



Máster en Ingeniería de Sistemas y Control

Trabajo de Fin de Máster

Optimización de trayectorias 3D de búsqueda de UAVs mediante algoritmos genéticos con codificaciones a medida

Alumno: Iván Suárez López

Directores: Eva Besada Portas & Sara Pérez Carabaza

Curso 2016-2017

Convocatoria: Febrero 2017

Máster en Ingeniería de Sistemas y Control

Optimización de trayectorias 3D de búsqueda de UAVs mediante algoritmos genéticos con codificaciones a medida

Proyecto específico propuesto por un profesor

Alumno: Iván Suárez López

Directores: Eva Besada Portas & Sara Pérez Carabaza

Curso 2016-2017

Convocatoria: Febrero 2017



Autorización

Autorizamos a la Universidad Complutense de Madrid (UCM) y a la Universidad Nacional de Educación a Distancia (UNED) a difundir y utilizar con fines académicos, no comerciales y mencionando expresamente a sus autores, tanto la memoria de este Trabajo Fin de Máster, como el código, la documentación y/o el prototipo desarrollado.

Firmado: Iván Suárez López

A handwritten signature in black ink, which appears to read 'Iván Suárez López', followed by two short horizontal strokes at the end.

Firma del alumno

Resumen

El presente Trabajo de Fin de Máster consiste en un estudio de las posibilidades que ofrecen los GA (Algoritmos Genéticos) como solución al problema de la búsqueda de objetivos estáticos en tiempo mínimo (MTS, Minimum Time Search). Dicho problema radica en la obtención de las trayectorias óptimas de movimiento para un conjunto de UAVs cuya misión es encontrar lo antes posible un objetivo del que se desconoce su posición exacta, disponiéndose sin embargo de un mapa de distribución de probabilidad con las posibles localizaciones del mismo y de un modelo probabilístico que representa la eficacia del sensor con el que están equipados los UAVs encargados de realizar la búsqueda.

En este Trabajo de Fin de Máster, a partir de un sistema inicial basado en GA que permite obtener soluciones de una versión simplificada del problema, en la que la única variable de control de los UAVs que se emplea es su dirección, se desarrolla una nueva serie de variantes del GA (un total de 5 versiones) en las que se emplean tres variables de control diferentes (dirección, velocidad, altura) con la intención de obtener un conjunto de soluciones al problema MTS más amplio. Se busca, además de mejorar el sistema, realizar un estudio de cómo, a partir de un mismo conjunto de variables de control, diferentes codificaciones del mismo en las soluciones del GA (diferentes estructuras de genoma del GA) pueden dar lugar a resultados de diferente calidad. Para ello, se han diseñado una serie de escenarios de prueba variando algunos de los parámetros del problema, y se ha realizado una comparativa de como la versión inicial y las nuevas versiones del GA se comportan en tales casos.

Los resultados obtenidos indican una importante variabilidad en la calidad de las soluciones obtenidas en función de la codificación empleada, determinándose además que la selección de la codificación más favorable para la resolución del problema MTS puede depender de las condiciones del escenario. Por otra parte, se constata que las codificaciones basadas en variaciones de las tres variables de control de los UAVs superan en todos los casos a la versión inicial en la que solo se permite variar su orientación.

Palabras clave

Planificación de Caminos para UAVs - Búsqueda en Tiempo Mínimo - Algoritmos Genéticos Multiobjetivo - Representación de Soluciones

Índice

Resumen	4
Palabras clave	4
Índice	5
Lista de Ilustraciones	8
Lista de Tablas.....	10
1 Introducción.....	11
1.1 Estado del Arte	13
1.2 Objetivos.....	16
1.3 Organización de la memoria.....	17
2 Búsqueda en Tiempo Mínimo (MTS)	18
2.1 Descripción general	18
2.2 Modelo probabilístico del objetivo	18
2.3 Modelo probabilístico del sensor de los UAVs.....	19
2.4 Modelo cinemático de los UAVs.....	21
2.5 Criterios de evaluación de soluciones	23
2.5.1 Factibilidad de soluciones (NFZs, detección de colisiones)	23
2.5.2 Optimización del tiempo esperado de localización (ET).....	25
2.5.3 Optimización del criterio heurístico de miopía (MYOP)	26
2.5.4 Optimización del criterio heurístico de suavidad (SMOOTH)	29
2.5.5 Optimización del criterio de ahorro de combustible (FUEL)	29
3 GA Multi-etapa para trayectorias de dirección variable.....	30
3.1 Estructura general del GA.....	30
3.1.1 Inicialización.....	33
3.1.2 Evaluación de soluciones	33
3.1.3 Operador de Selección.....	34
3.1.4 Operador de Cruce.....	36
3.1.5 Operador de Mutación	37
3.1.6 Operador de Recombinación	38
3.1.7 Parada y obtención de la solución	40
3.2 Algoritmo GA Multi-etapa	40
4 GA Multi-etapa para trayectorias de dirección, velocidad y altura variables	43

4.1 Codificación de soluciones	44
4.1.1 Codificación 2 (variaciones de dirección, velocidad o altura)	44
4.1.2 Codificación 3 (variaciones de dirección, velocidad o altura y posibilidad de no variación)	46
4.1.3 Codificación 4 (variaciones de dirección, velocidad y altura simultáneas)	47
4.1.4 Codificación 5 (variaciones de combinaciones de dirección, velocidad y altura simultáneas).....	49
4.1.5 Codificación 6 (variaciones de dirección, velocidad o altura en subsecuencias)	50
4.1.6 Referencia de codificaciones	53
4.2 Desarrollo del GA Multi-etapa para trayectorias de dirección, velocidad y altura variables.	53
4.2.1 Modelo cinemático de los UAVs	54
4.2.2 Criterios de evaluación de soluciones	54
4.2.3 Inicialización.....	55
4.2.4 Evaluación de soluciones	56
4.2.5 Operador de Cruce.....	56
4.2.6 Operador de Mutación	57
5 Resultados.....	60
5.1 Pruebas cualitativas.....	60
5.1.1 Codificación 1.....	62
5.1.2 Codificación 2.....	64
5.1.3 Codificación 3.....	65
5.1.4 Codificación 4.....	67
5.1.5 Codificación 5.....	68
5.1.6 Codificación 6.....	69
5.2 Pruebas cuantitativas	71
5.2.1 Descripción de escenarios	73
5.2.1.1 Escenario 1.....	73
5.2.1.2 Escenario 2.....	75
5.2.1.3 Escenario 3.....	76
5.2.1.4 Escenario 4.....	78
5.2.1.5 Escenario 5.....	79
5.2.1.6 Escenario 6.....	81
5.2.2 Resultados cuantitativos.....	82
5.2.2.1 Comparativa general de codificaciones.....	83
5.2.2.2 Comparativa de codificaciones sin variaciones simultáneas de variables de control	85
6 Conclusiones	87
6.1 Consecución de objetivos.....	87

6.2 Conclusiones obtenidas.....	87
6.3 Líneas de trabajo futuras.....	88
Bibliografía.....	90
Siglas, abreviaturas y acrónimos.....	93
Anexo 1 - Correspondencia de funciones Matlab	94
Modelos de elementos del problema MTS	94
Operadores de los GA Multi-etapa.....	94
Anexo 2 - Ejemplos de soluciones a los escenarios de las pruebas cuantitativas empleando la	
Codificación 4.....	95
Escenario 1	95
Escenario 2	96
Escenario 3	96
Escenario 4	97
Escenario 5	97
Escenario 6	98

Lista de Ilustraciones

Ilustración 1 - UAV de diseño similar a un avión	11
Ilustración 2 - Representación esquemática del problema MTS	12
Ilustración 3 – (Izquierda) Fórmula interpolada de probabilidad P de detección de un submarino, en función de la visibilidad V y la distancia al avión W - (Derecha) Fotografía de un convoy realizada desde un hidroavión de escolta	13
Ilustración 4 - Mapa de creencia inicial de un escenario del problema MTS	19
Ilustración 5 - Ejemplo de curva de probabilidad de detección del sensor de un UAV en función de la distancia al posible objetivo.....	20
Ilustración 6 - Modelo cinemático de un UAV real.....	21
Ilustración 7 - Ejemplo de mapa de probabilidad con varias NFZs marcadas en negro	24
Ilustración 8 - Efecto en MYOP de la no alineación hacia τ de la dirección final de la trayectoria del UAV	28
Ilustración 9 - Efecto en MYOP de la necesidad de rodear NFZs.....	28
Ilustración 10 - Ejemplo de un tipo de solución y de dos genomas diferentes para la misma	31
Ilustración 11 - Esquema de operadores de un GA típico	32
Ilustración 12 - Selección mediante torneo binario	36
Ilustración 13 - Cruce mediante corte en un único punto de corte	37
Ilustración 14 - Mutación mediante incremento por distribuciones gaussianas	38
Ilustración 15 - Subdivisión de un problema mediante GA Multi-etapa y composición de la solución al problema original	42
Ilustración 16 - Ejemplo de genoma empleando la Codificación 2.....	45
Ilustración 17 - Ejemplo de genoma empleando la Codificación 3.....	46
Ilustración 18 - Ejemplo esquemático de punto de máxima probabilidad de presencia del objetivo tras una NFZ.....	47
Ilustración 19 - Ejemplo de genoma empleando la Codificación 4.....	48
Ilustración 20 - Ejemplo de genoma empleando la Codificación 5.....	50
Ilustración 21 - Ejemplo de genoma empleando la Codificación 6.....	52
Ilustración 22 - Escenario con diferentes tipos de zonas de alta probabilidad de presencia del objetivo y varias NFZs	60
Ilustración 23 - Trayectoria empleando la Codificación 1	63
Ilustración 24 - Trayectoria empleando la Codificación 2	64
Ilustración 25 - Trayectoria empleando la Codificación 3	66
Ilustración 26 - Trayectoria empleando la Codificación 4	67

