Culyer, A. J., & Wagstaff, A. (1993). Equity and equality in health and health care. *Journal of Health Economics*, *12*(4), 431-457. [https://doi.org/https://doi.org/10.1016/0167-6296\(93\)90004-X](https://doi.org/https://doi.org/10.1016/0167-6296(93)90004-X)
- Current, J. R., & Storbeck, J. E. (1988). Capacitated covering models. *Environment & Planning B: Planning & Design*, *15*(2), 153-163. <https://doi.org/10.1068/b150153>
- Current, J., & Schilling, D. (2002). Discrete Network Location Problems. En Z. Drezner & H. W. Hamacher (Eds.), *Facility Location; Applications and Theory*. Springer Science & Business Media. [http://fisher.osu.edu/~schilling\\_1/pub/ch3-DiscreteNetworkLocnModels.pdf](http://fisher.osu.edu/~schilling_1/pub/ch3-DiscreteNetworkLocnModels.pdf)
- Daniel, S., & Doran, M.-A. (2013). *geoSmartCity*. 65-71. <https://doi.org/10.1145/2479724.2479738>
- Daskin, M. S. (2008). What You Should Know About Location Modeling. *Naval Research Logistics*, *55*, 283-294. <https://doi.org/10.1002/nav.20284>

- Daskin, M. S. (2011). *Network and Discrete Location Models, Algorithms, and Applications* (2da ed.). John Wiley & Sons.
- Daskin, M. S., & Dean, L. K. (2004). Location of Health Care. *Operations Research and Health Care: A Handbook of Methods and Applications*, 43-76.
- De Cáceres, A. M., & De la Hoz, D. (2009). Efectos sobre la movilidad dinámica territorial de Madrid. *Urban*, 1(14), 58-71. <http://polired.upm.es/index.php/urban/article/view/307/309>
- Dear, M. (1978). Planning for Mental Health Care: A Reconsideration of Public Facility Location Theory. *International Regional Science Review*, 3(2), 93-111. <https://doi.org/10.1177/016001767800300201>
- Degele, J., Gorr, A., Haas, K., Kormann, D., Krauss, S., Lipinski, P., & Hertweck, D. (2018). *Identifying E-scooter sharing customer segments using clustering*. 1-8. <https://doi.org/10.1109/ICE.2018.8436288>
- Del Rivero, M. (2017). *Smart Cities: una visión para el ciudadano*. Editorial Almuzara.
- Dempsey, C. (2012, octubre 28). *Where is the Phrase "80% of Data is Geographic" From?* Gis Lounge. <https://www.gislounge.com/80-percent-data-is-geographic/>
- Deng, X., Liu, P., Liu, X., Wang, R., Zhang, Y., He, J., & Yao, Y. (2019). Geospatial Big Data: New Paradigm of Remote Sensing Applications. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(10), 3841-3851. <https://doi.org/10.1109/JSTARS.2019.2944952>
- Densham, P. (1991). Spatial Decision Support Systems. *Principles & Applications*, 1, 403-412. [https://doi.org/10.1016/S0967-0645\(02\)00022-X](https://doi.org/10.1016/S0967-0645(02)00022-X)
- DeVerteuil, G. (2000). Reconsidering the legacy of urban public facility location theory in human geography. *Progress in Human Geography*, 24(1), 47-69. <https://doi.org/10.1191/030913200668094045>
- Deville, P., Linard, C., Martin, S., Gilbert, M., Stevens, F. R., & Gaughan, A. E. (2014). *Dynamic population mapping using mobile phone data*. 111(45). <https://doi.org/10.1073/pnas.1408439111>
- Dibene, J. C., Maldonado, Y., Vera, C., de Oliveira, M., Trujillo, L., & Schütze, O. (2017). Optimizing the location of ambulances in Tijuana, Mexico. *Computers in*

*Biology and Medicine*, 80, 107-115.  
<https://doi.org/10.1016/j.combiomed.2016.11.016>

Dingil, A. E., Schweizer, J., Rupi, F., & Stasiskiene, Z. (2018). *Transport indicator analysis and comparison of 151 urban areas, based on open source data*. *European Transport Research Review*; *European Transport Research Review*.  
<https://doi.org/10.1186/s12544-018-0334-4>

Drezner, T. (2010). Cannibalization in a Competitive Environment. *International Regional Science Review*, 34(3), 306-322.  
<https://doi.org/10.1177/0160017610389328>

Drezner, T. (2011). Cannibalization in a competitive environment. *International Regional Science Review*, 34(3), 306-322.  
<https://doi.org/10.1177/0160017610389328>

Drezner, T., & Drezner, Z. (1996). Competitive facilities: Market share and location with random utility. *Journal of Regional Science*, 36(1), 1-15.  
<https://doi.org/10.1111/j.1467-9787.1996.tb01098.x>

Drezner, T., & Drezner, Z. (2002). Validating the gravity-based competitive location model using inferred attractiveness. En *Annals of Operations Research* (Vol. 111, Números 1-4, pp. 227-237). <https://doi.org/10.1023/A:1020910021280>

Drezner, Z. (1982). Competitive location strategies for two facilities. *Regional Science and Urban Economics*, 12(4), 485-493. [https://doi.org/10.1016/0166-0462\(82\)90003-5](https://doi.org/10.1016/0166-0462(82)90003-5)

Dumbliauskas, V., Grigonis, V., & Barauskas, A. (2017). Application of Google-based Data for Travel Time Analysis: Kaunas City Case Study. *PROMET - Traffic&Transportation*, 29(6), 613-621. <https://doi.org/10.7307/ptt.v29i6.2369>

Eaton, D. J., Daskin, M. S., Simmons, D., Bulloch, B., & Jansma, G. (1985). Determining emergency medical service vehicle deployment in Austin, Texas. *Interfaces*, 15(1), 96-108. <https://doi.org/10.1287/inte.15.1.96>

Ebert, A., Kerle, N., & Stein, A. (2009). Urban social vulnerability assessment with physical proxies and spatial metrics derived from air- and spaceborne imagery and GIS data. *Natural Hazards*, 48(2), 275-294. <https://doi.org/10.1007/s11069-008-9264-0>

- Eiselt, H. A., Laporte, G., & Thisse, J. F. (1993). Competitive location models: A framework and bibliography. *Transportation Science*, 27(1), 44-54. <https://doi.org/10.1287/trsc.27.1.44>
- Eiselt, Horst A. (1995). Objectives in location problems. *Facility location: a survey of applications and methods*.
- El-Hallaq, M. A., & Mosabeh, R. (2019). Optimization of Municipal Solid Waste Management of Bins Using GIS. A Case Study: Nuseirat City. *Journal of Geographic Information System*, 11(01), 32-43. <https://doi.org/10.4236/jgis.2019.111003>
- El Karim, A. A., & Awawdeh, M. M. (2020). Integrating GIS accessibility and location-allocation models with multicriteria decision analysis for evaluating quality of life in Buraidah city, KSA. *Sustainability (Switzerland)*, 12(4). <https://doi.org/10.3390/su12041412>
- Elkady, S. K., & Abdelsalam, H. M. (2015). A simulation-based optimization approach for healthcare facility location allocation decision. *Proceedings of the 2015 Science and Information Conference, SAI 2015*, 500-505. <https://doi.org/10.1109/SAI.2015.7237189>
- EMSWorld. (2004, abril 15). *EMS Response Time Standards*. <https://www.hmpgloballearningnetwork.com/site/emsworld/article/10324786/ems-response-time-standards>
- Enayati, S., Mayorga, M. E., Toro-Díaz, H., & Albert, L. A. (2019). Identifying trade-offs in equity and efficiency for simultaneously optimizing. *International Transactions in Operational Research*, 26, 415-438. <https://doi.org/10.1111/itor.12590>
- Erdoğan, G., Erkut, E., Ingolfsson, A., & Laporte, G. (2010). Scheduling ambulance crews for maximum coverage. *Journal of the Operational Research Society*, 61(4), 543-550. <https://doi.org/10.1057/jors.2008.163>
- Erfani, S. M. H., Danesh, S., Karrabi, S. M., Shad, R., & Nemati, S. (2018). Using applied operations research and geographical information systems to evaluate effective factors in storage service of municipal solid waste management systems. *Waste Management*, 79, 346-355. <https://doi.org/10.1016/j.wasman.2018.08.003>

- Erkut, E., & Neuman, S. (1989). Analytical models for locating undesirable facilities. *European Journal of Operational Research*, 40(3), 275-291. [https://doi.org/10.1016/0377-2217\(89\)90420-7](https://doi.org/10.1016/0377-2217(89)90420-7)
- Escobar Garcia, D. A., Zuluaga García, J. D., & Younes velosa, C. (2018). A GIS approach based on user location to evaluate a bike-sharing program. *Dyna*, 85(204), 257-263. <https://doi.org/10.15446/dyna.v85n204.67670>
- Fainstein, S. S. (2014). The just city. *International journal of urban Sciences*, 18(1), 1-18. <https://doi.org/https://doi.org/10.7591/9780801460487>
- Farahani, R. Z., Asgari, N., Heidari, N., Hosseiniinia, M., & Goh, M. (2012a). Covering problems in facility location: A review. *Computers and Industrial Engineering*, 62(1), 368-407. <https://doi.org/10.1016/j.cie.2011.08.020>
- Farahani, R. Z., Asgari, N., Heidari, N., Hosseiniinia, M., & Goh, M. (2012b). Covering problems in facility location: A review. En *Computers and Industrial Engineering* (Vol. 62, Número 1, pp. 368-407). Pergamon. <https://doi.org/10.1016/j.cie.2011.08.020>
- Farber, S., Morang, M. Z., & Widener, M. J. (2014). Temporal variability in transit-based accessibility to supermarkets. *Applied Geography*, 53, 149-159. <https://doi.org/10.1016/j.apgeog.2014.06.012>
- Fayyaz S., S. K., Liu, X. C., & Zhang, G. (2017). An efficient General Transit Feed Specification (GTFS) enabled algorithm for dynamic transit accessibility analysis. *PLoS ONE*, 12(10), 1-22. <https://doi.org/10.1371/journal.pone.0185333>
- Flahaut, B., Laurent, M. A., & Thomas, I. (2002). Locating a community recycling center within a residential area: A Belgian case study. *Professional Geographer*, 54(1), 67-82. <https://doi.org/10.1111/0033-0124.00316>
- Forsey, B. (2014). Using Location-Allocation Models to Aid in the Locating of Preventive Health Care Facilities for Newfoundland & Labrador. *Implementation Science*, 39(1), 1-15. <https://doi.org/10.4324/9781315853178>
- Fosso W., S., Akter, S., Edwards, A., Chopin, G., & Gnanzou, D. (2015). How «big data» can make big impact: Findings from a systematic review and a longitudinal case study. *International Journal of Production Economics*, 165, 234-246. <https://doi.org/10.1016/j.ijpe.2014.12.031>

- Fotheringham, A. S., Densham, P. J., & Curtis, A. (1995). The Zone Definition Problem in Location-Allocation Modeling. *Geographical Analysis*, 27(1), 60-77. <https://doi.org/10.1111/j.1538-4632.1995.tb00336.x>
- Frade, I., & Ribeiro, A. (2015). Bike-sharing stations: A maximal covering location approach. *Transportation Research Part A: Policy and Practice*, 82, 216-227. <https://doi.org/10.1016/j.tra.2015.09.014>
- Fredriksson, A., Sylvia, M., & Saes, M. (2019). *Analyzing the spatial distribution of public services: Political effects , misallocation and welfare . A method and evidence from Citizen Service Centers in Brazil*. <http://andersfredriksson.be/wp-content/uploads/2019/12/1912FredrikssonSaesAnalyzingTheSpatialDistributionOfPublicServices.pdf>
- Fuenzalida, M., & Moreno, A. (2010). Diseño con SIG de la localización óptima de centros de atención primaria de salud, discriminando según estatus socioeconómico. En J. Ojeda, M. F. , Pita, & I. Vallejo (Eds.), *Tecnologías de la Información Geográfica: La Información Geográfica al servicio de los ciudadanos* (pp. 453-465). Publicaciones de la Universidad de Sevilla. <https://repositorio.uam.es/bitstream/handle/10486/669118/dise%F1o.pdf?sequence=1>
- Gallego, C. Z., & Carrasco, J. S. (2018). Geolocalized tweets for assessing daily mobility: Methodology to analyse and detect homelocation in the urban area of Valencia. *Boletín de la Asociación de Geógrafos Españoles*, 2018(79). <https://doi.org/10.21138/bage.2464>
- Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137-144. <https://doi.org/10.1016/J.IJINFOMGT.2014.10.007>
- Gao, L., Ji, Y., Yan, X., Fan, Y., & Guo, W. (2020). Incentive measures to avoid the illegal parking of dockless shared bikes: the relationships among incentive forms, intensity and policy compliance. *Transportation*, 0123456789. <https://doi.org/10.1007/s11116-020-10088-x>
- Gao, X., Liu, L., Zhuang, J., Ou, D., Li, Q., Deng, O., Li, J., & Zeng, M. (2019). The commuting rural labour forces revealed by mobile phone trace data. *Environment and Planning A*, 51(8), 1611-1614. <https://doi.org/10.1177/0308518X18810874>

- García-Palomares, J. C., Gutierrez-Puebla, J., & Mínguez, C. (2015). Identification of tourist hot spots based on social networks: A comparative analysis of European metropolises using photo-sharing services and GIS. *Applied Geography*, 63, 408-417. <https://doi.org/10.1016/j.apgeog.2015.08.002>
- García-Palomares, J. C., Gutiérrez, J. J., & Latorre, M. (2012). Optimizing the location of stations in bike-sharing programs: A GIS approach. *Applied Geography*, 35(1-2), 235-246. <https://doi.org/10.1016/j.apgeog.2012.07.002>
- García-Palomares, J. C., Salas-Olmedo, M. H., Moya-Gómez, B., Condeço-Melhorado, A., & Gutiérrez, J. (2018). City dynamics through Twitter: Relationships between land use and spatiotemporal demographics. *Cities*, 72, 310-319. <https://doi.org/10.1016/j.cities.2017.09.007>
- García Palomares, J. C. (2007). *Movilidad laboral en la comunidad de Madrid [Tesis de doctorado, Universidad Complutense de Madrid]*. <https://eprints.ucm.es/7523/1/T29712.pdf>
- Ghahramani, M., Zhou, M., & Wang, G. (2020). Urban sensing based on mobile phone data: Approaches, applications, and challenges. *IEEE/CAA Journal of Automatica Sinica*, 7(3), 627-637. <https://doi.org/10.1109/JAS.2020.1003120>
- Ghosh, A., & Rushton, G. (1987). *Spatial analysis and location-allocation models.. Economic Geography*, 64(2), 196-198. <https://doi.org/10.2307/144127>
- Giffinger, R., Fertner, C., Kramar, H., Kalasek, R., Pichler-Milanovic, N., Meijers, E. (2007). Smart cities – Ranking of European medium-sized cities. Vienna, UT: Centre of Regional Science. From: (<http://www.smart-cities.eu>) Retrieved 18.12.22.
- Giménez-Gaydou, D. A., Ribeiro, A. S. N., Gutiérrez, J., & Antunes, A. P. (2016). Optimal location of battery electric vehicle charging stations in urban areas: A new approach. *International Journal of Sustainable Transportation*, 10(5), 393-405. <https://doi.org/10.1080/15568318.2014.961620>
- Gokalp, O. (2020). An iterated greedy algorithm for the obnoxious p-median problem. *Engineering Applications of Artificial Intelligence*, 92, 103674. <https://doi.org/10.1016/j.engappai.2020.103674>
- Goodchild, M. F. (1984). A Location-Allocation Model for Retail Site Selection. *Spring*,

60(1), 84-100.

