

UNIVERSIDAD COMPLUTENSE DE MADRID

FACULTAD DE CIENCIAS FÍSICAS

Máster en Nuevas Tecnologías Electrónicas y Fotónicas



TRABAJO DE FIN DE MÁSTER

**Diseño y Simulación de un Sistema
para el Control de Contaminantes en Embalses**

María Caro Huertas

Directores:

José Antonio López Orozco

Eva Besada Portas

CURSO ACADÉMICO 2018-19

Junio 2019

*A mis hermanos,
porque gran parte de lo que soy es gracias a ellos.*

*Y, por supuesto, a mis padres,
por estar ahí siempre.*

Abstract

Reservoir water quality monitoring is a current problem of great impact in multiple areas: social, economic, environmental, etc. To date, the methodology followed to monitor the level of pollution is very localized. This prevents the continuous monitoring of the physical-chemical parameters that define the water quality throughout the entire body of the reservoir. This problem can be solved by using autonomous surface vehicles equipped with suitable measuring instruments which are capable of exploring the extension and depth of the reservoir. To concentrate exploration efforts on the areas of greater interest in each scenario, in this Master's Thesis, a planning tool has been developed to determine the most efficient routes to be followed by such vehicle in a given contamination scenario. The planning is carried out in two successive stages: in the first, the route of the vehicles that maximizes the observed contaminated area is determined; and, in the second, the height at which the sensor must be submerged along the vehicle's path is calculated. The performance of the developed planner, which takes into account the vehicle dynamics and simplified location models of the pollutants, is statistically characterized for different scenarios. The obtained results show that the first planning stage find routes that transverse areas with high concentration of pollutants, while the second stage determines the sensor height to the pollutant distribution.

Keywords: water quality; unmanned surface vehicle; trajectory planning; genetic algorithms.

Resumen

El seguimiento de la calidad de las aguas embalsadas supone un problema actual de gran repercusión en todos los ámbitos: social, económico, medioambiental, etc. Hasta la fecha, la metodología por la que se lleva a cabo la monitorización de los contaminantes es muy local, no permitiendo tener un conocimiento continuo, a lo largo de todo el volumen de agua, de los parámetros físico-químicos que determinan su estado. Este problema puede ser resuelto mediante embarcaciones autónomas equipadas con instrumentos de medida adecuados que sean capaces de explorar la extensión y profundidad del embalse. Para concentrar los esfuerzos de exploración en las zonas de mayor interés en cada escenario, en este Trabajo Fin de Máster se ha desarrollado una herramienta de planificación con la que se obtienen las rutas más eficientes a seguir por el vehículo en un escenario de contaminación dado. La planificación se realiza en dos etapas sucesivas: en la primera se determina la ruta de los vehículos que maximiza la zona contaminada observada y en la segunda se calcula la altura a la que se debe sumergir el sensor a lo largo de la trayectoria del vehículo. El comportamiento del planificador desarrollado, que tiene en cuenta la dinámica del vehículo y modelos simplificados de las manchas de contaminación, es caracterizado de forma estadística sobre diferentes escenarios. Los resultados obtenidos muestran que en su primera etapa consigue determinar rutas que, en la mayoría de los casos, pasan sobre las zonas de mayor contaminación, y que en su segunda etapa consigue adecuar la altura del sensor a la mancha del contaminante.

Palabras clave: calidad del agua; embarcación autónoma; planificación de trayectorias; algoritmos genéticos.

Índice

1. Introducción	1
1.1. Calidad de las aguas a lo largo de la historia	1
1.2. Motivación del Trabajo	2
1.3. Objetivos del Trabajo	3
1.4. Estructura de la memoria	4
2. Seguimiento de calidad de aguas embalsadas	4
2.1. Puntos de control	5
2.2. Tácticas de seguimiento	6
2.3. Incorporación de embarcaciones autónomas	7
2.4. Modelos hidrodinámicos	8
3. Definición y modelado del problema	11
3.1. Modelado del barco	11
3.1.1. Aspectos Generales del USV	12
3.1.2. Dinámica del Barco	12
3.1.3. Ecuaciones de Movimiento	13
3.2. Modelado de los contaminantes	17
4. Planificador	19
4.1. Algoritmos Genéticos	20
4.1.1. Población Inicial	21
4.1.2. Función Objetivo	21
4.1.3. Selección	22
4.1.4. Cruce	22
4.1.5. Mutación	23
4.1.6. Reproducción	24
4.2. Planificador I: trayectorias	24
4.3. Planificador II: altura de la sonda	25
5. Resultados	27
5.1. Metodología de análisis	27

5.2. Parametrización del planificador	30
5.2.1. Puntos de cruce	30
5.2.2. Multiobjetivo	32
5.3. Planificador I	35
5.3.1. Partículas móviles	36
5.3.2. Varios barcos	37
5.4. Planificador II	40
6. Conclusiones y trabajo futuro	43
6.1. Conclusiones	43
6.2. Trabajo futuro	45

1. Introducción

La calidad del agua juega un papel fundamental en el desarrollo social, económico y medioambiental del planeta, puesto que es uno de los recursos de los que depende la vida de forma directa. La Tierra es el Planeta Azul porque la mayor parte de su superficie –el 70%– está cubierta por agua. Sin embargo, tan solo un pequeño porcentaje es apto para el consumo. El volumen total de agua estimado es del orden de $1,3 \cdot 10^9 \text{ km}^3$, del cual el 2,5 % es agua dulce [1].

Los ríos, lagos, arroyos y manantiales naturales son considerados como fuentes de agua superficial y componen la última fracción del porcentaje de agua dulce de la Tierra: el 0,0014% (no se considera la masa de agua presente en la humedad del suelo o acuíferos, en la lluvia, o la parte solidificada en glaciares) [1, 2].

Aunque en la Tierra existen millones de lagos de agua dulce y muchos kilómetros de arroyos y ríos, la cantidad de agua dulce que simbolizan estas fuentes de agua es insignificante, pero de gran valor. La mayor parte del volumen de agua potable destinado al consumo procede de ellos. Es por esto que el agua superficial sigue siendo una de las fuentes más importantes de agua dulce del planeta.

El principal problema que se plantea a escala global es garantizar la disponibilidad de agua en cantidad y calidad suficiente. Las líneas de actuación preferentes para la gestión de un recurso tan escaso como preciado se fundamentan en promover un uso más eficiente de esta. Este objetivo se consigue mediante técnicas de ahorro, de gestión de la demanda, de reutilización, de uso conjunto de aguas subterráneas y superficiales, etc. y el empleo de técnicas no convencionales (desalinización). No obstante, no cabe duda que la construcción de nuevas presas y embalses seguirá siendo necesaria en la misma medida que la optimización de la explotación de los embalses ya existentes.

Estos son motivos más que suficientes para justificar la trascendencia de los estudios que se llevan a cabo para monitorizar y mejorar la calidad del agua en embalses y lagos.

1.1. Calidad de las aguas a lo largo de la historia

Desde hace más de 4000 años se conocen métodos para mejorar el olor y sabor del agua: los antiguos pueblos orientales la purificaban con arena y barro poroso; los griegos empleaban filtros a través de carbón, exposición a los rayos solares y ebullición; los romanos

instalaron filtros y separaron el agua según su uso (para el consumo o no); en el Antiguo Egipto se dejaba reposar en vasijas durante meses para precipitar las partículas, y luego extraerla con un sifón [3].

Hasta inicios del siglo XX, la calidad del agua destinada al abastecimiento se conseguía mediante unos tratamientos de decantación, filtración y desinfección muy sencillos; reconociendo su aptitud para el consumo en base a verificaciones de ausencia de sabores y olores.

A causa del aumento de las contaminaciones producidas por los procesos industriales del siglo XX, a finales de éste se planteó la necesidad de aplicar nuevas normativas y requisitos técnicos para mantener a salvo la salud de los consumidores.

En España se controla la calidad de las aguas superficiales de una manera sistemática desde el año 1962, en el que se creó la Red COCA (Control Oficial de la Calidad del Agua). Entonces las estaciones instaladas eran de muestreo manual. Actualmente, desde las estaciones que integran las nuevas redes de control –tales como la Red SAICA, que se comentará en la sección 2.2– se controlan los vertidos más significativos, midiendo parámetros como: temperatura, oxígeno disuelto, DBO5, sólidos en suspensión, coliformes, diversos aniones, metales pesados... con objeto de tener una visión global y representativa de la calidad de las aguas en el conjunto de la cuenca.

1.2. Motivación del Trabajo

Actualmente, en España se están desarrollando varios programas de seguimiento de calidad de aguas superficiales. En función del procedimiento que se sigue para realizar el muestreo se distinguen dos programas: uno de seguimiento periódico y otro de seguimiento automático. Se detallarán en más profundidad en la sección 2.2.

Ambos programas de seguimiento se soportan en estaciones de control para realizar el muestreo y obtener registros de parámetros físico-químicos, necesarios para la posterior evaluación y diagnóstico del estado del agua. Desde estas estaciones, la toma de medidas se hace en puntos concretos de los embalses con sondas situadas en las orillas o en las presas, o en su interior empleando boyas estáticas. Este método presenta varias desventajas y carencias en cuanto a la gestión y monitorización integral de la calidad del agua.

A pesar de que los instrumentos con los que se lleva a cabo la recogida de información están dispuestos puntualmente en zonas estratégicas de la cuenca hidrográfica, no es posible tener una continuidad en los parámetros físico-químicos en el curso de todo el volumen

de la masa de agua. Es decir, con las actuales estaciones de alerta ciertamente se tiene información en tiempo real; sin embargo, no de todo el embalse, sino de pequeñas regiones muy localizadas.

Bien es cierto que este matiz puede no afectar a algunos casos aislados, en los que dada la disposición y condiciones del embalse (ya sea por su tamaño, profundidad, dinámica...), sí que es lícito admitir que las medidas locales cubren la totalidad del embalse. Por el contrario, la situación que se presenta de forma más reiterada es la opuesta: embalses con forma y distribución complejas y flujos de corrientes desiguales, conformes a la orografía del territorio.

El hecho de no tener capacidad de monitorizar todas las zonas del embalse tiene implicaciones negativas de gran importancia: no permite una prevención temprana ante brotes esporádicos de contaminación, con lo que la actuación humana puede no llevarse a cabo a tiempo; tampoco es posible generar un modelo real de cómo evoluciona dinámicamente la zona contaminada; es muy difícil establecer con certeza qué regiones del embalse son más proclives a gestar el inicio de la polución; etc.

Por otra parte, la utilización de sondas de medida dispuestas en localizaciones fijas requieren de un mantenimiento periódico por parte de un personal especializado. En algunos casos, aún la extracción del registro de datos ha de hacerse de forma manual, lo que ralentiza en exceso la capacidad de reacción ante una aparición repentina de sustancias que pongan en riesgo la calidad de la masa de agua.

Por estos motivos, y de forma concluyente, resulta necesaria la generación de una herramienta que permita obtener medidas en toda la extensión y profundidad del embalse, con el propósito de subsanar los defectos del actual sistema de seguimiento de calidad.

1.3. Objetivos del Trabajo

El objetivo principal de este Trabajo de fin de Máster es elaborar una herramienta de planificación de rutas automática de pequeñas embarcaciones no tripuladas equipadas de forma adecuada para el control de contaminantes en embalses.

Para conseguirlo, será necesario alcanzar los siguientes objetivos secundarios:

1. Estudiar las técnicas actuales de seguimiento de calidad del agua y los modelos existentes en la literatura.

2. Modelar el problema tanto desde el punto de vista de las sustancias contaminantes y sus posibles escenarios, como de la dinámica del barco.
3. Familiarizarse con las herramientas de optimización con las que se implementará el planificador responsable de proponer una solución al problema de monitorización de las sustancias contaminantes con las sondas que se encuentran en una o varias embarcaciones.
4. Desarrollar un planificador que obtenga la ruta óptima a realizar por la embarcación y su sonda de acuerdo a un escenario de contaminación concreto.
5. Analizar de forma sistemática el comportamiento del planificador realizando un estudio estadístico de los resultados obtenidos para cada escenario simulado.

1.4. Estructura de la memoria

El presente Trabajo se estructura de la siguiente manera. En la sección 2 se presenta el estado actual del arte, en el que se analizan los diferentes aspectos que involucra el estudio completo del seguimiento de calidad del agua. Seguidamente, en la sección 3 se plantea la definición del problema y se modelan las componentes que lo conforman. A lo largo de la sección 4 se describe el diseño y descripción de las herramientas desarrolladas que permiten planificar la monitorización de contaminantes en embalses. En la sección 5 se exponen los resultados obtenidos en varios escenarios prototipo de contaminación. Finalmente, las conclusiones y perspectivas del trabajo futuro se resumen en la sección 6.

2. Seguimiento de calidad de aguas embalsadas

La valoración del estado de las masas de agua y su seguimiento representa un elemento central de la planificación hidrológica y de la gestión del agua, puesto que determina la necesidad de evaluar, implantar o corregir medidas que den lugar a la consecución de los objetivos medioambientales que se plantee la propia planificación. Para obtener una visión clara de su estado, es necesario establecer unos programas de seguimiento o control que permitan obtener una información fiable.

2.1. Puntos de control

En un estudio de calidad del agua se pretende obtener información de los parámetros representativos de todos los indicadores de calidad establecidos para la evaluación de cada elemento. Estos elementos se pueden agrupar en tres bloques principales, según queda establecido en el Real Decreto (RD) 817/2015 [4]:

- **Biológicos:** fitoplancton, macrófitos, invertebrados bentónicos, fauna ictiológica, fauna bentónica de invertebrados, y otra flora acuática.
- **Hidromorfológicos.** En el caso de ríos serán la variación de la profundidad y anchura del río, su continuidad, la estructura y sustrato del lecho del río, y la estructura de la zona ribereña. En el caso de lagos y embalses se controla el requisito hídrico ambiental, la variación media de la profundidad, y el indicador de vegetación ribereña. En ambos casos se incluyen genéricamente las condiciones morfológicas y el régimen hidrológico.
- **Físico-químicos:** entre los que se encuentran las condiciones térmicas, de oxigenación, salinidad, transparencia, nutrientes, acidez... También se incluyen tasas de bacterias, metales, plaguicidas, sustancias peligrosas y contaminantes específicos.

Los indicadores correspondientes a los elementos de calidad biológicos, hidromorfológicos, y físico-químicos que se aplican en función del tipo de masa de agua que se esté tratando de monitorizar quedan definidos en el anexo II del Real Decreto (RD) 817/2015 [4]. Asimismo, los contaminantes específicos se precisan en los anexos V y VI del citado RD.

Los indicadores biológicos e hidromorfológicos dan una información algo “menos precisa” pero más global, ya que reflejan las condiciones existentes en el ecosistema acuático tiempo atrás del momento de la realización del muestreo, tratándose, por tanto, de una información integrada y extendida en el tiempo.

Los indicadores físico-químicos se analizan principalmente en la matriz de agua. En determinados puntos de control se realiza un control adicional en sedimento y biota. Estos parámetros proporcionan información precisa sobre la calidad del agua (nutrientes, contaminantes, oxígeno, pH, etc). Sin embargo, esta información es parcial ya que únicamente refleja las condiciones del medio acuático en un punto y momento determinado [5].

2.2. Tácticas de seguimiento

Como ya se introdujo en la sección 1.2, el seguimiento de calidad de las masas de agua en España se desarrolla con dos sistemas, diferenciados por la técnica que siguen para llevar a cabo el muestreo.

El programa de seguimiento periódico se ramifica en otros cuatro programas, regido por la normativa del Real Decreto (RD) 817/2015 [4, 6]. Cada uno de ellos centra sus objetivos en diferentes aspectos. El *control de vigilancia* pretende desarrollar una visión global del estado de las masas de agua. El *control operativo* se centra en determinar el nivel de riesgo de no cumplir los objetivos medioambientales, evaluando los cambios que se producen en el estado de las aguas. El *control adicional de zonas protegidas* intensifica el control anterior sobre zonas que requieren de especial cuidado: destinadas a abastecimientos, las afectadas por nitratos de origen agrario, las que están situadas en zonas sensibles por vertidos urbanos, etc. Por último, el *control de investigación* que se impondrá cuando se desconozca las causas del incumplimiento de los objetivos medioambientales o cuando se esté en riesgo probable de incumplirlas; determinará la magnitud e impacto de una contaminación accidental.