Ilustración 27 - Trayectoria empleando la Codificación 5	68
Ilustración 28 - Trayectoria empleando la Codificación 6	70
Ilustración 29 - Ejemplo de matriz de comparación entre algoritmos	72
Ilustración 30 - Escenario 1.....	74
Ilustración 31 - Escenario 2.....	75
Ilustración 32 - Escenario 3.....	77
Ilustración 33 - Escenario 4.....	78
Ilustración 34 - Escenario 5.....	80
Ilustración 35 - Escenario 6.....	81
Ilustración 36 - Matrices de comparación obtenidas en las pruebas cuantitativas	84
Ilustración 37 - Ejemplo de solución al Escenario 1.....	95
Ilustración 38 - Ejemplo de solución al Escenario 2.....	96
Ilustración 39 - Ejemplo de solución al Escenario 3.....	96
Ilustración 40 - Ejemplo de solución al Escenario 4.....	97
Ilustración 41 - Ejemplo de solución al Escenario 5.....	97
Ilustración 42 - Ejemplo de solución al Escenario 6.....	98

Lista de Tablas

Tabla 1 - Codificación de las variables de control modificadas en la Codificación 5.....	50
Tabla 2 - Referencia de codificaciones de soluciones del GA.....	53
Tabla 3 - Parametrización del GA Multi-etapa y del escenario para las pruebas cualitativas.....	62
Tabla 4 - Señales de control del UAV empleando la Codificación 1.....	63
Tabla 5 - Señales de control del UAV empleando la Codificación 2.....	65
Tabla 6 - Señales de control del UAV empleando la Codificación 3.....	66
Tabla 7 - Señales de control del UAV empleando la Codificación 4.....	68
Tabla 8 - Señales de control del UAV empleando la Codificación 5.....	69
Tabla 9 - Señales de control del UAV empleando la Codificación 6.....	71
Tabla 10 - Parametrización del GA Multi-etapa y del Escenario 1.....	75
Tabla 11 - Parametrización del GA Multi-etapa y del Escenario 2.....	76
Tabla 12 - Parametrización del GA Multi-etapa y del Escenario 3.....	78
Tabla 13 - Parametrización del GA Multi-etapa y del Escenario 4.....	79
Tabla 14 - Parametrización del GA Multi-etapa y del Escenario 5.....	81
Tabla 15 - Parametrización del GA Multi-etapa y del Escenario 6.....	82
Tabla 16 - Resultados totales de comparación entre todas las versiones del GA Multi-etapa.....	83
Tabla 17 - Resultados totales de comparación entre las versiones del GA Multi-etapa basadas en codificaciones no teóricas.....	85
Tabla 18 – Resultados por escenario de las versiones del GA Multi-etapa basadas en las Codificaciones 2 y 6.....	86
Tabla 19 - Modelos de elementos del problema MTS.....	94
Tabla 20 - Operadores de los GA Multi-etapa.....	94

1 Introducción

El mundo actual vive sumido en una enorme revolución tecnológica, cuyas bases se desarrollan a lo largo de todo el siglo XX, culminando en lo que actualmente se conoce como la Era de la Información o Era Digital. Esta última etapa, cuyo inicio puede fecharse en torno a la década de los 70, podría distinguirse de las anteriores en el sentido de que los grandes avances tecnológicos están habitualmente ligados al desarrollo de sistemas de información que los hacen posibles.

Estos sistemas de información han ido evolucionando desde plataformas muy exclusivas y costosas, al alcance tan solo de gobiernos de Estados o empresas multinacionales para proyectos de carácter muy ambicioso, hasta llegar a una situación como la actual en la que los aparatos más sencillos y cotidianos están dotados de o están conectados a sistemas de información. El abaratamiento de los costes de producción de la tecnología, y el desarrollo de las redes de telecomunicaciones en general, y de la red Internet en particular, han permitido primero el auge de los dispositivos móviles y, en última instancia, el concepto del Internet de las Cosas, impensable siquiera hace 10 años.

Al diversificarse los campos de actuación de los sistemas de información, se ramifican igualmente el tipo de problemas a los que estos deben enfrentarse. Una de las disciplinas más extensas y complicadas es la de la robótica, que en realidad combina aspectos técnicos muy anteriores a los sistemas de información (mecánica, movimiento, sensores) con retos informáticos enormemente complejos (procesamiento de señales, toma de decisiones, actuación independiente, ...). Curiosamente, la proliferación y el abaratamiento de la tecnología antes mencionados han permitido que se plantee en la actualidad el desarrollo de robots relativamente sencillos para realizar tareas bastante simples, como por ejemplo limpiar el suelo de una casa.

Una clase de robot a cuyo desarrollo se está prestando actualmente una atención de carácter especial es la de los vehículos aéreos no tripulados (UAV, Unmanned Aerial Vehicle), como el que se muestra en la Ilustración 1. Estos vehículos cuentan con la capacidad inherente de verse libres de los problemas asociados a la existencia de obstáculos, diferentes tipos de terreno y restricciones mecánicas a los que se ven sujetos los robots terrestres.



Ilustración 1 - UAV de diseño similar a un avión

El desarrollo de este tipo de robots permite plantearse a día de hoy obtener resultados prácticos para determinadas aplicaciones en las que las necesidades incluyan relativamente poca interacción física con el entorno. Los campos de aplicación en los que ya se están empleando con

éxito sistemas basados en UAVs más o menos autónomos son muy diversos: topografía (elaboración de mapas), agricultura (monitorización de cultivos, fumigación automatizada), meteorología (detección y análisis de lluvias, tormentas, huracanes), zoología (seguimiento de especies animales), industria (mantenimiento de instalaciones de difícil acceso), seguridad (reconocimiento de zonas peligrosas), etc.

Un problema común a la mayoría de estas aplicaciones consiste en la obtención de los caminos o trayectorias óptimas a seguir por los UAVs para cumplir sus funciones. De forma genérica, dichas funciones suelen consistir en alcanzar uno o varios objetivos (posiblemente para realizar alguna acción relacionada con ellos), cumpliendo algunas restricciones durante la trayectoria. Una particularización de este problema es el de la búsqueda en tiempo mínimo (MTS, Minimum Time Search, [15, 16, 17, 21]), sobre el cual versa el presente Trabajo de Fin de Máster.

En el problema MTS se especifica que la misión del conjunto de UAVs (denominados formalmente *agentes de búsqueda*) es localizar, empleando el menor tiempo posible, un determinado objetivo cuya posición exacta no se conoce, sino que en su lugar se dispone de un mapa de probabilidad que indica en qué zonas hay una mayor esperanza de que se encuentre dicho objetivo. Además, se permite la definición de zonas prohibidas de vuelo (NFZs, Non-Flying Zones), que los UAVs deben evitar.

En la Ilustración 2 se observa una representación gráfica del problema MTS, en la que el mapa de probabilidad del objetivo indica mediante colores cálidos (tendiendo hacia rojo) las zonas en las que la probabilidad de presencia del objetivo es mayor y, mediante colores fríos (tendiendo hacia azul) las zonas en las que dicha probabilidad es menor. Se representan también dos agentes de búsqueda dirigiéndose hacia zonas de alta probabilidad de presencia del objetivo.




Ilustración 2 - Representación esquemática del problema MTS

El problema genérico MTS puede corresponder con diversas aplicaciones en el mundo real, tales como misiones de búsqueda y rescate de personas extraviadas, misiones de ataque o reconocimiento de objetivos militares, misiones de recuperación de restos de accidentes, misiones de detección de materiales nocivos para el medio ambiente, etc.

La resolución de problemas que, como el MTS, consisten en la obtención de trayectorias óptimas de movimiento de un robot o conjunto de robots en función de diversos criterios ha sido abordada desde hace muchos años, inicialmente con métodos clásicos ([8, 11, 26, 27, 30]), que con el tiempo se han demostrado como insuficientes para enfrentarse a problemas de dimensión realista, desplazándose la tendencia en los últimos años hacia el empleo de algoritmos de

optimización estocásticos y heurísticos de diversas familias ([1, 2, 3, 4, 5, 9, 10, 14, 20, 21, 23, 24, 25, 31, 32, 34]). Este último tipo de algoritmos son no deterministas y, por tanto, no garantizan ni pretenden la solución óptima al problema. En esta clase se engloban los Algoritmos Genéticos (GA [1, 4, 5, 9, 12, 19, 21, 22]), sobre cuya aplicación a MTS versa este trabajo.

El empleo de este tipo de algoritmos no deterministas se fundamenta en la asunción de que, para la obtención de resultados prácticos, resulta más interesante un algoritmo que encuentre soluciones suficientemente buenas, aunque no sean óptimas, que un algoritmo ideal cuya implementación sea en la práctica irrealizable por no disponerse de la capacidad de cómputo necesaria para obtener la solución óptima en un tiempo admisible.

1.1 Estado del Arte

El problema de la obtención de trayectorias óptimas de búsqueda ya fue abordado por investigadores del *Operations Research Group* (Grupo de Investigación Operativa) de la Marina de EEUU durante la Segunda Guerra Mundial, principalmente para la resolución de diversos problemas relacionados con la guerra submarina llevada a cabo por Alemania en el Océano Atlántico. Entre ellos se puede destacar la generación de las rutas óptimas en cuanto a la seguridad para los convoys de barcos de suministro o de las rutas óptimas para descubrir submarinos enemigos para los aviones y barcos de escolta de los convoys. En la Ilustración 3 se pueden ver un extracto de documentación del *Operations Research Group* y un convoy de barcos de suministro fotografiado desde un avión de escolta.