- Goodchild, M. F. (2007). Citizens as Sensors: The World of Volunteered Geography. *GeoJournal*, 69(4), 211-221. <http://kfrichter.org/crowdsourcing-material/day1/goodchild07.pdf>
- Google COVID-19 Community Mobility Report. (2020, septiembre 2). *Informes de Movilidad Local*. Informe de Movilidad Local sobre el COVID-19. [https://www.gstatic.com/covid19/mobility/2022-08-28\\_ES\\_Community\\_of\\_Madrid\\_Mobility\\_Report\\_es.pdf](https://www.gstatic.com/covid19/mobility/2022-08-28_ES_Community_of_Madrid_Mobility_Report_es.pdf)
- Gordon, M. (1991). Equality measures and facility location. *Regional science association*, 4(70), 345-365.
- Graig, C. S. (1984). Models of the retail location process. *Journal of retailing*, 60(1), 5-36. <https://doi.org/https://doi.org/info:doi/>
- Guan, C. H., Song, J., Keith, M., Akiyama, Y., Shibasaki, R., & Sato, T. (2020). Delineating urban park catchment areas using mobile phone data: A case study of Tokyo. *Computers, Environment and Urban Systems*, 81(January), 101474. <https://doi.org/10.1016/j.compenvurbsys.2020.101474>
- Guo, Z., & Qi, M. (2014). Modeling and Simulation of Emergency Service Facilities Location Problem Under Fuzzy Environment. *The Open Mechanical Engineering Journal*, 8(1), 48-52. <https://doi.org/10.2174/1874155x01408010048>
- Gutierrez-Puebla, J., Benítez, C., García-Palomares, J.C. Romanillos-Arroyo, G. Rubinstein, E., Leño, M., Maia-Ribero, K., Scholl, L., Moya- Gomez, B., & Condeco-Melhorado, A. (2020). Cómo Aplicar Big Data En La Planificación Del Transporte: El Uso de los Datos de GPS en el Análisis de la Movilidad Urbana. En *Banco Interamericano de Desarrollo*. <https://publications.iadb.org/es/como-aplicar-big-data-en-la-planificacion-del-transporte-el-uso-de-datos-de-gps-en-el-analisis-de>
- Gutiérrez-Puebla, J., García-Palomares, J. C., & Salas-Olmedo, M. H. (2016). Big (Geo)Data en Ciencias Sociales: Retos y Oportunidades Big (Geo)Data in Social Sciences: Challenges and Opportunities. *Revista de Estudios Andaluces*, 33(331), 1-23. <https://doi.org/10.12795/rea.2016.i33.01>
- Gutiérrez Puebla, J. (2018). Big Data y nuevas geografías: la huella digital de las

- actividades humanas. *Documents d'Anàlisi Geogràfica*, 64(2), 195. <https://doi.org/10.5565/rev/dag.526>
- Gutiérrez Puebla, J., Benítez, C., Leño, J. M., García Palomares, J. C., Condeço Melhorado, A., Mojica, C., Scholl, L., Adler, V., Vera, F., Moya Gómez, B., & Romanillos Arroyo, G. (2019). *Cómo aplicar big data en la planificación del transporte urbano: El uso de datos de telefonía móvil en el análisis de la movilidad*. 124. <https://doi.org/10.18235/0002009>
- Gutiérrez Puebla, J., & Chicharro Fernández, E. (2003). *Grandes centros comerciales-Gutiérrez Puebla*. <https://idus.us.es/bitstream/handle/11441/64367/Grandes centros comerciales-Gutiérrez Puebla.pdf?sequence=1&isAllowed=y>
- Gutiérrez Puebla, J., & Fernández Varone, D. (2013). *Localización óptima de centros de salud en futuros desarrollos urbanísticos de la Comunidad de Madrid. Una aplicación de los modelos location-allocation* <https://ucm.on.worldcat.org/oclc/1051293729>. <https://eprints.ucm.es/23172/>
- Hahmann, S., Burghardt, D., & Weber, B. (2011). "80 % of All Information is Geospatially Referenced"??? Towards a Research Framework: Using the Semantic Web for ( In ) Validating this Famous Geo Assertion. In Proceedings of the 14th AGILE Conference on Geographic Information Science.
- Hakimi, L. J. (1964). Optimum Locations of Switching Centers and the Absolute Centers and Medians of a Graph. *Operations Research*, 12(3), 450-459. <https://www.jstor.org/stable/pdf/168125.pdf>
- Hakimi, S. L. (1983). On locating new facilities in a competitive environment. *European Journal of Operational Research*, 12(1), 29-35. [https://doi.org/10.1016/0377-2217\(83\)90180-7](https://doi.org/10.1016/0377-2217(83)90180-7)
- Hakimi, S. L. (1990). Locations with spatial interactions: competitive locations and games. En B. Mirchandani & R. L. Francis (Eds.), *Discrete location theory*. Wiley, New York.
- Hale, T. S., & Moberg, C. R. (2003). Location science research: a review. *Annals of operations research*, 21-35. <https://doi.org/10.1023/A:1026110926707>
- Hamacher, H. W., Labbé, M., Nickel, S., & Skriver, A. J. V. (2002). Multicriteria semi-obnoxious network location problems (MSNLP) with sum and center objectives.

- Annals of Operations Research*, 110(1-4), 33-53.  
<https://doi.org/10.1023/A:1020707315345>
- Han, B., Hu, M., & Wang, J. (2020). Site Selection of Fire Stations in Large Cities Based on Actual Spatiotemporal Demands: A Case Study of Nanjing City. *ISPRS International Journal of Geo-Information*, 9(10).  
<https://doi.org/10.3390/ijgi9100559>
- Hanjoul, P., & Peeters, D. (1985). A comparison of two dual-based procedures for solving the p-median problem. *European Journal of Operational Research*, 20(3), 387-396. [https://doi.org/10.1016/0377-2217\(85\)90012-8](https://doi.org/10.1016/0377-2217(85)90012-8)
- Hao, J., Zhu, J., & Zhong, R. (2015). The rise of big data on urban studies and planning practices in China: Review and open research issues. *Journal of Urban Management*, 4(2), 92-124. <https://doi.org/10.1016/j.jum.2015.11.002>
- Hashim, N. M., Shariff, S. S. R., & Deni, S. M. (2017). Capacitated maximal covering location allocation problem during flood disaster. *Advanced Science Letters*, 23(11), 11545-11548. <https://doi.org/10.1166/asl.2017.10325>
- Hassan, A., & Vijayaraghavan, J. (2019). Geospatial Data Science Quick Start Guide: Effective techniques for performing smarter geospatial analysis using location intelligence. Packt Publishing Ltd.
- Heikinheimo, V., Tenkanen, H., Bergroth, C., Järv, O., Hiippala, T., & Toivonen, T. (2020). Understanding the use of urban green spaces from user-generated geographic information. *Landscape and Urban Planning*, 201(January), 103845. <https://doi.org/10.1016/j.landurbplan.2020.103845>
- Heinen, E., van Wee, B., & Maat, K. (2010). Commuting by bicycle: An overview of the literature. *Transport Reviews*, 30(1), 59-96. <https://doi.org/10.1080/01441640903187001>
- Hodgart, R. L. (1978). Optimizing access to public services: a review of problems, models and methods of locating central facilities. *Progress in Human Geography*, 2(1), 17-48.
- Holmes, J., Williams, F. B., & Brown, L. A. (1972). Facility Location under a Maximum Travel Restriction: An Example Using Day Care Facilities. *Geographical Analysis*, 4(3), 258-266. <https://doi.org/10.1111/j.1538-4632.1972.tb00474.x>

- Hosseini, S., & Moharerhaye, A. (2012). Contributions to Management Science. En *Icclab.Nl*. <https://doi.org/10.1007/978-3-7908-2151-2>
- Hotelling, H. (1929). Stability in competition. *The Economic Journal*, 39(153), 41-57. <https://www.jstor.org/stable/2224214>
- Howe, E., & Jakobsen, F. J. (2020). *Global Moped Sharing Market Report 2020*. <https://mopedsharing.com/moped-sharing-report>
- Hu, Y., Zhang, Y., Lamb, D., Zhang, M., & Jia, P. (2019). Examining and optimizing the BCycle bike-sharing system – A pilot study in Colorado, US. *Applied Energy*, 247, 1-12. <https://doi.org/10.1016/j.apenergy.2019.04.007>
- Hua, M., Chen, X., Zheng, S., Cheng, L., & Chen, J. (2020). Estimating the parking demand of free-floating bike sharing: A journey-data-based study of Nanjing, China. *Journal of Cleaner Production*, 244, 118764. <https://doi.org/10.1016/j.jclepro.2019.118764>
- Huang, B., & Wang, J. (2020). Big spatial data for urban and environmental sustainability. *Geo-Spatial Information Science*, 23(2), 125-140. <https://doi.org/10.1080/10095020.2020.1754138>
- Huang, Q., & Wong, D. W. S. (2016). Activity patterns, socioeconomic status and urban spatial structure: what can social media data tell us? *International Journal of Geographical Information Science*, 30(9), 1873-1898. <https://doi.org/10.1080/13658816.2016.1145225>
- Huff, D. L. (1964). Defining and Estimating a Trading Area. *Journal of Marketing*, 28(3), 34-38. <https://doi.org/10.1177/002224296402800307>
- Hunter, R. F., Garcia, L., Herick de Sa, T., Zapata-Diomedí, B., Millet, C., Woodcock, J., Sandy Pentland, A., & Moro, E. (2020). Effect of COVID-19 response policies on walking behavior in US cities. *medRxiv*, 1-12. <https://doi.org/https://doi.org/10.1038/s41467-021-23937-9>
- Huotari, T., Rusanen, J., Keistinen, T., Lähderanta, T., Ruha, L., Sillanpää, M. J., & Antikainen, H. (2020). Effect of centralization on geographic accessibility of maternity hospitals in Finland. En *BMC Health Services Research* (Vol. 20, Número 1). <https://doi.org/10.1186/s12913-020-05222-5>
- Instituto Nacional de Estadística de España. (2020, septiembre 5). *Estadística*

*experimental*. Estudios de movilidad 2020-2021.  
[https://www.ine.es/experimental/movilidad/experimental\\_em4.htm#tablas\\_resultados](https://www.ine.es/experimental/movilidad/experimental_em4.htm#tablas_resultados)

- Israel, E., & Frenkel, A. (2018). Social justice and spatial inequality: Toward a conceptual framework. *Progress in Human Geography*, 42(5), 647-665. <https://doi.org/10.1177/0309132517702969>
- Jakimavičius, M., Palevičius, V., Antuchevičienė, J., & Karpavičius, T. (2019). Internet GIS-based multimodal public transport trip planning information system for travelers in Lithuania. *ISPRS International Journal of Geo-Information*, 8(8), 319. <https://doi.org/10.3390/ijgi8080319>
- Järv, O., Tenkanen, H., & Toivonen, T. (2017). Enhancing spatial accuracy of mobile phone data using multi-temporal dasymetric interpolation. *International Journal of Geographical Information Science*, 31(8), 1630-1651. <https://doi.org/10.1080/13658816.2017.1287369>
- Ji, Y., Ma, X., He, M., Jin, Y., & Yuan, Y. (2020). Comparison of usage regularity and its determinants between docked and dockless bike-sharing systems: A case study in Nanjing, China. *Journal of Cleaner Production*, 255, 120110. <https://doi.org/10.1016/j.jclepro.2020.120110>
- Jia, H., Ordóñez, F., & Dessouky, M. (2007). A modeling framework for facility location of medical services for large-scale emergencies. *IIE Transactions (Institute of Industrial Engineers)*, 39(1), 41-55. <https://doi.org/10.1080/07408170500539113>
- Jiang, B., Ma, D., Yin, J., & Sandberg, M. (2016). Spatial Distribution of City Tweets and Their Densities. *Geographical Analysis*, 48(3), 337-351. <https://doi.org/10.1111/gean.12096>
- Jiang, B., & Ren, Z. (2019). Geographic space as a living structure for predicting human activities using big data. *International Journal of Geographical Information Science*, 33(4), 764-779. <https://doi.org/10.1080/13658816.2018.1427754>
- Jo, J., & Lee, K. W. (2018). High-performance geospatial big data processing system based on MapReduce. *ISPRS International Journal of Geo-Information*, 7(10), 6-9. <https://doi.org/10.3390/ijgi7100399>
- Joyanes A., L. (2014). *Big data: análisis de grandes volúmenes de datos en*

*organizaciones* (1ª ed.). Marcombo.

- Kanaroglou, P. S., Jerrett, M., Morrison, J., Beckerman, B., Arain, M. A., Gilbert, N. L., & Brook, J. R. (2005). Establishing an air pollution monitoring network for intra-urban population exposure assessment: A location-allocation approach. *Atmospheric Environment*. <https://doi.org/10.1016/j.atmosenv.2004.06.049>
- Karatas, M., & Yakıcı, E. (2019). An analysis of p-median location problem: Effects of backup service level and demand assignment policy. *European Journal of Operational Research*, 272(1), 207-218. <https://doi.org/10.1016/j.ejor.2018.06.017>
- Karlı, R. G. Ö., & Selma Çelikyay. (2021). Current Trends in Smart Cities: Shared Micromobility. *Lecture Notes in Networks and Systems*, March. <http://link.springer.com/book/10.1007/978-3-030-66840-2>
- Karner, A. (2018). Assessing public transit service equity using route-level accessibility measures and public data. *Journal of Transport Geography*, 67, 24-32. <https://doi.org/10.1016/j.jtrangeo.2018.01.005>
- Kaveh, M., Kaveh, M., Mesgari, M. S., & Paland, R. S. (2020). Multiple criteria decision-making for hospital location-allocation based on improved genetic algorithm. *Applied Geomatics*, 12(3), 291-306. <https://doi.org/10.1007/s12518-020-00297-5>
- Kellner, F. (2016). Exploring the impact of traffic congestion on CO2 emissions in freight distribution networks. *Logistics Research*, 9(1), 1-15. <https://doi.org/10.1007/s12159-016-0148-5>
- Kim, J., & Lee, B. (2019). More than travel time: New accessibility index capturing the connectivity of transit services. *Journal of Transport Geography*, 78, 8-18. <https://doi.org/10.1016/j.jtrangeo.2019.05.008>
- Kiptenai, T., & Hunja, E. (2013). GIS Location-Allocation Model in Improving Accessibility to Health Care Facilities: A Case Study of Mt. Elgon Sub-County. *International Journal of Science and Research (IJSR)*, 4(4), 3306-3310. <https://www.ijsr.net/archive/v4i4/SUB153898.pdf>
- Kotavaara, O. (2018). Integrated location-allocation of private car and public transport users – Primary health care facility allocation in the Oulu Region of Finland. *21st International Conference on Geographic Information Science (AGILE 2018)*, 1-8.