En la actualidad, el programa de seguimiento automático se lleva a cabo por la Red de alerta SAICA (Sistema Automático de Información de Calidad de las Aguas) [7], de la Conferencia Hidrográfica Española, sucesora de la antigua Red COCA. El estudio se realiza mediante analizadores y toma de muestras automáticos en estaciones fijas que obtienen datos físico-químicos con un periodo de muestreo pequeño y permiten en este caso la transmisión de los resultados analíticos en tiempo real.

Tal y como se analizó en la motivación del presente Trabajo (en la sección 1.2), el hecho de que la distribución de las sondas sea fija en el espacio impide realizar un estudio de cómo evolucionan los puntos de control en el cuerpo de toda la masa de agua, traduciéndose en un desconocimiento del estado de ciertas zonas. Este hecho compromete directamente la gestión de la calidad de aguas superficiales, ya que queda expuesta por la incapacidad de anticiparse a cambios repentinos de los parámetros indicadores de presencia de polución.

Con los pretextos manifestados, surge la necesidad de crear un sistema que permita evaluar los puntos de control de la sección 2.1 de forma continua en toda la extensión del embalse.

2.3. Incorporación de embarcaciones autónomas

En la última década se han venido desarrollando los primeros vehículos autónomos de superficie con los que poder realizar las tareas de medición. Estas pequeñas embarcaciones, en la actualidad ya comercializadas, están equipadas con sondas de propósito general según la aplicación a la que esté destinada. Algunos de los servicios que ofrece esta tecnología emergente son: mapeo hidrográfico, batimetría, muestreo y monitorización del agua, medidas de corrientes y descargas de agua, etc. En el mercado es posible encontrar gran variedad de modelos diseñados por diferentes firmas [8, 9, 10, 11], de aspecto similar al que se muestra más adelante en la figura 1.

A parte de estas aplicaciones centradas en la supervisión medioambiental, también se crean modelos con otros fines, tales como: tareas de seguridad y vigilancia, operaciones de búsqueda y rescate, envíos de carga. . .

Retomando las carencias que presenta la metodología de monitorización de la Red de alerta SAICA [7], la incorporación de vehículos autónomos de superficie resulta una opción atrayente para subsanarlas. Varias de las ventajas que brindaría su uso son que permitirían realizar las medidas de forma autónoma y continua, además de ser fáciles de transportar de un sitio a otro. Esto mejoraría significativamente la eficiencia de trabajo, evitando, además, las labores de mantenimiento que se han de efectuar *in situ*. Asimismo, permitiría inspeccionar áreas de difícil acceso y peligrosas, y recorrer rutas complejas.

Ahora bien, en las heramientas existentes la decisión de las trayectorias a seguir por los barcos la toma el usuario, indicando las coordenadas de los *waypoints*, puntos por los que se traza la ruta. Es decir, el proceso de planificación en función del estado de la calidad del agua es inexistente. La importancia de la planificación de trayectorias reside en la búsqueda y obtención de estrategias de control para lograr de la embarcación las trayectorias adecuadas, seguras y que posean el mayor provecho funcional en su recorrido.

Más aún, la planificación que se ha de desarrollar debe involucrar no solamente la dinámica del vehículo, sino también la del embalse como fluido y la evolución tanto espacial como temporal de las sustancias contaminantes. De esta forma, integrando todos estos elementos en un escenario específico será posible determinar la solución del recorrido óptimo a seguir por la embarcación.

Es fundamental, por tanto, diseñar un modelo que logre plasmar de forma realista el movimiento de las sustancias contaminantes en el agua. Para ello, se ha realizado un estudio de los modelos ya existentes en la literatura, analizando sus características principales.

2.4. Modelos hidrodinámicos

Tal y como se refería en el primer capítulo, el interés por el cuidado del agua es una preocupación que acontece desde antaño, pero de forma más intensa desde el comienzo del desarrollo industrial. De hecho, toda la documentación consultada data a partir de la segunda mitad del siglo XX.

A finales de 1997, Hamilton y Schladow elaboraron un modelo unidimensional de predicción de la calidad de aguas superficiales que, al ser 1D, no necesita de calibración por parte de las componentes hidrodinámicas [12, 13]. En él se combina el proceso de un modelo hidrodinámico ya existente (DYRESM, “modelo de simulación de la dinámica de un embalse”) con descripciones numéricas de la producción de fitoplancton, el ciclo de nutrientes, la estimación de oxígeno y la dinámica de las partículas. Parte de un conjunto de aproximaciones sobre el sistema y se involucran solo los parámetros que son más representativos y esenciales relacionados con los factores biológicos y químicos, a fin de realizar una interpretación fundamental. El aspecto más interesante del modelo es la adaptación de un modelo hidrodinámico a una dimensión. Esta consiste en discretizar el volumen en n capas horizontales, de diferente altura, con capacidad de desplazarse, contraerse y expandirse verticalmente. Las variables del sistema (temperatura, salinidad...) se especifican para cada estrato. Finalmente, se extraen varias conclusiones con respecto a esta aproximación. Desde el punto de vista hidrodinámico, el modelo unidimensional es satisfactorio siempre que el embalse sea ‘compacto’, es decir, que no sea muy alargado y estrecho, o ancho y poco profundo. Los autores enfatizan que los gradientes en las direcciones horizontales son generalmente pequeños al compararlos con los verticales que existen durante gran parte del año. Sin embargo, los parámetros que determinan la calidad del agua no se pueden reproducir fielmente con un diseño laminar del problema. Los autores sostienen que “aunque esto se reconoce como un defecto del modelo unidimensional, ello no implica necesariamente que aplicar un enfoque multidimensional produzca una imagen más precisa; de hecho, dada la complejidad de establecer condiciones iniciales realistas en todos los parámetros que determinan la calidad del agua en un modelo multidimensional, los resultados de las predic-

ciones pueden ser altamente inciertos”. Como se expondrá con un ejemplo más adelante, esta presunción se verá refutada con el tiempo, cuando se confirme la validez y éxito de determinados modelos tridimensionales.

Persiguiendo la misma finalidad que los anteriores, Kuo y demás autores en [14] combinaron una red neuronal con algoritmos genéticos para gestionar la calidad del agua de un embalse en Taiwán. Se centran en lograr el control los niveles de eutrofización, que es el aumento de nutrientes en un ecosistema acuático. Un exceso de nutrientes da lugar al crecimiento de algas y otros organismos, lo que afecta directamente al agua disminuyendo de forma drástica su calidad y limitando sus usos. Para construir un modelo de nutrientes simplificado entrenaron una red neuronal con un registro de datos del embalse almacenados durante 6 años. Con datos de otros 2 años más verificaron su validez. Posteriormente, se ayudaron de algoritmos genéticos para determinar las tasas de reducción en fósforo adecuadas, de modo que se logre controlar a tiempo los niveles de eutrofización.

En varias ocasiones, diversos autores han empleado modelos tridimensionales para estudiar las corrientes internas en masas de agua y relacionarlas con la eutrofización [15, 16, 17, 18]. A modo de ejemplo, en [19], los autores procuran modelar el transporte de sedimentos en las cuencas de un río, sirviéndose de un sistema definido con un total de cinco ecuaciones: dos de momento, una de continuidad, una de estado y una de transporte para el sedimento suspendido.

El modelo tridimensional más citado de todos ellos es el propuesto en 1987 por Blumberg y Mellor [16], con el que pretenden representar la física oceánica de la forma más realista posible. Las variables que estudian son las tres componentes del campo vectorial de velocidades, la temperatura, la salinidad y dos cantidades que caracterizan la turbulencia. En el artículo se emplea un sistema de coordenadas verticales que se maneja en modelos de océanos. Históricamente, la representación de la topografía del fondo marino ha sido complicada. El uso de las coordenadas sigma (σ -coordinates) es un enfoque elegante que incorpora la topografía hábilmente y con facilidad. Esta aproximación radica en normalizar la coordenada vertical por la profundidad del fluido, de forma que la ‘altura’ en cada punto es un valor entre cero y la unidad.

Este modelo hidrodinámico es aplicado con éxito en [20], donde consiguen predecir la evolución de los niveles de nutrientes en un embalse de China (*Guanting Reservoir*). Estas reservas de agua se habían dejado de utilizar para el consumo a causa de sus altos niveles

de eutrofización y otros problemas de contaminación relacionados. Con el modelo calibrado se consiguió simular la evolución dinámica de tres especies de organismos vivos (fitoplanctons), de forma que era posible hacer un pronóstico futuro y poder prevenir brotes que aumentarían los niveles de nutrientes actuando a tiempo con herramientas biológicas.

En un análisis inicial del presente Trabajo, se consideró emplear el modelo hidrodinámico propuesto en [16] para emular la dinámica de los contaminantes en el interior del agua. Sin embargo, la obtención de la solución del problema es de gran complejidad y tiene una gran carga computacional: requiere de la resolución de un sistema de ecuaciones en derivadas parciales de segundo orden con cuatro variables, y coeficientes de primer orden no nulos. Teniendo en cuenta que este Trabajo es un primer estudio del diseño y modelado de un sistema de planificación del control de contaminantes, basado en la optimización de las trayectorias de las embarcaciones, se ha considerado más adecuado utilizar un modelo simplificado de la situación de los contaminantes en el pantano para poder centrar los esfuerzos en el modelado y planificación del comportamiento de las embarcaciones.

Además de los modelos publicados más representativos ya citados, existen herramientas *software* que permiten aplicar modelos hidrodinámicos y de predicción de calidad del agua directamente sobre una base de datos de los parámetros por los que está especificado el embalse. Por ejemplo, SPARROW (*SPAtially Referenced Regression On Watershed Attributes*) relaciona las medidas de la calidad del agua en la corriente con las características espaciales de las cuencas hidrográficas, incluidas las fuentes de contaminantes y los factores que influyen en el transporte terrestre y fluvial [21]. Con ello estima empíricamente la cantidad, el origen y el destino de los contaminantes en las corrientes, y cuantifica las incertidumbres de estas estimaciones basadas en el coeficiente de error del modelo y la variabilidad en los datos observados. Otras herramientas *software* relacionadas con la anterior son: WASP (*Water Quality Analysis Simulation Program*, [22]), Delft3D (*3D/2D modelling suite for integral water solutions*, [23]) y QUAL2EU (*the Enhanced Stream Water Quality Model*, [24]).

Las utilidades *software* mencionadas requieren de la especificación de gran cantidad de parámetros que describan el embalse en un mallado espacial 3D de puntos. Es por esto que se decidió no recurrir a estas herramientas para el modelado de los contaminantes en este Trabajo, y se optó por una simplificación válida, que se detallará más adelante en la sección 3.2.

3. Definición y modelado del problema

Para llevar a cabo el desarrollo del diseño y modelado de un sistema de monitorización de contaminantes es necesario plantear, inicialmente, el escenario general del problema y los elementos que lo componen.

Supuesto un embalse de ciertas dimensiones, se desea estudiar zonas específicas de este, en las que se cree que existen sustancias contaminantes. Para comprobarlo y poder hacer un seguimiento de la calidad del agua es necesario recoger el mayor número de muestras posible. Para ello se emplearán pequeñas embarcaciones no tripuladas equipadas con una sonda sumergida cierta profundidad. Con la sonda multiparamétrica se podrán evaluar un cierto número de variables y parámetros directamente relacionados con los índices e indicadores de monitorización establecidos en el Real Decreto (RD) 817/2015 [4].

El objetivo que se persigue es, por tanto, conseguir que los barcos se muevan de acuerdo a trayectorias que permitan observar la mayor parte de las zonas contaminadas en el menor tiempo posible. Por consiguiente, el planteamiento del problema requiere del modelado de dos elementos: la embarcación y los contaminantes.

Por una parte se ha de definir el modelo de la embarcación, ajustando su dinámica a un prototipo general de vehículos autónomos, similar a los citados en la sección 2.3. En base a los valores a los que se fijan los parámetros que ajustan el sistema de ecuaciones dinámicas, es posible simular el movimiento del vehículo sobre la superficie del embalse.

Por otro lado, el modelado de los contaminantes se simplificará a un diseño que permite generalizar las características más relevantes de los modelos citados en la sección 2.4.

3.1. Modelado del barco

Para llevar a cabo la monitorización de la calidad de las aguas se ha modelado un prototipo de barco autónomo, que será manejado de forma automática en base a señales de control de propulsión y timón. Este tipo de vehículos reciben las siglas en inglés USV (*Unmanned Surface Vehicle*), por ser no tripulados. Como indica su nombre, consiste en una embarcación que se ha configurado o adaptado para poder ser utilizada a distancia o que funcione de forma autónoma.

En el presente estudio se ha tomado como embarcación la presentada en la figura 1. Se trata de un modelo destinado a la medida en corrientes de agua dulce de caudal, veloci-



Figura 1: Modelo de vehículo de superficie no tripulado: embarcación sensorizada manejada de forma remota tanto para trabajos hidrográficos como hidrológicos. Fuente: Grupo Álava Ingenieros [8].

dad de corriente, cantidad de agua descargada, etc. [8] A continuación se expondrán las especificaciones más significativas, a las que el modelo será ajustado para asegurar que la simulación sea más realista.

3.1.1. Aspectos Generales del USV

El barco simulado está dentro de los estándares de USVs del mercado. Se caracteriza por un peso total de $m = 20$ kg, considerando motores, batería y la equipación de instrumentos necesarios para la sonda de medida. El casco del barco tiene dimensiones $a = 0,5$ m de ancho y $b = 1,1$ m de largo. La velocidad típica de navegación es del orden de $v \sim 1,0$ m/s, alcanzando una velocidad punta en línea recta de $v_{max} = 1,8$ m/s.

3.1.2. Dinámica del Barco

Como planteamiento general, la dinámica de los movimientos que realiza un barco en la superficie del agua (sus trayectorias) se ven afectadas por varios factores. Se ha de tener presente la suma total de las fuerzas externas, las corrientes de aire y de agua (según la aerodinámica del barco), las fuerzas debidas a la presencia del timón y del propulsor, la inercia propia del movimiento, la resistencia que opone el barco... Para que el manejo de la embarcación sea apropiado se ha ajustado un modelo que permite que las maniobras de giro y de cambio de velocidad sean suaves y rápidas.

En este estudio se asumirá que los movimientos del vehículo están contenidos en el plano horizontal sobre la superficie del agua ($z = 0$). Considerado como un sólido rígido de tres dimensiones, sus movimientos estarán definidos por seis grados de libertad: tres traslaciones y tres rotaciones. Para el desarrollo que seguirá más adelante será necesario

definir primeramente los tres ejes de referencia principales, perpendiculares entre sí, cuyo punto de intersección está situado sobre su centro de gravedad:

- El eje vertical z , o eje de guiñada, es la línea imaginaria trazada verticalmente a través de la nave y a través de su centro de gravedad. Un movimiento de guiñada es un movimiento de lado a lado de la proa y la popa del barco.
- El eje lateral y , o eje de cabeceo, es la línea imaginaria que se traza horizontalmente de babor a estribor a través de la nave y a través del centro de gravedad. Un movimiento de cabeceo es un movimiento hacia arriba o hacia abajo de la proa y la popa de la nave.
- El eje longitudinal x , o eje de balanceo o alabeo, es la línea imaginaria que se extiende horizontalmente a través del largo de la nave (de popa a proa), a través de su centro de gravedad y paralela a la línea de flotación. Un movimiento de balanceo es un movimiento de inclinación de lado a lado (o babor-estribor) de la nave alrededor de este eje.

