

**UNIVERSIDAD COMPLUTENSE DE MADRID**  
**FACULTAD DE ESTUDIOS ESTADÍSTICOS**



**TESIS DOCTORAL**

**Gestión estratégica de atención al cliente mediante modelos  
lingüísticos difusos, modelos de decisión y machine learning.  
Aplicación práctica en entornos B2C y B2B**

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

**Gabriel Marín Díaz**

Directores

**Ramón Alberto Carrasco González**

**Daniel Gómez González**

**Carlos Gregorio Rodríguez**

Madrid

**UNIVERSIDAD COMPLUTENSE DE MADRID**  
**FACULTAD DE ESTUDIOS ESTADÍSTICOS**



**TESIS DOCTORAL**

**Gestión estratégica de atención al cliente mediante modelos lingüísticos difusos, modelos de decisión y machine learning. Aplicación práctica en entornos B2C y B2B**

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

**Gabriel Marín Díaz**

DIRECTORES

**Ramón Alberto Carrasco González, Daniel Gómez González, Carlos Gregorio Rodríguez**

Madrid, 2022

**UNIVERSIDAD COMPLUTENSE DE MADRID**

Facultad de Estudios Estadísticos

Doctorado en Análisis de Datos (Data Science)



**TESIS DOCTORAL**

**Gestión estratégica de atención al cliente mediante modelos lingüísticos difusos, modelos de decisión y machine learning. Aplicación práctica en entornos B2C y B2B**

MEMORIA PARA OPTAR AL GRADO DE DOCTOR

PRESENTADA POR

**Gabriel Marín Díaz**

DIRECTORES

**Ramón Alberto Carrasco González, Daniel Gómez González, Carlos Gregorio Rodríguez**

Madrid, junio de 2022

*A mi padre, aprendimos todos innumerables valores, te echamos mucho de menos.*

*A mi madre, la más apreciada abuela.*

*A mi mujer e hijos por demostrarme tanto cariño.*

*Y a todos mis amigos, por estar ahí en todo momento.*

# Agradecimientos

*“Solo a base de trabajar duro puede  
descubrirse algo.”*

*Richard Feynman*

Hace unos tres años aproximadamente mi gran amigo Miguel Ángel Blanco me invitó a la Facultad de Estudios Estadísticos, él daba clases allí, yo le comenté las ganas que tenía de dedicarme a la enseñanza, tenía ganas de dar un giro a mi carrera profesional.

La verdad es que llevaba mucho tiempo con ganas de dedicarme a esto de la docencia, allá por el año 2006 terminé el CAP con esa intención, pero avatares del destino me llevaron a montar no una, varias empresas, vamos que me gusta estar entretenido.

En fin, que acabamos en la Facultad de Estudios Estadísticos y allí conocí a Concepción Latorre, Vicedecana de Posgrado y Relaciones Internacionales. Quería empezar las cosas bien y comenté las ganas de dedicarme a la docencia y las ganas de hacer el doctorado en Ciencia de Datos. Y en nada de tiempo contacté con Ramón Carrasco, que me propuso investigar en una línea que yo por aquel entonces había oído algo hablar, pero desconocía, me dijo, “yo te veo haciendo la tesis en teoría de la decisión”. Así que me puse a ello, y aquí estamos.

En el camino tuve la fortuna de que saliera una plaza de profesor asociado en la Facultad de Informática, para dar clase en la misma Facultad de Estudios Estadísticos, solicité la plaza, y no la obtuve, pero me quedé en la reserva. Así que estando con mi gran amigo Ramón Carrasco, me llaman de la Facultad de Informática diciéndome que la plaza estaba disponible. Asentí enseguida, así que este es mi tercer año dedicado a la enseñanza en la Universidad Complutense.

He conocido a grandes profesores y amigos, no me querría dejar a nadie, así que empiezo por la cercanía de despacho con mi amiga María Isabel Riomoros, gran ayuda y soporte en todo momento, muchísimas gracias por estar siempre ahí.

Gracias a Cristóbal Pareja, decano de la Facultad de Estudios Estadísticos, por esos momentos de conversaciones que podemos tener muy de vez en cuando y que por falta de tiempo no las podemos prodigar un poco más.

Gracias a Daniel Gómez y Carlos Gregorio Rodríguez codirectores de la tesis, y a Concepción Latorre que siempre me han animado a seguir, dándome todo su apoyo y confianza.

Y me dejo para el final a mis dos grandes amigos, José Javier Galán, que lleva camino de leer la tesis en menos tiempo que yo, gracias por estar siempre atento y con esas ganas que se contagian. Y por supuesto a Ramón Carrasco, no estaría donde estoy si no es por él, por su ánimo, sus ganas y su gran ayuda.

Gracias a mi mujer Marisa y mis hijos Raquel, Daniel y Gabriel. Siento que me he perdido en estos años un poco de vosotros, pero espero compensarlo con más tiempo y dedicación.

Y por supuesto mi familia, mis hermanos a los que también quiero dedicar este trabajo, siempre han estado dando apoyo a toda la familia. Y especialmente mis padres, Gabriel y Carmen, me han enseñado el valor del trabajo, de la educación, del respeto, de la entrega, de la responsabilidad y también de la confianza.

No quiero olvidarme tampoco de mis grandes amigos, excompañeros de trabajo, Santi, Mónica y Sandra cada vez que quedamos hace que mi día cambie.

Y por último mis amigos de la Facultad de Ciencias Físicas, amigos de antes y de ahora, lástima que no nos podemos ver más a menudo, prefiero no nombrar a todos porque posiblemente me olvide de alguno.

A todos vosotros, gracias.



# Índice general de la memoria

Agradecimientos.....	2
Índice general de la memoria .....	6
Resumen.....	14
Abstract .....	19
Motivación .....	23
1. Estructura de la memoria .....	30
2. Introducción.....	33
2.1 Objetivos.....	37
3. Análisis del estado actual y estudios relacionados .....	39
3.1 Introducción.....	39
3.1.1 Conocimiento avanzado del cliente .....	40
3.1.2 Omnicanalidad.....	41
3.1.3 Calidad del servicio.....	42
3.1.4 Vinculación y fidelización .....	43
3.1.5 Integración tecnológica.....	43
3.2 Customer Service, Métricas .....	44
3.3 Estudios y usos del modelo RFM.....	45
3.3.1 Ventajas y limitaciones del modelo RFM .....	49
3.3.2 Ampliación del modelo RFM.....	50
3.4 Interpretabilidad en Machine Learning .....	51
3.4.1 Iniciativas hacia una IA Interpretable .....	58
3.4.1.1 Empresas tecnológicas.....	58
3.4.1.2 Legislación, Organismos y Documentos regulatorios.....	60
3.4.1.3 Ciencia e Investigación .....	62
3.4.2 Indicadores de Interpretabilidad .....	64
4. Marco teórico de la investigación .....	66
4.1 Modelo Lingüístico Difuso 2-Tupla .....	66
4.2 Modelo RFM .....	69
4.3 Modelo AHP .....	71
4.3.1 Estructuración del problema de decisión en un modelo jerárquico .....	73
4.3.2 Comparaciones por pares y obtención de la matriz de valoración.....	74
4.3.3 Obtención de ponderaciones locales y revisión de la coherencia de las comparaciones .....	75
4.4 Tratamiento de Información Heterogénea .....	76
4.5 Interpretabilidad en Modelos de Machine Learning .....	79
4.5.1 Diagrama de Dependencia Parcial (PDP).....	83
4.5.2 Curvas de Expectativa Condicional Individual (ICE).....	84
4.5.3 Cálculo de la Importancia de las Características .....	86
4.5.4 Sustituto Local LIME.....	87
4.5.5 SHAP .....	89
5. Planteamiento metodológico .....	92
5.1 Nuevo modelo RFID .....	93

---

5.1.1	Obtención de datos.....	95
5.1.2	Preprocesado .....	97
5.1.3	Agregación.....	97
5.1.4	Cálculo de las puntuaciones .....	98
5.1.5	Cálculo de la puntuación global para RFID .....	98
5.1.5.1	Estructurando el problema de decisión en un modelo jerárquico .....	99
5.1.5.2	Matriz de comparación por pares .....	99
5.1.5.3	Obtención de ponderaciones locales y consistencia de las comparaciones.....	99
5.1.6	Estrategia de recomendación individualizada .....	100
5.1.7	Segmentación de clientes.....	100
5.1.8	Estrategia de recomendación grupal.....	102
5.2	Nuevo modelo VIUE .....	102
5.2.1	Obtención de datos.....	104
5.2.2	Dominio CBTL .....	106
5.2.3	Cálculo de las puntuaciones .....	107
5.2.4	Cálculo de la puntuación global para VIUE .....	108
5.2.5	Priorización y personalización.....	108
5.3	Aplicación de XAI a la tasa de abandono de cliente .....	110
5.3.1	Obtención de datos.....	112
5.3.2	Predicción de abandono de clientes .....	113
5.3.3	Análisis de interpretabilidad de ML .....	115
6.	Aplicación práctica del modelo RFID para la valoración de clientes en su relación con el Contact Center .....	120
6.1	Aplicación del modelo RFID a la industria de Telecomunicaciones (B2C) ....	120
6.1.1	Obtención de datos.....	120
6.1.2	Preprocesado .....	121
6.1.3	Agregación.....	122
6.1.4	Cálculo de las puntuaciones .....	122
6.1.5	Cálculo de la puntuación global para RFID .....	123
6.1.6	Estrategia de recomendación individualizada .....	124
6.1.7	Segmentación de clientes.....	125
6.1.8	Estrategia de recomendación grupal.....	128
6.1.9	Conclusiones.....	134
6.2	Aplicación del modelo RFID a la industria de la comercialización de licencias de software (B2B) .....	137
6.2.1	Obtención de datos.....	137
6.2.2	Preprocesado .....	137
6.2.3	Agregación.....	138
6.2.4	Cálculo de las puntuaciones .....	139
6.2.5	Cálculo de la puntuación global para RFID .....	140
6.2.6	Estrategia de recomendación individualizada .....	141
6.2.7	Segmentación de clientes.....	142
6.2.8	Estrategia de recomendación grupal.....	144
6.2.9	Conclusiones.....	148

---

7.	Aplicación práctica del modelo VIUE, priorización y personalización en la interacción cliente y marca .....	151
7.1	Aplicación del modelo VIUE en un entorno B2B.....	151
7.1.1	Obtención de datos.....	151
7.1.2	Selección del dominio CBTL.....	153
7.1.3	Cálculo de las puntuaciones .....	154
7.1.4	Cálculo de la puntuación global para VIUE .....	155
7.1.5	Priorización de Tickets .....	157
7.1.6	Conclusiones.....	163
8.	Aplicación de Modelos Agnósticos Interpretables en la Toma de Decisiones	166
8.1	Obtención, Procesamiento y Transformación de Datos .....	168
8.2	Evaluación de Algoritmos de ML .....	170
8.3	Desbalanceo de Datos.....	172
8.4	Aplicación de las Técnicas de Interpretabilidad .....	174
8.4.1	Diagrama de Dependencia Parcial (PDP).....	175
8.4.2	Cálculo de la Importancia de las Características (ELI5).....	177
8.4.3	Sustituto Local (LIME) .....	178
8.4.4	Valores de SHAP.....	179
8.4.5	Skater .....	180
8.4.6	FairML .....	182
8.5	Conclusiones.....	182
9.	Conclusiones, contribuciones y futuras áreas de investigación.....	185
9.1	Reflexión General sobre la Investigación. ....	185
9.2	Análisis de objetivos enunciados y contribuciones conseguidas.....	189
9.3	Futuras líneas de investigación.....	196
10.	Bibliografía.....	198

# Índice de tablas

Tabla 1. Métricas Customer Services .....	45
Tabla 2. Estudios relacionados con el CLV .....	46
Tabla 3. Estudios CLV y su aplicación a sectores y modelos de negocio .....	49
Tabla 4. Métodos Interpretables .....	63
Tabla 5. Estudios Interpretabilidad ML.....	63
Tabla 6. Escala Saaty (Thomas L. Saaty, 2008).....	75
Tabla 7. Valores de consistencia aleatoria en función del tamaño de la matriz. (Thomas L. Saaty, 2008).....	76
Tabla 8. Límites de consistencia (Saaty, 2008) .....	76
Tabla 9. Algoritmos de ML aplicados al modelo .....	114
Tabla 10. Extracto del conjunto T' .....	121
Tabla 11. Extracto del conjunto TU .....	122
Tabla 12. Extracto del conjunto TRFID .....	123
Tabla 13. Puntuación global RFID para algunos clientes.....	124
Tabla 14. Puntuación global RFID detallada para algunos clientes .....	124
Tabla 15. Número de clústeres propuestos por diferentes índices.....	127
Tabla 16. Resultados del algoritmo k-means .....	128
Tabla 17. Resultados del algoritmo k-means expresados en el modelo 2-tupla .....	128
Tabla 18. Estrategia de recomendación para cada clúster .....	129
Tabla 19. Valor de <i>RFID<sub>c</sub></i> para algunos clientes .....	131
Tabla 20. Extracto del conjunto T' .....	138
Tabla 21. Extracto del conjunto TU .....	139
Tabla 22. Extracto del conjunto TRFID .....	140
Tabla 23. Puntuación global RFID detallada para algunos clientes .....	141
Tabla 24. Puntuación detallada RFID para clientes a priori de especial cuidado .....	142
Tabla 25. Resultados del algoritmo k-means .....	144
Tabla 26. Resultados del algoritmo k-means expresados en el modelo 2-tupla .....	145
Tabla 27. Estrategia de recomendación para cada clúster .....	145
Tabla 28. Clientes en cada clúster, y tasa de abandono por clúster.....	148
Tabla 29. Valoración del cliente, RFID.....	153
Tabla 30. Matriz de interacciones VIUE .....	154
Tabla 31. Valoración VIUE .....	155
Tabla 32. Puntuación global VIUE detallada para algunos clientes.....	156
Tabla 33. Puntuación global ordenada VIUE, detallada para algunos clientes .....	158
Tabla 34. Valoración VIUE extendida.....	159
Tabla 35. Valoración VIUE extendida, 2-tupla .....	160
Tabla 36. Puntuación global extendida VIUE para algunos clientes.....	161
Tabla 37. Descripción del conjunto RFIDT.....	168
Tabla 38. Descripción RFIDT, aplicando <i>MinMaxScaler</i> (0,5) .....	170
Tabla 39. Evaluación de algoritmos de predicción aplicados.....	171
Tabla 40. Importancia de cada característica (ELI5) .....	178

# Índice de figuras

Figura 1. Relaciones entre los tres modelos propuestos.....	36
Figura 2. Definición de CEV (Kumar et al., 2010).....	40
Figura 3. Evolución del Contact Center (Ryu & Kim, 2018).....	42
Figura 4. Modelo tecnológico Customer Centric.....	44
Figura 5. Etapas modelado RFM (Ramón Alberto Carrasco et al., 2019).....	69
Figura 6. Definición del conjunto S.....	70
Figura 7. Clasificación de los Problemas de TD.....	72
Figura 8. Ejemplo de estructura jerárquica AHP.....	74
Figura 9. Modelo de unificación de información heterogénea en valoraciones lingüísticas 2-tupla (F. Herrera et al., 2005).....	77
Figura 10. Transformación de un valor numérico, 0.32, a $F(S)$ .....	78
Figura 11. Transformación de un valor intervalar, [0.32, 0.64] a $F(S)$ .....	78
Figura 12. Transformación de un término lingüístico.....	79
Figura 13. Interpretabilidad vs Flexibilidad. Fuente: (Duval, 2019).....	82
Figura 14. Ejemplo PDP. Análisis abandono de empleados, característica: OverTime.....	84
Figura 15. Curvas ICE. Análisis abandono de empleados, característica: OverTime.....	85
Figura 16. Importancia de las características (ELI5) – Análisis de abandono de empleados.....	87
Figura 17. Sustituto local LIME – Análisis abandono de empleados (abandono = no).....	89
Figura 18. Sustituto local LIME – Análisis abandono de empleados (abandono = sí).....	89
Figura 19. Importancia de las características SHAP – Análisis abandono de empleados.....	91
Figura 20. SHAP - Predicción individual, abandono = no.....	91
Figura 21. SHAP - Predicción individual, abandono = sí.....	91
Figura 22. Esquema general de los tres modelos propuestos.....	93
Figura 23. Modelo RFID.....	95
Figura 24. Apertura de un caso en Salesforce CRM.....	96
Figura 25. Modelo Jerárquico AHP.....	99
Figura 26. Modelo VIUE.....	104
Figura 27. Transformación de un término lingüístico, $s_1$ a $F(S)$ .....	108
Figura 28. Etapas modelo KDD (Shafique & Qaiser, 2014).....	112
Figura 29. Ejemplo curva ROC/AUC aplicado al abandono de clientes.....	115
Figura 30. Algoritmos empleados para la interpretabilidad de ML.....	116
Figura 31. Gráfica univariante modelo PDP – Importance (RFID).....	116
Figura 32. Gráfica ICE.....	117
Figura 33. Gráfica ELI5.....	117
Figura 34. Gráfica LIME.....	118
Figura 35. Gráfica SHAP.....	118
Figura 36. Gráfica Skater.....	118
Figura 37. Gráfica FairML.....	119
Figura 38. Salesforce CRM. Modelo de datos para la gestión de tickets.....	121
Figura 39. Matriz de correlación.....	126
Figura 40. Determinación del número óptimo de segmentos.....	127
Figura 41. Distribución de clientes por segmento.....	129

---

Figura 42. Distribución de incidencias según prioridad .....	139
Figura 43. Matriz de correlación.....	143
Figura 44. Técnica del codo para la selección del número óptimo de clústeres .....	143
Figura 45. Algoritmo en Python, técnica del coeficiente de silueta.....	144
Figura 46. # incidencias / mes en el año 2020.....	152
Figura 47. Clientes por clúster que han abandonado (Type = 1).....	166
Figura 48. Número total de clientes (Partner / Abandono) .....	167
Figura 49. Tipos de valores de la columna Type.....	168
Figura 50. Recencia y Frecuencia de transacciones por cliente .....	169
Figura 51. Importancia y Duración de transacciones por cliente.....	169
Figura 52. Matriz de correlación.....	170
Figura 53. Curva ROC / AUC del modelo balanceado.....	171
Figura 54. Evaluación de predicciones XGBoost, datos no balanceados .....	173
Figura 55. Evaluación de predicciones XGBoost, con datos balanceados .....	174
Figura 56. Diagrama de dependencia parcial PDP (Recencia).....	175
Figura 57. Diagrama de dependencia parcial PDP (Frecuencia) .....	175
Figura 58. Diagrama de dependencia parcial PDP (Duración).....	176
Figura 59. Diagrama de interacción parcial PD bivalente (Frecuencia, Recencia).....	176
Figura 60. Gráfico ICE (Duración).....	177
Figura 61. Predicción de abandono en función de las características (Abandono (No)).....	178
Figura 62. Predicción de abandono en función de las características (Abandono (Sí)) .....	179
Figura 63. Importancia de las características SHAP .....	179
Figura 64. Predicción de valores de SHAP (Abandono (Sí)) .....	179
Figura 65. Predicción de valores de SHAP (Abandono (No)) .....	180
Figura 66. Importancia de las características Skater .....	180
Figura 67. Gráficos de dependencia con Skater.....	181
Figura 68. Gráficos de dependencia con FairML .....	182

# Índice de nomenclaturas

AHP	Proceso Analítico Jerárquico
AUC	Area Under The Curve
B2B	Business to Business
B2C	Business to Customer
BI	Business Intelligence
CBTL	Conjunto Básico de Términos Lingüísticos
CES	Customer Effort Score
CEV	Customer Engagement Value
CIV	Customer Influencer Value
CJM	Customer Journey Map
CKV	Customer Knowledge Value
CRM	Customer Relationship Management
CRV	Customer Referral Value
CSAT	Customer Satisfaction Score
CSV	Customer Service Value
DL	Deep Learning
ERP	Enterprise Resource Planning
EVIUE	Extended VIUE
FCRR	Incremento en la resolución de incidencias en primera llamada
FPR	Ratio de falsos positivos
IA	Inteligencia Artificial
ICE	Curvas de Expectativa Condicional Individual
ITIL	Information Technology Infrastructure Library
KDD	Metodología Knowledge Discovery Databases
LD2T	Lógica Difusa 2-tupla
MCDM	Problemas de decisión multicriterio (Multi-Criteria Decision-Making)
ML	Machine Learning
NPS	Net Promote Score
PDP	Diagrama de Dependencia Parcial
RFID	Modelo RFID, basado en Recencia, Frecuencia, Importancia y Duración
RFM	Modelo RFM, basado en Recencia, Frecuencia y Monetario
RNA	Redes Neuronales Artificiales
ROC	Receiver Operating Characteristic
RPA	Automatización Robótica de Procesos
SLA	Service Level Agreement
TD	Toma de Decisión
TDG	Toma de Decisión en Grupo
TMO	Tiempo Medio de Operación
TMS	Líneas Alternativas de Razonamiento
TPR	Ratio de verdaderos positivos
VIUE	Modelo VIUE, basado en Valor del Cliente, Importancia, Urgencia y Emoción
XAI	Inteligencia Artificial Explicable



## Resumen

En el último decenio hemos asistido a lo que se conoce como 4ª Revolución Industrial. Entre los factores que han contribuido a este cambio están entre otros la capacidad de almacenamiento y procesamiento de información, además de la velocidad de las comunicaciones.

Desde el punto de vista del consumidor, esta irrupción digital está transformando la forma en la que los usuarios se relacionan con las marcas. Y en este sentido, cada segmento de población, cada cliente define su propio mapa de viaje (en inglés Customer Journey Map) en su relación con la marca (Lemon & Verhoef, 2016), creando de esta forma una mayor comprensión de la experiencia del cliente y de su viaje a través de sus distintas interacciones a través de cualquier canal. Por otro lado, atraer a los clientes es importante, pero más aún es poder retenerlos, las estrategias de marketing están focalizadas en este proceso de retención de los clientes más rentables.

Todo esto ha supuesto para las empresas un importante cambio de paradigma, pasando de una aproximación centrada en el producto a otra donde el cliente pasa a ser el centro de su estrategia, en inglés Customer Centric. Conceptos como Transformación Digital e Industria 4.0 (Oztemel & Gursev, 2020), entre otros aspectos tienen en cuenta este empoderamiento del consumidor, y esta aproximación centrada en el cliente (V. Kumar & Reinartz, 2012). En este modelo, cobra especial relevancia la comunicación bidireccional entre cliente y marca, donde el marketing y el servicio de atención al cliente personalizados son fundamentales en la definición de una estrategia de reconocimiento de marca y de fidelización, logrando una mayor retención de clientes y en consecuencia mayor rentabilidad para la empresa.

Existen diversos modelos que intentan rentabilizar el proceso de gestión de clientes desde un punto de vista de marketing y ventas, intentando fidelizar al mismo. En este

sentido, uno de los modelos más utilizados es el RFM (A. M. Hughes, 1994), está basado en los siguientes parámetros de venta (Recencia, Frecuencia y Monetario). Este modelo se utiliza para la segmentación del cliente de tal manera que permite focalizar acciones de marketing de venta cruzada (Cross Selling), o de venta incremental (Up Selling) sobre el cliente de acuerdo con la categoría o el segmento al que pertenezca.

Un aspecto crucial de la filosofía Customer Centric es considerar que las comunicaciones entre empresa y cliente son bidireccionales y que el cliente desea ser atendido de forma íntegra, consistente y a través de cualquier canal. La importancia de la tecnología sumada a la estrategia es fundamental, así los sistemas basados en Customer Relationship Management (CRM) permiten realizar una integración multicanal y por consiguiente disponer de un conocimiento más profundo del cliente para una mejor gestión de este (Payne & Frow, 2004). Por tanto, para cualquier estrategia centrada en el cliente es fundamental la implementación adecuada de los procesos de soporte al cliente integrados en el CRM y realizados por el Contact Center (Saberri et al., 2017).

A pesar de la utilidad demostrada y validada por el amplio uso del modelo RFM, este modelo no contempla las interacciones que ocurren entre empresa y cliente tras el proceso de venta y que, en muchos casos, son tan importantes o más que la propia venta realizada, de cara a establecer una verdadera estrategia con centro en el cliente. Ejemplos cotidianos en relación con estas interacciones postventa pueden ser: retraso en la entrega de un pedido, entrega defectuosa, deficiente calidad en el servicio de soporte, etc. Es importante notar que la literatura es escasa en relación con la interpretación del valor del cliente o tipificación de éste desde el punto de vista de la interacción que el cliente realiza con el Contact Center.

El objetivo primero de la presente tesis es proponer un nuevo modelo, basado en el modelo RFM ampliado con el modelo lingüístico difuso 2-tupla (LD2T) (F. Herrera & Martínez, 2000), pensado para trabajar con información heterogénea, para pasar después a unificar toda la información en conjuntos lingüísticos difusos interpretables, utilizando las

técnicas de decisión multicriterio (MCDM) y en concreto una de las técnicas multicriterio más utilizada, el proceso de análisis jerárquico, en inglés Analytic Hierarchy Process (AHP) (Thomas L Saaty, 1980), de forma que permita a los expertos del área de atención al cliente (Customer Service) establecer estrategias de relación con los clientes, cimentadas en su interacción con el Contact Center. Optimizando de esta manera el valor del cliente no solo desde el punto de vista de las compras que éste realiza, se propone obtener una valoración del cliente desde el punto de vista del histórico de relación del cliente con la marca a través del Contact Center. Como resultado del modelo desarrollado, y mediante procesos de segmentación, se proponen distintas estrategias relacionales entre cliente y marca. Por tanto, el modelo desarrollado, constituye una mejora del modelo RFM-LD2T, ya que es aplicado a un ámbito de trabajo inédito hasta ahora, es decir, a la interacción entre cliente y Contact Center.

Como objetivo segundo, una extensión del modelo desarrollado nos ha permitido investigar el proceso de priorización y establecer un cierto grado de personalización en las interacciones del cliente con el Contact Center, aplicando para ello los mismos fundamentos teóricos que los comentados en el párrafo anterior, RFM, AHP y LD2T, de esta forma se propone para la gestión de colas de incidencias un enfoque de toma de decisión multicriterio que permite priorizar en tiempo real la comunicación entre cliente y marca, y como consecuencia, personalizar y recomendar el canal de comunicación más adecuado en el momento en que se produce la interacción.

La literatura relacionada con los modelos de Inteligencia Artificial (IA) y con la predicción de abandono de clientes o bien del personal de una compañía es abundante y rica. Como tercer objetivo, se ha propuesto un proceso metodológico que contribuye a analizar la explicabilidad de las predicciones de algoritmos de IA relacionadas con la predicción de abandono, para ello se utilizan técnicas de aprendizaje automático, en inglés Machine Learning (ML), y sobre dichas técnicas se ha desarrollado un modelo de trabajo que incluye un conjunto de algoritmos agnósticos de interpretabilidad, para de esta forma

proporcionar una guía metodológica que permita desarrollar un modelo explicativo aplicable a algoritmos poco interpretables (caja negra), aplicados a la tasa de abandono de clientes o bien del personal del Contact Center.

---

---

# Abstract

The last decade has seen what is known as the 4th Industrial Revolution. Factors that have contributed to this change include information storage and processing capacity, as well as the speed of communications.

From the consumer's point of view, this digital disruption is transforming the way in which users relate to brands. And in this sense, each segment of the population, each customer defines their own Customer Journey Map in their relationship with the brand (Lemon & Verhoef, 2016), thus creating a greater understanding of the customer experience and their journey through their different interactions across any channel. On the other hand, attracting customers is important, but even more important is being able to retain them, and marketing strategies are focused on this process of retaining the most profitable customers.

All this has meant a major paradigm shift for companies, moving from a product-centric approach to one where the customer becomes the center of their strategy, Customer Centric. Concepts such as Digital Transformation and Industry 4.0 (Oztemel & Gursev, 2020), among other aspects, take into account this empowerment of the consumer and this customer-centric approach (V. Kumar & Reinartz, 2012). In this model, two-way communication between customer and brand takes on special relevance, where personalized marketing and customer service are fundamental in the definition of a brand recognition and loyalty strategy, achieving greater customer retention and consequently greater profitability for the company.

There are several models that try to make the customer management process profitable from a marketing and sales point of view, trying to build customer loyalty. In this sense, one of the most widely used models is the RFM (A. M. Hughes, 1994), which is based on the following sales parameters (Recency, Frequency and Monetary). This model is used for customer categorization in such a way that it allows to focus cross-selling or up-

selling marketing actions on the customer according to the category or segment to which he/she belongs.

A crucial aspect of the Customer Centric philosophy is to consider that communications between the company and the customer are bidirectional, and that the customer wants to be served in an integral, consistent manner and through any channel. The importance of technology combined with strategy is fundamental, and systems based on Customer Relationship Management (CRM) allow multi-channel integration and therefore provide a deeper knowledge of the customer for better customer management (Payne & Frow, 2004). Therefore, for any customer-centric strategy, the proper implementation of customer support processes integrated in the CRM and carried out by the contact center is essential (Saber et al., 2017).

Despite the proven and validated usefulness of the RFM model, this model does not consider the interactions that occur between the company and the customer after the sales process and which, in many cases, are as important or more important than the sale itself, to establish a true customer-centric strategy. Everyday examples in relation to these post-sales interactions can be, delay in the delivery of an order, defective delivery, poor quality of support service, etc. It is important to note that literature is scarce in relation to the interpretation of customer value or customer typification from the point of view of customer interaction with the contact center.

The first objective of the present thesis is to propose a new model, based on the RFM model extended with the fuzzy 2-tuple linguistic model (LD2T) (F. Herrera & Martinez, 2000), designed to work with heterogeneous information, and then to unify all the information in interpretable fuzzy linguistic sets, using multi-criteria decision techniques (MCDM) and specifically one of the most widely used multi-criteria techniques, the Analytic Hierarchy Process (AHP) (Thomas L Saaty, 1980), in order to allow Customer Service experts to establish customer relationship strategies, based on their interaction with the Contact Center. In this way, optimizing the value of the customer not only from the

point of view of the purchases made, but it is also proposed to obtain a customer valuation from the point of view of the history of the customer's relationship with the brand through the Contact Center. As a result of the model developed, and by means of segmentation processes, different relational strategies are proposed between the customer and the brand. Therefore, the model developed constitutes an improvement of the RFM-LD2T model, as it is applied to a previously unpublished area of work, i.e., the interaction between the customer and the Contact Center.

As a second objective, an extension of the developed model has allowed us to investigate the prioritization process and establish a certain degree of personalization in customer interactions with the Contact Center, applying the same theoretical foundations as those discussed in the previous paragraph, RFM, AHP and LD2T, thus proposing a multi-criteria decision making approach for the management of incident queues that allows real-time prioritizations of communication between customer and brand, and as a consequence, personalizing and recommending the most appropriate communication channel at the time the interaction takes place.

The literature related to Artificial Intelligence (AI) models related to the prediction of customer or company staff abandonment is abundant and rich. As a third objective, a methodological process has been proposed that helps to analyze the explainability of the predictions of AI algorithms related to the prediction of abandonment, using Machine Learning (ML) techniques, and based on these techniques a working model has been developed that includes a set of interpretability agnostic algorithms, in order to provide a methodological guide that allows the development of an explanatory model applicable to algorithms that are not interpretable (black box) related to the abandonment rate of customers or Contact Center staff.



## Motivación

Es un hecho que la relación entre cliente y marca está cambiando, hemos pasado de una comunicación unidireccional a una bidireccional. Es el cliente quien elige cuándo, cómo y dónde interactuar con la marca. Los factores que han contribuido a este cambio de paradigma sin duda han sido, la capacidad y velocidad de procesamiento de información, así como la velocidad en las comunicaciones (Oztemel & Gursev, 2020). Vivimos en una sociedad hiperconectada, a nivel mundial más de la mitad de la población tiene conexión a Internet. Casi el 52% del tráfico web se origina en un dispositivo móvil. El número total de usuarios activos en Redes Sociales es de 3.725 millones. En un minuto más de 87.500 personas utilizan Twitter, 2.1 millones de snaps en Snapchat, 46.200 fotos en Instagram, 4.5 millones de reproducciones en Youtube. Google supera los 3.8 millones de peticiones. App Store y Google Play generan 390.000 descargas de aplicaciones (Ali, 2020).

Por otro lado, la valoración que un cliente hace de la marca no solo depende del producto o servicio que esta le proporciona, la satisfacción del cliente depende de factores adicionales como la personalización, la atención a través de múltiples canales de comunicación y la excelencia en los servicios prestados (Andrade et al., 2020).

En este entorno es donde el marketing y el servicio de atención al cliente aparecen con una fuerza renovada. Los grandes retos a los que se enfrentan las marcas en este contexto se pueden resumir en (Lemon & Verhoef, 2016; van Dun et al., 2011; Verhoef et al., 2015; Zeithaml et al., 1996):

- Conocimiento avanzado del cliente. El peso que el valor del cliente tiene en el tiempo para la marca, en inglés Customer Lifetime Value (CLV), se puede analizar a partir de la métrica introducida por Hughes en 1994 (A. M. Hughes, 1994), basada en las variables RFM (Recencia, Frecuencia y Monetario), esta métrica proporciona una categorización del cliente de forma que se puedan focalizar acciones de

marketing (Cross Selling y Up Selling) de acuerdo con la categoría a la que pertenezca (Ramón Alberto Carrasco et al., 2019; Khajvand et al., 2011).

- Omnicanalidad. La aceleración tecnológica ha puesto de manifiesto un cambio de conducta en los hábitos del consumidor, estos disponen de distintos canales de comunicación con las marcas como Internet, teléfonos móviles, tabletas, redes sociales, tiendas físicas (Verhoef et al., 2015). Todo esto ha motivado que el proceso de conversión haya cambiado, ya no solo se trata de ofrecer un producto o servicio por parte de la marca, se trata de interactuar con el cliente a través del canal más adecuado de forma pertinente, proactiva y única; aprovechando los factores emocionales durante todo el proceso y ofreciendo experiencias en tiempo real (Kumar et al., 2019).
- Calidad del servicio. La calidad se puede medir en virtud de la diferencia entre el valor percibido y el valor esperado (Caceres & Paparoidamis, 2007; Zeithaml & Berry, 1988). La necesidad de disponer de un Contact Center conectado a múltiples canales, proporcionando un servicio de atención de calidad, derivando las consultas e incidencias al canal más adecuado para su respuesta cumpliendo los estándares de calidad de servicio, en inglés Service Level Agreement (SLA), constituyen una vinculación fundamental entre cliente y marca. Esa vinculación redundante en un valor mayor del cliente para la marca Customer Engagement Value (CEV) (V. Kumar et al., 2010, 2019).
- Vinculación y fidelización. El concepto de fidelización con la marca está muy ligado con el concepto de calidad del servicio, satisfacción del cliente y Engagement con la marca (Ramón Alberto Carrasco et al., 2017; van Dun et al., 2011), los procesos de medición de calidad están sujetos a la subjetividad de la evaluación. Sin embargo, lo que se persigue es vincular al cliente no solo con la empresa, también con la marca, desarrollar seguidores, fans de la marca. Y el servicio de atención al cliente constituye una pieza básica en este objetivo.

- Integración tecnológica. Para poder tomar decisiones adecuadas, todos los sistemas empresariales deben estar conectados. En el caso que nos ocupa, el CRM es una pieza fundamental, integra la información relativa al cliente en sus distintos puntos de interacción con la empresa (V. Kumar & Reinartz, 2012), tanto presenciales como online. El Contact Center se constituye en el proceso de transformación digital de cualquier compañía en una pieza clave, ya que integra todo el valor de la marca en un punto de contacto del que el consumidor espera una experiencia genuina y personalizada.

El avance de la digitalización motiva que las empresas se encuentren en un proceso continuo de transformación digital, y es el servicio de atención al cliente uno de los pilares básicos en este proceso. Un dato que poseen casi todas las empresas en sus sistemas es el histórico de compras de sus clientes, es por esto que aplicar la metodología RFM en la que es primordial la identificación del cliente y su historial de compras asociado (Wei et al., 2010) es relativamente fácil de ejecutar y poner en marcha. Este modelo nos permite conocer el valor del cliente, CLV (Sohrabi & Khanlari, 2007), y de esta forma construir perfiles de cliente de acuerdo con la valoración que éste tiene para la marca.

Si nos centramos en el Contact Center, las empresas disponen de los datos de las interacciones que el cliente realiza a través del Contact Center. Y también se dispone de la valoración que el cliente hace de la marca a través de una métrica como el Net Promote Score (NPS) (Reichheld, 2003), y una medida del esfuerzo del cliente, en inglés Customer Effort Score (CES) (Dixon et al., 2010), que se basa en la idea de reforzar el valor de la interacción con el cliente de forma sencilla, primando soluciones sobre la rapidez. La pregunta es cómo optimizar e integrar toda esta información para poder incrementar el engagement del cliente y por consiguiente el volumen de ventas.

Fabricantes de primer nivel como Salesforce (Gartner, 2021), disponen de herramientas integradas en la funcionalidad del CRM que permiten desarrollar con garantías todos los procesos operativos relativos a la gestión de clientes, entre otros,

marketing, ecommerce, sales y service. Las principales funcionalidades recogidas por el CRM centradas en el Contact Center están dirigidas a conseguir gestionar una mejor demanda del servicio, un adecuado dimensionamiento del personal, una priorización de las interacciones, y al desarrollo de una atención multicanal. El objetivo principal de todas estas acciones es el de reducir el tiempo medio de operación (TMO) en cada interacción y consecuentemente mejorar los niveles de satisfacción del cliente.

Por otra parte, en lo referente al ámbito de la investigación, existen numerosos estudios que hacen referencia a la necesidad de gestionar adecuadamente la relación entre cliente y marca, entre otros (Parasuraman et al., 1985; van Dun et al., 2011). Y como hemos visto en párrafos anteriores, las métricas más importantes relativas a la calidad del servicio están basadas en encuestas de satisfacción. En la presente tesis se estima conveniente aportar una visión 360º, es decir, complementar la evaluación que el cliente hace de la marca, obteniendo para ello una valoración de la marca hacia el cliente a partir de sus interacciones con el Contact Center, de igual forma que se hace con el método RFM para obtener la valoración del cliente en función de sus compras.

Esta idea dio paso a investigar y desarrollar en la presente tesis qué se había hecho antes en relación con este propósito, y cómo se podría mejorar la relación entre cliente y marca teniendo como foco el Contact Center. De aquí surgieron dos líneas de investigación inmediatas, la primera ya comentada de evaluación de cliente basado en parámetros como la Recencia, Frecuencia, Importancia y Duración (RFID) de las interacciones del cliente con el Contact Center en un período de tiempo (Marín Díaz et al., 2021b), y la segunda línea que tiene que ver con los procesos de priorización y personalización de las interacciones, atendiendo a criterios como el Valor del Cliente, el Impacto, la Urgencia y el carácter Emocional de la interacción (VIUE), ampliando de esta forma el concepto de gestión clásica de colas.

En cuanto a la metodología planteada, se ha tenido en cuenta que la mayor parte de las medianas y grandes empresas que han crecido amparadas bajo un modelo de CRM

disponen de los datos básicos del cliente, su historial de compra y su historial de interacción con el Contact Center. De esta forma, ampliando el modelo RFM a las interacciones del cliente con el Contact Center, surgen los modelos propuestos en la presente tesis, tomando especial relevancia la mejora que supone el uso de la teoría de conjuntos difusos (Goguen, 1973), el modelo 2-tupla para representar la información lingüística (Francisco Herrera & Martínez, 2000), junto con el tratamiento de información heterogénea (F. Herrera et al., 2005) y el modelo de toma de decisiones multicriterio propuesto por Thomas L. Saaty en 1980, (Thomas L Saaty, 1980) que determinará el peso de cada criterio en los modelos implementados en la presente tesis, y la aplicación del modelo lingüístico 2-tupla sobre el modelo RFM utilizado para la gestión de campañas (Ramón Alberto Carrasco et al., 2019).

Por otro lado, amparados en el trabajo realizado para el congreso Ethicomp 2021 (Marín Díaz et al., 2021a), y dada la importancia del Contact Center en la interacción entre marca y cliente, se optó por aplicar una metodología de trabajo que permitiese abordar mediante Inteligencia Artificial (IA) modelos predictivos interpretables (Molnar, 2019), que ayudasen a entender las causas relacionadas con la tasa de abandono de clientes. En este sentido, se trabajó en correlacionar la clasificación de clientes obtenida a partir del modelo RFID con la tasa de abandono, con el objetivo de analizar las posibles causas que determinan a un cliente dejar la relación con la marca, en este estudio proponemos un modelo de trabajo que desarrolla los conceptos de Inteligencia Artificial Interpretable (XAI) (Gunning et al., 2019), aplicados a la predicción de abandono del cliente en un modelo Business to Business (B2B), y en futuros trabajos será ampliado y adaptado a la tasa de rotación de personal del Contact Center.

Atendiendo a estas necesidades reales del mercado y que tienen una respuesta limitada en el mundo científico, sentía la necesidad de dejar constancia de que la investigación académica puede ser relevante y ayudar a las empresas en los procesos de

transformación digital, siendo el Contact Center una de las claves en este proceso de digitalización.



# 1. Estructura de la memoria

En este capítulo se presenta una estructura completa de cada uno de los capítulos que componen la memoria, además de un esquema general del contenido de esta.

En el segundo capítulo se hace una introducción general a la situación actual, revisaremos en la literatura el estado actual del Contact Center como pieza clave en los procesos de transformación digital de las empresas. Se revisarán también los objetivos generales y específicos que responden a la casuística encontrada en la modelización de la metodología en escenarios Business to Customer (B2C) y Business to Business (B2B).

El capítulo tercero responde a un análisis detallado del estado del arte actual de los modelos utilizados en la presente tesis, se propone una revisión de las métricas utilizadas en el servicio de atención al cliente, así como los estudios relacionados, en segundo lugar, se realiza un análisis de los estudios y usos del modelo RFM considerando sus ventajas y limitaciones, se explica y detalla cómo la extensión LD2T ayuda en la mejora del modelo RFM. Por último, se aborda el estado del arte actual de la interpretabilidad en modelos de ML y su aplicación al caso.

En el capítulo cuarto se aborda el marco teórico de investigación, introduciremos el modelo LD2T, el modelo RFM, y el modelo de toma de decisiones multicriterio AHP, incorporaremos también un estudio acerca del tratamiento de información heterogénea a un dominio CBTL. Por último, se introduce un epígrafe abordando los métodos de interpretabilidad agnóstica en modelos de ML, que se aplicarán a lo largo de la memoria en el desarrollo de un modelo predictivo interpretable que anticipe la probabilidad de abandono de clientes.

En el capítulo quinto se aborda la metodología que se va a aplicar en todo el proceso, diferenciando dos partes, la primera de ellas correspondiente a la definición del nuevo modelo RFID de clasificación de clientes atendiendo a su relación con el Contact Center y al nuevo modelo VIUE que prioriza y personaliza las colas de interacciones con

el Contact Center. En ambos casos los modelos propuestos están basados en las metodologías ya comentadas RFM, LD2T y AHP. En la segunda parte del capítulo se aborda el problema de la interpretabilidad en la toma de decisiones tras aplicar algoritmos de caja negra, para ello trataremos las distintas técnicas de interpretabilidad agnósticas en modelos de ML.

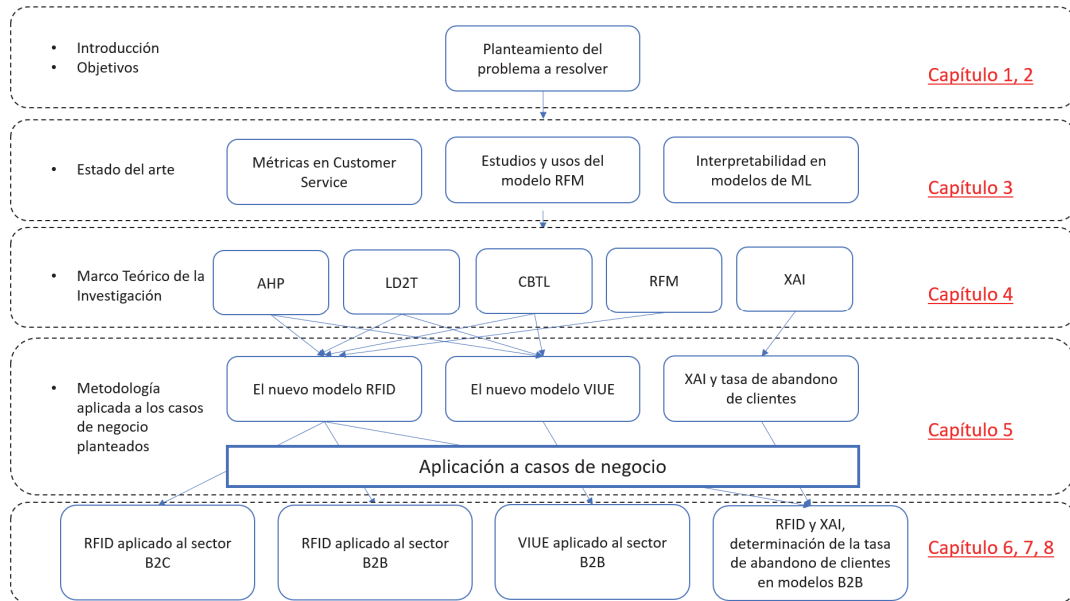
En el capítulo sexto se presenta el nuevo modelo RFID, y se aplica a dos casos de negocio, el primero orientado al mercado B2C (empresa de Telecom) y el segundo orientado al mercado B2B (empresa de fabricación y distribución de software), en ambos casos se utiliza ampliamente la metodología expuesta en el capítulo quinto, acompañada de un proceso que determina la segmentación de clientes atendiendo a la valoración ofrecida por el modelo RFID.

En el capítulo séptimo se presenta el nuevo modelo VIUE que prioriza y personaliza las colas de interacciones de los clientes con el Contact Center, adaptado y personalizado al caso de estudio de un modelo B2B (empresa de fabricación y distribución de software), aplicando para ello la metodología desarrollada en el capítulo quinto.

En el capítulo octavo desarrollamos una metodología XAI de interpretabilidad independiente del modelo de ML (agnóstica), para ello, a partir del modelo RFID aplicado al entorno B2B (empresa de fabricación y distribución de software), se ha conseguido segmentar a los clientes de acuerdo con su relación con el Contact Center, en esta fase se pasan a diseñar un conjunto de estrategias basadas en IA tendentes a predecir el abandono de un cliente atendiendo a su relación con el Contact Center, y como objetivo final aplicar una metodología de interpretabilidad agnóstica a los resultados obtenidos.

En el capítulo noveno presentamos las conclusiones al trabajo realizado, las contribuciones realizadas, así como posibles nuevas líneas de investigación en las que ya se está trabajando.

Todo este resumen se sintetiza en el siguiente esquema:



Esquema general de la memoria

## 2. Introducción

El incremento de capacidad en las infraestructuras: comunicaciones, almacenamiento, y el uso de las tecnologías móviles han influido en la conducta del consumidor y están transformando la forma en la que los clientes se relacionan con las marcas (V. Kumar et al., 2019). Los clientes se encuentran hiperconectados y el grado de fidelidad a la marca está cambiando, el empoderamiento del consumidor hace que éste demande cada vez productos de mayor calidad, personalizados y con un tiempo de entrega menor. Por otro lado, la valoración que un cliente hace de la marca no solo depende del producto o servicio que esta le proporciona, la satisfacción del cliente depende de factores adicionales como la personalización, la atención a través de múltiples canales de comunicación y la excelencia en los servicios prestados (Andrade et al., 2020).

Las empresas se encuentran inmersas en un cambio profundo intentando afrontar los nuevos retos digitales, la relación bidireccional entre cliente y marca ha impulsado un cambio de paradigma (Verhoef et al., 2021). Las empresas deben adaptarse a este cambio y el primero de los pasos a tener en cuenta es disponer un conocimiento profundo del cliente, entender la experiencia del cliente y su recorrido a lo largo del tiempo, a través de la construcción de Customer Journey personalizados (Lemon & Verhoef, 2016). Para dar este primer paso, es importante que toda la información de la empresa esté conectada, integrando los silos de información, de forma que cualquier interacción de la marca con el cliente, tanto en el canal presencial (Off) como en el canal online (On) pase a ser relevante, integral y consistente, de esta forma, la gestión Omnicanal se ha convertido en una pieza fundamental en el proceso de interacción entre cliente y marca (Brynjolfsson et al., 2013; Verhoef et al., 2015).

Además, debemos tener en cuenta fenómenos como la globalización y cómo afecta esta a los hábitos de consumo y por ende al comportamiento del consumidor, tanto de forma homogénea como heterogénea, combinándose en identidades globales y locales (Cleveland & Laroche, 2017).

Las redes sociales determinan que cualquier información es compartida por el cliente de forma pública y por ende cualquier opinión positiva o negativa se extiende de forma exponencial a través de distintos canales. Es por ello por lo que el valor del cliente no se debe ceñir simplemente al historial de compra, el impacto que el cliente puede tener en la marca en redes sociales puede ser determinante. En el estudio realizado por Kumar (V. Kumar et al., 2010) va más allá del aspecto de las transacciones e integra los canales de comunicación, para sugerir la adopción de un marco estratégico multicanal y multimedia, que se centra en las preferencias de los clientes y en la creación de valor para ellos, introduce el concepto de CEV, ya comentado anteriormente, compuesto por cuatro variables: la primera, el ya comentado CLV, basado en el comportamiento de compra del cliente; el Customer Referral Value (CRV) basado en el valor de referenciación del cliente; el Customer Influencer Value (CIV) basado en el valor de la influencia del cliente hacia otros clientes y por último el Customer Knowledge Value (CKV) basado en el valor añadido a la empresa por la retroalimentación del cliente.

En este entorno Omnicanal cobran especial relevancia las interacciones a través del Contact Center, el cliente es quien elige cómo se va a desarrollar la interacción y para ello la marca debe poner a disposición de éste cualquier canal, con el objetivo de facilitar el proceso de comunicación. Junto con la estrategia, la tecnología basada en sistemas CRM constituye una pieza fundamental (Saberri et al., 2017), podemos integrar el historial de comunicación entre cliente y marca a través de una única plataforma que permite disponer en tiempo real y en el momento de la interacción de toda la información del cliente, de forma que se puede facilitar el proceso de toma de decisiones y ofrecer una mejor gestión del cliente en tiempo real (Payne & Frow, 2004; Verhoef, 2003).

En el momento de la interacción, el Contact Center integrado con el CRM es capaz de proporcionar en tiempo real la ficha completa del cliente e indicar al operador las acciones más recomendables tanto a nivel colectivo, por la pertenencia del cliente a un segmento determinado, como a nivel individual, personalizando de esta manera el proceso

de comunicación (V. Kumar & Reinartz, 2018). El valor del cliente no puede ser solo su historial de compra, hay que tener en cuenta los factores comentados anteriormente (CEV), pero además es necesario aportar un conocimiento adicional, el valor del cliente desde el punto de vista del Contact Center, es por ello por lo que el nuevo modelo RFID presentado en esta tesis cobra un papel determinante, ya que, permite valorar al cliente en el proceso de relación con el Contact Center (Marín Díaz et al., 2021b).