<http://jultika.oulu.fi/Record/nbnfi-fe2019052116475>

- Kwon, P., Kim, M. J., Lee, Y., Yu, K., & Huh, Y. (2017). Locating automated external defibrillators in a complicated urban environment considering a pedestrian-accessible network that focuses on out-of-hospital cardiac arrests. *ISPRS International Journal of Geo-Information*, 6(2). <https://doi.org/10.3390/ijgi6020039>
- Laasasenaho, K., Lensu, A., Lauhanen, R., & Rintala, J. (2019). GIS-data related route optimization, hierarchical clustering, location optimization, and kernel density methods are useful for promoting distributed bioenergy plant planning in rural areas. *Sustainable Energy Technologies and Assessments*, 32, 47-57. <https://doi.org/10.1016/j.seta.2019.01.006>
- Lai, Z., Yan, G., Chen, Y., & Wang, Z. (2020). Location and design of urban facilities considering competitors' responses: A case study of putuo District, Shanghai. *Mathematical Problems in Engineering*, 2020. <https://doi.org/10.1155/2020/6759520>
- Lansley, G., & Longley, P. A. (2016). The geography of Twitter topics in London. *Computers, Environment and Urban Systems*, 58, 85-96. <https://doi.org/10.1016/j.compenvurbsys.2016.04.002>
- Lasa N, Gomez J, Padilla J, Garcia J, Gorosiaga A, S. M. (2020). *Las Consecuencias Psicológicas De La Covid-19 y El Confinamiento*. [https://www.ub.edu/web/ub/ca/menu\\_eines/noticies/docs/Consecuencias\\_psicologicas\\_COVID-19.pdf](https://www.ub.edu/web/ub/ca/menu_eines/noticies/docs/Consecuencias_psicologicas_COVID-19.pdf)
- Laurila, J. K., Gatica-Perez, D., Aad, I., Blom, J., Bornet, O., Do, T. M. T., Dousse, O., Eberle, J., & Miettinen, M. (2013). From big smartphone data to worldwide research: The Mobile Data Challenge. *Pervasive and Mobile Computing*, 9(6), 752-771. <https://doi.org/10.1016/j.pmcj.2013.07.014>
- Lazarus, J., Pourquier, J. C., Feng, F., Hammel, H., & Shaheen, S. (2020). Micromobility evolution and expansion: Understanding how docked and dockless bikesharing models complement and compete – A case study of San Francisco. *Journal of Transport Geography*, 84, 102620. <https://doi.org/10.1016/j.jtrangeo.2019.102620>
- Ledesma, L., & Zurita, J. (1995). Localizacion de equipamientos deseables los

- hospitales de la provincia Del Chaco. En J. Bosque Sendra & A. Moreno Jiménez (Eds.), *Localización de equipamientos y sig* (p. 164). RAMA.
- Lee, G., & Murray, A. T. (2010). Maximal covering with network survivability requirements in wireless mesh networks. *Computers, Environment and Urban Systems*, 34(1), 49-57. <https://doi.org/10.1016/j.compenvurbsys.2009.05.004>
- Lee, J. G., & Kang, M. (2015). Geospatial Big Data: Challenges and Opportunities. *Big Data Research*, 2(2), 74-81. <https://doi.org/10.1016/j.bdr.2015.01.003>
- Lei, T. L., Church, R. L., & Lei, Z. (2016). A unified approach for location-allocation analysis: integrating GIS, distributed computing and spatial optimization. *International Journal of Geographical Information Science*, 30(3), 515-534. <https://doi.org/10.1080/13658816.2015.1041959>
- Lejeune, M. A., & Prasad, S. Y. (2013). Effectiveness-equity models for facility location problems on tree networks. *Networks*, 62(4), 243-254. <https://doi.org/10.1002/net.21510>
- Lenormand, M., Thomas, L., Oliva G., C.-R., Miguel, P., Ricardo, H., Juan Murillo, A., Marc, B., Maxi, S. M., & José, R. (2015). Credito\_Influence of sociodemographic characteristics on human mobility. *Scientific Reports*, 5. <https://doi.org/http://dx.doi.org/10.1038/srep10075>
- Li, M., Wang, F., Kwan, M. P., Chen, J., & Wang, J. (2022). Equalizing the spatial accessibility of emergency medical services in Shanghai: A trade-off perspective. En *Computers, Environment and Urban Systems*, 92. <https://doi.org/10.1016/j.compenvurbsys.2021.101745>
- Li, S., Dragicevic, S., Castro, F. A., Sester, M., Winter, S., Coltekin, A., Pettit, C., Jiang, B., Haworth, J., Stein, A., & Cheng, T. (2016). Geospatial big data handling theory and methods: A review and research challenges. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 119-133. <https://doi.org/10.1016/j.isprsjprs.2015.10.012>
- Li, X., Zhao, Z., Zhu, X., & Wyatt, T. (2011). Covering models and optimization techniques for emergency response facility location and planning: A review. *Mathematical Methods of Operations Research*, 74(3), 281-310. <https://doi.org/10.1007/s00186-011-0363-4>

- Li, Yingcheng, Xiong, W., & Wang, X. (2019). Does polycentric and compact development alleviate urban traffic congestion? A case study of 98 Chinese cities. *Cities*, 88, 100-111. <https://doi.org/10.1016/J.CITIES.2019.01.017>
- Li, Yue, Li, Q., & Shan, J. (2017). Discover patterns and mobility of twitter users—a study of four US college cities. *ISPRS International Journal of Geo-Information*, 6(2), 1-17. <https://doi.org/10.3390/ijgi6020042>
- Li, Z., Tang, W., Huang, Q., Shook, E., & Guan, Q. (2020). Introduction to big data computing for geospatial applications. *ISPRS International Journal of Geo-Information*, 9(8). <https://doi.org/10.3390/ijgi9080487>
- Lison<sup>1</sup>, A., Persson<sup>1</sup>, J., Banholzer<sup>1</sup>, N., Feuerriegel, S., Adrian, L., Joel, P., & Nicolas, B. (2022). *Estimating the effect of mobility on SARS-CoV-2 transmission during the first and second wave of the COVID-19 epidemic, Switzerland, March to December 2020*. 1. <https://doi.org/10.2807/1560-7917.ES.2022.27.10.2100374>
- Liu, Lingbo, Peng, Z., Wu, H., Jiao, H., & Yu, Y. (2018). Exploring urban spatial feature with dasymetric mapping based on mobile phone data and LUR-2SFCAe method. *Sustainability (Switzerland)*, 10(7), 1-15. <https://doi.org/10.3390/su10072432>
- Liu, Lun, Gao, X., Zhuang, J., Wu, W., Yang, B., Cheng, W., Xiao, P., Yao, X., & Deng, O. (2020). Evaluating the lifestyle impact of China's rural housing land consolidation with locational big data: A study of Chengdu. *Land Use Policy*, 96, 104623. <https://doi.org/10.1016/j.landusepol.2020.104623>
- Liu, S., Zhang, L., & Long, Y. (2019). Urban vitality area identification and pattern analysis from the perspective of time and space fusion. *Sustainability (Switzerland)*, 11(15). <https://doi.org/10.3390/su11154032>
- Liu, Yixiao, & Tian, L. (2021). A graded cluster system to mine virtual stations in free-floating bike-sharing system on multi-scale geographic view. *Journal of Cleaner Production*, 281, 124692. <https://doi.org/10.1016/j.jclepro.2020.124692>
- Liu, Yuandong, Zhang, Z., Han, L. D., & Brakewood, C. (2021). Automatic Traffic Queue-End Identification using Location-Based Waze User Reports. *Transportation Research Record*, 2675(10), 895-906. <https://doi.org/10.1177/03611981211013353>
- Lobo, A. V. (1984). Movilidad espacial en Madrid. *Anales de Geografía de la*

*Universidad Complutense*, 4, 208-209.

- Longley, P. A., & Adnan, M. (2016). Geo-temporal Twitter demographics. *International Journal of Geographical Information Science*, 30(2), 369-389. <https://doi.org/10.1080/13658816.2015.1089441>
- Loukili, Y., El Aissi, M. E. M., Benjelloun, S., Lakhrissi, Y., Chougrad, H., Elhaj Ben Ali, S., & El Boushaki, A. (2020). Analysis and exploitation of Geospatial Big Data: State of art. *14th IEEE International Conference on Application of Information and Communication Technologies, 2020 Proceedings*. <https://doi.org/10.1109/AICT50176.2020.9368706>
- Ma, Y., Lan, J., Thornton, T., Mangalagu, D., & Zhu, D. (2018). Challenges of collaborative governance in the sharing economy: The case of free-floating bike sharing in Shanghai. *Journal of Cleaner Production*, 197, 356-365. <https://doi.org/10.1016/j.jclepro.2018.06.213>
- Maleki, H. R., Bruni, M. E., Jahedi, S., Beraldi, P., Conforti, D., & Khodaparasti, S. (2016). Balancing efficiency and equity in location-allocation models with an application to strategic EMS design. *Optimization Letters*, 10(5), 1053-1070. <https://doi.org/10.1007/s11590-015-0929-9>
- Malik, M. M., & Shivamallu, D. (2017). Location-Allocation model applied to urban public services : Spatial analysis of fire stations in Mysore urban area Karnataka , India. *International Journal of Advanced Research and Development*, 2(5), 795-801. [http://eprints.uni-mysore.ac.in/4174/1/Location-Allocation model applied.pdf](http://eprints.uni-mysore.ac.in/4174/1/Location-Allocation%20model%20applied.pdf)
- Manyika, J., Chui, M., Brown, B., Bughin, J., Dobbs, R., Roxburgh, C., & Byers, A. H. (2011). *Big data : The next frontier for innovation , competition , and productivity*. <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/big-data-the-next-frontier-for-innovation>
- Marianov, V., & ReVelle, C. (1995). Siting emergency services in facility Location: A survey of applications and methods. *Facility Location, a Survey of Applications and Methods*. Springer-Verlag.
- Marsh, M. T., & Schilling, D. A. (1994). Equity measurement in facility location analysis: A review and framework. *European Journal of Operational Research*, 74(1), 1-17. [https://doi.org/10.1016/0377-2217\(94\)90200-3](https://doi.org/10.1016/0377-2217(94)90200-3)

- Mayo Clinic. (2022, marzo 1). *Actividades seguras al aire libre durante la pandemia de COVID-19*. Recuperado el 07 de julio de 2022 de. <https://www.mayoclinic.org/es-es/diseases-conditions/coronavirus/in-depth/safe-activities-during-covid19/art-20489385>
- Mcallister, D. M. (1976). Efficiency in public facility location. *Geographical Analysis and Technologies*, 8, 47-63. <https://doi.org/https://doi.org/10.1111/j.1538-4632.1976.tb00528.x>
- McAllister, D. M. (1976). Equity and Efficiency in Public Facility Location. *Geographical Analysis*, 8(1), 47-63. <https://doi.org/10.1111/j.1538-4632.1976.tb00528.x>
- Mckenzie, G. (2019a). Shared micro-mobility patterns as measures of city similarity. *1st ACM SIGSPATIAL International Workshop on Computing with Multifaceted Movement Data (MOVE++ 2019)*. <https://doi.org/10.1145/3356392.3365221>
- Mckenzie, G. (2019b). Urban mobility in the sharing economy: A spatiotemporal comparison of shared mobility services. *Computers, Environment and Urban Systems*, 79, 101418. <https://doi.org/10.1016/j.compenvurbsys.2019.101418>
- McKenzie, G. (2019). Spatiotemporal comparative analysis of scooter-share and bike-share usage patterns in Washington, D.C. *Journal of Transport Geography*, 78, 19-28. <https://doi.org/10.1016/j.jtrangeo.2019.05.007>
- McKenzie, G. (2020). Urban mobility in the sharing economy: A spatiotemporal comparison of shared mobility services. *Computers, Environment and Urban Systems*, 79, 101418. <https://doi.org/10.1016/j.compenvurbsys.2019.101418>
- McKenzie, H. (2022, mayo 9). *Hexagons for Location Intelligence: Why, When & How?* CARTO Blog. <https://carto.com/blog/hexagons-for-location-intelligence/>
- McKittrick, M. K., Schuurman, N., & Crooks, V. A. (2022). Collecting, analyzing, and visualizing location-based social media data: review of methods in GIS-social media analysis. *GeoJournal*, 0123456789. <https://doi.org/10.1007/s10708-022-10584-w>
- Medina Tapia, M., & Cerda Troncoso, J. (2008). Modelo de localización óptima de actividades no deseadas aplicado a los residuos sólidos en la región metropolitana. *Ingeniare*, 16(2), 211-219. <https://doi.org/10.4067/s0718-33052008000100011>