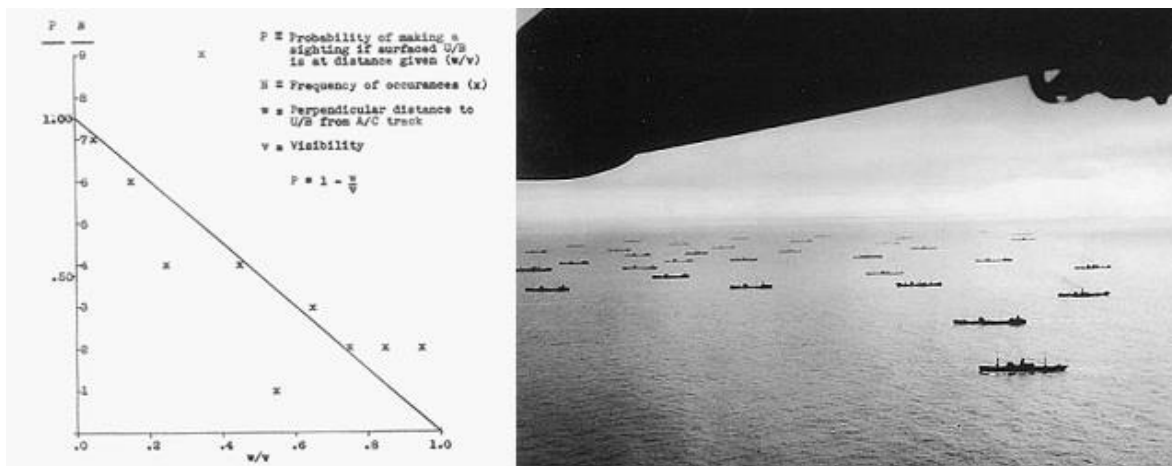


Ilustración 3 – (Izquierda) Fórmula interpolada de probabilidad P de detección de un submarino, en función de la visibilidad V y la distancia al avión W - (Derecha) Fotografía de un convoy realizada desde un hidroavión de escolta

La primera formalización de este tipo de procedimientos se debe a L. D. Stone [27], en el año 1975, que propone y recopila diversos métodos matemáticos de generación de rutas óptimas que trabajan con mapas de probabilidad discretos generados a partir de la teoría Bayesiana. Su trabajo se fundamenta parcialmente en varios casos prácticos de búsqueda de elementos perdidos en el fondo submarino llevados a cabo con éxito mediante este tipo de métodos.

Como indica el mismo autor posteriormente en [28], a partir de esa fecha los esfuerzos de la investigación comienzan en general a alejarse del formalismo matemático y a centrarse en la

generación de algoritmos específicos, debido al aumento en la disponibilidad de sistemas de computación cada vez más potentes y menos costosos, que permiten poner dichos algoritmos en práctica. Se comienzan además a abordar problemas de búsqueda de trayectorias en las que el objetivo es dinámico (no estático) obteniéndose resultados tanto en problemas en los que se considera un objetivo relativamente lento ([8, 30]), como en aquellos otros problemas en los que el objetivo tiene una velocidad cercana a la de los agentes de búsqueda ([11, 26]).

Una aseveración importante es la realizada en 1986 por Trummel y Weisinger en [29], que demuestran formalmente que el problema de la búsqueda del camino óptimo para alcanzar un objetivo estacionario en un espacio y tiempo discretos, sin restricción temporal para finalizar la búsqueda, es un problema del tipo NP-Duro, lo cual significa que no puede resolverse por un algoritmo que se ejecute en tiempo polinomial. Adicionalmente, en 2002, llega a demostrarse en [6] que las versiones descentralizadas de estos algoritmos, en las que los propios agentes que realizan la búsqueda toman las decisiones siguientes a partir de sus propias observaciones, pertenecen a la clase de complejidad NEXP-duro, es decir, no pueden resolverse de forma óptima ni siquiera con algoritmos de orden de complejidad exponencial.

La constatación de estas complejidades para las diferentes versiones del problema de búsqueda de caminos óptimos explica la tendencia posterior que se ha ido desarrollando, y que continúa ofreciendo resultados a día de hoy, de intentar resolverlos mediante técnicas de inteligencia artificial o algoritmos estocásticos y heurísticos, que no aspiran a obtener la mejor solución, pero ofrecen ordenes de complejidad asumibles, a diferencia de los algoritmos más clásicos.

Las familias de algoritmos de este tipo que se están empleando son muy variadas. Cabe destacar como principales ejemplos:

- Redes Neuronales (NN): consisten en sistemas que tratan de resolver el problema empleando estructuras inspiradas en la organización del cerebro humano, compuestas de diversas capas de elementos activables independientemente (*neuronas*) en función a su vez del nivel de activación de las otras neuronas cercanas, a las que están conectadas por otros elementos denominados *conexiones sinápticas*. Se puede aplicar este método al problema MTS ([25]), o a problemas similares de búsqueda de caminos ([24, 31]), aunque la necesidad de disponer de información previa para realizar el entrenamiento de la red puede reducir su usabilidad.
- Algoritmos de Colonias de Hormigas (ACO): se trata de un algoritmo a priori muy apropiado para problemas como el MTS ([14]) o similares ([9, 10, 20]), por estar directamente orientado a la búsqueda de caminos. Imita la forma en la que las hormigas se transmiten la información acerca del mejor camino desde el hormiguero a una zona de interés para ellas (comida, principalmente), dejando un rastro de feromona que es más potente cuanto mejor es el camino de la hormiga que lo deja. Este rastro de feromona influye en el movimiento del resto de hormigas cuyo camino discorra cerca de él, añadiendo su influencia a la que produce un mapa de probabilidad inicial de las zonas de interés, y se evapora con el tiempo, permitiendo así la posibilidad de escapar de mínimos locales.

- Algoritmos Genéticos (GA): uno de los métodos heurísticos más empleado por ser muy genérico, se basa en tratar a un conjunto de soluciones como si de una población de seres vivos se tratase, simulando el paso de las generaciones, de forma que las soluciones mutan (son parcialmente modificadas con una probabilidad relativamente baja), compiten por el derecho a reproducirse (se reproducen las mejores), se reproducen (se combinan entre sí generando nuevas soluciones) y desaparecen por selección natural (las peores se eliminan de la siguiente generación). Se ha aplicado en diversas variantes al problema MTS ([21]) y a problemas similares ([1, 4, 5, 9]).
- Programación Genética (GP): esta técnica consiste en una particularización de los GA, en la cual las soluciones obtenidas consisten en programas de un determinado lenguaje. En su aplicación al problema MTS ([2]) o similares ([3, 23]), un sistema basado en programación genética funciona generando programas controladores de los agentes de búsqueda (no generando caminos directamente, como los GA), para intentar obtener el programa controlador que genere a su vez mejores caminos para los agentes del problema.
- Algoritmos de Optimización Bayesiana (BOA): este tipo de algoritmos consisten en una versión particular de los Algoritmos de Estimación de Distribuciones (EDA, Estimation of Distribution Algorithms), que se basan en obtener la distribución de probabilidad de las mejores soluciones al problema (caminos, en el caso de MTS) mediante un proceso iterativo, partiendo de la distribución uniforme, generando una serie de soluciones mediante la distribución actual y construyendo una nueva distribución en función de las mejores soluciones generadas previamente por medio de un algoritmo de aprendizaje de distribuciones de probabilidad. En el caso particular de los BOA (aplicados a MTS en [18]), el modelo probabilístico que se construye iterativamente es una Red Bayesiana en lugar de una distribución de probabilidad clásica.
- Optimización de Entropía Cruzada (CEO): otro algoritmo, como el anterior, que consiste en una particularización de los EDA, en la que el mecanismo para modificar los parámetros que definen la distribución actual de las soluciones al problema consiste en la minimización de la expresión conocida como la Divergencia de Kullback-Leibler aplicada a la distribución actual y a la nueva distribución. Este método se ha aplicado también a la resolución de MTS en [16] y se diferencia del EDA anterior (BOA) en la dependencia/independencia condicional que se permite/fuerza entre las variables de decisión del problema durante el aprendizaje de la distribución de probabilidad.

Cabe destacar que alguno de los trabajos referidos combina varias de estas técnicas obteniendo mejores resultados que en una aplicación aislada de las mismas, como por ejemplo ACO y GA en [9]. Sin embargo, aunque las técnicas anteriores han sido ya aplicadas a la resolución del problema MTS en [2, 14, 16, 18, 21, 25], en estos trabajos se optimizan trayectorias en las que los UAVs están obligados a volar a altitud y velocidad constantes y que, por lo tanto, no tienen en cuenta todas las posibilidades de vuelo propias de un UAV real. Además, en [2, 14, 25] se considera

que los UAVs siguen trayectorias simplificadas definidas por segmentos adyacentes orientados según las 8 direcciones cardinales, hecho que las hace todavía más restrictivas que las que se plantean en [21], donde se permiten cambios de dirección del UAV sin restricciones y se aplica un modelo cinemático del mismo para calcular la trayectoria real. El presente Trabajo de Fin de Máster sigue la línea de [21] y tiene como objetivo afrontar una versión más realista del problema MTS, optimizando el tiempo de búsqueda de una flota de UAVs en la que sus trayectorias puedan sufrir cambios de altitud, velocidad y dirección, tal y como se permite en otros problemas de planificación diferentes al MTS, pero orientados también a la generación de trayectorias de UAVs como [1].

Finalmente, es importante mencionar que existen también otros trabajos como [13, 33], orientados no ya al desarrollo de soluciones al problema MTS o similares, sino a comparar diferentes soluciones ya existentes, habitualmente empleando métodos estadísticos de análisis sobre conjuntos de soluciones obtenidas en múltiples ejecuciones de cada algoritmo, ya que por su naturaleza estocástica una solución aislada no es representativa. En otros como [7] la temática es precisamente un estudio de qué métodos estadísticos pueden ser los más apropiados para este tipo de comparaciones. El contenido de estos trabajos resulta de interés para este Trabajo de Fin de Máster, ya que algunos de los tipos de análisis estadísticos que proponen son tenidos en cuenta en el estudio de los resultados obtenidos mediante los algoritmos aquí propuestos.

1.2 Objetivos

El presente trabajo se articula en torno al problema MTS y a la búsqueda de soluciones para el mismo, en la línea del Estado del Arte expuesto en el apartado 1.1 para los problemas de búsqueda de caminos en general y para el MTS en particular, es decir, empleando técnicas heurísticas que permitan obtener algoritmos aplicables en la práctica por ser computacionalmente viables. La intención es continuar la línea seguida por el Departamento de Arquitectura de Computadores y Automática de la Universidad Complutense de Madrid en trabajos como [2, 14, 15, 16, 18, 21, 25, 33], centrados en diferentes versiones del problema MTS.