La necesidad de disponer de un Contact Center conectado a múltiples canales, proporcionando un servicio de atención de calidad, derivando las consultas e incidencias al canal más adecuado para su respuesta cumpliendo los estándares de SLA, constituyen una vinculación fundamental entre cliente y marca (V. Kumar et al., 2019). Es importante en esta línea disponer de un modelo que permita la priorización y personalización de la comunicación entre cliente y marca atendiendo a criterios como el valor del cliente, el carácter emocional de la interacción, el impacto, la urgencia y otros factores que pueden ser personalizados dependiendo de la tipología de negocio, el modelo VIUE presentado en esta tesis cubre esta necesidad.

Por otro lado, la tasa de abandono del cliente es algo que preocupa a las marcas, en un mercado global, en el que el cliente puede cambiar sus preferencias y comprar a la competencia, es necesario adoptar estrategias que fomenten el Engagement del cliente. Proponiendo para ello alternativas a clientes estratégicamente rentables, que podrían tener una tendencia positiva en abandonar la relación con la marca, o bien dejando marchar a los que no son estratégicamente rentables (Jain & Singh, 2002; Mulhern, 2007). La valoración proporcionada por RFID agregada con el CEV nos permite determinar el grado de satisfacción entre cliente y marca, y por tanto diseñar las acciones más recomendables para no perder al cliente o bien dejar marchar al cliente poco rentable. Ahora bien, estas decisiones que podrían dejarse en manos de algoritmos de caja negra deben estar sujetas a interpretabilidad para no incurrir en sesgos discriminatorios y poder tomar decisiones explicables.

No menos importante que el punto anterior, y que preocupa mucho a las marcas, es la alta tasa de rotación de los empleados de Contact Center, uno de los puestos de trabajo con tasas de rotación más elevadas. El comportamiento del agente que atiende la interacción con el cliente es altamente impactante ya que puede generar una satisfacción positiva o negativa que está directamente relacionada con el valor de la marca. En el siguiente estudio (Iwu et al., 2021) se examinan las interconexiones entre la orientación al cliente, la gestión del conocimiento, la satisfacción laboral y la intención de los empleados de abandonar el trabajo. Es fundamental, ayudar al empleado con herramientas que le permitan tomar decisiones en tiempo real, elevando con ello el grado de satisfacción del cliente y la confianza del agente.

Los tres modelos expuestos y sus relaciones se pueden ver en la siguiente figura,

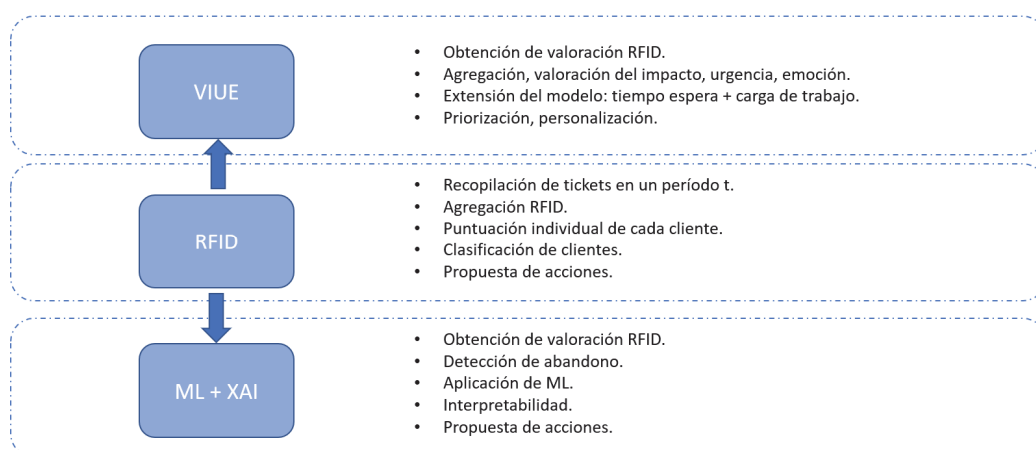


Figura 1. Relaciones entre los tres modelos propuestos

Podemos concluir que el Contact Center pasa a ser una pieza fundamental en los procesos de transformación digital de las empresas, la relación con el cliente va más allá del proceso de compra y se cimenta en una relación duradera basada en la confianza, la fidelidad y la empatía (van Dun et al., 2011). En este punto, la tecnología y la puesta en marcha de una gestión del cambio organizativo deben ser pilares en este proceso.

Por todas estas razones, en la presente tesis se presenta una estrategia de gestión integral del Contact Center, proporcionando una metodología de trabajo y soluciones que

puedan ser aplicadas y extendidas a cualquier entorno B2B y B2C. En este proceso se desarrollarán las acciones especificadas anteriormente, construcción de un nuevo modelo de valoración del cliente RFID, priorización de la gestión de las interacciones VIUE y por último la aplicación de una metodología XAI aplicada a dar explicación y determinar la variable target binaria abandono de clientes.

## 2.1 Objetivos

En esta sección se plantean los objetivos generales y específicos, durante el desarrollo de la tesis y en el capítulo de conclusiones se hará una revisión de su consecución.

### Objetivos generales

Como ya se ha comentado, este trabajo surge como respuesta a la necesidad que se observa en empresas donde he realizado labores de consultoría, se precisa optimizar los procesos de Contact Center y servir experiencias que fomenten el Engagement entre cliente y marca.

El propósito general de esta memoria es por tanto diseñar un método formal que permita la gestión estratégica del Contact Center, en distintos mercados B2B y B2C. Dicha mejora debe implicar una mayor efectividad en la relación entre cliente y marca, logrando un mayor grado de fidelización y vinculación, consiguiendo una mayor precisión en el proceso de evaluación de cliente y poder dar así respuesta personalizada a sus necesidades.

### Objetivos específicos

El objetivo general anterior se concreta en los siguientes objetivos específicos:

- Revisión de las métricas ligadas a los procesos de Customer Service, así como los estudios relacionados.

- Investigar los usos del modelo RFM y su aplicación en distintos escenarios, validando de esta forma la originalidad de los modelos RFID y VIUE planteados.
- Diseño de un nuevo proceso metodológico que llamaremos RFID, que permita mejorar el grado de fidelización de los clientes respecto a su relación con el Contact Center.
- Diseño de un nuevo proceso metodológico que llamaremos VIUE, que permita la priorización y gestión de las interacciones entre cliente y marca a través del Contact Center de forma automática.
- Diseño de un proceso metodológico que permita disponer de mecanismos de aplicación de Inteligencia Artificial Explicable (XAI) para determinar la variable target binaria abandono de clientes, y establecer las medidas oportunas para mitigarlo.
- Implementación de los modelos diseñados bajo herramientas open-source, en este caso la suite de Python y R.
- Aplicación de los modelos obtenidos, generalizando su aplicabilidad a los mercados B2B y B2C.

## 3. Análisis del estado actual y estudios relacionados

A lo largo de este capítulo se realiza un análisis detallado del estado del arte actual, revisando las métricas utilizadas en el servicio de atención al cliente, así como los estudios relacionados, en segundo lugar, se realiza un análisis de los estudios y usos del modelo RFM considerando sus ventajas y limitaciones, así como la extensión LD2T, ambos se aplican a las metodologías RFID y VIUE propuestas en la presente tesis. Por último, abordaremos el estado del arte actual de la interpretabilidad en modelos de ML y su aplicación al caso de negocio.

### 3.1 Introducción

La valoración que un cliente hace de la marca no solo depende del producto o servicio que esta le proporciona, la satisfacción del cliente depende de factores adicionales como la personalización, la atención a través de múltiples canales de comunicación y la excelencia en los servicios prestados (Andrade et al., 2020).

En el capítulo en el que se indican las motivaciones que me han llevado a optar por este estudio, se han identificado los siguientes factores como determinantes en lo que se ha denominado cambio de paradigma en las relaciones entre cliente y marca:

- Conocimiento avanzado del cliente.
- Omnicanalidad.
- Calidad del servicio.
- Vinculación y fidelización.
- Integración tecnológica.

A continuación, se pasa a detallar cada uno de estos puntos.

### 3.1.1 Conocimiento avanzado del cliente

En el proceso de conocimiento avanzado del cliente, la métrica juega un papel fundamental, sobre el conjunto de clientes o clientes potenciales es necesario realizar un proceso de segmentación que permita categorizarlos de acuerdo con una escala de valores. Este valor determinará la estrategia y el conjunto de acciones de marketing a realizar con dicho cliente o bien con el segmento al que pertenece. Sin olvidar un aspecto importante, las comunicaciones son bidireccionales y el cliente desea ser atendido de forma consistente y a través de cualquier canal. La importancia de la tecnología sumada a la estrategia es fundamental, los sistemas basados en CRM permiten realizar una integración multicanal y por consiguiente disponer de un conocimiento profundo del cliente a través de cualquier interacción con la marca (V. Kumar & Reinartz, 2012).

En los siguientes estudios (Hamilton et al., 2016; V. Kumar et al., 2010), se incorporan conceptos adaptados al consumidor Omnicanal, ya comentados, CIV, CRV y CKV, todos ellos contribuyen junto con el CLV proporcionando de forma más adecuada el peso del valor del cliente para la marca CEV.

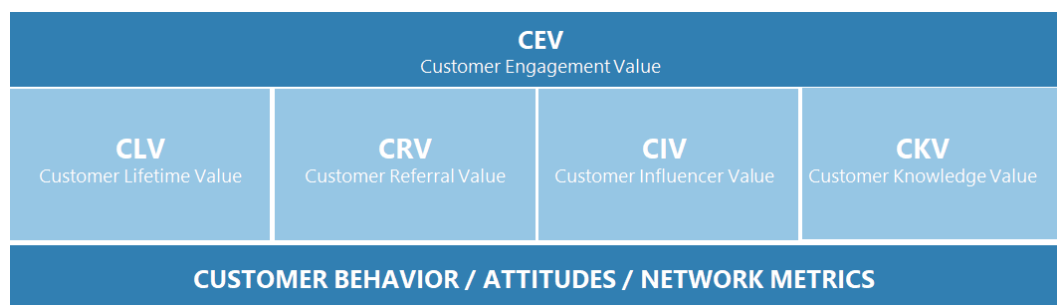


Figura 2. Definición de CEV (Kumar et al., 2010)

Una vez seleccionado el método más adecuado para la categorización del cliente, se puede evaluar la importancia relativa de cada variable identificada utilizando la metodología AHP. Por ejemplo si la valoración del cliente es una composición del CEV (CLV, CRV, CIV, CKV), por áreas de la compañía se pueden establecer pesos a cada una de las variables de la definición del modelo (D. R. Liu & Shih, 2005). En esta memoria propondremos una nueva métrica para la valoración del cliente desde el punto de vista del

Contact Center (RFID), y lo que se ha bautizado como Customer Service Value (CSV). De esta forma, podemos medir el CEV como una función  $f(CLV, CRV, CIV, CKV, CSV)$  y como consecuencia, podemos tener agrupados y clasificados por segmentos clientes o clientes potenciales, de forma que se puedan desarrollar estrategias de inbound marketing y de atención personalizada.

### 3.1.2 Omnicanalidad

La aceleración tecnológica ha puesto de manifiesto un cambio de conducta en los hábitos del consumidor, estos disponen de distintos canales de comunicación con las marcas como Internet, teléfonos móviles, tabletas, medios sociales, tiendas físicas (Verhoef et al., 2015). El mundo off-on tiende a estar completamente conectado.

Desde el punto de vista tecnológico se producen desajustes entre los datos de distintas plataformas que dan cobertura a los canales de comunicación con el cliente. La información de toda la organización debe estar conectada para poder proporcionar una experiencia satisfactoria en el proceso de comunicación cliente - marca (Saghiri et al., 2017).

Lograr la integración superando los llamados silos de información se ha convertido en una tarea importante para mejorar el proceso de transformación digital de las empresas. Si llevamos esto a la integración de todos los canales, de forma que la comunicación sea consistente a través de cualquier canal, estamos transformando la multicanalidad en omnicanalidad (Ailawadi & Farris, 2017; Hilken et al., 2018; Saghiri et al., 2017; Shen et al., 2018), y de esta forma mejorando el valor percibido por el cliente y en consecuencia el CEV (V. Kumar et al., 2010, 2019).

En la siguiente Figura se presenta el proceso de evolución tecnológica del Contact Center en los últimos 60 años (Ryu & Kim, 2018), pasando de soluciones basadas en la voz, la integración con los servicios web, la multicanalidad, la omnicanalidad y personalización a través de la IA y el ML.

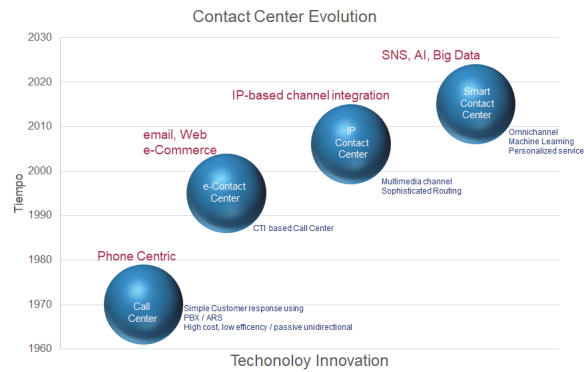


Figura 3. Evolución del Contact Center (Ryu & Kim, 2018)

### 3.1.3 Calidad del servicio

La calidad se mide en virtud de la diferencia entre el valor percibido y el valor esperado (Caceres & Paparoidamis, 2007; Zeithaml & Berry, 1988).

En el estudio de (Parasuraman et al., 1985) se establecen diez parámetros determinantes de la calidad del servicio: acceso, comunicación, competencia, cortesía, credibilidad, fiabilidad, respuesta, seguridad, evidencia, entendimiento de las necesidades del cliente.

Aplicando los conceptos derivados del estudio de (Parasuraman et al., 1985) a un escenario de Contact Center (van Dun et al., 2011), se determinan las siguientes dimensiones como fundamentales en el proceso de relación entre cliente y marca, y corresponden con los criterios de evaluación de los servicios prestados: fiabilidad, empatía, conocimiento del cliente, enfoque en el cliente, tiempo de espera, facilidad de uso, y accesibilidad.

La medición de la calidad del servicio, entendida como la diferencia entre el valor esperado por el cliente y el valor entregado por la marca, está íntimamente relacionada con los SLA, y en consecuencia con la prioridad y la rapidez con que las incidencias son atendidas. Además, un aspecto fundamental en esta priorización es el grado de personalización en la comunicación. La metodología Information Technology Infrastructure Library (ITIL) (Bartolini & Sallé, 2004; Marrone & Kolbe, 2011), recomienda

determinar la prioridad en la resolución de incidencias a partir del impacto y de la urgencia de las interacciones. En esta memoria en el nuevo modelo VIUE, además del impacto y la urgencia, se incluirá algún aspecto adicional en la determinación de la prioridad, como el valor del cliente a través del modelo RFID (Marín Díaz et al., 2021b); el carácter emocional de la interacción, que repercute directamente en los procesos y el resultado final del servicio ofrecido por el agente que atiende la interacción (Altman et al., 2021); la carga de trabajo del Contact Center y los SLAs (Milner & Olsen, 2008).

### 3.1.4 Vinculación y fidelización

El estudio realizado por (Wallace et al., 2004) investiga la fidelidad de los clientes en el sector retail, como conclusión de dicho estudio se determina que las estrategias de venta en entornos multicanal además de mejorar la cartera de servicios prestados al cliente, proporcionan una mejor satisfacción y vinculación del cliente con la marca.

La necesidad de disponer de un Contact Center conectado a múltiples canales, proporcionando un servicio de atención de calidad, derivando las consultas e incidencias al canal más adecuado para su respuesta cumpliendo los estándares de SLA, constituyen una vinculación fundamental entre cliente y marca. Esa vinculación redundante en un valor mayor del cliente para la marca CEV (V. Kumar et al., 2010, 2019).

### 3.1.5 Integración tecnológica

La tecnología desempeña un papel muy importante en el apoyo del personal del Contact Center, como se ha comentado, la información debe estar integrada para que el operador pueda tomar decisiones y proporcionar una experiencia positiva al cliente (Jayachandran et al., 2005), incrementando de esta forma su satisfacción.

El modelo tecnológico que proponemos para la adecuada toma de decisiones en los procesos de transformación digital de las compañías y en concreto para el objeto de estudio

de este artículo, está basado en los aspectos comentados en los puntos anteriores y que podemos resumir en la siguiente Figura:

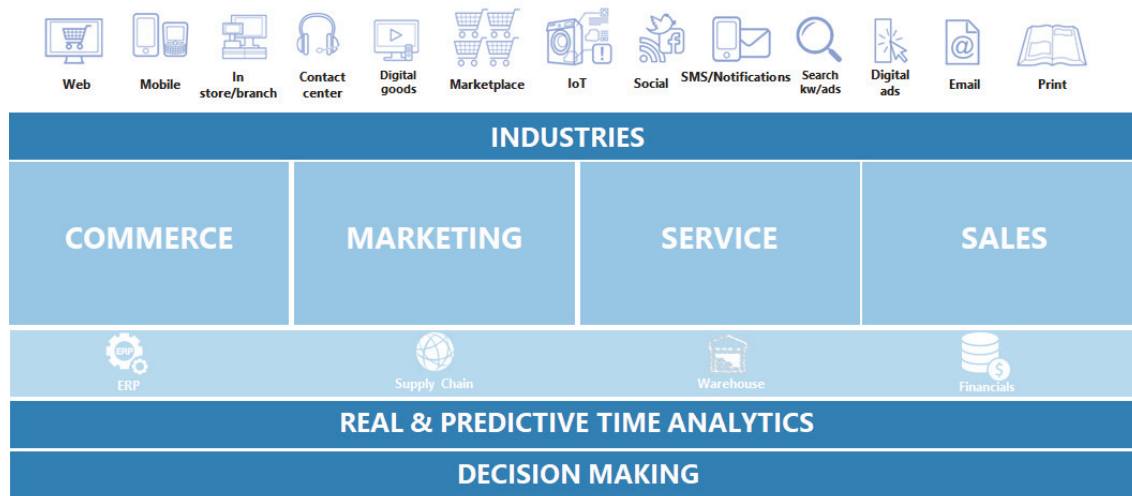


Figura 4. Modelo tecnológico Customer Centric

Todos los sistemas internos conectados y relacionados con los canales de comunicación con el cliente, con el objetivo de poder procesar, análisis descriptivo y predictivo con el objeto de tomar decisiones en tiempo real.

### 3.2 Customer Service, Métricas

La satisfacción del cliente es una métrica importante en la ciencia del marketing y son innumerables los estudios que hacen referencia a la necesidad de gestionar adecuadamente la relación entre el cliente y la marca. El siguiente estudio, ya comentado, abarca las cinco dimensiones clave de la medición de la calidad del servicio percibido: fiabilidad, garantía, tangibilidad, empatía y capacidad de respuesta (Parasuraman et al., 1985). Una ampliación del estudio anterior adaptado a las particularidades del contact center (van Dun et al., 2011) identifica las siguientes dimensiones como fundamentales en el proceso de relación cliente-marca: fiabilidad, empatía, conocimiento del cliente, orientación al cliente, tiempo de espera, facilidad de uso y accesibilidad.

Basándonos en el modelo de calidad y satisfacción del cliente, podemos destacar la siguiente métrica como una de las más utilizadas, el NPS propuesto por F. Reichheld (Reichheld, 2003) que utiliza el valor de la recomendación de la marca por parte del cliente como medida de fidelidad. Entre los estudios similares a éste se encuentra la puntuación CES (Dixon et al., 2010), que se basa en la idea de que las interacciones con el cliente deben ser sencillas, priorizando la solución sobre cualquier otro factor. En el siguiente estudio (Lemon & Verhoef, 2016), los autores destacan que, aunque estas métricas tienen cierto poder intuitivo, carecen de un desarrollo teórico sólido, se centran en un dominio específico CES o se centran en operaciones ad hoc NPS, y subrayan que las métricas que evalúen el comportamiento del cliente desde una perspectiva 360° predicen el comportamiento del cliente mejor que una única métrica. La Tabla 1 enumera los principales estudios relacionados con las métricas de valoración de la experiencia del cliente:

Tabla 1. Métricas Customer Services

Autor	Título
(V. Kumar et al., 2019)	Customer engagement in service.
(Lemon & Verhoef, 2016)	Understanding customer experience throughout the customer journey.
(Reichheld, 2003)	The one number you need to grow.
(Dixon et al., 2010)	Stop trying to delight your customers.
(Gupta & Zeithaml, 2006)	Customer metrics and their impact on financial performance.
(van Doorn et al., 2013)	Satisfaction as a predictor of future performance: a replication.
(De Haan et al., 2015)	The role of mobile devices in the online customer journey.
(De Keyser et al., 2015);	A framework for understanding and managing the CX.
(Grewal et al., 2009)	Customer experience management in retailing: an organizing framework.
(Morgan & Rego, 2006)	The value of different customer satisfaction and loyalty metrics in predicting business performance.
(Korneta, 2018)	Net promoter score, growth, and profitability of transportation companies.
(Rocks, 2016)	Interval estimation for the "net promoter score".
(Baehre et al., 2021)	The use of net promoter score (NPS) to predict sales growth: insights from an empirical investigation.
(Jahnert & Schmeiser, 2021)	The relationship between net promoter score and insurers' profitability: an empirical analysis at the customer level.

### 3.3 Estudios y usos del modelo RFM

En un proceso RFM el objetivo consiste en clasificar a los clientes según su comportamiento de compra, de esta forma podemos segmentar al conjunto de clientes e iniciar acciones de marketing de acuerdo con su perfil utilizando como herramienta tecnológica el CRM y como herramienta de diseño el Customer Journey (Lemon & Verhoef,

2016), de esta forma podemos descubrir por ejemplo a los clientes más valiosos, a los que tenemos que incentivar, a los que están en peligro de abandonar la relación con la marca, etc. (Wei et al., 2010).

En los últimos años se han empleado técnicas de minería de datos para realizar los procesos de segmentación de clientes, así, por ejemplo, k-means, regresión logística, redes neuronales, etc. Sin embargo, la tendencia en entornos de Marketing, es el uso del modelo RFM combinándolo con otros modelos, principalmente por la fácil interpretabilidad del modelo y la posibilidad de toma de decisiones explicables (Sembiring Brahmana et al., 2020).

A continuación, se hace una revisión de los distintos usos y aplicaciones del modelo RFM en distintos ámbitos empresariales y en otro tipo de organizaciones.

Tabla 2. Estudios relacionados con el CLV

Autor	Título
(Anderson, 1986)	A method for customer lifetime value ranking. Preventing School Failure.
(Shih & Liu, 2003)	Integrating AHP and data mining for product recommendation based on customer lifetime value
(Venkatesan & Kumar, 2004)	Framework for Customer Selection
(D. R. Liu & Shih, 2005)	Integrating AHP and data mining for product recommendation based on customer lifetime value
(Sohrabi & Khanlari, 2007)	Customer Lifetime Value (CLV) Measurement Based on RFM Model
(Chan, 2008)	Intelligent value-based customer segmentation method for campaign management: A case study of automobile retailer
(V. Kumar et al., 2008)	The power of CLV: Managing customer lifetime value at IBM
(Yeh et al., 2009)	Knowledge discovery on RFM model using Bernoulli sequence
(Khajvand & Tarokh, 2011)	Estimating customer lifetime value based on RFM analysis of customer purchase behavior: Case study
(Moro et al., 2015)	Using customer lifetime value and neural networks to improve the prediction of bank deposit subscription in telemarketing campaigns.
(Hamilton et al., 2016)	Social Media and Value Creation: The Role of Interaction Satisfaction and Interaction Immersion
(Monalisa et al., 2019)	Analysis for customer lifetime value categorization with RFM model
(Martínez et al., 2019)	A comparison between Fuzzy Linguistic RFM Model and traditional RFM model applied to Campaign Management. Case study of retail business
(Haggerty et al., 2019)	Genomics-First Evaluation of Heart Disease Associated With Titin-Truncating Variants.
(Mahdiraji et al., 2019)	Marketing strategies evaluation based on big data analysis: a CLUSTERING-MCDM approach
(Alet Vilagínés, 2020)	Predicting customer behavior with Activation Loyalty per Period. From RFM to RFMAP
(Wu et al., 2020)	A review of the application of RFM model
(Heldt et al., 2021)	Predicting customer value per product: From RFM to RFM/P
(Rahim et al., 2021)	RFM-based repurchase behavior for customer classification and segmentation
(Zong & Xing, 2021)	Customer stratification theory and value evaluation-analysis based on improved RFM model

En los siguientes párrafos se amplía la literatura relacionada con el modelo RFM teniendo en cuenta el sector y caso de negocio.

En el siguiente estudio (Hsieh, 2004) propone un modelo integrado para la gestión de los clientes que disponen de tarjeta de crédito bancaria. Se utilizó una red neuronal para

segmentar a los clientes basada en el comportamiento de devolución de los reembolsos y en el modelo RFM, clasificando de esta manera a los clientes en grupos de mayor a menor rentabilidad.

En este otro estudio (Sohrabi & Khanlari, 2007) utilizan el modelo RFM para segmentar los clientes de una entidad bancaria, de forma que se pueda calcular el CLV de cada cliente, aplicando la clusterización con k-means.

Al margen del entorno empresarial (King, 2007) propone el uso del CRM como elemento clave en la relación entre ciudadanos y administraciones públicas con el objetivo principal de conocer al ciudadano, animándole a participar en las decisiones públicas de servicios que pueden consumir.

En el siguiente estudio (Lumsden et al., 2008) se propone distinguir el valor del cliente en función de las motivaciones previas al proceso de compra, los resultados predicen que la frecuencia es el mejor indicador del valor del cliente, por encima de la recencia y del valor monetario.

En un marco distinto a los anteriores (Li et al., 2010) se propone un modelo de evaluación del poder de influencia de los prescriptores de marca, para ello se adapta el modelo RFM previa la utilización de una red neuronal para identificar a los recomendadores más activos y se evalúa la eficacia del modelo contrastando con un sitio web de revisión de productos.

En este otro estudio (Van Vlasselaer et al., 2015) se propone un enfoque para la posible detección de transacciones fraudulentas realizadas con tarjetas de crédito en transacciones online, utilizando RFM para realizar el análisis del historial de compras del cliente.

En el sector sanitario (Mohammadzadeh et al., 2017) se propone una metodología de rastreo de clientes para obtener agrupaciones y tendencias especiales, el objetivo es detectar los clientes “potencialmente fieles” y “potencialmente descartables”, de forma que

se pudieran optimizar las campañas de fidelización. El modelo propuesto está basado en el modelo RFM tradicional, pero incorporando una variable adicional, L que define la fidelidad del paciente.

Por otro lado y aplicado al mundo de los juegos para móviles (Perisic & Pahor, 2020) se propone trabajar en un modelo de detección de clientes con alta propensión al abandono, para ello utilizan un análisis de regresión logística en el marco del modelo RFM.

Un modelo centrado en ampliar la fidelización de clientes vía servicios adicionales a los productos vendidos se detalla en la siguiente publicación (Stormi et al., 2020), utiliza el modelo RFM ampliado en cuatro variantes específicas de producto-soporte-servicio.

Orientado al sector hotelero el trabajo (Bueno et al., 2021) está orientado a la utilización del modelo RFM pero adaptándolo e incorporando otro criterio en sustitución de la variable Monetary, lo que se ha dado en llamar Helpfulness (RFH), agregando mediante 2-tupla la información que los usuarios introducen en Redes Sociales.

Un modelo centrado en la perspectiva de lanzamiento de un nuevo producto al mercado (Hwang & Lee, 2021) de forma que podamos utilizar el modelo RFM, pero solo con las variables Recencia y Frecuencia de los datos de acceso al sitio web de los clientes. Permitiendo a los profesionales del marketing encontrar clientes objetivo sin historial de compras.

Como se puede observar el modelo RFM se aplica a distintos sectores tanto empresariales como gubernamentales, donde se necesita clasificar al cliente, paciente o ciudadano, con el objetivo final de personalizar acciones sobre segmentos poblacionales, identificar clientes y analizar la rentabilidad de los mismos (Wei et al., 2010).

En la Tabla 3, se presenta un resumen de los casos de uso comentados clasificados por sectores / marcos de actuación.

Tabla 3. Estudios CLV y su aplicación a sectores y modelos de negocio

Industria	Autor	Descripción
Financiamiento	(Hsieh, 2004)	An integrated data mining and behavioral scoring model for analyzing bank customers
	(Sohrabi & Khanlari, 2007)	Customer Lifetime Value (CLV) Measurement Based on RFM Model
	(Van Vlasselaer et al., 2015)	APATE: A novel approach for automated credit card transaction fraud detection using network-based extensions
Viajes	(Lumsden et al., 2008)	Customer Value in an All-Inclusive Travel Vacation Club: An Application of the RFM Framework
	(Bueno et al., 2021)	A linguistic multi-criteria decision making methodology for the evaluation of tourist services considering customer opinion value
Gobierno	(King, 2007)	Citizens as customers: Exploring the future of CRM in UK local government
Marketing Social	(Li et al., 2010)	Identifying influential reviewers for word-of-mouth marketing
	(Hwang & Lee, 2021)	Identifying customer priority for new products in target marketing: Using RFM model and TextRank
Juegos	(Perisic & Pahor, 2020)	Extended RFM logit model for churn prediction in the mobile gaming market
Salud	(Mohammadzadeh et al., 2017)	A data mining approach for modeling churn behavior via RFM model in specialized clinics Case study: A public sector hospital in Tehran
Manufactura	(Stormi et al., 2020)	RFM customer analysis for product-oriented services and service business development: an interventionist case study of two machinery manufacturers

### 3.3.1 Ventajas y limitaciones del modelo RFM

La principal ventaja del modelo RFM es la facilidad de aplicación ya que los datos sobre las ventas de los clientes casi siempre están disponibles. A partir de dichas transacciones y con el uso de las variables cuantificables ya comentadas se puede explicar con facilidad las agrupaciones en perfiles por comportamiento similar, además permite identificar a los clientes más valiosos, y poder establecer acciones de forma individual o bien grupal (Ramón Alberto Carrasco et al., 2019). Por otro lado, la recopilación de la información se realiza a través de herramientas corporativas como el CRM (Wu et al., 2020) de forma que no tenemos que realizar grandes procesos de agregación de información para obtener resultados comprensibles por los responsables de toma de decisiones (Mccarty & Hastak, 2007).

Los enfoques basados en RFM presentan limitaciones, una de ellas es la falta de precisión, las puntuaciones se expresan mediante n-escalas  $\{1..n\}$ , donde  $n$  representa el coeficiente de mayor aportación y 1 el de menor. Típicamente  $n = 5$ , esto es, frecuentemente se usan quintiles. Además la importancia de cada medida del RFM depende de la tipología de empresa (Yeh et al., 2009) e incluso de la estacionalidad del servicio. Y por último, el modelo puede tener sesgos en el caso de clientes que tienen un tiempo de vida corto en su relación con la marca (Wei et al., 2010).

En la revisión de la literatura no se han encontrado estudios que apliquen el modelo RFM en obtener una valoración y/o clasificación del cliente atendiendo a su relación con el Contact Center. Es por eso por lo que consideramos el modelado con RFID un complemento fundamental en el proceso de segmentación y evaluación de clientes.

### 3.3.2 Ampliación del modelo RFM

Dadas las limitaciones de los modelos RFM, algunos autores han considerado incluir ampliaciones al modelo usando el modelo lingüístico difuso 2-tupla para resolver la falta de precisión mencionada (Ramón Alberto Carrasco et al., 2019). Un problema frecuente en la aplicación del modelo consiste en determinar el peso de cada una de las variables que depende obviamente de criterios de negocio. Algunos autores resuelven este problema mediante el uso de AHP (D. R. Liu & Shih, 2005) que permite tomar este tipo de decisiones fácilmente mediante comparaciones por pares y chequeo de consistencia. Frecuentemente, diversos autores proponen el uso de algoritmos de clustering como k-means tras la aplicación del modelo RFM (Ramón Alberto Carrasco et al., 2019). En los nuevos modelos RFID y VIUE se aplican todas estas mejoras.

Como hemos visto en los puntos anteriores, el modelo RFM se aplica en varios estudios para obtener el CLV en los procesos de venta, ver Tablas 2 y 3. Sin embargo, si queremos conocer el grado de satisfacción del cliente, utilizaremos métricas basadas en encuestas como el NPS y el CES, véase la Tabla 1. Los modelos basados en la satisfacción del cliente son sencillos de aplicar, pero carecen de un desarrollo teórico sólido y se centran en un área específica CES o transacciones ad-hoc NPS (Lemon & Verhoef, 2016), se basan en recoger la opinión del cliente después de la prestación del servicio.

La novedad del modelo RFID radica en analizar el valor del cliente desde el punto de vista del Contact Center, proporcionando una visión 360° entre el cliente y la marca, de esta manera los modelos tradicionales de evaluación del servicio (NPS, CES) pueden ser complementados con el valor del cliente proporcionado por el modelo RFID, a través del

historial de relación del cliente con el Contact Center, de la misma manera que el modelo RFM obtiene el valor del cliente a través de las compras que éste realiza.

### 3.4 Interpretabilidad en Machine Learning

¿Pueden las máquinas pensar? Esta cuestión la planteó Alan M. Turing (1950) a mediados del siglo XX. La respuesta a esa pregunta es la propuesta del llamado test de Turing. En dicho test se considera Inteligencia Artificial a la forma de actuar que imita el comportamiento inteligente de los seres humanos. Desde entonces hasta ahora la IA ha ido superando al ser humano en tareas para las que se suponía que había que tener inteligencia: juegos de estrategia como el ajedrez, conducir vehículos, componer sinfonías, planificaciones automáticas, y un largo etcétera que no parece tener fin. De hecho, los cambios producidos en las últimas décadas en el sector de las telecomunicaciones, acompañado por el desarrollo de la capacidad de almacenamiento y procesamiento de la información han supuesto un cambio de paradigma a la que se ha dado el nombre de Industria 4.0.

En algunos casos puede no ser relevante entender por qué se ha tomado una determinada decisión sobre todo en entornos de bajo riesgo. Si bien, en la mayoría de las ocasiones el ser humano debería entender por qué se ha tomado una decisión que le afecta a nivel individual o como colectivo. Sirvan como ejemplos: la decisión de concesión de un préstamo, una decisión médica, autoconducción de vehículos, un proceso de selección a un determinado puesto de trabajo, etc.

En un estudio dirigido en 2019 por Brandon Fornwalt, Centro Médico Geisinger, Pennsylvania, entrenaron dos algoritmos de IA capaces de predecir el riesgo de muerte en el primer año a través de la lectura de electrocardiogramas, incluso de personas aparentemente “normales”, el acierto del algoritmo fue de un 85% (Samad et al., 2019).

Se ha demostrado que los modelos de ML aprenden muy bien de los datos, pero también recogen los sesgos que puedan estar incorporados de forma voluntaria o no en los

datos de entrenamiento. Esto puede convertir al modelo de entrenamiento en potencialmente sectario y discriminar a ciertos colectivos e individuos. Estos sesgos potenciales constituyen un punto fundamental en la investigación del problema de su interpretabilidad (Miller, 2019).

Desde el punto de vista histórico, en 1950 Turing crea el test que lleva su nombre, en 1952 Arthur L. Samuel crea el primer algoritmo que es capaz de aprender, en 1956 nace el concepto de Inteligencia Artificial, en los años 70 surgen los algoritmos de reconocimiento de patrones, en los 80 los sistemas expertos basados en reglas, el concepto de ML empezó a tener relevancia en los años 90 siendo actualmente uno de los subcampos más populares dentro de la IA, y está íntimamente ligado con la estadística matemática.

Históricamente, la prioridad de la investigación en IA se ha desplazado hacia la implementación de algoritmos y modelos centrados en el poder predictivo en detrimento de la interpretabilidad. La interpretabilidad del modelo se destacó en las primeras investigaciones sobre aprendizaje automático. En los años 70 y 90 surgieron iniciativas como MYCIN (Britannica, 2018), GUIDON (Clancey, 1987). Desde la década de los 80 hasta los 90 se desarrollaron sistemas para rastrear líneas alternativas de razonamiento (TMS). En la década de los 90 surgen iniciativas en el contexto de la explicación de redes neuronales en el ámbito sanitario. En el año 2010, las preocupaciones derivadas del sesgo en la toma de decisiones de IA han llevado a la demanda de inteligencia artificial transparente y a hacer foco en la interpretabilidad de modelos de ML.

Además, en estos últimos años se ha vivido la expansión de los sistemas de redes sociales, amparadas en la velocidad de procesamiento de información, las comunicaciones y la capacidad de almacenamiento. Como consecuencia, debido al aumento exponencial de la recopilación de datos heterogéneos y a la enorme cantidad de potencia computacional, los sistemas de aprendizaje automático (ML) están presentes en nuestras vidas, alcanzando un mayor rendimiento predictivo y, para la mayoría de ellos, una mayor complejidad (Carvalho et al., 2019).

En la práctica lo que queremos es que los algoritmos sean explicables, es decir que sus operaciones puedan ser entendidas por seres humanos. A pesar de la correspondencia entre ambos términos, interpretable vs explicable, hay autores que desarrollan cierta diferenciación entre ambos conceptos (Rudin, 2019).

En distintos entornos decisiones importantes se confían cada vez más en modelos que no pueden explicarse en sí y tampoco por parte de una persona cualificada, es por ello por lo que surgen iniciativas como la Inteligencia Artificial Explicable (XAI) (Gunning et al., 2019), centrada en la interpretabilidad de los algoritmos de aprendizaje automático y pretende dar un giro hacia un modelo de IA interpretable.

Por otro lado y relativo a las características que deberían llevar aparejadas los modelos interpretables (Molnar, 2019): las explicaciones debieran ser contrastantes (P. Lipton, 1990), la pregunta que nos hacemos es por qué se hizo una determinada predicción en lugar de otra, necesitamos entender por comparación. Además, las explicaciones se seleccionan, es decir del conjunto de causas que pueden dar una determinada explicación, estamos acostumbrados a seleccionar una o dos causas como las más ligadas a la explicación. Las explicaciones son sociales, forman parte de una interacción entre el explicador y el receptor de la explicación en donde en muchos casos interviene el entorno social. Las explicaciones se centran en lo anormal (Kahneman & Tversky, 1981), causas a las que se les atribuye un gran potencial pero con escasa probabilidad. Las explicaciones son verdaderas, las buenas explicaciones demuestran ser ciertas en la realidad, se debe predecir el evento con la mayor probabilidad posible. Las explicaciones son consistentes con las creencias previas, es lo que se llama sesgo de confirmación, devaluando aquellas explicaciones que no concuerden con sus creencias (Nickerson, 1998). Las buenas explicaciones son generales y probables, en ausencia de un escenario anormal, las causas generales son buenas explicaciones (curva de Gauss).

Como se puede apreciar el concepto de interpretabilidad sugiere la participación de más de un área de conocimiento, (Carvalho et al., 2019) destacan al menos tres:

- **Ciencia de datos:** la predicción de los algoritmos de ML está basada en la calidad y la cantidad de datos, y por tanto unas predicciones más precisas conllevan unas explicaciones más exactas.
- **Ciencia humana:** es necesario entender cómo los humanos somos capaces de entender las explicaciones y qué propiedades son necesarias en dicho proceso.
- **Interacción Persona – Computador:** el objetivo principal es capacitar al usuario y dar prioridad a su percepción (Abdul et al., 2018), de forma que se puedan desarrollar sistemas interpretables de fácil visualización.

La interpretabilidad es, por tanto, un hito necesario para el éxito del ML y de la propia IA. Como afirma (Roy, 2017), "al final, los modelos matemáticos deberían ser nuestras herramientas, no nuestros amos", lo que sólo es posible con la interpretabilidad.

Según Miller "La interpretabilidad es el grado en que un humano puede entender la causa de una decisión" (Miller, 2019). Esto significa que en la interpretación de un modelo hay una vinculación directamente proporcional con la causalidad, entender el por qué una predicción fue hecha por el modelo.

Por otro lado, una predicción correcta sólo resuelve parcialmente el problema original, un modelo explicativo de caja negra que tiene una concordancia del 85% con el modelo original, efectivamente, explica el modelo original la mayor parte del tiempo, sin embargo, se equivoca en el 15% de las ocasiones. Por tanto, la confianza en este modelo de caja negra está circunscrita a ese 85% de fiabilidad.

Cuando se consideran problemas que tienen datos estructurados con características relevantes, a menudo no hay una diferencia significativa en el rendimiento entre clasificadores más complejos (redes neuronales profundas, árboles de decisión) y clasificadores mucho más simples (regresión logística, listas de decisión) (Rudin, 2019).

Cuanto más alta es la interpretabilidad de un modelo de aprendizaje automático, más fácil es para alguien comprender por qué se han tomado ciertas decisiones o predicciones. En algunos casos puede no ser relevante entender el por qué se ha tomado una determinada decisión sobre todo en entornos de bajo riesgo, puede ocurrir cuando el impacto en la decisión no sea significativo o bien cuando el problema está suficientemente estudiado y validado en aplicaciones reales (Doshi-Velez & Kim, 2017). Si bien, en la mayoría de las ocasiones debemos entender el por qué ya que puede ayudarnos a conocer mejor el problema y entender las razones por las cuales un modelo puede fallar.

La tendencia en los últimos años ha sido aprovechar las características del ML para la toma de decisiones de alto riesgo, sirvan de ejemplo la utilización en servicios legales, financieros y sanitarios, todos ellos con un profundo impacto en la sociedad y en particular en las vidas humanas (Rudin, 2019). Todo esto hace que estemos abordando un nuevo escenario en la utilización de la interpretabilidad en los procesos de toma de decisión.

Existe un número creciente de ejemplos de modelos predictivos que se fueron deteriorando con el tiempo, los modelos de ML pueden recoger sesgos de los datos de entrenamiento, como ya hemos comentado.

Los sesgos introducidos por los algoritmos de caja negra en los procesos de toma de decisión y su repercusión en la vida de los individuos, constituyen un punto fundamental en la investigación del problema de su interpretabilidad (Miller, 2019; Molnar, 2019).

A continuación, se pasan a enumerar algunos ejemplos de sesgo como resultado de la aplicación de aprendizaje automático en distintos entornos:

- El 7 de noviembre de 2019 el empresario creador de Ruby on Rails, David Heinemeier Hansson compartió una inquietante historia en Twitter (Business, 2019), alegando que la tarjeta de Apple estaba discriminando a su esposa. Tanto él como su esposa solicitaron esta tarjeta, pero él recibió un límite de crédito 20 veces

mayor que ella, a pesar de que la solicitud de la tarjeta la hicieron a la vez y presentan declaraciones de impuesto conjuntas.

- En otoño de 2019, Google reveló una tecnología de ML llamada BERT (Bert, 2018) para mejorar sus criterios de búsqueda, incorporando para ello el contexto de palabras que acompañan el objeto de búsqueda. Sin embargo, los datos con que trabaja corresponden con la mayor biblioteca digital de la historia, arrastrando con ello décadas de prejuicios y sesgos que están incluidos en el algoritmo de búsqueda, con muchas posibilidades de perpetuarse.
- En 2015, la aplicación Google Photos etiquetó a dos afroamericanos como "gorilas" (BBC Mundo Tecnología, 2015). Los ingenieros de Google analizaron la cuenta y descubrieron que el algoritmo tuvo problemas para ajustarse con el contraste de la foto, la iluminación y la tonalidad de piel. Además, confesaron que, debido a este mismo problema, el algoritmo etiquetó a personas de piel blanca como perros y focas.
- En 2016, se observó que alguno de los algoritmos de LinkedIn tenía un sesgo de género (Day, 2016), recomendaba empleos mejor remunerados a hombres. Esta casuística puede estar reforzada por el hecho de que los puestos de elevada remuneración están predominantemente ocupados por hombres.
- En 2016 Microsoft lanzó "Tay" (BBC Mundo, 2016), un chatbot cuyo fin era imitar el comportamiento de una adolescente curiosa que buscaba entablar una conversación informal en redes sociales con un público objetivo entre 18 y 24 años. En menos de 24 horas, Tay a través de tweets, mostraba su empatía hacia Hitler o su apoyo al genocidio al responder a preguntas de los usuarios de las redes sociales.
- En 2016, el algoritmo COMPAS (Correctional Offender Management Profiling for Alternative Sanctions), desarrollado por Northpointe (ahora Equivant), utilizado

para predecir la reincidencia en delitos, incluía un sesgo contra los afroamericanos (Larson et al., 2016).

- En 2018, oncólogos criticaron a Watson for Oncology de IBM por ofrecer recomendaciones inseguras e inexactas (Ross, 2018).
- En 2018, se descubrió que el sistema de Amazon para la detección del currículum vitae estaba sesgado en contra de las mujeres (Dastin, 2018).
- En 2019, se descubre que los algoritmos detrás de la tarjeta de crédito de Apple presentan una propensión a desarrollar sesgos de género (Fast Company, 2019).

Como se puede observar existe un número importante de modelos predictivos que se deterioraron con el tiempo, o sus conjuntos de entrada están sesgados, o bien, existe una utilización de alto riesgo para la seguridad y los derechos de las personas, dando lugar a graves violaciones de los principios éticos y de equidad. En este contexto, se hace imprescindible la construcción de herramientas que permitan realizar una exploración del modelo, en particular que tengan en cuenta la explicación del modelo, su examen y la evaluación de su desempeño, además de la comprensión de sus debilidades y fallos.

Si disponemos de modelos que cumplan con estas variables de diseño, tendremos modelos interpretables pero menos precisos, caja blanca (Molnar, 2019). Otra opción es utilizar modelos más precisos, caja negra, consiguiendo interpretabilidad a través del uso aproximado de modelos de caja blanca y, por último, explicar predicciones de cualquier modelo de ML a través de modelos de explicación agnósticos.

No menos importante es la realización de auditorías algorítmicas para detectar la discriminación y el sesgo, así como incorporar valores éticos a estos sistemas (Carvalho et al., 2019).

Según (Doshi-Velez & Kim, 2017) los aspectos que podrían optimizarse mediante la interpretabilidad son los siguientes:

- Imparcialidad, predicciones imparciales, no discriminatorias.
- Privacidad, protección de la información.
- Fiabilidad, pequeños cambios en la entrada de datos no afecten a la predicción.
- Causalidad, solo recoger las relaciones causales (causa – efecto).
- Confianza, los sistemas deben explicar sus decisiones para que sean confiables.

El objetivo fundamental es ganar la confianza y la aceptación social de los algoritmos de ML mediante la interpretabilidad.

### 3.4.1 Iniciativas hacia una IA Interpretable

Actualmente, no existe un consenso real sobre qué es la interpretabilidad en modelos de ML y tampoco está claro cómo medir dicha interpretabilidad. Sin embargo, compañías tecnológicas, organismos internacionales y administraciones públicas son conscientes del problema y están dando los pasos para mitigar las consecuencias de un sesgo discriminatorio en los algoritmos:

#### 3.4.1.1 Empresas tecnológicas

Se enumeran a continuación una relación de iniciativas relacionadas con el mundo empresarial y la interpretabilidad,

- IBM lanzó en el año 2018 el proyecto Fairness 360 Kit (R. Hughes et al., 2020), este kit de herramientas de código abierto ayuda a examinar, informar y mitigar la discriminación y el sesgo en los modelos de aprendizaje automático. Adversarial Robustness 360 (ART) Toolbox (Adversarial Robustness Toolbox, 2021) es una biblioteca de Python para la seguridad del aprendizaje automático. AI Explainability 360 (AIX360) Toolkit (AI Explainability 360, 2021) es un completo conjunto de herramientas de código abierto con diversos algoritmos, códigos,

guías, tutoriales y demostraciones que apoyan la interpretabilidad y la explicabilidad de los modelos de aprendizaje automático.

- Microsoft dispone de un SDK de interpretación de modelos en Azure Machine Learning para utilizar en Python (Microsoft, 2021).
- Google dispone de un API, Explainable AI (R. Hughes et al., 2020), lo constituyen un conjunto de herramientas y frameworks capaces de ayudar a depurar y entender el comportamiento de los modelos de ML.
- H2O Driverless AI, es una plataforma de aprendizaje automático (H2O.ai., 2020) ofrecida por H2O.ai, ofrece la interpretabilidad como una de sus características distintivas.
- DataRobot (DataRobot, 2021), es otra solución de ML comercializada, "incluye varios componentes que dan lugar a modelos altamente interpretables por los humanos".
- Google Vizier, un servicio para optimizar los modelos de caja negra (Golovin et al., 2017).
- Facebook, en colaboración con Georgia Tech, publicó un artículo en el que muestra una herramienta de exploración visual de modelos DNN a escala industrial (Kahng et al., 2018).
- Uber anunció recientemente Manifold, una herramienta de depuración visual agnóstica de modelos para ML (Zhang et al., 2018).

### 3.4.1.2 Legislación, Organismos y Documentos regulatorios

A medida que las decisiones empresariales y gubernamentales se vuelvan cada vez más automatizadas, será determinante la necesidad de protección ante algoritmos menos interpretables, caja negra. Necesitaremos conocer el cómo y el porqué de las decisiones adoptadas, entender es crucial para avanzar con seguridad. Para ello será necesario trabajar en el control y auditar los algoritmos cuya decisión afecta directamente a las personas, serán necesarios organismos independientes que sean capaces de determinar la “calidad” del algoritmo, otorgando las garantías suficientes a los ciudadanos, aumentando de esta forma la aceptación social de este tipo de prácticas. Asegurándose que se cumplen las siguientes cualidades: equidad, privacidad, fiabilidad, solidez, causalidad, confianza (Doshi-Velez & Kim, 2017).

La elaboración de perfiles y las decisiones automatizadas pueden plantear riesgos importantes en cuanto a derechos y libertades individuales. La legislación europea y española en tema de protección de datos obliga y requiere de ciertas garantías. En el artículo 22° del RGPD (UE, 2016) se establece que los ciudadanos europeos tienen el derecho a no ser objeto de una decisión basada únicamente en medios automatizados, incluida la elaboración de perfiles, si la decisión produce efectos jurídicos que los afecten significativamente de modo similar. ¿Se está cumpliendo este reglamento? ¿Puede el reglamento de la RGPD protegernos de las decisiones tomadas por un sesgo de algoritmo?

Por otro lado, disponemos de la norma ISO/IEC 27001 (Blackmer, 2018), que pretende asegurar la confidencialidad, integridad y disponibilidad de la información de una organización y de los sistemas y aplicaciones que la tratan, esta norma ha sido desarrollada por la Organización Internacional de Normalización (ISO: “International Organization for Standardization”) y por la Comisión Electrotécnica Internacional (IEC: “International Electrotechnical Commission”), que tendrá que adaptar su contenido a las necesidades derivadas de la interpretabilidad en la IA (Weller, 2019). Además, será

necesario definir qué explicación será la más adecuada a cada caso (Goodman & Flaxman, 2017).

Una de las entidades más notables en el campo de investigación de la IA es Defense Advanced Research Projects (DARPA), creó el programa XAI (Gunning et al., 2019). En el año 2016 la Oficina de Política Científica y Tecnológica de la Casa Blanca (OSTP) publicó el informe estadounidense sobre la IA titulado "Preparing for the Future of Artificial Intelligence" (Bundy, 2017).

La Royal Society, que es la Academia de Ciencias del Reino Unido, publicó en abril de 2017 un informe sobre su proyecto de aprendizaje automático (Royal Society of Great Britain, 2017).

En España se constituyó en diciembre de 2019 el subcomité técnico de normalización CTN 71/SC 42 – Inteligencia Artificial y Big Data (UNE, 2021) precisamente para elaborar estándares en el campo de la IA, participando en el desarrollo de los estándares a nivel global que se están desarrollando en el comité internacional ISO/IEC JTC 1/SC 42 Artificial Intelligence (Standardization, 2021).