- Mehndiratta, S., Zegras, C., & Webb, K. (2014). *Applying the General Transit Feed*.  
<https://doi.org/http://dx.doi.org/10.3141/2442-06>
- Melachrinoudis, E. (1967). The Location of Undesirable Facilities. En *Angewandte Chemie International Edition*, 6(11), 951–952. (pp. 5-24).
- Meskarian, R., Penn, M. L., Williams, S., & Monks, T. (2017). A facility location model for analysis of current and future demand for sexual health services. En *PLoS ONE* (Vol. 12, Número 8). <https://doi.org/10.1371/journal.pone.0183942>
- Mete, S., Cil, Z. A., & Özceylan, E. (2018). Location and coverage analysis of bike-sharing stations in university campus. *Business Systems Research*, 9(2), 80-95.  
<https://doi.org/10.2478/bsrj-2018-0021>
- Miliotis, P., Dimopoulou, M., & Giannikos, I. (2002). A Hierarchical Location Model for Locating Bank Branches in a Competitive Environment. *International Transactions in Operational Research*, 9(5), 549-565. <https://doi.org/10.1111/1475-3995.00373>
- Min, H., & Melachrinoudis, E. (2001). The Three-Hierarchical Location-Allocation of Banking Facilities with Risk and Uncertainty. *International Transactions in Operational Research*, 8(4), 381-401. <https://doi.org/10.1111/1475-3995.00272>
- Mishra, S., Sahu, P. K., Sarkar, A. K., Mehran, B., & Sharma, S. (2019). Geo-spatial site suitability analysis for development of health care units in rural India: Effects on habitation accessibility, facility utilization and zonal equity in facility distribution. *Journal of Transport Geography*, 78, 135-149.  
<https://doi.org/10.1016/j.jtrangeo.2019.05.017>
- Mooney, S. J., Hosford, K., Howe, B., Yan, A., Winters, M., Bassok, A., & Hirsch, J. A. (2019). in access to docklesFreedom from the station: Spatial equitys bike share. *Journal of Transport Geography*, 74, 91-96.  
<https://doi.org/10.1016/j.jtrangeo.2018.11.009>
- Moovit. (2020, noviembre 7). *Impact of coronavirus on public transit usage*.  
[https://moovitapp.com/insights/es/Moovit\\_Insights\\_Índice\\_de\\_Transporte\\_Público-countries](https://moovitapp.com/insights/es/Moovit_Insights_Índice_de_Transporte_Público-countries)
- Morrill, R. L., & Symons, J. (1977). Efficiency and Equity Aspects of Optimum Location. *Geographical Analysis*, 9(3), 215-225. <https://doi.org/10.1111/j.1538-4632.1977.tb00575.x>

- Moya-Gómez, B., & García-Palomares, J. C. (2015). Working with the daily variation in infrastructure performance on territorial accessibility. The cases of Madrid and Barcelona. *European Transport Research Review*, 7(2). <https://doi.org/10.1007/s12544-015-0168-2>
- Moya-Gómez, B., & García-Palomares, J. C. (2017a). Representation of dynamic spatial phenomena: The daily car accessibility in London. *Journal of Maps*, 13(1), 31-39.
- Moya-Gómez, B., & García-Palomares, J. C. (2017b). The daily dynamic potential accessibility by car in London on wednesdays. *Journal of Maps*, 13(1), 31-39. <https://doi.org/10.1080/17445647.2017.1305301>
- Moya-Gómez, B., Henar Salas-Olmedo, M., Carlos García-Palomares, J., & Gutiérrez, J. (2018). Dynamic Accessibility using Big Data: The Role of the Changing Conditions of Network Congestion and Destination Attractiveness. *Networks and Spatial Economics*, 18(2), 273-290. <https://doi.org/10.1007/s11067-017-9348-z>
- Moyano, A., Moya-Gómez, B., & Gutiérrez, J. (2018). Access and egress times to high-speed rail stations: a spatiotemporal accessibility analysis. *Journal of Transport Geography*, 73, 84-93. <https://doi.org/10.1016/j.jtrangeo.2018.10.010>
- Moyano, A., Stępnik, M., Moya-Gómez, B., & García-Palomares, J. C. (2021). Traffic congestion and economic context: changes of spatiotemporal patterns of traffic travel times during crisis and post-crisis periods. *Transportation*, 0123456789. <https://doi.org/10.1007/s11116-021-10170-y>
- Mumphrey, A. J., Seley, J. E., & Wolpert, J. (1971). A decision model for locating controversial facilities. *Journal of the American Institute of Planners*, 37(6), 397-402. <https://doi.org/10.1080/01944367108977389>
- Munir, B. A., Hafeez, S., Rashid, S., Iqbal, R., & Javed, M. A. (2020). Geospatial assessment of physical accessibility of healthcare and agent-based modeling for system efficacy. *GeoJournal*, 85(3), 665-680. <https://doi.org/10.1007/s10708-019-09987-z>
- Murad, A. A. (2014). Using geographical information systems for defining the accessibility to health care facilities in Jeddah City, Saudi Arabia. *Geospatial Health*, 8(3), S661-S669. <https://doi.org/10.4081/gh.2014.295>

- Murray, A. T. (2010). Advances in location modeling: GIS linkages and contributions. *Journal of Geographical Systems*, 12(3), 335-354. <https://doi.org/10.1007/s10109-009-0105-9>
- Murray, A. T., & Church, R. L. (1998). Impact Models for siting Undesirable Facilities. *Regional science*, 77(1), 19-36. <https://doi.org/https://doi.org/10.1111/j.1435-5597.1998.tb00706.x>
- Murray, A. T., & Gerrard, R. A. (1997). Capacitated service and regional constraints in location-allocation modeling. *Location science*, 5(2), 103-118. [https://doi.org/10.1016/S0966-8349\(97\)00016-8](https://doi.org/10.1016/S0966-8349(97)00016-8)
- Nakanishi, M., & Cooper, L. G. (1974). Parameter estimation for a multiplicative competitive interaction model—least squares approach. *Journal of marketing research*, 11(3), 303-311. <https://doi.org/10.1177/002224377401100309>
- Namazian, Z., & Roghanian, E. (2019). A decision problem for bank branch site selection: A GIS Mapping perspective with Maximal Covering Location Problem: A case study of Isfahan, Iran. *Computers and Society*. <http://arxiv.org/abs/1909.00130>
- Nassir, N., Khani, A., Lee, S. G., Noh, H., & Hickman, M. (2012). Transit Stop-Level Origin–Destination Estimation through Use of Transit Schedule and Automated Data Collection System. *Transportation Research Record: Journal of the Transportation Research Board*, 2263(1), 140-150. <https://doi.org/10.3141/2263-16>
- Ngowi, K. A., & William, C. M. P. (2020). *Geospatial Location-Allocation Approach to Optimize Healthcare Facilities in Peri-Urban dwellers in Mbeya City , Tanzania*. 1(1), 56-78. <http://41.59.86.228/index.php/mjrd/article/view/33>
- Nguyen, T., ZHOU, L., Spiegler, V., Ieromonachou, P., & Lin, Y. (2018). Big data analytics in supply chain management: A state-of-the-art literature review. *Computers & Operations Research*, 98, 254-264. <https://doi.org/10.1016/J.COR.2017.07.004>
- Niu, H., & Silva, E. A. (2020). Crowdsourced Data Mining for Urban Activity: Review of Data Sources, Applications, and Methods. *Journal of Urban Planning and Development*, 146(2). [https://doi.org/10.1061/\(asce\)up.1943-5444.0000566](https://doi.org/10.1061/(asce)up.1943-5444.0000566)

- Nogueira, L. C., Pinto, L. R., & Silva, P. M. S. (2016). Reducing Emergency Medical Service response time via the reallocation of ambulance bases. *Health Care Management Science*, 19(1), 31-42. <https://doi.org/10.1007/s10729-014-9280-4>
- Noland, R. B. (2019). Trip patterns and revenue of shared e-scooters in Louisville, Kentucky. *Transport Findings*, 0-3. <https://doi.org/10.32866/7747>
- Norheim, K., Tiwari, C., & Oppong, J. (2021). Surface ozone monitoring and policy : A geospatial decision support tool for suitable location of monitoring stations in urban areas. *Environmental Science and Policy*, 126, 48-59. <https://doi.org/10.1016/j.envsci.2021.09.011>
- OMS. (2008). *Emergency medical services systems in the European Union*. [https://www.euro.who.int/\\_\\_data/assets/pdf\\_file/0016/114406/E92038.pdf](https://www.euro.who.int/__data/assets/pdf_file/0016/114406/E92038.pdf)
- Osorio-Arjona, J. (2020a). Análisis de los patrones espacio-temporales de eventos a partir de datos de Twitter: el caso de la World Pride 2017 en Madrid. *Estudios Geográficos*, 81(288), 032. <https://doi.org/10.3989/estgeogr.202047.027>
- Osorio-Arjona, J. (2020b). *Oportunidades de los datos geolocalizados de Twitter en el estudio de la movilidad metropolitana [Tesis de doctorado, Universidad Complutense de Madrid]*. <https://eprints.ucm.es/65270/1/T42273.pdf>
- Osorio-Arjona, J., & García-Palomares, J. C. (2019). Social media and urban mobility: Using twitter to calculate home-work travel matrices. *Cities*, 89, 268-280. <https://doi.org/10.1016/j.cities.2019.03.006>
- Osorio Arjona, J., & García Palomares, J. C. (2019). Big Data y Universidades: Análisis de Movilidad de Los Estudiantes Universitarios a Partir de Datos de Twitter. *GeoFocus*, 24, 37-57. <https://doi.org/10.1017/CBO9781107415324.004>
- Osorio Arjona, Joaquín, & García-Palomares, J. C. (2018). Áreas de influencia de los campus universitarios de la Comunidad de Madrid a partir de Twitter. En *Actas del XIII Congreso de Ingeniería del Transporte* (pp. 2786-2799). <https://www.researchgate.net/publication/330244411>
- Özceylan, E., Uslu, A., Erbaş, M., Çetinkaya, C., & Kürşat, S. (2017). Optimizing the location-allocation problem of pharmacy warehouses : A case study in Gaziantep. *An International Journal of Optimization and Control: Theories & Applications*, 7(1), 117-129. <https://doi.org/10.11121/ijocta.01.2017.00373>

- Özkan, B., Mete, S., Çelik, E., & Özceylan, E. (2019). Gis-Based Maximum Covering Location Model in Times of Disasters: the Case of Tunceli. *Beykoz Akademi Dergisi*, 100-111. <https://doi.org/10.14514/byk.m.26515393.2019.sp/100-111>
- Páez, A., Scott, D. M., & Morency, C. (2012). Measuring accessibility: Positive and normative implementations of various accessibility indicators. *Journal of Transport Geography*, 25, 141-153. <https://doi.org/10.1016/j.jtrangeo.2012.03.016>
- Palacios, J., & Mora, C. (2012). Ubicación óptima de módulos electorales en el estado de chihuahua (México) utilizando modelos de localización- asignación mediante un sig. *Boletín de la Asociación de Geógrafos Españoles*, 60, 227-252. <https://dialnet.unirioja.es/servlet/articulo?codigo=4067078>
- Pan, Y., & He, S. Y. (2022). Analyzing COVID-19's impact on the travel mobility of various social groups in China's Greater Bay Area via mobile phone big data. *Transportation Research Part A: Policy and Practice*, 159, 263-281. <https://doi.org/10.1016/J.TRA.2022.03.015>
- Park, C., & Young Sohn, S. (2017). An Optimization Approach for the Placement of Bicycle-sharing stations to Reduce Short Car Trips: An Application to the City of Seoul. *Transportation Research Part A: Policy and Practice*, 105(June), 154-166. <https://doi.org/10.1016/j.tra.2017.08.019>
- Pastor, J. T. (1994). *Bicriterion Programs and Managerial Location Decisions : Application to the Banking Sector Published by : Palgrave Macmillan Journals on behalf of the Operational Research Society Stable*, 45(12), 1351-1362. <https://www.jstor.org/stable/2583929>
- Patgiri, R., & Ahmed, A. (2017). Big Data: The V's of the Game Changer Paradigm. *Proceedings - 18th IEEE International Conference on High Performance Computing and Communications, 14th IEEE International Conference on Smart City and 2nd IEEE International Conference on Data Science and Systems, HPCC/SmartCity/DSS 2016, December, 17-24*. <https://doi.org/10.1109/HPCC-SmartCity-DSS.2016.0014>
- Peeters, D., & Thomas, I. (2000). Distance predicting functions and applied location-allocation models. *Journal of Geographical Systems*, 2(2), 167-184. <https://doi.org/10.1007/PL00011453>

- Peeters, P. H. (1996). The Pareto-Huff model. En *Brussels, Belgium: Vrije Universiteit Brussel*.
- Peng, X., Bao, Y., & Huang, Z. (2020). Perceiving Beijing's "city image" across different groups based on geotagged social media data. *IEEE Access*, 8, 1-1. <https://doi.org/10.1109/access.2020.2995066>
- Pereira, R. H. M., Schwanen, T., & Banister, D. (2017). Distributive justice and equity in transportation. *Transport reviews*, 37(2), 170-191.
- Philip Chen, C. L., & Zhang, C. Y. (2014). Data-intensive applications, challenges, techniques and technologies: A survey on Big Data. *Information Sciences*, 275, 314-347. <https://doi.org/10.1016/j.ins.2014.01.015>
- Pirie, G. H. (1983). On Spatial Justice. *Environment and Planning A: Economy and Space*, 15(4), 465-473. <https://doi.org/10.1068/a150465>
- Pirkul, H., & Schilling, D. (1989). The Capacitated Maximal Covering Location Problem with Backup Service. *Annals of Operations Research*, 18(1), 141-154. [https://www.researchgate.net/profile/Hasan-Pirkul/publication/226807433\\_The\\_Capacitated\\_Maximal\\_Covering\\_Location\\_Problem\\_with\\_Backup\\_Service/links/02e7e52254a03ed96a000000/The-Capacitated-Maximal-Covering-Location-Problem-with-Backup-Service.pdf](https://www.researchgate.net/profile/Hasan-Pirkul/publication/226807433_The_Capacitated_Maximal_Covering_Location_Problem_with_Backup_Service/links/02e7e52254a03ed96a000000/The-Capacitated-Maximal-Covering-Location-Problem-with-Backup-Service.pdf)
- Plastria, F. (1995). Continuous location problems: research, results and questions. *Facility location: a survey of applications and methods*, 85-127.
- Plastria, F. (2001). Static competitive facility location: An overview of optimization approaches. *European Journal of Operational Research*, 129(3), 461-470. [https://doi.org/10.1016/S0377-2217\(00\)00169-7](https://doi.org/10.1016/S0377-2217(00)00169-7)
- Plaza, A., Sánchez, R., Ordaz, A., & Álvarez, P. J. (2019, febrero 23). Más gente, menos trenes: los datos que explican el profundo deterioro de Metro de Madrid. *e/Diario.es*. [https://www.eldiario.es/madrid/metro-de-madrid\\_1\\_1684898.html](https://www.eldiario.es/madrid/metro-de-madrid_1_1684898.html)
- Polo, G., Acosta, C. M., Ferreira, F., & Dias, R. A. (2015). Location-allocation and accessibility models for improving the spatial planning of public health services. *PLoS ONE*, 10(3), 1-14. <https://doi.org/10.1371/journal.pone.0119190>
- Pons, P. T., Haukoos, J. S., Bludworth, W., Cribley, T., Pons, K. A., & Markovchick, V. J. (2005). Paramedic response time: Does it affect patient survival? *Academic*