Concretamente, se desea extender el diseño e implementación del Algoritmo Genético Multi-etapa (MSGGA, Multi-Stepped Genetic Algorithm) expuesto en [21], que aborda una versión avanzada del problema MTS. Los objetivos que se proponen en este sentido son:

1. Comprensión de la definición formal del problema MTS descrito en [21], incluyendo elementos que intervienen, funciones a optimizar, restricciones, etc.
2. Análisis y familiarización con el GA Multi-etapa para trayectorias de dirección variable propuesto en [21] y con su implementación en el entorno Matlab.
3. Desarrollo de un GA Multi-etapa para trayectorias de dirección, velocidad y altura variables e implementación en el entorno Matlab. Este objetivo se considera de importancia porque se centra en obtener un algoritmo que explore todas las posibilidades de control que ofrecen los UAVs reales.
4. Diseño de varias propuestas alternativas de codificación de soluciones del GA Multi-etapa para trayectorias de dirección, velocidad y altura variables, obteniendo de esta forma varios

GA Multi-etapa, e implementación en el entorno Matlab. La importancia de este objetivo es doble: en el sentido práctico, porque puede permitir obtener un mejor algoritmo para la resolución de MTS, y en el aspecto didáctico, ya que se pretende resaltar la influencia en el rendimiento del GA Multi-etapa de las diferentes codificaciones de la solución diseñadas.

5. Diseño de escenarios de prueba y análisis de resultados del GA Multi-etapa para trayectorias de dirección variable de [21] y de las diferentes versiones del GA Multi-etapa para trayectorias de dirección, velocidad y altura variables.

1.3 Organización de la memoria

El presente documento se divide en varios capítulos estructurados acorde a los objetivos perseguidos en el trabajo.

El primer capítulo sirve como introducción general a los problemas de búsqueda de caminos o trayectorias y en particular al problema MTS, y para realizar el planteamiento de los objetivos que se desean alcanzar en el presente trabajo.

El segundo capítulo aborda la descripción y la definición formal de la versión del problema MTS descrita en [21], incluyendo una descripción del modelado de los diferentes elementos que conforman el problema (probabilidad de localización del objetivo, probabilidad de detección mediante el sensor de los UAVs, movimiento de los UAVs) y de las funciones de optimización y restricciones asociadas al problema (tiempo estimado de localización, miopía, zonas de vuelo prohibido, ...).

En el capítulo tercero se introduce la teoría de GA en general (concepto general, operadores, variaciones, ...), para describir posteriormente las especificidades del algoritmo GA Multi-etapa presentado en [21] como solución al problema MTS, haciendo especial mención de las características que lo diferencian de un GA tradicional.

El capítulo cuarto presenta el desarrollo de un nuevo GA Multi-etapa para solucionar el problema MTS mediante trayectorias de dirección, velocidad y altura variables, describiéndose además las diferentes codificaciones de soluciones que se proponen y lo que se espera obtener de cada una de ellas.

Los escenarios de prueba diseñados para analizar el funcionamiento de las diferentes versiones del GA Multi-etapa generadas se reseñan en el capítulo quinto, junto con los resultados obtenidos al comparar la ejecución de cada algoritmo un cierto número de veces para cada escenario.

Por último, el capítulo sexto contiene las conclusiones obtenidas a lo largo del trabajo, una recapitulación acerca de la consecución de los objetivos marcados inicialmente, descritos en el apartado anterior, y una propuesta de líneas de trabajo futuras que se podrían seguir.

2 Búsqueda en Tiempo Mínimo (MTS)

Se presenta a continuación la descripción formal de la versión del problema MTS a resolver en el presente trabajo, que extiende el propuesto en [21] a través de la inclusión de cambios de altitud y velocidad en las trayectorias de los UAVs, incluyendo la definición de los elementos que intervienen, los modelos probabilísticos que los caracterizan, el formato de las soluciones y los criterios de evaluación de las mismas.

2.1 Descripción general

Como ya se ha introducido en el capítulo 1, el problema MTS consiste en la planificación de las rutas de búsqueda de un conjunto de UAVs para la localización de un cierto objetivo en el menor tiempo posible. Por ello, como primeros elementos a modelizar, se encontrarían claramente las trayectorias de los UAVs y la situación del objetivo. Por otra parte, para intentar acercar la definición del problema lo máximo posible a una situación real, se modela también la influencia del tipo de sensor empleado en los UAVs en la probabilidad de localizar al objetivo, es decir, no se considera una detección automática ideal del objetivo cuando un UAV se acerca a un determinado umbral.

Además de la modelización del comportamiento de estos elementos, se introducen varios criterios de evaluación de la calidad y de la factibilidad de las soluciones del problema y una prioridad de dichos criterios. Esto es necesario porque, aunque el principal objetivo que se busca en el problema MTS es, como el propio nombre del problema indica, la búsqueda en tiempo mínimo del objetivo, esto no impide que puedan evaluarse de otras formas las soluciones en base a otros criterios de menor importancia como, por ejemplo, el gasto de combustible de los UAVs. Dichos criterios secundarios permiten, en el caso de que existan diferentes soluciones con el mismo tiempo de búsqueda, elegir una u otra en base a ellos mientras que, por otra parte, acercan el problema al mundo real en el que otros criterios adicionales deben ser tenidos en cuenta.

El objetivo a localizar por los UAVs está situado en una posición τ desconocida y fija (es decir, es estático). Dicho objetivo se encuentra situado en una zona confinada de búsqueda, sobre la que se define una rejilla G de w_x por w_y celdas, de forma que $\tau \in G$.

Se establece además M como el número de UAVs disponibles para realizar la búsqueda. Los sensores con los que están equipados estos UAVs realizan observaciones del terreno en busca del objetivo a intervalos regulares, de forma que el número de observaciones realizadas a lo largo de la trayectoria de los UAVs es igual a N . Además, el estado de cada uno de los M UAVs en cada uno de los N momentos en los que realizan una observación se define como s_i^k , de forma que $i \in \{1: M\}$ y $k \in \{1: N\}$.

2.2 Modelo probabilístico del objetivo

Aunque la posición exacta del objetivo no sea conocida, en un escenario real habitualmente se dispone de algún tipo de información inicial que indique las zonas en las que la probabilidad de encontrarlo es más alta. Por ejemplo, en un escenario de rescate de una persona extraviada, las zonas de mayor probabilidad corresponden a los últimos puntos de avistamiento por parte de algún

testigo, o las zonas potencialmente peligrosas en el área de búsqueda, donde la persona habría podido accidentarse.

Con toda esta información se compone un mapa de probabilidad indicando para cada punto del mismo la probabilidad de encontrar en él al objetivo. Formalmente, sobre la variable $\tau \in G$ que indica la celda de posible localización del objetivo, se define la función de probabilidad o función de creencia inicial de presencia del objetivo como $b_0(\tau) = P(\tau)$.

La Ilustración 4 muestra un ejemplo de un mapa de creencia inicial, en el que se representan con una altura mayor y colores cálidos los puntos en los que hay más probabilidad de encontrar al objetivo, y en colores fríos aquellos donde la probabilidad es menor.




Ilustración 4 - Mapa de creencia inicial de un escenario del problema MTS

2.3 Modelo probabilístico del sensor de los UAVs

Los sensores con los que están equipados los UAVs del problema no son ideales ni deterministas, sino que en una posición dada tienen una probabilidad de localizar el objetivo dependiente de varios factores. El modelado de estos sensores es un problema complejo en sí mismo estudiado en [15], trabajo en el que se aborda el problema MTS para vehículos no tripulados equipados con diferentes tipos de sensores y se presentan los modelos probabilísticos de detección asociados a los mismos.

En particular, el modelo probabilístico de detección del radar recogido en [15] se define mediante la Expresión (1), que indica la probabilidad de detección del objetivo en la casilla τ , por parte del UAV i en el momento k , y hallándose en ese momento dicho UAV en el estado s_i^k (una de

las variables que se incluyen en el estado s_i^k del UAV, y que es relevante en la Expresión (1), es su posición):

$$P(D_i^k | \tau, s_i^k) = \left(1 + \frac{2 \cdot S_{NR} \cdot T_{NR}}{(2 + S_{NR})^2}\right) \cdot e^{\frac{-2 \cdot T_{NR}}{2 + S_{NR}}} \quad (1)$$

Esta expresión depende de los valores S_{NR} (Signal to Noise Ratio), que se define mediante la Expresión (2), y T_{NR} (Threshold to Noise Ratio), definido en la Expresión (3):

$$S_{NR} = \frac{C_e}{(d_{\tau,i}^k)^4} \quad (2)$$

$$T_{NR} = -\log(P_{fa}) \quad (3)$$

En la Expresión (2) que define S_{NR} , el valor $d_{\tau,i}^k$ indica la distancia del UAV i a la casilla τ en el instante k (la cual puede obtenerse a partir de la posición del UAV, en s_i^k , y de las coordenadas de la casilla τ), mientras que C_e es característico del sensor (radar) empleado.

En la Expresión (3) que define T_{NR} , el parámetro P_{fa} indica la probabilidad de que el radar devuelva una falsa detección. Como se indica en [15], se puede ajustar el umbral de respuesta del sensor (radar) para que este parámetro P_{fa} tenga un valor lo suficientemente pequeño, pero esto a su vez afectará al resultado de la Expresión (1) haciendo menos probable la detección.

La Ilustración 5 muestra un ejemplo concreto expuesto en [15] de configuración del umbral de detección del radar para que la probabilidad de falsa detección P_{fa} sea muy baja (10^{-6}), lo que a su vez produce que, a una distancia de 250 metros entre el UAV y la casilla τ , la probabilidad de detección sea de 0,75.




Ilustración 5 - Ejemplo de curva de probabilidad de detección del sensor de un UAV en función de la distancia al posible objetivo

Nótese la influencia en el problema de la altura a la que vuelan los UAVs, ya que en una configuración como la mostrada en la Ilustración 5, si los UAVs volasen a más de 400 metros del suelo las probabilidades de detección decrecerían drásticamente incluso volando justo encima de la posible localización del objetivo mientras que, si los UAVs volasen a 100 metros del suelo, la localización del objetivo si el UAV pasara por encima sería prácticamente segura.