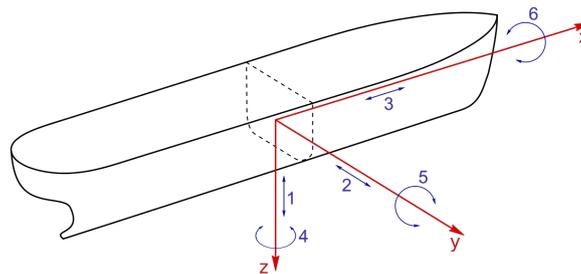


Figura 2: Movimientos de rotación y traslación de una embarcación sometida al oleaje.

En función de estos ejes se pueden definir los tres movimientos de rotación y de traslación. En la figura 2 se indican con flechas rectilíneas los desplazamientos vertical (1: ascenso y descenso), lateral (2: ronza o abatimiento), y longitudinal (3: avance o retroceso). Con flechas curvas, en la misma imagen, se describen las rotaciones sobre los ejes principales: eje z (4: guiñada de rumbo), eje y (5: cabeceo o arfada), y eje x (6: escora).

3.1.3. Ecuaciones de Movimiento

En este estudio, a efectos prácticos, solo se tendrán en cuenta las traslaciones y rotaciones en el plano horizontal ($z = 0$), esto es, los desplazamientos a lo largo de los ejes x e y , y los giros en torno al eje z . Para resolver este modelo dinámico numéricamente se ha procedido con el método de Runge-Kutta de cuarto orden. Este es un método iterativo basado en

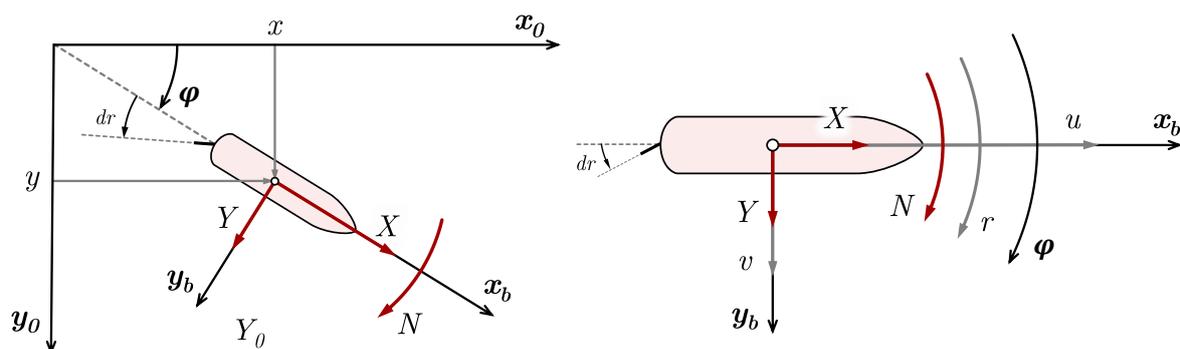


Figura 3: Sistemas de coordenadas globales (x_0, y_0) y locales (x_b, y_b) .

el método de Euler, que emplea la discretización temporal para aproximar la solución de ecuaciones diferenciales ordinarias.

Se considerarán tres coordenadas de posición globales referidas a los ejes (x_0, y_0) : dos para la ubicación en el mapa de cartesianas (x, y) , y una para la orientación φ del barco. Las velocidades lineales, tomadas en el sistema de referencia del barco (x_b, y_b) , se denotan como u y v ; y la velocidad angular del barco sobre el eje vertical (guiñada) se denota como r . En la figura 3 se indican los dos sistemas de coordenadas, señalando sobre el barco las fuerzas (en rojo) y velocidades (en gris) citadas. Los ángulos se tomarán positivos en sentido antihorario según el sistema de coordenadas, no respecto a la vista azimutal –se recuerda que el eje vertical es positivo hacia abajo–.

La dinámica del barco se puede modelar con las tres expresiones siguientes:

$$\begin{cases} \dot{x} = u \cos \varphi - v \sin \varphi \\ \dot{y} = u \sin \varphi + v \cos \varphi \\ \dot{\varphi} = r \end{cases} \quad (1)$$

La señal de control que recibe el barco tiene dos componentes: propulsión dp y timón dr . El término de propulsión dp está contenido entre 0 y 100, considerándose como un porcentaje sobre el flujo total que puede producir la turbina, con velocidad:

$$v_i = dp \cdot \frac{0,388}{100} \quad (2)$$

El factor multiplicativo que aparece en la ecuación se ha ajustado a 0,388, con el fin de ajustar el límite superior de velocidad a $v_{max} = 1,8$ m/s. La componente de fuerza de empuje total T (del inglés *thrust*) debida a la propulsión que sufre el barco es:

$$T = 2 \rho A v_i^2 \quad (3)$$

donde A es la sección de la turbina y ρ la densidad del agua. Todos los valores de los parámetros empleados en esta sección se recogen al final de esta en la tabla 1.

El timón, por su parte, tendrá un rango de movilidad de ± 30 grados respecto al eje x_b . La velocidad en el timón V_r (con subíndice r de *rudder*, en inglés) se define con las componentes u_r en el eje x_b , y v_r en el eje y_b . El cálculo de V_r ha de incluir las contribuciones de la velocidad de la embarcación, su rotación, el hecho de que el timón está separado una distancia l_r del centro de masas y, finalmente, la perturbación aerodinámica creada por la hélice (*propwash*) o efecto de guiñada adversa [25]:

$$\begin{cases} u_r = u + v_i \\ v_r = v - r \cdot l_r \end{cases} \quad (4)$$

siendo el módulo de la velocidad total en el timón:

$$V_r^2 = u_r^2 + v_r^2 \quad (5)$$

El ángulo de ataque en la posición del timón (sin tener en cuenta su orientación) será α , que se calculará con la función *atan2*. Este es el ángulo que subtiende la velocidad V_r recién calculada con respecto al eje x_b :

$$\alpha = \text{atan2}(v_r, u_r) \quad (6)$$

Al tener en cuenta la deflexión del timón dr , el ángulo de ataque en él es:

$$\alpha_r = \alpha + dr \quad (7)$$

La geometría del timón empleado viene caracterizada por sus coeficientes aerodinámicos C_L y C_D . Ajustando a un polinomio de primer y segundo orden, respectivamente, sus variaciones con respecto al ángulo que subtiende la dirección de movimiento con la de inclinación del timón α_r , las fuerzas de sustentación L (*lift*) y de arrastre D (*drag*) se determinan con las expresiones:

$$\begin{cases} L = \frac{1}{2} \rho V_r^2 S_r C_L, & C_L = C_{L\alpha} \alpha_r \\ D = \frac{1}{2} \rho V_r^2 S_r C_D, & C_D = (C_{D0} + C_{Da} \alpha_r^2) \end{cases} \quad (8)$$

La fuerza de empuje o arrastre D es paralela a la dirección del timón, en el sentido del flujo; mientras que la fuerza de sustentación L será perpendicular al plano del timón. En la figura 4 se ilustran sus direcciones y sentidos. Estas dos fuerzas, expresadas en componentes ortogonales al sistema de coordenadas del barco (x_b, y_b) son:

$$\begin{cases} X_r = -D \cos \alpha + L \sin \alpha \\ Y_r = -D \sin \alpha - L \cos \alpha \end{cases} \quad (9)$$

donde X_r sería la componente de fuerza paralela al eje x_b , y Y_r la paralela al eje y_r .

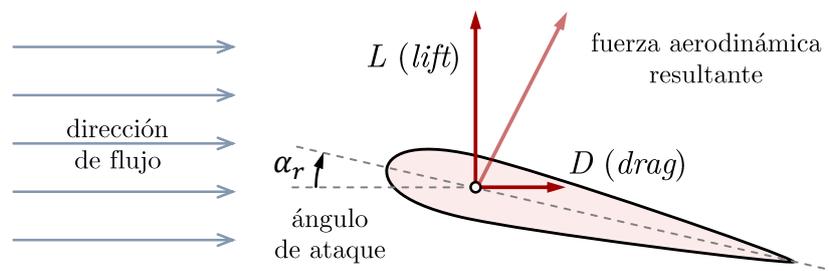


Figura 4: Fuerzas aerodinámicas sobre el timón

Las fuerzas totales sobre la embarcación incluyen contribuciones del empuje del agua, que es diferente en función de la dirección (si empuja de frente o desde los lados) ya que la sección transversal del barco es distinta. Se incluye también la fuerza de propulsión y las fuerzas del timón. Estas fuerzas están descritas sobre el sistema de coordenadas de referencia del barco (x_b, y_b) , tal y como se representaron en la figura 3 con color rojo.

$$\begin{cases} X = -c_{\text{front}} \cdot u + T + X_r \\ Y = -c_{\text{sideways}} \cdot v + Y_r \end{cases} \quad (10)$$

El momento total de fuerza (también conocido como *torque*) que sufre el barco es:

$$N = -c_{\text{rotate}} \cdot r - l_r \cdot Y_r, \quad (11)$$

en la que se incorpora un factor proporcional al empuje del agua, además de la componente del timón responsable del giro principal de la embarcación.

El momento de inercia en el eje z del vehículo se aproximará al de un prisma rectangular de ancho a y largo b , y masa total m :

$$I_{zz} = \frac{1}{12} m \cdot (a^2 + b^2) \quad (12)$$

Empleando la segunda ley de Newton y el teorema de transporte de Reynolds (consecuencia de la guiñada de rumbo), las ecuaciones diferenciales para las velocidades del barco anexionan los desarrollos que se han seguido hasta ahora:

$$\begin{cases} \dot{u} = \frac{X}{m} + r \cdot v \\ \dot{v} = \frac{Y}{m} - r \cdot u \\ \dot{r} = \frac{N}{I_{zz}} \end{cases} \quad (13)$$

Los parámetros empleados durante las simulaciones se detallan a continuación, en la siguiente tabla.

$m = 20 \text{ kg}$	$S_r = 0,0418 \text{ m}^2$
$\rho = 997 \text{ kg/m}^3$	$a = 0,4726 \text{ m}$
$A = 0,0467 \text{ m}^2$	$b = 1,0976 \text{ m}$
$l_r = 0,61 \text{ m}$	$I_{zz} = 2,38 \text{ kg m}^2$
$C_{d0} = 7,37 \cdot 10^{-5}$	$c_{\text{front}} = 0,2$
$C_{da} = 0,0037$	$c_{\text{sideways}} = 0,26$
$C_{la} = 0,07$	$c_{\text{rotate}} = 0,0075$

Tabla 1: Valores de los parámetros empleados en el modelo dinámico de la embarcación.

Tal y como se ha mencionado en varias ocasiones, los valores se han establecido ajustándolo a las características tanto físicas (tamaño, masa, ...) como dinámicas (velocidad en ruta, velocidad máxima, ...) del USV prototipo que se ha tomado como patrón (figura 1).

3.2. Modelado de los contaminantes

En la sección 2.4 se llevó a cabo un análisis de los modelos hidrodinámicos más relevantes de la literatura y de algunas herramientas *software* que permiten reproducirlos. Se aludió, también, al notable grado de complejidad que suponía implementarlos. Para una primera aproximación al problema de la planificación de trayectorias, es apropiado considerar un conjunto de partículas que se puedan desplazar de acuerdo a un movimiento no muy complejo en una región del agua. En relación con problemas reales, la configuración de la distribución de partículas fijada también hará que el problema de la planificación sea más o menos difícil.

Estas partículas estarán repartidas por el espacio en un rango determinado de profundidades. Inspirado por el uso de las coordenadas sigma (σ -coordinates) en [16], la profundidad del embalse en cada punto se ha reescalado a un valor comprendido entre $z = 0$ y $z = -10$. Esto permite cierta flexibilidad a la hora de adaptar este modelo sobre la topografía de diferentes embalses. Puesto que el barco operaría desde la superficie ($z = 0$), se ha cedido cierto margen hasta la presencia de contaminación. Las sustancias contaminantes representadas mediante las partículas puntuales se podrán percibir en la banda de profundidades $z \in [-1, -10]$.

Para realizar el presente estudio se han establecido una serie de escenarios de contaminación, distinguibles en cuanto a la disposición espacial y al patrón geométrico del conjunto de las partículas. En la figura 5 se presentan vistas desde el plano cenital de todos ellos.

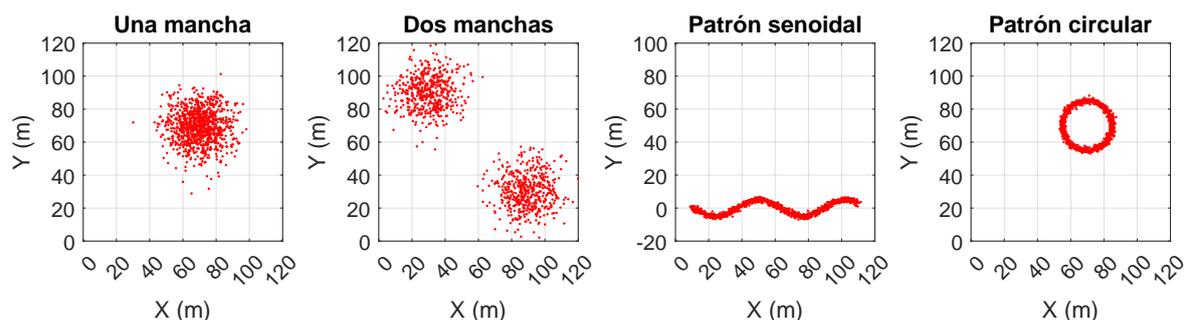
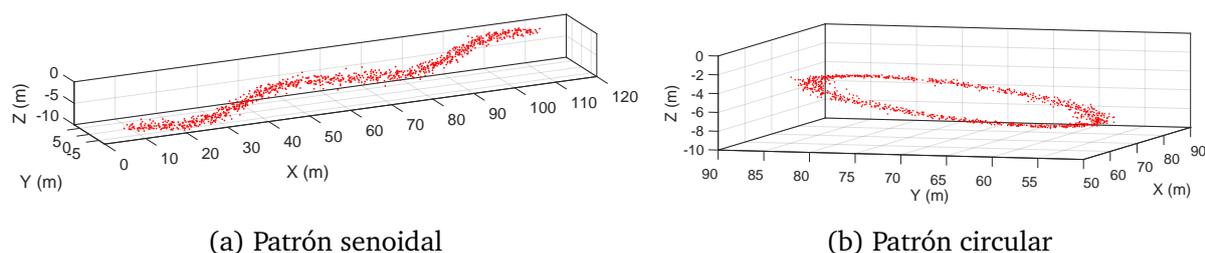


Figura 5: Distribuciones de contaminación empleadas en la evaluación del planificador.

Los dos primeros escenarios (según como se muestran de izquierda a derecha en la figura) son distribuciones gaussianas tridimensionales de una y dos manchas, respectivamente. Cabe señalar que la distribución en altura de las muestras es también gaussiana, centrada en $z = -4$ y acotada a los márgenes permitidos de profundidad. El primero de ellos representa el prototipo de mancha contaminante más sencillo. Será utilizado para analizar las soluciones del planificador en diferentes configuraciones del algoritmo. El segundo escenario, en el que las dos manchas de partículas están equidistantes de la posición inicial de la que partirá el barco, ha sido diseñado para validar el rendimiento del planificador en base a las trayectorias que obtiene.

En el tercer y cuarto escenario (representados en las dos últimas imágenes de la figura 5) se exponen situaciones más complejas, en las que la geometría de la distribución de las partículas (una senoide y una circunferencia) forzará al planificador a encontrar trayectorias que logren perfilarlas. Además, en estos dos casos, la profundidad de las partículas no seguirá una distribución gaussiana, sino que irá variando linealmente en altura a lo largo de la longitud de la mancha, alcanzando el aspecto que se puede observar en la representación 3D de la figura 6. Con estos dos escenarios se pondrá a prueba la calidad del planificador en cuanto a la detección de las partículas en altura. Se detallará en profundidad más adelante a lo largo de esta memoria.



(a) Patrón senoidal

(b) Patrón circular

Figura 6: Detalle tridimensional de los dos últimos escenarios.