- Emergency Medicine*, 12(7), 594-600. <https://doi.org/10.1197/j.aem.2005.02.013>
- Pons, P. T., & Markovchick, V. J. (2002). Eight minutes or less: Does the ambulance response time guideline impact trauma patient outcome? *Journal of Emergency Medicine*, 23(1), 43-48. [https://doi.org/10.1016/S0736-4679\(02\)00460-2](https://doi.org/10.1016/S0736-4679(02)00460-2)
- Pritchard, J. P., Tomasiello, D. B., Giannotti, M., & Geurs, K. (2019). Potential impacts of bike-and-ride on job accessibility and spatial equity in São Paulo, Brazil. *Transportation Research Part A: Policy and Practice*, 121, 386-400. <https://doi.org/10.1016/j.tra.2019.01.022>
- Prommaharaj, P., Phithakkitnukoon, S., Demissie, M. G., Kattan, L., & Ratti, C. (2020). Visualizing public transit system operation with GTFS data: A case study of Calgary, Canada. *Heliyon*, 6(4), e03729. <https://doi.org/10.1016/j.heliyon.2020.e03729>
- Pu, Q., Yoo, E., Rothstein, D. H., Cairo, S., & Malemo, L. (2020). Improving the spatial accessibility of healthcare in North Kivu, Democratic Republic of Congo. *Applied Geography*, 121, 102262. <https://doi.org/10.1016/j.apgeog.2020.102262>
- Puerto-Albandoz, J. (1996). *Lecturas en teoría de localización (vol 46.)*. Universidad de Sevilla, Secretariado de Publicaciones.
- Radaković, M. (2017). Utilizing Geographic Information System (GIS) for determining new locations of post office in Novi Sad, Serbia. *Zbornik radova Departmana za geografiju, turizam i hotelijerstvo*, 46-2, 105-115. <https://doi.org/10.5937/zbdgth1702105r>
- Radzimski, A., & Dziecielski, M. (2021). Exploring the relationship between bike-sharing and public transport in Poznań, Poland. *Transportation Research Part A: Policy and Practice*, 145, 189-202. <https://doi.org/10.1016/j.tra.2021.01.003>
- Rahman, M., Chen, N., Islam, M. M., Dewan, A., Pourghasemi, H. R., Washakh, R. M. A., Nepal, N., Tian, S., Faiz, H., Alam, M., & Ahmed, N. (2021). Location-allocation modeling for emergency evacuation planning with GIS and remote sensing: A case study of Northeast Bangladesh. *Geoscience Frontiers*, 12(3), 101095. <https://doi.org/10.1016/j.gsf.2020.09.022>
- Rahman, S. U., & Smith, D. K. (2000). Use of location-allocation models in health service development planning in developing nations. En *European Journal of*

- Operational Research*, 123(3), 437-452. [https://doi.org/10.1016/S0377-2217\(99\)00289-1](https://doi.org/10.1016/S0377-2217(99)00289-1)
- Rajagopalan, H. K., Saydam, C., & Xiao, J. (2008). A multiperiod set covering location model for dynamic redeployment of ambulances. *Computers and Operations Research*, 35(3), 814-826. <https://doi.org/10.1016/j.cor.2006.04.003>
- Ramírez, M. L. (2000). Metodología básica para la localización de hospitales mediante sistemas de información geográfica raster y vectorial. *GEONATURA: Aplicaciones de los SIG a las Ciencias Ambientales y de la Salud*, 1-16. <http://hum.unne.edu.ar/investigacion/geografia/labtig/publicaciones/public03.pdf>
- Ramirez, M. L., & Bosque Sendra, J. (2001). Localización de Hospitales : analogías y diferencias del uso del modelo P-mediano en SIG raster y vectorial. *Anales de Geografía de la Universidad Complutense de Madrid*, 21, 53-79. <http://hum.unne.edu.ar/investigacion/geografia/labtig/publicaciones/public05.pdf>
- Rathore, P., Sarmah, S. P., & Singh, A. (2019). Location–allocation of bins in urban solid waste management: a case study of Bilaspur city, India. *Environment, Development and Sustainability*, 1-23. <https://doi.org/10.1007/s10668-019-00347-y>
- Reck, D. J., Guidon, S., Haitao, H., & Axhausen, K. W. (2020). Explaining shared micromobility usage, competition and mode choice by modelling empirical data from Zurich, Switzerland. *BRISK Binary Robust Invariant Scalable Keypoints*, 15(3), 12-19. <https://doi.org/10.1016/j.trc.2020.102947>
- Repede, J. F., & Bernardo, J. J. (1994). Developing and validating a decision support system for locating emergency medical vehicles in Louisville, Kentucky. *European Journal of Operational Research*, 75(3), 567-581. [https://doi.org/10.1016/0377-2217\(94\)90297-6](https://doi.org/10.1016/0377-2217(94)90297-6)
- Reshadat, S., Zangeneh, A., Saeidi, S., Teimouri, R., & Yigitcanlar, T. (2019). Measures of spatial accessibility to health centers: investigating urban and rural disparities in Kermanshah, Iran. En *Journal of Public Health* , 27( 4), 519-529. <https://doi.org/10.1007/s10389-018-0966-9>
- ReVelle, C. (1986). The maximum capture or “sphere of influence” location problem: Hotelling revisited on a network. *Journal of Regional Science*, 26(2), 343-358.

- Revelle, C. S., & Eiselt, H. A. (2005). Location analysis: A synthesis and survey. *European Journal of Operational Research*, 165(1), 1-19. <https://doi.org/10.1016/j.ejor.2003.11.032>
- ReVelle, C. S., Eiselt, H. A., & Daskin, M. S. (2008). A bibliography for some fundamental problem categories in discrete location science. *European Journal of Operational Research*, 184(3), 817-848. <https://doi.org/10.1016/j.ejor.2006.12.044>
- ReVelle, Charles S, & Swain, W. R. (1970). Central facilities location. *Geographical Analysis*, 2(1), 30-42. <https://doi.org/10.1111/j.1538-4632.1970.tb00142.x>
- Revistainforetail. (2020, septiembre 5). ¿Cuál es la calle comercial de Madrid con más afluencia? <https://www.revistainforetail.com/noticiadet/cual-es-la-calle-comercial-de-madrid-con-mas-afluencia/50897b357f88e13b73fdea16ccad840a>
- Ribeiro, A., & Antunes, A. P. (2002). A GIS-based decision-support tool for public facility planning. *Environment and Planning B: Planning and Design*, 29(4), 553-569. <https://doi.org/10.1068/b1281>
- Richard, D., Beguin, H., & Peeters, D. (1990). The location of fire stations in a rural environment: a case study. *Environment & Planning A*, 22(1), 39-52. <https://doi.org/10.1068/a220039>
- Riu, Z., Zhang, X., Kondor, D., Santi, P., & Ratti, C. (2020). Understanding spatio-temporal heterogeneity of bike-sharing and scooter-sharing mobility. *Computers, Environment and Urban Systems*, 81(3), 101-483. <https://doi.org/10.1016/j.compenvurbsys.2020.101483>
- Rizeei, H. M., Pradhan, B., & Saharkhiz, M. A. (2019). Allocation of emergency response centres in response to pluvial flooding-prone demand points using integrated multiple layer perceptron and maximum coverage location problem models. *International Journal of Disaster Risk Reduction*, 38, 101205. <https://doi.org/10.1016/j.ijdrr.2019.101205>
- Rodríguez, Sánchez, Y., Gómez, Figueroa, O., Diéguez, E. M., & Rosales, L. De. (2016). Localización-asignación de los servicios de atención primaria en un área de salud Location-assignment of the services of primary care in a health area. *Rev Méd Electrón*, 837-850.

<http://www.revmedicaelectronica.sld.cu/index.php/rme/article/view/2029/3251>

- Rodríguez, V., Olarte-Pascual, C., & Saco, M. (2017). Application of geographical information systems for the optimal location of a commercial network. *European Journal of Management and Business Economics*, 26(2), 220-237. <https://doi.org/10.1108/EJMBE-07-2017-013>
- Roig-Tierno, N., Baviera-Puig, A., Buitrago-Vera, J., & Mas-Verdu, F. (2013). The retail site location decision process using GIS and the analytical hierarchy process. *Applied Geography*, 40, 191-198. <https://doi.org/10.1016/j.apgeog.2013.03.005>
- Romanillos, G., García-Palomares, J. C., Moya-Gómez, B., Gutiérrez, J., Torres, J., López, M., Cantú-Ros, O. G., & Herranz, R. (2021). The city turned off: Urban dynamics during the COVID-19 pandemic based on mobile phone data. *Applied Geography*, 134. <https://doi.org/10.1016/j.apgeog.2021.102524>
- Rosso, I. (2016). Distribucion dasimétrica de datos censales y análisis de redes para la localización óptima de equipamiento urbano. *Parrafos Geográficos*, 15(Nº1).
- Roukouni, A., & Correia, G. H. de A. (2020). Evaluation methods for the impacts of shared mobility: Classification and critical review. *Sustainability (Switzerland)*, 12(24), 1-22. <https://doi.org/10.3390/su122410504>
- Russom, P. (2011). Big data analytics - Tdwi Best Practices Report: Introduction to Big Data Analytics. *TDWI RESEARCH*, 1, 3-5. <https://vivomente.com/wp-content/uploads/2016/04/big-data-analytics-white-paper.pdf>
- Saidani, N., Chu, F., & Chen, H. (2012). Competitive facility location and design with reactions of competitors already in the market. *European Journal of Operational Research*, 219(1), 9-17. <https://doi.org/10.1016/j.ejor.2011.12.017>
- Salari, M. (2014). An iterated local search for the budget constrained generalized maximal covering location problem. *Journal of Mathematical Modelling and Algorithms in Operations Research*, 13(3), 301-313.
- Salas-Olmedo, M. H., Moya-Gómez, B., García-Palomares, J. C., & Gutiérrez, J. (2018). Tourists' digital footprint in cities: Comparing Big Data sources. *Tourism Management*, 66, 13-25. <https://doi.org/10.1016/j.tourman.2017.11.001>
- SAMUR. (2020, abril 15). *Parque de vehículos. Ambulancias*. <https://www.madrid.es/portales/munimadrid/es/Samur/SAMUR-Proteccion->

Civil/?vgnnextfmt=default&vgnnextoid=c88fcdb1bffa010VgnVCM100000d90ca8c0  
RCRD&vgnnextchannel=84516c77e7d2f010VgnVCM1000000b205a0aRCRD&id  
Capitulo=10269430&page=1

- Santos, S. R. dos, Davis Jr., C. A., & Smarzaró, R. (2017). Analyzing Traffic Accidents based on the Integration of Official and Crowdsourced Data. *Journal of Information and Data Management*, 8(1), 66-81.
- Savas, E. S. (1978). On equity in providing public services. *Management Science*, 24(8), 800-808. [https://www.researchgate.net/profile/E-S-Savas/publication/227444808\\_On\\_Equity\\_in\\_Providing\\_Public\\_Services/links/57abde0f08ae0932c9717cfa/On-Equity-in-Providing-Public-Services.pdf](https://www.researchgate.net/profile/E-S-Savas/publication/227444808_On_Equity_in_Providing_Public_Services/links/57abde0f08ae0932c9717cfa/On-Equity-in-Providing-Public-Services.pdf)
- Schmid, V. (2012). Solving the dynamic ambulance relocation and dispatching problem using approximate dynamic programming. *European Journal of Operational Research*, 219(3), 611-621. <https://doi.org/10.1016/j.ejor.2011.10.043>
- Scott, A. J. (1970). location-Allocation Systems. *Geographical Analysis.*, 2(2), 95-119. <https://doi.org/https://doi.org/10.1111/j.1538-4632.1970.tb00149.x>
- Serra, D., & ReVelle, C. (1994). *Competitive location in discrete space.* <https://repositori.upf.edu/bitstream/handle/10230/20879/96.pdf?sequence=1>
- Serra, D., & Marianov, V. (2002). New trends in public facility location modeling. *UPF Economics and Business working paper.* <https://doi.org/10.2139/ssrn.563843>
- Serra, D., ReVelle, C., & Rosing, K. (1999). Surviving in a competitive spatial market: The threshold capture model. *Journal of Regional Science*, 39(4), 637-650. <https://doi.org/10.1111/0022-4146.00153>
- Shaheen, S. A., & Cohen, A. P. (2019). Shared Micromobility Policy Toolkit: Docked and Dockless Bike and Scooter Sharing. *UC Berkeley: Transportation Sustainability Research Center*, 1-9. <https://doi.org/10.7922/G2TH8JW7>
- Shahparvari, S., Fadaki, M., & Chhetri, P. (2020). Spatial accessibility of fire stations for enhancing operational response in Melbourne. *Fire Safety Journal*, 103149. <https://doi.org/10.1016/j.firesaf.2020.103149>
- Shan, W., Yan, Q., Chen, C., Zhang, M., Yao, B., & Fu, X. (2019). Optimization of competitive facility location for chain stores. *Annals of Operations Research*, 273(1-2), 187-205. <https://doi.org/10.1007/s10479-017-2579-z>

- Shariff, S. S. R., Moin, N. H., & Omar, M. (2012). Location allocation modeling for healthcare facility planning in Malaysia. *Computers and Industrial Engineering*, 62(4), 1000-1010. <https://doi.org/10.1016/j.cie.2011.12.026>
- Shaw, S.-L., Tsou, M.-H., & Ye, X. (2016). Editorial: Human dynamics in the mobile and big data era. *International Journal of Geographical Information Science*, 30, 1687–1693. <https://doi.org/10.1080/13658816.2016.1164317>
- Shen, Y., Zhang, X., & Zhao, J. (2018). Understanding the usage of dockless bike sharing in Singapore. *International Journal of Sustainable Transportation*, 12(9), 686-700. <https://doi.org/10.1080/15568318.2018.1429696>
- Shi, Y., Zhai, G., Xu, L., Zhu, Q., & Deng, J. (2019). Planning emergency shelters for urban disasters: A multi-level location-allocation modeling approach. *Sustainability (Switzerland)*, 11(16). <https://doi.org/10.3390/su11164285>
- Sladjana, A., Gordana, P., & Ana, S. (2011). Emergency response time after out-of-hospital cardiac arrest. *European Journal of Internal Medicine*, 22(4), 386-393. <https://doi.org/10.1016/J.EJIM.2011.04.003>
- Slovic, A. D., Tomasiello, D. B., Giannotti, M., Andrade, M. de F., & Nardocci, A. C. (2019). The long road to achieving equity: Job accessibility restrictions and overlapping inequalities in the city of São Paulo. *Journal of Transport Geography*, 78, 181-193. <https://doi.org/10.1016/j.jtrangeo.2019.06.003>
- Soja, E. W. (2013). *Seeking spatial justice* (Vol. 16). U of Minnesota Press. doi:10.1057/cpt.2011.40
- Sommerhalter, K. M., Insaf, T. Z., Akkaya-Hocagil, T., McGarry, C. E., Farr, S. L., Downing, K. F., Lui, G. K., Zaidi, A. N., & Van Zutphen, A. R. (2017). Proximity to Pediatric Cardiac Surgical Care among Adolescents with Congenital Heart Defects in 11 New York Counties. *Birth Defects Research*, 109(18), 1494-1503. <https://doi.org/10.1002/bdr2.1129>
- Song, B. D., Morrison, J. R., & Ko, Y. D. (2013). Efficient location and allocation strategies for undesirable facilities considering their fundamental properties. *Computers and Industrial Engineering*, 65(3), 475-484. <https://doi.org/10.1016/j.cie.2013.03.009>
- Steenbruggen, J., Borzacchiello, M. T., Nijkamp, P., Scholten, H., Steenbruggen, J.,