2.4 Modelo cinemático de los UAVs

La resolución del problema MTS adaptado a un caso realista exige la definición de un modelo cinemático de los UAVs empleados ya que, del espacio de posibles trayectorias a realizar dentro del área de búsqueda, tan solo un cierto subconjunto puede ser seguido por un UAV real. Ciertas maniobras son imposibles, ya que los UAVs reales no pueden girar, acelerar/decelerar ni cambiar de altura por encima de unos límites marcados por su diseño y parámetros aerodinámicos.

El conjunto de trayectorias irrealizables es tan superior al conjunto de trayectorias realizables, que, en lugar de generar posibles trayectorias de los UAVs y después comprobar si son factibles, resulta más práctico computacionalmente hablando generar directamente trayectorias factibles. Esto se traduce en que, realmente, es más sencillo generar modificaciones de las variables de control que permiten gobernar el vuelo del UAV y, mediante un modelo cinemático realista del comportamiento del mismo, obtener la trayectoria que dichas modificaciones de las variables de control van produciendo.

La Ilustración 6 muestra el modelado del comportamiento genérico de un UAV realista propuesto en [21], de forma que variando algunas parametrizaciones se pueden obtener los comportamientos precisos de varios modelos diferentes de UAVs reales. Las variables de control que permiten alterar la trayectoria del UAV son la dirección θ (heading_C, en la Ilustración 6), la velocidad respecto al aire v (airVelocity_C) y la altura h (height_C). Pueden verse en color azul turquesa en la parte inferior izquierda de la Ilustración 6, como entradas al modelo cinemático.

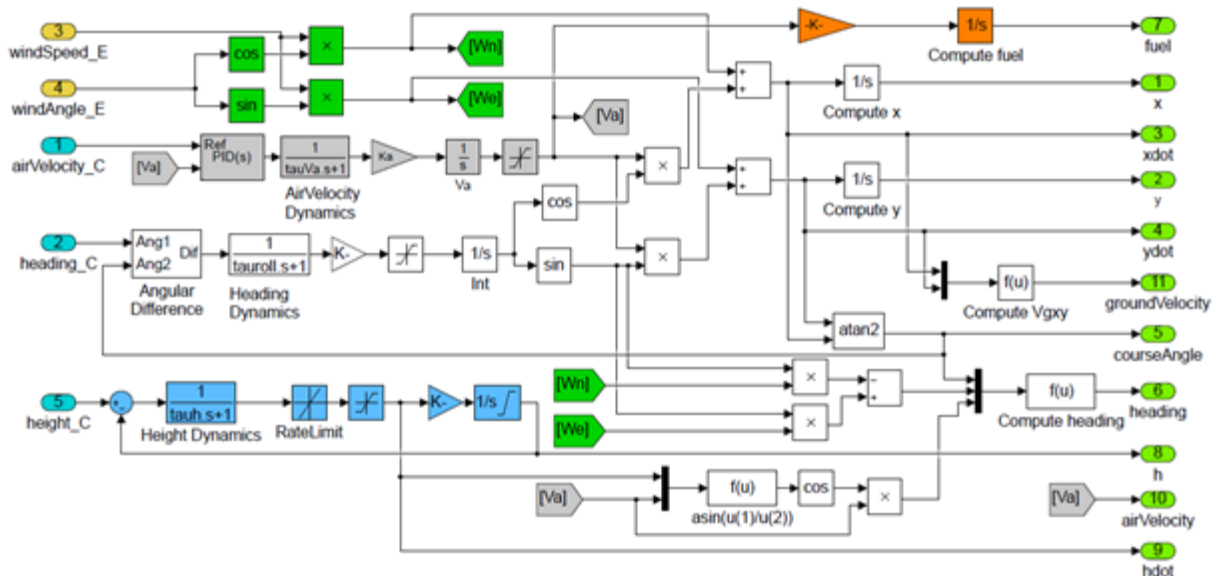


Ilustración 6 - Modelo cinemático de un UAV real

De esta forma, para la resolución del problema MTS, en lugar de generar trayectorias, se generan secuencias de variaciones de las tres variables de control indicadas para cada uno de los M UAVs a lo largo de T momentos espaciados un determinado intervalo de tiempo y, a partir de dichas secuencias y del modelo cinemático, se obtienen las trayectorias reales de los UAVs. Nótese que T no tiene por qué coincidir con N , es decir, los instantes de variación de las señales de control no tienen por qué coincidir con los instantes en los que se realizan las mediciones del sensor de los UAVs. Formalmente, a partir de una secuencia de variaciones de las variables de control de la forma $u_i^j = (\theta_i^j, v_i^j, h_i^j)$, de forma que $i \in \{1:M\}$ y $j \in \{1:T\}$, la Expresión (4) representa como se obtiene el estado de los UAVs a partir del estado en el intervalo anterior, de las correcciones de las variables de control y de la función f que representa el modelo cinemático de la Ilustración 6. Se introduce además un parámetro ϵ que representa el efecto de las condiciones ambientales del viento (velocidad y dirección del viento, en amarillo oscuro en la Ilustración 6) sobre el comportamiento del UAV.

$$s_i^j = f(s_i^{j-1}, u_i^{j-1}, \epsilon) \quad (4)$$

En la Ilustración 6 se pueden ver como salidas del modelo cinemático (en la parte derecha, en color verde claro) las variables que forman parte del estado s_i^j de los UAVs. Tal y como se hacía referencia en el apartado 2.3, la posición del UAV en coordenadas (x, y, h) es parte de este estado. El conocimiento de esta posición es necesario para aplicar el modelo probabilístico del sensor con el que están equipados los UAVs descrito en 2.3 y, por lo tanto, para evaluar la probabilidad de encontrar el objetivo que genera una determinada trayectoria y el tiempo esperado de búsqueda.

Nótese que, si bien en el apartado 2.1 se había definido el estado de cada uno de los M UAVs en cada uno de los N momentos en los que realizan una observación como s_i^k , de forma que $i \in \{1:M\}$ y $k \in \{1:N\}$, hay que extender ahora esa definición, y establecer que se conoce (se puede calcular) también el estado de cada uno de los M UAVs en cada uno de los T momentos en los que realiza una variación sobre las variables de control que gobiernan su trayectoria, y que dicho estado se denota como s_i^j , de forma que $i \in \{1:M\}$ y $j \in \{0:T\}$. En la práctica, esto significa que el modelo cinemático permite obtener el estado de cada UAV tanto en los instantes en los que se varían las variables de control del UAV como en aquellos en los que se realiza lectura mediante el sensor. El hecho de que se conozca el estado cuando $j = 0$ quiere decir que se conoce un estado inicial (posición, velocidad, dirección, ...) de cada UAV.

Aunque trascienda el ámbito del problema MTS, es interesante destacar la complejidad del modelo cinemático de la Ilustración 6, en cuyo interior se han diferenciado por colores los bloques empleados según su finalidad:

- Modelado de la dinámica vertical (azules claros)
- Modelado del efecto del viento (verdes oscuros)
- Modelado del gasto de combustible (naranjas)
- Modelado de la velocidad respecto al aire (grises)

- Modelado de la dinámica lateral (blancos)

2.5 Criterios de evaluación de soluciones

Los diferentes elementos intervinientes en el problema MTS cuya modelización se describe en los apartados 2.1 a 2.4 permiten definir soluciones al mismo, codificadas como secuencias de valores de las variables de control de los UAVs, y calcular la probabilidad que tiene el conjunto de UAVs de encontrar al objetivo siguiendo las rutas que estos describen empleando dichas señales de control, así como el tiempo esperado para hacerlo.

Para completar la definición formal del problema, se hace necesario definir los criterios de factibilidad y calidad de las soluciones, así como la prioridad de los mismos. En el caso concreto del problema MTS se debe priorizar la rapidez con la que se maximiza la probabilidad de encontrar al objetivo sobre cualquier otra consideración, a excepción únicamente de la integridad de los UAVs que realizan la búsqueda.

En este apartado se exponen una serie de criterios de optimización para valorar las soluciones del problema MTS. Primeramente, se definen dos tipos de restricciones, una para evitar colisiones entre UAVs y otra para evitar zonas de vuelo prohibidas, que establecen la factibilidad de las soluciones. Por otra parte, se definen cuatro criterios de optimización: un criterio que mide el tiempo esperado de búsqueda, un criterio heurístico que informa sobre la idoneidad de los tramos futuros de las trayectorias de búsqueda más allá del horizonte temporal tratado, un criterio para suavizar los giros de las trayectorias y, por último, un criterio de consideración del combustible empleado. Todos los criterios expuestos, tanto los de factibilidad como los de optimización, consisten en funciones a minimizar.

Nótese que los elementos del problema de búsqueda definidos en los apartados 2.1 a 2.4, en combinación con un conjunto de funciones de valoración de factibilidad y optimización diferentes a los expuestos en los apartados 2.5.1 al 2.5.5, podrían utilizarse para resolver problemas de búsqueda diferentes. Por ejemplo, para optimizar el gasto de combustible de los UAVs sin importar la rapidez con la que se encontrase al objetivo, sino valorando solo la probabilidad de encuentro al final del recorrido, o para optimizar la vida útil de los UAVs restringiendo de alguna forma las secuencias de señales de control de las soluciones para evitar maniobras agresivas con la mecánica del UAV.

2.5.1 Factibilidad de soluciones (NFZs, detección de colisiones)

Una de las grandes ventajas del empleo de UAVs en misiones de búsqueda es, como ya se indicó en el capítulo 1, la gran libertad de acción que tienen este tipo de robots en comparación con los robots terrestres, los cuales se enfrentan a muchos tipos de obstáculos, terrenos y situaciones complejas en general que limitan su movimiento de alguna forma.