En los cuatro escenarios mencionados previamente, se considerará que las partículas permanecen inmóviles durante el desarrollo de la misión. Además, para analizar el comportamiento del planificador ante escenarios dinámicos, donde la distribución de la mancha contaminante varía con el tiempo, sobre el primero de los escenarios de la figura 5, el que concentra las partículas en una única región circular, se construyen dos nuevos escenarios que consideran dos tipos de desplazamientos de las partículas diferentes. En el primero se ha modelado el desplazamiento de las partículas en el agua en base a unos movimientos sencillos por advección. La advección es el transporte de una sustancia en un fluido, que en este caso será el arrastre de los contaminantes por el agua. En caso de solo tener en cuenta este proceso, el contaminante viajaría a la misma velocidad que el agua y la extensión ocupada por él sería constante. En concreto se propondrá un escenario, en el que la mancha en conjunto se traslada en una dirección con un movimiento predominantemente lineal, al que se le incorporará una pequeña componente oscilatoria longitudinal y transversal para hacer más realista el desplazamiento. Sin embargo, lo habitual es que este proceso de advección esté acompañado de muchos otros, todos ellos descritos por la rama de la termodinámica que estudia los sistemas que se encuentran fuera del equilibrio termodinámico. Por simplicidad, en el segundo escenario, se contempla un caso en el que exista, además de advección, cierta componente de difusión y dispersión. De esta forma, se tratará del mismo movimiento pero esta vez el radio promedio de la mancha irá también creciendo en función del avance del tiempo. Además, sobre la parametrización del movimiento de cada una de las partículas añade algo de ruido gaussiano a fin de simular la turbulencia del agua.

4. Planificador

Para poder controlar los niveles de contaminación en una masa de agua, se ha desarrollado una herramienta de planificación, que obtendrá las rutas óptimas que deberían seguir las embarcaciones para recoger el máximo número de muestras en el embalse. Esta herramienta está dividida en dos bloques:

- Un primer planificador que hallará la mejor trayectoria de la embarcación en el plano XY en base a señales de control de propulsión y de timón. Para ello se supone que el barco es capaz de observar toda la columna de agua que está por debajo de él.

- Un segundo planificador que recibe la solución del bloque anterior y optimiza la profundidad de la sonda que toma las medidas en cada punto de la ruta.

Con esta división se consigue, por un lado, planificar el recorrido a realizar por el barco de forma global dependiendo del escenario de polución, y, por otro, perfilar la altura del sensor de medida una vez validada la presencia de partículas contaminantes en la columna de agua. Esto permite mejorar los tiempos de computo y realizar una planificación más adecuada del movimiento del sensor que si se realizase de forma conjunta con la trayectoria, en una única optimización.

Ambos planificadores están basados en la búsqueda heurística de soluciones con algoritmos genéticos. A continuación se introducirá brevemente el concepto y uso de estos algoritmos, y posteriormente se detallará el funcionamiento de cada uno de los planificadores.

4.1. Algoritmos Genéticos

La optimización de las señales de control se ha computado con algoritmos genéticos. Estos son algoritmos de búsqueda basados en los mecanismos de selección natural y evolución genética. Citando la definición de Goldberg [26]:

“Los algoritmos genéticos son algoritmos de búsqueda basados en la mecánica de selección natural y de la genética natural. Combinan la supervivencia de las estructuras de secuencias más aptas con un intercambio de información estructurado pero aleatorizado, para construir un algoritmo de búsqueda con algo del estilo innovador de las búsquedas humanas.”

Bajo este formalismo, la posible solución de un problema de optimización se puede presentar como una cadena de valores que se asignan uno a uno a sus variables o incógnitas. Diferentes combinaciones de valores darán lugar a diferentes soluciones del problema. En la terminología de los algoritmos genéticos, cada uno de los parámetros se denominan *alelos*. Las variables se pueden agrupar en *genes*, que al disponerlos linealmente en una cadena o *cromosoma* conforman un *individuo*. En la figura 7 se esquematiza lo expuesto.

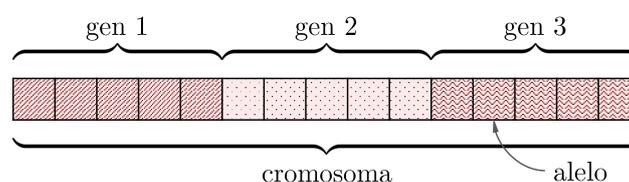


Figura 7: Estructura de un cromosoma: ejemplo de individuo compuesto por tres genes

Para alcanzar la solución a un problema se parte de un conjunto inicial de *individuos*, llamado población, generado de manera aleatoria. Cada uno de estos cromosomas representa una solución posible del problema. El algoritmo combinará todos ellos de una forma estructurada y aleatoria, dejando sobrevivir en las siguientes iteraciones (*generaciones*) los mejores individuos [27].

4.1.1. Población Inicial

La población inicial en un algoritmo genético es el conjunto de individuos que conformarán la primera generación. Lo habitual es generar los cromosomas de forma aleatoria, de forma que se intente barrer un amplio espacio de posibles soluciones al problema según los valores que se asignan a cada *alelo* (parámetro).

A veces, se inicializa un pequeño porcentaje de la población que ya ha sido sometido a técnicas heurísticas, y que se acerca más a la solución del problema. No es conveniente introducir demasiados individuos ya ‘procesados’, puesto que puede perjudicar el resultado del algoritmo. En estos casos puede ocurrir que la solución converja demasiado pronto o que se encuentre una solución de mínimo local [28].

4.1.2. Función Objetivo

La función objetivo o función de aptitud (*fitness*) evalúa qué tan cerca está una solución dada de la solución óptima del problema bajo estudio. Sobre ella se evaluarán los individuos de la población, tanto los iniciales como los que se generan en cada iteración del algoritmo. Esta función, por tanto, determina el grado de aptitud de cada uno de los nuevos individuos con un valor conforme al objetivo que se ha establecido y hacia el cual se orienta la evolución. Con ello se consigue encontrar el mejor conjunto de soluciones para resolver el problema dado.

Por lo general, un amplio conjunto de los problemas que se dan en la ciencia e ingeniería requieren de la optimización en paralelo de más de un objetivo. Existe la alternativa de emplear múltiples funciones de aptitud en algoritmos genéticos multiobjetivo, que no son más que extensiones adaptadas del algoritmo genético original. En este tipo de problemas, lo usual es que no exista una solución que optimice simultáneamente todos los objetivos, si no que la mejora de uno de ellos compromete el empeoramiento de los demás, ya que existe conflicto entre ellos. Por lo tanto, un algoritmo genético multiobjetivo generará un conjunto

de soluciones que no puede mejorar ninguno de los objetivos sin degradar al menos uno de los restantes. Este conjunto de soluciones reciben el nombre de *frente Pareto*.

Por este motivo, al contrario de lo que ocurre con la optimización de soluciones en los problemas con un único objetivo, en el caso multiobjetivo la solución ‘óptima’ será relativa, siendo necesario decidir al final cual es la solución más adecuada. Evidentemente, esta elección dependerá del diseño intrínseco del problema y del peso o valoración que se le dé a cada uno de los objetivos programados.

Finalmente, es importante indicar que los problemas multiobjetivo también pueden ser resueltos con técnicas mono-objetivo, a través de la combinación de todos los criterios en uno único. La más habitual es una combinación lineal de los objetivos, donde los pesos se eligen para indicar la importancia de la contribución de cada criterio en la función de evaluación mono-objetivo.

4.1.3. Selección

En cada iteración del algoritmo, se escoge un porcentaje de la población existente para producir la siguiente generación. Existen diferentes criterios para seleccionar los individuos de población que serán *padres* de la siguiente. Todos ellos se basan en el grado de aptitud de cada individuo, que ha sido evaluado con la función objetivo.

La selección más habitual, y la que se empleará en este Trabajo, es la denominada “método de la ruleta”. Esta técnica asigna a cada individuo i una probabilidad p_i de ser elegido como *padre* que es proporcional a su grado de aptitud f_i (*fitness*) entre la suma de la aptitud de una población compuesta por N individuos.

$$p_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (14)$$

De forma análoga a los mecanismos de evolución biológica, la información de los individuos más “adaptados” tendrá más probabilidades de sobrevivir en la información de los hijos que la del resto de los individuos.

4.1.4. Cruce

Una vez seleccionados los *padres*, el mecanismo principal de reproducción de los algoritmos genéticos es el operador de cruce. Este operador intercambia *alelos* entre los cromosomas de los *padres*, obteniendo nuevos elementos poblacionales: los *hijos*. Estos nuevos cromosomas conservarán ciertas características genéticas de los dos padres. Las opciones

que se eligen en el algoritmo determinan cómo se combinarán los dos *padres* para formar dos *hijos* cruzados en la siguiente generación [27, 28].

El operador de cruce más sencillo es el que está basado en un punto. Este método corta los dos cromosomas de los *padres* en una posición escogida al azar, quedando dos cadenas iniciales y dos finales. Al intercambiar dos de ellas se producen dos nuevos cromosomas completos. Ambos descendientes heredan genes de cada uno de los padres. En el diagrama de la figura 8 se representa el resultado de la aplicación de este operador.

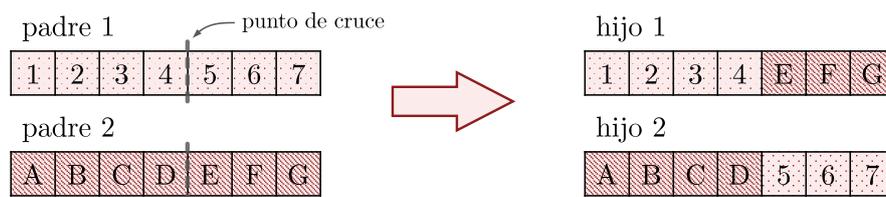


Figura 8: Operador de cruce de un punto sobre dos *padres*, dando lugar a dos *hijos*

Siguiendo este mismo procedimiento, el operador de cruce basado en dos puntos fracciona los cromosomas progenitores en tres segmentos (figura 9). En este caso, para generar un descendiente se escogerá la porción central de uno de los padres y se unificará con los dos extremos del otro padre.

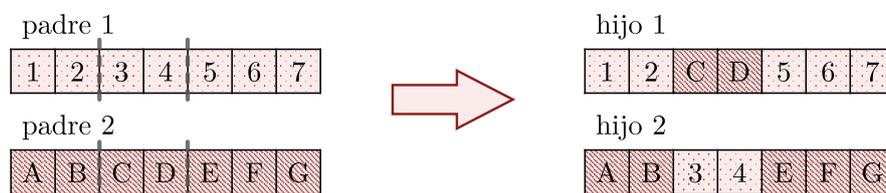


Figura 9: Operador de cruce de un punto sobre dos *padres*, dando lugar a dos *hijos*

4.1.5. Mutación

El operador de mutación se aplica individualmente a cada cromosoma *hijo*. De forma análoga a su definición biológica, la mutación introduce pequeños cambios aleatorios en la secuencia genética del individuo. Generalmente, la probabilidad de introducir mutaciones es muy pequeña, menor al 1%. Este modo de proceder se justifica con el hecho de que los cromosomas mutados suelen tener menor grado de aptitud evaluada con la función objetivo. No por esto esta operación deja de tener capital importancia, puesto que se consigue aumentar el espacio de búsqueda de soluciones, y contribuye a la convergencia del algoritmo hacia diferentes zonas del espacio de búsqueda [27, 28].

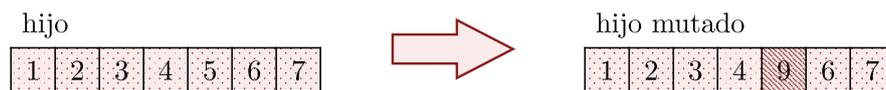


Figura 10: Operador de mutación en un cromosoma *hijo*

4.1.6. Reproducción

En las opciones de reproducción del algoritmo se puede decidir la cantidad de individuos de una generación que sobrevivirán en la siguiente. Esta práctica se conoce como selección elitista y, puesto que permite solo el paso de los mejores cromosomas, garantiza que la idoneidad de la solución calculada por el algoritmo genético no se reduzca de una generación a la próxima [27].

4.2. Planificador I: trayectorias

Tal y como se expuso en el preámbulo de este capítulo, el primer planificador tiene que determinar el mejor recorrido que la embarcación debe realizar sobre la superficie del embalse, suponiendo que es capaz de comprobar la presencia de partículas contaminantes en la columna de agua que está por debajo de ella. El radio de esta columna se fija, teniendo en cuenta el alcance de la sonda, a un metro.

En el comienzo del código de este planificador se inicializan todas las variables necesarias para realizar la simulación de la embarcación. Es necesario determinar la duración en segundos de la misión, indicando el paso mínimo (dt) al que se discretizará el tiempo (para la integración numérica del Runge-Kutta). Además, se carga en memoria (o se genera) la distribución espacial de partículas objetivo que representan la distribución espacial de las sustancias contaminantes. También se decide el número de embarcaciones con las que se quiere optimizar y simular la recogida de partículas, y se establecen las coordenadas y condiciones iniciales de cada una de ellas.

Posteriormente, se obtiene, mediante un optimizador basado en algoritmos genéticos, la trayectoria óptima sobre el plano XY . Las variables que deciden la forma de la trayectoria, y por ende, las que se optimizan, son las secuencias de las señales de control de propulsión (dp) y de timón (dr) que se aplican en un intervalo de tiempo.

Este intervalo de tiempo, periodo durante el que se aplica una señal de control a la embarcación, será superior a dt , el paso fino del Runge-Kutta. Concretamente, será proporcional a dt con un factor entero. Operando de esta manera se consigue reducir el número

de señales de control, atenuar la carga computacional del algoritmo genético, y realizar una simulación más realista (en el que el lapso entre señales de control es del orden de los segundos).

El optimizador recibe un total de 100 semillas como población inicial. Gran parte de ellas se generan de manera aleatoria, siguiendo una distribución uniforme que respeta los márgenes a los que están constreñidos los valores de las señales de control dp y dr (establecidos en la sección 3.1). También se introducen, en menor cantidad, individuos cuyas trayectorias se han obtenido anteriormente con la intención de recorrer la mancha de partículas objetivo. Para obtener estas señales de control se sintetiza la información del conjunto de partículas en dos o tres puntos (*waypoints*), obtenidos como los centroides del cúmulo o cúmulos de partículas que presente el escenario. Además, se calculan tantas rutas como permutaciones posibles del orden en el que se pueden visitar dichos *waypoints*. Las señales de control de propulsión y ángulo del timón se hallan mediante un sistema de control proporcional tomando como señales de error la distancia que separa al barco del *waypoint* y la diferencia en la dirección, respectivamente. De todas las posibles combinaciones se tomarán las dos mejores, esto es, las que mayor porcentaje de partículas pueden atrapar según la función objetivo.

En este estudio será primordial maximizar el porcentaje de partículas recogidas sobre el total de partículas presentes. Por tanto, la función objetivo que el algoritmo genético minimizará será el porcentaje de partículas que no ha conseguido recoger en el tiempo establecido.

Finalmente, en este planificador tiene cabida proponer algoritmos multiobjetivo, con una segunda función objetivo que minimice, por ejemplo, la distancia recorrida por la embarcación, o el número de choques entre las embarcaciones (en los casos en los que se realice la monitorización de los contaminantes con más de una).

4.3. Planificador II: altura de la sonda

En la segunda etapa de planificación se optimiza la altura en profundidad de la sonda multiparamétrica sumergida en el agua, que ha de tomar el mayor número de muestras posible. El alcance de detección de la sonda es de un metro de radio.

En esta etapa se recibe la solución de la etapa anterior y se obtienen las coordenadas en (x, y) de toda la trayectoria en cada instante de tiempo dt . Además, con el objeto de reducir

la carga computacional de este planificador, se optimizará la altura de la sonda únicamente en los puntos del recorrido en los que se observa la presencia de partículas contaminantes en la columna de agua inferior. Es decir, puesto que es irrelevante la altura de la sonda en las zonas en las que no existen partículas, no se dictarán señales de referencia para la sonda multiparamétrica sobre ella –esto es, en esos instantes de tiempo específicos–.