En abril de 2018, la Comisión Europea publicó el siguiente comunicado sobre la Inteligencia Artificial para Europa (Commission, 2018). En 2019, el Grupo de Expertos de Alto Nivel sobre Inteligencia Artificial formuló unas directrices sobre una IA confiable (European Commission, 2019). Paralelamente, en diciembre de 2018 se publicó el primer plan coordinado sobre la IA como compromiso conjunto con los Estados miembros (Digitales et al., 2020).

El Libro Blanco de la Comisión sobre la IA, publicado en 2020, expone una visión clara de la IA en Europa: “un ecosistema de excelencia y confianza que sienta las bases de la propuesta de hoy” (Comisión Europea, 2020).

En abril de 2021, la Comisión Europea, lanza un plan coordinado con los estados miembros y con el objetivo de fortalecer la confianza y la excelencia en la IA, el

planteamiento está basado en el riesgo, y penaliza incluso prohíbe, los sistemas de IA que se consideren una clara amenaza para la seguridad. Los sistemas de alto riesgo estarán sujetos a obligaciones estrictas antes de que puedan comercializarse (Munchen, 2021).

Poco a poco tanto los países pertenecientes a la UE como el resto de los países se irán sumando a iniciativas de este tipo, de forma que se pueda ofrecer un atisbo de esperanza e intentar garantizar la confiabilidad en sistemas de IA.

### 3.4.1.3 Ciencia e Investigación

La forma más fácil de lograr la interpretabilidad es utilizar algoritmos de ML interpretables, caja blanca, entre ellos, la regresión lineal, regresión logística, los árboles de decisión, RuleFit y Naive Bayes (Molnar, 2019). De estos modelos se pueden extraer características en función de otras que permiten definir e interpretar el modelo a nivel global (Sundararajan et al., 2017).

Por otro lado, existen métodos de explicación específicos para cada algoritmo de ML, muchos de estos modelos están diseñados para ser utilizados con redes neuronales de difícil interpretabilidad, caja negra. Otra opción es extraer conocimiento de un modelo más complejo, aproximándolo mediante un modelo interpretable (Bastani et al., 2017), (Tan et al., 2018).

Por último, tenemos los métodos de explicación agnósticos, no dependen del modelo de ML, y son post hoc, la gran ventaja de estos modelos frente a los específicos es su flexibilidad, si bien, en algunos casos, podría resultar más eficaz utilizar métodos específicos que un modelo puramente agnóstico, ya que este último no aprovecha las propiedades intrínsecas de un modelo específico (Carvalho et al., 2019).

Una visión general de modelos agnósticos se representa en la siguiente Tabla (Carvalho et al., 2019):

Tabla 4. Métodos Interpretables

Explanation Method	Scope	Result
Partial Dependence Plot	Global	Feature Summary
Individual Condition Expectation	Global / Local	Feature Summary
Accumulated Local Effects Plot	Global	Feature Summary
Feature Interaction	Global	Feature Summary
Feature Importance	Global / Local	Feature Summary
Local Surrogate Model	Local	Surrogate Interpretable Model
Shapley Values	Local	Feature Summary
BreakDown	Local	Feature Summary
Anchors	Local	Feature Summary
Counterfactual Explanations	Local	(new) Data Point
Prototypes and Criticisms	Global	(existent) Data Point
Influence Functions	Global / Local	(existent) Data Point

La tendencia actual es centrar la atención en herramientas de interpretación independientes del modelo, es mucho más fácil automatizar la interpretabilidad si separamos el método de interpretación del modelo utilizado. Con métodos agnósticos podemos reemplazar tanto el modelo de aprendizaje como el método de interpretación, las capacidades que brinda este sistema son altamente escalables (Carvalho et al., 2019; Molnar, 2019; Ribeiro et al., 2016a).

A continuación, se detalla una relación de estudios relacionados con los métodos de interpretabilidad aplicados a modelos de ML de caja negra.

Tabla 5. Estudios Interpretabilidad ML

Modelos	Autor	Descripción
Lime Eli5 InterpretML AIX360 Skater	(Ribeiro et al., 2016b)	"Why Should I Trust You?" Explaining the Predictions of Any Classifier
PDPbox InterpretML Skater	(Friedman, 2001)	Greedy function approximation: A gradient boosting machine
Shap Alibi AIX360 InterpretML	(Lundberg & Lee, 2017)	A unified approach to interpreting model predictions
Eli5	(Altmann et al., 2010)	Permutation importance: A corrected feature importance measure
PyCEbox	(Goldstein et al., 2015)	Peeking inside the black box: Visualizing statistical learning with plots of individual conditional expectation
DLIME	(Zafar & Khan, 2019)	DLIME: A Deterministic Local Interpretable Model-Agnostic Explanations Approach for Computer-Aided Diagnosis Systems
AIX360	(Gurumoorthy & Cecchi, n.d.)	Efficient Data Representation by Selecting Prototypes with Importance Weights

---

### 3.4.2 Indicadores de Interpretabilidad

¿Podemos medir y evaluar la interpretabilidad? A pesar de todo el trabajo que se está realizando en diferentes áreas de conocimiento, esta cuestión lamentablemente sigue sin respuesta. Si bien, el trabajo que se está realizando va orientado en dos líneas claras, el uso de algoritmos de ML que permitan tener un alto grado de precisión y en hacer que la decisión adoptada por estos sistemas sea interpretable, explicable para el ser humano.

Haciendo una revisión de la literatura, podemos concluir que se ha trabajado poco en el desarrollo de modelos que permitan medir y evaluar las interpretaciones, de forma que se pueda elegir la explicación más adecuada (Honegger, 2018). Si bien, podemos distinguir dos tipos de indicadores a la hora de comparar y evaluar explicaciones (Carvalho et al., 2019), cuantitativos y cualitativos.

Dentro de los indicadores cualitativos en los trabajos (Doshi-Velez & Kim, 2017, 2018) se mencionan los siguientes indicadores:

- ¿De qué están compuestas las explicaciones? ¿Qué características son las predominantes en una explicación?
- ¿Con cuántos subconjuntos de bloques de características se puede tener una explicación? ¿Y si suprimimos algún bloque, se ve afectado el resultado?
- ¿Cómo están formados esos bloques? ¿Qué composición se debe dar entre los bloques?
- ¿Qué relaciones pueden ser más intuitivas para los humanos?
- ¿Algún proceso aleatorio forma parte de la explicación?

Como se puede ver, todas estas preguntas no son fáciles de responder, si bien, es necesario escarbar en el modelo para interpretarlo correctamente. La mente humana está

---

hecha para manejar un número limitado de características, cuanto menor sea el número de bloques que interactúen para dar una explicación, mayor será su comprensión.

Para los indicadores cuantitativos (Honegger, 2018; Sundararajan et al., 2017) establecen un marco de trabajo en el que se mide la consistencia de los métodos de explicación cuya predicción debe ser coherente con la explicación humana. Es necesario según (Honegger, 2018) relacionar el objeto (instancia y predicción) con su consiguiente explicación (valor de importancia de las características).

- **Identidad.** Los objetos idénticos deben tener explicaciones idénticas. Si a un método de explicación se le pide que explique un determinado objeto, las explicaciones que dé tienen que ser iguales.
- **Separabilidad.** Los objetos no idénticos no pueden tener explicaciones idénticas. Es consecuencia de la anterior premisa.
- **Estabilidad.** Los objetos similares deben tener explicaciones similares. Si ligeras perturbaciones modifican considerablemente la respuesta, el sistema no es estable.

Además, hay que tener en cuenta otras variables como puede ser la completitud, la audiencia tiene que verificar la validez de la explicación. La corrección, la explicación debe generar confianza. Y por último la compactación, la explicación debe ser precisa, breve y concisa.

## 4. Marco teórico de la investigación

En este capítulo se aborda el marco teórico de investigación, se introducirá el modelo LD2T, el modelo RFM, el modelo de toma de decisiones AHP y el tratamiento de información heterogénea en la toma de decisiones, estos modelos serán utilizados durante nuestra propuesta. Además, se introduce un epígrafe abordando los métodos de interpretabilidad en modelos de ML, que se aplicarán en el modelado de toma de decisiones relacionado con la tasa de abandono de clientes en un entorno B2B.

### 4.1 Modelo Lingüístico Difuso 2-Tupla

En numerosas ocasiones la información necesaria para la toma de decisiones no está representada en el mismo dominio de expresión. Si es así, se puede dar el caso de que algunos criterios involucrados en el proceso de toma de decisión sean no cuantificables en valores numéricos, presentando de esta forma imprecisión y por tanto subjetividad. En estos casos será necesario utilizar un modelo que permita obtener valoraciones intermedias y globales que sean interpretables bajo un mismo dominio de expresión. Es por ello por lo que utilizaremos un dominio lingüístico (F. Herrera & Martínez, 2000) para la unificación de la información tratada en nuestros dos modelos RFID y VIUE.

El modelo 2-tupla fue propuesto por (Francisco Herrera & Martínez, 2000), el objetivo de este modelo es el de mejorar los problemas de pérdida de información presentes en los procesos de computación con etiquetas lingüísticas, a continuación se revisa brevemente el modelo lingüístico de representación 2-tupla y su modelo computacional. Dicho modelo tiene como base de representación un par de valores  $(s_i, \alpha_i)$ , donde  $s_i \in S$  y  $\alpha_i \in [-0.5, 0.5)$ .

**Definición 1.** Sea  $S = \{s_0, \dots, s_g\}$  un conjunto de términos lingüísticos, y  $\beta \in [0, g]$  un valor en el intervalo de granularidad de  $S$ . La traslación simbólica de un término lingüístico  $s_i$  es un número valorado en el intervalo  $[-0.5, 0.5)$  que expresa la diferencia de información entre una cantidad de información expresada por el valor  $\beta \in [0, g]$  obtenido en una operación

simbólica y el valor entero más próximo,  $i \in \{0, \dots, g\}$ , que indica el índice de la etiqueta lingüística ( $s_i$ ) más cercana en  $S$ .

Este modelo de representación define un par de funciones para realizar transformaciones entre valores numéricos definidos en el intervalo de la granularidad y valores lingüísticos 2-tupla con el objetivo de realizar los procesos computacionales sobre valores lingüísticos 2-tupla.

**Definición 2.** Sea  $S = \{s_0, \dots, s_g\}$  un conjunto de términos lingüísticos,  $\langle S \rangle = S \times [-0.5, 0.5]$  y  $\beta \in [0, g]$  un valor que representa el resultado de una operación simbólica entonces la valoración lingüística 2-tupla que expresa la información equivalente a  $\beta$  se obtiene usando la siguiente función:

$$\Delta_S : [0, g] \rightarrow \langle S \rangle$$

$$\Delta_S(\beta) = (s_i, \alpha_i), \text{ con } \begin{cases} i = \text{round}(\beta) \\ \alpha = \beta - i, \quad \alpha \in [-0.5, 0.5), \end{cases} \quad (1)$$

donde  $\text{round}(\cdot)$  es el operador de redondeo,  $s_i$  es la etiqueta con índice más cercano a  $\beta$  y  $\alpha$  es el valor de la traslación simbólica.

Así un valor en el intervalo  $[0, g]$  siempre queda identificado con un valor lingüístico 2-tupla en  $\langle S \rangle$ .

**Definición 3.** Sea  $S = \{s_0, \dots, s_g\}$  un conjunto de términos lingüísticos y  $(s_i, \alpha_i) \in \langle S \rangle = S \times [-0.5, 0.5]$ . El valor numérico en el intervalo de granularidad  $[0, g]$  que representa el valor lingüístico 2-tupla  $(s_i, \alpha_i)$  se obtiene utilizando la función:

$$\Delta_S^{-1} : \langle S \rangle \rightarrow [0, g] \quad (2)$$

$$\Delta_S^{-1}(s_i, \alpha_i) = i + \alpha = \beta$$

Junto con el modelo de representación visto anteriormente, podemos analizar el modelo computacional asociado, para ello se definen los siguientes operadores:

**Operador de comparación de valores lingüísticos 2-tupla.** Dados dos valores lingüísticos 2-tupla  $(s_k, \alpha_1)$  y  $(s_l, \alpha_2)$  que representan cantidades de información:

- Si  $k < l$ , entonces  $(s_k, \alpha_1)$  es menor que  $(s_l, \alpha_2)$ .
- Si  $k = l$ , entonces
  - a) Si  $\alpha_1 = \alpha_2$ , entonces  $(s_k, \alpha_1)$  y  $(s_l, \alpha_2)$  representan la misma información.
  - b) Si  $\alpha_1 < \alpha_2$ , entonces  $(s_k, \alpha_1)$  es menor que  $(s_l, \alpha_2)$ .
  - c) Si  $\alpha_1 > \alpha_2$ , entonces  $(s_k, \alpha_1)$  es mayor que  $(s_l, \alpha_2)$ .

**Operador de negación de un valor lingüístico 2-tupla.** Se define como:

$$\text{neg}(s_i, \alpha) = \Delta_S (g - (\Delta_S^{-1}(s_i, \alpha))) \quad (3)$$

siendo  $g+1$  la cardinalidad del conjunto de etiquetas lingüísticas  $S$ .

**Operadores de agregación para valores lingüísticos 2-tupla.** La agregación de información consiste en obtener un valor lingüístico 2-tupla que resuma un conjunto de valores 2-tupla. Describimos los operadores de agregación que utilizaremos en nuestro modelo:

**Definición 4.** Sea  $((s_1, \alpha_1), \dots, (s_m, \alpha_m))$  un vector de valores lingüísticos 2-tupla en  $\langle S \rangle$ , el valor lingüístico 2-tupla que simboliza la Media Aritmética,  $\bar{x}^e$ , está dada por la función  $\bar{x}^e: \langle S \rangle^m \rightarrow \langle S \rangle$  definida como:

$$\bar{x}^e((s_1, \alpha_1), \dots, (s_m, \alpha_m)) = \Delta_S \left( \sum_1^m \frac{1}{m} \Delta_S^{-1}(s_i, \alpha_i) \right) = \Delta_S \left( \frac{1}{m} \sum_1^m \beta_i \right) \quad (4)$$

**Definición 5.** Sea  $((s_1, \alpha_1), \dots, (s_m, \alpha_m))$  un vector de valores lingüísticos 2-tupla en  $\langle S \rangle$ , y  $\omega = (\omega_1, \dots, \omega_m)$  donde  $\omega_i \in [0,1]$  un vector de pesos tal que  $\sum_1^m \omega_i = 1$ , entonces el valor lingüístico 2-tupla que simboliza la Media Ponderada asociada con  $\omega$  está dada por la función  $F^\omega \langle S \rangle^m : \rightarrow \langle S \rangle$  definida como:

$$F^\omega((s_1, \alpha_1), \dots, (s_m, \alpha_m)) = \Delta_S \left( \sum_1^m \omega_i \Delta_S^{-1}(s_i, \alpha_i) \right) \quad (5)$$

## 4.2 Modelo RFM

El modelo RFM sigue una metodología que nos permite segmentar a los clientes según características similares. Se utiliza para medir la Recencia, Frecuencia y Valor Monetario en las transacciones del cliente con la marca.

La idea, por tanto, consiste en categorizar a cada cliente mediante puntuaciones basadas en estas tres variables, utilizando típicamente quintiles (el 5 representa el 20% de los mejores clientes en esa variable y el 1 el 20% de los peores), a partir de los cuales se calcula una única puntuación que representa el valor del cliente. Sin embargo, estas puntuaciones no son muy precisas, por lo que en (Ramón Alberto Carrasco et al., 2019) se propone una mejora del RFM, que consiste en representar estas puntuaciones mediante el modelo de 2-tupla. A continuación, se explican las etapas de esta propuesta:

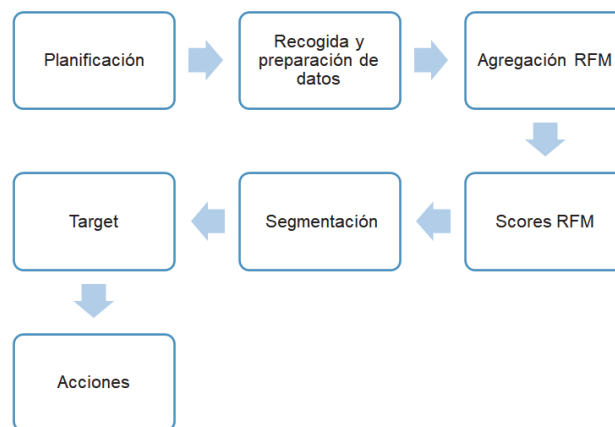


Figura 5. Etapas modelado RFM (Ramón Alberto Carrasco et al., 2019)

- **Recogida y preparación de datos.** Sea  $U = \{u_1, \dots, u_{\#U}\}$  el conjunto de clientes que han realizado al menos una compra durante un periodo de análisis preestablecido,  $T = \{u_1, d_1, a_1, \dots, u_{\#T}, d_{\#T}, a_{\#T}\}$  el detalle de las transacciones realizadas por estos clientes en ese período, donde  $u_j \in U$  identifica al cliente que ha realizado la compra en fecha  $d_i$  por el importe  $a_i$ .
- **Agregación RFM.** En esta fase,  $T$  se agrega a nivel de cliente, obteniendo el conjunto  $TU = \{u_1, r_1, f_1, m_1, \dots, u_{\#U}, r_{\#U}, f_{\#U}, m_{\#U}\}$ , donde  $r_e$  serían los días transcurridos desde

la última compra del cliente  $u_e$  (utilizando una fecha de referencia fija posterior para todas las compras del cliente),  $f_e$  es el número de veces que el cliente ha comprado, y  $m_e$  corresponde con el importe total de dichas compras.

- **Puntuaciones RFM.** Sea  $RFM = \{(u_1, R_1, F_1, M_1, RFM_1), \dots, (u_{\#U}, R_{\#U}, F_{\#U}, M_{\#U}, RFM_{\#U})\}$  con las puntuaciones RFM 2-tupla. En primer lugar, se define un dominio  $S$  simétrico y uniformemente distribuido que utiliza cinco etiquetas lingüísticas. Estas etiquetas tienen un significado semántico para las variables del modelo RFM referido:

Sea  $S = \{s_0, \dots, s_T\}$  con  $T = 4: s_0 = \text{Very Low} = VL, s_1 = \text{Low} = L, s_2 = \text{Moderate} = M, s_3 = \text{High} = H, s_4 = \text{Very High} = VH$ , con la definición mostrada en la Figura 6.

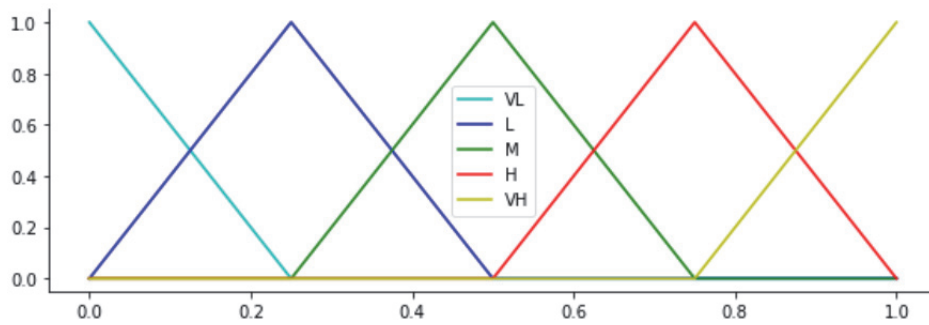


Figura 6. Definición del conjunto  $S$

Por tanto, tenemos las variables objeto de cálculo:  $R_e, F_e, M_e, RFM_e \in S \times [-0.5, 0.5]$ . Para cada cliente  $u_e$ ,  $e = 1, \dots, \#U$ , obtenemos  $A_e = (A_{e1}, A_{e2}, A_{e3})$  con  $A_{e1} = R_e, A_{e2} = F_e, A_{e3} = M_e$ . En primer lugar, los clientes se clasifican en orden ascendente según cada uno de los componentes individuales  $B_e = (B_{e1}, B_{e2}, B_{e3})$  con  $B_{e1} = r_e, B_{e2} = f_e, B_{e3} = m_e$ , contenida en TU. Se define,  $rank \in \{1, \dots, \#U\}$  como la clasificación de cada cliente respecto a cada una de estas variables:

$$\text{percent\_rank}_e(B_{ei}) = \frac{\text{rank}(B_{ei} - 1)}{\#U - 1} \quad (6)$$

con  $percent\_rank \in [0,1]$ ,  $e = 1, \dots, \#U$  e  $i = 1, \dots, 3$ . La puntuación final 2-tupla  $A_{ei}$  se obtiene como sigue:

$$A_{ei} = \begin{cases} \Delta(percent\_rank(B_{ei})), & \text{if } i \neq 1 \\ neg(\Delta(percent\_rank(B_{ei})), & \text{if } i = 1 \end{cases} \quad (7)$$

donde  $\Delta(\cdot)$  y  $neg(\cdot)$  se han definido en el punto 4.1 (Ecuaciones 1 y 3). Utilizamos la función de negación para la recencia ya que las puntuaciones más altas representan a los compradores más recientes.

- **RFM Cálculo de la puntuación global.** En este paso, el valor 2-tupla  $RFM_e$ , que caracteriza conjuntamente las puntuaciones  $R_e$ ,  $F_e$  y  $M_e$  se calcula para cada cliente utilizando la Ecuación 5 como  $RFM_e = F^\omega [A_{ei}]$ , con los pesos de las ponderaciones  $W = \{w_R, w_F, w_M\}$  definidos previamente por los expertos del área de marketing.

### 4.3 Modelo AHP

En un entorno cotidiano y más en el mundo empresarial, el problema de toma de decisiones es crítico, diariamente se presentan complejos problemas que no son fáciles de resolver porque implican un gran volumen de criterios, subcriterios y alternativas (Khaira & Dwivedi, 2018).

Factores que hay que tener en cuenta dentro de los procesos de toma de decisión (TD) son, el número de criterios, el ambiente de decisión y el número de expertos (Cid-López et al., 2016).

- El número de criterios. Si el número de criterios es mayor que uno, nos encontramos ante un problema de toma de decisiones multicriterio. Los problemas MCDM son mucho más complicados de resolver que los problemas en los que interviene un solo criterio, ya que requieren un paso de unificación de información, y en muchos casos ésta es heterogénea.

- El ambiente de decisión. Si conocemos con exactitud todos los factores que intervienen en el problema de decisión, estamos hablando de un ambiente de certidumbre. Por el contrario, si la información de la que disponemos es imprecisa o no muy concreta estamos hablando de problema de decisión con incertidumbre. Y si alguno de los factores responde al azar, el ambiente es de riesgo.
- El número de expertos. En el caso de participar varios expertos en la toma de decisión, el problema se complica, tenemos que ser capaces de agregar la información de todos los expertos para resolver el problema. Sin embargo, puntos de vista distintos proporcionan al problema una solución más satisfactoria, se conoce como toma de decisión en grupo (TDG).

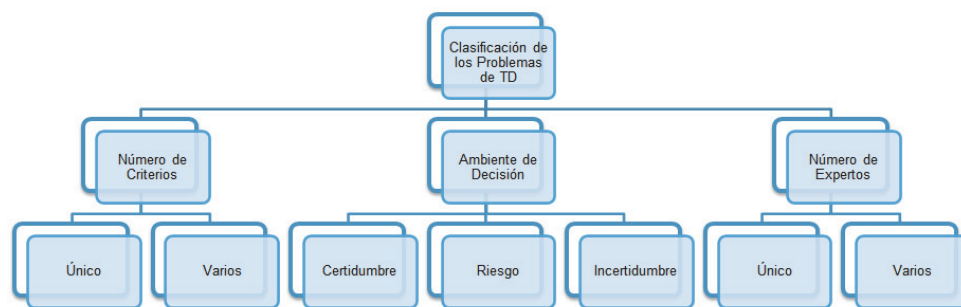


Figura 7. Clasificación de los Problemas de TD

Lo más habitual en entornos empresariales es que los problemas de TD involucren múltiples criterios y múltiples expertos (MCDM-ME).

Dentro de los modelos MCDM se encuentra el método AHP (Thomas L Saaty, 1980). Basado en las matemáticas y en la psicología, está diseñado para resolver problemas complejos de criterios múltiples (Bernasconi et al., 2009).

La principal característica del modelo AHP, es que el problema de decisión se modeliza mediante una jerarquía en cuyo vértice superior está el principal objetivo del problema, meta a alcanzar, y en la base se encuentran las posibles alternativas a evaluar. En los niveles intermedios se representan los criterios (los cuales a su vez se pueden

estructurar también en jerarquías) en base a las cuales se toma la decisión. La segunda característica del método es que, en cada nivel de la jerarquía, se realizan comparaciones entre pares de elementos de ese nivel, en base a la importancia o contribución de cada uno de ellos al elemento de nivel superior al que están ligados. Por último, una vez evaluada la contribución de cada elemento a los elementos del nivel de la jerarquía inmediatamente superior, se calcula la contribución global de cada alternativa al objetivo principal o meta mediante una agregación de tipo aditivo (T. L. Saaty, 2002; Thomas L. Saaty, 2013).

En el modelo RFID, se utilizará el método AHP para establecer los pesos de cada uno de los criterios que determinarán la puntuación total de cada cliente, una vez realizado el proceso de agregación y clasificación mediante el modelo RFM 2-tupla.

En el modelo VIUE nos ayudará a determinar los pesos de cada uno de los criterios que determinarán la valoración final y en consecuencia la priorización de la interacción entre cliente y marca.

Todo este proceso se detalla en los siguientes subapartados.

### 4.3.1 Estructuración del problema de decisión en un modelo jerárquico

El primer paso del método AHP consiste en modelar el problema de decisión que se pretende resolver como una jerarquía. Este hecho es una de las principales características del método, de ahí que el término “jerárquico” aparezca en su denominación.

Consiste en la descomposición del problema de decisión en elementos, según sus características comunes, construyendo de forma visual un modelo jerárquico de diferentes criterios interrelacionados, facilitando su comprensión y evaluación. El primer nivel contiene siempre el objetivo del problema,  $G$ , el segundo nivel está constituido por los criterios, este nivel puede subdividirse en subcriterios, y el último nivel contiene las diferentes alternativas. Así, en este paso definimos el conjunto de alternativas  $A = \{a_1, \dots, a_{1\#A}\}$  y los criterios jerárquicos para su evaluación  $C. C_1 = \{c_{11}, \dots, c_{1\#C1}\}$ , cada uno

de estos criterios  $c_{1i}$  puede, a su vez, ser dividido en subcriterios, en varios niveles,  $c_{1ij} = \{c_{1i1}, \dots, c_{1\#cij}\}$  y así de forma recursiva, Figura 8.

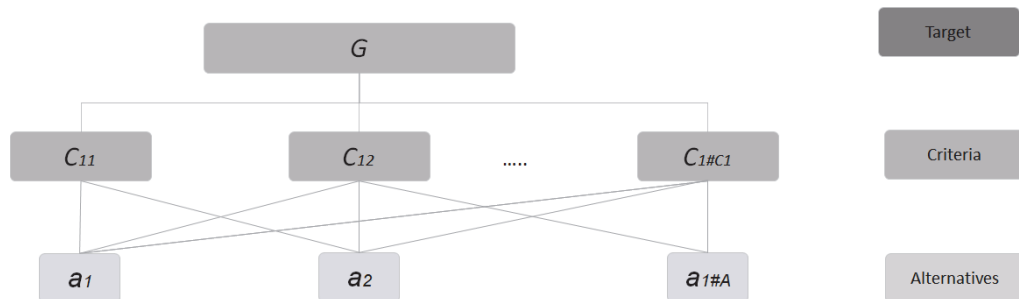


Figura 8. Ejemplo de estructura jerárquica AHP

Como podemos observar en la Figura 8, el objetivo de la toma de decisión se encuentra en el nivel superior, los criterios y subcriterios definen los niveles inferiores, las alternativas se definen en función de criterios y subcriterios. Es importante que no existan dependencias entre criterios para que la metodología AHP pueda ser representativa y las conclusiones obtenidas sean las más adecuadas al problema de decisión definido.

### 4.3.2 Comparaciones por pares y obtención de la matriz de valoración

En este paso, la opinión de los decisores se utiliza para hacer una comparación por pares, es decir, los elementos de un nivel particular con respecto a un elemento específico del nivel inmediatamente superior, de esta forma,  $PW = (pw_{ij}) n \times n$  es una matriz de comparación por pares donde los elementos  $pw_{ij}$  representan la importancia del criterio  $i$  sobre el criterio  $j$ , evaluados por los responsables de la toma de decisión, donde el valor de la importancia relativa de un criterio con respecto a otro en relación al objetivo, así como la importancia relativa de un subcriterio con respecto a otro en relación al criterio padre, los cuales se representan a través de la escala de valoración predefinida de números de la

Tabla 6. Cada entrada  $a_{ij}$  de la matriz de comparación por pares está gobernada por las siguientes reglas:  $pw_{ij} > 0$ ;  $pw_{ij} = \frac{1}{pw_{ji}}$  y su recíproca; y  $pw_{ii} = 1$  para todo  $i$ .

Tabla 6. Escala Saaty (Thomas L. Saaty, 2008)

Valor	Significado	Explicación
1	Igual importancia	Los dos elementos contribuyen de igual manera al objetivo.
2	Débil o Ligero	
3	Importancia moderada	La experiencia y el juicio favorecen ligeramente una actividad sobre otra.
4	Moderada plus	
5	Gran importancia	La experiencia y el juicio favorecen fuertemente una actividad sobre otra.
6	Importancia plus	
7	Importancia muy fuerte	Una actividad se ve favorecida en gran medida sobre otra.
8	Importancia muy, muy fuerte	
9	Importancia extrema	Las pruebas que favorecen una actividad sobre otra son del mayor orden de afirmación posible.
Valores Recíprocos		Si la actividad $i$ tiene asignado uno de los números anteriores distinto de cero cuando se compara con la actividad $j$ , entonces $j$ tiene el valor recíproco cuando se compara con $i$ .

### 4.3.3 Obtención de ponderaciones locales y revisión de la coherencia de las comparaciones

El vector de pesos de los criterios,  $w$ , se construye mediante el método de los vectores propios a través de la siguiente ecuación:

$$\sum_{j=1}^n pw_{ij}w_j = \lambda_{max} w_i \quad (8)$$

donde  $\lambda_{max}$  es el valor propio máximo de  $PW$  y  $w$  es el vector propio normalizado asociado al valor propio principal de  $PW$ . Este enfoque proporciona las mejores ponderaciones de prioridad para cada criterio o subcriterio. La consistencia del método AHP puede ser chequeada a través del Ratio de Consistencia (CR) el cual es definido como:

$$CR = \frac{CI}{RI} \quad (9)$$

Es decir, el cociente entre el Índice de Consistencia ( $CI$ ), definido como  $\frac{\lambda_{max}-n}{n-1}$  y el Índice de Consistencia Aleatoria ( $RI$ ), ver Tabla 7, el cual representa la consistencia de una matriz de comparación por pares generada aleatoriamente. Si  $CR \leq 0.1$  los resultados del

tipo jerárquico individual se satisfacen y se garantiza la coherencia, de lo contrario será necesario ajustar los valores de los elementos de la comparación por pares, y los juicios deberán ser ajustados de nuevo por los decisores hasta que sean consistentes.

Tabla 7. Valores de consistencia aleatoria en función del tamaño de la matriz. (Thomas L. Saaty, 2008)

n	1	2	3	4	5	6	7	8	9	10
Random Consistency Index (RI)	0	0	0.58	0.9	1.12	1.24	1.32	1.41	1.45	1.49

Por otro lado, disponemos los siguientes tramos proporcionados por Saaty, para valorar si la matriz resultante del modelo AHP es o no consistente.

Tabla 8. Límites de consistencia (Saaty, 2008)

Tamaño de la matriz (n)	Ratio de Consistencia
3	5%
4	9%
≥5	10%

#### 4.4 Tratamiento de Información Heterogénea

En el presente trabajo realizaremos la unificación de información heterogénea basándonos en un dominio de información lingüística 2-tupla (F. Herrera et al., 2005). Antes de realizar el proceso de unificación, será necesario definir el Conjunto Básico de Términos Lingüísticos (CBTL), la computación y resultados obtenidos se realizarán sobre dicho modelo.

La selección del dominio CBTL  $\bar{S} = \{s_0, \dots, s_g\}$  se realiza obteniendo el conjunto de términos lingüísticos de máxima granularidad dentro del marco heterogéneo (F. Herrera et al., 2000). Haciendo una selección de este tipo, mantenemos el máximo grado

de información representada dentro del dominio lingüístico. Una vez seleccionado el CBTL, pasamos a realizar la transformación de los distintos dominios de expresión al conjunto CBTL seleccionado.

La información puede estar representada en distintos dominios: numérico, intervalar y lingüístico; para cada uno de ellos analizamos cómo funciona el proceso (F. Herrera et al., 2005).

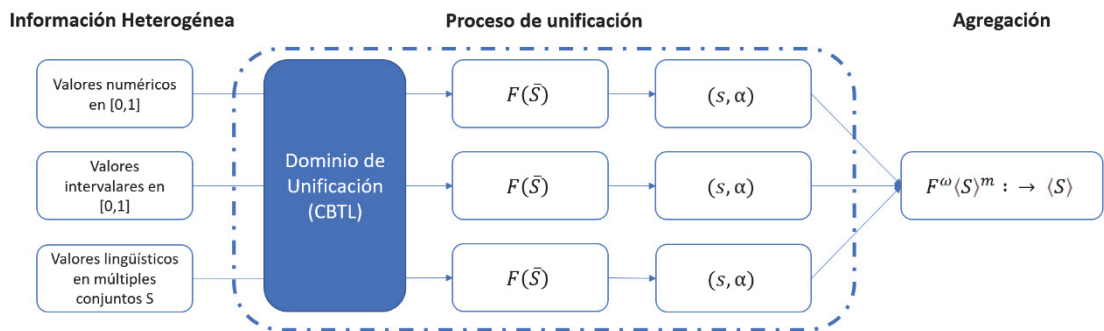


Figura 9. Modelo de unificación de información heterogénea en valoraciones lingüísticas 2-tupla (F. Herrera et al., 2005)

### Dominio numérico

- **Definición 1.** Dado un valor numérico  $n \in [0,1]$  y el conjunto perteneciente al dominio CBTL  $\bar{S} = \{\bar{s}_0, \dots, \bar{s}_g\}$  la función de transformación numérica  $T_{N\bar{S}}: [0,1] \rightarrow F(\bar{S})$ , se define como:

$$T_{N\bar{S}}(n) = \{(\bar{s}_0, \gamma_0), \dots, (\bar{s}_g, \gamma_g)\}, \bar{s}_i \in \bar{S} \quad (10)$$

con

$$\gamma_i = \mu_{\bar{s}_i}(n) = \begin{cases} 0 & \text{si } n \notin \text{soporte}(\mu_{\bar{s}_i}(x)) \\ \frac{n - a_i}{b_i - a_i} & \text{si } a_i \leq n \leq b_i \\ \frac{c_i - n}{c_i - b_i} & \text{si } b_i \leq n \leq c_i \end{cases} \quad (11)$$

donde  $\gamma_i = \mu_{\bar{s}_i}(n) \in [0, 1]$  es el grado de pertenencia de  $n$  a  $\bar{s}_i \in \bar{S}$ .




Figura 10. Transformación de un valor numérico, 0.32, a  $F(\bar{S})$

$$T_{N\bar{S}}(0.32) = \{(\bar{s}_0, 0), (\bar{s}_1, 0.72), (\bar{s}_2, 0.28), (\bar{s}_3, 0), (\bar{s}_4, 0)\}$$

**Dominio intervalar**

- Definición 2.** Dado un valor  $u = [a, b] \in P([0,1])$  y el conjunto perteneciente al dominio CBTL,  $\bar{S} = \{\bar{s}_0, \dots, \bar{s}_g\}$  la función de transformación intervalar  $T_{I\bar{S}}: P([0,1]) \rightarrow F(\bar{S})$  se define como:

$$T_{I\bar{S}}(u) = \{(\bar{s}_k, \gamma_k^i) / k \in \{0, \dots, g\}\} \tag{12}$$

donde  $\gamma_k^i = \max_y \min\{\mu_I(y), \mu_{\bar{s}_k}(y)\}$ ;  $\mu_I(y)$ ,  $\mu_{\bar{s}_k}(y)$  identifican respectivamente a las funciones de pertenencia asociadas al intervalo  $I$  y los términos  $\bar{s}_k$ .

$$\mu_I(y) = \begin{cases} 0 & \text{si } y < a \\ 1 & \text{si } a \leq y \leq b ; \text{ con } y \in [0,1] \\ 0 & \text{si } y > b \end{cases} \tag{13}$$




Figura 11. Transformación de un valor intervalar, [0.32, 0.64] a  $F(\bar{S})$

$$T_{I\bar{S}}([0.32, 0.64]) = \{(\bar{s}_0, 0), (\bar{s}_1, 0.72), (\bar{s}_2, 1.0), (\bar{s}_3, 0.56), (\bar{s}_4, 0)\}$$

### Dominio lingüístico

- Definición 3.** Dado  $S = \{l_0, \dots, l_h\}$ , y el conjunto perteneciente al dominio CBTL  $\bar{S} = \{\bar{s}_0, \dots, \bar{s}_g\}$ , ambos dos conjuntos de términos lingüísticos, tal que  $g \geq h$ . La función de transformación lingüística  $T_{S\bar{S}}: S \rightarrow F(\bar{S})$  se define como:

$$T_{S\bar{S}}(l_i) = \{(\bar{s}_k, \gamma_k^i) / k \in \{0, \dots, g\}\} \quad \forall l_i \in S \quad (14)$$

donde  $\gamma_k^i = \max_y \min\{\mu_{l_i}(y), \mu_{\bar{s}_k}(y)\}$ ,  $i = 0, \dots, g$  y  $\mu_{l_i}(y)$ ,  $\mu_{\bar{s}_k}(y)$  identifican respectivamente a las funciones de pertenencia asociadas a los términos  $l_i$  y  $\bar{s}_k$ .




Figura 12. Transformación de un término lingüístico

Una vez realizada la unificación de la información heterogénea en un dominio lingüístico 2-tupla, pueden ser aplicadas las operaciones definidas en el apartado 4.1 del presente documento. Los resultados obtenidos en este sentido son interpretables y unifican en un único dominio las valoraciones heterogéneas en relación con un determinado criterio.

## 4.5 Interpretabilidad en Modelos de Machine Learning

Las decisiones amparadas bajo algoritmos de ML cada vez tienen un impacto social más significativo, sin embargo, la mayoría de estos sistemas están basados en algoritmos poco interpretables, modelos cuyas reglas no son comprensibles para el ser humano. Por otro lado, distintos organismos tanto públicos como privados, así como la comunidad

científica (Casillas, J., Cordon, O., Triguero, F. H., & Magdalena, 2013) han reconocido el problema de la interpretabilidad, centrándose en el desarrollo de modelos interpretables, basados en métodos que permitan la explicación.

Con el marco teórico propuesto hasta ahora, podemos proporcionar un entorno de toma de decisiones aceptable, si bien, nos queda completar una fase importante, una vez establecido y determinado el perfil del cliente, precisamos realizar investigación adicional, responder a preguntas relativas a la tasa de abandono tanto del cliente, como del personal propio de la compañía, o bien, por qué un determinado cliente es clasificado de una determinada forma, o por qué se realizan determinadas acciones de marketing hacia un segmento y otras distintas hacia otro. O por qué la segmentación de un cliente implica que no se le proporcione un cierto crédito, o un cierto nivel de descuento.

Por citar de nuevo a Miller "La interpretabilidad es el grado en que un humano puede entender la causa de una decisión" (Miller, 2019). Esto significa que en la interpretación de un modelo hay una vinculación directamente proporcional con la causalidad, entender el por qué una predicción fue hecha por el modelo.

La IA corresponde con un campo del conocimiento que incluye el ML y este a su vez el Deep Learning (DL). En ambos campos, para resolver un problema se procede al entrenamiento de los modelos para que aprendan el problema en cuestión a partir de los datos existentes. Una vez obtenidas las reglas, podemos aplicarlas a nuevos conjuntos de datos para producir las respuestas oportunas aplicando las reglas aprendidas mediante la experiencia. Para realizar procesos de ML son necesarios al menos tres partes fundamentales: datos de entrada, los resultados esperados y la medición del funcionamiento del algoritmo, de forma que se pueda ir ajustando el trabajo del algoritmo mediante procesos realimentados (Casella et al., 2013).

Un modelo de ML, una vez implementado, puede completar una tarea mucho más rápida y con mayor fiabilidad que cualquier humano, entrega resultados consistentes de

manera “confiable” y puede ser infinitamente replicado. El entrenamiento de una persona para la realización de una tarea con la misma eficiencia es costoso y puede llevar años.

Un aspecto importante del uso del ML es la interpretabilidad de los modelos una vez que han sido entrenados. Desde este punto de vista algunos autores distinguen dos tipos de modelos (H. Liu et al., 2016):

- **Modelos de caja blanca**, son modelos cuyo comportamiento predictivo o de identificación de patrones puede explicarse claramente en base a las variables que en él intervienen. Por tanto, es relativamente sencillo investigar las reglas que dichos modelos han inferido de los datos.
- **Modelos de caja negra**, son modelos cuyas reglas no son comprensibles de una forma sencilla para el ser humano, sería muy dificultoso explicar cómo el sistema llegó a tomar una cierta decisión concreta ante una entrada determinada. Sirvan de ejemplo las Redes Neuronales Artificiales (RNA) y los algoritmos de DL en general, de tal manera que se necesitan millones de operaciones para describir una red neuronal profunda, y no hay forma de entender el modelo en su totalidad, ocultándose el cómo resuelve la máquina una tarea en modelos cada vez más complejos (H. Liu et al., 2016).

Algunos autores ponen en duda incluso la interpretabilidad de los algoritmos de caja blanca (Z. C. Lipton, 2018). En la Figura 13 se puede apreciar, por regla general, que cuanto mayor es la interpretabilidad del algoritmo de ML, menor es su grado de flexibilidad y por consiguiente menor su grado de fiabilidad. En otras palabras, actualmente no hay duda de que los algoritmos más potentes no son interpretables.

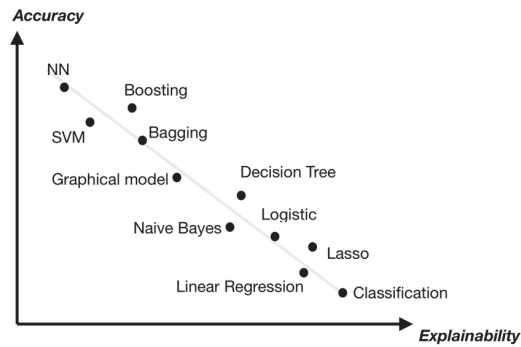


Figura 13. Interpretabilidad vs Flexibilidad. Fuente: (Duval, 2019)

Los métodos de interpretación para el aprendizaje automático pueden clasificarse según varios criterios (Z. C. Lipton, 2018).

- **¿Intrínseco o post hoc?** Este criterio distingue si la interpretabilidad se logra restringiendo la complejidad del modelo de aprendizaje automático (intrínseco) o aplicando métodos que analizan el modelo después del entrenamiento (post hoc). En el primero de los casos, la interpretabilidad es inherente al modelo, en el segundo caso, los métodos pueden estar o no desacoplados del modelo de ML, y entramos en la siguiente definición,
- **¿Específico o agnóstico?** Las herramientas de interpretación se limitan a clases de modelos específicos p.e. regresión lineal, o bien aplicables a cualquier modelo una vez se ha entrenado (post hoc). Las herramientas agnósticas pueden utilizarse en cualquier modelo de aprendizaje automático y separan la explicación del tipo de modelo. Ofrecen la libertad de poder escoger un conjunto de modelos para tratar un problema y luego compararlos.
- **¿Local o global?** ¿El método de interpretación explica una predicción individual o todo el comportamiento del modelo? ¿O el alcance está en algún punto intermedio? Los métodos globales describen el comportamiento medio del modelo de ML, son muy útiles cuando se quiere analizar el mecanismo de funcionamiento general de los datos. Sin embargo, los métodos locales, explican predicciones individuales.

A continuación, se desarrolla el marco teórico de un subconjunto de modelos agnósticos (globales y locales) que se emplean en el análisis de la interpretabilidad de las decisiones tomadas por modelos de ML aplicados al modelo RFID y determinar la variable target binaria abandono de clientes.

#### 4.5.1 Diagrama de Dependencia Parcial (PDP)

La visualización de datos constituye una de las herramientas de interpretación más poderosas, si bien, nuestra mente puede analizar la dependencia de una o dos variables frente a una tercera. Cuando consideramos más de un cierto número de variables, es necesario analizar la dependencia parcial de una o dos variables en relación con la predicción de la variable respuesta (Friedman, 2001).

Definimos el siguiente vector de variables predictoras  $X_S = (x_1, x_2, \dots, x_l)$  de dimensión  $l$  y el vector de variables de entrada  $X_T = (X_1, X_2, \dots, X_p)$ , donde  $l < p$ . Por otro lado, definimos  $C$  como el conjunto tal que  $S \cup C = \{1, 2, \dots, p\}$ . Definimos de esta forma la dependencia parcial (Friedman, 2001),

$$\hat{f}_S(x_S) = E_{X_C}[\hat{f}(x_S, X_C)] = \int \hat{f}(x_S, X_C) d\mathbb{P}(X_C) \quad (15)$$

Cada subconjunto de predictores  $S$  tiene su propia función de dependencia parcial  $\hat{f}_S$ , que proporciona el valor medio de  $f$  cuando  $x_S$  es fijo y  $X_C$  varía sobre su distribución normal marginal  $d\mathbb{P}(X_C)$ .

La función parcial anterior se estima calculando promedios en los datos de entrenamiento:

$$\hat{f}_S(x_S) = \frac{1}{n} \sum_{i=1}^n \hat{f}(x_S, x_C^{(i)}) \quad (16)$$

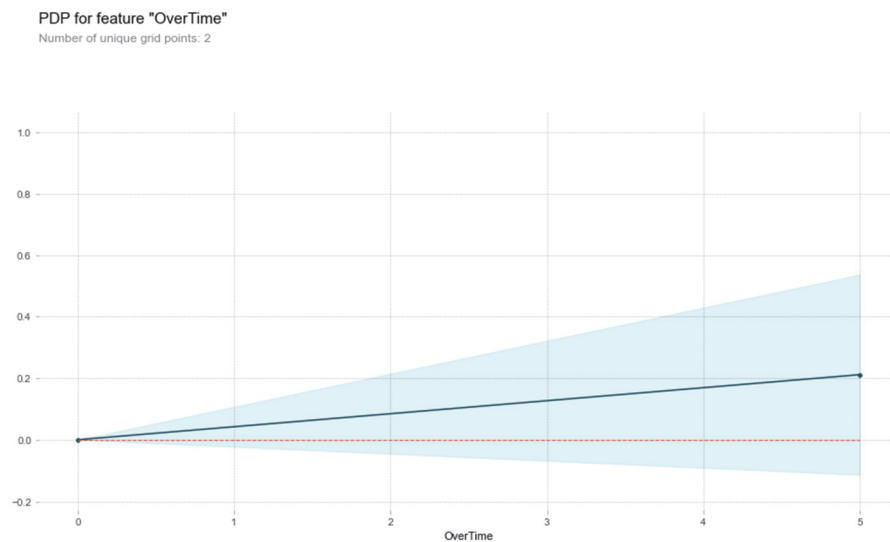


Figura 14. Ejemplo PDP. Análisis abandono de empleados, característica: OverTime

Es importante indicar que la correlación entre el conjunto de características  $x_S$  y  $X_C$  no debe ser fuerte y esto no siempre se da, por otro lado, el número máximo de predictores para este tipo de función debe ser dos, la limitación está dada por lo comentado anteriormente, no podemos representar ningún modelo con más de tres dimensiones. En el gráfico de la Figura 14, la zona de color azul muestra el intervalo de confianza.

El PDP corresponde con modelos de interpretación globales.

#### 4.5.2 Curvas de Expectativa Condicional Individual (ICE)

En el anterior modelo, representábamos un valor promedio de una característica, de esta forma podríamos incurrir en errores, si una característica tiene una predicción positiva para un conjunto de valores positivos y también positiva para otro conjunto de valores negativos, podríamos determinar que la predicción global es una línea horizontal,

y como conclusión obtendríamos que no existe evolución. Este problema lo podemos resolver utilizando ICE, ya que visualiza la dependencia de la predicción de una característica de forma individual, el resultado es una gráfica por cada instancia. Trazamos de esta forma las  $n$  - curvas de expectativas condicionales estimadas, y cada una de ellas representa la respuesta predicha como una función del conjunto de variables  $X_S$ , condicionada por la  $X_C$  observada. Es por ello por lo que ICE se corresponde con modelos de interpretación locales.

En notación matemática (Goldstein et al., 2015), para cada observación que hacemos en el conjunto  $\{(x_S^i, x_C^i)\}_{i=1}^N$  se representa la curva  $f_S^i$  con el conjunto de valores  $x_S^i$  mientras  $x_C^i$  permanece fijo.




Figura 15. Curvas ICE. Análisis abandono de empleados, característica: OverTime

Como se puede apreciar, las curvas ICE son más intuitivas que las gráficas de dependencia parcial. Y al igual que, en el caso anterior, sí existe fuerte correlación entre los subconjuntos  $X_S$  y  $X_C$ .

### 4.5.3 Cálculo de la Importancia de las Características

El concepto de la importancia de las características es simple, se trata de valorar la importancia de una determinada característica calculando el aumento en el error de predicción después de hacer una permutación de esta. Cuanto mayor sea el incremento en el error de predicción, más importante será la característica para el valor predictivo. Un primer modelo fue introducido por (Breiman, 2001) basado en Random Forest. El modelo propuesto por (Fisher et al., 2019) está basado en el anterior, pero en este caso es independiente del algoritmo de ML utilizado.

Suponiendo que  $X$  corresponde con la matriz de características, y la variable respuesta,  $S(y, f)$  la medida del error. Seguimos los siguientes pasos:

- Estimamos el error cuadrático medio del modelo original  $e_c = S(y, f(x))$
- Generamos la matriz de características  $X_m$  permutando una de ellas  $k$  para cada una de las características pertenecientes al conjunto de datos  $k = 1, \dots, p$ .
- En función de las predicciones de los datos permutados, se va calculando el error cuadrático medio de forma que  $e_p = S(Y, f(X_m))$ .
- Por último, se calcula la importancia de la característica de permutación  $IC^k = e_p/e_c$  y se ordenan por  $IC$  de manera descendente.

En el trabajo realizado con Python y para los casos que vamos a tratar en este documento, utilizaremos ELI5 como herramienta para depurar clasificadores y regresores de aprendizaje automático, explicando sus predicciones de manera intuitiva.

Weight	Feature
0.1715	OverTime
0.0761	JobLevel
0.0654	MaritalStatus_Single
0.0418	JobRole_Research Director
0.0372	WorkLifeBalance
0.0332	StockOptionLevel
0.0323	YearsInCurrentRole
0.0321	JobRole_Sales Representative
0.0283	EducationField_Marketing
0.0270	JobInvolvement
0.0254	JobRole_Research Scientist
0.0251	BusinessTravel_Travel_Frequently
0.0235	JobRole_Manufacturing Director
0.0234	TotalWorkingYears
0.0224	Department_Research & Development
0.0210	JobRole_Sales Executive
0.0208	YearsSinceLastPromotion
0.0203	EnvironmentSatisfaction
0.0202	RelationshipSatisfaction
0.0199	NumCompaniesWorked
	... 24 more ...