- Nijkamp, Á. P., Scholten, Á. H., Nijkamp, P., Scholten, H., & Borzacchiello, M. T. (2013). Mobile phone data from GSM networks for traffic parameter and urban spatial pattern assessment: a review of applications and opportunities. *GeoJournal*, 78, 223-243. <https://doi.org/10.1007/s10708-011-9413-y>
- Steenbruggen, J., Tranos, E., & Nijkamp, P. (2015). Data from mobile phone operators: A tool for smarter cities? *Telecommunications Policy*, 39(3-4), 335-346. <https://doi.org/10.1016/J.TELPOL.2014.04.001>
- Steiger, E., de Albuquerque, J. P., & Zipf, A. (2015). An Advanced Systematic Literature Review on Spatiotemporal Analyses of Twitter Data. *Transactions in GIS*, 19(6), 809-834. <https://doi.org/10.1111/tgis.12132>
- Stępniań, M., & Goliszek, S. (2017). Spatio-temporal variation of accessibility by public transport—the equity perspective. In *The rise of big spatial data*. Springer, Cham, December, 241-261. <https://doi.org/10.1007/978-3-319-45123-7>
- Stępniań, M., & Goliszek, S. (2017). Spatio-temporal variation of accessibility by public transport—the equity perspective. *Lecture Notes in Geoinformation and Cartography*, 241-261. [https://doi.org/10.1007/978-3-319-45123-7\\_18](https://doi.org/10.1007/978-3-319-45123-7_18)
- Stępniań, M., Pritchard, J. P., Geurs, K. T., & Goliszek, S. (2019a). The impact of temporal resolution on public transport accessibility measurement: Review and case study in Poland. *Journal of Transport Geography*, 75(January), 8-24. <https://doi.org/10.1016/j.jtrangeo.2019.01.007>
- Stępniań, M., Pritchard, J. P., Geurs, K. T., & Goliszek, S. (2019b). The impact of temporal resolution on public transport accessibility measurement: Review and case study in Poland. *Journal of Transport Geography*, 75, 8-24. <https://doi.org/10.1016/j.jtrangeo.2019.01.007>
- Stock, K. (2018). Mining location from social media: A systematic review. *Computers, Environment and Urban Systems*, 71, 209-240. <https://doi.org/10.1016/j.compenvurbsys.2018.05.007>
- Stone, D. (2012). *Policy paradox. The art of political decision making* (3ra ed.). Norton & Company.
- Strohmandl, J., Tomek, M., Molnár, V., Jakubčeková, J. M., Fedorko, G., & Maláková, S. (2021). Using travel times for optimization numbers of medical rescue service

- points—case study from Slovakia. *Sustainability*, 13(1), 1-12.  
<https://doi.org/10.3390/su13010207>
- Suárez-Vega, R., Santos-Peñate, D. R., & Dorta-González, P. (2012). Location models and GIS tools for retail site location. *Applied Geography*, 35(1-2), 12-22.  
<https://doi.org/10.1016/j.apgeog.2012.04.009>
- Sun, C. H., Cheng, C. Y., Wang, C. H., & Hsiao, P. H. (2020). Dynamic floating stations model for emergency medical services with a consideration of traffic data. *ISPRS International Journal of Geo-Information*, 9(5). <https://doi.org/10.3390/ijgi9050336>
- Sun, Z., Li, Y., & Zuo, Y. (2019). *Optimizing the Location of Virtual Stations in Free-Floating Bike-Sharing Systems with the User Demand during Morning and Evening Rush Hours, 2019*. Journal of Advanced Transportation.  
<https://doi.org/10.1155/2019/4308509>
- Suraraksa, J., & Shin, K. S. (2019). Urban transportation network design for fresh fruit and vegetables using gis-the case of bangkok. *Applied Sciences (Switzerland)*, 9(23). <https://doi.org/10.3390/app9235048>
- Taiwo, O. J. (2021). Maximal covering location problem for nuclear medicine clinics allocation in Nigeria. *Spatial Information Research*, 29(6), 219-935  
<https://doi.org/10.1007/s41324-021-00405-6>
- Talavera-Garcia, R., & Pérez-Campaña, R. (2021). Applying a pedestrian level of service in the context of social distancing: The case of the city of madrid. *International Journal of Environmental Research and Public Health*, 18(21).  
<https://doi.org/10.3390/ijerph182111037>
- Tanveer, H., Balz, T., Cigna, F., & Tapete, D. (2020). Monitoring 2011-2020 traffic patterns in Wuhan (China) with COSMO-SkyMed SAR, amidst the 7th CISM military world games and COVID-19 outbreak. *Remote Sensing*, 12(10).  
<https://doi.org/10.3390/rs12101636>
- Tao, S., Rohde, D., & Corcoran, J. (2014). Examining the spatial-temporal dynamics of bus passenger travel behaviour using smart card data and the flow-comap. *Journal of Transport Geography*, 41, 21-36.  
<https://doi.org/10.1016/j.jtrangeo.2014.08.006>
- Tassone, J., & Choudhury, S. (2020). *A comprehensive survey on the ambulance*

- routing and location problems.* 1-30.  
<https://doi.org/https://doi.org/10.48550/arXiv.2001.05288> Focus to learn more
- TC Group Solutions. (2021). *Informe retail intelligence 2021.*  
<https://www.tcgroupsolutions.com/recurso/informe-retail-intelligence-2021/>
- Teixeira, J. C., & Antunes, A. P. (2008). A hierarchical location model for public facility planning. *European Journal of Operational Research*, 185(1), 92-104.  
<https://doi.org/10.1016/j.ejor.2006.12.027>
- Thomas, I. (2002). *Transportation networks and the optimal location of human activities: a numerical geography approach.* E. Elgar Pub.  
<https://ucm.on.worldcat.org/oclc/758174375>
- Toledo, M. (2013, septiembre 14). Transportes y la EMT reducirán los autobuses en circulación de 18 líneas urbanas de Madrid. *20Minutos.es.*  
<https://www.20minutos.es/noticia/1918743/0/autobuses-emt/madrid-transportes/18-lineas-circulacion/>
- Tomintz, M., Clarke, G. P., & Alfadhli, N. (2015). Location-allocation models. *Geocomputation. A practical primer*, 185-197.
- TomTom. (2020, noviembre 7). *Clasificación del índice de tráfico.*  
[https://www.tomtom.com/en\\_gb/traffic-index/madrid-traffic/](https://www.tomtom.com/en_gb/traffic-index/madrid-traffic/)
- Toregas, C., & ReVelle, C. (1972). Optimal location under time or distance constraints. En *Papers of the Regional Science Association*, 28(1), 131-143.  
<https://doi.org/10.1007/BF01961457>
- Toregas, C., Swain, R., ReVelle, C., & Bergman, L. (1971). The Location of Emergency Service Facilities. *Operations Research*, 19(6), 1363-1373.  
<https://doi.org/10.1287/opre.19.6.1363>
- Truelove, M. (1993). Measurement of Spatial Equity. *Environment and Planning C: Government and Policy*, 11(1), 19-34. <https://doi.org/10.1068/c110019>
- Tu, W., Li, Q., Fang, Z., Shaw, S. lung, Zhou, B., & Chang, X. (2016). Optimizing the locations of electric taxi charging stations: A spatial-temporal demand coverage approach. *Transportation Research Part C: Emerging Technologies*, 65(3688), 172-189. <https://doi.org/10.1016/j.trc.2015.10.004>

- Tu, W., Zhu, T., Xia, J., Zhou, Y., Lai, Y., Jiang, J., & Li, Q. (2020). Portraying the spatial dynamics of urban vibrancy using multisource urban big data. *Computers, Environment and Urban Systems*, 80, 101428. <https://doi.org/10.1016/j.compenvurbsys.2019.101428>
- Uno, T., Katagiri, H., & Kato, K. (2009). Competitive facility location with random demands. *AIP Conference Proceedings*, 1174(1), 83-93. <https://doi.org/10.1063/1.3256263>
- Verter, V., & Lapierre, S. (2002). Location of Preventive Health Care Facilities. *Operations Research and Health Care*, 43-76. [https://doi.org/10.1007/1-4020-8066-2\\_3](https://doi.org/10.1007/1-4020-8066-2_3)
- Vora, K. S., Yasobant, S., Sengupta, R., De Costa, A., Upadhyay, A., & Mavalankar, D. V. (2015). Options for optimal coverage of free C section services for poor mothers in indian state of Gujarat: Location allocation analysis using GIS. *PLoS ONE*, 10(9), 1-16. <https://doi.org/10.1371/journal.pone.0137122>
- Wang, W., Xu, Z., Sun, D., & Lan, T. (2021). Spatial optimization of mega-city fire stations based on multi-source geospatial data: A case study in beijing. *ISPRS International Journal of Geo-Information*, 10(5). <https://doi.org/10.3390/ijgi10050282>
- Wang, Y., Li, J., Zhao, X., Feng, G., & Luo, X. (Robert). (2020). Using Mobile Phone Data for Emergency Management: a Systematic Literature Review. *Information Systems Frontiers*, 22(6), 1539-1559. <https://doi.org/10.1007/s10796-020-10057-w>
- Wang, Z., He, S. Y., & Leung, Y. (2018). Applying mobile phone data to travel behaviour research: A literature review. *Travel Behaviour and Society*, 11, 141-155. <https://doi.org/10.1016/J.TBS.2017.02.005>
- Wichapa, N., & Khokhajaikiat, P. (2018). A hybrid multi-criteria analysis model for solving the facility location–allocation problem: A case study of infectious waste disposal. *Journal of Engineering and Technological Sciences*, 50(5), 699-719. <https://doi.org/10.5614/j.eng.technol.sci.2018.50.5.8>
- Wildman, S. (2018). *Social Media Definition and the Governance Challenge: An Introduction to the Special Issue. Telecommunications policy*, 39(9), 745-750.

<https://doi.org/10.2139/ssrn.2637879>

- Williams, S., White, A., Waiganjo, P., Orwa, D., & Klopp, J. (2015). The digital matatu project: Using cell phones to create an open source data for Nairobi's semi-formal bus system. *Journal of Transport Geography*, 49, 39-51. <https://doi.org/10.1016/J.JTRANGEO.2015.10.005>
- Wondwossen, M., & Bedasa, A. (2019). Location allocation analysis for urban public services using GIS techniques : A case of primary schools in Yeka sub-city, Addis, Ethiopia. *American Journal of Geographic Information System*, 8(1), 26-38. <https://doi.org/10.5923/j.ajgis.20190801.03>
- Wu, Y., Wang, L., Fan, L., Yang, M., Zhang, Y., & Feng, Y. (2020). Comparison of the spatiotemporal mobility patterns among typical subgroups of the actual population with mobile phone data: A case study of Beijing. *Cities*, 100(60), 102670. <https://doi.org/10.1016/j.cities.2020.102670>
- Xiong, Q., Liu, Y., Xing, L., Wang, L., Ding, Y., & Liu, Y. (2022). Measuring spatio-temporal disparity of location-based accessibility to emergency medical services. *Health and Place*, 74, 102766. <https://doi.org/10.1016/j.healthplace.2022.102766>
- Xu, D., Bian, Y., Rong, J., Wang, J., & Yin, B. (2019). Study on clustering of free-floating bike-sharing parking time series in Beijing subway stations. *Sustainability (Switzerland)*, 11(19), 1-20. <https://doi.org/10.3390/su11195439>
- Xu, H., Fang, D., & Jin, Y. (2018). *Emergency Logistics Theory, Model and Method: A Review and Further Research Directions*. 65, 188-192. <https://doi.org/10.2991/cimns-18.2018.42>
- Xu, J., Murray, A. T., Church, R. L., & Wei, R. (2022). A heuristic algorithm for balancing workloads in coverage modeling. *Computers, Environment and Urban Systems*, 92, 1-20. <https://doi.org/10.1016/j.compenvurbsys.2021.101746>
- Yamaguchi, K. (2011). Location of an undesirable facility on a network: A bargaining approach. *Mathematical Social Sciences*, 62(2), 104-108. <https://doi.org/10.1016/j.mathsocsci.2011.05.005>
- Yang, Jie, Dong, J., & Hu, L. (2017). A data-driven optimization-based approach for siting and sizing of electric taxi charging stations. *Transportation Research Part C: Emerging Technologies*, 77(2), 462-477.

<https://doi.org/10.1016/j.trc.2017.02.014>

- Yang, Jun, & Yang, C. (2005). The retail stores' competitive location problem with retail regional saturation. *2005 International Conference on Services Systems and Services Management, Proceedings of ICSSSM'05*, 2, 1511-1516. <https://doi.org/10.1109/icsssm.2005.1500252>
- Yang, L., Zhang, F., Kwan, M., Wang, K., Zuo, Z., & Xia, S. (2020). Space-time demand cube for spatial-temporal coverage optimization model of shared bicycle system : A study using big bike GPS data. *Journal of Transport Geography*, 88, 102861. <https://doi.org/10.1016/j.jtrangeo.2020.102861>
- Yang, Y., Heppenstall, A., Turner, A., & Comber, A. (2019). A spatiotemporal and graph-based analysis of dockless bike sharing patterns to understand urban flows over the last mile. *Computers, Environment and Urban Systems*, 77, 101361. <https://doi.org/10.1016/j.compenvurbsys.2019.101361>
- Yeh, A. G. O., & Chow, M. H. (1996). An integrated Gis and location-allocation approach to public facilities planning - An example of open space planning. *Computers, Environment and Urban Systems*, 20(4-5), 339-350. [https://doi.org/10.1016/S0198-9715\(97\)00010-0](https://doi.org/10.1016/S0198-9715(97)00010-0)
- Yin, P., & Mu, L. (2012). Modular capacitated maximal covering location problem for the optimal siting of emergency vehicles. *Applied Geography*, 34, 247-254. <https://doi.org/10.1016/j.apgeog.2011.11.013>
- Yong Gu, Lie Zhang, Wang, Z., & Yangyang Zheng. (2017). Bi - level planning model for NIMBY facility location problem. *Proceeding of the 36th Chinese control conference*, 7553-7558.
- Younes, H., Zou, Z., Wu, J., & Baiocchi, G. (2020). Comparing the Temporal Determinants of Dockless Scooter-share and Station-based Bike-share in Washington, D.C. *Transportation Research Part A: Policy and Practice*, 134, 308-320. <https://doi.org/10.1016/j.tra.2020.02.021>
- Yu, W., Guan, M., & Chen, Y. (2020). Fire stations siting with multiple objectives and geospatial big data. *Earth Science Informatics*, 14(1), 141-160. <https://doi.org/10.1007/s12145-020-00539-5>
- Yubero, C., Fontes, A. C., Condeço-Melhorado, A., & García-Hernández, M. (2021).