Por otra parte, la señal que se optimiza en este planificador no es la posición en altura absoluta z de la sonda, sino los incrementos dz respecto a las posiciones previas. El desplazamiento máximo entre cada intervalo de tiempo (en valor absoluto) es de medio metro. Es decir, el valor de dz está restringido a un rango comprendido entre $-0,5$ y $0,5$ metros. El rango de movilidad permitido en profundidad para la sonda será $z \in [-1, -10]$. Al mismo tiempo, la posición z de la sonda se restringe a un rango de profundidades contenido en $z \in [-1, -10]$. En todas las simulaciones realizadas, se considera que inicialmente la sonda se encuentra a media altura ($z = -4$).

Al igual que en el Planificador I, el intervalo de tiempo entre cada señal de control de la sonda es un número entero de veces dt , el paso fino del Runge-Kutta. De este modo, la señal de control se actualiza cada segundo, lo que se ajusta a un modelo más realista del problema y permite disminuir el número de parámetros a manejar por el algoritmo genético.

La población inicial del algoritmo genético se compondrá por 200 individuos (semillas) generados de forma aleatoria y cuyas variables dz siguen una distribución uniforme que cumple con las dos restricciones anteriores. En concreto, para generar cada semilla se muestrearán de forma secuencial cada uno de los elementos que compondrán el *chromosoma*, a partir de una distribución uniforme comprendida entre $-0,5$ y $0,5$. Se comprobará que la posición de la sonda no sobrepasa el margen de movilidad $z \in [-1, -10]$ en ese instante de tiempo. En caso de que lo haga, el valor de ese elemento se fija a 0 (es decir, se mantiene la sonda a altura constante), y se pasa al siguiente elemento del *chromosoma*.

El objetivo de este segundo planificador es maximizar el número de muestras recogidas o, dicho de otra forma, minimizar las que no consigue recoger la sonda. A fin de poder comparar qué parte de las observadas con el Planificador I es capaz de recoger o medir, la función objetivo del Planificador II será el porcentaje de las que finalmente recoge sobre el máximo que le permite la trayectoria trazada. De esta forma, el valor de la función *fitness* está contenido en un rango de 0 a 100.

5. Resultados

En esta sección se lleva a cabo el estudio de los resultados de las optimizaciones realizadas por cada uno de los planificadores en diferentes escenarios y configuraciones. En cada caso se han realizado un total 50 optimizaciones sobre el problema, manteniendo los mismos parámetros y condiciones iniciales en todos ellos. Esta forma de proceder es adecuada para analizar el funcionamiento de un planificador soportado por un algoritmo genético, ya que este tipo de algoritmo de optimización conlleva una aleatoriedad que hace que normalmente no obtenga dos soluciones idénticas en dos ejecuciones consecutivas. De esta forma se obtendrán unos resultados con suficiente peso estadístico para realizar el análisis.

El estudio que se presenta en esta sección se estructura en tres partes dispuestas en el siguiente orden:

- En la primera parte (sección 5.2) se analizarán las consecuencias de usar unas configuraciones u otras sobre los parámetros del optimizador, concretamente del algoritmo genético.
- En la segunda parte (sección 5.3) se examinarán los resultados obtenidos para la planificación de trayectorias, es decir, el rendimiento del Planificador I en diferentes escenarios.
- Por último, en la tercera parte (sección 5.4) se hará un estudio de los resultados de las optimizaciones del Planificador II que determinará la variación de la altura de la sonda para trayectorias optimizadas en la segunda parte.

Previo al análisis de resultados, se explicará brevemente de la metodología seguida para analizar los resultados obtenidos a lo largo de la sección.

5.1. Metodología de análisis

Debido a la naturaleza estocástica de muchas de las configuraciones comparadas en este Trabajo, es necesario realizar un análisis estadístico de los resultados. Este estudio se apoyará en diferentes tipos de gráficas en función del matiz que se pretenda reflejar.

Como se adelantaba anteriormente, para cada configuración del algoritmo o escenario se computan un total de 50 optimizaciones. De cada una de ellas se almacena en memoria la evolución del algoritmo genético a lo largo de sus iteraciones. Se recuerda que, en el algoritmo genético, cada generación la compone una población de 100 individuos o *cromosomas*,

todos ellos soluciones en potencia del problema. Cada uno de estos individuos tendrá una aptitud mejor o peor según el valor que se obtenga con la función *fitness* al evaluarlo. Además, al tener almacenados los cromosomas de los 100 individuos de cada generación y sus correspondientes aptitudes, es posible analizar: 1) la evolución del *fitness promedio* de las 100 soluciones de cada una de las 50 ejecuciones del algoritmo, o, alternativamente, 2) la evolución del *mejor fitness* de cada una de las 50 ejecuciones del algoritmo.

Durante el análisis de la sección 5.2, donde se busca determinar la mejor parametrización del algoritmo genético, se compararán los resultados obtenidos por parejas de configuraciones, que se distinguen en un aspecto en concreto a analizar. Además, a fin de constatar si existe diferencia estadística significativa entre los dos conjuntos de soluciones o ejecuciones obtenidos de sendas configuraciones se procederá a evaluarlas con el test de Wilcoxon [29]. Este test, también conocido como la *prueba de suma de rangos Wilcoxon*, es un método no paramétrico (no asume que la distribución esté definida a priori) que permite determinar si dos poblaciones de valores han sido tomadas de muestras independientes. Es decir, si se tienen dos conjuntos de valores, este test estadístico permite determinar si proceden de la misma distribución o si, por el contrario, son, desde un punto de vista estadístico, significativamente diferentes. Para ello el test devuelve un valor p (*p-value*) que se debe comparar con un nivel de certeza. El valor de certeza fijado en este Trabajo es del 95% de similitud.

Más en concreto, el test de Wilcoxon se realiza sobre cada generación del algoritmo genético, comparando los valores de la función objetivo (*promedio* o *mejor*) de las 50 computaciones de una configuración con las 50 del otro. Tal y como se mostrará más adelante en algunas de las gráficas, el resultado de este test se ha indicado con un código de colores en la parte inferior de las mismas. En caso de que el test dé positivo, es decir, que exista correlación entre los dos conjuntos de datos, el color indicado será blanco. Por el contrario, cuando las dos muestras sean significativamente diferentes desde un punto de vista estadístico, el color que se muestre corresponderá a la configuración del optimizador del que se obtiene mejor resultado, evaluado con la función objetivo.

Como el test anterior únicamente permite determinar si los resultados obtenidos con una parametrización del algoritmo son estadísticamente diferentes de los obtenidos con otra, es conveniente complementarlo con información adicional, para poder apreciar la magnitud de la diferencia. Por ese motivo, en la parte superior de la gráfica del test de Wilcoxon también se representa: 1) la evolución del *fitness promedio* de los 100 individuos de la población, o

2) la evolución del *fitness* de la *mejor* solución de las 50 ejecuciones. Para diferenciar el caso en el que se analiza la evolución de la población del caso en el que se estudia la evolución de la mejor solución de las ejecuciones, se emplearán dos conjuntos de colores diferentes. En el caso 1) se empleará la paleta de colores naranja y morado, mientras que en el caso 2) se usará la combinación de verde y azul. En las figuras 11a y 12a se representa un ejemplo de cada caso, respectivamente; y en la parte inferior de ambas el resultado de evaluar, para cada generación, el test de Wilcoxon correspondiente.

En un segundo tipo de gráfica (como el de las figuras contiguas 11b y 12b), se mostrará el promedio de cada conjunto de resultados anteriores frente al tiempo de cómputo empleado en cada caso. Para calcular el tiempo de cómputo por iteración se ha tomado la media global de la duración de cada una de las computaciones y se ha dividido sobre el número de generaciones total. Además, en este tipo de gráfica también se indica la dispersión de los datos con las barras de error extendidas a dos veces la desviación estándar (2σ). Por lo tanto, en el caso en el que los datos siguiesen una distribución gaussiana, en ese rango entraría el 95 % de los datos.

Por otra parte, para analizar en detalle los resultados del planificador sobre un escenario concreto, se representa este de forma independiente. En estas representaciones alternativas (véase la figura 18a como ejemplo) se realiza un histograma que se ha de entender de la siguiente manera. El eje vertical será el valor otorgado por la función objetivo para un individuo o solución del problema. En el eje horizontal se tendrá la numeración de las generaciones del algoritmo genético. Por tanto, en cada columna del histograma (generación) se representa la distribución de las 50 optimizaciones según el valor de la función *fitness*. El código de colores indica la cantidad de individuos en cada *bin* del histograma, según la barra de color situada a la derecha del gráfico. El color blanco representaría un *bin* vacío, mientras que el color más oscuro indicaría que hay más de 10 individuos en el *bin*. Superpuesto al histograma, se encuentra el valor promedio de cada generación con las barras $\pm 2\sigma$ de error. Con esta gráfica se permite visualizar gran cantidad de información: aunque en los problemas de análisis estadístico de conjuntos de valores se representa habitualmente la media y la varianza de los datos, la distribución de las soluciones del presente problema no tiene por que ser necesariamente gaussiana. Este hecho se podrá apreciar de forma sencilla en las figuras de este tipo que aparecerán a lo largo de la memoria.

Por último, con el objetivo de visualizar la solución que se obtiene de una optimización, se ha representado el escenario final en figuras tales como la 13a. En ellas, la trayectoria del barco se delinea con color azul. El conjunto de partículas contaminantes al final de la misión (o hasta el instante indicado en la parte superior de la gráfica) se plasma con dos colores, según si la embarcación las ha conseguido detectar (verdes) o no (rojas).

5.2. Parametrización del planificador

A fin de conocer con más profundidad los efectos de emplear una u otra configuración de los parámetros del optimizador, se compararán los resultados obtenidos con dos de ellas. En primer lugar se estudiará la influencia de emplear el operador de cruce de dos puntos frente el de un punto. Después se analizará si existe diferencia en la resolución de una variante del problema con varios objetivos empleando un algoritmo genético multiobjetivo o uno mono-objetivo que, con ciertos pesos, los combina linealmente.

En los dos casos se utiliza el mismo escenario de contaminación: la distribución tridimensional gaussiana de partículas de la primera gráfica de la figura 5. La exploración se llevará a cabo durante 300 segundos con una sola embarcación. El punto de partida de la trayectoria del barco, que es $(x_0, y_0) = (0, 0)$, está alejado del centroide de la mancha una distancia del orden de 100 metros.

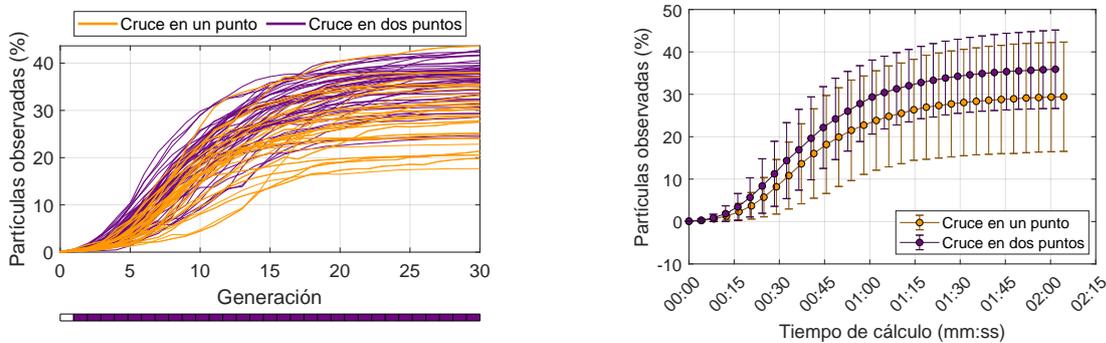
Como se mencionó anteriormente, en esta primera parte del análisis se empleará el Planificador I como apoyo para el estudio de los parámetros del algoritmo genético. Es por eso que el escenario escogido es el más sencillo. Se recuerda que, con este planificador, únicamente se optimizará la ruta a seguir por el barco en el plano XY , suponiendo que es capaz de observar la presencia de partículas en toda la columna de agua que se encuentra por debajo de él en cada punto de su trayectoria.

Finalmente, cabe indicar que, siguiendo una metodología similar a la mostrada en esta sección, se podría analizar la influencia de otros parámetros del algoritmo genético, con el fin de obtener la mejor configuración para los planificadores desarrollados en este Trabajo.

5.2.1. Puntos de cruce

Retomando el concepto del operador de cruce detallado en la subsección 4.1.4, se describieron dos técnicas distintas. La primera de ellas, y la más sencilla, estaba basada en un punto (figura 8). La segunda es una extensión de la anterior, cruzando a los *padres* en dos

puntos (figura 9). A continuación, se realizará una comparativa de los resultados obtenidos para 50 ejecuciones del Planificador I con cada una de las configuraciones. Además, para este primer análisis, la función objetivo (o *fitness*) a optimizar se centrará en conseguir observar el mayor porcentaje de partículas contaminantes en todo el recorrido.



(a) Resultado promedio de las poblaciones

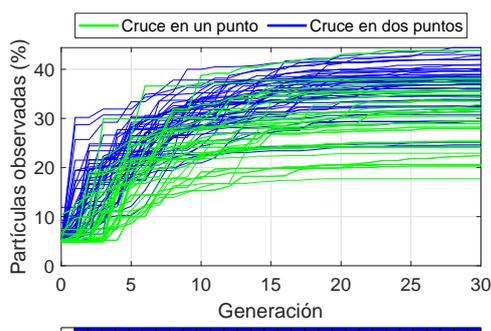
(b) Evolución temporal del resultado promedio

Figura 11: Comparativa de resultados entre dos configuraciones distintas del operador de cruce del Planificador I: promedio de la población.

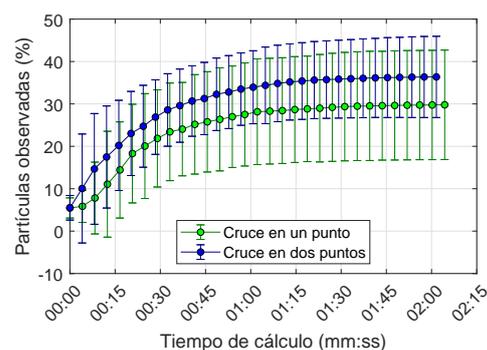
En primer lugar, utilizando la información recogida, se analizará el valor *promedio* de las poblaciones de cada generación para cada una de las 50 computaciones del optimizador. Tal y como se observa en la figura 11a, de forma general –y reafirmado por el test de Wilcoxon–, se obtienen mejores resultados con el algoritmo genético configurado con el operador de cruce basado en dos puntos (en morado) que con el de uno (en naranja). Por otra parte, el tiempo de cálculo promedio que emplean las optimizaciones de cada configuración es muy similar, como se observa en la figura 11b. En dicha figura también se aprecia que la configuración con dos puntos de cruce observa más partículas en promedio con una dispersión menor, corroborando lo indicado con el test de Wilcoxon.

En la figura 12 se muestra el mismo análisis, pero esta vez considerando los *mejores* individuos de la población de cada una de las generaciones en las 50 computaciones, para cada caso. Confrontando este dúo de gráficas con las anteriores, se observa que la evolución del valor promedio es más suave y lenta que la del mejor individuo. Cuando el algoritmo comienza a converger (figura 12a) –sobre la generación 18, en ambas configuraciones–, el conjunto global de la población aún sigue incrementando su grado de adaptación (figura 11a). Este es el comportamiento propio de los algoritmos genéticos, según lo descrito en la sección 4.1.