Figura 16. Importancia de las características (ELI5) – Análisis de abandono de empleados

Este modelo proporciona una visión global acerca del comportamiento del modelo de aprendizaje, modelo agnóstico global. Si dos o más características están muy correlacionadas y el estimador utiliza todas por igual, la importancia de la permutación puede ser baja para todas las características, y en consecuencia podría presentar resultados poco probables.

#### 4.5.4 Sustituto Local LIME

Este modelo es utilizado para explicar las predicciones individuales de los modelos de ML de caja negra. LIME actúa comprobando qué ocurre con las predicciones cuando se introducen variaciones en los datos de entrada. Para ello, LIME va generando nuevos conjuntos de datos con dichas variaciones obteniendo de esta forma conjuntos de predicciones. Básicamente, las explicaciones se basan en modelos sustitutos locales. Los modelos sustitutos son modelos interpretables (como un modelo lineal o un árbol de decisión) que aprenden sobre las predicciones del modelo original de caja negra. Pero en lugar de intentar ajustar un modelo sustituto global, LIME se centra en ajustar modelos sustitutos locales para explicar por qué se hicieron predicciones individuales (Ribeiro et al., 2016b).

El flujo de trabajo que podría representar el funcionamiento anterior es el siguiente:

- Elegir la instancia para la que se desea tener una explicación de las predicciones.
- Perturbar el conjunto de datos y obtener las predicciones para los nuevos puntos obtenidos tras la perturbación.
- Ponderar las nuevas muestras por su proximidad a la instancia de interés.
- Ajustar un modelo ponderado e interpretable (sustituto) en el conjunto de datos con las variaciones.
- Explicar la predicción interpretando el modelo local.

Teniendo en cuenta que  $x \in R^d$  sea una instancia la cual queremos interpretar, y el conjunto  $x' \in \{0,1\}^{d'}$  un vector binario para representar su posible interpretación.

Si consideramos  $g \in G$  un modelo de ML que pertenece al conjunto  $G$  de modelos potencialmente interpretables. Siendo el dominio de  $g \in \{0,1\}^{d'}$ , es decir, un vector binario que representa la capacidad de interpretación del dominio  $g$ . El grado de complejidad de la explicación del modelo  $g$  lo representamos como  $\Omega(g)$ . Si definimos  $f(x)$  como la probabilidad (o un indicador binario) de que  $x$  pertenezca al vector binario definido anteriormente  $x' \in \{0,1\}^{d'}$ . Y si utilizamos  $\Pi_x(z)$  como medida de proximidad entre una instancia  $z$  y  $x$ .

Entonces, la función  $L(f, g, \Pi_x)$  es una medida de la fidelidad de  $g$  a la hora de aproximarse a  $f$  en la proximidad definida por  $\Pi_x$ . Para garantizar tanto la interpretabilidad como la fidelidad local, debemos minimizar  $L(f, g, \Pi_x)$  y al mismo tiempo hacer que  $\Omega(g)$  sea lo suficientemente bajo como para ser interpretable. La explicación producida por LIME se obtiene de la siguiente manera (Ribeiro et al., 2016b):

$$E(x) = L(f, g, \Pi_x) + \Omega(g) \quad (17)$$

La medida de fidelidad representada por  $L(f, g, \Pi_x)$  nos da una idea de la fiabilidad del modelo interpretable para explicar las predicciones realizadas por los modelos de caja negra. Como factor desfavorable del modelo es que continúa en fase de desarrollo y se necesitan resolver ciertos problemas derivados de la inestabilidad de las explicaciones (Alvarez-Melis & Jaakkola, 2018).

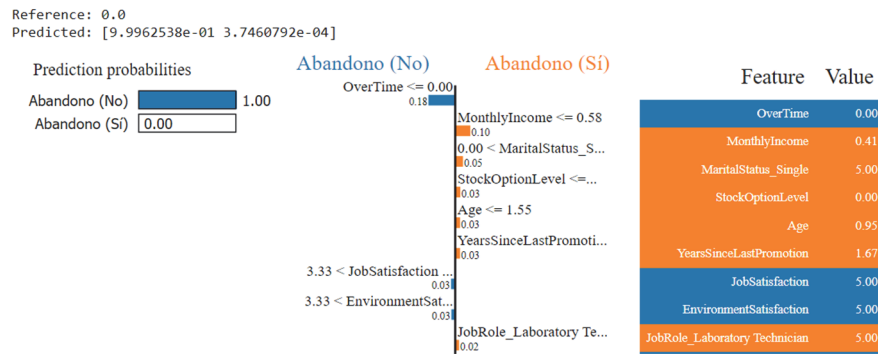


Figura 17. Sustituto local LIME – Análisis abandono de empleados (abandono = no)

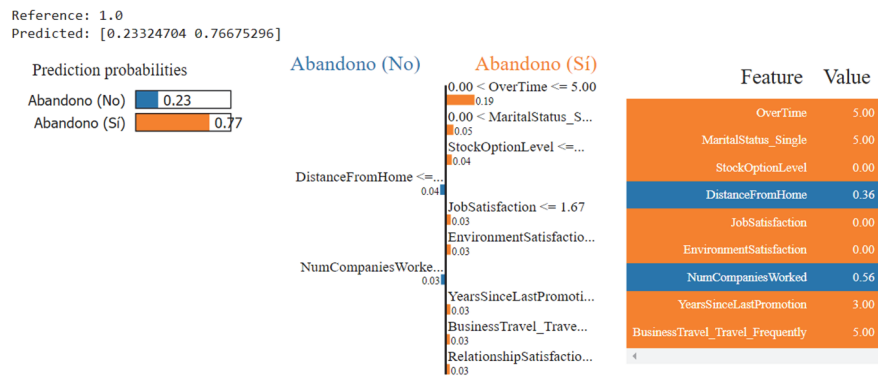


Figura 18. Sustituto local LIME – Análisis abandono de empleados (abandono = sí)

### 4.5.5 SHAP

El objetivo del modelo de interpretabilidad SHAP es poder proporcionar una explicación a una instancia  $x$  a partir de la contribución de cada una de las características a la predicción (Lundberg & Lee, 2017). Los valores SHAP intentan explicar la salida de una función  $f$  como una suma de los efectos  $\phi_i$  de cada característica introducida de forma

condicional. Es importante destacar que para las funciones no lineales importa el orden en que se introducen las características.

El modelo teórico propuesto por (Lundberg et al., 2018), cumple con las siguientes propiedades,

Los valores SHAP resultan de promediar todos los valores posibles, de forma que  $\sum_{i=0}^M \phi_i = f(x)$ .

Los métodos de atribución de características aditivas tienen un modelo interpretable  $g$  representado mediante una función lineal de variables binarias:

$$g(z') = \phi_0 + \sum_{i=1}^M \phi_i z'_i = f(x) \quad (18)$$

Donde  $z'_i \in \{0,1\}^M$ ,  $M$  es el número de características de entrada y  $\phi_i \in R$ .

Las variables  $z'_i$  suelen representar una característica observada ( $z'_i = 1$ ), o desconocida ( $z'_i = 0$ ) y  $\phi_i$ 's corresponde con la atribución de una característica  $i$  a los valores de Shapley.

Una propiedad importante de la clase de métodos de atribución de características aditivas es que la solución posible debe tener tres propiedades deseables: precisión local, ausencia de rasgos y consistencia. La precisión local establece que la suma de las atribuciones de rasgos es igual a la salida de la función que buscamos explicar. La ausencia de rasgos indica que  $z' = 0$ , no se les atribuye ninguna importancia. La consistencia establece que cambiar un modelo para que una característica tenga un mayor impacto en este no disminuirá la atribución asignada a esa característica.




Figura 19. Importancia de las características SHAP – Análisis abandono de empleados




Figura 20. SHAP - Predicción individual, abandono = no



Figura 21. SHAP - Predicción individual, abandono = sí

Aplicando SHAP, obtenemos explicaciones contrastadas que comparan la predicción con la predicción media. Por otro lado, SHAP conecta los valores LIME y Shapley. Esto es muy útil para comprender mejor ambos métodos. También ayuda a unificar el campo del aprendizaje automático interpretable.

## 5. Planteamiento metodológico

El planteamiento metodológico se ha dividido en dos partes, en la primera de ellas abordaremos la problemática de la segmentación de clientes de acuerdo con su relación con el Contact Center, esto es lo que hemos dado en llamar el nuevo modelo RFID (apartado 5.1), basado en la Recencia, Frecuencia, Importancia y Duración de las interacciones del cliente con la marca durante un tiempo determinado. Complementando esta primera parte, abordaremos un nuevo modelo metodológico destinado a la priorización y personalización de las interacciones en el Contact Center, VIUE (apartado 5.2). Es decir, propondremos una metodología de trabajo que permita en función de distintos criterios entre ellos el Valor del Cliente, la Importancia, Urgencia, el Grado de Emoción (positivo, negativo o neutro) de la interacción, el Tiempo de Espera y el SLA (Bartolini & Sallé, 2004; Marrone & Kolbe, 2011), priorizar las interacciones y determinar en consecuencia el grado de personalización que tendríamos en el proceso de comunicación.

En la segunda parte (apartado 5.3) de esta guía metodológica, abordaremos una problemática inherente a los procesos descritos, directamente relacionada con una métrica de importancia para todas las empresas, el abandono del cliente (Figalí et al., 2019). Utilizando la puntuación obtenida por cada cliente en función del modelo RFID, se contrasta dicha puntuación con la posibilidad de abandono del cliente, se aplicarán para ello un conjunto de algoritmos de IA para posteriormente realizar el proceso descrito en el apartado 4.5 de la presente tesis referido a la interpretabilidad de algoritmos, de esta forma, se puede determinar la variable target binaria abandono de un cliente, y en consecuencia proponer acciones correctoras.

A continuación, se puede visualizar en la Figura 22 un proceso completo, el cliente abre una incidencia en el Contact Center y a partir de ahí se genera una interacción que es priorizada con VIUE. El siguiente paso, es la atención por parte de un agente de la incidencia, que es recogida en el CRM de la compañía. Si la incidencia requiere de personal

especializado, se iniciará un proceso de trabajo interno en busca de la solución, el caso irá pasando por diferentes estados que obligarán a realizar el apunte correspondiente en el CRM. Por el contrario, si el agente puede resolver la incidencia, dará respuesta al cliente y realizará de la misma forma el apunte de cierre de incidencia en el CRM.

En cualquier caso, esté o no resuelta la incidencia, el proceso RFID se ejecutará con la periodicidad indicada por la compañía, de forma que en todo momento se puede obtener la valoración del cliente, integrando dicha valoración tanto en el modelo VIUE, como en la determinación de la variable target binaria abandono.

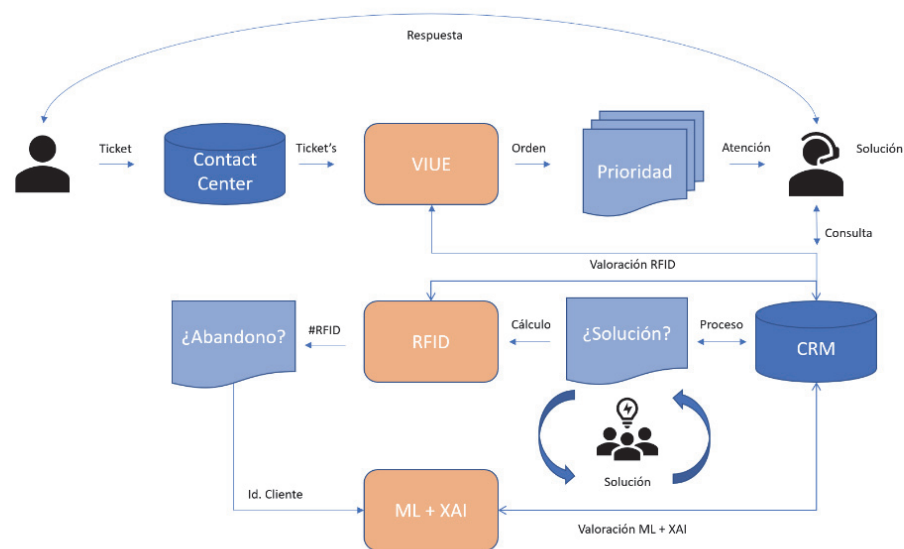


Figura 22. Esquema general de los tres modelos propuestos

## 5.1 Nuevo modelo RFID

El nuevo modelo RFID descrito en la presente memoria se basa en los parámetros de Recencia, Frecuencia, Importancia y Duración de las interacciones entre cliente y marca durante un período. Este modelo nos ayudará a determinar el valor del cliente desde el punto de vista de sus interacciones con el Contact Center, además de proporcionarnos una segmentación y una estrategia de acciones a realizar por cada grupo de clientes.

A partir de la información de los tickets almacenada en un CRM operativo convencional, nuestro modelo obtiene dos tipos de recomendaciones para los clientes en función del histórico de sus interacciones con el servicio de atención al cliente: individualizadas y grupales. El modelo se parametriza con la información proporcionada por los expertos en atención al cliente. Estos mismos usuarios son también los encargados de determinar y aplicar las estrategias finales de tratamiento de los clientes.

El proceso que se ha seguido es el siguiente:

- En la sección 5.1.1, se recuperan los datos del CRM.
- En el apartado 5.1.2, se realiza un preprocesamiento de la información en el que se define el periodo de análisis.
- En el apartado 5.1.3, se realiza el proceso de agregación por cliente.
- En el apartado 5.1.4, se aplica el modelo 2-tupla sobre los datos obtenidos en el paso anterior.
- En el apartado 5.1.5, se obtiene la valoración global de cada cliente aplicando el modelo AHP.
- En el apartado 5.1.6, se establece una estrategia de recomendación individualizada.
- En el apartado 5.1.7, a partir de los resultados obtenidos en la sección 5.1.4, agrupamos a los clientes según el modelo k-means.
- En el apartado 5.1.8, se obtiene finalmente una estrategia de recomendación por grupos.

El modelo propuesto se muestra en la figura 23 y cada paso se explica con más detalle a continuación.

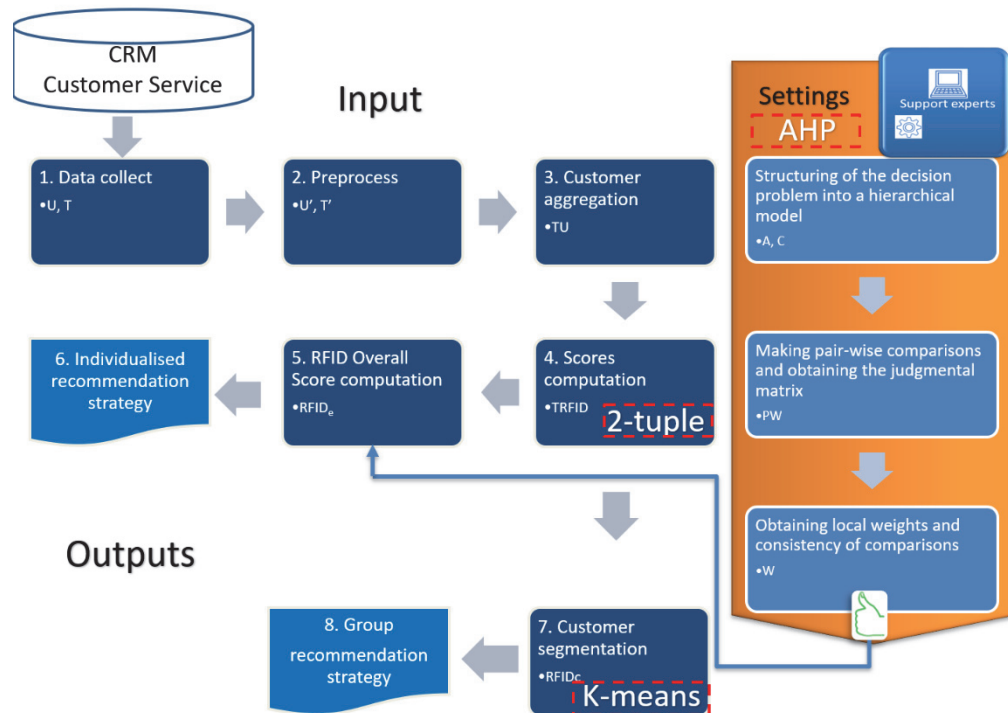


Figura 23. Modelo RFID

### 5.1.1 Obtención de datos

En la terminología del CRM, la incidencia representada mediante un ticket o caso (Ramón Alberto Carrasco et al., 2018) corresponde con cualquier tipo de solicitud de servicio por parte del cliente o queja, este tipo de incidencias se producen después del proceso de venta.

Dado  $T =$

$\{(u_1, ticket\_id_1, ticket\_date_1, status\_id_1, status\_date_1, trouble\_id_1, ticket\_importance_1), \dots,$

$(u_{\#T}, ticket\_id_{\#T}, ticket\_date_{\#T}, status\_id_{\#T}, status\_date_{\#T}, trouble\_id_{\#T}, ticket\_importance_{\#T})\}$

los detalles de estas solicitudes, donde:

- $ticket\_id_i$ : es un código que identifica de forma única cada ticket, esto es, una incidencia abierta por el cliente  $u_i$ , con  $i \in 1, \dots, \#T$ .
- $ticket\_date_i$ : es la fecha en la que se requirió inicialmente el servicio.

- $status\_id_i$ : es un código que identifica el estado del ticket con respecto a su gestión, por ejemplo, iniciado, resuelto, cancelado, etc.
- $status\_date_i$ : el servicio requerido por el cliente pasa por distintos estados, la fecha correspondiente al último estado es la que queda almacenada en este atributo.
- $trouble\_id_i$ : identifica el tipo de solicitud, queja o problema que tiene el cliente.
- $ticket\_importance_i$ : la relevancia del ticket es una característica estándar de la mayoría de los CRM. Suele expresarse en una escala ordinal y/o lingüística de  $n$  valores, de forma que cuanto mayor sea el valor, mayor será la relevancia del ticket. En esta memoria consideraremos que la escala tiene cinco valores  $S = \{very\ low, low, moderate, high, very\ high\}$ . Al tratarse de una escala lingüística, consideraremos su modelización con el conjunto  $S$ .

En la Figura 24, se presentan los detalles de un nuevo ticket en la herramienta CRM de Salesforce, se establece una correspondencia entre los campos,

$casenumber = ticket\_id$ ,  $date/timeopened = ticket\_date$ ,  $status = status\_id$ ,  $lastmodified = status\_date$ ,  $type = trouble\_id$ ,  $importance = ticket\_importance$ ,  $account = u_i$

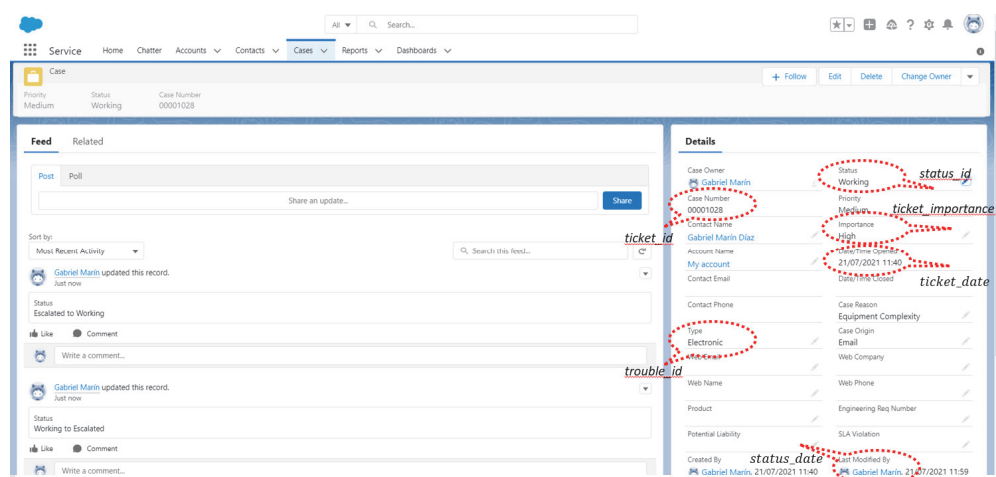


Figura 24. Apertura de un caso en Salesforce CRM

## 5.1.2 Preprocesado

Dado un periodo de tiempo,  $t$ , para el análisis delimitado por las fechas  $t_1$  y  $t_2$  con  $t_1 < t_2$ , en este escenario de fechas, identificamos las solicitudes de servicio reales de los clientes que se van a analizar. Así, necesitamos identificar todos los tickets del conjunto  $T$  dentro del periodo de análisis  $t$ , es decir, cuyo  $status\_id_i$  pertenezca a dicho periodo  $t$ , que no correspondan a solicitudes de cancelación final de contrato ya que consideramos que son clientes que ya no se pueden gestionar. Esto es fácil porque los tickets contienen un campo que se categoriza en función del tipo de solicitud que realiza el cliente,  $trouble\_id_i$ .

Representamos este conjunto como,  $T' =$

$$\{(u_1, ticket\_id_1, ticket\_date_1, status\_id_1, status\_date_1, trouble\_id_1, ticket\_importance_1), \dots, (u_{\#T}, ticket\_id_{\#T}, ticket\_date_{\#T}, status\_id_{\#T}, status\_date_{\#T}, trouble\_id_{\#T}, ticket\_importance_{\#T})\}$$

## 5.1.3 Agregación

Representamos el conjunto de clientes como  $U = \{u_1, \dots, u_{\#U}\}$ , tales que cada uno de ellos ha realizado al menos una solicitud de servicio a lo largo del periodo de análisis preestablecido  $t$ , es decir, se corresponde con los diferentes clientes contenidos en el conjunto  $T'$ . En esta fase,  $T'$  se agrega a este nivel de cliente  $u_e$ ,  $e \in 1, \dots, \#U$ , considerando el conjunto de tickets,  $ticket\_id_i$  para este cliente en el conjunto  $T'$ . De esta forma, obtenemos el conjunto  $TU = (u_1, r_1, f_1, i_1, d_1), \dots, (u_{\#U}, r_{\#U}, f_{\#U}, i_{\#U}, d_{\#U})$ , donde:

- $r_e$ : corresponde con el número de días desde la última petición de servicio por parte del cliente  $u_e$  (utilizando como referencia la fecha de finalización del periodo de análisis). Por tanto,  $r_e = diffdays(t_2 - \max(ticket\_date_i))$ , donde  $diffdays$  es una función que devuelve la diferencia de días entre dos fechas, y  $\max$  es una función que devuelve la última fecha de las diferentes fechas de entrada.
- $f_e$ : es el número de veces que el cliente ha realizado una solicitud de servicio, es decir, con diferentes códigos de ticket,  $ticket\_id_i$ .

- $i_e$ : es la importancia media. Al tratarse de una variable lingüística, este valor se calcula para cada cliente mediante la ecuación (4),  $i_e = \bar{x}^e [ticket\_importance_i]$ .
- $d_e$ : contiene la duración total en días de todos los tickets del cliente. Por lo tanto,  $d_e = \sum_i (diffdays (status\_date_i - ticket\_date_i))$ .

### 5.1.4 Cálculo de las puntuaciones

En este paso, se obtienen las puntuaciones 2-tupla para el conjunto  $TRFID = \{u_1, R_1, F_1, I_1, D_1, \dots, u_{\#U}, R_{\#U}, F_{\#U}, I_{\#U}, D_{\#U}\}$ .

Por tanto, tenemos que calcular las siguientes variables:  $R_e, F_e, I_e, D_e \in S \times [-0.5, 0.5]$ . Para cada cliente  $u_e$ , obtenemos  $A_e = (A_{e1}, A_{e2}, A_{e3}, A_{e4})$  con  $A_{e1} = R_e, A_{e2} = F_e, A_{e3} = I_e, A_{e4} = D_e$ . En primer lugar, los clientes se clasifican en orden ascendente según cada uno de los componentes individuales  $B_e = (B_{e1}, B_{e2}, B_{e3}, B_{e4})$ , con  $B_{e1} = r_e, B_{e2} = f_e, B_{e3} = i_e, B_{e4} = d_e$  contenidos en  $TU$ . Con  $e \in 1, \dots, \#U$  e  $i \in 1, \dots, 4$ , la puntuación final 2-tupla  $A_{ei}$  se obtiene mediante la siguiente ecuación:

$$A_{ei} = \begin{cases} \Delta(\text{percent\_rank}(B_{ei})), & \text{if } i = 2, 4 \\ B_{ei}, & \text{if } i = 3 \\ \text{neg}(\Delta(\text{percent\_rank}(B_{ei}))), & \text{if } i = 1 \end{cases} \quad (19)$$

donde  $\Delta(\cdot)$  y  $\text{neg}(\cdot)$  han sido definidas en las ecuaciones (1) y (3) respectivamente y  $\text{percent\_rank}$  en la ecuación (6). En este caso utilizamos la función de negación con el valor de la recencia, ya que las mayores puntuaciones corresponden a clientes con solicitudes más recientes.

### 5.1.5 Cálculo de la puntuación global para RFID

En este paso el valor de la 2-tupla  $RFID_e$ , que caracteriza las puntuaciones conjuntas de  $R_e, F_e, I_e, D_e$ , es calculado para cada cliente utilizando la Ecuación (5), de tal forma que  $RFID_e = F^\omega[A_{ei}]$ , aplicando los pesos  $W = w_R, w_F, w_I, w_D$ , obtenidos a partir de la información proporcionada por los expertos del servicio de atención al cliente.

A continuación, proponemos el uso del modelo AHP introducido en la sección 4.3, pasamos a describir las fases contempladas para este proceso:

### 5.1.5.1 Estructurando el problema de decisión en un modelo jerárquico

Para estructurar un problema en el marco MCDM es necesario definir las alternativas disponibles y los criterios necesarios. Los criterios (C) y las alternativas (A) son las variables de puntuación de la *RFID*:  $A = \{R, F, I, D\}$ . La Figura 25 muestra la jerarquía del modelo AHP propuesto.

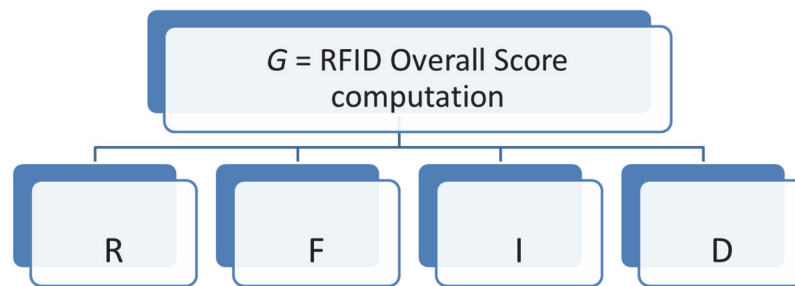


Figura 25. Modelo Jerárquico AHP

### 5.1.5.2 Matriz de comparación por pares

En este paso, los expertos del Contact Center deberán complementar la matriz de comparación por pares, *PW*, comparando los criterios del modelo jerárquico *C*, expresando de esta forma la importancia relativa de cada variable *RFID* sobre las otras, con el fin de calcular el cómputo global de la puntuación a nivel de cliente.

### 5.1.5.3 Obtención de ponderaciones locales y consistencia de las comparaciones

Para garantizar la coherencia de la matriz dada, su *CR* (Ecuación (9)), debe ser inferior o igual a 0,1. Si el *CR* no es lo suficientemente bueno, se considerará que las especificaciones empresariales no cumplen sus criterios de calidad, es decir, que pueden contradecirse entre sí. Una vez comprobada la coherencia, se calcula el peso

de cada criterio tal y como definimos en el apartado 4.3.3 (Ecuación (8)). Los pesos de cada una de las alternativas de RFID se expresan de la siguiente manera:  $W = W_R, W_F, W_I, W_D$ .

### 5.1.6 Estrategia de recomendación individualizada

En los modelos customer-centric, es esencial tener en cuenta la atención y servicio de soporte una vez finalizado el proceso de venta (Kotler, 2016; V. Kumar & Reinartz, 2012).

Utilizando el modelo  $RFID_e \in Sx[-0.5,0.5]$ , y con los cálculos realizados en el paso anterior, es posible caracterizar y gestionar individualmente a cada cliente, en función de los servicios requeridos por éste. Hay que tener en cuenta que el valor 2-tupla se trata de un valor de dos cifras que permite una fácil interpretación y una alta precisión en la medición. Esta alta precisión ayuda a clasificar a los clientes de tal manera que se pueden priorizar a los de mayor valor para la marca, y así realizar una mejor gestión y seguimiento.

### 5.1.7 Segmentación de clientes

El objetivo de esta fase es obtener grupos homogéneos de clientes basados en variables *RFID* que permitan establecer estrategias comunes para cada uno de ellos. Para eso, utilizaremos el algoritmo de clustering más utilizado en ML, es decir, k-means. Algunas de sus ventajas son (Govender & Sivakumar, 2020): baja complejidad, rapidez computacional y capacidad para manejar grandes conjuntos de datos, adaptándose en problemas de Big Data (Lu, 2020). El uso de este algoritmo tiene la ventaja adicional de que ha sido adaptado al modelo 2-tupla (Ramón A. Carrasco et al., 2018). Algunas de las principales desventajas son, (Govender & Sivakumar, 2020): es sensible a los valores atípicos y a la escala del conjunto de datos. En nuestro caso, esto no supondrá un problema, ya que la escala siempre se expresa en el modelo 2-tupla y, además, al estar basado en la clasificación (véase la Ecuación (20)), difícilmente generará valores atípicos.

En este paso, el conjunto  $RFID_c = c_1, \dots, c_{\#U}$ , donde cada  $c_e \in 1, \dots, \#c$  identifica el clúster al que pertenece cada cliente  $u_e$ . Las variables de entrada al algoritmo de segmentación son valores 2-tupla, este caso ya ha sido resuelto (Ramón A. Carrasco et al., 2018). A partir de este enfoque, los valores de estos centroides se expresarán utilizando el modelo de 2-tupla, con lo que se consigue una mejor interpretabilidad. Para aplicar el algoritmo, utilizamos la distancia euclidiana  $d_{ec}$  entre un cliente y el centroide del clúster a través de la siguiente ecuación:

$$d_{ec} = \sqrt{\sum_{i=1}^4 (\Delta^{-1}(A_{ei}) - (\Delta^{-1}(v_{ci})))^2} \quad (20)$$

para cada cliente  $u_e, e \in 1, \dots, \#U$  y por cada clúster definido por el centroide  $v_c = (v_{c1}, v_{c2}, v_{c3}, v_{c4}), c \in 1, \dots, \#c$ . En cada paso del algoritmo k-mean, recalculamos el nuevo centroide del clúster utilizando la ecuación (4):  $v_c = (\bar{A}[v_{c1}], \bar{A}[v_{c2}], \bar{A}[v_{c3}], \bar{A}[v_{c4}])$ .

Un problema típico cuando se utiliza k-means es la selección del número óptimo de grupos (Govender & Sivakumar, 2020),  $\#c$ . Para esta modelización RFID utilizaremos un enfoque ecléctico, utilizando varios métodos para este fin, sintetizados en (Charrad et al., 2014).

Por otro lado, se utilizará en el modelo RFID aplicado a B2B el coeficiente de silueta, mide la calidad del agrupamiento obtenido a través de clustering, identificando el número óptimo de agrupamientos. El coeficiente de silueta para una agrupación  $s(i)$  se define como:

$$s(i) = \frac{(b - a)}{\max(a, b)} \quad (21)$$

Donde  $a$  es el promedio de las distancias de la observación  $i$  en relación con las demás observaciones del clúster al que pertenece  $i$ . Y  $b$  es la distancia mínima a otro clúster distinto al que se realiza la observación  $i$  y vecino a dicha observación. El coeficiente de silueta está comprendido entre -1 y 1.

### 5.1.8 Estrategia de recomendación grupal

Como los diferentes clústeres obtenidos son fácilmente interpretables al estar descritos con el modelo lingüístico 2-tupla, los expertos en atención al cliente pueden establecer diferentes estrategias de gestión personalizada para los clientes pertenecientes a cada uno de los segmentos.

## 5.2 Nuevo modelo VIUE

El Contact Center debe tratar de maximizar la satisfacción del cliente, minimizando los costes, contribuyendo a enriquecer el perfil del cliente, su huella digital, que lleve a procesos automáticos de toma de decisión.

El nuevo modelo VIUE propuesto en la presente memoria se basa en la priorización y personalización de las interacciones del cliente con el Contact Center. Para ello se analizan las interacciones recibidas en el Contact Center en tiempo real, registradas en el CRM, y se clasifican éstas de acuerdo con factores como el valor del cliente ( $V$ ), impacto ( $I$ ), urgencia ( $U$ ) y el carácter emocional de la interacción ( $E$ ); por tanto, la prioridad de la interacción la podemos definir como un valor agregado de todos los criterios anteriores  $\mathbb{P} = f(V, I, U, E)$ . Los criterios anteriores proporcionarán una primera clasificación de las interacciones y están basados en la metodología ITIL (Bartolini & Sallé, 2004; Marrone & Kolbe, 2011), la cual, como hemos comentado en la sección 3.1.3 recomienda determinar la prioridad en la resolución de incidencias a partir del impacto y de la urgencia de las interacciones, para nuestro modelo de Customer Service, hemos ampliado esta metodología con conceptos como el valor del cliente (Marín Díaz et al., 2021b) y su relación con el Contact Center y el carácter emocional de la interacción (Altman et al., 2021), que como se ha comentado en el punto 3.1.3 afecta directamente a los procesos y resultados del servicio.

En segundo lugar, esta clasificación evidentemente está viva, estamos recibiendo continuamente interacciones en tiempo real y, por tanto, la cola de actividad del Contact

Center sufre modificaciones, se podría dar el caso de que, si solo clasificamos las interacciones por estos criterios, podríamos dejarnos clientes con una valoración de la prioridad baja y que queden sin atender. Para evitar esto, se realiza una segunda clasificación, que depende de los criterios prioridad (definido anteriormente), de los SLA definidos para el cliente o segmento de cliente, es decir del tiempo máximo de espera ( $T$ ) y de la carga de trabajo del Contact Center ( $C$ ) (Milner & Olsen, 2008); obteniéndose de esta forma el modelo extendido con la prioridad final, Extended VIUE (EVIUE).

El modelo se parametriza, con la información proporcionada por los expertos en atención al cliente, por tratarse de un modelo vivo, los expertos en función de la estacionalidad, historial, carga de trabajo y otros factores dependientes del sector de actividad, podrán balancear en tiempo real los pesos de cada uno de los criterios. Estos mismos expertos serán los encargados de determinar y aplicar estrategias finales de tratamiento y personalización con cada cliente o grupo de clientes. Y analizar si con la primera clasificación VIUE, podría ser suficiente para determinar la prioridad de atención de los clientes, en algunos entornos empresariales donde no existan definidos SLAs y con una gestión clásica de colas, no sería necesario aplicar el modelo Extended VIUE.

El proceso que se sigue pasa a ser el siguiente:

- En la sección 5.2.1, obtenemos los datos del CRM.
- En la sección 5.2.2, por tratarse de información heterogénea, determinamos el dominio de expresión CBTL para cada criterio.
- En la sección 5.2.3, aplicamos el modelo 2-tupla sobre los datos obtenidos en el paso anterior.
- En el apartado 5.2.4, obtenemos la valoración global de cada interacción aplicando el modelo AHP.

- En la sección 5.2.5, si fuese necesario, establecemos una reordenación de prioridades atendiendo a los valores de SLA y carga de trabajo del Contact Center, aplicando el modelo extendido VIUE (EVIUE).

El modelo propuesto se muestra en la Figura 26 y cada paso se explica con más detalle a continuación.

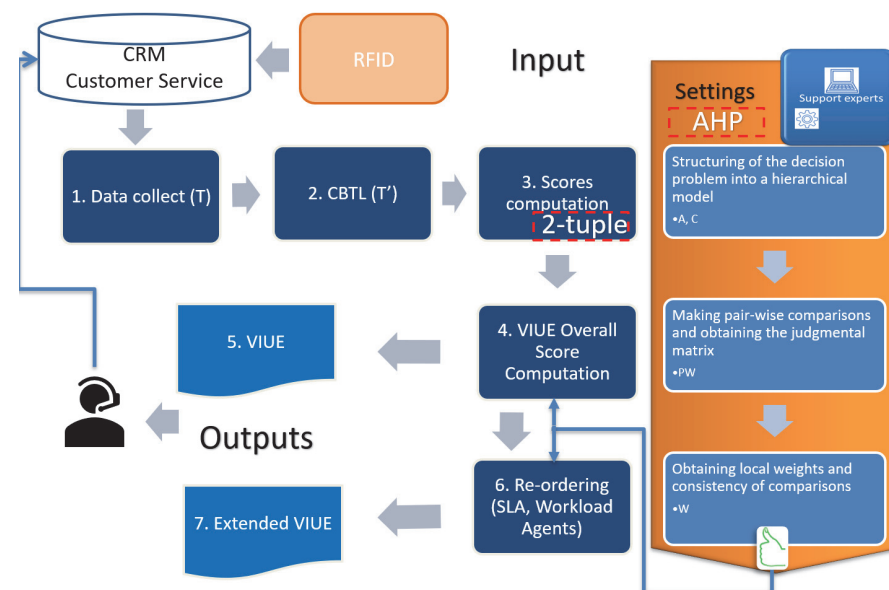


Figura 26. Modelo VIUE

## 5.2.1 Obtención de datos

Como comentamos en el apartado 5.1.1, en la terminología del CRM, la incidencia representada mediante un ticket o caso corresponde con cualquier tipo de solicitud de servicio por parte del cliente o queja, este tipo de incidencias se producen después del proceso de venta. Para nuestro propósito, la incidencia es grabada automáticamente en el CRM por parte del sistema de gestión del Contact Center, para ello será necesario que el cliente sea atendido por un bot (llamada, chat), en este proceso de atención se recopilará la información relevante que permitirá categorizar el ticket y con ello desencadenar el proceso que permita definir la prioridad y personalización en la atención. En el caso que nos ocupa, el conjunto de datos  $T$  estará identificado por los siguientes parámetros,

algunos de ellos calculados y otros expresados en un dominio 2-tupla. En el CRM se encuentra recopilada la valoración RFID de cada cliente, por tanto, dado

$$T = \{(u_1, RFID_1, ticket\_id_1, ticket\_date_1, trouble\_id_1, ticket\_impact_1, ticket\_urgency_1, ticket\_emotion_1), \dots, (u_{\#T}, RFID_{\#T}, ticket\_id_{\#T}, ticket\_date_{\#T}, trouble\_id_{\#T}, ticket\_impact_{\#T}, ticket\_urgency_{\#T}, ticket\_emotion_{\#T})\}$$

los detalles de estas solicitudes, donde:

- $RFID_i$ : corresponde con el valor del cliente desde el punto de vista del Contact Center tal y como hemos definido en el apartado 5.1 de la presente memoria. Para este caso lo definiremos en una escala lingüística  $\{very\ low, low, moderate, high, very\ high\}$ . Aunque hemos propuesto este valor para el presente trabajo, se podría optar por trabajar con cualquier otro criterio o agregación de criterios dentro del dominio *CEV* (V. Kumar et al., 2010), indicado en el punto 3.1.1 de la presente memoria.
- $ticket\_id_i$ : corresponde con el código que identifica de forma única cada ticket, esto es, una incidencia abierta por el cliente  $u_i$ , con  $i \in 1, \dots, \#T$ .
- $ticket\_date_i$ : corresponde con la fecha en la que se requirió inicialmente el servicio.
- $trouble\_id_i$ : identifica el tipo de solicitud, queja o problema que tiene el cliente.
- $ticket\_impact_i$ : la relevancia del ticket es una característica estándar de la mayoría de los CRM. Esta variable se encarga de medir los efectos de la incidencia en los procesos de negocio. Suele expresarse en una escala ordinal y/o lingüística de  $n$  valores, de forma que cuanto mayor sea el valor, mayor será la relevancia del ticket. En esta memoria, y teniendo en cuenta el caso de uso trabajado, consideraremos que la escala tiene cinco valores  $\{very\ low, low, moderate, high, very\ high\}$ . Al tratarse de una escala lingüística, consideraremos su modelización con el conjunto  $S$ .
- $ticket\_urgency_i$ : la urgencia del ticket también es una característica estándar de la mayoría de los CRM. Es una medida de cuánto daño puede hacer en el negocio la incidencia. Suele expresarse de la misma forma que el impacto en una escala

ordinal y/o lingüística de  $n$  valores. En esta memoria, y teniendo en cuenta el caso de uso trabajado, consideraremos que la escala tiene cinco valores  $\{very\ low, low, moderate, high, very\ high\}$ . Al tratarse de una escala lingüística, consideraremos su modelización con el conjunto  $S$ .

- $ticket\_emotion_i$ : corresponde con el valor emocional de la interacción, es una medida del “grado de enfado” del cliente en su interacción con la marca. Para lo cual realizaremos un análisis de sentimiento que nos permitirá clasificar la interacción y el carácter emocional de la interacción (Do et al., 2019). El análisis de sentimiento lo llevaremos, teniendo en cuenta el caso de uso trabajado, a un modelo difuso con tres valores  $\{low, moderate, high\}$ .

## 5.2.2 Dominio CBTL

Como se comentó en el apartado 4.4 en el tratamiento de información heterogénea, la selección del dominio CBTL  $\bar{S} = \{\bar{s}_0, \dots, \bar{s}_g\}$  se realiza obteniendo el conjunto de términos lingüísticos de máxima granularidad dentro del marco heterogéneo. En nuestro caso, los dominios definidos son:

- $RFID_i, ticket\_impact_i, ticket\_urgency_i$ : En los tres casos se ha decidido trabajar en un dominio lingüístico  $S5$ .
- $ticket\_emotion_i$ : En este caso se ha decidido trabajar en un dominio lingüístico  $S3$ .

Y, por tanto, atendiendo a las consideraciones expresadas en el apartado 4.4, se define el dominio de máxima granularidad en  $S5$ .

### 5.2.3 Cálculo de las puntuaciones

En este paso, se obtienen las puntuaciones 2-tupla para el conjunto  $TVIUE = \{u_1, V_1, I_1, U_1, E_1, \dots, u_{\#U}, V_{\#U}, I_{\#U}, U_{\#U}, E_{\#U}\}$ .

Por tanto, tenemos que calcular las siguientes variables:  $V_e, I_e, U_e, E_e \in S \times [-0.5, 0.5]$ . Para cada cliente  $u_e$ , obtenemos  $A_e = (A_{e1}, A_{e2}, A_{e3}, A_{e4})$  con  $A_{e1} = V_e, A_{e2} = I_e, A_{e3} = U_e, A_{e4} = E_e$ . En primer lugar, las interacciones se clasifican en orden ascendente según cada uno de los componentes individuales  $B_e = (B_{e1}, B_{e2}, B_{e3}, B_{e4})$ , con  $B_{e1} = v_e, B_{e2} = i_e, B_{e3} = u_e, B_{e4} = e_e$  contenidos en  $TU$ . Con  $e \in 1, \dots, \#U$  e  $i \in 1, \dots, 4$ , la puntuación final 2-tupla  $A_{ei}$  se obtiene mediante la siguiente ecuación:

$$A_{ei} = B_{ei} \tag{22}$$

En este caso no utilizamos la función  $\Delta(\cdot)$  definida en la ecuación (1), y tampoco la de negación  $neg(\cdot)$  definida en la ecuación (3), por estar todas las variables recogidas en un dominio lingüístico.

Las variables 1, 2 y 3 (V, I, U) están definidas en un dominio lingüístico  $S5$ , la variable 4 (E) está definida en un dominio lingüístico  $S3$ ,  $T_{S\bar{S}}: S \rightarrow F(\bar{S})$ . Por tanto, debemos aplicar la transformación de dominio de  $S3$  a  $S5$  según la ecuación (14). De esta forma tendremos las variables  $A_{ei}$  en un mismo dominio lingüístico  $S5$ .

Por ejemplo, dado  $S_i = \{s_0, s_1, s_2\}$  el conjunto de términos lingüísticos correspondiente al dominio de definición de  $ticket\_emotion_i$ , y  $\bar{S} = \{\bar{s}_0, \bar{s}_1, \bar{s}_2, \bar{s}_3, \bar{s}_4\}$  el conjunto CBTL, entonces,

$$T_{S\bar{S}}(s_1) = \{(\bar{s}_0, 0.33), (\bar{s}_1, 0.67), (\bar{s}_2, 0), (\bar{s}_3, 0.67), (\bar{s}_4, 0.33)\}$$




Figura 27. Transformación de un término lingüístico,  $s_1$  a  $F(\bar{S})$

Una vez realizada la unificación de todas las variables a un dominio difuso CBTL, pasaremos a transformar este dominio a variables lingüísticas 2-tupla y de esta forma operar sobre cada uno de los valores a través del modelo computacional 2-tupla.

## 5.2.4 Cálculo de la puntuación global para VIUE

En este paso el valor de la 2-tupla  $VIUE_e$ , que caracteriza la puntuación de cada interacción con el Contact Center  $V_e, I_e, U_e, E_e$ , es calculado para cada cliente utilizando la Ecuación (5), de tal forma que  $VIUE_e = F^\omega[A_{ei}]$ , aplicando los pesos  $W = w_V, w_I, w_U, w_E$ , obtenidos a partir de la información proporcionada por los expertos del servicio de atención al cliente. Esto nos determinará un primer orden de clasificación de interacciones.

A continuación, se realizan los pasos seguidos en las secciones 5.1.5.1, 5.1.5.2 y 5.1.5.3 aplicados al caso, estructuraremos el problema de decisión en un modelo jerárquico (AHP), para después elaborar la matriz de comparación por pares, obteniendo el vector de ponderaciones para cada una de las variables  $W = w_V, w_I, w_U, w_E$ .

## 5.2.5 Priorización y personalización

En una primera fase, nos podemos quedar con la ordenación de tickets determinados por los pasos anteriores, sin embargo, se propone una acción más. Como el proceso de priorización es dinámico, las prioridades se actualizan en tiempo real ya que

continúan entrando nuevas incidencias, en determinados entornos empresariales es necesario no quedarse con esta primera clasificación, algún cliente podría quedarse en cola sin atender. Así que una mejora posible al modelo consiste en, una vez determinado el valor de la prioridad con las fases descritas anteriormente, realizar una nueva reordenación que responda al tiempo de espera, de esta forma, cuando se alcance un % del valor de tiempo de espera marcado en el SLA, la interacción pasará a la cabeza en la cola de interacciones. Y, por otro lado, también influye la carga de trabajo del Contact Center, o en terminología inversa, la capacidad de trabajo del Contact Center, a mayor carga de trabajo, menor capacidad y viceversa. El responsable del Contact Center definirá los valores mínimo y máximo de carga de trabajo, así como el valor del tiempo de espera máximo por cliente.

Como se ha comentado en el apartado 5.2, el proceso extendido VIUE en algunos entornos empresariales donde no existan definidos SLA para el servicio de atención, y con una gestión clásica de colas, no sería necesario aplicarlo, bastaría con utilizar el modelo VIUE.

Además, se propone realizar un proceso de personalización en la interacción, para ello, tendremos en cuenta los criterios anteriores: prioridad inicial obtenida, tiempo de espera y la carga de trabajo del equipo de agentes asignados a resolver la incidencia, ya que estos, para el caso que nos ocupa, tienen asignadas tareas adicionales a la atención de incidentes. Las alternativas propuestas son:

- Alternativa 1. La interacción será atendida por un Bot en el canal correspondiente.
- Alternativa 2. La interacción será atendida por personal generalista.
- Alternativa 3. La interacción será atendida por personal especializado.

El modelo utilizado en esta nueva reordenación será similar al descrito en los pasos anteriores, y se basará en:

- Definición del dominio CBTL, en este caso, los criterios están definidos como sigue: prioridad, obtenida del modelo VIUE, la cual está en un dominio difuso  $F(\bar{S}) = \{very\ low, low, medium, high, very\ high\}$ ; tiempo de espera ( $T$ ) y carga de trabajo ( $C$ ) están en un dominio numérico  $T_{NS}: [0,1] \rightarrow F(\bar{S})$ , Figura 10.
- Unificación de la información heterogénea al dominio CBTL definido ( $S5$ ).
- Valoración de los pesos de cada uno de los criterios que componen el proceso de toma de decisión  $W = w_p, w_T, w_C$ .
- Priorización y recomendaciones de personalización de las interacciones de acuerdo con los pesos de cada criterio y la valoración global de cada interacción obtenida como función de los criterios prioridad, tiempo de espera y carga de trabajo.

El dominio final obtenido, Extended VIUE,  $EVIUE_i \in Sx[-0.5,0.5]$ , está representado en un valor 2-tupla, estableciendo de esta forma una reordenación de todas las interacciones en función de los criterios vistos en los puntos anteriores.

El proceso descrito nos marca un orden de atención de incidencias, completamente dinámico, ya que a medida que van entrando nuevas incidencias se realiza un ajuste de prioridades por el tiempo de espera y la capacidad de trabajo del Contact Center, y por otro lado recomendando acciones de personalización en la interacción.

### 5.3 Aplicación de XAI a la tasa de abandono de cliente

Como ya se ha comentado, uno de los puntos fuertes del Contact Center es tratar de maximizar la satisfacción del cliente, una variable importante en este sentido es el grado de satisfacción del personal de Contact Center (Altman et al., 2021). Como se ha comentado en la introducción, el comportamiento del agente que atiende la interacción con el cliente puede generar una satisfacción positiva o negativa que está directamente relacionada con el valor de la marca. En el siguiente estudio (Iwu et al., 2021) encontró relaciones

significativas entre la gestión del conocimiento, la orientación al cliente, la satisfacción laboral y la intención de abandonar la compañía por parte del agente.

En la presente guía metodológica abordaremos un procedimiento de trabajo cuyo objetivo es analizar en función de los valores obtenidos por el modelo RFID, la variable target binaria abandono, y en futuros trabajos el modelo propuesto se extenderá a la rotación de personal del Contact Center.

Siguiendo la metodología Knowledge Discovery Databases (KDD) (Shafique & Qaiser, 2014), Figura 28:

- En el apartado 5.3.1, revisaremos el dominio del problema, pasaremos a crear un conjunto de datos objetivo basado en el modelo RFID al que incorporaremos la variable solicitud de cancelación por parte del cliente (abandono), seguidamente se realiza un preprocesamiento y transformación de datos a un dominio numérico.
- En el apartado 5.3.2, se aplicarán un conjunto de técnicas pre-modelo, para obtener así el primer conocimiento que nos proporciona el conjunto de datos. Posteriormente se aplicarán los algoritmos de ML detallados en la Tabla (9), y obtener de esta forma el algoritmo óptimo para el caso de estudio.
- En el apartado 5.3.3, interpretaremos los resultados y la conveniencia o no de utilizar interpretabilidad, en cuyo caso aplicaremos los algoritmos agnósticos globales y locales vistos en la sección 4.5 de la presente memoria; por último, se obtendrán las conclusiones.