En el caso de los robots aéreos del problema MTS, las únicas consideraciones que se realizan son, por una parte, la de que los diferentes UAVs no colisionen entre sí y, por otra, que su trayectoria se mantenga fuera de ciertas áreas del espacio de búsqueda especificadas de antemano. El motivo por el que se desea que los UAVs se mantengan fuera de estas áreas puede ser variado y

depende lógicamente de la aplicación práctica del problema. Por ejemplo, en una misión de búsqueda de personas accidentadas en una zona montañosa, podría resultar interesante evitar las zonas con montañas más altas donde no se espera que se encuentre el objetivo y los UAVs pudiesen colisionar contra el terreno, o en una misión de reconocimiento militar podría ser interesante evitar zonas que se saben ocupadas por sistemas de defensa que podrían derribar los UAVs. En general, en el problema MTS, se denominan estas áreas como zonas de vuelo prohibido (NFZs). Se puede observar en la Ilustración 7 un ejemplo de mapa de probabilidad del problema MTS en el que se han definido además tres NFZs.




Ilustración 7 - Ejemplo de mapa de probabilidad con varias NFZs marcadas en negro

Se define la Expresión (5) para el cálculo del número de colisiones entre UAVs que sucederían en una determinada solución. La función *Collision* es una función sencilla que devuelve 1 si la distancia entre las dos ternas de coordenadas pasadas como parámetros es menor a una distancia límite de seguridad, y 0 en otro caso. Los valores de las coordenadas de los puntos por los que pasa la trayectoria de los UAVs forman parte del estado s_i^j de los mismos.

$$\#COL = \sum_{j=1}^T \sum_{i=1}^M \sum_{l=i+1}^M Collision(x_i^j, y_i^j, h_i^j, x_l^j, y_l^j, h_l^j) \quad (5)$$

Se considera, por tanto, que una solución es factible si $\#COL$ es 0 para ella. No resulta admisible una solución con mejor tiempo mínimo de búsqueda, pero en la que se ponen en peligro los propios UAVs que realizan la búsqueda.

Por otra parte, la Expresión (6) se define para chequear que los UAVs no cruzan las NFZs definidas para el problema. La función *WithinNFZ* se limita a comprobar si las coordenadas del punto pasado como parámetro se encuentran dentro de alguna de las NFZs definidas para el

problema, devolviendo 1 en ese caso y 0 en caso contrario, es decir, devuelve el número de veces que algún UAV invade una NFZ.

$$\#NFZ = \sum_{j=1}^T \sum_{i=1}^M \text{WithinNFZ}(x_i^j, y_i^j) \quad (6)$$

Nótese que las NFZs se consideran de altura infinita, por lo que no es necesario el parámetro h_i^j de la altura a la que vuela el UAV.

En los algoritmos heurísticos para resolver el problema MTS pueden emplearse estos dos criterios de diferente forma: un método consiste en descartar aquellas soluciones que no cumplen $\#COL = 0$ y $\#NFZ = 0$, mientras que otra opción consiste en considerar estas funciones como los criterios a optimizar con mayor prioridad, entendiendo que deben minimizarse. La segunda opción suele ser más sencilla de implementar, ya que trata las restricciones exactamente de la misma forma que el resto de criterios de optimización. Si se procede de esta forma, debe asumirse que el algoritmo heurístico va a generar al menos una solución factible, o bien comprobarse al final de la ejecución que la solución escogida es factible. En un espacio de soluciones como el que se define en esta modelización del problema MTS (generando las trayectorias a partir de las señales de control de los UAVs, no como trayectorias directamente), el hecho de que la mayoría de las soluciones sean factibles o no dependerá principalmente de la proporción de NFZs sobre el total del espacio de búsqueda y del número de UAVs definido como parámetro del problema.

2.5.2 Optimización del tiempo esperado de localización (ET)

El problema MTS tiene como principal misión la minimización del tiempo de búsqueda del objetivo, por lo que el criterio de optimización más importante a definir es precisamente una función o expresión que permita estimar dicho tiempo de alguna forma.

Al desconocerse la localización precisa del objetivo, no es posible calcular de manera exacta el tiempo de búsqueda. En realidad, como la definición del problema MTS que se hace en este capítulo está orientada a la resolución mediante algoritmos heurísticos, habitualmente basados en la comparación entre diferentes soluciones, es suficiente con obtener una función que permita comparar el tiempo de búsqueda entre dos soluciones diferentes y ver cuál es mejor, aunque dicho tiempo de búsqueda no sea exacto sino aproximado.

El enfoque propuesto en [18] consiste en realizar una estimación del tiempo de búsqueda basada no en la duración de las posibles trayectorias, sino en la probabilidad de no encontrar al objetivo durante las mismas. La forma en la que se generan las posibles soluciones o trayectorias en esta versión de MTS, descrita en 2.4, implica que en realidad todas las soluciones tienen la misma longitud temporal. Es decir, se está planteando el MTS no como un problema en el que se busca la trayectoria más corta que garantice encontrar al objetivo, sino más bien como la búsqueda de una trayectoria que, en un tiempo determinado (el mismo tiempo que tarda en recorrerse cualquiera de las posibles soluciones al problema consideradas), minimice la probabilidad de no encontrar al objetivo y, por tanto, minimice el tiempo de búsqueda.

Para ello se emplea la Expresión (7) propuesta en [18] y empleada en [21], que devuelve el ET o tiempo estimado de detección del objetivo. En realidad, se trata de una expresión que

devuelve un valor no normalizado y acumulado de probabilidad de no detección del objetivo en el instante N , lo que equivale a una estimación del instante k en el que se espera encontrar al objetivo, que se podría traducir a tiempo multiplicando el valor de ET por el número de segundos que transcurren entre dos instantes k consecutivos. Este valor así calculado de ET es realmente una cota inferior del instante esperado de detección ya que no se tiene en cuenta la probabilidad de no detección en instantes posteriores a N . El valor esperado total del tiempo de búsqueda se obtendría extendiendo el sumatorio de N a infinito o al menos hasta un N en el que el sumatorio de \tilde{b} en τ llegase a 0. En el planteamiento del problema realizado, como solo se analizan trayectorias de N instantes de duración, se optimiza la Expresión (7).

$$ET = 1 + \sum_{k=1}^N \sum_{\tau \in G} \tilde{b}(\tau, s_{1:M}^{1:k}) \quad (7)$$

La función \tilde{b} de no detección del objetivo en la casilla τ , teniendo en cuenta los $s_{1:M}^{1:k}$ estados de los M UAVs en los k primeros instantes, se define basándose en teoría probabilística de la siguiente forma (8), empleando la propiedad que dice que la probabilidad de no ocurrencia de la unión de sucesos (en este caso, la no ocurrencia de la unión de sucesos de detección del objetivo por parte de alguno de los UAVs en un instante igual o inferior a k) consiste en la intersección (multiplicación) de las probabilidades de no ocurrencia de cada uno de los sucesos individuales.

$$\tilde{b}(\tau, s_{1:M}^{1:k}) = \prod_{l=1}^k \prod_{i=1}^M (1 - P(D_l^i | \tau, s_l^i)) \cdot b^0(\tau) \quad (8)$$

La probabilidad de cada suceso individual de no detección por parte del UAV i en el instante l , condicionada a la probabilidad de que el objetivo se halle en la casilla τ , se calcula como 1 menos la probabilidad de detección. Dicha probabilidad de detección puede obtenerse mediante el modelo probabilístico de los sensores con los que están equipados los UAVs, descrito en el apartado 2.3.

La función \tilde{b} (en la que \sim indica que se trata de una probabilidad “no normalizada”) se puede denominar como la función de creencia restante. Su sumatorio en G decrece con el tiempo, a medida que los UAVs van recopilando información y hacen que la probabilidad (creencia) restante de no detección sea cada vez menor. Nótese que, de emplearse únicamente la Expresión (8) para evaluar la calidad de una solución, se estaría evaluando únicamente la probabilidad de no detección al final del periodo temporal de búsqueda establecido para los UAVs, independientemente del momento en el cual hubiese mayor probabilidad de detección. La Expresión (7) es la que, al acumular la función de creencia restante respecto al tiempo, premia a aquellas soluciones en las que la creencia restante decaiga más rápidamente, lo cual es el auténtico problema a resolver en MTS.

2.5.3 Optimización del criterio heurístico de miopía (MYOP)

Al modificarse el enfoque del problema MTS de la manera indicada en 2.5.2, de forma que no se busca una solución en la que se garantice encontrar al objetivo, sino que se busca la solución de una determinada longitud temporal que menor ET (menor creencia acumulada restante, o cota inferior del tiempo estimado de detección) tenga, resulta interesante introducir algún criterio de optimización secundario que valore la dificultad o facilidad de acceder al resto de puntos del área de búsqueda G a los que no se haya podido hacerlo durante el periodo de tiempo concedido a los

UAVs como parámetro del problema. Este criterio, al que se le podría conceder una prioridad menor que al ET, permitiría elegir, de entre aquellas soluciones que tuvieran un mismo ET, aquella en la que los UAVs estuvieran al final de sus trayectorias en el tiempo T en mejor situación para continuar la búsqueda si se extendiese el periodo de tiempo permitido. En la versión MTS aquí definida, se define este criterio como MYOP (miopía) en alusión a que se valora un horizonte de búsqueda futuro, más allá de lo que la solución puede “ver”.

Como se verá en el apartado 3.2, disponer de este criterio adicional MYOP permitirá además afrontar el problema MTS descomponiéndolo en varios subproblemas más pequeños (las soluciones consistirán en trayectorias más pequeñas) resolubles mediante la evaluación combinada de los criterios ET y MYOP para cada uno de ellos, obteniéndose la solución global al problema MTS por concatenación de las soluciones parciales (concatenación de trayectorias) a cada uno de los subproblemas. Al estudiarse en los subproblemas trayectorias más pequeñas, gana importancia (y prioridad) la evaluación del criterio MYOP que permite estimar la complejidad del resto de la búsqueda que la trayectoria solución del problema no llega a abarcar.