A continuación, se representa la mejor trayectoria obtenida en cada variante del algoritmo genérico en el conjunto de figuras 13. Visualmente son muy similares, y se comprueba el



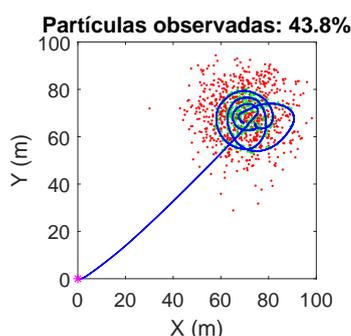
(a) Resultado de las poblaciones



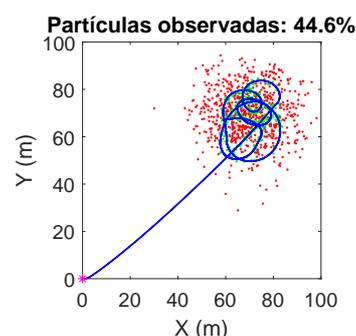
(b) Evolución temporal del algoritmo

Figura 12: Comparativa de resultados entre dos configuraciones distintas del operador de cruce del Planificador I: mejor individuo de la población.

buen resultado conseguido: la embarcación se desplaza directamente a la zona contaminada y comienza a virar para detectar la mayor cantidad de partículas contaminantes posible en el tiempo de simulación dado.



(a) Cruce en un punto



(b) Cruce en dos puntos

Figura 13: Trayectorias óptimas calculadas con cada configuración

Se concluye, por tanto, que la mejor opción de operador de cruce para el algoritmo genético (y para este escenario en particular) será la basada en dos puntos, por su rendimiento tanto en adaptabilidad a la solución del problema como en eficacia temporal. De ahora en adelante se empleará esta configuración en las siguientes optimizaciones.

5.2.2. Multiobjetivo

El problema de optimización presentado en esta memoria es muy adecuado para ser resuelto con técnicas multiobjetivo, ya que existen diversos factores a tener en cuenta, como podrían ser la distancia recorrida, el consumo y gasto de combustible, el tiempo de exploración... Como se introdujo en el apartado 4.1.2, existen algoritmos multiobjetivo que implementan la optimización de varios objetivos simultáneamente. Sin embargo, tam-

bién se puede resolver combinando linealmente varias funciones objetivo en un problema mono-objetivo, fijando diferentes pesos para cada uno.

Se verá, en el ejemplo que se expone a continuación, la comparativa entre estos dos casos. Los objetivos serán dos: 1) maximizar el porcentaje de partículas observadas f_1 en la exploración, y 2) minimizar la distancia recorrida en metros f_2 por la embarcación. Este es un problema presente en la realidad, puesto que la distancia realizada por un vehículo está directamente relacionada con el combustible o batería disponible.

Por un lado, la función de aptitud del planificador mono-objetivo combinará los resultados con la siguiente expresión:

$$f = f_1 - \frac{f_2}{500} \quad (15)$$

de forma que el algoritmo busque el máximo de f o, lo que es lo mismo, el mínimo de $-f$. Los coeficientes que relacionan los objetivos se han fijado de acuerdo a la magnitud de cada uno de ellos. Se tiene que $f_1 \in [0, 100]$, y la distancia recorrida en una trayectoria optimizada es del orden de $f_2 \sim 300$ m. Obsérvese que f_2 puede llegar a ser 0, lo que implicaría que el barco no se movería, comprometiendo al primer objetivo f_1 y dando lugar a un bajo valor de aptitud f . Se prioriza, de esta forma, el primer objetivo sobre el segundo.

Por otra parte, el algoritmo genético multiobjetivo optimizará ambos objetivos a la par en cada generación, dando lugar a un conjunto de individuos de los cuales, los mejores de ellos se situarán en el frente Pareto (véase sección 4.1.2).

Durante la optimización de cada uno de los 50 cómputos de las dos configuraciones, se ha guardado la evolución de cada objetivo por separado en cada generación. Para el caso mono-objetivo se ha tomado el *mejor* individuo de los 100 que componen la población de cada generación. Para el multiobjetivo, se han evaluado los individuos del frente Pareto de cada generación con la función *fitness* del mono-objetivo (ecuación (15)), de forma que se tome el más apto de ellos. Con esto se podrá comparar de acuerdo con el criterio mono-objetivo las dos configuraciones.

En las figuras 14a y 14b se muestran los resultados obtenidos para cada objetivo de forma independiente en los dos estudios, y en la figura 14c el grado de *fitness* evaluado con la ecuación (15). Como era de esperar, el hecho de reducir el peso del objetivo f_2 frente al f_1 se refleja en la gran similitud presente entre las gráficas 14a y 14c.

El comportamiento del algoritmo genético mono-objetivo es el siguiente. Debido a los pesos elegidos, primero maximizará el número de partículas a recoger (f_1). Una vez se ha

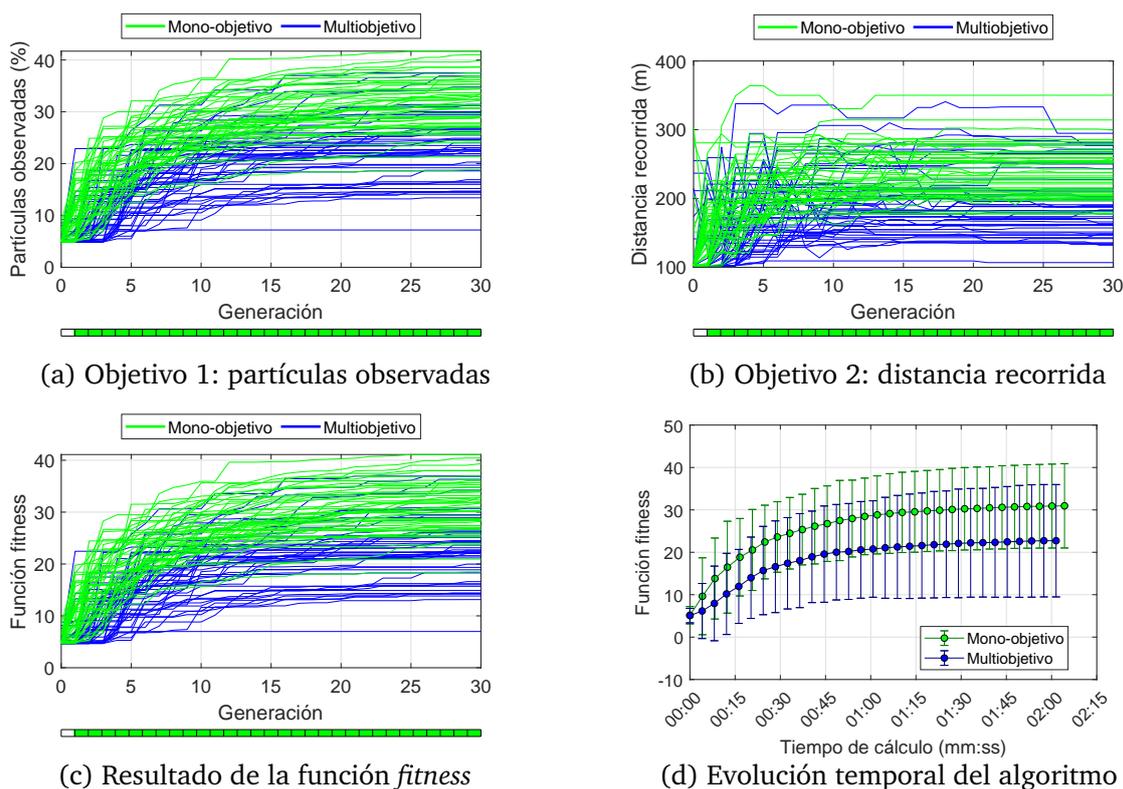


Figura 14: Comparativa de resultados obtenidos del optimizador multiobjetivo puro de dos objetivos y del mono-objetivo que los combina linealmente.

estabilizado el número de partículas que puede recoger, el algoritmo comienza a converger a una solución que además intenta minimizar la distancia recorrida (f_2).

En la figura 14d se aprecia que el algoritmo multiobjetivo es ligeramente más rápido que el mono-objetivo. Por otra parte, se ha de recordar que, tal y como se detallaba en la sección 4.1.2, los algoritmos genéticos multiobjetivo utilizados tienen que repartir su esfuerzo computacional en la optimización de todo el frente Pareto por igual. Aunque esto permitiría encontrar otras soluciones de interés, al comparar las soluciones obtenidas en los dos tipos de optimización según el criterio de la función de aptitud del algoritmo mono-objetivo (15), los resultados que se obtienen con el algoritmo multiobjetivo son peores que las del algoritmo mono-objetivo. Además, en el caso de usar un algoritmo multi-objetivo de frente Pareto es necesario seleccionar, al final de su optimización, la solución (trayectoria) que se utilizará sobre el vehículo.

En vistas de que el vehículo solo puede utilizar una única solución (trayectoria) al final del proceso, a lo largo de las dos siguientes secciones se optará por emplear el algoritmo mono-objetivo con combinación lineal de varios objetivos cuando sea necesario tener más de uno en cuenta. Sin embargo, se ha de prestar mucha atención en la determinación de los

pesos que combinan los objetivos, ya que con ello se prioriza un tipo de soluciones finales frente a otras.

A modo de conclusión, se grafican en el conjunto de figuras 15 las mejores soluciones de cada configuración, seleccionadas en términos de la función de aptitud mono-objetivo (15). Los resultados, cualitativamente, son análogos a los del estudio anterior (figura 13).

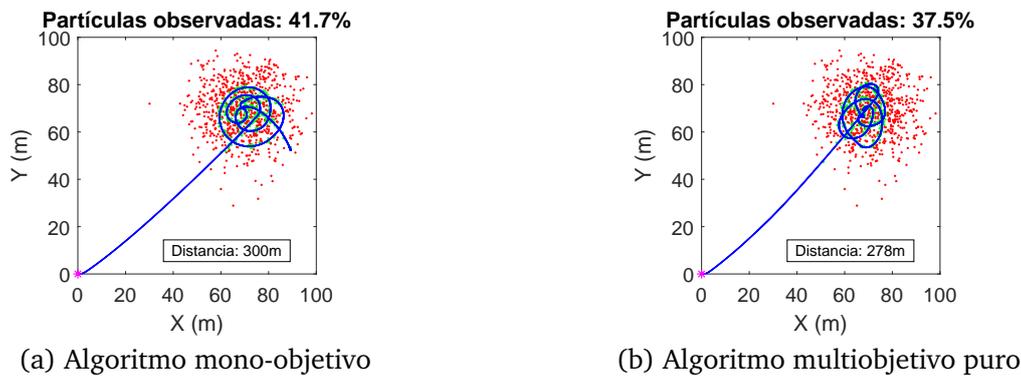


Figura 15: Trayectorias óptimas calculadas con cada configuración

5.3. Planificador I

Una vez determinadas las configuraciones óptimas de los parámetros del algoritmo genético para el primer planificador, se procederá a verificar el comportamiento de ambos planificadores. En esta sección se comprobará el rendimiento del Planificador I en diferentes escenarios configurado con un operador de cruce basado en dos puntos.

Primeramente se analizarán los resultados en un par de escenarios en que una distribución tridimensional gaussiana de partículas se desplaza por advección en el agua. Se considerarán las dos configuraciones descritas en la sección 3.2: en una de ellas se tendrá en cuenta la difusión y en otra no. Se partirá desde la misma configuración inicial del barco y el escenario de contaminación empleado en el caso anterior. Este caso representa una primera aproximación de los complejos modelos hidrodinámicos estudiados en la sección 2.4. En el segundo caso habrá dos manchas de contaminación estáticas, que serán también distribuciones gaussianas (tal y como se muestra en la segunda gráfica de la figura 5). En este escenario se realizarán dos planificaciones: una exploración con un solo barco, y otra con dos barcos.

Al igual que en la sección anterior, únicamente se mostrarán los resultados de la optimización de la trayectoria en el plano XY que realizará la embarcación, considerando que

desde la posición en la que se encuentra es capaz de advertir partículas situadas en la región inferior.

5.3.1. Partículas móviles

En esta sección, debido a que los escenarios son más complejos (presentan movimiento), se ha decidido prescindir del objetivo que consigue reducir la distancia recorrida durante la trayectoria. Esta quedará acotada, exclusivamente, por el tiempo establecido para realizar la exploración. Con esto, la función de aptitud que determine el comportamiento del Planificador I en este caso solo tendrá en cuenta un objetivo: la observación del mayor porcentaje de partículas contaminantes.

Retomando la descripción de los dos escenarios de partículas que se desplazan en función del tiempo especificados en la sección 3.2, se analizarán los resultados del Planificador I para cada uno ellos.

El primer escenario consistía en la misma mancha de sustancias contaminantes del estudio anterior, que se transportan por advección conforme a un movimiento prácticamente lineal (con ligeras oscilaciones y ruido añadido). En la figura 16 se observa el mejor resultado obtenido en el Planificador I para este escenario. Se han capturado cuatro instantes de toda la exploración, incluyendo el estado final ($t = 300$ s). En las gráficas se puede observar que el vehículo se desplaza hacia la mancha y se dispone a hacer bucles sobre la misma según esta se sigue desplazando.

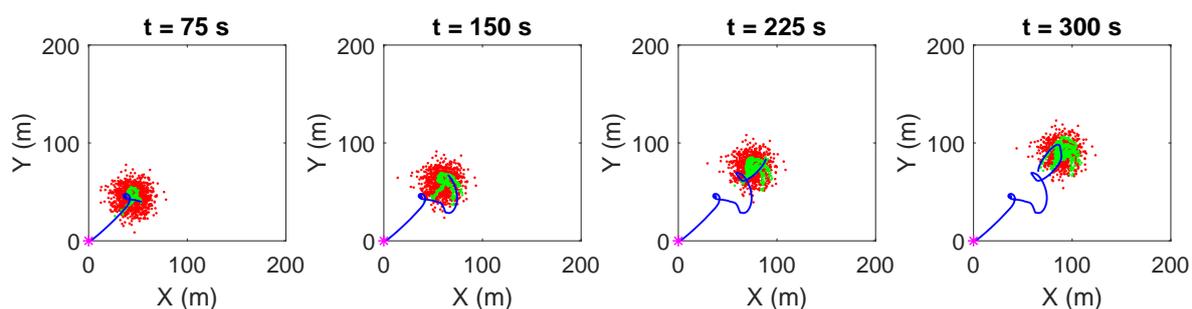


Figura 16: Escenario 1: partículas móviles por advección

En el segundo escenario, la parametrización del movimiento de las partículas contaminantes incluye una componente dispersiva, es decir, a medida que la mancha se desplaza por el agua se va expandiendo, disminuyendo gradualmente la densidad de partículas por unidad de volumen. Con el mismo criterio que antes, en la figura 17 se presenta el recorrido a realizar por el barco calculado por el optimizador. En ella se aprecia que los bucles

del barco son más amplios para intentar maximizar las partículas observadas durante su desplazamiento.