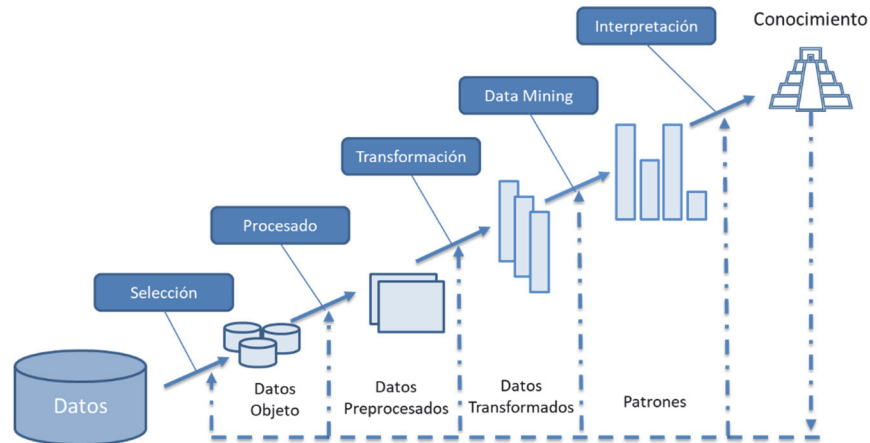


Figura 28. Etapas modelo KDD (Shafique & Qaiser, 2014)

### 5.3.1 Obtención de datos

Los datos son recogidos desde el CRM, realizaremos el mismo proceso descrito en la sección 5.1, en este caso nos interesa el valor de la recencia, frecuencia, importancia y duración en formato numérico. Realizaremos el proceso de agregación como se había descrito en el apartado 5.1.3 y a partir de ahí guardaremos esta información para determinar la variable target binaria abandono en relación con el resto de los criterios.

El valor asociado a la tipología de la incidencia en el CRM, nos indica si es o no una solicitud de cancelación por parte del cliente, valor en el CRM del atributo *Type* = "Cancellation Request".

$$\text{Dado } T = \{(u_1, r_1, f_1, i_1, d_1, t_1), \dots, (u_{\#T}, r_{\#T}, f_{\#T}, i_{\#T}, d_{\#T}, t_{\#T})\}$$

Donde al igual que se definió en el apartado 5.1.3,

- $r_e$ : corresponde con el número de días desde la última petición de servicio por parte del cliente  $u_e$  (utilizando como referencia la fecha de finalización del periodo de análisis). Por tanto,  $r_e = \text{diffdays}(t_2 - \max(\text{ticket\_date}_i))$ , donde  $\text{diffdays}$  es una función que devuelve la diferencia de días entre dos fechas, y  $\text{max}$  es una función que devuelve la última fecha de las diferentes fechas de entrada.

- $f_e$ : es el número de veces que el cliente ha realizado una solicitud de servicio, es decir, con diferentes códigos de ticket,  $ticket\_id_i$ .
- $i_e$ : es la importancia media. Al tratarse de una variable lingüística, este valor se calcula para cada cliente mediante la ecuación (4),  $i_e = \bar{x}^e [ticket\_importance_i]$ .
- $d_e$ : contiene la duración total en días de todos los tickets del cliente. Por lo tanto,  $d_e = \sum_i (diffdays (status\_date_i - ticket\_date_i))$ .
- $t_e$ : contiene el valor del tipo de servicio *Type*, en este caso solicitud de cancelación del servicio por parte del cliente.

El siguiente paso será realizar una limpieza de datos, esto es, revisaremos si la información recogida requiere de algún tipo de depuración de datos, por ejemplo, los outliers, suele ocurrir que pueden abrirse incidencias sin un cliente concreto, imputándose éstas a clientes genéricos, creciendo en número por encima de la media, desvirtuando de esta manera la información recogida y por tanto el análisis.

Una vez realizada la limpieza de datos se lleva a cabo un proceso de normalización, los algoritmos de aprendizaje automático funcionan mejor cuando las variables numéricas de entrada caen dentro de una escala similar, en este caso normalizaremos en el rango (0, 5).

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (23)$$

### 5.3.2 Predicción de abandono de clientes

Una vez realizados los pasos anteriores, se aplican algunas de las técnicas pre-modelo, visualización de datos y exploración necesarias para explorar, interpretar y obtener el primer conocimiento del conjunto de datos y así predecir el abandono o no de clientes. La aplicación de estas técnicas ayudará a identificar las características clave

del modelo, al ser independientes de éste, son aplicables a cualquier conjunto de datos y previas a cualquier selección inicial del modelo de ML escogido.

La primera técnica que se emplea es el análisis univariante, a través de histogramas. En segundo lugar, el análisis multivariante nos permitirá establecer un mapa de correlación entre variables (Casella et al., 2013), así como la distribución de outcomes y obtener de esta forma un análisis inicial de datos.

Una vez hecha la primera aproximación y valoración del conjunto de datos, podemos dividir dicho conjunto en entrenamiento y test, teniendo en cuenta que la variable  $x$  corresponde con los criterios RFID (recencia, frecuencia, importancia y duración) y la variable  $y$  corresponde con la variable a predecir, dato de abandono (sí / no) de cliente.

Se realizará un análisis con los algoritmos de la Tabla 9, para ver cuál de ellos es el que mejor encaja con el modelo predictivo:

Tabla 9. Algoritmos de ML aplicados al modelo

<b>Algoritmo</b>
Regresión Logística
Random Forest
Support Vector Machine
K-nearest neighbors
Decision Tree Classifier
Gaussian NB
XGboost

Se evalúa cada uno de los modelos descritos en la Tabla 9 mediante un proceso de validación cruzada (K-fold), y se pasa a analizar las curvas Receiver Operating Characteristic (ROC) y Area Under The Curve (AUC), el análisis de estas curvas nos ayudará a determinar cuál de los modelos es el más óptimo (Hanley & McNeil, 1982; P. Bradley, 1997) para nuestro estudio. Cuanto mayor sea el área bajo la curva, AUC, mejor será el modelo para predecir 0 clases como 0 y 1 clases como 1. La curva ROC se puede ver representada en la Figura 29, en el eje

y disponemos del ratio de verdaderos positivos (TPR) y en el eje  $x$  encontramos el ratio de falsos positivos (FPR). La precisión (Accuracy) la podemos obtener como resultado del cociente del sumatorio de predicciones correctas, entre el número total de predicciones.




Figura 29. Ejemplo curva ROC/AUC aplicado al abandono de clientes

Una vez testados los distintos modelos de aprendizaje automático se pasará a discutir la explicabilidad de cada uno de estos versus la capacidad predictiva, nos quedaremos con aquel modelo que cumpla mejor la expectativa predictiva y pasaremos a utilizar interpretabilidad en el caso de que fuese necesario.

### 5.3.3 Análisis de interpretabilidad de ML

A continuación, en esta sección se analizará la interpretabilidad de los modelos de ML descritos en la sección anterior. En particular y para tratar de cuantificar la interpretación de dichos modelos se aplicarán algunas de las métricas y gráficas vistas en la sección 4.5 de esta memoria.

En general la metodología diseñada en esta memoria es extensible a cualquier caso en el que tengamos que predecir una variable (clasificación o regresión) en función del resto de características.

## Interpretabilidad




Figura 30. Algoritmos empleados para la interpretabilidad de ML

Comenzaremos aplicando el Diagrama de Dependencia Parcial (PDP), muestra el efecto que tienen una o dos características en el resultado de predicción por un modelo de ML (Friedman, 2001). El diagrama nos permite trabajar con gráficas univariantes y bivariantes (correlación).




Figura 31. Gráfica univariante modelo PDP – Importance (RFID)

El PDP, es un promedio de las líneas de un diagrama ICE; en el siguiente paso, se trabaja con el modelo de curvas de expectativa condicional individual (ICE), que como se ha comentado en el apartado 4.5.2 de la presente memoria, ofrecen una expectativa local, enfocándose en instancias de datos individuales.




Figura 32. Gráfica ICE

A continuación, se utiliza el modelo ELI5 para medir la importancia de las características, nos ayuda a ver cuándo nuestro modelo puede responder a resultados contraintuitivos, ELI5 nos permite ajustar el modelo utilizando la librería XGboost y a continuación analizar la importancia de cada característica dentro del modelo aplicado.




Figura 33. Gráfica ELI5

En el siguiente paso se aplica el modelo LIME para predecir las explicaciones individuales, se basa en modelos sustitutos locales, es decir, los modelos sustitutos son modelos explicables (regresión lineal, árbol de decisión), que aprenden sobre el modelo de caja negra. Se trata de adaptar el modelo de caja negra a modelos sustitutos interpretables.

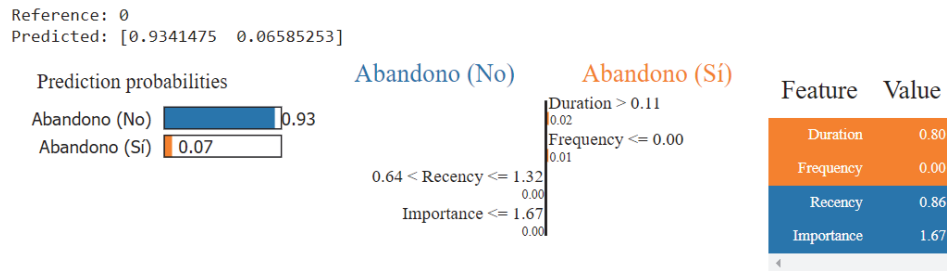


Figura 34. Gráfica LIME

Por último, aplicaremos SHAP, nos permite conocer qué características fueron las más influyentes para que el modelo tomara la decisión correcta de predecir si el cliente fue calificado con posibilidad baja o alta de abandono.




Figura 35. Gráfica SHAP

Algunos algoritmos adicionales que se han utilizado en el procedimiento son Skater y FairML, corresponden con dos marcos unificados de reciente incorporación y en vías de desarrollo (Linardatos et al., 2021). Skater permite una interpretación tanto global como local, para las explicaciones globales se basa en el uso de PDP, y para las explicaciones locales se basa en LIME.




Figura 36. Gráfica Skater

FairML, proyecta ortogonalmente la entrada para medir la dependencia del modelo predictivo de cada atributo. La proyección ortogonal de los vectores es importante porque nos permite eliminar completamente la dependencia lineal entre

los atributos. Si dos vectores son ortogonales entre sí, ninguna transformación lineal de un vector puede producir el otro. Esta intuición es la base de la medida de dependencia de las características.




Figura 37. Gráfica FairML

## 6. Aplicación práctica del modelo RFID para la valoración de clientes en su relación con el Contact Center

En las siguientes secciones, se presentan dos ejemplos de aplicación del modelo RFID expuesto en la sección 5.1 de la presente memoria, utilizando la información del CRM de una empresa multinacional de servicios de Telecom en un modelo puro B2C; y para el otro caso se trabajará en un escenario complementario, en un modelo B2B, una empresa fabricante y distribuidor de software. En ambos casos, seguiremos el modelo presentado en la Figura 23 de la sección 5.1 y analizaremos la viabilidad del modelo propuesto.

### 6.1 Aplicación del modelo RFID a la industria de Telecomunicaciones (B2C)

En esta sección, presentamos un ejemplo de aplicación de nuestro modelo RFID, utilizando la información del CRM de una empresa multinacional de servicios de Telecom, y nos ceñiremos a la parte de negocio ubicada en España.

#### 6.1.1 Obtención de datos

La información de los tickets es gestionada en un CRM operativo desarrollado por la propia empresa. Aunque no se nos han facilitado detalles en profundidad sobre dicho CRM, su estructura es bastante convencional y análoga en su modelo de datos a otros CRM como el presentado en la Figura 38. Por lo tanto, para obtener el conjunto  $T$ , se utilizan las especificaciones que se pueden ver a continuación:

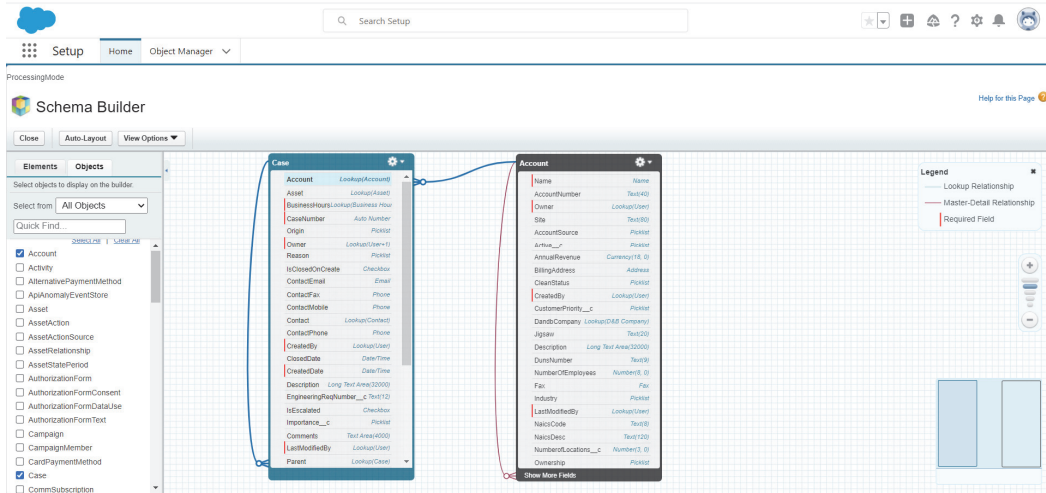


Figura 38. Salesforce CRM. Modelo de datos para la gestión de tickets

## 6.1.2 Preprocesado

El periodo de tiempo,  $t$ , para el análisis está delimitado por las fechas  $t_1 = 1 \text{ April } 2019$  and  $t_2 = 30 \text{ April } 2019$ . A partir de la información del CRM contenida en  $T$ , se obtienen todos los tickets de incidencias que han sido gestionados durante dicho período, es decir,  $status\_date_i \geq t_1$  and  $\leq t_2$ . Como ya se ha mencionado, sólo se seleccionan los tickets que no corresponden a cancelaciones de clientes, utilizando  $trouble\_id_i$ .

En estas condiciones se obtiene  $T'$  con un número total de tickets de 13619, es decir,  $\#T' = 13619$ . Un extracto de esta relación de tickets se muestra en la Tabla 10 con varios clientes seleccionados para los que seguiremos todo el proceso.

Tabla 10. Extracto del conjunto  $T'$

<b>u</b>	<b>Ticket_id</b>	<b>Ticket_Date</b>	<b>Status_id</b>	<b>Status_Date</b>	<b>Ticket_Importance</b>
21046586	155395585	25 January 2016	Closed	02 April 2019	M
21046586	155402659	25 January 2016	Closed	02 April 2019	VL
21046586	155418120	25 January 2016	Closed	04 April 2019	VL
21046586	155520776	25 January 2016	Closed	04 April 2019	VL
21046586	155887861	25 January 2016	Closed	08 April 2019	VL
21046586	156171484	25 January 2016	Closed	13 April 2019	VH
21334657	156206850	12 April 2016	Closed	13 April 2019	L
21334657	156548471	12 April 2016	Closed	19 April 2019	L
21334657	156750555	12 April 2016	Closed	25 April 2019	VH
2288774	155508450	12 September 2015	Closed	04 April 2019	M
24583147	155628991	18 October 2018	Closed	06 April 2019	VL

25860618	155670320	28 March 2019	Closed	06 April 2019	VL
25860618	156085093	28 March 2019	Closed	12 April 2019	M
25860618	156086410	28 March 2019	Working	12 April 2019	M
25860618	156345579	28 March 2019	Closed	15 April 2019	VH
25860618	156345680	28 March 2019	Working	15 April 2019	L
25864456	155401447	29 March 2019	Closed	02 April 2019	VH
25864456	155420645	29 March 2019	Closed	04 April 2019	VH
26053204	157048831	27 April 2019	Closed	28 April 2019	VL
26064419	157149871	29 April 2019	Closed	29 April 2019	L
26064419	157214640	29 April 2019	Closed	29 April 2019	VL
26064419	157215347	29 April 2019	Closed	29 April 2019	M

### 6.1.3 Agregación

Agrupamos los diferentes clientes en  $T'$ , dando un total de 6789, es decir,  $\#U = 6789$ . De esta forma, obtenemos el conjunto  $TU$  con las especificaciones mencionadas anteriormente. En la Tabla 11 se muestra un extracto de este conjunto.

Tabla 11. Extracto del conjunto  $TU$

<b>u</b>	<b>r</b>	<b>f</b>	<b>i</b>	<b>d</b>
21046586	17	6	L	6999
21334657	5	3	M	3306
2288774	26	1	M	1300
24583147	24	1	VL	170
25860618	15	5	(M, -0.05)	75
25864456	26	2	VH	10
26053204	2	1	VL	1
26064419	1	3	L	0

### 6.1.4 Cálculo de las puntuaciones

El conjunto  $TU$  en esta etapa se utiliza para obtener el conjunto  $TRFID$  como se explica en la sección anterior. El RFID contiene las variables básicas de este nuevo modelo. En la Tabla 12, se presenta un extracto de este conjunto para los mismos clientes que se muestran en la Tabla 11.

Tabla 12. Extracto del conjunto TRFID

<b>u</b>	<b>R</b>	<b>F</b>	<b>I</b>	<b>D</b>
21046586	(M, -0.087)	(VH, -0.035)	L	(VH, -0.002)
21334657	(H, -0.026)	(H, 0.008)	M	(VH, -0.024)
2288774	(VL, 0.085)	VL	M	(VH, -0.12)
24583147	(L, -0.086)	VL	VL	(L, 0.12)
25860618	(M, -0.003)	(VH, -0.065)	(M, -0.05)	(L, -0.009)
25864456	(VL, 0.085)	(M, 0.01)	VH	(VL, 0.098)
26053204	(VH, -0.097)	VL	VL	(VL, 0.038)
26064419	(VH, -0.025)	(H, 0.008)	L	VL

### 6.1.5 Cálculo de la puntuación global para RFID

En esta fase, hay que obtener la importancia de cada una de las variables del modelo RFID antes de calcular la puntuación global del cliente. Para ello, como se ha mencionado anteriormente, se utilizará el modelo AHP. El experto consultado ha especificado la siguiente matriz utilizando la escala de Saaty (Tabla 1):

$$PW = \begin{bmatrix} & R & F & I & D \\ R & 1 & 7 & 3 & 5 \\ F & 1/7 & 1 & 1/5 & 1/5 \\ I & 1/3 & 5 & 1 & 3 \\ D & 1/5 & 5 & 1/3 & 1 \end{bmatrix}$$

Sólo cuando  $CR \leq 0,10$  (véase la ecuación (9)) se satisfacen los resultados del tipo jerárquico individual y se garantiza la coherencia. En este caso,  $CR = 0,091$  por lo que los resultados son válidos para el modelo.

Las ponderaciones finales calculadas son  $W = \{w_R = 0.556, w_F = 0.259, w_I = 0.136, w_D = 0.049\}$ . Por tanto, el experto ha dado mayor importancia a la recencia de las entradas, seguida de su frecuencia e importancia. La duración total de su resolución es la menos importante.

Como se ha mencionado anteriormente, con esta  $W$  obtenemos la puntuación global de RFID para cada cliente. En la Tabla 13 presentamos los resultados para los mismos clientes que se muestran en la Tabla 10.

Tabla 13. Puntuación global RFID para algunos clientes

<b>u</b>	<b>RFID</b>
21046586	(M, 0.062)
21334657	(H, -0.035)
2288774	(L, -0.092)
24583147	(VL, 0.109)
25860618	(M, 0.092)
25864456	(L, 0.07)
26053204	(M, 0.004)
26064419	(H, 0.022)

### 6.1.6 Estrategia de recomendación individualizada

La puntuación global del modelo RFID permite cuantificar la atención que debe prestar el Contact Center con estos clientes. A modo de ejemplo, la Tabla 14 muestra los clientes RFID más valiosos para la empresa. Como se puede observar, predominan los que tienen una recencia y una frecuencia muy altas, ya que son las variables con mayor peso en  $W$ . Hay que tener en cuenta que el uso del modelo 2-tupla permite una alta interpretabilidad lingüística, así como una alta precisión en los resultados.

Todos estos clientes deben recibir una atención especial en su interacción con el Contact Center, por ejemplo, el cliente 23420561 tiene una puntuación global  $RFID = (VH, -0.087)$ , lo que le otorga una importancia muy alta para la empresa, con valores de recencia y frecuencia muy altos.

Tabla 14. Puntuación global RFID detallada para algunos clientes

<b>u</b>	<b>r</b>	<b>f</b>	<b>i</b>	<b>d</b>	<b>R</b>	<b>F</b>	<b>I</b>	<b>D</b>	<b>RFID</b>
23420561	0	10	(M, -0.125)	3911	VH	(VH, -0.005)	(M, -0.125)	(VH, -0.013)	(VH, -0.087)
25403001	0	7	M	585	VH	(VH, -0.018)	M	(H, -0.057)	(VH, -0.088)
23987407	1	7	M	1926	(VH, -0.025)	(VH, -0.018)	M	(VH, -0.071)	(VH, -0.09)
21858356	0	4	M	3442	VH	(VH, -0.125)	M	(VH, -0.021)	(VH, -0.101)
22242821	0	4	M	2803	VH	(VH, -0.125)	M	(VH, -0.031)	(VH, -0.102)
23694383	1	5	M	1689	(VH, -0.025)	(VH, -0.065)	M	(VH, -0.085)	(VH, -0.103)
23888282	1	5	M	1470	(VH, -0.025)	(VH, -0.065)	M	(VH, -0.1)	(VH, -0.103)
25972671	0	5	(H, -0.1)	45	VH	(VH, -0.065)	(H, -0.1)	(L, -0.062)	(VH, -0.104)
2227948	1	5	(M, -0.05)	6626	(VH, -0.025)	(VH, -0.065)	(M, -0.05)	(VH, -0.003)	(VH, -0.105)
24178272	1	5	M	1120	(VH, -0.025)	(VH, -0.065)	M	(H, 0.087)	(VH, -0.106)
25905579	1	9	(M, 0.083)	117	(VH, -0.025)	(VH, -0.007)	(M, 0.083)	(L, 0.048)	(VH, -0.107)
2194707	1	9	(L, 0.056)	12110	(VH, -0.025)	(VH, -0.007)	(L, 0.056)	VH	(VH, -0.11)
25962365	0	4	(H, -0.062)	66	VH	(VH, -0.125)	(H, -0.062)	(L, -0.026)	(VH, -0.113)

23304767	0	6	L	2452	VH	(VH, -0.035)	L	(VH, -0.046)	(VH, -0.113)
2463879	1	6	(L, 0.083)	7739	(VH, -0.025)	(VH, -0.035)	(L, 0.083)	(VH, -0.002)	(VH, -0.114)
24128560	1	7	(L, 0.071)	1677	(VH, -0.025)	(VH, -0.018)	(L, 0.071)	(VH, -0.086)	(VH, -0.115)
2640503	0	11	(L, -0.091)	13764	VH	(VH, -0.003)	(L, -0.091)	VH	(VH, -0.115)
23640429	0	11	(L, -0.091)	3752	VH	(VH, -0.003)	(L, -0.091)	(VH, -0.016)	(VH, -0.116)
25410677	0	6	(L, 0.083)	517	VH	(VH, -0.035)	(L, 0.083)	(H, -0.085)	(VH, -0.116)
25845359	0	10	(L, 0.1)	246	VH	(VH, -0.005)	(L, 0.1)	(M, -0.041)	(VH, -0.116)

### 6.1.7 Segmentación de clientes

Como se ha comentado, las variables RFID se expresan en el modelo 2-tupla, lo que permite una fácil interpretación y puede computarse sin pérdida de información. Sin embargo, en esta fase, para seguir el proceso de segmentación convencional, trabajaremos con estas variables convertidas a una escala numérica mediante la función  $\Delta^1$  (Ecuación (2)).

Por tanto, al estar todas las variables en la misma escala, no es necesario ningún proceso de normalización adicional. No obstante, es necesario un estudio de las correlaciones entre las variables, ya que una alta correlación entre ellas indica la inadecuación de utilizar una distancia euclidiana, que es la que utiliza el algoritmo k-means.

La Figura 39 muestra la matriz de correlaciones de Pearson. La mayor correlación se da entre la recencia y la duración, con un 0.3, que puede considerarse no significativo.




Figura 39. Matriz de correlación  $\Delta^{-1}(R)$ ,  $\Delta^{-1}(F)$ ,  $\Delta^{-1}(I)$ , y  $\Delta^{-1}(D)$

Como se ha mencionado anteriormente, para resolver el típico problema de obtener el número óptimo de segmentos, utilizaremos el método propuesto en (Charrad et al., 2014). Este método ofrece al usuario el mejor esquema de clustering (es decir, mejor k) entre diferentes resultados después de utilizar diferentes índices. El número final de clústeres se propone en base a la mayoría de los índices. Tras la aplicación en lenguaje R (utilizando el paquete NbClust para determinar el número óptimo de clústeres entre 6 y 12) el resumen de los diferentes algoritmos para determinar el número óptimo de segmentos se muestra en la Tabla 15. Como se puede observar en la Figura 40, la mayoría de los algoritmos determinan que el número óptimo de clústeres es 8. Por lo tanto, en nuestro caso  $\#c = 8$ . Aunque hemos aplicado un método automático de terminación del número de clústeres, hay que tener en cuenta que es habitual considerar también criterios empresariales en la determinación del clustering final. De este modo, hemos probado la segmentación cambiando el valor de k y también nos satisfizo la que obtuvo ocho clústeres.

Tabla 15. Número de clústeres propuestos por diferentes índices

Index	Number of Clusters	Value Index
KL	8	57.13
CH	11	682.26
Hartigan	8	272.03
CCC	12	74.13
Scott	8	876.63
Marriot	8	1477204.00
TrCovW	8	326.29
TraceW	8	19.57
Friedman	8	15.09
Rubin	8	-2.67
Cindex	10	0.26
DB	7	0.92
Silhouette	8	0.39
Duda	6	4.10
PseudoT2	6	-305.40
Beale	6	-1.82
Ratkowsky	6	0.33
Ball	7	4.73
PtBiserial	8	0.58
Frey	6	1.04
McClain	6	1.81
Dunn	11	0.03
SDindex	8	4.93
SDbw	11	0.39



Figura 40. Determinación del número óptimo de segmentos

Una vez aplicado el algoritmo k-means, utilizando la distancia euclidiana (véase la ecuación (20)), los resultados se muestran en la Tabla 16.

Tabla 16. Resultados del algoritmo k-means

Cluster c	R vc1	F vc2	I vc3	D vc4	Number of Customers
1	0.3468286	0.004483071	0.64094575	0.3294273	682
2	0.802829	0.728453895	0.23999396	0.82394	1059
3	0.3025948	0	0.14033457	0.6893585	807
4	0.3091454	0.622837611	0.27908176	0.2508257	645
5	0.3238762	0.636744215	0.27405076	0.7974674	892
6	0.2976317	0	0.09399773	0.2478526	883
7	0.8238419	0	0.17406221	0.4135224	1093
8	0.7944105	0.683038143	0.26883786	0.257423	728

### 6.1.8 Estrategia de recomendación grupal

Los resultados del clustering, resumidos en la Tabla 16, se obtienen tras aplicar la función  $\Delta^1$  (ecuación (2)) a cada una de las variables del conjunto TRFID. Esto ha permitido un proceso más preciso que el que se suele aplicar en los modelos tradicionales de RFM. Sin embargo, para comprender mejor los clústeres es preferible utilizar la representación lingüística de los mismos. Esto se consigue aplicando la correspondiente función  $\Delta$  (Ecuación (1)) a los centroides, véase la Tabla 17.

Tabla 17. Resultados del algoritmo k-means expresados en el modelo 2-tupla

Cluster c	R vc1	F vc2	I vc3	D vc4
1	(L, 0.097)	(VL, 0.004)	(H, -0.109)	(L, 0.079)
2	(H, 0.053)	(H, -0.022)	(L, -0.01)	(H, 0.074)
3	(L, 0.053)	VL	(L, -0.11)	(H, -0.061)
4	(L, 0.059)	(M, 0.123)	(L, 0.029)	(L, 0.001)
5	(L, 0.074)	(H, -0.113)	(L, 0.024)	(H, 0.047)
6	(L, 0.048)	VL	(VL, 0.094)	(L, -0.002)
7	(H, 0.074)	VL	(L, -0.076)	(M, -0.086)
8	(H, 0.044)	(H, -0.067)	(L, 0.019)	(L, 0.007)

Para apoyar esta información, la Figura 41 muestra la distribución de todos los clientes segmentados por cada una de las variables utilizadas en este proceso.

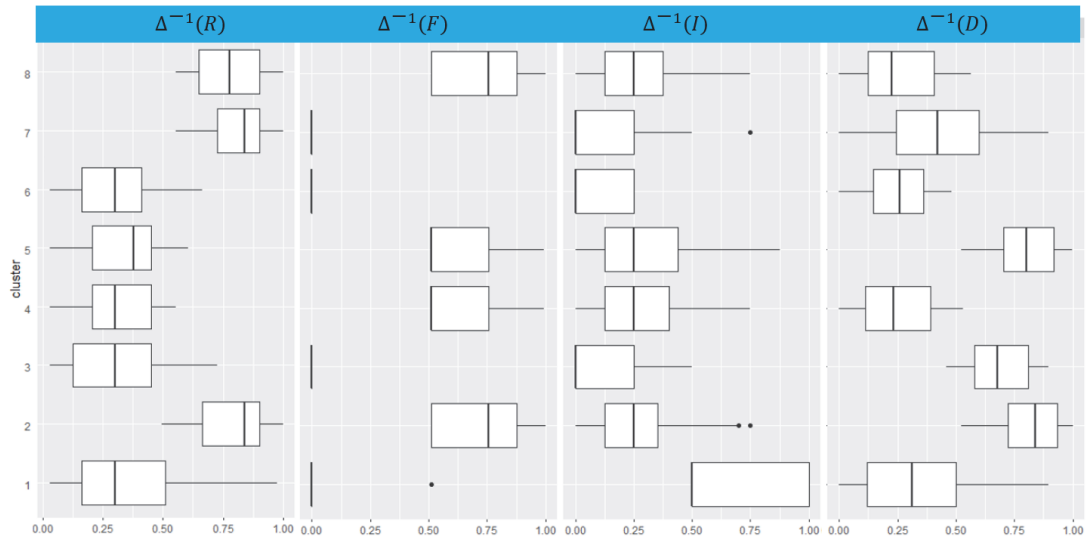


Figura 41. Distribución de clientes por segmento

La Tabla 18 muestra las estrategias de recomendación por perfil de cliente, respondiendo cada agrupación a un perfil con la distribución de segmentos observada en la Figura 41. Las métricas de recomendación que se utilizarán en las futuras interacciones bidireccionales entre el cliente y la marca deberían basarse en ofrecer la máxima calidad de servicio con el objetivo de obtener la máxima satisfacción del cliente (Andrade et al., 2020; van Dun et al., 2011; Zeithaml & Berry, 1988).

Tabla 18. Estrategia de recomendación para cada clúster

Cluster	Interacción	Estrategia de recomendación
1	<i>SelfCustom</i>	<p><b>Descripción:</b> A priori se trata de clientes poco problemáticos, no tienen incidencias recurrentes y tampoco frecuentes, pero las incidencias que han tenido son de cierta importancia.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del cliente con el Contact Center se recomienda utilizar bot (faqs, chat, voz), en el caso de requerirse personalización porque así lo demande el cliente, se podría pasar de un canal automático a uno personalizado e incluso especializado.</p> <p><b>Campañas:</b> Se propone para este tipo de clientes premiar la fidelización a la marca con campañas de descuento por permanencia.</p>
2	<i>StrongCustom</i>	<p><b>Descripción:</b> Cliente considerado en alto peligro de abandono.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del cliente con el Contact Center se recomienda personalizar la comunicación mediante agentes especializados.</p> <p><b>Campañas:</b> Se proponen campañas que tiendan a elevar la percepción del cliente del servicio y de la marca. Se recomienda escuchar al cliente, adquirir un conocimiento profundo del cliente y en función de ello proponer descuentos, ofertas y promociones.</p>

3	<i>SelfCustom</i>	<p><b>Descripción:</b> A priori se trata de clientes poco problemáticos, no tienen incidencias recurrentes y tampoco frecuentes, pero las incidencias que han tenido son de mediana a elevada duración. Suele tratarse de clientes que tuvieron problemas iniciales con los servicios de instalación.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del cliente con el Contact Center se recomienda utilizar bot (faqs, chat, voz), en el caso de requerirse personalización porque así lo demande el cliente, se podría pasar de un canal automático a uno personalizado e incluso especializado.</p> <p><b>Campañas:</b> Se propone para este tipo de clientes premiar la fidelización a la marca con campañas de descuento por permanencia.</p>
4	<i>Custom</i>	<p><b>Descripción:</b> A priori se trata de clientes que tuvieron incidencias frecuentes y en el pasado, posiblemente problemas relacionados con la puesta en marcha del servicio. Si bien, la resolución de dichas incidencias fue rápida y sin importancia.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del cliente con el Contact Center se recomienda personalizar la comunicación mediante agentes generalistas y si es necesario especializados.</p> <p><b>Campañas:</b> Se proponen campañas destinadas a fortalecer y premiar la fidelidad del cliente, descuentos por permanencia.</p>
5	<i>Custom</i>	<p><b>Descripción:</b> A priori se trata de clientes que tuvieron incidencias frecuentes y en el pasado, posiblemente problemas derivados de la instalación, que produjeron incidencias de alta duración. Hay que vigilar la llegada de nuevos tickets, ya que implicaría el paso a cluster 2.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del cliente con el Contact Center se recomienda personalizar la comunicación mediante agentes generalistas y si es necesario especializados.</p> <p><b>Campañas:</b> Se proponen campañas destinadas a fortalecer y premiar la fidelidad del cliente, así mismo, elevar la imagen de marca, escuchar al cliente y generar contenidos de valor.</p>
6	<i>Self</i>	<p><b>Descripción:</b> A priori se trata de clientes con incidencias poco frecuentes en el pasado, y sin mucha relevancia.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del cliente con el Contact Center se recomienda utilizar bot (faqs, chat, voz), no se requiere excesiva personalización, se buscará la auto respuesta en la interacción con el cliente.</p> <p><b>Campañas:</b> Esta tipología de cliente podría ser un excelente embajador de la marca, se proponen campañas que premien su interacción y participación en redes sociales, además de fortalecer la fidelidad del cliente con descuentos asociados a la permanencia.</p>
7	<i>SelfCustom</i>	<p><b>Descripción:</b> Aunque las incidencias no son frecuentes, sí existe una recencia en las mismas, sin embargo, la importancia y duración es baja, clientes con baja tasa de abandono.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del cliente con el Contact Center se recomienda utilizar bot (faqs, chat, voz), en el caso de requerirse personalización porque así lo demande el cliente, se podría pasar de un canal automático a uno personalizado e incluso especializado.</p> <p><b>Campañas:</b> Se proponen campañas destinadas a fortalecer la imagen de marca, en el caso de que el cliente lleve tiempo con la marca, se proponen estrategias complementarias que premien la fidelización.</p>
8	<i>Custom</i>	<p><b>Descripción:</b> Incidencias frecuentes y reiteradas, pero sin importancia. La tipología de cliente puede corresponder con clientes que buscan excelencia en los servicios de la marca.</p>

**Interacciones futuras:** En siguientes interacciones del cliente con el Contact Center se recomienda personalizar la comunicación mediante agentes generalistas y si es necesario especializados.

**Campañas:** Destinadas a promover la confianza entre los clientes, crear mensajes de valor que puedan ayudar al cliente y entender qué hace la marca en su beneficio.

Partiendo de la premisa anterior, el objetivo principal de las estrategias de recomendación por perfil será personalizar la interacción del cliente con la marca, analizando el nivel de personalización en las interacciones con el Contact Center y así conectar mejor emocionalmente con los clientes (Hilken et al., 2018; Lemon & Verhoef, 2016).

Intentamos que los grupos de clientes que necesitan una atención personalizada, es decir, los grupos que consideramos críticos (strongcustom, custom) reciban esta atención en la siguiente interacción con el contact center. Además, los grupos que no consideramos tan críticos (selfcustom, self) pueden gestionarse de forma autónoma o a través de un bot.

La Tabla 19 muestra el segmento final asignado a los clientes mostrados en las Tablas 10-13.

Tabla 19. Valor de *RFIDc* para algunos clientes

Client_ID	Cluster
21046586	5
21334657	2
2288774	3
24583147	6
25860618	4
25864456	1
26053204	7
26064419	8

En la Tabla 19 se evalúan 8 clientes distintos explicando la pertenencia a los perfiles de clúster definidos en la Tabla 18, a partir de su pertenencia podemos considerar entre otras acciones a realizar en la interacción entre cliente y marca, medir

el grado de personalización en siguientes interacciones y definir acciones de marketing adecuadas al perfil.

El perfil del cliente 21046586 encaja con el clúster 5, por tratarse de un cliente con la siguiente evaluación individual,  $R = (M, -0.087)$ ,  $F = (VH, -0.035)$ ,  $I = L$ ,  $D = (VH, -0.002)$ . De forma que es un cliente con incidencias de duración muy alta y frecuente, la recencia es moderada y con valor bajo en la importancia, ver Tabla 12. El tipo de atención será personalizada.

El perfil del cliente 21334657 encaja con el clúster 2, por tratarse de un cliente con la siguiente evaluación individual,  $R = (H, -0.026)$ ,  $F = (H, -0.008)$ ,  $I = M$ ,  $D = (VH, -0.024)$ . De forma que es un cliente con incidencias de duración muy alta y frecuente, la recencia es muy alta y con valor medio de la importancia, ver Tabla 12. Este perfil de cliente es considerado de relevancia crítica para la marca, y será atendido de forma personalizada.

El perfil del cliente 2288774 encaja con el clúster 3, por tratarse de un cliente con la siguiente evaluación individual,  $R = (VL, 0.085)$ ,  $F = VL$ ,  $I = M$ ,  $D = (VH, -0.12)$ . De forma que es un cliente con incidencias de duración muy alta y muy poco frecuentes, la recencia es muy baja y con valor medio de la importancia, ver Tabla 12. Este perfil de cliente no ha dado muchos problemas a la marca, son clientes fieles que tuvieron problemas iniciales ligados a los procesos de implantación, en las siguientes interacciones del cliente con el Contact Center se recomienda utilizar bot de autoayuda y en el caso de requerirse personalización se pasaría a un agente libre.

El perfil del cliente 24583147 encaja con el clúster 6, por tratarse de un cliente con la siguiente evaluación individual,  $R = (L, -0.086)$ ,  $F = VL$ ,  $I = VL$ ,  $D = (L, 0.12)$ . De forma que es un cliente con incidencias de duración baja y muy poco frecuentes, la recencia es baja y con valor muy bajo de la importancia, ver Tabla 12. Este perfil de cliente al igual que en el caso anterior, no ha dado muchos problemas a la marca, en

las siguientes interacciones del cliente con el Contact Center se recomienda utilizar bot de autoayuda, se buscará la auto respuesta en la interacción con el cliente.

El perfil del cliente 25860618 encaja con el clúster 4, por tratarse de un cliente con la siguiente evaluación individual,  $R = (M, -0.003)$ ,  $F = (VH, -0.065)$ ,  $I = (M, -0.05)$ ,  $D = (L, -0.009)$ . De forma que es un cliente con incidencias de duración baja y muy frecuentes, la recencia es media, al igual que la importancia, ver Tabla 12. Este perfil de cliente, aunque el valor de la recencia e importancia es medio, hay que tener especial cuidado, en siguientes interacciones del cliente con el Contact Center se recomienda personalizar la comunicación mediante agentes generalistas y si es necesario especializados.

El perfil del cliente 25864456 encaja con el clúster 1, por tratarse de un cliente con la siguiente evaluación individual,  $R = (VL, -0.085)$ ,  $F = (M, 0.01)$ ,  $I = VH$ ,  $D = (VL, -0.098)$ . De forma que es un cliente con incidencias de duración muy baja y de frecuencia moderada, la recencia es muy baja, y la importancia muy alta, ver Tabla 12. Este perfil de cliente corresponde con clientes con incidencias muy importantes en el pasado, en siguientes interacciones del cliente con el Contact Center se recomienda utilizar bot de autoayuda, en el caso de requerirse personalización porque así lo demande el cliente, se podría pasar de un canal automático a uno personalizado e incluso especializado.

El perfil del cliente 26053204 encaja con el clúster 7, por tratarse de un cliente con la siguiente evaluación individual,  $R = (VH, -0.097)$ ,  $F = VL$ ,  $I = VL$ ,  $D = (VL, 0.038)$ . De forma que es un cliente con incidencias de duración, importancia y frecuencia muy baja, la recencia es muy alta, ver Tabla 12. Este perfil de cliente corresponde con clientes fieles con pocos problemas, si bien, recientes, es por ello importante que si se incrementa el valor de la frecuencia dirigir al cliente hacia una atención personalizada.

El perfil del cliente 26064419 encaja con el clúster 8, por tratarse de un cliente con la siguiente evaluación individual,  $R = (VH, -0.025)$ ,  $F = (H, 0.008)$ ,  $I = L$ ,  $D = VL$ . De forma que es un cliente con incidencias de duración e importancia bajas, frecuencia y recencia altas, ver Tabla 12. Este perfil de cliente corresponde con clientes fieles con problemas frecuentes y recientes, es por ello importante dirigir al cliente hacia una atención personalizada.

### 6.1.9 Conclusiones

Los datos que hemos trabajado en los apartados del punto anterior proceden de una empresa de implantación de servicios de telecomunicaciones, como conclusiones a este estudio aplicado a dicha empresa, y analizando el volumen de datos, podemos ver que los tiempos de apertura y cierre de tickets es elevado, esto se debe principalmente a los procesos de implantación de tecnología 4G en entornos rurales, donde los períodos de implantación y alcance de niveles de cobertura óptima son elevados.

La metodología de trabajo que hemos utilizado nos ayuda a obtener dos objetivos, el primero disponer de una clasificación individual de los clientes de acuerdo con los criterios definidos en la relación entre el cliente y el Contact Center, RFID, para ello hemos adaptado el modelo RFM, muy utilizado en marketing por su sencillez de uso y facilidad de interpretación, a un entorno distinto del tradicional, en este caso los servicios de atención al cliente, Customer Service. Además, con el objetivo de proporcionar unos mejores resultados del modelo RFID y basados en el trabajo previo (Ramón A. Carrasco et al., 2015), se aplica el modelo 2-tupla para solucionar el problema de la falta de precisión del modelo RFM, hemos utilizado además la metodología AHP para dar peso a cada una de las variables que componen el modelo RFID y así poder obtener un score global de cada cliente. Con el segundo objetivo, hemos dotado al modelo RFID de un argumento adicional, es decir, la posibilidad de

segmentar a los clientes utilizando k-means, y desarrollar de esta manera un modelo de atención por segmentos.

De esta forma, y a través del primero de los objetivos, podemos establecer una estrategia de clasificación individual con cada cliente de acuerdo con los criterios definidos en el modelo RFID, que nos ayudará a cuantificar el cuidado con que debe gestionarse de forma individual la atención de cada cliente atendiendo a su clasificación, ver Tabla 14. En una típica operativa, el agente encargado de gestionar esa interacción reconoce al cliente y, por tanto, pueden establecerse recomendaciones basadas en su historial de relación con la marca, no sólo por lo que compra RFM, también por el histórico de la atención recibida RFID.

Y, a través del segundo objetivo, hemos procedido a realizar una segmentación de los clientes aplicando k-means de forma que somos capaces de aplicar acciones grupales por perfiles de cliente. Para este caso, nos hemos centrado en ayudarnos de estas agrupaciones para poder establecer escenarios de menor a mayor coste en el proceso de interacción del cliente con la marca, es decir, intentamos que los grupos de cliente que necesitan atención personalizada, los grupos que consideramos críticos (StrongCustom, Custom) reciban dicha atención personalizada en la siguiente interacción con el Contact Center. La imagen de marca que el usuario percibe crece considerablemente con este tipo de interacciones (Andrade et al., 2020). Y, por otro lado, los grupos que no consideramos tan críticos (SelfCustom, Self) pueden autogestionarse de forma autónoma o a través de un bot, el coste de la interacción es menor y la imagen de marca no se resiente, ver Tabla 18.

Por último, hemos dado unas recomendaciones acerca de las campañas que podrían ser más eficaces atendiendo a la segmentación de clientes, buscando la fidelización entre cliente y marca para los clústeres susceptibles de abandono, premiando a los clientes más fieles para que contribuyan a incrementar imagen de

marca generando contenidos de valor y como siempre, utilizar la palanca de las ofertas y promociones.

A efectos prácticos, hemos evaluado a distintos clientes de cada clúster y analizado las acciones que desde el punto de vista del Contact Center podrían realizarse, ver Tabla 19. Básicamente atendiendo al valor del clúster se han recomendado acciones de personalización y posibles campañas en un entorno Omnicanal.

A criterio del responsable del Contact Center queda utilizar un modelo u otro, o ambos. Con el objetivo de establecer estrategias que ayuden en el proceso de fidelización entre cliente y marca, ya que la valoración que un cliente hace de la marca no solo depende del producto o servicio que esta le proporciona, la satisfacción del cliente depende de factores adicionales como la personalización, la atención a través de múltiples canales de comunicación y la excelencia en los servicios prestados (Andrade et al., 2020).

El modelo desarrollado puede aplicarse a diferentes sectores, en modelos B2B o en modelos B2C en los que el Contact Center se convierte en un elemento fundamental en la relación entre el cliente y marca. Sectores como el turismo, los servicios profesionales, los fabricantes, las compañías de seguros, los bancos, los retailers, las entidades públicas, los hospitales y los centros de salud disponen de herramientas CRM integradas en el Contact Center. Si en una interacción entre el cliente y la marca, el agente que se encarga de la gestión tiene una valoración adecuada del cliente, el agente puede entender y personalizar la comunicación. Si además dotamos al sistema de un modelo de inteligencia IA, el sistema será capaz de recomendar las mejores acciones para el perfil del cliente que el agente está tratando. Además, y, por último, podemos utilizar el valor agregado del cliente para la gestión de colas en el Contact Center.

Este modelo puede complementar el modelo RFM y así obtener resultados agregados de la evaluación del cliente a través de los diferentes puntos de interacción entre el cliente y la marca (venta y postventa), con la ventaja de que toda la información procesada por el modelo se puede encontrar en los sistemas habituales de gestión de clientes de cualquier empresa, CRM, y por tanto aplicable a cualquier sector. Esto nos ayudará a tener un mejor conocimiento del cliente y, por tanto, a desarrollar e implementar acciones que tiendan a contribuir al enriquecimiento de la imagen de marca. Por otro lado, complementamos también la visión que el cliente nos deja acerca del servicio prestado a través de encuestas, de forma que podemos tener una visión 360° de las interacciones en el Contact Center entre cliente – marca.

## 6.2 Aplicación del modelo RFID a la industria de la comercialización de licencias de software (B2B)

En esta sección, se presenta un ejemplo de uso del modelo RFID, aplicado en esta ocasión a una empresa distribuidora de licencias de software, en un modelo de relación B2B. Aunque utilizaremos en muchas ocasiones el término cliente, el perfil de éste corresponde con partner tecnológicos que distribuyen e implantan los productos del fabricante de software.

### 6.2.1 Obtención de datos

La información de los tickets es gestionada en un CRM operativo, en este caso Salesforce, su estructura está basada en el modelo presentado en la Figura 38.

### 6.2.2 Preprocesado

El periodo de tiempo,  $t$ , para el análisis está delimitado por las fechas  $t_1 = 1 \text{ Enero } 2018$  and  $t_2 = 31 \text{ Diciembre } 2020$ . A partir de la información del CRM contenida en  $T$ , se obtienen todos los tickets de incidencias que han sido gestionados durante dicho período, es decir,  $status\_date_i \geq t_1$  and  $\leq t_2$ . Como ya se ha

mencionado, sólo se seleccionan los tickets que no corresponden a cancelaciones de clientes, utilizando para ello el valor del campo  $trouble\_id_i$ .

El período seleccionado es amplio, debido a que las relaciones en un modelo B2B suelen ser prolongadas en el tiempo, y más en un modelo de comercialización basado en la implantación de servicios de software.

En estas condiciones se obtiene  $T'$  con un número total de tickets de 1842191, es decir,  $\#T' = 1842191$ . Un extracto de esta relación de tickets se muestra en la Tabla 20 con varios clientes seleccionados para los que seguiremos todo el proceso.

Tabla 20. Extracto del conjunto  $T'$

u	Ticket_id	Ticket_Date	Status_id	Status_Date	Ticket_Imp ortance	Type
0010600001wReca	5000600004jE96k	2020-12-11 13:35:00	Closed	2020-12-11 13:39:00	Medium	Question
0010600001wReca	5000600004stFQQ	2021-01-03 17:04:00	Closed	2021-01-03 17:10:00	Medium	Question
0010600001wRenT	5000600004vE3uv	2021-05-05 11:31:00	Closed	2021-05-05 11:34:00	Medium	Problem
0010600001wRenT	5000600004vE3xB	2021-05-05 11:34:00	Closed	2021-05-05 11:46:00	Medium	Problem
0010600001wRenT	5000600004wThZc	2021-05-19 14:48:00	Closed	2021-05-19 14:48:00	Medium	Problem
0010600001wRenT	5000600004wULEu	2021-05-26 14:09:00	Closed	2021-05-26 14:09:00	Medium	Question
0010600001wReue	5000600004n0V19	2020-12-31 16:00:00	Closed	2020-12-31 16:01:00	Medium	Question
0010600001wRezt	5000600004eELbT	2020-09-22 18:57:00	Closed	2020-09-22 18:57:00	Medium	Question
0010600001wRf4A	5000600004eFX3A	2020-09-10 15:54:00	Closed	2020-09-10 15:54:00	Medium	Question
0010600001wRf4A	5000600004wU73K	2021-05-23 19:25:00	Closed	2021-05-24 20:01:00	Medium	Question
0010600001wRf5G	50006000051FfjA	2021-07-28 09:30:00	Closed	2021-07-28 09:32:00	Medium	Problem
0010600001wRf6k	5000600004eFGJX	2020-06-10 15:12:00	Closed	2020-06-10 21:33:00	Medium	Question
0010600001wRg8S	5000600004eGEUf	2020-10-20 15:08:00	Closed	2020-10-21 08:16:00	Medium	Problem
0010600001wRg8S	5000600004jCzMH	2020-10-27 11:37:00	Closed	2020-10-27 11:45:00	Medium	Problem
0010600001wRgDS	5000600004eEAva	2020-09-20 17:30:00	Closed	2020-09-21 16:32:00	Medium	Question
0010600001wRgDS	5000600004eEK57	2020-09-22 14:29:00	Closed	2020-09-22 14:33:00	Medium	Problem
0010600001wRgcl	5000600004n1SzQ	2021-01-18 12:00:00	Closed	2021-01-18 12:04:00	Medium	Problem
0010600001wRgcl	5000600004n1TFJ	2021-01-18 12:34:00	Closed	2021-01-18 12:35:00	Medium	Problem
0010600001wRgdG	5000600004jE94U	2020-12-11 13:31:00	Closed	2020-12-11 13:32:00	Medium	Problem

### 6.2.3 Agregación

Agrupamos los diferentes clientes en  $T'$ , ofreciendo un resultado total de 200615, es decir,  $\#U = 200615$ . Así, obtenemos el conjunto  $TU$  con las

especificaciones mencionadas anteriormente. En la Tabla 21 se muestra un extracto de este conjunto.