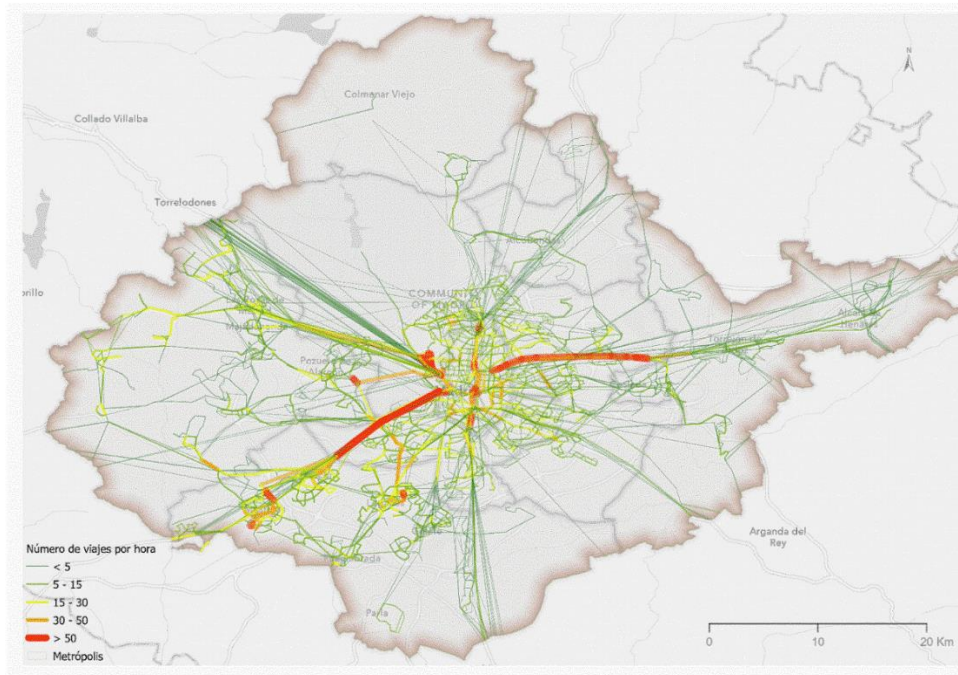
- Comparing spatial and content analysis of residents and tourists using Geotagged Social Media Data . The Historic Neighbourhood of Alfama ( Lisbon ), a case study.* *Investigaciones Turísticas*, 22, 95-120.  
<https://doi.org/10.14198/INTURI2021.22.5>
- Yue, Y., Lan, T., Yeh, A. G. O., & Li, Q. Q. (2014). Zooming into individuals to understand the collective: A review of trajectory-based travel behaviour studies. *Travel Behaviour and Society*, 1(2), 69-78.  
<https://doi.org/10.1016/J.TBS.2013.12.002>
- Zhang, J., & Meng, M. (2019). Bike allocation strategies in a competitive dockless bike sharing market. *Journal of Cleaner Production*, 233, 869-879.  
<https://doi.org/10.1016/j.jclepro.2019.06.070>
- Zhang, Ying, Zuidgeest, M., Brussel, M., Sliuzas, R., & Maarseveen, M. Van. (2013). Spatial Location-Allocation Modeling of Bike Sharing Systems : a Literature Search. In *13th World conference on transport research (WCTR), 15-18 July 2013, Rio de Janeiro, Brazil (pp. -)*. WCTR.  
[http://intranet.itc.nl/papers/2013/conf/zhang\\_spa.pdf](http://intranet.itc.nl/papers/2013/conf/zhang_spa.pdf)
- Zhang, Yongping, Lin, D., & Mi, Z. (2019). Electric fence planning for dockless bike-sharing services. *Journal of Cleaner Production*, 206, 383-393.  
<https://doi.org/10.1016/j.jclepro.2018.09.215>
- Zhou, L., Wang, S., & Xu, Z. (2020). A multi-factor spatial optimization approach for emergency medical facilities in Beijing. *ISPRS International Journal of Geo-Information*, 9(6). <https://doi.org/10.3390/ijgi9060361>
- Zhou, X., Yeh, A. G. O., & Yue, Y. (2018). Spatial variation of self-containment and jobs-housing balance in Shenzhen using cellphone big data. *Journal of Transport Geography*, 68, 102-108. <https://doi.org/10.1016/j.jtrangeo.2017.12.006>
- Zhu, Y., Du, Q., Tian, F., Ren, F., Liang, S., & Chen, Y. (2016). Location optimization using a hierarchical location-allocation model for trauma centers in Shenzhen, China. *ISPRS International Journal of Geo-Information*, 5(10), 190.  
<https://doi.org/10.3390/ijgi5100190>

# **ANEXOS**

## Anexo 1

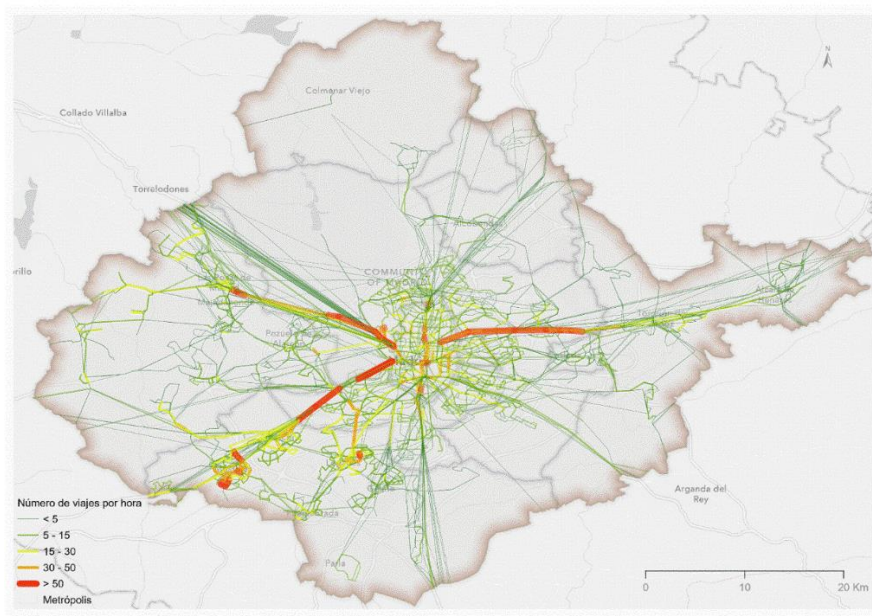
Frecuencias de viajes en transporte público los jueves y sábados durante las horas seleccionadas en la tesis.

Frecuencia de viajes los jueves a las 8:00 (GTFS)



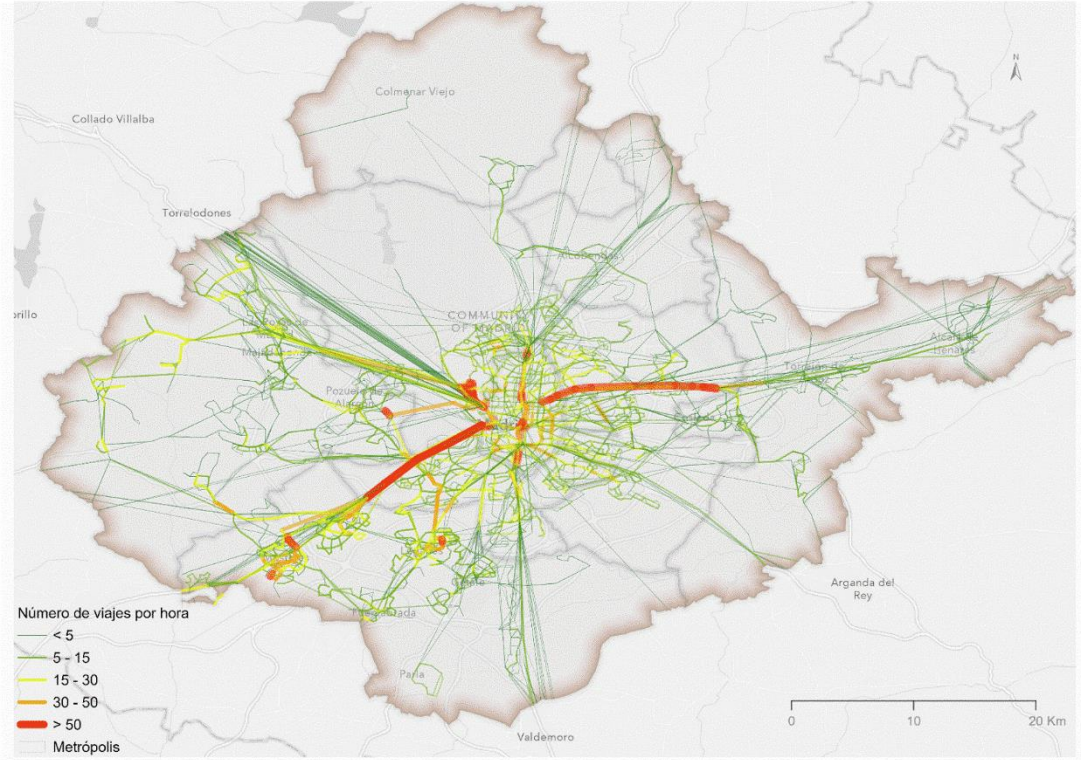
Fuente: Elaboración propia

Frecuencia de viajes los jueves a las 18:00 (GTFS)



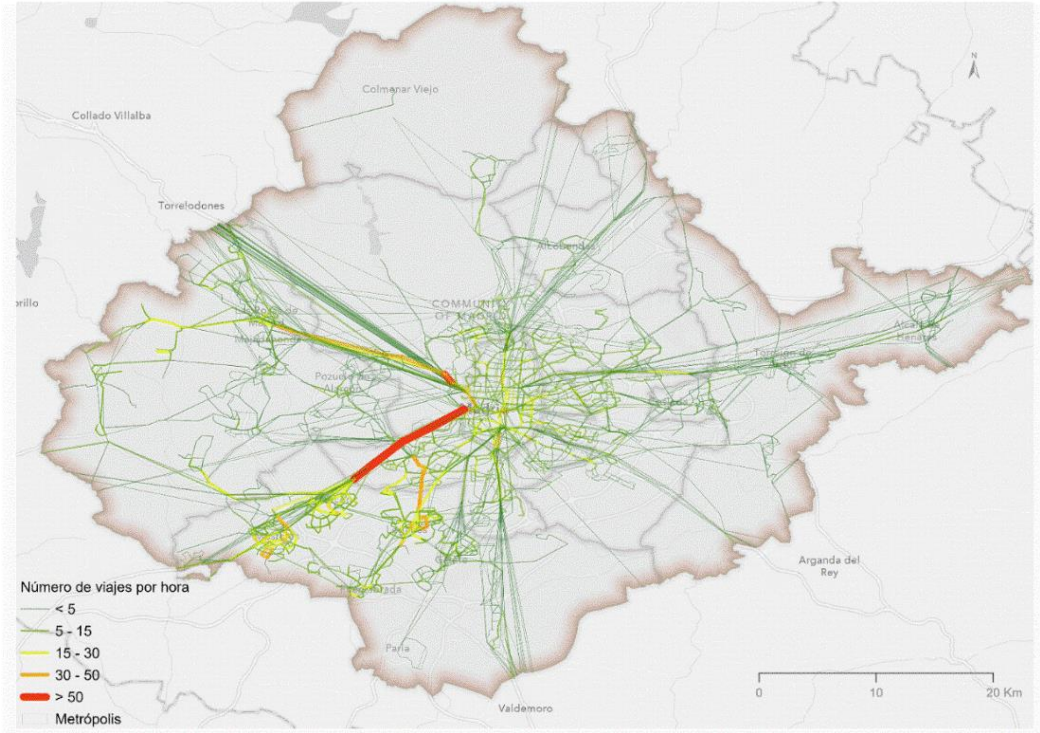
Fuente: Elaboración propia.

Frecuencia de viajes los sábados a las 8:00 (GTFS)



Fuente: Elaboración propia.

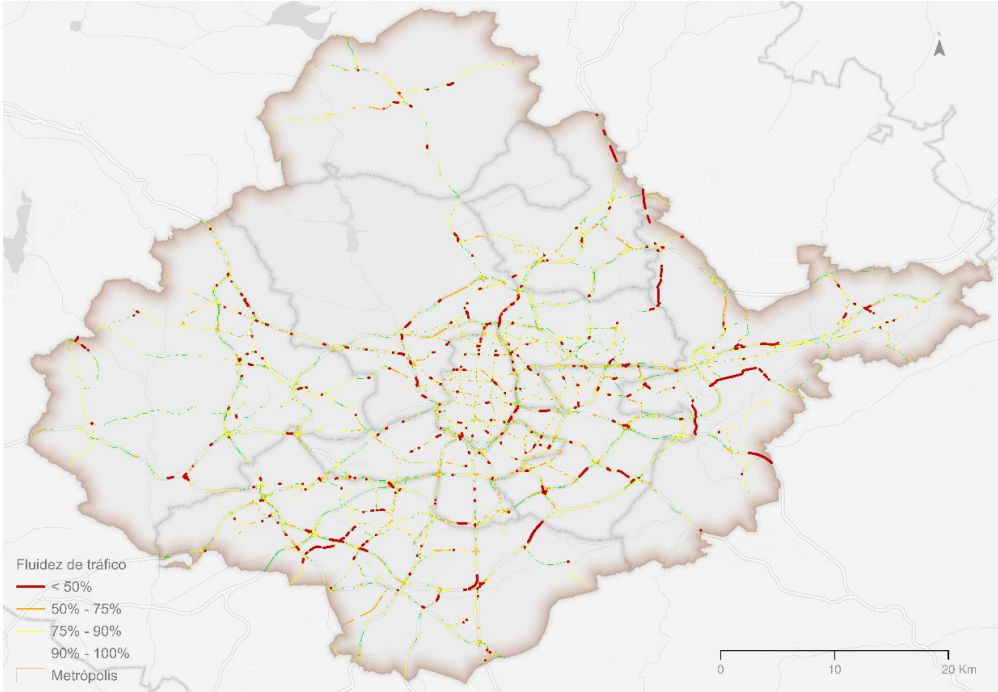
Frecuencia de viajes los sábados a las 18:00 (GTFS)



Fuente: Elaboración propia.