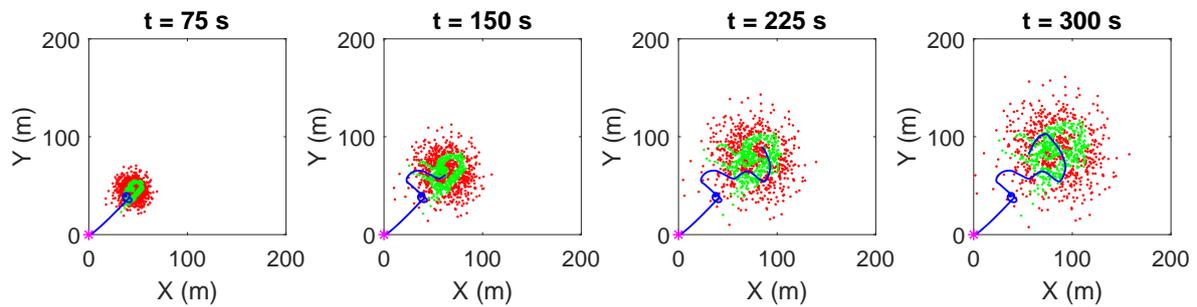
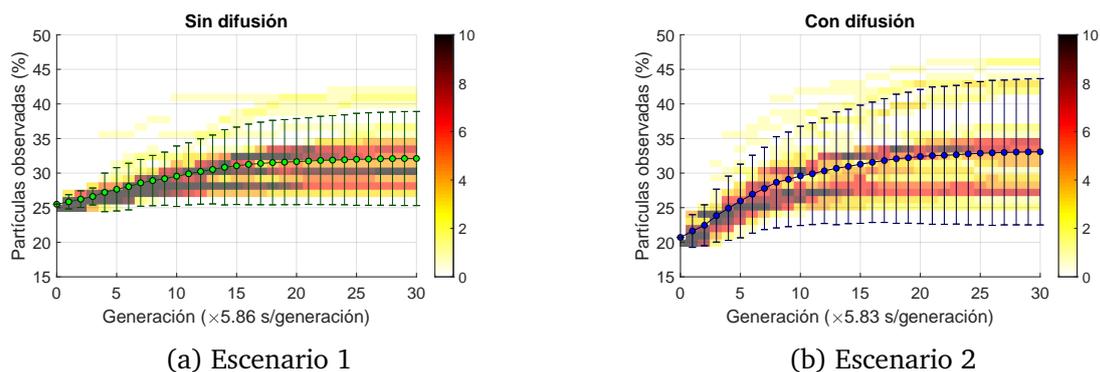


Figura 17: Escenario 2: partículas móviles por advección y difusión

En el análisis actual, el algoritmo genético es mono-objetivo, siendo la función *fitness* (que se ha de maximizar) el porcentaje de partículas que la embarcación es capaz de detectar a lo largo del recorrido de su trayectoria. A fin de estudiar cada escenario de forma individual, se han representado en cada una de las gráficas de la figura 18 un histograma de resultados por generación. En la gráfica del segundo escenario (a la derecha) se muestra una mayor dispersión que en la del primero (a la izquierda), lo que es lógico considerando que el escenario que no presenta el proceso de difusión mantiene las partículas contaminadas confinadas en un área constante. Por otra parte, los gráficos reflejan que la distribución de los valores de la función objetivo (número de partículas observadas) en cada generación no sigue una distribución gaussiana.



(a) Escenario 1

(b) Escenario 2

Figura 18: Histogramas de los resultados obtenidos

5.3.2. Varios barcos

El problema que se presenta en este Trabajo es apropiado para ser extendido al uso de más de una embarcación para el rastreo del embalse. A continuación, a lo largo de este apar-

tado se contrastarán los resultados obtenidos por el Planificador I realizando la exploración con un solo barco y con dos barcos.

El escenario de contaminación que se planteará será el compuesto por dos manchas de partículas, aproximadamente equidistantes al punto de partida del barco (segundo escenario de la figura 5).

En la primera optimización se obtendrá la trayectoria de un único barco. La función objetivo a maximizar, para este caso, será la misma que la de la sección anterior: el porcentaje de partículas observadas.

El segundo caso requiere una atención especial debido a la presencia simultánea de dos barcos en la superficie del agua, con lo que surge la necesidad de incluir un segundo objetivo en el problema. Es decir, no solo se ha de intentar maximizar la cantidad de partículas observadas sobre el total –que se representa como f_1 en la expresión (16)–, sino que además se ha de minimizar el número de choques que se puedan producir –representado por f_2 – debido al cruce de trayectorias en el mismo instante de tiempo. En la función *fitness* del caso con varios vehículos se contemplan, por tanto, dos objetivos. Retomando las conclusiones del apartado 5.2.2, estos se combinarán linealmente en una función mono-objetivo, quedando:

$$f = f_1 - f_2 \quad (16)$$

donde los pesos de cada objetivo se han determinado experimentalmente realizando varios ensayos. Con esta configuración se consigue igualar la importancia de aumentar la proporción de contaminación que se logra percibir, y la de evitar la oportunidad de que se produzca una colisión entre los vehículos. La distancia de seguridad de estos es 1,5 m.

En la figura 19 se visualizan la mejor solución obtenida por el Planificador I para cada una de las configuraciones descritas. A primera vista, las trayectorias que realizan no parecen

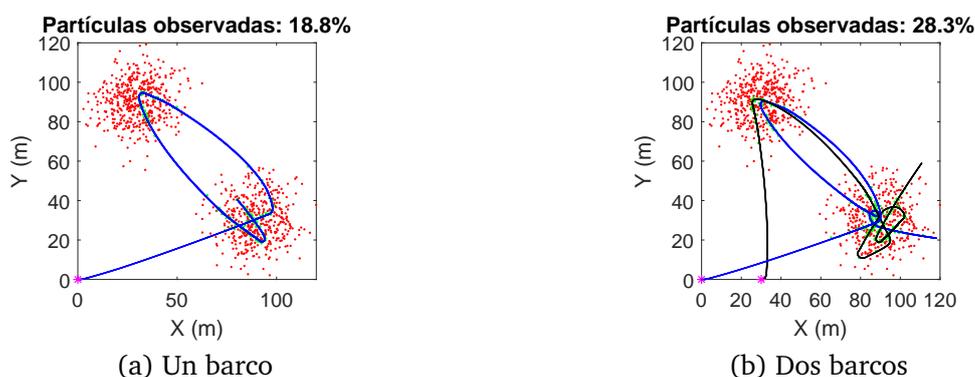


Figura 19: Exploración con uno y dos barcos en el escenario propuesto

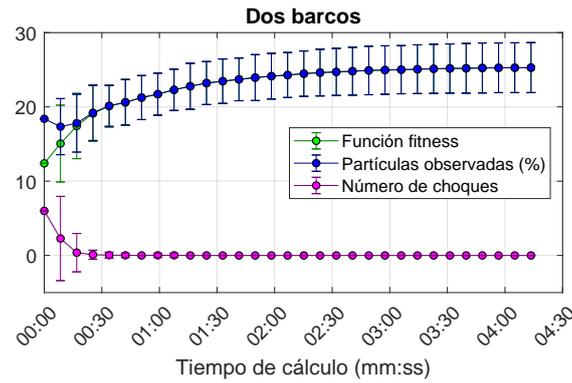
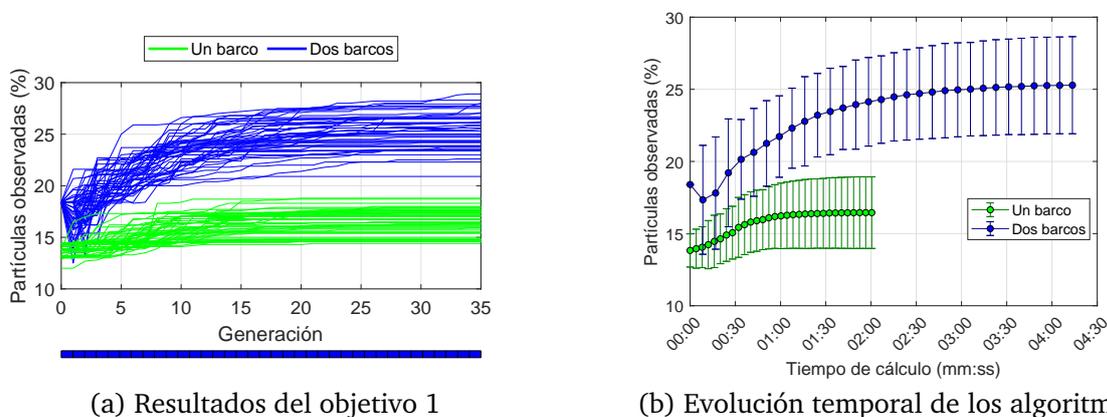


Figura 20: Evolución detallada del algoritmo mono-objetivo

ser las más eficientes, puesto que hay demasiado recorrido empleado en trasladarse de una mancha a otra. Será un aspecto negativo a analizar más adelante.

Por otra parte, se ha comprobado que el número de choques en la optimización de dos barcos (es decir, el objetivo segundo, f_2) se reduce a cero en las 10 primeras generaciones del algoritmo. Para ponerlo de manifiesto, en la figura 20 se representan, en función del tiempo, los valores óptimos de los objetivos individuales en cada iteración (generación) del algoritmo mono-objetivo. Se comprueba, en efecto, que tras estas 10 primeras iteraciones, la función *fitness* f es equivalente al primer objetivo f_1 , ya que $f_2 = 0$.

Por este motivo, es posible comparar el rendimiento de la optimización de ambos estudios en base al primer objetivo exclusivamente, común en ellos. En la figura 21a se presentan los resultados de las mejores soluciones de las 50 computaciones de cada caso por número de generación, y en la figura 21b sus respectivas medias y desviaciones estándar. Lo primero que llama la atención de la segunda figura es la diferencia en el tiempo total que emplea el optimizador de cada configuración: el caso de dos barcos duplica al de uno. Esto se justifica en base a que la carga computacional se dobla, ya que el optimizador ha de simular el



(a) Resultados del objetivo 1

(b) Evolución temporal de los algoritmos

Figura 21: Comparativa de resultados entre dos configuraciones distintas sobre el mismo escenario.

movimiento del doble de vehículos que en el primer caso. Por otra parte, aunque en menor medida, el tiempo de cómputo también se ve afectado por el hecho de que el algoritmo genético está operando con *cromosomas* (individuos) del doble de longitud.

Al comparar la evolución del algoritmo de las dos configuraciones, se aprecia que en el segundo caso se consigue observar mayor cantidad de partículas, como es lógico, ya que la operación se realiza con dos barcos. Sin embargo, debido a que éstos “desaprovechan” parte del tiempo de la exploración transitando entre las manchas, el resultado final no llega a ser el doble de porcentaje respecto a la exploración con un único barco. Una buena solución sería aquella en la que cada barco se dirigiera a una mancha y la recorriera, de forma independiente del otro (lo que minimizaría también el número de choques).

Es importante destacar que al analizar las trayectorias resultantes de la figura 19 se observa la clara dependencia de la evolución del algoritmo en función del individuo progenitor (generación 0) más adaptado, es decir, de la semilla que se generó inicialmente. Esta semilla estaba calculada con el objetivo de que la ruta de un barco se proyectase en dirección de los *waypoints*, navegando de uno a otro reiteradamente. El algoritmo encuentra dificultad para variar la trayectoria y encontrar otra mejor, puesto que ese es el individuo que más puntuación obtiene en la función objetivo inicialmente. El optimizador se ha quedado atrapado en torno a un mínimo local, como se refleja en la figura 21a, donde se aprecia cómo el valor objetivo del problema converge rápidamente a su valor final.

Vista la repercusión que comprende la inclusión de semillas en esta configuración del problema, se debería desarrollar una metodología adecuada para la generación de semillas en escenarios que incluyan diferentes focos de polución e integren varias embarcaciones en la expedición.

5.4. Planificador II

Tras evaluar en diversas condiciones el Planificador I, se dará paso al Planificador II, encargado de la optimización de la altura de la sonda. Para este estudio se emplearán los dos escenarios propuestos en la sección 3.2 (figura 6).

Puesto que ya se ha evaluado en detalle el Planificador I, para esta subsección se estudiará únicamente la optimización de la profundidad del sensor. Es decir, para cada escenario se partirá de la mejor solución obtenida tras calcular 50 optimizaciones con el Planificador I mono-objetivo (con la función *fitness* como el porcentaje de partículas observadas). Una

vez definida la ruta a seguir por la embarcación, el proceso de estudio es el habitual: se ejecutarán 50 computaciones del Planificador II y se analizarán los resultados obtenidos estadísticamente.

El algoritmo genético del Planificador II es mono-objetivo puro. La función objetivo a maximizar será la fracción de partículas contaminantes que consigue medir (o recoger) sobre la cantidad que es capaz de observar en toda la trayectoria –resultado que se obtiene directamente del Planificador I–.

Antes de proceder con el análisis, conviene indicar que durante el diseño de este planificador se planteó la posibilidad de incluir un segundo objetivo que lograra restringir el rango de profundidades en el que puede moverse el sensor de medida al rango $z \in [-1, -10]$. Para ello, se configuró una segunda función objetivo que penalizase las soluciones que excedían este margen establecido, otorgándole un valor proporcional al exceso de distancia y al número de instantes de tiempo en los que ocurría. Tras varios ensayos, se descartó la necesidad de incluir este segundo objetivo en el planificador, ya que el mecanismo propio del algoritmo genético construye la solución de acuerdo a la distribución de partículas en el volumen, que ya cumplen la restricción $z \in [-1, -10]$. Es decir, la función de penalización no ofrece ninguna contribución en las últimas iteraciones del algoritmo genético cuando la solución comienza a converger debido a que la señal de control de la sonda está muy guiada por la presencia de partículas –que es tenida en cuenta por la función objetivo–.

Tomando el tercer escenario presentado en la figura 6a, a continuación se muestra el resultado final de la trayectoria del barco y la profundidad de la sonda. En este escenario se presenta una distribución alargada y sinusoidal con la altura variando de forma monótonamente creciente. Se ha reproducido la mejor solución obtenida (figura 22), en la que el porcentaje de partículas que se observan con el Planificador I es 57,5%. Tras optimizar la altura de la sonda (tomando la mejor solución de las 50 optimizaciones), el porcentaje de partículas que recoge sobre las observadas es un 72,3%. De esta forma, finalmente, la

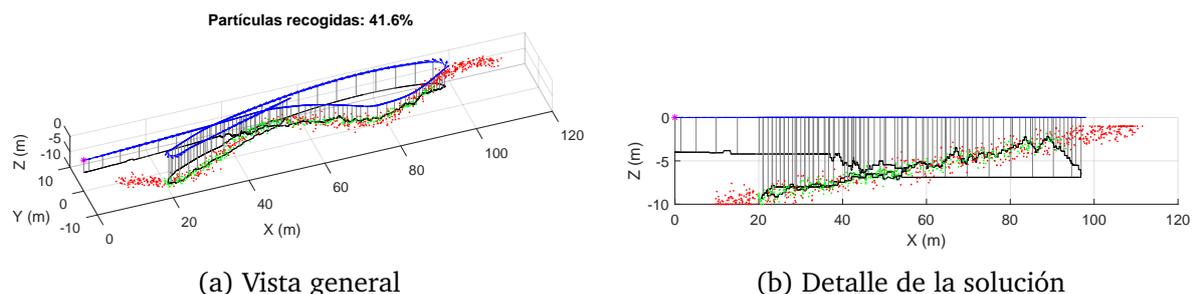


Figura 22: Escenario: patrón sinusoidal

embarcación consigue atrapar el 41,6% del total de partículas contaminantes en su exploración.

En la vista en detalle de la solución (figura 22b) se aprecia una línea horizontal que podría confundir al lector. Esta corresponde a la parte de la trayectoria que, en la vista general (figura 22a), queda en la zona posterior de la mancha de partículas. Puesto que en esos puntos de la ruta no observa ninguna partícula, la posición de la sonda se mantiene fija, tal como se configuró el Planificador II (sección 4.3).

A su vez, la optimización de la exploración en el segundo escenario elegido (cuarto escenario de la figura 6b) se ha plasmado en la figura 23. La distribución de partículas conforma una circunferencia, cuyo plano forma un pequeño ángulo con respecto al eje Z, de forma que la profundidad de las partículas a lo largo del borde varía de forma continua. En este caso, el resultado de la función objetivo del Planificador I para el individuo óptimo es 61,8%. Tras pasar esta solución por el Planificador II, con la mejor solución se recogen un 95,8% de las partículas observadas. Con ello, finalmente se logran medir el 59,2% del conjunto total de partículas contaminantes.