Tabla 21. Extracto del conjunto TU

	<b>u</b>	<b>r</b>	<b>f</b>	<b>i</b>	<b>d</b>
0	0010600001wReca	339	2	M	0.0
1	0010600001wRenT	196	4	M	0.0
2	0010600001wReue	68	2	M	0.0
3	0010600001wRezt	442	1	M	0.0
4	0010600001wRf4A	199	2	M	25.0
5	0010600001wRf5G	133	1	M	0.0
6	0010600001wRf6k	546	1	M	6.0
7	0010600001wRg8S	407	2	M	17.0
8	0010600001wRgDS	442	2	M	23.0
9	0010600001wRgcl	324	2	M	0.0

Como se puede apreciar, en la evaluación del parámetro importancia, por defecto a la mayoría de los tickets se les asigna un valor igual a Medium. Es un hecho que a primera vista ha llamado la atención y se ha tratado con los responsables de CRM del fabricante de software para que a futuro se pueda mejorar.

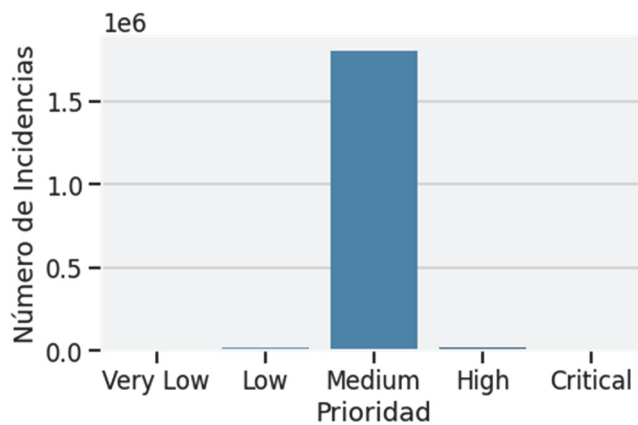


Figura 42. Distribución de incidencias según prioridad

## 6.2.4 Cálculo de las puntuaciones

El conjunto *TU* en esta etapa se utiliza para obtener el conjunto *TRFID* como se explica en la sección anterior. El RFID contiene las variables básicas de este nuevo

modelo. En la Tabla 22, se presenta un extracto de este conjunto para los mismos clientes que se muestran en la Tabla 21.

Tabla 22. Extracto del conjunto TRFID

	<b>u</b>	<b>R</b>	<b>F</b>	<b>I</b>	<b>D</b>
0	0010600001wReca	(M,0.04)	(M,0.009)	(M,0.025)	(L,0.077)
1	0010600001wRenT	(H,-0.022)	(H,-0.007)	(M,0.025)	(L,0.077)
2	0010600001wReue	(VH,-0.079)	(M,0.009)	(M,0.025)	(L,0.077)
3	0010600001wRezt	(M,-0.083)	(L,-0.042)	(M,0.025)	(L,0.077)
4	0010600001wRf4A	(H,-0.029)	(M,0.009)	(M,0.025)	(H,0.119)
5	0010600001wRf5G	(H,0.084)	(L,-0.042)	(M,0.025)	(L,0.077)
6	0010600001wRf6k	(L,0.068)	(L,-0.042)	(M,0.025)	(H,0.026)
7	0010600001wRg8S	(M,-0.039)	(M,0.009)	(M,0.025)	(H,0.062)
8	0010600001wRgDS	(M,-0.083)	(M,0.009)	(M,0.025)	(H,0.094)
9	0010600001wRgcl	(M,0.052)	(M,0.009)	(M,0.025)	(L,0.077)

### 6.2.5 Cálculo de la puntuación global para RFID

En esta fase, hay que obtener la importancia de cada una de las variables del modelo RFID antes de calcular la puntuación global del cliente. Para ello, como se ha mencionado anteriormente, se utilizará el modelo AHP. El experto consultado ha especificado la siguiente matriz utilizando la escala de Saaty (Tabla 1):

$$PW = \begin{bmatrix} & R & F & I & D \\ R & 1 & 5 & 7 & 3 \\ F & 1/5 & 1 & 5 & 1/3 \\ I & 1/7 & 1/5 & 1 & 1/5 \\ D & 1/3 & 3 & 5 & 1 \end{bmatrix}$$

Sólo cuando  $CR \leq 0,10$  (véase la ecuación (9)) se satisfacen los resultados del tipo jerárquico individual y se garantiza la coherencia. En este caso,  $CR = 0,093$  por lo que los resultados son válidos para el modelo.

Las ponderaciones finales calculadas son  $W = \{w_R = 0.548, w_F = 0.145, w_I = 0.051, w_D = 0.256\}$ . Por tanto, el experto ha dado mayor importancia a la recencia de las entradas, seguida de su duración y la frecuencia. La importancia media de su resolución es la menos importante por las razones consideradas anteriormente.

Como se ha mencionado anteriormente, con esta  $W$  obtenemos la puntuación global de RFID para cada cliente. En la Tabla 23 presentamos los resultados para algunos clientes, incluidos los que se muestran en la Tabla 21.

Tabla 23. Puntuación global RFID detallada para algunos clientes

	<b>u</b>	<b>R</b>	<b>F</b>	<b>I</b>	<b>D</b>	<b>RFID</b>
0	0010600001wReca	(M,0.04)	(M,0.009)	(M,0.025)	(L,0.077)	(M, -0.213)
1	0010600001wRenT	(H,-0.022)	(H,-0.007)	(M,0.025)	(L,0.077)	(M, 0.443)
2	0010600001wReue	(VH,-0.079)	(M,0.009)	(M,0.025)	(L,0.077)	(H, -0.183)
3	0010600001wRezt	(M,-0.083)	(L,-0.042)	(M,0.025)	(L,0.077)	(M, -0.433)
4	0010600001wRf4A	(H,-0.029)	(M,0.009)	(M,0.025)	(H,0.119)	(H, -0.181)
5	0010600001wRf5G	(H,0.084)	(L,-0.042)	(M,0.025)	(L,0.077)	(M, 0.167)
6	0010600001wRf6k	(L,0.068)	(L,-0.042)	(M,0.025)	(H,0.026)	(M, -0.399)
7	0010600001wRg8S	(M,-0.039)	(M,0.009)	(M,0.025)	(H,0.062)	(M, 0.249)
8	0010600001wRgDS	(M,-0.083)	(M,0.009)	(M,0.025)	(H,0.094)	(M,0.236)
9	0010600001wRgcI	(M,0.052)	(M,0.009)	(M,0.025)	(L,0.077)	(M,-0.206)
10	0010600001wRgdG	(M,0.021)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,-0.376)
11	0010600001wRgda	(M,-0.085)	(L,-0.042)	(VL,0.035)	(H,0.062)	(M,-0.027)
12	0010600001wRgdk	(M,-0.006)	(H,-0.095)	(M,0.025)	(H,0.077)	(M,0.405)
13	0010600001wRge9	(M,-0.085)	(L,-0.042)	(M,0.025)	(H,0.039)	(M,0.070)
14	0010600001wRgeJ	(H,-0.124)	(L,-0.042)	(M,0.025)	(H,0.039)	(H,-0.404)
15	0010600001wRgeT	(M,0.022)	(M,0.009)	(M,0.025)	(VH,-0.02)	(H,-0.479)
16	0010600001wRhHf	(M,-0.08)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,-0.430)
17	0010600001wRhMg	(M,-0.085)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,-0.432)
18	0010600001wRhIw	(M,0.11)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,-0.326)
19	0010600001wRhmu	(M,-0.046)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,-0.411)

## 6.2.6 Estrategia de recomendación individualizada

La puntuación global del modelo RFID permite cuantificar la atención que debe prestar el Contact Center con estos clientes. A modo de ejemplo, la Tabla 24 muestra los clientes RFID más valiosos para la empresa. Como se puede observar, predominan los que tienen una recencia y una frecuencia muy altas, ya que son las variables con mayor peso en  $W$ . Hay que tener en cuenta que el uso del modelo 2-tupla permite una alta interpretabilidad lingüística, así como una alta precisión en los resultados.

Todos estos clientes deben recibir una atención especial en su interacción con el Contact Center, por ejemplo, el cliente 0010600001wRmKr tiene una puntuación

global  $RFID = (VH, -0.119)$ , lo que le otorga una importancia muy alta para la empresa, con valores de recencia, frecuencia y duración muy altos.

Tabla 24. Puntuación detallada RFID para clientes a priori de especial cuidado

	<b>u</b>	<b>R</b>	<b>F</b>	<b>I</b>	<b>D</b>	<b>RFID</b>
<b>45</b>	0010600001wRiro	(VH,-0.115)	(VH,-0.027)	(M,0.025)	(VH,-0.121)	(VH,-0.200)
<b>75</b>	0010600001wRk0D	(VH,-0.041)	(VH,-0.117)	(M,0.025)	(L,0.077)	(H,0.111)
<b>102</b>	0010600001wRljY	(VH,-0.029)	(VH,-0.018)	(M,0.025)	(H,-0.022)	(VH,-0.382)
<b>104</b>	0010600001wRIIZ	(VH,-0.103)	(VH,-0.027)	(M,0.025)	(H,-0.022)	(VH,-0.375)
<b>111</b>	0010600001wRIrv	(VH,-0.046)	(VH,-0.117)	(M,0.025)	(L,0.077)	(H,0.108)
<b>115</b>	0010600001wRmGE	(VH,-0.006)	(VH,-0.018)	(M,0.025)	(H,-0.002)	(VH,-0.364)
<b>117</b>	0010600001wRmKr	(VH,-0.006)	(VH,-0.07)	(M,0.025)	(VH,-0.012)	(VH,-0.119)
<b>157</b>	0010600001wRnnZ	(VH,-0.068)	(VH,-0.117)	(M,0.025)	(L,0.077)	(H,0.096)
<b>251</b>	0010600001wRtwh	(VH,-0.055)	(VH,-0.091)	(M,0.025)	(L,0.077)	(H,0.107)
<b>315</b>	0010600001wRyhb	(VH,-0.021)	(VH,-0.091)	(M,0.025)	(L,0.077)	(H,0.126)
<b>356</b>	0010600001wS050	(VH,-0.029)	(VH,-0.117)	(M,0.025)	(L,0.077)	(H,0.117)
<b>597</b>	0010600001wSEya	(VH,-0.084)	(VH,-0.039)	(M,0.025)	(VH,-0.045)	(VH,-0.165)
<b>615</b>	0010600001wSFI5	(VH,-0.107)	(VH,-0.01)	(M,0.025)	(H,-0.065)	(VH,-0.435)
<b>624</b>	0010600001wSGZe	(VH,-0.002)	(VH,-0.039)	(M,0.025)	(VH,-0.095)	(VH,-0.133)
<b>635</b>	0010600001wSH1c	(VH,-0.055)	(VH,-0.117)	(M,0.025)	(L,0.077)	(H,0.103)
<b>654</b>	0010600001wSIts	(VH,-0.029)	(VH,-0.117)	(M,0.025)	(VH,-0.095)	(VH,-0.159)
<b>683</b>	0010600001wSJdX	(VH,-0.099)	(VH,-0.091)	(M,0.025)	(VH,-0.063)	(VH,-0.186)
<b>718</b>	0010600001wSKjZ	(VH,-0.099)	(VH,-0.091)	(M,0.025)	(VH,-0.037)	(VH,-0.179)
<b>722</b>	0010600001wSKtj	(VH,-0.025)	(VH,-0.01)	(M,0.025)	(VH,-0.02)	(VH,-0.122)
<b>886</b>	0010600001wSRDN	(VH,-0.084)	(VH,-0.01)	(M,0.025)	(VH,-0.005)	(VH,-0.151)

## 6.2.7 Segmentación de clientes

Como se ha comentado, las variables RFID se expresan en el modelo 2-tupla, lo que permite una fácil interpretación y puede computarse sin pérdida de información. Sin embargo, en esta fase, para seguir el proceso de segmentación convencional, trabajaremos con estas variables convertidas a una escala numérica mediante la función  $\Delta^{-1}$  (Ecuación (2)).

Por tanto, al estar todas las variables en la misma escala, no es necesario ningún proceso de normalización adicional. Igual que en el modelo B2C a continuación aplicaremos un modelo de correlación entre variables, ya que una alta correlación entre ellas indica la inadecuación de utilizar una distancia euclidiana, que es la que

utiliza el algoritmo k-means. La Figura 43 muestra la matriz de correlaciones de Pearson. La mayor correlación se da entre la recencia y frecuencia, con un 0.46, que puede considerarse poco significativo, indicando una correlación moderada.




Figura 43. Matriz de correlación  $\Delta^{-1}(R), \Delta^{-1}(F), \Delta^{-1}(I),$  y  $\Delta^{-1}(D)$

Para este caso, utilizaremos la técnica del codo (Syakur et al., 2018) para determinar el mejor número de clústeres relativos al caso de estudio. Como se puede observar en la Figura 44, no está muy clara la identificación del número de clústeres. Como hemos comentado en la sección 5.2.7, hay que tener en cuenta que es habitual considerar también criterios empresariales en la determinación del clustering final. Es por ello por lo que se puede considerar un número de clústeres de 5 como una solución acertada y que más adelante discutiremos.




Figura 44. Técnica del codo para la selección del número óptimo de clústeres

Una recomendación adicional es utilizar el coeficiente de silueta, definido en el apartado 5.1.7 de la presente memoria, una puntuación más alta, se relaciona con un modelado de grupos bien definido (Rousseeuw, 1987). En nuestro caso, las puntuaciones obtenidas son:

```

from sklearn.metrics import silhouette_score
for n_cluster in range(2, 6):
    kmeans = KMeans(n_clusters=n_cluster, max_iter=1000, init = 'k-means++').fit(newdata_rfidCL2)
    label = kmeans.labels_
    sil_coeff = silhouette_score(newdata_rfidCL2, label, metric='euclidean')
    print("For n_clusters={}, The Silhouette Coefficient is {}".format(n_cluster, sil_coeff))# Correlación entre variables
For n_clusters=2, The Silhouette Coefficient is 0.3552494598468131
For n_clusters=3, The Silhouette Coefficient is 0.34659616339189653
For n_clusters=4, The Silhouette Coefficient is 0.3731206094467046
For n_clusters=5, The Silhouette Coefficient is 0.39629493666106136
    
```

Figura 45. Algoritmo en Python, técnica del coeficiente de silueta

Lo que nos demuestra que la elección a partir de la técnica del codo de 5 clústeres no está mal encaminada, aunque, por otro lado, la lógica del negocio nos lleva a confirmar también este número.

Una vez aplicado el algoritmo k-means, utilizando la distancia euclidiana (véase la ecuación (20)), los resultados se muestran en la Tabla 25.

Tabla 25. Resultados del algoritmo k-means

Cluster c	R vc1	F vc2	I vc3	D vc4	Number of Customers
1	0.20895552	0.30738694	0.52200707	0.32707802	27304
2	0.74247949	0.79663542	0.4939548	0.82391703	39467
3	0.25689749	0.35895303	0.39680612	0.83958694	50637
4	0.65879637	0.71779173	0.52003818	0.32705852	58236
5	0.70023622	0.20816033	0.51924676	0.41005369	24973

## 6.2.8 Estrategia de recomendación grupal

Para obtener una mejor comprensión de los clústeres, los pasaremos a un dominio 2-tupla, esto se consigue aplicando la correspondiente función  $\Delta$  (Ecuación (1)) a los centroides, ver Tabla 26.

Tabla 26. Resultados del algoritmo k-means expresados en el modelo 2-tupla

Cluster c	R vc1	F vc2	I vc3	D vc4
1	(L, -0.041)	(L, 0.057)	(M, 0.092)	(L, 0.077)
2	(H, -0.008)	(H, 0.047)	(M, -0.006)	(H, 0.074)
3	(L, 0.007)	(L, 0.109)	(M, -0.103)	(H, 0.090)
4	(H, -0.091)	(H, -0.032)	(M, 0.020)	(L, 0.077)
5	(H, -0.050)	(L, -0.042)	(M, 0.019)	(M, -0.090)

La tabla 27 muestra las estrategias de recomendación por perfil de partner, respondiendo cada agrupación a un perfil con la distribución de segmentos observada en las Tablas 25 y 26. Como hemos comentado en el modelo B2C, las métricas de recomendación que se utilizarán en las futuras interacciones bidireccionales entre el cliente y la marca deberían basarse en ofrecer la máxima calidad de servicio con el objetivo de obtener la máxima satisfacción del cliente (Andrade et al., 2020; van Dun et al., 2011; Zeithaml & Berry, 1988), en el caso objeto de este estudio el cliente corresponde con un perfil de partner tecnológico. Constatamos que, con los resultados obtenidos, el modelo B2C puede ser aplicado a una relación B2B.

Tabla 27. Estrategia de recomendación para cada clúster

Clúster	Interacción	Estrategia de recomendación (B2B)
1	<i>Automática / Perosonalizada</i>	<p><b>Descripción:</b> A priori se trata de partner consolidados, no tienen incidencias recurrentes, tampoco frecuentes y duración baja, la importancia está de acuerdo con la media. Corresponde con un perfil de partner que está acostumbrado a resolver las incidencias directamente con sus clientes, sin necesidad de contar con el fabricante. O, por el contrario, se trata de un partner de reciente incorporación que necesita dar sus primeros pasos para arrancar y, por tanto, con alto peligro de poder abandonar.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones con el Contact Center se recomienda utilizar bot (faqs, chat, voz), en el caso de requerirse personalización porque así lo demande el partner, se podría pasar de un canal automático a uno personalizado e incluso especializado.</p> <p><b>Acciones:</b> Se propone para este tipo de partner consolidado premiar la fidelidad a la marca mejorando el cambio de categoría interna de partner y además aportándole nuevos clientes (a mayor categoría, más margen comercial). Y para el partner recién incorporado planes de formación para que pueda elevar la confianza en la marca y crecer de forma conjunta, antes de que se produzca el abandono.</p>
2	<i>Personalizada</i>	<p><b>Descripción:</b> Partner tecnológico con gran cartera de clientes, y que por consiguiente las interacciones con el Contact Center son superiores a la media, corresponden con una categoría de partner alta.</p>

		<p><b>Interacciones futuras:</b> En siguientes interacciones del partner con el Contact Center se recomienda personalizar la comunicación mediante agentes especializados y atender de forma rápida cualquier interacción, ya que la duración en la resolución de incidencias es alta.</p> <p><b>Acciones:</b> Se recomienda escuchar al partner, y proponer procesos de formación especializada de forma que puedan ser más autónomos en el proceso de resolución de incidencias con su cartera de clientes.</p>
3	<i>Automática / Personalizada</i>	<p><b>Descripción:</b> A priori se trata de partner poco problemáticos, no tienen incidencias recurrentes y tampoco frecuentes, pero las incidencias que han tenido son de elevada duración. Suele tratarse de partner que tuvieron problemas iniciales esporádicos y que tras la formación pueden resolver sus incidencias. O bien, partner nuevos, con primeras implantaciones e incidencias de alta duración, es importante cuidar a estos partner nuevos ya que pueden tener una alta tasa de abandono.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del partner con el Contact Center se recomienda utilizar bot (faqs, chat, voz), en el caso de requerirse personalización porque así lo demande el partner, se podría pasar de un canal automático a uno personalizado e incluso especializado. Intentar que el servicio sea ejecutivo y rápido en la resolución de problemas, aminorando así la duración de futuras incidencias. Especial cuidado con los partner nuevos, ya que necesitan pasar por un proceso de formación para que las incidencias iniciales no se repitan.</p> <p><b>Acciones:</b> Para los partner consolidados, se propone premiar la fidelidad a la marca mejorando el cambio de categoría interna de partner y además aportándole nuevos clientes (a mayor categoría, más margen comercial). Y al partner nuevo, ayudarle en crecer para intentar que no abandone en la fase de arranque que suele ser la más complicada.</p>
4	<i>Automática</i>	<p><b>Descripción:</b> Se trata de partner con incidencias frecuentes y recurrentes. Si bien la duración en la resolución fue rápida y sin importancia. El perfil corresponde con partner con una base instalada de clientes importante y que utiliza el Contact Center del fabricante para resolver problemas puntuales.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del partner con el Contact Center se recomienda utilizar una comunicación automática, si bien a requerimiento del partner, personalizar la comunicación mediante agentes especializados, teniendo en cuenta que sus interacciones son breves, precisan de especialización.</p> <p><b>Acciones:</b> Se proponen acciones que tiendan a la especialización del partner, de forma que pueda resolver esas breves incidencias de forma autónoma. Por otro lado, para partner asentados con base instalada importante, premiar la fidelidad con el cambio de categoría y la aportación de base instalada de clientes.</p>
5	<i>Automática / Personalizada</i>	<p><b>Descripción:</b> A priori se trata de partner de reciente incorporación al canal, que tuvieron incidencias recientes, si bien, la frecuencia de dichas incidencias es baja, aunque la duración en la resolución ha sido moderada.</p> <p><b>Interacciones futuras:</b> En siguientes interacciones del partner con el Contact Center se recomienda personalizar la comunicación mediante agentes generalistas y si es necesario especializados.</p> <p><b>Acciones:</b> Se proponen acciones de formación y especialización del partner personalizadas, por tratarse principalmente de nuevos partner.</p>

La Tabla 27 muestra de forma clara la distribución de perfiles de partner, y encajan con la problemática que he ido trabajando como responsable de canal en un fabricante de software de primer nivel. Por un lado, partner consolidados que apenas necesitan del soporte del fabricante para realizar los procesos de implantación en su cartera de clientes y que precisan de formaciones especializadas para temas muy concretos. Y, por otro lado, partner que no han llegado a consolidarse, que precisan de equipo de consultores especializados y el fabricante necesita realizar planes de formación especializados para cubrir las necesidades del partner y por supuesto del mercado.

En un modelo B2B como en este caso, la puntuación RFID es un indicador de la relación entre marca y partner, mayor valoración RFID indica una mayor relación entre ambos, mayor número de clientes y en consecuencia mayor número de interacciones. Por el contrario, en modelos B2C si el índice de puntuación RFID es elevado es un indicador importante de la posible tasa de abandono. Este caso, es inverso. En la Tabla 28, podemos apreciar la tasa de abandono en relación con el clúster de partner definido. Las tasas de abandono mayores corresponden con partner con valores bajos de interacciones con el Contact Center, son partner poco consolidados en el canal de distribución y que no les ha dado tiempo a desarrollarse (clústeres 1 y 3). El resto de los clústeres (2, 4 y 5) corresponden con clientes cuyas incidencias son recientes y frecuencia de alta a moderada, corresponden con partner consolidados en el canal (clústeres 2 y 4), o bien partner de reciente incorporación, clúster 5.

Tabla 28. Clientes en cada clúster, y tasa de abandono por clúster

Cluster	R	F	I	D	Number	Number	Ratio
c	vc1	vc2	vc3	vc4	of Customers	of Churn	of Churn
1	(L, -0.041)	(L, 0.057)	(M, 0.092)	(L, 0.077)	27304	662	2,42%
2	(H, -0.008)	(H, 0.047)	(M, -0.006)	(H, 0.074)	39467	299	0,76%
3	(L, 0.007)	(L, 0.109)	(M, -0.103)	(H, 0.090)	50637	858	1,69%
4	(H, -0.091)	(H, -0.032)	(M, 0.020)	(L, 0.077)	58236	124	0,21%
5	(H, -0.050)	(L, -0.042)	(M, 0.019)	(M, -0.090)	24973	179	0,72%

## 6.2.9 Conclusiones

Los datos que hemos trabajado en los apartados del punto anterior proceden de una empresa fabricante de soluciones software, como conclusiones a este estudio aplicado a dicha empresa, y analizando el volumen de datos, se puede comprobar lo que advertíamos en apartados anteriores, la importancia de las incidencias por defecto se marca en la variable lingüística “Medium”, si bien, el resto de criterios asociados a esta clasificación de la importancia hacen que se constate que este atributo no está suficientemente explotado.

El número de incidencias anuales registradas son un indicador de la importancia del Contact Center en la relación entre fabricante y partner. Se han clasificado los partner de acuerdo con la clusterización propuesta por k-means, y aunque se ha comprobado que tanto la técnica del codo y el coeficiente de silueta no son definitivos a la hora de ofrecer una explicación para los clústeres, sí existe una coincidencia entre el número de perfiles propuesto por ambos métodos y lo que negocio propone en la gestión de la relación entre fabricante y partner.

Por otro lado, el uso del nuevo modelo RFID tanto en sectores B2C, caso visto en el apartado 6.1 de la presente memoria, como en sectores B2B visto en este apartado, es consistente y puede aportar un factor importante a la hora de clasificar a los clientes desde el punto de vista de sus relaciones con el Contact Center. Los agentes tienen a su disposición una metodología de trabajo que les permitirá gestionar de forma

adecuada a los clientes, anticipándose a sus necesidades y orientándoles en la prestación de un mejor servicio.

El modelo se puede extender y agregar, como ya se ha comentado, a otras valoraciones que el fabricante puede hacer del partner, por ejemplo, a través de su historial de compra, proporcionando de esta forma una valoración integral del cliente.

La metodología de trabajo que hemos utilizado en este modelo B2B y en el modelo B2C del caso de negocio visto en el apartado 6.1, permite disponer de una clasificación individual de los clientes de acuerdo con el modelo RFID, para ello, se ha procedido a adaptar y extender el modelo RFM mediante el modelo 2-tupla, además la metodología AHP ha ayudado a proporcionar peso a cada una de las variables que componen el modelo RFID y así poder obtener un score global de cada cliente. En paralelo, se ha dotado al modelo de un argumento adicional, es decir, la posibilidad de clasificar a los clientes utilizando algoritmos de clasificación como k-means.

El objetivo primero es el de disponer de una ficha de cliente y una valoración personalizada de los valores de recencia, frecuencia, importancia y duración de las interacciones, por tanto, el personal del Contact Center dispone de un conocimiento profundo y amplio de cada partner.

A través de la clasificación individual de cada partner, se ayudará al personal del Contact Center a cuantificar el cuidado con que debe gestionarse de forma individual la atención de cada cliente atendiendo a su clasificación, ver Tablas 23 y 24. El agente encargado de gestionar esa interacción reconoce al cliente y, por tanto, pueden establecerse recomendaciones basadas en su historial de relación con la marca, no sólo por el valor facturado, RFM, también por el histórico de la atención recibida RFID.

Y, por otro lado, un segundo objetivo es el de realizar un proceso de segmentación de los partner que componen el canal de venta, para ello se ha utilizado

k-means de forma que a través de este resultado, somos capaces de aplicar acciones grupales por perfiles de partner, identificando distintas categorías de partner; partner nuevos, (clúster 5); partner con los que hay que tener cierto cuidado, aunque no muy alta, sí con mayor tasa de abandono (clúster 1 y 3); partner asentados, con poca problemática, el fabricante puede proporcionarles más clientes para ayudarles a crecer (clúster 1 a 4); y partner asentados con baja tasa de abandono (clúster 2, 4 y 5).

Para estos casos de segmentación, el centro se ha situado en identificar, analizar las interacciones futuras por tipología de partner y anticiparse con acciones tendentes a mejorar los procesos de formación y de crecimiento del partner, si éste pasa a ser suficientemente autónomo, podrá proporcionar un servicio de calidad y autogestionado a su cartera de clientes. Es labor del fabricante detectar los déficits de cada partner y proponer planes personalizados de formación que al principio de la relación pueden ser generalistas, pero que tenderán a la especialización a medida que el partner va creciendo y desarrollando su negocio en relación con la marca.

Para los partner más activos y que son capaces de proporcionar un servicio autogestionado a su cartera de clientes, el fabricante adoptaría medidas tendentes a hacerles crecer, proporcionándoles apoyo especializado y desarrollando planes de formación a medida.

Por último, se han proporcionado unas recomendaciones acerca de las acciones que tienen que ver con la formación, la personalización en la interacción, la gestión de categorías de partner (a mayor categoría más margen comercial) y la inyección de nuevos clientes.

A criterio del responsable del Contact Center queda utilizar un modelo individualizado, clusterizado, o ambos. Si además dotamos al sistema de un modelo de IA, que veremos en siguientes secciones, se puede decir que el Contact Center puede pasar a ser el centro de la transformación digital de las compañías.

## 7. Aplicación práctica del modelo VIUE, priorización y personalización en la interacción cliente y marca

### 7.1 Aplicación del modelo VIUE en un entorno B2B

En esta sección, presentamos un ejemplo de aplicación del nuevo modelo VIUE, desarrollado en la sección 5.2 de la presente memoria, en esta ocasión se ha aplicado a una empresa distribuidora de licencias de software, que colabora con clientes en un modelo de negocio B2B. Como hemos comentado en la sección anterior, aunque utilizaremos en muchas ocasiones el término cliente, el perfil corresponde con el de partner tecnológico que distribuye e implanta los productos del fabricante de software. En el resto de las secciones, seguiremos el modelo presentado en la Figura 26 de la sección 5.2 y analizaremos la viabilidad del modelo propuesto.

#### 7.1.1 Obtención de datos

La información de los tickets es gestionada en un CRM operativo, en este caso Salesforce, su estructura está basada en el modelo presentado en la Figura 38.

Se dispone del conjunto de tickets  $T$ , ver apartado 5.2, correspondiente con las interacciones en tiempo real entre partner y fabricante, este conjunto de tickets se gestiona desde la herramienta interna CRM. Por otro lado, para cada cliente disponemos de su valoración atendiendo al histórico de las relaciones con el Contact Center, modelo RFID.

La interacción entre partner y fabricante se inicia a través de un bot, este puede ser telefónico o bien chat. El bot es el encargado de hacer una valoración inicial de factores como el emocional, el impacto y la urgencia de la interacción.

Para el factor emocional, se hace un análisis de sentimiento de la interacción, en cualquiera de los canales de comunicación (Basiri et al., 2021; R. S. Kumar et al.,

2021), con ello obtenemos una puntuación en un dominio lingüístico  $S = \{low, moderate, high\}$ .




Figura 46. # incidencias / mes en el año 2020

El análisis del departamento de calidad del fabricante de software determina en tiempo real mediante un programa desarrollado a medida y atendiendo a ciertos KPIs propios del negocio, el grado de impacto y urgencia de cualquier incidencia, para ello se utiliza la metodología ITIL (Bartolini & Sallé, 2004; Marrone & Kolbe, 2011), de esta forma se establece una escala lingüística  $\bar{S} = \{very\ low, low, moderate, high, very\ high\}$  asociada al impacto y a la urgencia. En el tipo de negocio que estamos analizando, el impacto versa sobre la cantidad de personas (y la importancia de estas) afectadas por la incidencia.

Por ejemplo, una caída de un sistema Cloud origina un impacto muy alto con gran número de clientes afectados y fuertes efectos en los procesos de negocio. La urgencia versa sobre la medida de cuánto tiempo pasará hasta que el impacto en el negocio sea significativo; para este servicio origina una urgencia también muy alta, con pérdidas económicas muy elevadas, debido a los SLAs y las penalizaciones correspondientes, además de la pérdida de confianza por parte del cliente / partner.

## 7.1.2 Selección del dominio CBTL

En este momento será necesario seleccionar el dominio CBTL, tal y como vimos en el apartado 5.2.2. De esta forma, se puede obtener una primera aproximación al modelo lingüístico 2-tupla, con las valoraciones obtenidas para el valor del cliente a partir del modelo RFID, y los valores lingüísticos en formato 2-tupla de los otros tres criterios, emocional, impacto y urgencia. Se puede ver a través del siguiente ejemplo, se han seleccionado un conjunto de interacciones en el mismo rango de tiempo y que corresponden con clientes pertenecientes a los 5 clústeres definidos en la sección 6.2.7, total 25 clientes, a continuación, se pueden observar los resultados en las Tablas 29 y 30.

Tabla 29. Valoración del cliente, RFID

Ticket_id	u	R	F	I	D	V = RFID
91	0010600001wRIM0	(L,0.098)	(L,-0.042)	(M,0.025)	(L,0.077)	(L,0.120)
113	0010600001wRlth	(L,-0.073)	(L,-0.042)	(M,0.025)	(L,0.077)	(L,0.027)
135	0010600001wRmUk	(L,0.041)	(L,-0.042)	(M,0.025)	(L,0.077)	(L,0.089)
136	0010600001wRmWM	(L,0.041)	(L,-0.042)	(M,0.025)	(L,0.077)	(L,0.089)
197	0010600001wRqQO	(L,0.042)	(L,-0.042)	(M,0.025)	(L,0.077)	(L,0.090)
33	0010600001wRiEY	(VH,-0.051)	(H,-0.095)	(M,0.025)	(VH,-0.041)	(VH,-0.299)
45	0010600001wRiro	(VH,-0.115)	(VH,-0.027)	(M,0.025)	(VH,-0.121)	(VH,-0.200)
71	0010600001wRjqc	(VH,-0.011)	(H,0.099)	(M,0.025)	(VH,-0.113)	(VH,-0.267)
102	0010600001wRljY	(VH,-0.029)	(VH,-0.018)	(M,0.025)	(H,-0.022)	(VH,-0.382)
104	0010600001wRIIZ	(VH,-0.103)	(VH,-0.027)	(M,0.025)	(H,-0.022)	(VH,-0.424)
6	0010600001wRf6k	(L,0.068)	(L,-0.042)	(M,0.025)	(H,0.026)	(M, -0.398)
65	0010600001wRjYB	(L,0.041)	(L,-0.042)	(M,0.025)	(H,-0.022)	(M,-0.425)
214	0010600001wRrLB	(L,0.097)	(L,-0.042)	(M,0.025)	(H,-0.022)	(M,-0.394)
310	0010600001wRyOF	(L,0.041)	(L,-0.042)	(M,0.025)	(H,-0.065)	(M,-0.436)
317	0010600001wRyni	(L,0.041)	(L,-0.042)	(M,0.025)	(H,-0.065)	(M,-0.436)
1	0010600001wRenT	(H,-0.022)	(H,-0.007)	(M,0.025)	(L,0.077)	(M,0.445)
38	0010600001wRiOQ	(H,-0.028)	(H,-0.095)	(M,0.025)	(L,0.077)	(M,0.429)
44	0010600001wRipv	(VH,-0.076)	(H,0.055)	(M,0.025)	(L,0.077)	(H,-0.028)
47	0010600001wRish	(H,-0.004)	(H,-0.007)	(M,0.025)	(L,0.077)	(M,0.454)
56	0010600001wRiyz	(H,-0.007)	(VH,-0.117)	(M,0.025)	(L,0.077)	(H,-0.418)
5	0010600001wRf5G	(H,0.084)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,0.498)
34	0010600001wRiIG	(H,-0.032)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,0.434)
35	0010600001wRiIV	(H,-0.108)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,0.392)
41	0010600001wRinp	(VH,-0.011)	(L,-0.042)	(M,0.025)	(L,0.077)	(H,-0.007)
54	0010600001wRiwj	(H,-0.102)	(L,-0.042)	(M,0.025)	(L,0.077)	(M,0.396)

Tabla 30. Matriz de interacciones VIUE

Ticket_id	u	V = RFID	I	U	E
91	0010600001wRIM0	(L,0.120)	VL	VH	M
113	0010600001wRlth	(L,0.027)	L	VL	L
135	0010600001wRmUk	(L,0.089)	M	H	M
136	0010600001wRmWM	(L,0.089)	VH	VH	L
197	0010600001wRqQO	(L,0.090)	VL	H	H
33	0010600001wRiEY	(VH,-0.299)	H	VL	L
45	0010600001wRiro	(VH,-0.200)	M	L	L
71	0010600001wRjqc	(VH,-0.267)	H	M	H
102	0010600001wRljY	(VH,-0.382)	M	VH	H
104	0010600001wRllZ	(VH,-0.424)	M	VH	H
6	0010600001wRf6k	(M, -0.398)	VL	VH	L
65	0010600001wRjYB	(M,-0.425)	H	L	L
214	0010600001wRrLB	(M,-0.394)	L	L	H
310	0010600001wRyOF	(M,-0.436)	M	L	H
317	0010600001wRyni	(M,-0.436)	VH	M	H
1	0010600001wRenT	(M,0.445)	H	M	M
38	0010600001wRiOQ	(M,0.429)	VL	H	L
44	0010600001wRipv	(H,-0,028)	M	VL	L
47	0010600001wRish	(M,0.454)	L	H	L
56	0010600001wRiyz	(H,-0.418)	VH	M	L
5	0010600001wRf5G	(M,0.498)	VL	M	M
34	0010600001wRiIG	(M,0.434)	L	VL	M
35	0010600001wRiIV	(M,0.392)	VL	VL	H
41	0010600001wRinp	(H,-0.007)	M	M	H
54	0010600001wRiwj	(M,0.396)	VL	M	M

En la Tabla 29 disponemos de la valoración de clientes según el modelo RFID, y en la Tabla 30 la valoración del resto de criterios de acuerdo con las consideraciones comentadas anteriormente.

### 7.1.3 Cálculo de las puntuaciones

Los criterios valor del cliente, impacto y urgencia están representados bajo un dominio lingüístico  $S5$ , el criterio emoción está definido en un dominio lingüístico  $S3$ ,  $T_{SS}: S \rightarrow F(\bar{S})$ . Se aplica la transformación de dominio de  $S3$  a  $S5$  según la ecuación (14), sección 4.4 (Figuras 10, 11 y 12) y sección 5.2.3 (Figura 27). Obteniendo la siguiente valoración,

Tabla 31. Valoración VIUE

Ticket_id	u	V = RFID	I	U	E
91	0010600001wRIM0	(L,0.120)	VL	VH	M
113	0010600001wRlth	(L,0.027)	L	VL	(L,0.33)
135	0010600001wRmUk	(L,0.089)	M	H	M
136	0010600001wRmWM	(L,0.089)	VH	VH	(L,0.33)
197	0010600001wRqQO	(L,0.090)	VL	H	(H,0.33)
33	0010600001wRiEY	(VH,-0.299)	H	VL	(L,0.33)
45	0010600001wRiro	(VH,-0.200)	M	L	(L,0.33)
71	0010600001wRjqc	(VH,-0.267)	H	M	(H,0.33)
102	0010600001wRljY	(VH,-0.382)	M	VH	(H,0.33)
104	0010600001wRllZ	(VH,-0.424)	M	VH	(H,0.33)
6	0010600001wRf6k	(M, -0.398)	VL	VH	(L,0.33)
65	0010600001wRjYB	(M,-0.425)	H	L	(L,0.33)
214	0010600001wRrLB	(M,-0.394)	L	L	(H,0.33)
310	0010600001wRyOF	(M,-0.436)	M	L	(H,0.33)
317	0010600001wRyni	(M,-0.436)	VH	M	(H,0.33)
1	0010600001wRenT	(M,0.445)	H	M	M
38	0010600001wRiOQ	(M,0.429)	VL	H	(L,0.33)
44	0010600001wRipv	(H,-0,028)	M	VL	(L,0.33)
47	0010600001wRish	(M,0.454)	L	H	(L,0.33)
56	0010600001wRiyz	(H,-0.418)	VH	M	(L,0.33)
5	0010600001wRf5G	(M,0.498)	VL	M	M
34	0010600001wRiIG	(M,0.434)	L	VL	M
35	0010600001wRiIV	(M,0.392)	VL	VL	(H,0.33)
41	0010600001wRinp	(H,-0.007)	M	M	(H,0.33)
54	0010600001wRiwj	(M,0.396)	VL	M	M

#### 7.1.4 Cálculo de la puntuación global para VIUE

En esta fase, hay que obtener la importancia de cada una de las características del modelo VIUE antes de calcular la puntuación global de la interacción. Para ello, como se ha mencionado anteriormente, se utilizará el modelo AHP.

El experto consultado ha especificado la siguiente matriz utilizando la escala de Saaty (Tabla 1):

$$PW = \begin{bmatrix} & V & I & U & E \\ V & 1 & 1/3 & 1/3 & 3 \\ I & 3 & 1 & 1 & 5 \\ U & 3 & 1 & 1 & 5 \\ E & 1/3 & 1/5 & 1/5 & 1 \end{bmatrix}$$

Sólo cuando  $CR \leq 0,10$  (véase la ecuación (9)) se satisfacen los resultados del tipo jerárquico individual y se garantiza la coherencia. En este caso,  $CR = 0,016$  por lo que los resultados son válidos para el modelo.

Las ponderaciones finales calculadas son  $W = \{w_V = 0.153, w_I = 0.389, w_U = 0.389, w_E = 0.069\}$ . Por tanto, el experto ha dado mayor relevancia al impacto de las incidencias, seguido de la urgencia y del carácter emocional de la interacción. Es cierto, que en modelos B2B es importante el carácter emocional de la interacción, pero no tanto como en modelos B2C. Ya que las relaciones en modelos B2B son a largo plazo, el compromiso entre fabricante y distribuidor / implantador de software es duradero, no cortoplacista. La apuesta que hace un partner para formar a su personal y crecer de forma conjunta con el fabricante es muy alta, el modelo de negocio está basado en los productos del fabricante y una incidencia con valoración emocional alta, no debe ser un factor determinante en la priorización de dicha interacción. En la Tabla 32 se pueden ver las puntuaciones globales del modelo VIUE,

Tabla 32. Puntuación global VIUE detallada para algunos clientes

Ticket_ID	u	V = RFID	I	U	E	P = VIUE
91	0010600001wRlM0	(L,0.120)	VL	VH	M	(L,-0.135)
113	0010600001wRlth	(L,0.027)	L	VL	(L,0.33)	(L,-0.362)
135	0010600001wRmUk	(L,0.089)	M	H	M	(M,0.249)
136	0010600001wRmWM	(L,0.089)	VH	VH	(L,0.33)	(H,0.370)
197	0010600001wRqQO	(L,0.090)	VL	H	(H,0.33)	(L,-0.437)
33	0010600001wRiEY	(VH,-0.299)	H	VL	(L,0.33)	(L,-0.174)
45	0010600001wRiro	(VH,-0.200)	M	L	(L,0.33)	(M,-0.159)
71	0010600001wRjqc	(VH,-0.267)	H	M	(H,0.33)	(H,-0.254)
102	0010600001wRljY	(VH,-0.382)	M	VH	(H,0.33)	(H,0.118)
104	0010600001wRlIZ	(VH,-0.424)	M	VH	(H,0.33)	(H,0.111)
6	0010600001wRf6k	(M,-0.398)	VL	VH	(L,0.33)	(M,-0.107)
65	0010600001wRjYB	(M,-0.425)	H	L	(L,0.33)	(M,-0.111)
214	0010600001wRrLB	(M,-0.394)	L	L	(H,0.33)	(L,0.253)

310	0010600001wRyOF	(M,-0.436)	M	L	(H,0.33)	(M,-0.364)
317	0010600001wRyni	(M,-0.436)	VH	M	(H,0.33)	(H,-0.198)
1	0010600001wRenT	(M,0.445)	H	M	M	(M,0.457)
38	0010600001wRiOQ	(M,0.429)	VL	H	(L,0.33)	(L,0.369)
44	0010600001wRipv	(H,-0.028)	M	VL	(L,0.33)	(L,0.325)
47	0010600001wRish	(M,0.454)	L	H	(L,0.33)	(M,0.024)
56	0010600001wRiyz	(H,-0.418)	VH	M	(L,0.33)	(H,-0.179)
5	0010600001wRf5G	(M,0.498)	VL	M	M	(L,0.299)
34	0010600001wRiIG	(M,0.434)	L	VL	M	(L,-0.100)
35	0010600001wRiIV	(M,0.392)	VL	VL	(H,0.33)	(L,-0.404)
41	0010600001wRinp	(H,-0.007)	M	M	(H,0.33)	(M,0.244)
54	0010600001wRiwj	(M,0.396)	VL	M	M	(L,0.283)

### 7.1.5 Priorización de Tickets

En el caso de uso planteado, se definen unos severos SLA con cada partner, los tiempos de respuesta y solución de las incidencias son críticos, por esta razón, aplicaremos el modelo VIUE extendido. Así, una vez determinado el valor de la prioridad con las fases descritas anteriormente, realizaremos una reordenación de las interacciones. Para ello, tendremos en cuenta los siguientes criterios: prioridad definida obtenida del modelo VIUE, tiempo de espera y la carga de trabajo del equipo de agentes asignados a resolver la incidencia, ya que estos, para el caso que nos ocupa, tienen asignadas tareas adicionales a la atención de incidencias.

Los pasos que se van a seguir son los siguientes:

- En primer lugar, en la Tabla 33 mostramos cómo quedan los tickets ordenados por prioridad en la gestión de la incidencia aplicando VIUE, y posteriormente procedemos a realizar una nueva reordenación atendiendo a los criterios expresados en el párrafo anterior.
- En segundo lugar, se obtiene la puntuación extendida VIUE, Tabla 34, atendiendo a la prioridad inicial (VIUE), tiempo de espera y carga de trabajo del Contact Center.

- En tercer lugar, se obtienen las valoraciones del conjunto extendido VIUE en 2-tupla, ver Tabla 35.
- Por último, obtendríamos la valoración global, Tabla 36, y por tanto la prioridad final y las recomendaciones de personalización aplicando AHP.

Tabla 33. Puntuación global ordenada VIUE, detallada para algunos clientes

Ticket_id	u	V = RFID	I	U	E	P = VIUE
136	0010600001wRmWM	(L,0.089)	VH	VH	(L,0.33)	(H,0.370)
102	0010600001wRljY	(VH,-0.382)	M	VH	(H,0.33)	(H,0.118)
104	0010600001wRllZ	(VH,-0.424)	M	VH	(H,0.33)	(H,0.111)
56	0010600001wRiyz	(H,-0.418)	VH	M	(L,0.33)	(H,-0.179)
317	0010600001wRyni	(M,-0.436)	VH	M	(H,0.33)	(H,-0.198)
71	0010600001wRjqc	(VH,-0.267)	H	M	(H,0.33)	(H,-0.254)
1	0010600001wRenT	(M,0.445)	H	M	M	(M,0.457)
135	0010600001wRmUk	(L,0.089)	M	H	M	(M,0.249)
41	0010600001wRinp	(H,-0.007)	M	M	(H,0.33)	(M,0.244)
47	0010600001wRish	(M,0.454)	L	H	(L,0.33)	(M,0.024)
6	0010600001wRf6k	(M,-0.398)	VL	VH	(L,0.33)	(M,-0.107)
65	0010600001wRjYB	(M,-0.425)	H	L	(L,0.33)	(M,-0.111)
45	0010600001wRiro	(VH,-0.200)	M	L	(L,0.33)	(M,-0.159)
310	0010600001wRyOF	(M,-0.436)	M	L	(H,0.33)	(M,-0.364)
38	0010600001wRiOQ	(M,0.429)	VL	H	(L,0.33)	(L,0.369)
44	0010600001wRipv	(H,-0.028)	M	VL	(L,0.33)	(L,0.325)
5	0010600001wRf5G	(M,0.498)	VL	M	M	(L,0.299)
54	0010600001wRiwj	(M,0.396)	VL	M	M	(L,0.283)
214	0010600001wRrLB	(M,-0.394)	L	L	(H,0.33)	(L,0.253)
34	0010600001wRiIG	(M,0.434)	L	VL	M	(L,-0.100)
91	0010600001wRIM0	(L,0.120)	VL	VH	M	(L,-0.135)
33	0010600001wRiEY	(VH,-0.299)	H	VL	(L,0.33)	(L,-0.174)
113	0010600001wRlth	(L,0.027)	L	VL	(L,0.33)	(L,-0.362)
35	0010600001wRiIV	(M,0.392)	VL	VL	(H,0.33)	(L,-0.404)
197	0010600001wRqQO	(L,0.090)	VL	H	(H,0.33)	(L,-0.437)

En este caso, la prioridad  $P = VIUE$  está en un dominio difuso  $F(\bar{S})$ ,  $\bar{S} = \{very\ low, low, moderate, high, very\ high\}$ ; tiempo de espera ( $T$ ) y carga de trabajo ( $C$ ) están en un dominio numérico  $T_{NS}: [0,1] \rightarrow F(\bar{S})$ , aplicaremos por tanto la Ecuación (10), de la sección 4.4.

Es necesario indicar que el tiempo de espera, para el caso que nos ocupa, está directamente relacionado con el SLA, en este modelo se ha considerado que las interacciones no pueden estar en espera un tiempo superior a un 80% del valor del SLA, que es el tiempo de atención comprometido con cada partner. En el momento que una interacción supera el 80% del valor de SLA pasa a ser prioritaria.

El responsable de negocio del Contact Center ha definido el valor máximo de SLA para el tiempo de espera en 20 minutos, y la carga del Contact Center por área de negocio estará entre un 20 – 100 % de dedicación. Teniendo en cuenta estas consideraciones las interacciones recogidas en el CRM tienen la siguiente información:

Tabla 34. Valoración VIUE extendida

<b>Ticket_id</b>	<b>u</b>	<b>P = VIUE</b>	<b>T</b>	<b>C</b>
136	0010600001wRmWM	(H,0.370)	6	66
102	0010600001wRljY	(H,0.118)	1	37
104	0010600001wRllZ	(H,0.111)	19	76
56	0010600001wRiyz	(H,-0.179)	6	62
317	0010600001wRyni	(H,-0.198)	16	22
71	0010600001wRjqc	(H,-0.254)	16	72
1	0010600001wRenT	(M,0.457)	16	96
135	0010600001wRmUk	(M,0.249)	19	88
41	0010600001wRinp	(M,0.244)	13	29
47	0010600001wRish	(M,0.024)	5	85
6	0010600001wRf6k	(M,-0.107)	7	20
65	0010600001wRjYB	(M,-0.111)	1	22
45	0010600001wRiro	(M,-0.159)	14	41
310	0010600001wRyOF	(M,-0.364)	4	81
38	0010600001wRiOQ	(L,0.369)	20	31
44	0010600001wRipv	(L,0.325)	16	39
5	0010600001wRf5G	(L,0.299)	2	60
54	0010600001wRiwj	(L,0.283)	19	26
214	0010600001wRrLB	(L,0.253)	0	41
34	0010600001wRiIG	(L,-0.100)	8	94
91	0010600001wRIM0	(L,-0.135)	18	76
33	0010600001wRiEY	(L,-0.174)	4	94
113	0010600001wRlth	(L,-0.362)	9	66
35	0010600001wRiIV	(L,-0.404)	14	28
197	0010600001wRqQO	(L,-0.437)	0	91

A continuación, unificamos la información a un dominio CBTL en S5, y se ha procedido a transformar el valor de carga con la función  $neg(\cdot)$  (Ecuación (3)), menor posibilidad de atención a mayor carga de trabajo, o lo que es lo mismo, mayor capacidad de respuesta a menor carga de trabajo, obteniéndose los siguientes resultados:

Tabla 35. Valoración VIUE extendida, 2-tupla

Ticket_id	u	P = VIUE	T	C
136	0010600001wRmWM	(H,0.370)	(L,0.05)	(M,-0.075)
102	0010600001wRljY	(H,0.118)	(VL,0.05)	(H,0.037)
104	0010600001wRllZ	(H,0.111)	(VH,-0.05)	(L,0.05)
56	0010600001wRiyz	(H,-0.179)	(L,0.05)	(M,-0.025)
317	0010600001wRyni	(H,-0.198)	(H,0.05)	(VH,-0.025)
71	0010600001wRjqc	(H,-0.254)	(H,0.05)	(L,0.1)
1	0010600001wRenT	(M,0.457)	(H,0.05)	(VL,0.05)
135	0010600001wRmUk	(M,0.249)	(VH,-0.05)	(L,-0.1)
41	0010600001wRinp	(M,0.244)	(H,-0.1)	(VH,-0.113)
47	0010600001wRish	(M,0.024)	L	(L,-0.062)
6	0010600001wRf6k	(M,-0.107)	(L,0.1)	VH
65	0010600001wRjYB	(M,-0.111)	(VL,0.05)	(VH,-0.025)
45	0010600001wRiro	(M,-0.159)	(H,-0.05)	(H,-0.012)
310	0010600001wRyOF	(M,-0.364)	(L,-0.05)	(L,-0.012)
38	0010600001wRiOQ	(L,0.369)	VH	(H,0.113)
44	0010600001wRipv	(L,0.325)	(H,0.05)	(H,0.012)
5	0010600001wRf5G	(L,0.299)	(VL,0.1)	M
54	0010600001wRiwj	(L,0.283)	(VH,-0.05)	(VH,-0.075)
214	0010600001wRrLB	(L,0.253)	VL	(H,-0.012)
34	0010600001wRiIG	(L,-0.100)	(M,-0.1)	(VL,0.075)
91	0010600001wRlM0	(L,-0.135)	(VH,-0.1)	(L,0.05)
33	0010600001wRiEY	(L,-0.174)	(L,-0.05)	(VL,0.075)
113	0010600001wRlth	(L,-0.362)	(M,-0.05)	(M,-0.075)
35	0010600001wRiIV	(L,-0.404)	(H,-0.05)	(VH,-0.1)
197	0010600001wRqQO	(L,-0.437)	VL	(VL,0.113)

En esta fase, hay que obtener la importancia de cada una de las variables del modelo extendido VIUE antes de calcular la puntuación global de cada interacción. Para ello, como se ha mencionado anteriormente, se utilizará el modelo AHP.