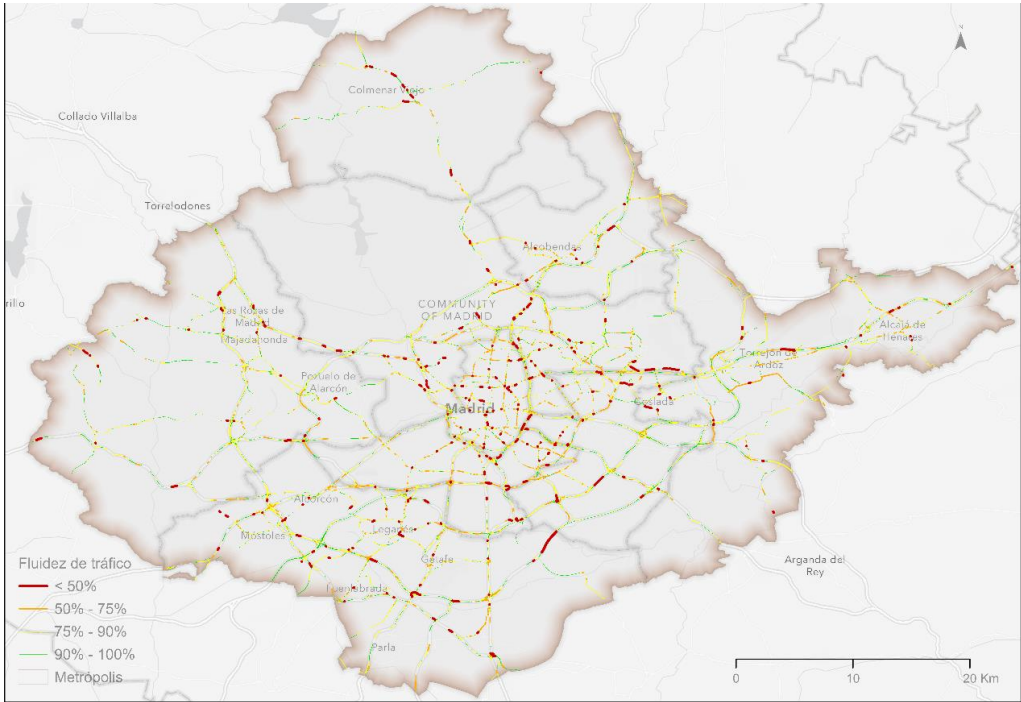
Anexo 2. Congestión vehicular los jueves y sábados durante las horas seleccionadas en la tesis.

Fluidez de tráfico los jueves a las 8:00 (TomTom)



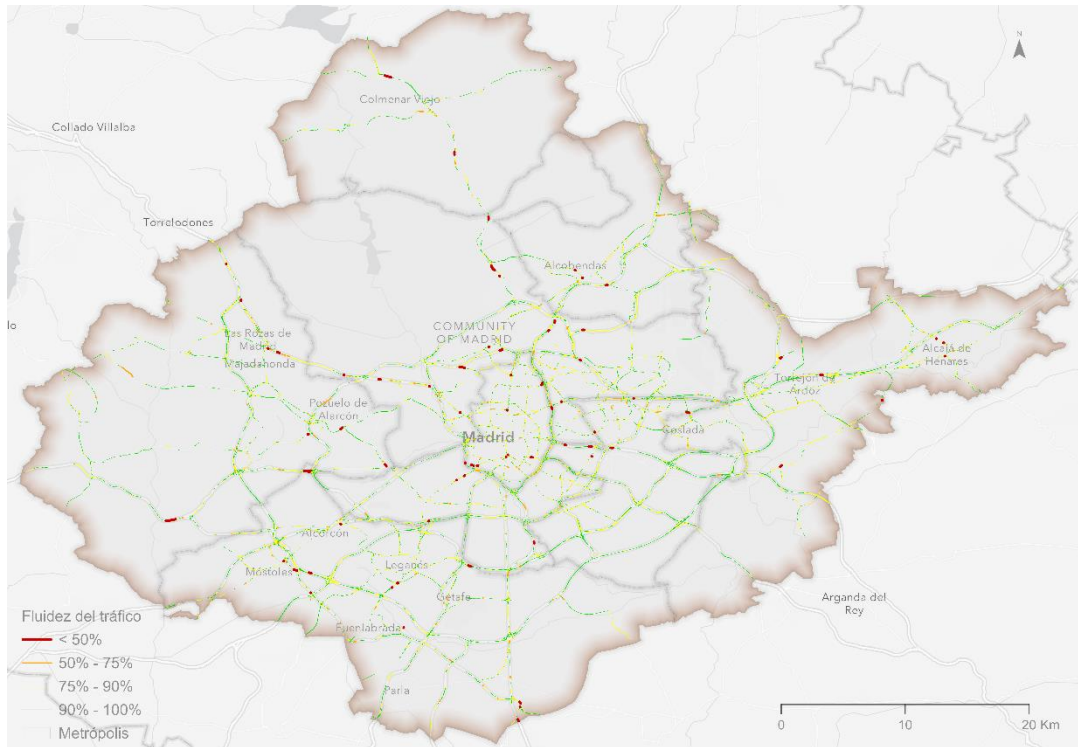
Fuente: Elaboración propia.

Fluidez de tráfico los jueves a las 18:00 (TomTom)



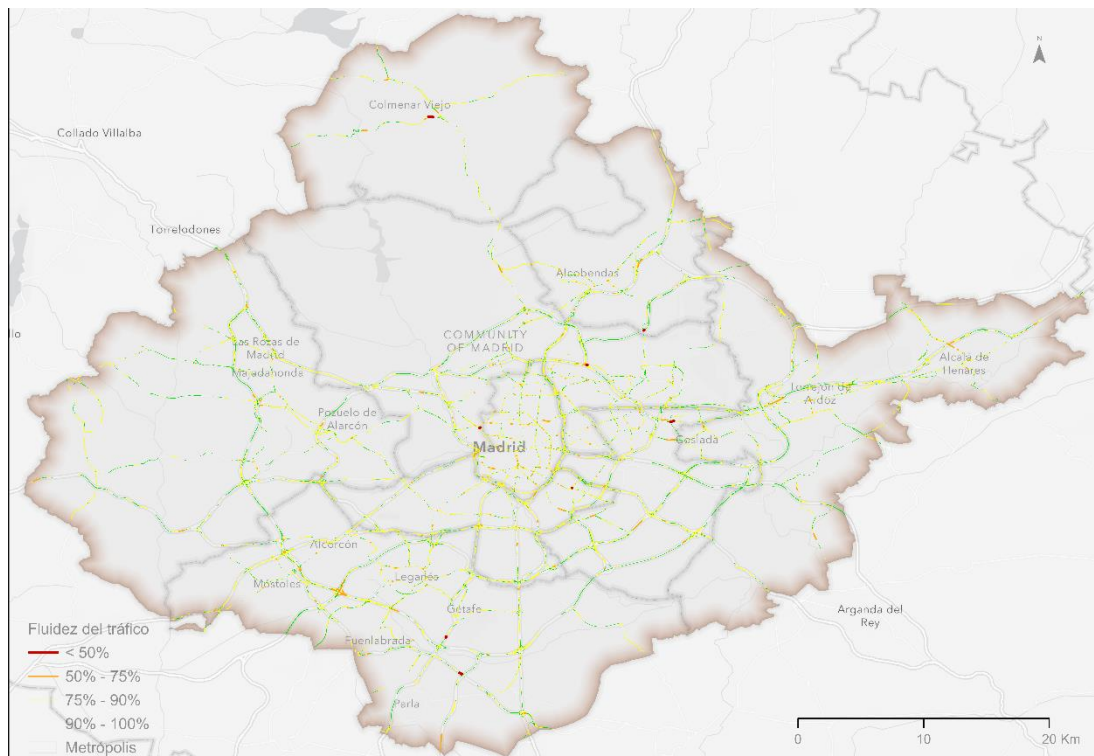
Fuente: Elaboración propia.

. Fluidez de tráfico los sábados a las 8:00 (TomTom)



Fuente: Elaboración propia.

. Fluidez de tráfico los sábados a las 18:00 (TomTom)



Fuente: Elaboración propia

Anexo 3. Script utilizado para correr los modelos de hospitales, centros comerciales (Adaptando un script de ESRI)

## Importar los módulos del sistema

```
import arcpy, os
from arcpy import env
import time
```

## Parámetros de la función

```
def OneLocationAllocationFunction (NumberOfFacilities,
                                   MinutesRecorrido,
                                   outNALayerName,
                                   outLayerFile,
                                   time_of_day):
    try:
        #Check out the Network Analyst extension license
        arcpy.CheckOutExtension("Network")

        #Ambiente de trabajo

        env.workspace = "C:/Users/OneL/Documents/Ayala2/GTFS.gdb"# Carpeta de trabajo##
        env.overwriteOutput = True

        #VARIABLES locales
        inNetworkDataset = "Madrid_GTFS_oryg/Madrid_GTFS_oryg_ND" #"Dataset de red" #
        impedanceAttribute = "TravelTime_WithTransit"#"Impedancia#"
        inFacilities = "Analysis/Hospitales_areas_salud2" # candidatos
        # activar en caso de usar instalaciones requeridas
        #requiredFacility = "Analysis/Hospitales_areas_salud2"
        inDemandPoints = "Analysis/Puntos_demanda" # demanda

        # Crear la capa de localización-asignación
        outNALayer = arcpy.na.MakeLocationAllocationLayer(inNetworkDataset,
                                                         outNALayerName,
                                                         impedanceAttribute,
                                                         "DEMAND_TO_FACILITY",
                                                         "MAXIMIZE_ATTENDANCE", #Tipo de solución
                                                         NumberOfFacilities, #Cantidad de instalaciones
                                                         MinutesRecorrido, # Tiempo de recorrido
                                                         "LINEAR",
                                                         UTurn_policy="ALLOW_UTURNS", #Política de giros
                                                         hierarchy="NO_HIERARCHY", #Jerarquía
                                                         output_path_shape="STRAIGHT_LINES",
                                                         time_of_day=time_of_day)

        #Obtener la capa de localización creada.

        outNALayer = outNALayer.getOutput(0)

        #subcapas de candidatos y demanda de la capa de localización -asignación.

        subLayerNames = arcpy.na.GetNAClassNames(outNALayer)
        facilitiesLayerName = subLayerNames["Facilities"]
        demandPointsLayerName = subLayerNames["DemandPoints"]
```

```

#Cargar los sitios candidatos y los campos de ponderación

CandidateFieldMappings = arcpy.na.NAClassFieldMappings(outNALayer, facilitiesLayerName)
CandidateFieldMappings["Name"].mappedFieldName = "Name"
arcpy.na.AddLocations(outNALayer, facilitiesLayerName, inFacilities,
CandidateFieldMappings, "5000 Meters",
"Name",
"Connectors_Stops2Streets NONE;
Streets_UseThisOne SHAPE;
TransitLines NONE;
Stops NONE;
Stops_Snapped2Streets NONE;
GTFS_MADRID_ND_Junctions NONE",
"MATCH_TO_CLOSEST",
"APPEND",
"NO_SNAP",
"5 Meters",
"EXCLUDE",
"Connectors_Stops2Streets #;
Streets_UseThisOne #;
TransitLines #;
Stops #;
Stops_Snapped2Streets #;
GTFS_MADRID_ND_Junctions #")

# Cargar instalaciones requeridas en modelos donde se utilice esta opción

#RequeridaFieldMappings = arcpy.na.NAClassFieldMappings(outNALayer, facilitiesLayerName)
#RequeridaFieldMappings["FacilityType"].defaultValue = 1
#arcpy.na.AddLocations(outNALayer, facilitiesLayerName, requiredFacility,
#RequeridaFieldMappings, "5000 Meters", "Name",
# "Connectors_Stops2Streets NONE;
#Streets_UseThisOne SHAPE;TransitLines NONE;
#Stops NONE;
#Stops_Snapped2Streets NONE;
#GTFS_MADRID_ND_Junctions NONE",
# "MATCH_TO_CLOSEST",
#"APPEND", "NO_SNAP",
#"5 Meters",
#"EXCLUDE",
# "Connectors_Stops2Streets #;
#Streets_UseThisOne #;
#TransitLines #;
#Stops #;
#Stops_Snapped2Streets
#;GTFS_MADRID_ND_Junctions #")

```

```

#Cargar los puntos de demanda
#En este caso utilizamos el campo POP2000.
demandFieldMappings = arcpy.na.NAClassFieldMappings(outNALayer,
demandPointsLayerName)
demandFieldMappings["Weight"].mappedFieldName = "POB2000"
arcpy.na.AddLocations(outNALayer, demandPointsLayerName, inDemandPoints,
demandFieldMappings, "",
exclude_restricted_elements = "EXCLUDE")

#Resuelve la capa de localización -asignación
arcpy.na.Solve(outNALayer)

# Guarda temporalmente la capa generada

```

```

arcpy.management.SaveToLayerFile(outNALayer,outLayerFile,"RELATIVE")

print "Script completed successfully"

except Exception as e:
    # If an error occurred, print line number and error message
    import traceback, sys
    tb = sys.exc_info()[2]
    print "An error occured on line %i" % tb.tb_lineno
    print str(e)

```

## Definir lista de días, horas, número de instalaciones,cantidad de minutos

```

ListOfDay = [("8/3/2018", "Jueves"), ("10/3/2018", "Sabado")]#, ("5/4/1970", "Domingo")]
ListOfHours = ["8:00 AM", "10:00 AM", "12:00 PM", "14:00 PM", "16:00 PM", "18:00 PM", "20:00 PM"]
ListNumberFacilities = [9]#, 35, 41]
ListTimeMinutes = [30]#, 50]
# Ciclo for para la busqueda del día, la hora, el número de instalaciones, etc
for selectedday in ListOfDay:
    for selectedhour in ListOfHours:
        for numberFacilities in ListNumberFacilities:
            for timeMinutes in ListTimeMinutes:
                outNALayerName = "NewStoreLocations"+"_" +
                selectedday[1] + "_" +
                str(selectedhour).replace(":", "-") + "_" +
                str(numberFacilities) + "_" +
                str(timeMinutes) + "_" + str(time.time())
                outLayerFile = os.path.join("C:/Users/Onel/Carpeta",
                outNALayerName + ".lyr")
                time_of_day = selectedday[0] + " " + selectedhour
                now = time.time()
                OnelLocationAllocationFunction(numberFacilities,
                timeMinutes,
                outNALayerName,
                outLayerFile,
                time_of_day)
                then = time.time() # time object
                total = then - now
                print(total)

```