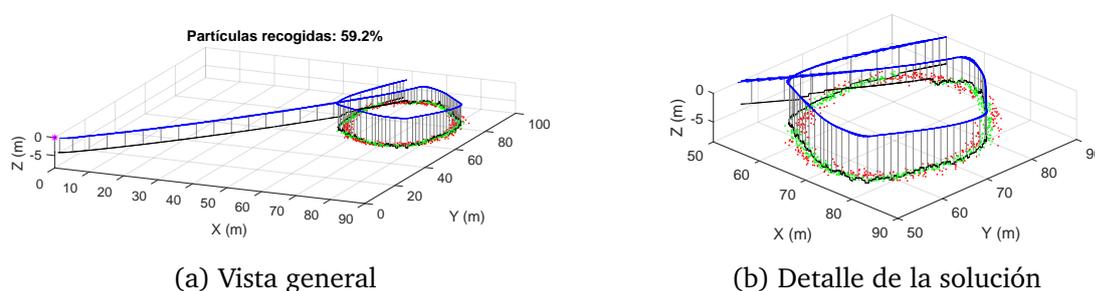


Figura 23: Escenario: patrón circular

En ambos escenarios, la ruta que se obtiene con el Planificador I es suficientemente eficiente, ya que consigue perfilar la forma de los patrones. Se aprecia que el optimizador del primer planificador encuentra más dificultad en delinear el patrón abierto que el cerrado. En cuanto al Planificador II, de forma gráfica se puede valorar el buen rendimiento de este, ya que ajusta correctamente la señal de control de la sonda para posicionarla en la zona de la columna de agua en la que percibe la sustancia contaminante.

En las figuras 24 se muestra la evolución temporal del algoritmo para cada escenario, representando el histograma de las mejores soluciones de las 50 optimizaciones en cada caso. Se destaca la poca dispersión de los resultados del Planificador II en comparación con los que se han ido observando en el Planificador I. Aún más, la distribución que se

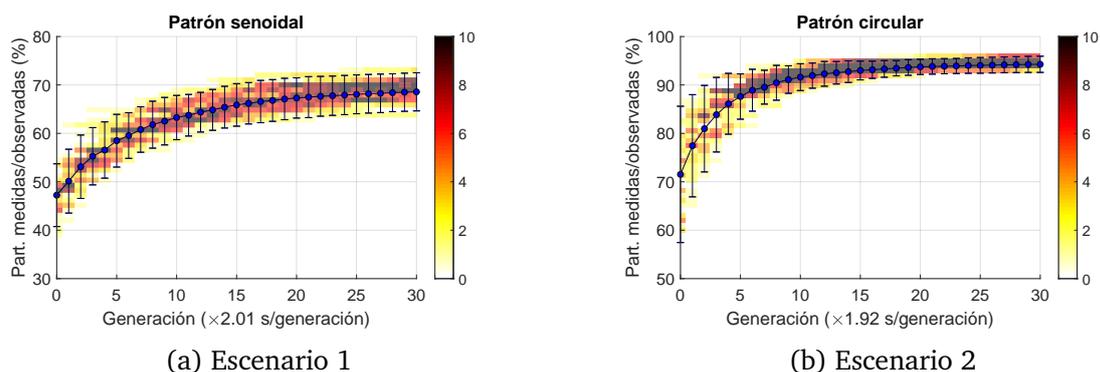


Figura 24: Histogramas de los resultados obtenidos

obtiene con estos resultados se ajusta en mayor medida a una gaussiana, según se puede examinar con la intensidad de color de los *bines* del histograma. Otro aspecto a considerar es el tiempo total de computación, mucho menor a los casos vistos previamente a lo largo de este Trabajo. Esto se debe al motivo ya discutido anteriormente: en este planificador, la carga computacional del optimizador es mucho más ligera (no ha de simular el movimiento del barco). Además, el número de variables que conforman el *chromosoma* del algoritmo genético en este caso es mucho menor.

6. Conclusiones y trabajo futuro

En esta sección se destacarán las conclusiones que se han ido obteniendo a lo largo del Trabajo, retomando los objetivos iniciales descritos en la sección 1.3. Posteriormente se indicarán las líneas de trabajo futuro.

6.1. Conclusiones

En este Trabajo se ha desarrollado una herramienta de planificación de trayectorias automática de pequeñas embarcaciones autónomas para la monitorización de contaminantes en embalses, que constituye el objetivo principal.

A continuación se analizan los logros alcanzados respecto a los objetivos secundarios:

1. Se ha realizado un estudio de las técnicas actuales de monitorización de la calidad del agua en embalses, en el que se ha profundizado en las tácticas de seguimiento de los puntos de control establecidos por la legislación. En base a esto, se ha puesto de manifiesto la necesidad de incorporar embarcaciones no tripuladas para realizar la toma de muestras en el embalse. Además, se ha llevado a término un estudio de

los modelos hidrodinámicos más relevantes de la literatura y herramientas *software* disponibles para simular el comportamiento de los contaminantes. Dada la alta complejidad que conlleva la aplicación de estos métodos, el Trabajo se ha centrado más en la parte de planificación de rutas para los vehículos.

2. El modelado del problema se ha separado en dos componentes. Por una parte, el modelado del barco se ha inspirado en un modelo real, ajustando los parámetros del simulador propuesto a una dinámica realista. Por otra parte, se ha realizado un modelo de contaminación inspirado en los ya existentes, pero simplificado y basado en partículas, con capacidad de movimiento y diferentes geometrías. Ambos elementos se han introducido con éxito en las funciones de evaluación de los algoritmos genéticos.
3. Se ha profundizado en el funcionamiento de los algoritmos genéticos, una herramienta de optimización gran versatilidad. Para ello, se han analizado cada uno de los parámetros intrínsecos que los describen, tales como el operador de cruce, la población inicial, la función objetivo. Además, se ha estudiado como aplicarlos a problemas multiobjetivo: mediante la combinación lineal de los criterios de optimización o mediante su extensión a la optimización Pareto. También se ha aprendido a caracterizar su funcionamiento de forma estadística, complementado los resultados con los obtenidos mediante el test de Wilcoxon.
4. El planificador desarrollado, basado en algoritmos genéticos, se ha dividido en dos etapas. En la primera se obtiene la trayectoria a efectuar por el barco sobre la superficie del agua, considerando que es capaz de observar toda la columna de agua situada debajo de él. En la segunda etapa se optimiza la profundidad de la sonda de medida a lo largo de esa ruta. Este planificador es capaz de funcionar con múltiples vehículos y adaptarse a modelos móviles de partículas contaminantes.
5. Se ha efectuado un análisis estadístico de los resultados obtenidos por cada uno de los planificadores bajo diferentes configuraciones de escenarios de contaminación. De este análisis se extraen diferentes conclusiones:
 - La configuración del operador de cruce más eficiente es la que está basada en dos puntos.

- Como alternativa a los algoritmos genéticos multiobjetivo basados en frente Pareto, es posible emplear un algoritmo genético mono-objetivo en el que la función objetivo combine linealmente varios objetivos. Según como se hayan determinado los coeficientes que pesan los diversos objetivos, el resultado final del optimizador puede llegar a ser más apropiado que el obtenido mediante la configuración multiobjetivo Pareto.
- Se observa un aumento en la dispersión de las soluciones que se obtienen con el Planificador I en los escenarios en los que el conjunto de partículas contaminantes presentan movimiento.
- La semilla procesada que se introduce en la población inicial del algoritmo del Planificador I es muy dominante y no necesariamente adecuada para escenarios con múltiples cúmulos de partículas.
- A pesar de que el tiempo de cómputo que requiere la planificación de trayectorias de dos barcos simultáneamente es superior al de uno solo, su rendimiento (capacidad de observar partículas) es mayor.
- Cuando la distribución de las partículas contaminantes de un escenario no presenta gran dispersión en profundidad, el Planificador II consigue recoger una elevada proporción de las partículas situadas en la columna de agua que está situada debajo de la trayectoria de la embarcación.

6.2. Trabajo futuro

Dentro del Trabajo que se ha realizado es importante identificar las líneas de mejora o de trabajo futuro de acuerdo a las contribuciones realizadas en los sistemas de monitorización de calidad del agua.

En primer lugar, se ha de remarcar que el estudio realizado no es extensivo a todos los escenarios de contaminación, sino que es muy selectivo. De hecho, los parámetros del algoritmo genético se han ajustado para escenarios concretos, lo que no asegura que sean adecuados en otros distintos. Por tanto, se propone sistematizar el análisis de los algoritmos genéticos de cada planificador –las curvas de evolución promedio de la población, de la mejor solución, etc.– sobre todos los escenarios propuestos y otros nuevos que sean más representativos y se ajusten a prototipos sencillos más realistas de polución.

Además, tal y como se ha planteado el problema, la embarcación tiene acceso a todo el área del plano horizontal XY para desplazarse. Sin embargo, en la realidad, los embalses tienen una extensión máxima definida por sus orillas e islotes. Se propone, por tanto, añadir una restricción espacial a la planificación de trayectorias, que permita integrar el contorno inherente al embalse y su escenario de contaminación a estudiar de forma unificada.

Por otra parte, en lo que refiere a los algoritmos genéticos que constituyen los dos planificadores, se ha de subrayar nuevamente la gran importancia que yace en la inclusión de individuos procesados en la población inicial. La buena elección de estas primeras soluciones repercuten directamente en la solución final del optimizador. Por ello, se exhorta a desarrollar nuevos métodos mejorados de generación de semillas, que además tengan en cuenta la incorporación de más de un vehículo en el reconocimiento de la masa de agua.

En lo que respecta al modelo de contaminantes empleado, se ha de subrayar que es una primera aproximación (muy reducida y simplificada) inspirada en los modelos hidrodinámicos existentes en la literatura que se han citado al inicio de la memoria. Por consiguiente, se proyecta como estudio futuro el diseño y el uso de unos modelos más realistas de contaminación, que estén fundamentados en la dinámica de las partículas o sustancias contaminantes contenidas en el agua como fluido.

Finalmente, como última línea de trabajo futuro, se plantea el uso de una codificación diferente de las soluciones del Planificador I. En el presente estudio se ha tratado con soluciones basadas en las señales de control de propulsión y de timón, es decir, en acciones. De esta forma, los elementos iniciales que constituyen el *cromosoma* de la solución condicionan a todos los demás y a la trayectoria en conjunto, por lo que no es eficiente localmente –ya que un cambio en una de las acciones iniciales repercute en las posiciones posteriores de toda la trayectoria–. Una alternativa existente es codificar las soluciones basándolas en curvas paramétricas, con las que se obtiene directamente la ruta a seguir por el barco. Sin embargo, la ventaja que presenta la técnica que se ha empleado en el presente Trabajo es que permite obtener soluciones que cumplen directamente las restricciones dinámicas impuestas por el modelo del barco. Para la alternativa propuesta habría que hacer un posterior procesamiento de las trayectorias con un controlador para computar las señales de control correspondientes a ese movimiento. A pesar de que las soluciones que se construyen con el método empleado en este Trabajo no son eficaces localmente, el hecho de optimizarlas con una herramienta tan potente como son los algoritmos genéticos hace que sus mecanis-

mos propios logren producir rutas planificadas suficientemente aptas en los escenarios de contaminación propuestos.

Referencias

- [1] P. H. Gleick, “Water in crisis,” *Pacific Institute for Studies in Dev., Environment & Security. Stockholm Env. Institute, Oxford Univ. Press.* 473p, vol. 9, 1993.
- [2] “El agua dulce puede provenir de diferentes fuentes sobre la Tierra,” <http://japac.gob.mx/2016/04/01/cuales-son-las-cuatro-fuentes-de-agua-dulce>, Apr. 2016.
- [3] “Calidad de las aguas. el ciclo integral del agua,” <https://www.canaldeisabelsegunda.es/documents/20143/85299/calidad.pdf>, Feb. 2017.
- [4] “Real decreto 817/2015, de 11 de septiembre, por el que se establecen los criterios de seguimiento y evaluación del estado de las aguas superficiales y las normas de calidad ambiental,” <https://www.boe.es/boe/dias/2015/09/12/pdfs/BOE-A-2015-9806.pdf>, Sep. 2015.
- [5] “Redes de control de las masas de agua superficiales: Elementos de calidad e indicadores,” <https://www.chsegura.es/chs/cuenca/redesdecontrol/calidadenaguassuperficiales/indicadores.html>, Sep. 2015.
- [6] “Programas de seguimiento,” <https://www.miteco.gob.es/es/agua/temas/estado-y-calidad-de-las-aguas/aguas-superficiales/programas-seguimiento>, Sep. 2015.
- [7] “Saica: Red de alerta,” <https://www.miteco.gob.es/gl/agua/temas/estado-y-calidad-de-las-aguas/aguas-superficiales/programas-seguimiento/saica.aspx>.
- [8] “Grupo Álava: USV - vehículos de superficie no tripulados,” <http://www.grupoalava.com/ingenieros/productos/tecnologias-marinas-terrestres-y-ambientales/oceanografia/vehiculos/usv---vehiculos-de-superficie-no-tripulados>.
- [9] “Oceanα: Water Monitoring Systems,” <https://www.oceanalpha.com/application/environmental-monitoringwater-sampling-and-monitoring>.
- [10] “Searobotics: Autonomous Surface Vehicles,” <https://www.searobotics.com/products/autonomous-surface-vehicles>.
- [11] “L3 ASV: Geophysical Survey,” <https://www.asvglobal.com/geophysical-survey>.
- [12] D. P. Hamilton and S. G. Schladow, “Prediction of water quality in lakes and reservoirs. part i—model description,” *Ecological Modelling*, vol. 96, no. 1-3, pp. 91–110, 1997.
- [13] S. G. Schladow and D. P. Hamilton, “Prediction of water quality in lakes and reservoirs: Part ii-model calibration, sensitivity analysis and application,” *Ecological Modelling*, vol. 96, no. 1-3, pp. 111–123, 1997.

- [14] J.-T. Kuo, Y.-Y. Wang, and W.-S. Lung, "A hybrid neural-genetic algorithm for reservoir water quality management," *Water research*, vol. 40, no. 7, pp. 1367–1376, 2006.
- [15] A. F. Blumberg, "Numerical tidal model of chesapeake bay," *Journal of Hydraulic Engineering*, vol. 103, no. 1, pp. 1–10, 1977.
- [16] A. F. Blumberg and G. L. Mellor, "A description of a three-dimensional coastal ocean circulation model," *Three-dimensional coastal ocean models*, pp. 1–16, 1987.
- [17] C. F. Cerco and T. Cole, "Three-dimensional eutrophication model of chesapeake bay," *Journal of Environmental Engineering*, vol. 119, no. 6, pp. 1006–1025, 1993.
- [18] M. J. Riley and H. G. Stefan, "Minlake: a dynamic lake water quality simulation model," *Ecological Modelling*, vol. 43, no. 3-4, pp. 155–182, 1988.
- [19] Q. Jun, Y. Zhifeng, and S. Zhenyao, "Three-dimensional modeling of sediment transport in the wuhan catchments of the yangtze river," *Procedia Environmental Sciences*, vol. 13, pp. 2437–2444, 2012.
- [20] G. He, H. Fang, S. Bai, X. Liu, M. Chen, and J. Bai, "Application of a three-dimensional eutrophication model for the Beijing guanting reservoir, china," *Ecological Modelling*, vol. 222, no. 8, pp. 1491–1501, 2011.
- [21] "SPARROW: Modeling of Water Quality," <https://water.usgs.gov/nawqa/sparrow>.
- [22] "WASP: Water Quality Analysis Simulation Program," <https://www.epa.gov/ceam/water-quality-analysis-simulation-program-wasp>.
- [23] "Delft3D: 3D/2D modelling suite for integral water solutions," <https://oss.deltares.nl/web/delft3d>.
- [24] "QUAL2EU," <https://www.epa.gov/ceam/qual2eu>.
- [25] T. I. Fossen, *Marine control system-guidance, navigation and control of ships, rigs and underwater vehicles*. Marine Cybernetics, 2002.
- [26] E. G. David *et al.*, "Genetic algorithms in search," *Optimization and Machine Learning*, Reading, Massachusetts, 1989.
- [27] M. Gestal, D. Rivero, J. R. Rabuñal, J. Dorado, and A. Pazos, *Introducción a los algoritmos genéticos y la programación genética*. Universidade da Coruña, 2010.
- [28] J. A. Prera Ivara, *Implementación de sistema híbrido inteligente formado por red neuronal tipo art y algoritmo genético*. Universidad Nacional de San Carlos de Guatemala, 2011.
- [29] F. Wilcoxon, "Individual comparisons by ranking methods," *Biometrics bulletin*, vol. 1, no. 6, pp. 80–83, 1945.