El experto consultado ha especificado la siguiente matriz utilizando la escala de Saaty (Tabla 1):

$$PW = \begin{bmatrix} & P & T & C \\ P & 1 & 1/5 & 1 \\ T & 5 & 1 & 3 \\ C & 1 & 1/3 & 1 \end{bmatrix}$$

Sólo cuando  $CR \leq 0,10$  (véase la ecuación (9)) se satisfacen los resultados del tipo jerárquico individual y se garantiza la coherencia. En este caso,  $CR = 0,025$  por lo que los resultados son válidos para el modelo.

Las ponderaciones finales calculadas son  $W = \{w_P = 0.158, w_T = 0.655, w_C = 0.187\}$ .

Por tanto, el experto como era de prever ha dado mayor relevancia al tiempo de espera, seguida de la carga de trabajo del Contact Center. Esto implica una reordenación de la prioridad de los tickets abiertos, atendiendo principalmente al tiempo de espera y a la carga de trabajo. Calculamos ahora la valoración global de las interacciones y la nueva reordenación teniendo en cuenta estos tres factores, es importante destacar que este proceso se debe ejecutar cada vez que se abre un nuevo ticket en el CRM, de forma que las colas de espera van agilizando la respuesta a los tickets abiertos cuyos tiempos de espera sean mayores.

Tabla 36. Puntuación global extendida VIUE para algunos clientes

Ticket_id	u	VIUE	T	C	Extended VIUE
136	0010600001wRmWM	(H,0.370)	(L,0.05)	(M,-0.075)	(L,0.342)
102	0010600001wRljY	(H,0.118)	(VL,0.05)	(H,0.037)	(L,-0.299)
104	0010600001wRllZ	(H,0.111)	(VH,-0.05)	(L,0.05)	(H,0.140)
56	0010600001wRiyz	(H,-0.179)	(L,0.05)	(M,-0.025)	(M,-0.411)
317	0010600001wRyni	(H,-0.198)	(H,0.05)	(VH,-0.025)	(H,-0.012)
71	0010600001wRjqc	(H,-0.254)	(H,0.05)	(L,0.1)	(M,0.493)
1	0010600001wRenT	(M,0.457)	(H,0.05)	(VL,0.05)	(M,0.299)
135	0010600001wRmUk	(M,0.249)	(VH,-0.05)	(L,-0.1)	(H,0.190)
41	0010600001wRinp	(M,0.244)	(H,-0.1)	(VH,-0.113)	(H,0.178)
47	0010600001wRish	(M,0.024)	L	(L,-0.062)	(L,0.321)
6	0010600001wRf6k	(M,-0.107)	(L,0.1)	VH	(M,-0.233)
65	0010600001wRjYB	(M,-0.111)	(VL,0.05)	(VH,-0.025)	(L,0.073)
45	0010600001wRiro	(M,-0.159)	(H,-0.05)	(H,-0.012)	(H,-0.311)
310	0010600001wRyOF	(M,-0.364)	(L,-0.05)	(L,-0.012)	(L,0.065)

38	0010600001wRiOQ	(L,0.369)	VH	(H,0.113)	(VH,-0.355)
44	0010600001wRipv	(L,0.325)	(H,0.05)	(H,0.012)	(H,-0.051)
5	0010600001wRf5G	(L,0.299)	(VL,0.1)	M	(L,-0.304)
54	0010600001wRiwj	(L,0.283)	(VH,-0.05)	(VH,-0.075)	(VH,-0.469)
214	0010600001wRrLB	(L,0.253)	VL	(H,-0.012)	(L,-0.123)
34	0010600001wRiIG	(L,-0.100)	(M,-0.1)	(VL,0.075)	(M,-0.296)
91	0010600001wRIM0	(L,-0.135)	(VH,-0.1)	(L,0.05)	(H,-0.043)
33	0010600001wRiEY	(L,-0.174)	(L,-0.05)	(VL,0.075)	(L,-0.221)
113	0010600001wRlth	(L,-0.362)	(M,-0.05)	(M,-0.075)	(M,-0.268)
35	0010600001wRiIV	(L,-0.404)	(H,-0.05)	(VH,-0.1)	(H,0.016)
197	0010600001wRqQO	(L,-0.437)	VL	(VL,0.113)	(VL,0.223)

El caso cuyo id de Ticket es igual a 136, pasa de tener una prioridad (H, 0.370) a una prioridad (L, 0.342), esto es debido a que el tiempo de espera es bajo y la capacidad (valor inverso al de la carga) del Contact Center es media (M, -0.075).

Otro ejemplo en caso contrario es el Ticket cuyo id es 35, como se puede observar, la prioridad inicial es baja (L, -0.437), pero el tiempo de espera es alto (H, -0.05) y la capacidad del Contact Center es muy alta (VH, -0.1), finalmente y después de realizado todo el proceso, la prioridad que se proporciona a la interacción es alta (H, 0.016).

Por otra parte, el grado de personalización será directamente proporcional a la prioridad de la interacción y al tiempo de espera, e inversamente proporcional a la carga de trabajo del área del Contact Center encargada de su atención. Es decir, cuando se supera el umbral de carga de trabajo del área, se atenderá al partner buscando la auto-respuesta mediante un bot, o bien se invitará a enviar su incidencia a través de email.

Las alternativas que se han definido, como se ha comentado en el apartado 5.2.5 son:

- Alternativa 1, la interacción será atendida por un Bot en el canal que se ha iniciado la comunicación.

- Alternativa 2, la interacción será atendida por personal con conocimientos generales.
- Alternativa 3, la interacción será atendida por personal especializado.

### 7.1.6 Conclusiones

En el Contact Center tradicional existe una doble medida, primando en muchas ocasiones los objetivos cuantitativos, entre otros, la resolución de incidencias en primera llamada, el tiempo de respuesta, tasa de abandono, llamadas atendidas, eficacia, tiempo de conversación, tiempo improductivo; sobre los objetivos cualitativos, satisfacción del cliente y nivel del servicio. Esta doble medida implica un estrés emocional en el agente y una alta rotación que se deriva en unos costes indirectos para la organización, y la consiguiente erosión del servicio (Robinson & Morley, 2006).

Las tecnologías tradicionales de manejo y enrutamiento en el Contact Center tratarán de enrutar y filtrar la interacción al primer agente disponible o bien al agente especialista (Armony & Maglaras, 2004). La gestión a las que se limitan este tipo de tecnologías es la de enrutar al operador que se encuentre disponible, o bien mantener en cola de espera al cliente hasta ser atendido. En algunos casos, se realiza una identificación del cliente de forma que se le clasifica de acuerdo con la estrategia de pesos por segmento de cliente que tenga establecida la organización, CLV.

Los datos que se han trabajado en los apartados del punto anterior proceden de una empresa fabricante de soluciones software, como conclusiones a este estudio aplicado a dicha empresa, podemos constatar que el procedimiento diseñado encaja con el cambio tecnológico que la empresa quiere poner en marcha en el proceso de atención a clientes.

Aplicando el proceso de valoración de clientes en su relación con el Contact Center (RFID), y añadiendo criterios que están presentes en la interacción, valor

emocional, impacto y urgencia, se puede realizar una primera aproximación a una priorización de tickets. Para lo cual se ha empleado el modelo 2-tupla, además de la metodología AHP que nos ha ayudado a proporcionar peso a cada una de las variables que componen el modelo y así poder obtener un score global de cada interacción, además de una primera ordenación de las interacciones.

Como el proceso es dinámico, debemos tener en cuenta factores adicionales, el primero son los SLAs de atención al cliente, en el caso que nos ocupa, el SLA definido para el tiempo de respuesta es inferior a 20 minutos. Y, por otro lado, la carga de trabajo del Contact Center, se fija entre un 20 y 80 % del tiempo total. Utilizando la misma metodología que la desarrollada en el paso previo, unificación de toda la información a un dominio CBTL y 2-tupla, para posteriormente agregar toda la información utilizando la metodología AHP que proporciona los pesos de cada uno de los criterios, podemos obtener la puntuación global de cada interacción, y por consiguiente su prioridad.

Además, se puede definir un grado de personalización en la comunicación atendiendo a los parámetros anteriores, de forma que se proponen las alternativas reseñadas en el apartado 5.2.5.

Por último, indicar que el modelo planteado es totalmente dinámico, es decir, los pesos de cada uno de los criterios pueden ser modificados de forma dinámica, de tal manera que, que por ejemplo dependiendo de la estacionalidad, para el modelo B2B al que nos estamos refiriendo, las necesidades de atención de incidencias en épocas como la presentación de impuestos son mucho mayores que en otra época del año, o bien, por el horario, las incidencias suelen tener picos y valles durante el día; se puedan adaptar dinámicamente las prioridades.

Y extender el modelo a cualquier otro tipo de negocio tanto en modalidad B2C como B2B, en cuyo caso, quizá los criterios definidos puedan o deban extenderse, así

como ajustar las prioridades definidas para cada criterio en función de las necesidades del Contact Center.

Al automatizar el Contact Center con herramientas que permitan integrar toda la información de la compañía (dato único) y capaces de proporcionar en tiempo real al agente y al cliente autoayuda para la toma de decisiones, la compañía mejorará sin duda en aspectos como (Abdullateef et al., 2010; Baron & Milner, 2009; Reichheld, 2003):

- Reducir el TMO del Contact Center.
- Incrementar la percepción del cliente, NPS.
- Automatizar las acciones repetitivas de los agentes a través de la automatización robótica de procesos (RPA), utilizar bots orientados a apoyar al agente en su esfuerzo de búsqueda y análisis con el objetivo de conectar mejor emocionalmente con los clientes.
- Integrar espacios de trabajo colaborativos, suprimiendo los silos de información, donde los expertos puedan resolver problemas de forma cooperativa.
- Aplicar modelos de IA (predictivos) que permitan analizar y dirigir al cliente hacia soluciones rápidas y en tiempo real.
- Reducir el tiempo de aprendizaje de los agentes de Contact Center al contar con herramientas que les permitan obtener información de los sistemas en tiempo real.
- Reducción de la tasa de abandono, al reducir el TMO liberamos de carga a los agentes.
- Incremento en la resolución de incidencias en primera llamada (FCRR)

## 8. Aplicación de Modelos Agnósticos Interpretables en la Toma de Decisiones

En esta sección, presentamos un ejemplo de aplicación de la guía metodológica desarrollada en el apartado 5.3 de la presente memoria a nuestro modelo RFID. Se intentará predecir si un partner abandona o no la relación con el fabricante, atendiendo a la valoración de su relación con el Contact Center. Si bien, en el modelo RFID aplicado al sector B2B ya se anticipaban 5 clústeres de clientes con la siguiente tasa de abandono representada en la Tabla 28 y la Figura 47.




Figura 47. Clientes por clúster que han abandonado (Type = 1)

Por otro lado, la Figura 48 muestra el número de clientes totales, representados en dos franjas, los que han abandonado y los que continúan como partner distribuidores.




Figura 48. Número total de clientes (Partner / Abandono)

Para un total de 200.615 clientes, continúan después de 3 años (2018 – 2020) 198.493 y han abandonado la relación de partner 2.122.

Siguiendo la metodología Knowledge Discovery Databases (KDD) (Shafique & Qaiser, 2014), Figura 28; y una vez revisado el dominio del problema, el conjunto de datos RFID es el desarrollado en los apartados 6.2.1 a 6.2.5 de la presente memoria, al que incorporaremos la variable solicitud de cancelación (abandono), Type = "Cancellation Request", Figura 49; obteniendo de esta manera el conjunto *RFIDT*, seguidamente se realiza una limpieza de datos y se transforman todos a un dominio numérico entre 0 y 5, para ello utilizaremos la función *MinMaxScaler* de Python (Ecuación (23)); a continuación, al estar los datos desbalanceados, ajustaremos los conjuntos de entrenamiento para evitar este problema; seguidamente, utilizaremos distintos algoritmos de clasificación de ML (Tabla 9) para analizar la relación entre precisión e interpretabilidad, aplicando interpretabilidad en el caso de obtener una mayor precisión y baja explicación; por último, aplicaremos los algoritmos globales y locales agnósticos vistos en la sección 4.5 de la presente memoria, obtendremos y analizaremos las conclusiones.

```
newdata['Type'].unique()
array(['Problem', 'Question', 'Subscription Management',
      'Feature Request', nan, 'Cancellation Request',
      'Professional Services', 'Proactive', 'Developer Support'],
      dtype=object)
```

Figura 49. Tipos de valores de la columna Type

## 8.1 Obtención, Procesamiento y Transformación de Datos

Los datos son recogidos desde la plataforma CRM, una vez procesados y transformados, disponemos de la siguiente descripción del modelo,

Tabla 37. Descripción del conjunto RFIDT

	<b>Recency</b>	<b>Frequency</b>	<b>Importance</b>	<b>Duration</b>	<b>Type</b>
<b>count</b>	200615	200615	200615	200615	200615
<b>mean</b>	416.21	3.16	0.51	10.85	0.02
<b>std</b>	276.97	3.04	0.05	25.70	0.10
<b>min</b>	0.00	1.00	0.25	0.00	0.00
<b>25%</b>	178.00	1.00	0.50	0.00	0.00
<b>50%</b>	378.00	2.00	0.50	0.00	0.00
<b>75%</b>	621.00	4.00	0.50	3.00	0.00
<b>max</b>	<b>1428.00</b>	<b>15.00</b>	<b>1.00</b>	<b>137.00</b>	<b>1.00</b>

Como parte del proceso descrito en el apartado 5.3.2, aplicaremos algunas de las técnicas pre-modelo, visualización de datos y exploración necesarias para explorar, interpretar y obtener el primer conocimiento del conjunto de datos. Nos ayudan a identificar las características clave del modelo, al ser independientes de éste, son aplicables a cualquier conjunto de datos y previas a cualquier selección inicial de modelo de ML.

Procedemos a continuación a realizar un análisis univariante,




Figura 50. Recencia y Frecuencia de transacciones por cliente

Para ambos casos, en el eje Y se representa el número de clientes, y en el eje X el intervalo de tiempo en días para el caso de la recencia y el número de interacciones en el caso de la frecuencia.

Y para la duración y la importancia obtenemos,




Figura 51. Importancia y Duración de transacciones por cliente

En el siguiente paso se visualiza la matriz de correlación,




Figura 52. Matriz de correlación

Se aprecia que existe correlación entre recencia y frecuencia, pero apenas existe correlación entre los criterios y el abandono.

A continuación, realizamos una transformación a un rango [0,5] mediante la función *MinMaxScaler* (Ecuación (23)).

Tabla 38. Descripción RFIDT, aplicando *MinMaxScaler* (0,5)

	Recency	Frequency	Importance	Duration	Type
<b>count</b>	200615	200615	200615	200615	200615
<b>mean</b>	1.457	0.77	1.70	0.39	0.011
<b>std</b>	0.97	1.08	0.30	0.93	0.10
<b>min</b>	0.00	0.00	0.00	0.00	0.00
<b>25%</b>	0.62	0.00	1.67	0.00	0.00
<b>50%</b>	1.32	0.36	1.67	0.00	0.00
<b>75%</b>	2.17	1.07	1.67	0.11	0.00
<b>max</b>	5.00	5.00	5.00	5.00	1.00

## 8.2 Evaluación de Algoritmos de ML

Seguidamente, y con el objetivo de analizar si procede o no aplicar el conjunto de algoritmos de interpretabilidad descritos en el apartado 4.5, se aplicarán un conjunto de técnicas pre-modelo, para obtener así el primer conocimiento del conjunto de datos. Posteriormente se evalúa cada uno de los modelos descritos en la Tabla 9 mediante un proceso de validación cruzada (K-fold), y se pasa a analizar las curvas

Receiver Operating Characteristic (ROC) y Area Under The Curve (AUC), para de esta forma obtener el algoritmo óptimo para el caso de estudio.

Los resultados obtenidos se pueden analizar en la siguiente Tabla,

Tabla 39. Evaluación de algoritmos de predicción aplicados

	Algorithm	ROC AUC	ROC AUC	Accuracy	Accuracy
		Mean	STD	Mean	STD
6	XGboost	70.40	1.24	98.75	0.08
5	Gaussian NB	67.25	1.78	98.83	0.09
0	Logistic Regression	67.14	1.76	61.02	0.44
1	Random Forest	60.40	1.34	98.80	0.08
3	KNN	55.27	0.85	98.93	0.07
4	Decision Tree Classifier	52.32	1.41	98.43	0.10
2	SVM	52.16	4.77	98.94	0.07




Figura 53. Curva ROC / AUC del modelo balanceado

El modelo seleccionado de acuerdo con el procedimiento descrito es XGboost, modelo de caja negra, y responde a la necesidad de utilizar interpretabilidad.

XGboost se utiliza en problemas de aprendizaje supervisado, el objetivo es predecir una variable objetivo  $y_i$  a partir de un conjunto de variables  $x_i$ . Un ejemplo común de aprendizaje supervisado es la regresión lineal, donde la predicción de una variable  $y_i$  se obtiene como,  $y_i = \sum_k(\beta_k x_{ik})$ , las características que componen la entrada están ponderadas por unos pesos  $\beta_k$ .

Cuando hablamos de entrenar a un modelo, se trata de ajustar los parámetros  $\beta$ , para lo cual necesitamos definir la función objetivo que mejor se adapte a los datos de entrenamiento  $x_i$  y que produzca como respuesta el mejor valor ajustado a  $y_i$ . Una característica destacada de las funciones objetivo es que constan de dos partes, la pérdida de entrenamiento y el término de regularización, en la sección 4.5.4. ya se habían introducido ambas variables en la ecuación (17):

$$Goal(\beta) = L(\beta) + \Omega(\beta) \quad (24)$$

Donde  $L$  es la función de pérdida de entrenamiento y  $\Omega$  es el grado de complejidad de explicabilidad del modelo. Para el caso que nos ocupa, se define el modelo de la siguiente forma (Chen & Guestrin, 2016):

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (25)$$

donde  $K$  es el número total de árboles y  $f_k$  es una función en el espacio de funciones  $F$ .

En definitiva, se trata de ir mezclando árboles de clasificación para ir midiendo cuál de las combinaciones es la mejor para nuestro modelo.

### 8.3 Desbalanceo de Datos

Como se puede apreciar en la Figura 48, nuestra clase abandono dispone de muy pocas muestras en relación con la clase mayoritaria (no abandono = partner). Esto provoca un desbalanceo de datos, y como consecuencia el entrenamiento del modelo será deficitario, respondiendo de forma desequilibrada a la detección del patrón de abandono que se quiere pronosticar.

En el primer análisis realizado utilizando XGBoost, el modelo nos ofreció los siguientes resultados:

```

Precisión: 0.9894
-----
Informe de clasificación:

              precision    recall  f1-score   support

Abandono(No)      0.99      1.00      0.99     49623
Abandono(Si)      0.00      0.00      0.00       531

   accuracy              0.99     50154
  macro avg              0.49     50154
 weighted avg             0.98     50154

-----
Matriz de confusión:

[[49621   2]
 [  531   0]]
    
```

Figura 54. Evaluación de predicciones XGBoost, datos no balanceados

Como se puede apreciar, el modelo presenta un resultado extraordinario, con casi un 99 % de predicción, pero basado en una precisión del 100% en la clase mayoritaria (no abandono = 0) y de un 0% en la clase minoritaria (abandono = 1). Se hace por tanto imprescindible realizar un proceso de desbalanceo de datos, tenemos que intentar incrementar el grado de predicción de la clase minoritaria.

Para tratar el posible problema del desbalanceo de datos en la clase abandono, se ha recurrido a modificar el algoritmo de entrenamiento de *XGBoost* introduciendo valor al hiperparámetro *scale\_pos\_weight*, el cual está diseñado para ajustar el comportamiento del algoritmo en problemas de clasificación desequilibrada. Un valor adecuado para este parámetro se encuentra en estimar una corrección correspondiente al inverso de la distribución de clases. Por ejemplo, en un conjunto de datos donde la proporción entre la clase minoritaria y mayoritaria es de 1 a 100, lo correcto es aplicar un valor de  $scale\_pos\_weight = 100$  (Wang et al., 2020).

Además, se ha procedido a combinar *scale\_pos\_weight* con el proceso Smote-Tomek (Batista et al., 2003), consistente en aplicar de forma simultánea un algoritmo de subsampling y de oversampling al conjunto de datos. Obteniendo en uno de los distintos entrenamientos del modelo el siguiente mejor resultado,

```

Precisión: 0.7628
-----
Informe de clasificación:
              precision    recall  f1-score   support

Abandono(No)    0.99      0.76      0.86    59548
Abandono(Sí)    0.03      0.57      0.05      637

   accuracy
 macro avg    0.51      0.67      0.46    60185
weighted avg    0.98      0.76      0.86    60185

-----
Matriz de confusión:

[[45549 13999]
 [ 274   363]]
    
```

Figura 55. Evaluación de predicciones XGBoost, con datos balanceados

Se puede apreciar que, a cambio de perder precisión en la clase mayoritaria, lo ganamos en la minoritaria, si bien no es justificable en el modelo de negocio objeto del estudio. La conclusión inmediata es que el modelo *RFID* para el caso que nos ocupa debe ser complementado y reforzado con otras métricas, como el *NPS*, que tendría más correlación con la tasa de abandono que *RFID*. Por lo comentado anteriormente, la relación entre un cliente (partner) y un fabricante de soluciones software es bastante vinculante, los partner que no han conseguido madurar en el canal de distribución son los más proclives a dejar la relación con la marca, ver clústeres definidos en la sección 6.2.8.

El siguiente paso, por tratarse *XGBoost* de un algoritmo de caja negra, consiste en desarrollar el proceso de interpretabilidad descrito en las secciones 4.5 y 5.3 de la presente tesis.

## 8.4 Aplicación de las Técnicas de Interpretabilidad

A continuación, se aplica el modelo de interpretabilidad detallado en el punto 5.3 de la presente memoria, se hará un estudio de los resultados obtenidos, si bien, como se ha podido apreciar, el modelo *RFID* no es suficiente preciso como para predecir de manera clara el abandono de clientes en el sector considerado, y debe estar

acompañado de otras técnicas como el valor del NPS del cliente en relación con el servicio prestado.

### 8.4.1 Diagrama de Dependencia Parcial (PDP)

Cuando consideramos más de un cierto número de variables, es necesario analizar la dependencia parcial de una o dos variables en relación con la predicción de la variable respuesta, a través del diagrama PDP podemos realizar este tipo análisis, la zona sombreada representa el intervalo de confianza (Friedman, 2001). Como se puede observar en los gráficos, se ha procedido a una normalización entre 0 y 5.




Figura 56. Diagrama de dependencia parcial PDP (Recencia)




Figura 57. Diagrama de dependencia parcial PDP (Frecuencia)




Figura 58. Diagrama de dependencia parcial PDP (Duración)




Figura 59. Diagrama de interacción parcial PD bivalente (Frecuencia, Recencia)

En el diagrama de las Figuras 56 a 58 se puede observar la influencia de la Recencia, Frecuencia y Duración en la predicción de abandono, y en el diagrama de la Figura 59, se puede observar el grado de correlación entre la recencia y la frecuencia. En los gráficos presentados no se ha tenido en cuenta la Importancia, ya que como se comentó en párrafos anteriores, el valor está sesgado hacia el valor medio (M).

Por último, incluimos dentro de este apartado los gráficos ICE, son similares a los gráficos PD, pero ofrecen una visión más detallada sobre el comportamiento de los

conglomerados casi similares en torno a la curva media del gráfico PD. El algoritmo ICE ofrece una visión de las diversas variantes de relaciones condicionales estimadas por la caja negra.




Figura 60. Gráfico ICE (Duración)

## 8.4.2 Cálculo de la Importancia de las Características (ELI5)

Como se comentó en el apartado 4.5.3, el concepto de la importancia de las características es simple, se trata de valorar la importancia de una determinada característica calculando el aumento en el error de predicción después de hacer una permutación de esta (Fisher et al., 2019).

Para que las predicciones de los árboles aleatorios sean más interpretables, cada predicción del modelo puede presentarse como una suma de contribuciones de características (más el sesgo), mostrando cómo las características conducen a una predicción particular. ELI5 lo hace mostrando las ponderaciones de cada característica, indicando su influencia en la decisión final de predicción en todos los árboles. Este es un buen paso en la dirección de la interpretación agnóstica del modelo, pero no totalmente agnóstica, como veremos más adelante, utilizando LIME. Los resultados obtenidos se muestran a continuación,

Tabla 40. Importancia de cada característica (ELI5)

Weight	Feature
0.3610	Importance
0.2542	Frequency
0.1998	Duration
0.1849	Recency

Según los resultados obtenidos, el criterio Importancia es el que más peso tiene en la evaluación de las características, seguido por la Frecuencia, Duración y Recencia. Si bien, como se ha podido observar, la importancia está sesgada hacia los valores medios dentro de toda la muestra.

### 8.4.3 Sustituto Local (LIME)

Como se comentó en el apartado 4.5.4, LIME se trata de un modelo local y actúa comprobando qué ocurre con las predicciones cuando se introducen variaciones en los datos de entrada (Ribeiro et al., 2016b). Para ello, LIME va generando nuevos conjuntos de datos con dichas variaciones obteniendo de esta forma conjuntos de predicciones. A continuación, se pueden ver los resultados aplicados al modelo objeto de estudio,

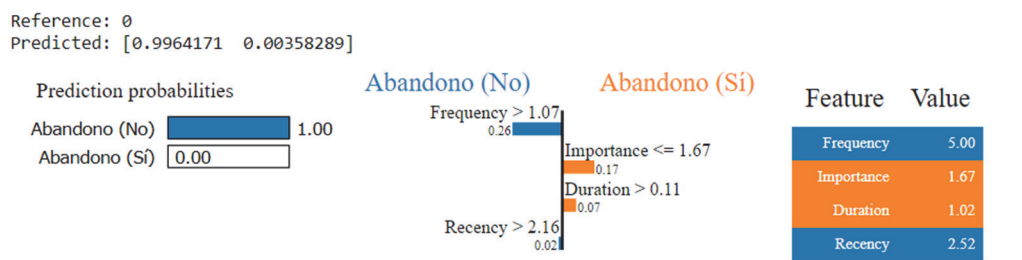


Figura 61. Predicción de abandono en función de las características (Abandono (No))

En el primer caso, Figura 61, se ha escogido un registro en el que se produce un 99,64% de acierto en la predicción de no abandono. En la Figura 62, la predicción de abandono es de un 75,49% que corresponde con un cliente que ha dejado de pertenecer al canal de partner.




Figura 62. Predicción de abandono en función de las características (Abandono (Sí))

### 8.4.4 Valores de SHAP

Como se comentó en el apartado 4.5.5, el objetivo del modelo de interpretabilidad SHAP es poder proporcionar una explicación a una instancia  $x$  a partir de la contribución de cada una de las características a la predicción (Lundberg & Lee, 2017).




Figura 63. Importancia de las características SHAP

En cuanto a la importancia de las características, el modelo a priori se muestra más fiable que ELI5, ya que la medida de la importancia no es un parámetro significativo para el modelo que estamos estudiando, recordemos que el valor por defecto está situado en la mayoría de las muestras en 0.5.

Las Figuras 64 y 65 muestran la predicción de valores de SHAP para el mismo cliente respectivamente de las Figuras 62 y 61 del modelo LIME.




Figura 64. Predicción de valores de SHAP (Abandono (Sí))



Figura 65. Predicción de valores de SHAP (Abandono (No))

Es significativo constatar que el estudio de segmentación realizado en el apartado 6.2.8, para el partner representado en las Figuras 62 y 64, se identificaría con el clúster #1 y, por consiguiente, se trata de un partner de reciente incorporación que necesita dar sus primeros pasos para arrancar y, por tanto, con alto peligro de abandono, de hecho, abandonó. Por el contrario, el partner representado en las Figuras 61 y 65, se identificaría con un clúster #4, el perfil corresponde con partner con una base instalada de clientes importante y que utiliza el Contact Center del fabricante para resolver problemas puntuales, por consiguiente, con bajo peligro de abandono.

### 8.4.5 Skater

Skater permite una interpretación tanto global como local, para las explicaciones globales se basa en el uso de PDP, y para las explicaciones locales se basa en LIME. Como se comentó en el apartado 5.3.3. corresponde con un marco de trabajo unificado de reciente incorporación y en vías de desarrollo (Linardatos et al., 2021)

Los resultados obtenidos se muestran a continuación,




Figura 66. Importancia de las características Skater

En el gráfico de la Figura 66, se puede observar que las previsiones obtenidas con Skater encajan con las del modelo SHAP de la Figura 63. Analizando más en

detalle, obtenemos los gráficos de dependencia, Figura 67, donde se puede apreciar la relación entre la variable de clasificación con respecto a cada una de las características,

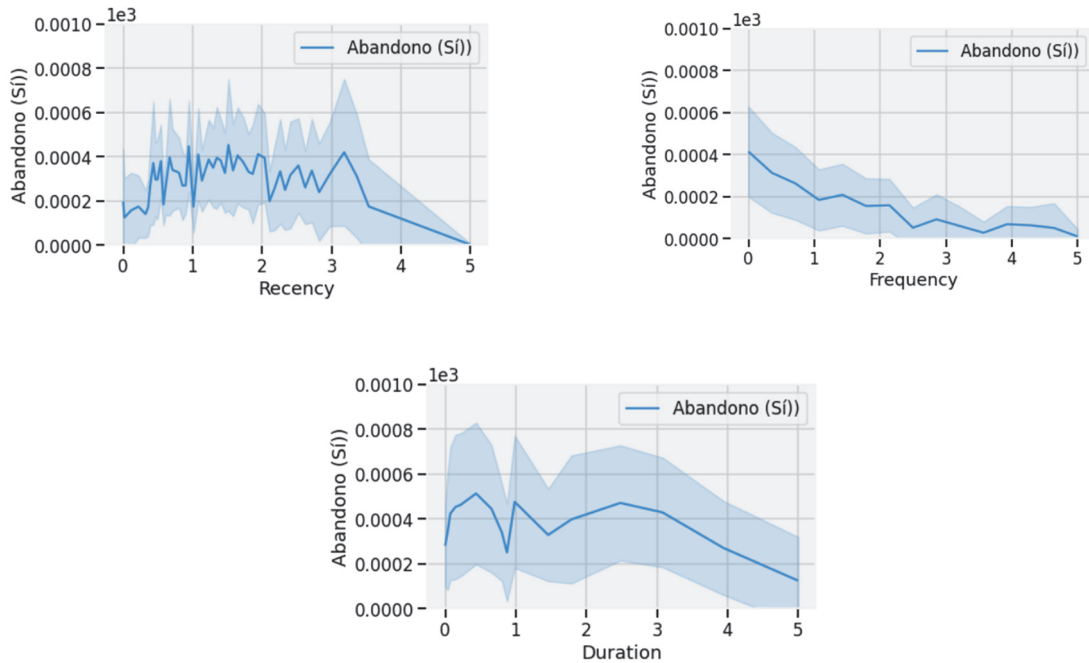


Figura 67. Gráficos de dependencia con Skater

En los gráficos de la Figura 67 se puede confirmar la tendencia que se había visto en el modelo PDP, Figuras 56, 57 y 58. La propensión de abandono se centra en aquellos partner con valores de Recencia medios y bajos (L, M); valores de Frecuencia también bajos (L); y con Duración de incidencias baja, media y alta (L, M, H). Como se ha comentado anteriormente, corresponden a partner de reciente entrada en el canal que no han conseguido madurar lo suficiente como para poder comercializar e implantar las soluciones del fabricante de software.

### 8.4.6 FairML

Con FairML podemos medir la dependencia del modelo predictivo de cada atributo, para ello el algoritmo se basa en realizar proyecciones ortogonales de las entradas y con ello deducir la dependencia de las características (Adebayo, 2016). A continuación, se presentan las conclusiones obtenidas en la aplicación del modelo al caso de uso,




Figura 68. Gráficos de dependencia con FairML

Se puede constatar lo que ya se había indicado en el inicio del análisis, la mala calidad del modelo para predecir la tasa de abandono del partner, RFID en este tipo de entorno debería aplicarse con métricas adicionales para obtener una predicción óptima en el proceso de abandono de partner. Si bien, consideramos que la métrica RFID puede dar buenos resultados en un modelo B2C, donde existe una correlación directa entre cada una de las características del modelo RFID y la propensión al abandono de clientes, hecho que pudimos comprobar en el modelo presentado en el capítulo 6.1.

## 8.5 Conclusiones

El objetivo de estudio es completar una metodología de trabajo para el análisis de la interpretabilidad de modelos de ML, utilizando para ello modelos agnósticos (globales y locales) que se han empleado para el análisis de la explicabilidad de abandono de clientes en un modelo B2B de distribución de soluciones software.

Aplicando el modelo de interpretabilidad a RFID, en un modelo B2C al uso, se pueden lograr altos grados de interpretabilidad en la tasa de abandono de clientes, ya que existe una dependencia directa entre la frecuencia, recencia, duración e importancia de las incidencias con la tasa de abandono. En el modelo B2B que se ha planteado, como se ha comentado anteriormente, la relación entre partner (distribuidor) y el fabricante, es muy estrecha. Es decir, el partner ha tenido que desarrollar toda una línea de negocio e inversión en su relación con el fabricante, que se traduce en:

- Adaptación a los planes de negocio establecidos por el fabricante: número de personas formadas, compromiso de venta y facturación anual.
- Proceso de formación muy exigente del personal técnico, comercial y preventa de cada partner.
- A medida que se va creciendo, necesidad de contratación de personal especializado, con el consiguiente coste económico relacionado.

Por tanto, a medida que el partner crece en venta, la relación con el fabricante es más estrecha y, como consecuencia la tasa de abandono de ese partner es muy baja, ver Figura 47. Por el contrario, nos encontramos con partner de reciente incorporación que no llegan a realizar el proceso de maduración descrito anteriormente, y por tanto tienden a abandonar antes de que su inversión en el modelo de negocio que propone el fabricante sea mayor.

Es por ello por lo que para este modelo en concreto y en general para modelos B2B en los que la relación entre partner y fabricante es tan estrecha, la tasa de abandono no puede estar solamente relacionada con la valoración del cliente en sus interacciones con el Contact Center (RFID). Para modelos B2B y B2C, se propone incluir alguna métrica adicional como el NPS, la valoración que el cliente hace de la marca o de cada una de las interacciones Customer Satisfaction Score (CSAT), o bien

el CES (Saberri et al., 2017). Y por supuesto, agregar otros factores como las métricas introducidas en el modelo CEV, (V. Kumar et al., 2010).

En cuanto a la metodología de trabajo aplicada para resolver el problema de interpretabilidad en modelos de ML, se ha realizado un profundo estudio de modelos agnósticos de interpretabilidad y se han aplicado al contexto del problema a tratar. Esta metodología nos ayuda a interpretar las decisiones tomadas por algoritmos de caja negra, además utiliza modelos de interpretabilidad agnósticos, no dependientes del modelo de ML, y por tanto se garantiza su flexibilidad y aplicabilidad a cualquier tipo de modelo de aprendizaje.

## 9. Conclusiones, contribuciones y futuras áreas de investigación.

Este último capítulo constituye una reflexión sobre el trabajo presentado en esta memoria, los objetivos planteados y conseguidos. Además, se plantean distintas líneas de investigación como fruto del trabajo realizado en esta tesis.

Este capítulo se ha estructurado en tres partes, la primera de ellas trata de reflexionar acerca del trabajo de investigación realizado y la aplicación de sus resultados y la metodología inherente a procesos de digitalización empresariales. En segundo lugar, se plantea una revisión acerca de los objetivos planteados y los resultados obtenidos, y las posibles contribuciones que este estudio tiene en el ámbito empresarial. Para finalizar, se enuncian las líneas de investigación resultantes del trabajo realizado que pueden extenderse a otros ámbitos empresariales. Soy un convencido de que el principal objetivo de la Investigación debe ser el acercamiento entre Universidad y Empresa.

### 9.1 Reflexión General sobre la Investigación.

Más de veinte años trabajando en el sector de la tecnología me han hecho ver la realidad de muchas empresas nacionales e internacionales. El principal problema con el que se presenta cualquier empresa es el de integridad del dato, lo que conocemos como dato único. La gran mayoría de las empresas han crecido en base a lo que llamamos silos, al ir creciendo, se van sumando tecnologías de forma que al final se obtiene un puzzle tecnológico, difícilmente integrable, y origina entre otros problemas una duplicidad e incoherencia de los datos y por consiguiente de la información.

En este trabajo, me he centrado en una problemática relacionada con los procesos de transformación digital, pero muchas veces olvidada, la relación entre cliente y Contact Center.

Como consultor del área de Customer Experience en una empresa como Informática El Corte Inglés, colaboré en la realización de consultoría en empresas cuya problemática iba más allá de la relación derivada de la compra y de la venta, uno de los procesos clave en el Engagement entre cliente y marca está en el Contact Center, pero no solo desde el punto de vista del proceso de venta, muchos estudios están encaminados a este fin, y muchas empresas consultoras están especializadas en mejorar los procesos de venta. Al visitar a clientes importantes, donde uno de los canales de venta y también de servicio era el Contact Center, primaban otras métricas que tenían que ver con la Calidad del Servicio y la Omnicanalidad.

Las soluciones que propone el mercado están relacionadas con la Omnicanalidad, la capacidad de atender al cliente a través de cualquier canal de comunicación, mejorar los tiempos de respuesta y solución e intentar automatizar todos estos procesos. De forma que las soluciones que se proponían desde nuestro área de consultoría iban destinadas a resolver la interacción con el cliente desde escenarios de menor a mayor coste, esto es, si la respuesta a la primera interacción la proporciona un bot, el ahorro de costes de personal y de atención es muy alta, así como la mejora en los tiempos de respuesta, solución y operación.

En este momento fue cuando me puse en contacto con mi director de tesis, quería dedicarme a la docencia y en especial a la investigación, así que empezamos a hablar de todo esto, y comentamos la posibilidad de trabajar esta línea de investigación en la que hay muchas cosas por hacer.

El primer modelo que propuse fue el VIUE, que hemos visto en los capítulos 5.2. y el 7 de la presente memoria. El objetivo es optimizar la priorización

de interacciones entre cliente y marca en función de parámetros como la valoración del cliente, el impacto, la urgencia y el carácter emocional de la interacción. Además, se aplica un extra adicional, que es la reordenación de las prioridades atendiendo a patrones como la carga de trabajo del Contact Center y el tiempo de espera de la interacción. El propósito de este modelo es lanzar al mercado una aplicación que, tras la identificación del cliente en su interacción, permita al sistema conectarse con el CRM empresarial, obtener la información necesaria para elaborar el correspondiente perfil de cliente, disponer de esta forma de las métricas necesarias para la evaluación de la interacción, y con ello en tiempo real priorizar la lista de espera de interacciones. Por otro lado, la definición de criterios es totalmente flexible y dinámica, puede realizarse en el mismo proceso de implantación (parametrización) y de igual forma se puede establecer el peso de cada criterio en tiempo real. Clasificar de una forma flexible, parametrizable y en tiempo real las interacciones con el Contact Center, mejorará sin duda la imagen de marca de cualquier cliente en relación con el prestador del servicio. Y además de aplicación a cualquier sector de actividad como la telefonía, comercio, hostelería, aseguradoras y servicios en general; donde la relación entre cliente y marca va más allá del proceso de compra.

Haciendo una revisión de la literatura y bibliografía relacionada con los procesos de Contact Center, empecé a valorar la posibilidad de trabajar un nuevo modelo de evaluación del cliente desde el punto de vista del Contact Center, de aquí surge el modelo RFID, descrito en los apartados 5.1 y 6 de la presente memoria. La pregunta en este contexto era clave, tenemos modelos como el NPS, CES, CSAT todos ellos sirven para evaluar la prestación del servicio por parte del Contact Center desde el punto de vista del cliente, pero ¿disponemos de alguna métrica que nos proporcione el valor del cliente desde un punto de vista de sus interacciones con el Contact Center? Tras revisar mucha literatura, no encontré ninguna o casi ninguna referencia a este problema. La mayor parte de las métricas

están centradas en la evaluación del cliente desde un punto de vista de venta RFM y CLV, de interacción en redes sociales CIV, de la capacidad de generación de conocimiento a la marca CKV o bien de la capacidad de recomendación CRV. Se echaba en falta alguna métrica que tuviese que ver con el Contact Center, aparte de las comentadas NPS, CES y CSAT. De ahí el desarrollo del modelo RFID, y el resultado fue el artículo publicado en la revista MDPI, Mathematics (Marín Díaz et al., 2021b). De igual forma, en este ámbito existe mucho por investigar y trabajar, hemos dado los primeros pasos con este artículo, la idea es seguir trabajando en modelos que fortalezcan el valor agregado del cliente. La información se encuentra disponible en los sistemas de gestión de la compañía, y en este caso en el CRM, así extraer, analizar y ponderar la valoración del cliente es tarea sencilla empleando técnicas basadas en el modelo RFM, multicriterio lingüístico 2-tupla, AHP y clasificación y clusterización con modelos como k-means. En estos modelos se ha basado gran parte del trabajo reflejado en esta tesis. La novedad del modelo RFID radica en analizar el valor del cliente desde el punto de vista del Contact Center.

Quedaba una parte final, el análisis de la interpretabilidad en modelos de ML, muchas de las decisiones que se toman en entornos empresariales están basadas en datos, pero también en formulaciones subjetivas. Existen herramientas de inteligencia de negocio, Business Intelligence (BI) (Analytics, 2021), son capaces de conectar en tiempo real con los sistemas empresariales de cualquier organización, principalmente el Enterprise Resource Planning (ERP) y el ya comentado CRM, como se puede ver, todo lo importante en tecnología parece tener tres siglas, una vez conectados se puede extraer información en tiempo real y desarrollar cuadros de mando personalizados, con más o menor profundidad, algunas de dichas herramientas permiten explotar más allá la información y realizar modelos predictivos. Así que motivado por todas estas circunstancias surgió la posibilidad de participar en el congreso Ethicomp 2021 (Marín Díaz et al., 2021a), allí pude exponer los distintos algoritmos de Interpretabilidad que

hemos visto en los apartados 4.5, 5.3 y 8 de la presente tesis. Y extraer un procedimiento de trabajo que permita realizar una interpretabilidad de cualquier modelo de ML utilizando modelos agnósticos.

## 9.2 Análisis de objetivos enunciados y contribuciones conseguidas.

En este apartado, se ponen en relación los objetivos iniciales propuestos en la memoria de este proyecto, así como las contribuciones conseguidas para tal fin.

***Objetivo general:** Diseñar un método formal que permita la gestión estratégica del Contact Center, en distintos mercados B2B y B2C. Dicha mejora debe implicar una mayor efectividad en la relación entre cliente y marca, logrando un mayor grado de fidelización y vinculación, consiguiendo una mayor precisión en el proceso de evaluación de cliente y poder dar así respuesta personalizada a sus necesidades.*

El objetivo general está marcado dentro de la estrategia de resolución de problemas relacionados con la consultoría de procesos de transformación digital en los que habitualmente trabajo y he trabajado. En este contexto, la formalización de una metodología como la expuesta en la presente tesis, ahorra considerables esfuerzos de consultoría y permite plantear una propuesta de valor diferencial, centrada en el cliente desde el punto de vista de su interacción con el Contact Center. Todas las propuestas presentadas en la presente memoria son susceptibles de aplicación a empresas donde exista un Contact Center volcado en el servicio de atención al cliente y en cualquier sector tanto en modelos B2C como en B2B.

***Objetivo específico 1:** Revisión de las métricas ligadas a los procesos de Customer Service, así como los estudios relacionados.*

Este objetivo quedó cubierto en el apartado 3 de la memoria, se profundizó en estudios y métricas relacionadas con el proceso de Customer Service, haciendo

foco en las premisas anteriores; se trabajó también en la literatura relacionada con el modelo RFM, en el cual basamos los nuevos modelos RFID y VIUE. Se analizaron las limitaciones del modelo RFM y las sugerencias de ampliación de dicho modelo utilizando el modelo lingüístico 2-tupla con el objetivo de solucionar la falta de precisión del modelo RFM al presentarse los resultados en escalas, típicamente de 5 valores.

Se analizó la literatura correspondiente a la valoración que el cliente hace del Contact Center, basadas principalmente en la recogida de información del cliente después de que el servicio se ha prestado, indicándose la novedad del modelo RFID, ya que amplía la visión a 360° entre cliente y marca desde el punto de vista del Contact Center.

Por último, se revisó la literatura correspondiente a los modelos de interpretabilidad en procesos de ML, se analizó la bibliografía y la importancia relevante que se está dando a la interpretabilidad de algoritmos de caja negra. Se analizaron ejemplos de errores de algoritmos y se abordó la iniciativa de desarrollar una IA explicable (XAI) desde distintos puntos de vista: tecnológico, legislativos y organismos regulatorios y ciencia e investigación. Se incluyó un apartado adicional analizando la literatura relacionada con los indicadores de interpretabilidad.

*Objetivo específico 2: Investigar los usos del modelo RFM y su aplicación en distintos escenarios, validando de esta forma la originalidad de los modelos RFID y VIUE planteados.*

Este objetivo quedó cubierto con el análisis efectuado en el apartado 3 de la presente memoria, realizándose una revisión formal del estado del arte actual, en el uso del modelo RFM considerando sus ventajas y limitaciones, así como la extensión lingüística 2-tupla ayuda en la mejora de dicho modelo. En dicho

apartado, se identificaron los factores determinantes del proceso de relación entre cliente y marca, proporcionándose bibliografía relacionada.

Se analizó también en dicho apartado la literatura relacionada con el Contact Center, no encontrando una valoración del cliente desde el punto de vista del Contact Center, si a la inversa, el cliente mediante NPS, CSAT puede realizar una valoración de la marca o bien del servicio prestado, sin embargo, y no en todas ocasiones, el cliente es valorado por la marca de acuerdo con la recencia, frecuencia y consumo realizado en un período determinado, algunos estudios adicionales incluían el valor del cliente como referenciador CRV, influenciador CIV y generador de conocimiento CKV, pero en ningún caso se mencionaba el valor del cliente desde el punto de vista del Contact Center, a lo que hemos dado en llamar, Customer Service Value CSV.

Por tanto, en este apartado 3 queda contrastada la validez y novedad del modelo RFID planteado, y como consecuencia también el modelo VIUE, basado en la valoración proporcionada por RFID, y el análisis de la literatura relacionado con los criterios adicionales cubiertos por el modelo: impacto, urgencia y carácter emocional de las interacciones con el Contact Center, además de la gestión de colas, los ratios de prestación de servicio (SLAs) y la carga de trabajo del Contact Center.

***Objetivo específico 3:** Diseño de un nuevo proceso metodológico que llamaremos RFID, que permita mejorar el grado de fidelización de los clientes respecto a su relación con el Contact Center.*

El proceso de diseño del modelo RFID se fraguó en el marco teórico de la investigación, apartado 4 de la presente memoria, donde se analiza el modelo lingüístico 2-tupla, el modelo RFM, el modelo AHP, junto con el modelo de tratamiento de información heterogénea. Por otro lado, el planteamiento

metodológico del modelo RFID quedó reflejado en el apartado 5.1 de la presente memoria, presentándose dos casos de negocio, el primero orientado a un sector B2C y el segundo a un sector B2B, se comprobó en ambos casos la validez del modelo propuesto, el detalle de ambos está expuesto en el apartado 6 de la presente memoria.

Fruto del trabajo del modelo RFID para una empresa del sector B2C se publicó el siguiente artículo en la revista *Mathematics*, y constituye un refrendo y contribución al marco de trabajo iniciado.

### **Contribución 1**

*Marín Díaz, G., Carrasco, R. A., & Gómez, D. (2021b). RFID: A Fuzzy Linguistic Model to Manage Customers from the Perspective of Their Interactions with the Contact Center. Mathematics, 9(19), 2362. <https://doi.org/10.3390/math9192362>*

*Nombre de la revista: Mathematics Volumen: 9*

*Páginas inicial: 1 final: 27 Editorial: MDPI*

*País de publicación: Suiza Año de publicación: 2021 (in press)*

*ISSN: 2227-7390 DOI: <https://doi.org/10.3390/math9192362>*

*Indicios de calidad:*

*Año: 2020*

*Índice de Impacto: 2.258 Base: ISI JCR Science Edition*

*Posición: 24 de 330 (Q1). Área: Mathematics*

**Objetivo específico 4:** *Diseño de un nuevo proceso metodológico que llamaremos VIUE, que permita la priorización y gestión de las interacciones entre cliente y marca a través del Contact Center de forma automática.*

El proceso de diseño del modelo VIUE se fraguó en el marco teórico de la investigación, apartado 4 de la presente memoria, donde se analiza el modelo lingüístico 2-tupla, el modelo RFM, el modelo AHP, junto con el modelo de tratamiento de información heterogénea. Por otra parte, el planteamiento metodológico del modelo VIUE quedó reflejado en el apartado 5.2 de la presente memoria, y se presentó un caso de negocio orientado al sector B2B (fabricante de software), comprobándose la validez del modelo propuesto, el detalle está expuesto en el apartado 7 de la presente memoria.

Fruto del trabajo realizado en la presente memoria en el diseño del modelo VIUE, a nivel científico actualmente se está trabajando en la presentación de un paper. Y, por otra parte, el interés suscitado en dicho modelo por empresas del sector Telecom y Servicios, hace que se esté trabajando en el desarrollo de un add-on que permita interconectar las fuentes de información de la compañía (CRM y Contact Center), y así poder priorizar en tiempo real las interacciones teniendo como base el modelo VIUE diseñado en Python para esta memoria.

***Objetivo específico 5:** Diseño de un proceso metodológico que permita disponer de mecanismos de aplicación de Inteligencia Artificial Explicable (XAI) a la tasa de abandono de un cliente, y diseñar las medidas oportunas para mitigarlo.*

El proceso de diseño del modelo metodológico que permita la interpretabilidad en modelos de ML de caja negra se fraguó en el marco teórico de la investigación, apartado 4 de la presente memoria, donde se analizan distintos modelos agnósticos PDP, ICE, ELI5, LIME y SHAP. Por otro lado, en el apartado 5.3 se materializa la metodología KDD para el uso de los modelos en el proceso de toma de decisión ante el posible abandono de un cliente.