El criterio MYOP se define en la Expresión (9) y, como se puede ver, consiste en una suma en el espacio G de la probabilidad remanente no normalizada de no detección por parte de ningún UAV, ponderada por una función heurística H cuya definición se muestra en la Expresión (10), que se apoya en la Expresión (11).

$$MYOP = \sum_{\tau \in G} \prod_{i=1}^M H(\tau, s_i^N) \cdot \tilde{b}(\tau, s_{1:M}^N) \quad (9)$$

$$H(\tau, s_i^N) = 1 - \beta^{F(\tau, s_i^N)} \quad 0 < \beta < 1 \quad (10)$$

$$F(\tau, s_i^N) = d_{\tau, i}^N + \alpha \left| \theta_i^N - \arctan \left(\frac{\tau_y - y_i^N}{\tau_x - x_i^N} \right) \right| + Corr_{NFZ} \quad (11)$$

La función heurística H , que se define en (10) empleando a su vez F , definida en (11), tiende a 1 cuando F tiende a infinito, y tiende a 0 cuando F tiende a 0.

F crece, y por lo tanto H crece, cuando:

- La distancia $d_{\tau, i}^N$ entre el punto final de la trayectoria del UAV i y el punto τ crece, como puede verse en las Ilustraciones 8 y 9 en las que se representan con colores más cálidos tendiendo a rojo los puntos τ más lejanos al punto final de la trayectoria del UAV i .
- La dirección final de la trayectoria del UAV θ_i^N no está alineada hacia el punto τ en cuestión (el sumando $\alpha \left| \theta_i^N - \arctan \left(\frac{\tau_y - y_i^N}{\tau_x - x_i^N} \right) \right|$ penaliza este hecho, como puede verse en la Ilustración 8 en la que se muestra la diferencia de dicho sumando entre el punto τ señalado con flecha verde, hacia el cual está alineada la dirección final de la trayectoria del UAV, y el punto τ señalado con flecha morada, hacia el cual no lo está).




Ilustración 8 - Efecto en MYOP de la no alineación hacia τ de la dirección final de la trayectoria del UAV

- La trayectoria más corta entre el punto final de la trayectoria del UAV y el punto τ cruza alguna NFZ, como se puede ver en la Ilustración 9 ($Corr_{NFZ}$ es una función que penaliza este hecho).

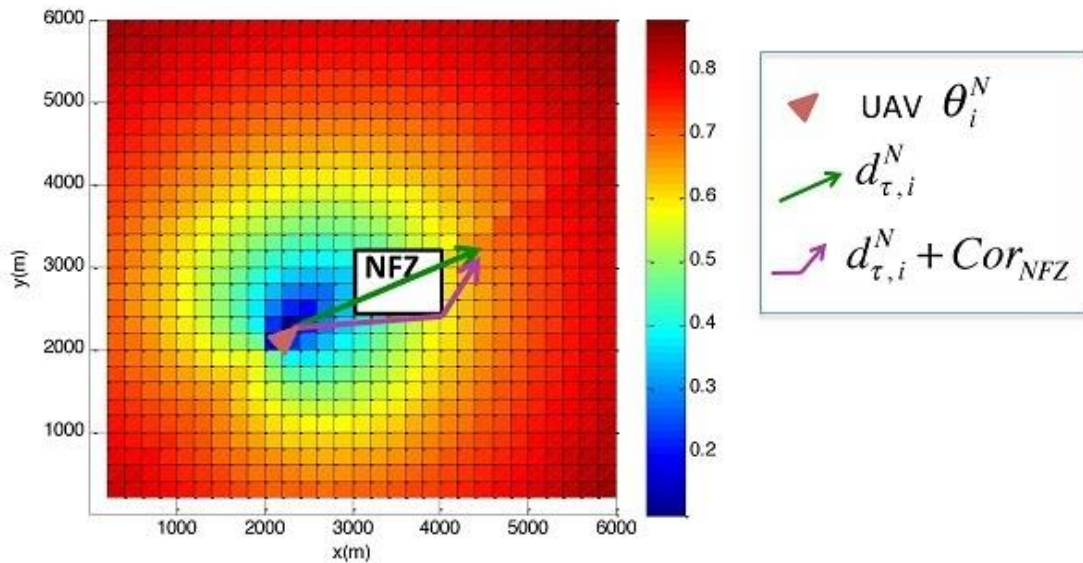


Ilustración 9 - Efecto en MYOP de la necesidad de rodear NFZs

Cada uno de los tres sumandos de la Expresión (11) es una función que, al crecer, indica que por un motivo u otro (distancia, dirección, NFZs) para el UAV será más complicado alcanzar el punto τ en el futuro. Al emplear esta función H en (9) para ponderar el sumatorio de creencia restante en G , la minimización de MYOP penaliza aquellos puntos τ con mucha creencia restante y que sean complicados de alcanzar por los UAVs desde los puntos finales de las trayectorias de la solución (es decir, desde su estado en el instante N). Se puede decir que el criterio MYOP es una estimación heurística indirecta relacionada con el ET futuro.

2.5.4 Optimización del criterio heurístico de suavidad (SMOOTH)

Se define de forma adicional un criterio que, si bien no es específico del problema MTS, permite encontrar soluciones más simples al mismo, a igualdad de ET entre ellas. Por ello, los algoritmos heurísticos diseñados para la resolución de MTS deben emplear este criterio con una prioridad menor que la de los criterios ET y MYOP.

La finalidad de este criterio es la de evitar trayectorias en las que las variaciones consecutivas de la dirección θ de los UAVs sean muy altas y tomen signos opuestos. Intuitivamente, puede entenderse esto como una penalización a las variaciones oscilantes bruscas de la dirección θ . Se entiende que, si una trayectoria con oscilaciones bruscas de la dirección pertenece a una buena solución, en cualquier caso, existirá una trayectoria similar con un menor nivel de oscilación perteneciente a otra solución igualmente buena o seguramente mejor.

Por tratarse de un método de premiar las trayectorias más suaves, y penalizar las más erráticas, se denomina al criterio SMOOTH. La definición exacta de este criterio puede verse en la Expresión (12), cuya definición se apoya en la Expresión (13).

$$SMOOTH = \sum_{j=1}^T \sum_{i=1}^M \text{change}(\Delta\theta_i^j, \Delta\theta_i^{j-1}) \quad (12)$$

$$\text{change}(a, b) = (a - b)^2 \cdot (|\text{sign}(a) - \text{sign}(b)| = 2) \quad (13)$$

Como puede verse en la Expresión (13), en la que la función sign es una función que devuelve 1 si el parámetro tiene valor positivo y -1 si el parámetro tiene valor negativo, los cambios de signo de variaciones consecutivas de la dirección θ se penalizan en proporción al cuadrado de la diferencia de variaciones.

2.5.5 Optimización del criterio de ahorro de combustible (FUEL)

Otro criterio de carácter secundario dentro del problema MTS, pero que puede tenerse en cuenta también con una prioridad baja en un algoritmo heurístico que lo resuelva, es el del ahorro del combustible de los UAVs que realizan la búsqueda.

Como en MTS la principal consideración es la de que el tiempo estimado de búsqueda sea lo más bajo posible, habitualmente este criterio (que se denomina mediante el nombre FUEL en esta definición de MTS) entrará en conflicto con los criterios ET y MYOP, y por ello cualquier algoritmo heurístico que haga uso de él debe priorizarlo siempre por debajo de ET y MYOP.

El cálculo del combustible empleado a lo largo de la búsqueda por el conjunto de UAVs lo realiza el propio modelo cinemático de vuelo de los UAVs ya descrito en el apartado 2.4, de forma que el combustible consumido es una variable más del estado s_i^j de los UAVs (variables en verde claro en la parte derecha de la Ilustración 6).

3 GA Multi-etapa para trayectorias de dirección variable

La versión del problema MTS descrita en el capítulo 2 consiste en una definición precisa de los elementos del problema (modelo probabilístico del objetivo, modelo probabilístico del sensor de los UAVs, modelo cinemático de los UAVs, ...), de la forma que tiene una solución del problema (secuencia de variaciones de las variables de control), y de las funciones necesarias para valorar la factibilidad y calidad de una solución (funciones COL, NFZ, ET, MYOP, ...).

Todas estas herramientas probabilísticas y matemáticas pueden emplearse para generar algoritmos que den solución al problema MTS. Son especialmente adecuadas para adaptar al problema MTS algoritmos heurísticos de carácter genérico como ACO [14], CEO [16], BOA [18], o, en general, cualquier algoritmo heurístico, bioinspirado o no, basado en generación de diversas soluciones y en la comparación de la calidad de dichas soluciones.

La generación de soluciones consiste, en esta versión de MTS, en la generación de cadenas de variaciones de las variables de control (dirección, velocidad, altura) empleadas para gobernar los UAVs, de una longitud dependiente de la parametrización del problema. Estas secuencias de órdenes pueden ser transformadas en secuencias de estados de los UAVs mediante el modelo cinemático descrito en 2.4, secuencias de estados que mediante el empleo de los modelos probabilísticos descritos en 2.2 y 2.3, permiten a su vez obtener la probabilidad de no detección o creencia restante en cada punto del dominio G . Por último, conociendo todo esto (variaciones de variables de control, estado de los UAVs, creencia restante), pueden evaluarse los criterios de factibilidad y calidad para la solución en cuestión, y comparar por tanto varias soluciones entre sí.

El presente trabajo se centra en el empleo de uno de los tipos de algoritmo bioinspirado que más tiempo lleva aplicándose, el algoritmo genético o GA [12, 19, 22]. En los siguientes apartados de este capítulo 3 se describe primero la estructura y operadores del GA propuesto como solución al problema MTS descrito en el capítulo 2, para posteriormente detallar la transformación de dicho GA en el GA Multi-etapa para trayectorias de dirección variable descrito en [21].

En el anexo 1 de esta documentación se puede encontrar la correspondencia entre los operadores del GA descritos en este capítulo y las funciones Matlab que los implementan en la codificación de los algoritmos GA y GA Multi-etapa realizada en el lenguaje Matlab. Dicho anexo incluye también la correspondencia entre los modelos de los elementos del problema descritos en el capítulo 2 y las funciones Matlab que los implementan.

3.1 Estructura general del GA

Los GA entran dentro de la categoría de los algoritmos bioinspirados, ya que su funcionamiento se basa en imitar el modo en el que una población de seres vivos de una determinada especie evoluciona a lo largo del tiempo, simulando el cruce entre individuos de la población, el nacimiento de nuevos individuos, la evolución de los mismos mediante mutaciones esporádicas, y el proceso de selección natural de los mejores individuos.