Para el desarrollo de la metodología KDD, después de extraer la información y procesarla, se aplican un conjunto de modelos de ML y se analiza

cuál de ellos proporciona unos mejores resultados, a partir de ahí, si el modelo es no interpretable (caja negra) aplicamos la metodología implementada en la presente memoria para modelos de interpretabilidad agnósticos, y esto nos permitirá determinar cuánto de explicable es la respuesta del modelo planteado en relación con las variables representadas en el modelo.

El caso de negocio planteado está basado en el modelo RFID de valoración del cliente de acuerdo con sus interacciones con el Contact Center, al que añadimos la variable respuesta (abandono). Para el caso planteado, se propone realizar una evaluación de la variable respuesta en función de las características Recencia, Frecuencia, Importancia y Duración de las interacciones del cliente con el Contact Center en un periodo considerado. Este caso de negocio está ampliamente desarrollado en el apartado 8 de la presente memoria, incorporando dos modelos de interpretabilidad adicionales Skater y FairML.

## **Contribución 2**

*Marín Díaz, G., Carrasco, R. A., & Gómez, D. (2021a). What do Machines Think About? 129–133*

*Nombre del Congreso: International Conference on the Ethical and Social Impact of ICT (19. 2021. Logroño)*

*Libro: Normal Technology Ethics*

*Artículo: What do Machines Think About?*

*Páginas inicial: 129 final: 133 Editorial: Universidad de La Rioja*

*País de publicación: España Año de publicación: 2021 (in press)*

*ISBN: 978-84-09-28671-3*

*url: <https://dialnet.unirioja.es/servlet/libro?codigo=824595>*

### **Contribución 3**

*Marín Díaz, G., Carrasco, R. A., & Gómez, D. (2021a). Interpretability Challenges in Machine Learning Models. 205–217.*

*Nombre del Congreso: International Conference on the Ethical and Social Impact of ICT (19. 2021. Logroño)*

*Libro: Moving technology ethics at the forefront of society, organisations and governments*

*Artículo: Interpretability Challenges in Machine Learning Models*

*Páginas inicial: 205 final: 217 Editorial: Universidad de La Rioja*

*País de publicación: España Año de publicación: 2021 (in press)*

*ISBN: 978-84-09-28672-0*

*url: <https://dialnet.unirioja.es/servlet/libro?codigo=829454>*

**Objetivo específico 6.** *Implementación de los modelos diseñados mediante herramientas open-source, R y Python*

Para el desarrollo, pruebas y prototipado se han utilizado ambas herramientas de programación durante todo el proceso de elaboración de la presente memoria.

**Objetivo específico 7.** *Aplicación de los modelos obtenidos, generalizando su aplicabilidad a los mercados B2B y B2C.*

Los casos de negocio detallados en los apartados 6, 7 y 8 de la presente tesis han sido adaptados a entornos B2B y B2C.

El modelo RFID ha sido probado en ambos entornos, en el apartado 6.1 se ha aplicado a un entorno B2C, a una empresa del sector de las telecomunicaciones. En el apartado 6.2 se ha aplicado a un entorno B2B, a una empresa del sector de la fabricación y distribución de software.

Las pruebas realizadas con Python del modelo VIUE han sido testadas en una base de datos proporcionada por un fabricante y distribuidor de software (mismo caso que el 6.2), ver apartado 7. Si bien, el modelo planteado es extensible a cualquier entorno empresarial, ya que el proceso de priorización de tickets es común a todas las empresas que reciben interacciones de clientes a través de un Contact Center. Por otro lado, VIUE es fácilmente parametrizable y permite en tiempo real modificar el peso de los criterios definidos en el proceso de priorización, por lo cual su extensibilidad a cualquier entorno está contrastada.

Por último, el modelo de interpretabilidad desarrollado en Python en el apartado 8 de la presente memoria, es extensible a cualquier entorno, ya que los modelos de interpretabilidad que se han desarrollado en la metodología presentada corresponden a modelos agnósticos, independientes del modelo de ML empleado.

### 9.3 Futuras líneas de investigación

El trabajo presentado en esta memoria ha cubierto los objetivos marcados para la investigación, se ha desarrollado un modelo completo de trabajo con el Contact Center, diseñando un modelo para la priorización y personalización de la comunicación entre cliente y marca (VIUE). Y, por otro lado, presentando un modelo de valoración del cliente desde el punto de vista de su interacción con el Contact Center (RFID).

Se ha reforzado el estudio a través del desarrollo de una metodología que permite aplicar interpretabilidad en algoritmos de caja negra, utilizando modelos agnósticos, y se ha desarrollado como caso de negocio la medición de la variable target binaria abandono de cliente utilizando las variables de Recencia, Frecuencia, Importancia y Duración del modelo RFID.

Entre los puntos de mejora y futuras líneas de investigación fruto del trabajo realizado, del estado del arte, del conocimiento del sector y de las necesidades de los clientes, se pueden destacar los siguientes:

- La medición del valor del cliente hemos visto que puede ser un agregado de varios factores:  $CEV = f(CLV, CKV, CIV, CRV)$  (V. Kumar et al., 2010). Es recomendable incluir un parámetro más, el valor del cliente desde el punto de vista del Contact Center, RFID y se ha bautizado en la presente memoria como Customer Service Value (CSV). Realizar un proceso de medición agregado y ponderado daría más fortaleza al modelo CEV.
- Una métrica que preocupa a los Contact Center es la tasa de abandono de los empleados, la rotación en el Contact Center es muy elevada debida principalmente a las exigencias laborales y emocionales (Rameshbabu et al., 2013). Utilizar el procedimiento diseñado en esta tesis para analizar, predecir e interpretar la tasa de abandono del personal de Contact Center sería un reto muy importante.
- Aplicar los modelos RFID y VIUE a distintos entornos empresariales, focalizando en retail, seguros, banca, servicios, sanidad y turismo. Cada caso aplicado contribuirá a fortalecer y a ampliar posiblemente cada uno de los modelos con características propias de cada sector.
- Aplicar y extender a entornos B2C la metodología XAI desarrollada en esta tesis, buscando la interpretabilidad en la tasa de abandono de clientes de cualquier sector empresarial.

## 10. Bibliografía

- Abdul, A., Vermeulen, J., Wang, D., Lim, B. Y., & Kankanhalli, M. (2018). Trends and trajectories for explainable, accountable and intelligible systems: An HCI research agenda. *Conference on Human Factors in Computing Systems - Proceedings, 2018-April*. <https://doi.org/10.1145/3173574.3174156>
- Abdullateef, A. O., Sanuri, S., Mokhtar, M., & Yusoff, R. Z. (2010). The impact of CRM Dimensions on Call Center Performance. *OR Spectrum*, 10(12), 184–194. <http://proquest.umi.com/pqdweb?did=669649341&Fmt=7&clientId=65345&RQT=309&VName=PQD>
- Adebayo, J. A. (2016). *FairML: Toolbox for diagnosing bias in predictive modeling*.
- Adversarial Robustness Toolbox. (2021). *Adversarial Robustness Toolbox*. <https://adversarial-robustness-toolbox.org/>
- AI Explanability 360. (2021). *AI Explanability 360*. <https://aix360.mybluemix.net/>
- Ailawadi, K. L., & Farris, P. W. (2017). Managing Multi- and Omni-Channel Distribution: Metrics and Research Directions. *Journal of Retailing*, 93(1), 120–135. <https://doi.org/10.1016/j.jretai.2016.12.003>
- Alet Vilagínés, J. (2020). Predicting customer behavior with Activation Loyalty per Period. From RFM to RFMAP. *ESIC MARKET Economic and Business Journal, Volume 51, Issue 3*, 609–637. <https://doi.org/10.7200/esicm.167.0513.4>
- Ali, A. (2020). *Here's What Happens Every Minute on the Internet in 2020*. <https://www.visualcapitalist.com/every-minute-internet-2020/>
- Altman, D., Yom-Tov, G. B., Olivares, M., Ashtar, S., & Rafaeli, A. (2021). Do customer emotions affect agent speed? An empirical study of emotional load in online customer contact centers. *Manufacturing and Service Operations Management*, 23(4), 854–875. <https://doi.org/10.1287/MSOM.2020.0897>
- Altmann, A., Toloşi, L., Sander, O., & Lengauer, T. (2010). Permutation importance: A corrected feature importance measure. *Bioinformatics*, 26(10), 1340–1347. <https://doi.org/10.1093/bioinformatics/btq134>
- Alvarez-Melis, D., & Jaakkola, T. S. (2018). *On the Robustness of Interpretability Methods*. *Whi*. <http://arxiv.org/abs/1806.08049>
- Analytics, P. I. (2021). *Analytics and Business Intelligence ( BI ) Platforms Reviews and Ratings What are Business Intelligence ( BI ) Tools ? Products In Analytics and Business Intelligence ( BI ) Platforms Market*.
- Anderson, K. M. (1986). A method for customer lifetime value ranking. *Preventing School Failure*, 51(3), 49–51. <https://search.proquest.com/docview/220297257?accountid=12834>

- Andrade, R., Moazeni, S., & Ramirez-Marquez, J. E. (2020). A systems perspective on contact centers and customer service reliability modeling. *Systems Engineering*, 23(2), 221–236. <https://doi.org/10.1002/sys.21526>
- Armony, M., & Maglaras, C. (2004). On customer contact centers with a call-back option: Customer decisions, routing rules, and system design. *Operations Research*, 52(2), 271–292. <https://doi.org/10.1287/opre.1030.0088>
- Baehre, S., O'Dwyer, M., O'Malley, L., & Lee, N. (2021). The use of Net Promoter Score (NPS) to predict sales growth: insights from an empirical investigation. *Journal of the Academy of Marketing Science*, 2007. <https://doi.org/10.1007/s11747-021-00790-2>
- Baron, O., & Milner, J. (2009). Staffing to maximize profit for call centers with alternate service-level agreements. *Operations Research*, 57(3), 685–700. <https://doi.org/10.1287/opre.1080.0585>
- Bartolini, C., & Sallé, M. (2004). Business driven prioritization of service incidents. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 3278, 64–75. [https://doi.org/10.1007/978-3-540-30184-4\\_6](https://doi.org/10.1007/978-3-540-30184-4_6)
- Basiri, M. E., Nemati, S., Abdar, M., Cambria, E., & Acharya, U. R. (2021). ABCDM: An Attention-based Bidirectional CNN-RNN Deep Model for sentiment analysis. *Future Generation Computer Systems*, 115, 279–294. <https://doi.org/10.1016/j.future.2020.08.005>
- Bastani, O., Kim, C., & Bastani, H. (2017). Interpreting blackbox models via model extraction. *ArXiv*.
- Batista, G. E. A. P. A., Bazzan, A. L. C., & Monard, M. C. (2003). Balancing Training Data for Automated Annotation of Keywords: a Case Study. In *Proceedings of the Second Brazilian Workshop on Bioinformatics, January*, 35–43. <http://www.cs.waikato.ac.nz/>
- BBC Mundo. (2016). *Tay, la robot racista y xenófoba de Microsoft*. Bbc. [https://www.bbc.com/mundo/noticias/2016/03/160325\\_tecnologia\\_microsoft\\_tay\\_bot\\_adolescente\\_inteligencia\\_artificial\\_racista\\_xenofoba\\_lb%0Ahttps://www.bbc.com/mundo/noticias/2016/03/160325\\_tecnologia\\_microsoft\\_tay\\_bot\\_adolescente\\_inteligencia\\_artificial\\_raci](https://www.bbc.com/mundo/noticias/2016/03/160325_tecnologia_microsoft_tay_bot_adolescente_inteligencia_artificial_racista_xenofoba_lb%0Ahttps://www.bbc.com/mundo/noticias/2016/03/160325_tecnologia_microsoft_tay_bot_adolescente_inteligencia_artificial_raci)
- BBC Mundo Tecnología. (2015). *Google pide perdón por confundir a una pareja negra con gorilas*. Bbc. [https://www.bbc.com/mundo/noticias/2015/07/150702\\_tecnologia\\_google\\_perdon\\_confundir\\_afroamericanos\\_gorilas\\_lv](https://www.bbc.com/mundo/noticias/2015/07/150702_tecnologia_google_perdon_confundir_afroamericanos_gorilas_lv)
- Bernasconi, M., Choirat, C., & Seri, R. (2009). "The Analytic Hierarchy Process and the Theory of Measurement", Working Paper No.24, Department of Economics Ca'Foscari University of Venice. 23.

- Bert, G. (2018). *Google BERT*. <https://cloud.google.com/tpu/docs/tutorials/bert>
- Blackmer, W. S. (2018). EU general data protection regulation. *American Fuel and Petrochemical Manufacturers, AFPM - Labor Relations/Human Resources Conference 2018, 2014*(April), 45–62. <https://doi.org/10.1308/rcsfdj.2018.54>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32, 2001, 5–32.
- Britannica, E. (2018). MYCIN. <https://www.britannica.com/technology/MYCIN>
- Brynjolfsson, E., Hu, Y. J., & Rahman, M. S. (2013). Competing in the Age of Omnichannel Retailing. *International Journal of Electronic Commerce*, 18(4), 5–16. <https://doi.org/10.2753/JEC1086-4415180400>
- Bueno, I., Carrasco, R. A., Porcel, C., Kou, G., & Herrera-Viedma, E. (2021). A linguistic multi-criteria decision making methodology for the evaluation of tourist services considering customer opinion value. *Applied Soft Computing*, 101, 107045. <https://doi.org/10.1016/j.asoc.2020.107045>
- Bundy, A. (2017). Preparing for the future of Artificial Intelligence. *Ai & Society*, 32(2), 285–287. <https://doi.org/10.1007/s00146-016-0685-0>
- Business, C. (2019). *Apple co-founder Steve Wozniak says Apple Card discriminated against his wife*. <https://edition.cnn.com/2019/11/10/business/goldman-sachs-apple-card-discrimination/index.html>
- Caceres, R. C., & Papparoidamis, N. G. (2007). Service quality, relationship satisfaction, trust, commitment and business-to-business loyalty. In *European Journal of Marketing* (Vol. 41, Issues 7–8). <https://doi.org/10.1108/03090560710752429>
- Carrasco, Ramón A., Blasco, M. F., & Herrera-Viedma, E. (2015). A 2-tuple fuzzy linguistic RFM model and its implementation. *Procedia Computer Science*, 55, 1340–1347. <https://doi.org/10.1016/j.procs.2015.07.118>
- Carrasco, Ramón A., Forero, L. N., López, S. X., Herrera-Viedma, E., & Porcel, C. (2018). Using the AHP model to improve the measurement of satisfaction in the ICT sector. *Frontiers in Artificial Intelligence and Applications*, 303, 299–311. <https://doi.org/10.3233/978-1-61499-900-3-299>
- Carrasco, Ramón Alberto, Blasco, M. F., García-Madariaga, J., & Herrera-Viedma, E. (2019). A Fuzzy Linguistic RFM Model Applied to Campaign Management. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(4), 21. <https://doi.org/10.9781/ijimai.2018.03.003>
- Carrasco, Ramón Alberto, Blasco, M. F., García-Madariaga, J., Pedreño-Santos, A., & Herrera-Viedma, E. (2018). A model to obtain a servperf scale evaluation of the crm customer complaints: An application to the 4g telecommunications sector. *Technological and Economic Development of Economy*, 24(4), 1606–1629. <https://doi.org/10.3846/tede.2018.5080>
- Carrasco, Ramón Alberto, Sánchez-Fernández, J., Muñoz-Leiva, F., Francisca Blasco, M.,

- & Herrera-Viedma, E. (2017). Evaluation of the hotels e-services quality under the user's experience. *Soft Computing*, 21(4), 995–1011. <https://doi.org/10.1007/s00500-015-1832-0>
- Carvalho, D. V., Pereira, E. M., & Cardoso, J. S. (2019). Machine learning interpretability: A survey on methods and metrics. *Electronics (Switzerland)*, 8(8), 1–34. <https://doi.org/10.3390/electronics8080832>
- Casella, G., Fienberg, S., & Olkin, I. (2013). An Introduction to Statistical Learning. In *Springer Texts in Statistics*. <http://books.google.com/books?id=9tv0taI8l6YC>
- Casillas, J., Cordon, O., Triguero, F. H., & Magdalena, L. (2013). *Interpretability issues in fuzzy modeling*. 128.
- Chan, C. C. H. (2008). Intelligent value-based customer segmentation method for campaign management: A case study of automobile retailer. *Expert Systems with Applications*, 34(4), 2754–2762. <https://doi.org/10.1016/j.eswa.2007.05.043>
- Charrad, M., Ghazzali, N., Boiteau, V., & Niknafs, A. (2014). NbClust: An R Package for Determining the Relevant Number of Clusters in a Data Set. *Journal of Statistical Software*, 61(1), 1–36. <https://doi.org/10.18637/JSS.V061.I06>
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *The Journal of the Association of Physicians of India*. <https://doi.org/2939672.2939785>
- Cid-López, A., Hornos, M. J., Carrasco, R. A., & Herrera-Viedma, E. (2016). Applying a linguistic multi-criteria decision-making model to the analysis of ICT suppliers' offers. *Expert Systems with Applications*, 57, 127–138. <https://doi.org/10.1016/j.eswa.2016.03.025>
- Clancey, W. J. (1987). The GUIDON Program. *MIT Press Series in Artificial Intelligence*.
- Cleveland, M., & Laroche, M. (2017). *Globalization , national identity , biculturalism and consumer behavior : A longitudinal study of Dutch consumers*. February 2021. <https://doi.org/10.1016/j.jbusres.2016.02.044>
- Comisión Europea. (2020). Libro Blanco sobre la Inteligencia Artificial - un enfoque europeo orientado a la excelencia y la confianza. *Comisión Europea*, 1–31. [https://ec.europa.eu/info/sites/info/files/commission-white-paper-artificial-intelligence-feb2020\\_es.pdf](https://ec.europa.eu/info/sites/info/files/commission-white-paper-artificial-intelligence-feb2020_es.pdf)
- Commission, E. (2018). *Artificial Intelligence for Europe - Communication*. <https://ec.europa.eu/transparency/regdoc/rep/1/2018/EN/COM-2018-237-F1-EN-MAIN-PART-1.PDF>
- Dastin, J. (2005). *Amazon scraps secret AI recruiting tool that showed bias against women*. <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight-idUSKCN1MK08G>
- DataRobot. (2021). *DataRobot*. <https://www.datarobot.com/wiki/interpretability/>

- Day, M. (2016). *How LinkedIn's search engine may reflect a gender bias*. The Seattle Times. <https://www.seattletimes.com/business/microsoft/how-linkedins-search-engine-may-reflect-a-bias/>
- De Haan, E., Kannan, P. K., Verhoef, P. C., & Wiesel, T. (2015). The Role of Mobile Devices in the Online Customer Journey. *Marketing Science Institute Working Paper Series 2015, Report No. 15-124, Forthcoming, Report No. 15-124*, 1–56.
- De Keyser, A., Lemon, K. N., Klaus, P., & Keiningham, T. L. (2015). A Framework for Understanding and Managing the CX. *Working Paper Series, 15(121)*, 1–47.
- Digitales, S., Unidos, E., Europa, H., & Digital, P. E. (2020). *Los Estados miembros y la Comisión colaborarán para impulsar la inteligencia artificial « fabricada en Europa » Contexto Más información*. 2019–2021.
- Dixon, M., Freeman, K., & Toman, N. (2010). Stop trying to delight your customers. *Harvard Business Review, 88(7–8)*.
- Do, H. H., Prasad, P. W. C., Maag, A., & Alsadoon, A. (2019). Deep Learning for Aspect-Based Sentiment Analysis: A Comparative Review. *Expert Systems with Applications, 118*, 272–299. <https://doi.org/10.1016/j.eswa.2018.10.003>
- Doshi-Velez, F., & Kim, B. (2017). *Towards A Rigorous Science of Interpretable Machine Learning*. *ML*, 1–13. <http://arxiv.org/abs/1702.08608>
- Doshi-Velez, F., & Kim, B. (2018). *Considerations for Evaluation and Generalization in Interpretable Machine Learning*. 3–17. [https://doi.org/10.1007/978-3-319-98131-4\\_1](https://doi.org/10.1007/978-3-319-98131-4_1)
- Duval, A. (2019). *Explainable Artificial Intelligence ( XAI ) Explainable Artificial*. April. <https://doi.org/10.13140/RG.2.2.24722.09929>
- European Commission. (2019). *COM(2019) 168 final Building Trust in Human Centric Artificial Intelligence*. 11. <https://ec.europa.eu/digital-single-market/en/news/communication-building-trust-human-centric-artificial-intelligence>
- Fast Company. (2019). *I applied for an Apple Card. What they offered was a sexist insult*. <https://www.fastcompany.com/90429224/i-applied-for-an-apple-card-what-they-offered-was-a-sexist-insult>
- Figalst, I., Elsner, C., Bosch, J., & Olsson, H. H. (2019). Customer churn prediction in B2B contexts. *Lecture Notes in Business Information Processing, 370 LNBIP(January)*, 378–386. [https://doi.org/10.1007/978-3-030-33742-1\\_30](https://doi.org/10.1007/978-3-030-33742-1_30)
- Fisher, A., Rudin, C., & Dominici, F. (2019). All models are wrong, but many are useful: Learning a variable's importance by studying an entire class of prediction models simultaneously. *Journal of Machine Learning Research, 20(Vi)*.
- Friedman, J. (2001). Greedy Function Approximation : A Gradient Boosting Machine Author ( s ): Jerome H . Friedman Source : The Annals of Statistics , Vol . 29 , No . 5 ( Oct . , 2001 ) , pp . 1189-1232 Published by : Institute of Mathematical Statistics

- Stable URL : [http://www. The Annals of Statistics](http://www.TheAnnalsofStatistics.com), 29(5), 1189–1232.  
<https://www.jstor.org/stable/2699986>
- Gartner. (2021). *Gartner Magic Quadrant for CRM Customer Engagement Center*.  
<https://www.salesforce.com/news/stories/salesforce-is-a-leader-in-2021-gartner-magic-quadrant-for-crm-customer-engagement-center/>
- Goguen, J. A. (1973). L. A. Zadeh. Fuzzy sets. *Information and control*, vol. 8 (1965), pp. 338–353. - L. A. Zadeh. Similarity relations and fuzzy orderings. *Information sciences*, vol. 3 (1971), pp. 177–200. *Journal of Symbolic Logic*, 38(4), 656–657.  
<https://doi.org/10.2307/2272014>
- Goldstein, A., Kapelner, A., Bleich, J., & Pitkin, E. (2015). Peeking Inside the Black Box: Visualizing Statistical Learning With Plots of Individual Conditional Expectation. *Journal of Computational and Graphical Statistics*, 24(1), 44–65.  
<https://doi.org/10.1080/10618600.2014.907095>
- Golovin, D., Solnik, B., Moitra, S., Kochanski, G., Karro, J., & Sculley, D. (2017). Google vizier: A service for black-box optimization. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Part F1296*, 1487–1496. <https://doi.org/10.1145/3097983.3098043>
- Goodman, B., & Flaxman, S. (2017). European union regulations on algorithmic decision making and a “right to explanation.” *AI Magazine*, 38(3), 50–57.  
<https://doi.org/10.1609/aimag.v38i3.2741>
- Govender, P., & Sivakumar, V. (2020). Application of k-means and hierarchical clustering techniques for analysis of air pollution: A review (1980–2019). *Atmospheric Pollution Research*, 11(1), 40–56. <https://doi.org/10.1016/j.apr.2019.09.009>
- Grewal, D., Levy, M., & Kumar, V. (2009). Customer Experience Management in Retailing: An Organizing Framework. *Journal of Retailing*, 85(1), 1–14.  
<https://doi.org/10.1016/j.jretai.2009.01.001>
- Gunning, D., Stefik, M., Choi, J., Miller, T., Stumpf, S., & Yang, G. Z. (2019). XAI- Explainable artificial intelligence. *Science Robotics*, 4(37), 0–1.  
<https://doi.org/10.1126/scirobotics.aay7120>
- Gupta, S., & Zeithaml, V. (2006). Customer metrics and their impact on financial performance. *Marketing Science*, 25(6), 718–739.  
<https://doi.org/10.1287/mksc.1060.0221>
- Gurumoorthy, K. S., & Cecchi, G. (n.d.). *Efficient Data Representation by Selecting Prototypes with Importance Weights*.
- H2O.ai. (2020). *H2O Driverless AI*. <https://www.h2o.ai/products/h2o-driverless-ai/>
- Haggerty, C. M., Damrauer, S. M., Levin, M. G., Birtwell, D., Carey, D. J., Golden, A. M., Hartzel, D. N., Hu, Y., Judy, R., Kelly, M. A., Kember, R. L., Lester Kirchner, H., Leader, J. B., Liang, L., Mcdermott-Roe, C., Babu, A., Morley, M., Nealy, Z., Person,

- T. N., ... Arany, Z. (2019). Genomics-First Evaluation of Heart Disease Associated With Titin-Truncating Variants. *Circulation*, *140*(1), 42–54. <https://doi.org/10.1161/CIRCULATIONAHA.119.039573>
- Hamilton, M., Kaltcheva, V. D., & Rohm, A. J. (2016). Social Media and Value Creation: The Role of Interaction Satisfaction and Interaction Immersion. *Journal of Interactive Marketing*, *36*, 121–133. <https://doi.org/10.1016/j.intmar.2016.07.001>
- Hanley, J. A., & McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, *143*(1), 29–36. <https://doi.org/10.1148/radiology.143.1.7063747>
- Heldt, R., Silveira, C. S., & Luce, F. B. (2021). Predicting customer value per product: From RFM to RFM/P. *Journal of Business Research*, *127*, 444–453. <https://doi.org/10.1016/j.jbusres.2019.05.001>
- Herrera, F., Herrera-Viedma, E., & Martínez, L. (2000). A fusion approach for managing multi-granularity linguistic term sets in decision making. *Fuzzy Sets and Systems*, *114*(1), 43–58. [https://doi.org/10.1016/S0165-0114\(98\)00093-1](https://doi.org/10.1016/S0165-0114(98)00093-1)
- Herrera, F., & Martinez, L. (2000). An approach for combining linguistic and numerical information based on the 2-tuple fuzzy linguistic representation model in decision-making. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, *8*(5), 539–562. <https://doi.org/10.1142/S0218488500000381>
- Herrera, F., Martínez, L., & Sánchez, P. J. (2005). Managing non-homogeneous information in group decision making. *European Journal of Operational Research*, *166*(1 SPEC. ISS.), 115–132. <https://doi.org/10.1016/j.ejor.2003.11.031>
- Herrera, Francisco, & Martínez, L. (2000). A 2-tuple fuzzy linguistic representation model for computing with words. *IEEE Transactions on Fuzzy Systems*, *8*(6), 746–752. <https://doi.org/10.1109/91.890332>
- Hilken, T., Heller, J., Chylinski, M., Keeling, D. I., Mahr, D., & de Ruyter, K. (2018). Making omnichannel an augmented reality: the current and future state of the art. *Journal of Research in Interactive Marketing*, *12*(4), 509–523. <https://doi.org/10.1108/JRIM-01-2018-0023>
- Honegger, M. R. (2018). *Shedding Light on Black Box Machine Learning Algorithms*. August.
- Hsieh, N. C. (2004). An integrated data mining and behavioral scoring model for analyzing bank customers. *Expert Systems with Applications*, *27*(4), 623–633. <https://doi.org/10.1016/j.eswa.2004.06.007>
- Hughes, A. M. (1994). *Strategic database marketing*. Probus Publishing Company.
- Hughes, R., Edmond, C., Wells, L., Glencross, M., Zhu, L., & Bednarz, T. (2020). *eXplainable AI (XAI)*. 1–62. <https://doi.org/10.1145/3415263.3419166>
- Hwang, S., & Lee, Y. (2021). Identifying customer priority for new products in target marketing: Using RFM model and TextRank. *Innovative Marketing*, *17*(2), 125–136.

[https://doi.org/10.21511/im.17\(2\).2021.12](https://doi.org/10.21511/im.17(2).2021.12)

- Iwu, C. G., Opute, A. P., Aliyu, O. A., Eresia-Eke, C., Musikavanhu, T. B., & Jaiyeola, A. O. (2021). A Structural Equation Modelling Evaluation of Antecedents and Interconnections of Call Centre Agents' Intention to Quit. *Journal of Risk and Financial Management*, 14(4), 179. <https://doi.org/10.3390/jrfm14040179>
- Jahnert, J. R., & Schmeiser, H. (2021). The relationship between net promoter score and insurers' profitability: an empirical analysis at the customer level. *Geneva Papers on Risk and Insurance: Issues and Practice*, 0123456789. <https://doi.org/10.1057/s41288-021-00237-3>
- Jain, D., & Singh, S. S. (2002). CUSTOMER LIFETIME VALUE RESEARCH IN MARKETING : A REVIEW AND FUTURE DIRECTIONS. 16(2), 34–46. <https://doi.org/10.1002/dir.10032>
- Jayachandran, S., Sharma, S., Kaufman, P., & Raman, P. (2005). The role of relational information processes and technology use in customer relationship management. *Journal of Marketing*, 69(4), 177–192. <https://doi.org/10.1509/jmkg.2005.69.4.177>
- Kahneman, D., & Tversky, A. (1981). The Simulation Heuristic. *University of British Columbia*.
- Kahng, M., Andrews, P. Y., Kalro, A., & Chau, D. H. P. (2018). ActiVis: Visual Exploration of Industry-Scale Deep Neural Network Models. *IEEE Transactions on Visualization and Computer Graphics*, 24(1), 88–97. <https://doi.org/10.1109/TVCG.2017.2744718>
- Khaira, A., & Dwivedi, R. K. (2018). A State of the Art Review of Analytical Hierarchy Process. *Materials Today: Proceedings*, 5(2), 4029–4035. <https://doi.org/10.1016/j.matpr.2017.11.663>
- Khajvand, M., & Tarokh, M. J. (2011). Estimating customer future value of different customer segments based on adapted RFM model in retail banking context. *Procedia Computer Science*, 3, 1327–1332. <https://doi.org/10.1016/j.procs.2011.01.011>
- Khajvand, M., Zolfaghar, K., Ashoori, S., & Alizadeh, S. (2011). Estimating customer lifetime value based on RFM analysis of customer purchase behavior: Case study. *Procedia Computer Science*, 3, 57–63. <https://doi.org/10.1016/j.procs.2010.12.011>
- King, S. F. (2007). Citizens as customers: Exploring the future of CRM in UK local government. *Government Information Quarterly*, 24(1), 47–63. <https://doi.org/10.1016/j.giq.2006.02.012>
- Korneta, P. (2018). Net promoter score, growth, and profitability of transportation companies. *International Journal of Management and Economics*, 54(2), 136–148. <https://doi.org/10.2478/ijme-2018-0013>
- Kotler. (2016). *Marketing management*. <https://www.pearson.com/uk/educators/higher-education-educators/program/Kotler-Marketing-Management-3rd-edn-3rd->

Edition/PGM1093412.html

- Kumar, R. S., Saviour Devaraj, A. F., Rajeswari, M., Julie, E. G., Robinson, Y. H., & Shanmuganathan, V. (2021). Exploration of sentiment analysis and legitimate artistry for opinion mining. *Multimedia Tools and Applications*.  
<https://doi.org/10.1007/s11042-020-10480-w>
- Kumar, V., Aksoy, L., Donkers, B., Venkatesan, R., Wiesel, T., & Tillmanns, S. (2010). Undervalued or overvalued customers: Capturing total customer engagement value. *Journal of Service Research*, 13(3), 297–310.  
<https://doi.org/10.1177/1094670510375602>
- Kumar, V., Rajan, B., Gupta, S., & Pozza, I. D. (2019). Customer engagement in service. *Journal of the Academy of Marketing Science*, 47(1), 138–160.  
<https://doi.org/10.1007/s11747-017-0565-2>
- Kumar, V., & Reinartz, W. (2012). *Strategic Customer Relationship Management Today*. 3–20. [https://doi.org/10.1007/978-3-642-20110-3\\_1](https://doi.org/10.1007/978-3-642-20110-3_1)
- Kumar, V., & Reinartz, W. (2018). Customer Relationship Management : Concept, Strategy, and Tools LK - <https://ucm.on.worldcat.org/oclc/1050446648>. In *Springer Texts in Business and Economics TA - TT* - (3rd ed.). Springer.
- Kumar, V., Venkatesan, R., Bohling, T., & Beckmann, D. (2008). The power of CLV: Managing customer lifetime value at IBM. *Marketing Science*, 27(4), 585–599.  
<https://doi.org/10.1287/mksc.1070.0319>
- Larson, J., Mattu, S., Kirchner, L., & Angwin, J. (2016). *How We Analyzed the COMPAS Recidivism Algorithm*. ProPublica. <https://www.propublica.org/article/how-we-analyzed-the-compas-recidivism-algorithm>
- Lemon, K. N., & Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of Marketing*, 80(6), 69–96.  
<https://doi.org/10.1509/jm.15.0420>
- Li, Y. M., Lin, C. H., & Lai, C. Y. (2010). Identifying influential reviewers for word-of-mouth marketing. *Electronic Commerce Research and Applications*, 9(4), 294–304.  
<https://doi.org/10.1016/j.elerap.2010.02.004>
- Linardatos, P., Papastefanopoulos, V., & Kotsiantis, S. (2021). Explainable ai: A review of machine learning interpretability methods. *Entropy*, 23(1), 1–45.  
<https://doi.org/10.3390/e23010018>
- Lipton, P. (1990). Contrastive explanation. *Contrastivism in Philosophy*, 11–34.  
<https://doi.org/10.4324/9780203117477>
- Lipton, Z. C. (2018). The mythos of model interpretability. *Communications of the ACM*, 61(10), 35–43. <https://doi.org/10.1145/3233231>
- Liu, D. R., & Shih, Y. Y. (2005). Integrating AHP and data mining for product recommendation based on customer lifetime value. *Information and Management*,

- 42(3), 387–400. <https://doi.org/10.1016/j.im.2004.01.008>
- Liu, H., Cocea, M., & Gegov, A. (2016). Interpretability of computational models for sentiment analysis. *Studies in Computational Intelligence*, 639(March), 199–220. [https://doi.org/10.1007/978-3-319-30319-2\\_9](https://doi.org/10.1007/978-3-319-30319-2_9)
- Lu, W. (2020). Improved K-Means Clustering Algorithm for Big Data Mining under Hadoop Parallel Framework. *Journal of Grid Computing*, 18(2), 239–250. <https://doi.org/10.1007/s10723-019-09503-0>
- Lumsden, S.-A., Beldona, S., & Morrison, A. M. (2008). Customer Value in an All-Inclusive Travel Vacation Club: An Application of the RFM Framework. *Http://Dx.Doi.Org/10.1080/10507050801946858*, 16(3), 270–285. <https://doi.org/10.1080/10507050801946858>
- Lundberg, S. M., Erion, G. G., & Lee, S.-I. (2018). *Consistent Individualized Feature Attribution for Tree Ensembles*. 2. <http://arxiv.org/abs/1802.03888>
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems, 2017-Decem*(Section 2), 4766–4775.
- Mahdiraji, H. A., Kazimieras Zavadskas, E., Kazemina, A., & Abbasi Kamardi, A. A. (2019). Marketing strategies evaluation based on big data analysis: a CLUSTERING-MCDM approach. *Economic Research-Ekonomska Istrazivanja*, 32(1), 2882–2898. <https://doi.org/10.1080/1331677X.2019.1658534>
- Marín Díaz, G., Carrasco, R. A., & Gómez, D. (2021a). *Interpretability Challenges in Machine Learning Models*. 205–217.
- Marín Díaz, G., Carrasco, R. A., & Gómez, D. (2021b). RFID: A Fuzzy Linguistic Model to Manage Customers from the Perspective of Their Interactions with the Contact Center. *Mathematics*, 9(19), 2362. <https://doi.org/10.3390/math9192362>
- Marrone, M., & Kolbe, L. M. (2011). Impact of IT Service Management Frameworks on the IT Organization. *Business & Information Systems Engineering*, 3(1), 5–18. <https://doi.org/10.1007/s12599-010-0141-5>
- Martínez, R. G., Carrasco, R. A., García-Madariaga, J., Gallego, C. P., & Herrera-Viedma, E. (2019). A comparison between Fuzzy Linguistic RFM Model and traditional RFM model applied to Campaign Management. Case study of retail business. *Procedia Computer Science*, 162(Itqm), 281–289. <https://doi.org/10.1016/j.procs.2019.11.286>
- Mccarty, J. A., & Hastak, M. (2007). *Segmentation approaches in data-mining : A comparison of RFM , CHAID , and logistic regression*. 60, 656–662. <https://doi.org/10.1016/j.jbusres.2006.06.015>
- Microsoft. (2021). *Instalar el SDK de Azure Machine Learning para Python*. <https://docs.microsoft.com/es-es/python/api/overview/azure/ml/install?preserve->

view=true&view=azure-ml-py

- Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. *Artificial Intelligence*, 267, 1–38. <https://doi.org/10.1016/j.artint.2018.07.007>
- Milner, J. M., & Olsen, T. L. (2008). Service-level agreements in call centers: Perils and prescriptions. *Management Science*, 54(2), 238–252. <https://doi.org/10.1287/mnsc.1070.0777>
- Mohammadzadeh, M., Hoseini, Z. Z., & Derafshi, H. (2017). A data mining approach for modeling churn behavior via RFM model in specialized clinics Case study: A public sector hospital in Tehran. *Procedia Computer Science*, 120, 23–30. <https://doi.org/10.1016/j.procs.2017.11.206>
- Molnar, C. (2019). Interpretable Machine Learning. A Guide for Making Black Box Models Explainable. *Book*, 247. <https://christophm.github.io/interpretable-ml-book>
- Monalisa, S., Nadya, P., & Novita, R. (2019). Analysis for customer lifetime value categorization with RFM model. *Procedia Computer Science*, 161, 834–840. <https://doi.org/10.1016/j.procs.2019.11.190>
- Morgan, N. A., & Rego, L. L. (2006). The value of different customer satisfaction and loyalty metrics in predicting business performance. *Marketing Science*, 25(5), 426–439. <https://doi.org/10.1287/mksc.1050.0180>
- Moro, S., Cortez, P., & Rita, P. (2015). Using customer lifetime value and neural networks to improve the prediction of bank deposit subscription in telemarketing campaigns. *Neural Computing and Applications*, 26(1), 131–139. <https://doi.org/10.1007/s00521-014-1703-0>
- Mulhern, F. (2007). *Understanding and Using Customer Loyalty and Customer Value*. March 2015. <https://doi.org/10.1300/J366v06n03>
- Munchen, T. U. (2021). European approach to Artificial Intelligence. *E-Conversion - Proposal for a Cluster of Excellence*, 29–50. <https://ec.europa.eu/digital-single-market/en/news/communication-building-trust-human-centric-artificial-intelligence>
- Nickerson, R. S. (1998). Confirmation Bias: A Ubiquitous Phenomenon in Many Guises. *Zeitschrift Für Neurologie*, 199(1–2), 145–150. <https://doi.org/10.1007/BF00316552>
- Oztemel, E., & Gursev, S. (2020). Literature review of Industry 4.0 and related technologies. *Journal of Intelligent Manufacturing*, 31(1), 127–182. <https://doi.org/10.1007/s10845-018-1433-8>
- P. Bradley, A. (1997). The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7), 1145–1159.
- Parasuraman, A., Zeithaml, V. A., & Berry, L. L. (1985). A Conceptual Model of Service Quality and Its Implications for Future Research. *Journal of Marketing*, 49(4), 41. <https://doi.org/10.2307/1251430>

- Payne, A., & Frow, P. (2004). The role of multichannel integration in customer relationship management. *Industrial Marketing Management*, 33(6), 527–538. <https://doi.org/10.1016/j.indmarman.2004.02.002>
- Perisic, A., & Pahor, M. (2020). Extended RFM logit model for churn prediction in the mobile gaming market. *Croatian Operational Research Review*, 11(2), 249–261. <https://doi.org/10.17535/crorr.2020.0020>
- Rahim, M. A., Mushafiq, M., Khan, S., & Arain, Z. A. (2021). RFM-based repurchase behavior for customer classification and segmentation. *Journal of Retailing and Consumer Services*, 61, 102566. <https://doi.org/10.1016/j.jretconser.2021.102566>
- Rameshbabu, A., Reddy, D. M., & Fleming, R. (2013). Correlates of negative physical health in call center shift workers. *Applied Ergonomics*, 44(3), 350–354. <https://doi.org/10.1016/j.apergo.2012.09.002>
- Reichheld, F. F. (2003). *The One Number You Need to Grow*. [www.hbr.org](http://www.hbr.org)
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016a). *Model-Agnostic Interpretability of Machine Learning*. *Whi*. <http://arxiv.org/abs/1606.05386>
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016b). “Why Should I Trust You?” Explaining the Predictions of Any Classifier. *NAACL-HLT 2016 - 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Proceedings of the Demonstrations Session*, 97–101. <https://doi.org/10.18653/v1/n16-3020>
- Robinson, G., & Morley, C. (2006). Call centre management: Responsibilities and performance. *International Journal of Service Industry Management*, 17(3), 284–300. <https://doi.org/10.1108/09564230610667122>
- Rocks, B. (2016). Interval Estimation for the “Net Promoter Score.” *American Statistician*, 70(4), 365–372. <https://doi.org/10.1080/00031305.2016.1158124>
- Ross, C. (2018). Watson for Oncology. *STAT*, 1–30. [papers3://publication/uuid/5566F158-417A-46D3-B583-04EE273812A1](https://papers3://publication/uuid/5566F158-417A-46D3-B583-04EE273812A1)
- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20(C), 53–65. [https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- Roy, M. (2017). Cathy O’Neil. *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy*. New York: Crown Publishers, 2016. 272p. Hardcover, \$26 (ISBN 978-0553418811). In *College & Research Libraries* (Vol. 78, Issue 3). <https://doi.org/10.5860/crl.78.3.403>
- Royal Society of Great Britain. (2017). *Machine learning : the power and promise of computers that learn by example*. In *Report by the Royal Society* (Vol. 66, Issue January).
- Rudin, C. (2019). Stop explaining black box machine learning models for high stakes

- decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
- Ryu, K., & Kim, W. (2018). *A Study on Contact Center Evaluation Model Using AHP and Content Analysis*. 19(5), 106–116.
- Saaty, T. L. (2002). Decision making with the Analytic Hierarchy Process. *Scientia Iranica*, 9(3), 215–229. <https://doi.org/10.1504/IJSSCI.2008.017590>
- Saaty, Thomas L. (2013). The modern science of multicriteria decision making and its practical applications: The AHP/ANP approach. *Operations Research*, 61(5), 1101–1118. <https://doi.org/10.1287/OPRE.2013.1197>
- Saaty, Thomas L. (1980). The analytic hierarchy process : planning, priority setting, resource allocation LK - <https://ucm.on.worldcat.org/oclc/911278091>. In *TA - TT -*. McGraw-Hill International Book Co.
- Saberi, M., Khadeer Hussain, O., & Chang, E. (2017). Past, present and future of contact centers: a literature review. *Business Process Management Journal*, 23(3), 574–597. <https://doi.org/10.1108/BPMJ-02-2015-0018>
- Saghiri, S., Wilding, R., Mena, C., & Bourlakis, M. (2017). Toward a three-dimensional framework for omni-channel. *Journal of Business Research*, 77(March), 53–67. <https://doi.org/10.1016/j.jbusres.2017.03.025>
- Samad, M. D., Ulloa, A., Wehner, G. J., Jing, L., Hartzel, D., Good, C. W., Williams, B. A., Haggerty, C. M., & Fornwalt, B. K. (2019). Predicting Survival From Large Echocardiography and Electronic Health Record Datasets: Optimization With Machine Learning. *JACC: Cardiovascular Imaging*, 12(4), 681–689. <https://doi.org/10.1016/j.jcmg.2018.04.026>
- Sembiring Brahmana, R. W., Mohammed, F. A., & Chairuang, K. (2020). Customer Segmentation Based on RFM Model Using K-Means, K-Medoids, and DBSCAN Methods. *Lontar Komputer : Jurnal Ilmiah Teknologi Informasi*, 11(1), 32. <https://doi.org/10.24843/lkjiti.2020.v11.i01.p04>
- Shafique, U., & Qaiser, H. (2014). A Comparative Study of Data Mining Process Models ( KDD , CRISP-DM and SEMMA ). *International Journal of Innovation and Scientific Research*, 12(1), 217–222. <http://www.ijisr.issr-journals.org/>
- Shen, X. L., Li, Y. J., Sun, Y., & Wang, N. (2018). Channel integration quality, perceived fluency and omnichannel service usage: The moderating roles of internal and external usage experience. *Decision Support Systems*, 109, 61–73. <https://doi.org/10.1016/j.dss.2018.01.006>
- Shih, Y.-Y., & Liu, C.-Y. (2003). A method for customer lifetime value ranking — Combining the analytic hierarchy process and clustering analysis. *Journal of Database Marketing & Customer Strategy Management*, 11(2), 159–172. <https://doi.org/10.1057/palgrave.dbm.3240216>

- Sohrabi, B., & Khanlari, A. (2007). Customer Lifetime Value (CLV) Measurement Based on RFM Model. *Iranian Accounting & Auditing Review*, 14(47), 7–20.
- Standardization, I. O. (2021). ISO. International Organization for Standardization. <https://www.iso.org/committee/6794475.html>
- Stormi, K., Lindholm, A., Laine, T., & Korhonen, T. (2020). RFM customer analysis for product-oriented services and service business development: an interventionist case study of two machinery manufacturers. *Journal of Management and Governance*, 24(3), 623–653. <https://doi.org/10.1007/s10997-018-9447-3>
- Sundararajan, M., Taly, A., & Yan, Q. (2017). Axiomatic attribution for deep networks. *ArXiv*.
- Syakur, M. A., Khotimah, B. K., Rochman, E. M. S., & Satoto, B. D. (2018). Integration K-Means Clustering Method and Elbow Method for Identification of the Best Customer Profile Cluster. *IOP Conference Series: Materials Science and Engineering*, 336(1). <https://doi.org/10.1088/1757-899X/336/1/012017>
- Tan, S., Caruana, R., Hooker, G., & Lou, Y. (2018). Distill-and-Compare: Auditing Black-Box Models Using Transparent Model Distillation. *AIES 2018 - Proceedings of the 2018 AAI/ACM Conference on AI, Ethics, and Society*, 303–310. <https://doi.org/10.1145/3278721.3278725>
- Thomas L. Saaty. (2008). Decision making with the analytic hierarchy process. *Journal of Manufacturing Technology Management*, 26(6), 791–806. <https://doi.org/10.1108/JMTM-03-2014-0020>
- UE. (2016). *Artículo 22 UE RGDP*. <https://www.privacy-regulation.eu/es/22.htm>
- UNE. (2021). *UNE Normalización Española*. [https://www.une.org/encuentra-tu-norma/comites-tecnicos-de-normalizacion/comite/?c=CTN 71/SC 42](https://www.une.org/encuentra-tu-norma/comites-tecnicos-de-normalizacion/comite/?c=CTN%2071/SC%2042)
- van Doorn, J., Leeflang, P. S. H., & Tijs, M. (2013). Satisfaction as a predictor of future performance: A replication. *International Journal of Research in Marketing*, 30(3), 314–318. <https://doi.org/10.1016/j.ijresmar.2013.04.002>
- van Dun, Z., Bloemer, J., & Henseler, J. (2011). Perceived customer contact centre quality: Conceptual foundation and scale development. *Service Industries Journal*, 31(8), 1347–1363. <https://doi.org/10.1080/02642060903437584>
- Van Vlasselaer, V., Bravo, C., Caelen, O., Eliassi-Rad, T., Akoglu, L., Snoeck, M., & Baensens, B. (2015). APATE: A novel approach for automated credit card transaction fraud detection using network-based extensions. *Decision Support Systems*, 75, 38–48. <https://doi.org/10.1016/j.dss.2015.04.013>
- Venkatesan, R., & Kumar, V. (2004). Framework for Customer Selection. *Journal of Marketing*, 68(October), 106–125.
- Verhoef, P. C. (2003). Understanding the Effect of Customer Relationship Management Efforts on Customer Retention and Customer Share Development. *Journal of*

- Marketing*, 67(4), 30–45. <https://doi.org/10.1509/jmkg.67.4.30.18685>
- Verhoef, P. C., Broekhuizen, T., Bart, Y., Bhattacharya, A., Dong, J. Q., Fabian, N., & Haenlein, M. (2021). *Digital transformation : A multidisciplinary reflection and research agenda* ☆. 122(November 2019), 889–901. <https://doi.org/10.1016/j.jbusres.2019.09.022>
- Verhoef, P. C., Kannan, P. K., & Inman, J. J. (2015). From Multi-Channel Retailing to Omni-Channel Retailing. Introduction to the Special Issue on Multi-Channel Retailing. *Journal of Retailing*, 91(2), 174–181. <https://doi.org/10.1016/j.jretai.2015.02.005>
- Wallace, D. W., Giese, J. L., & Johnson, J. L. (2004). Customer retailer loyalty in the context of multiple channel strategies. *Journal of Retailing*, 80(4), 249–263. <https://doi.org/10.1016/j.jretai.2004.10.002>
- Wang, C., Deng, C., & Wang, S. (2020). Imbalance-XGBoost: leveraging weighted and focal losses for binary label-imbalanced classification with XGBoost. *Pattern Recognition Letters*, 136, 190–197. <https://doi.org/10.1016/j.patrec.2020.05.035>
- Wei, J., Lin, S., & Wu, H. (2010). A review of the application of RFM model. *African Journal of Business Management*, 4(19), 4199–4206.
- Weller, A. (2019). Transparency: Motivations and Challenges. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11700 LNCS(Section 2), 23–40. [https://doi.org/10.1007/978-3-030-28954-6\\_2](https://doi.org/10.1007/978-3-030-28954-6_2)
- Wu, J., Shi, L., Lin, W.-P., Tsai, S.-B., Li, Y., Yang, L., & Xu, G. (2020). *An Empirical Study on Customer Segmentation by Purchase Behaviors Using a RFM Model and K-Means Algorithm*. <https://doi.org/10.1155/2020/8884227>
- Yeh, I. C., Yang, K. J., & Ting, T. M. (2009). Knowledge discovery on RFM model using Bernoulli sequence. *Expert Systems with Applications*, 36(3), 5866–5871. <https://doi.org/10.1016/J.ESWA.2008.07.018>
- Zafar, M. R., & Khan, N. M. (2019). *DLIME: A Deterministic Local Interpretable Model-Agnostic Explanations Approach for Computer-Aided Diagnosis Systems*. <http://arxiv.org/abs/1906.10263>
- Zeithaml, V. A., & Berry, L. L. (1988). *A multiple- Item Scale for measuring consumer perceptions of service quality*. January.
- Zeithaml, V. A., Berry, L. L., & Parasuraman, A. (1996). The behavioral consequences of service quality. *Journal of Marketing*, 60(2), 31–46. <https://doi.org/10.2307/1251929>
- Zhang, J., Wang, Y., Molino, P., Li, L., & Ebert, D. S. (2018). Manifold: A model-agnostic framework for interpretation and diagnosis of machine learning models. *ArXiv*, 25(1), 364–373.
- Zong, Y., & Xing, H. (2021). Customer stratification theory and value evaluation-

analysis based on improved RFM model. *Journal of Intelligent and Fuzzy Systems*, 40(3), 4155–4167. <https://doi.org/10.3233/JIFS-200737>