En el GA, los individuos que componen la población son en realidad posibles soluciones al problema a resolver, en este caso el problema MTS. Cada individuo es una solución del espacio de

soluciones del problema. En el MTS propuesto en el capítulo 2, se indicaba que la solución al problema consistía en una secuencia de variaciones de las variables de control de los UAVs, por lo que entonces los individuos que forman la población del GA serán conjuntos de M secuencias de T variaciones de las variables de control, siendo M el número de UAVs y correspondiendo por tanto cada secuencia a un determinado UAV. Es decir, un individuo del GA será un conjunto de M secuencias de T valores reales, cada uno de ellos representando una variación de cada variable de control en cada instante de variación.

Nótese que, si bien en la definición del MTS se indica que las variables de control de los UAVs son tres (dirección θ , velocidad v y altura h), el GA propuesto en [21] y descrito en este capítulo solo permite variar la dirección θ del UAV. Por ello, las soluciones del GA consisten entonces en conjuntos de M secuencias de T valores reales que corresponden a variaciones de la variable de control θ .

Se denomina genoma de los individuos del GA a la codificación que se realiza de la solución conceptual del problema para producir el individuo del GA en sí mismo. Una misma estructura de solución puede codificarse en genomas diferentes. Por ejemplo, tal y como se muestra en la Ilustración 10, una secuencia de T valores enteros podría codificarse en un genoma consistente en un vector de números enteros (esta sería la codificación más intuitiva), pero también podría codificarse en otro genoma como el vector de valores binarios resultantes de expresar los valores enteros en formato binario.

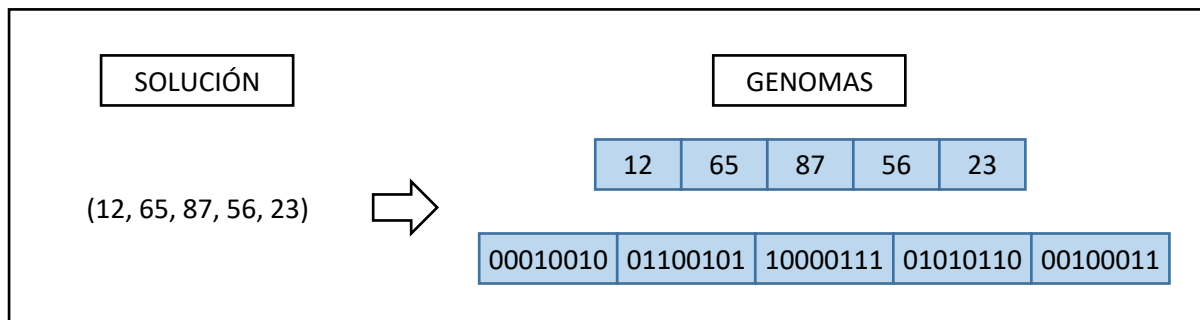


Ilustración 10 - Ejemplo de un tipo de solución y de dos genomas diferentes para la misma

En el GA existente, se emplea el genoma consistente en la codificación directa en un vector de números reales de los valores de variación de θ (dirección de los UAVs).

La estructura general del GA sigue la siguiente secuencia:

1. Inicialización de la población: se generan, obteniéndose mediante una distribución aleatoria los valores de cada genoma, un número de soluciones P , que serán los individuos que formen la población inicial. Se evalúa la calidad de cada uno de los individuos.
2. Selección de padres: se obtienen por un determinado método una serie de parejas de individuos, habitualmente $P/2$ parejas de individuos.

3. Cruce: las $P/2$ parejas generan P nuevos individuos, empleando un determinado método. Cada pareja de dos individuos de la población inicial genera dos individuos nuevos.
4. Mutación: algunos de los P nuevos individuos generados mediante la operación anterior de cruce, elegidos de forma aleatoria, sufren una modificación también aleatoria de parte de su genoma.
5. Recombinación: se evalúa la calidad de los nuevos individuos generados y, del conjunto formado por los P individuos originales más los P individuos generados en la operación de cruce, se seleccionan por algún método P individuos supervivientes que pasan a formar la nueva generación.
6. Comprobación de parada: se comprueba un determinado criterio de parada, si se cumple se termina la ejecución del GA pasando al punto 7, si no se cumple se vuelve al punto 2 para obtener una nueva generación.
7. Obtención de la solución: Se obtiene el mejor individuo de la última generación (la mejor solución) y se devuelve como solución del GA.

En la Ilustración 11 se puede observar una representación gráfica simplificada del bucle de obtención de sucesivas generaciones de individuos en un GA típico.




Ilustración 11 - Esquema de operadores de un GA típico

En los siguientes apartados se describen los métodos utilizados en cada uno de los operadores del GA Multi-etapa propuesto en [21] para la resolución del problema MTS.

3.1.1 Inicialización

El operador de inicialización de la población de soluciones del GA es habitualmente una función sencilla, pero puede haber casos excepcionales en los que hagan falta inicializaciones más específicas. Lo más habitual es que el operador se limite a obtener nuevos individuos generando de forma aleatoria, mediante una distribución de probabilidad uniforme, los valores numéricos que forman el genoma del individuo. Dependiendo del tipo de codificación de la solución en el genoma, los valores generados aleatoriamente deberán ser del tipo entero, real, o binario.

En el caso de conocerse a priori información acerca de la zona del espacio de soluciones en la que podrían encontrarse las mejores de ellas, puede ser interesante generar los valores numéricos del genoma empleando por ejemplo una distribución normal, en lugar de una uniforme, centrada en la zona que a priori se sabe más interesante.

En la implementación del GA Multi-etapa realizada en [21], y con la codificación de soluciones descrita en el apartado 3.1, la generación del genoma de los individuos de la población inicial se realiza mediante una distribución uniforme cuyos valores extremos (máximas variaciones posibles de la dirección θ en uno u otro sentido) se definen como parámetros del problema.

Nótese que conviene establecer los valores extremos de la distribución uniforme de θ en función de las posibilidades reales de giro del UAV, ya que los valores del genoma de los individuos son variaciones en la señal de control del UAV, no los giros de su trayectoria real. De no hacerse así, no se realizaría la búsqueda cubriendo todo el espacio posible de soluciones.

3.1.2 Evaluación de soluciones

En varios puntos del algoritmo, por ejemplo, tras generar la población inicial, o en cada iteración del mismo, tras obtener los nuevos individuos empleando los operadores de cruce y mutación, se realiza una operación consistente en la evaluación de los nuevos individuos o soluciones. Consiste en obtener un valor (GA monoevaluados) o un conjunto de valores (GA multievaluados) que sirva/n como indicador/es de que una solución es mejor o peor.

Esto se hace porque en otros puntos del algoritmo (selección de padres para el operador de cruce, recombinación para la siguiente generación) se escogen individuos (soluciones) en función de estos valores, prefiriéndose a los individuos “mejores” frente a los “peores”. En la versión del GA Multi-etapa implementada en [21], la evaluación de los individuos (soluciones) consiste en un proceso bastante complejo, que se describe a continuación.

Como se había indicado en el apartado 3.1, el genoma de un individuo consiste en una secuencia de variaciones de la variable de control que gobierna la dirección θ del UAV. Lo primero que se necesita para saber si las trayectorias del conjunto de UAVs resultantes son buenas, es obtener cuales son las trayectorias reales de los UAVs bajo dicha secuencia de señales de control. Para ello se emplea el modelo cinemático introducido en el apartado 2.4, el cual está implementado en un modelo *Simulink* que emplea como entradas la secuencia de variaciones de θ del genoma de

la solución a evaluar y secuencias de la misma longitud de variaciones nulas de altitud h y velocidad v .

Este modelo *Simulink* se encarga de computar y devolver como salida todos los valores correspondientes a los estados s_i^j de los UAVs, valores que incluyen la trayectoria tridimensional de los UAVs, la dirección θ y velocidad v reales a lo largo de dicha trayectoria, el consumo de combustible, etc.

Tras obtener todos estos valores correspondientes al estado de los UAVs durante la trayectoria, la evaluación de las soluciones se realiza empleando los diferentes criterios descritos desde el apartado 2.5.1 hasta el 2.5.5 (criterios de colisiones y NFZs, criterios de mínimo tiempo de búsqueda ET y MYOP, criterios adicionales FUEL y SMOOTH).

La evaluación de los dos criterios de factibilidad de soluciones (el criterio del número de colisiones y el del número de invasiones de NFZs por parte de los UAVs) es relativamente sencillo, disponiendo de los puntos que marcan las trayectorias de los UAVs y de la lista de NFZs con las coordenadas que las definen.

Los dos criterios más complejos de evaluar son los directamente relacionados con el problema MTS, es decir, los criterios ET y MYOP, que, como se puede ver en los apartados 2.5.2 y 2.5.3, miden respectivamente la probabilidad de encontrar al objetivo lo antes posible durante la trayectoria de los UAVs o en trayectorias futuras desde los puntos en los que finalizan las trayectorias calculadas en la solución. Nótese que, para realizar el cálculo de estos criterios, además de los estados de los UAVs, se necesita el modelo probabilístico del objetivo (ver apartado 2.2) y el del sensor con el que están equipados los UAVs (ver apartado 2.3).

Finalmente, el criterio SMOOTH (ver apartado 2.5.4) se calcula de forma directa empleando la información de las trayectorias de los UAVs, mientras que el criterio FUEL (ver apartado 2.5.5) se obtiene de la variable de salida del modelo cinemático de los UAVs que indica el combustible consumido por los mismos.

El conjunto de valores obtenido para un determinado individuo (solución) mediante todos estos criterios es un indicador de si este es mejor o peor que el resto de individuos de la población, y se emplea en alguno de los operadores descritos en los siguientes apartados para tomar decisiones respecto a qué individuos deben ser seleccionados (para el cruce, para la recombinación ...).

3.1.3 Operador de Selección

Realizada la inicialización y la evaluación de la población inicial de individuos (soluciones) del GA, se entra en el bucle principal del mismo. La primera operación que se hace en él consiste en la selección de parejas de individuos que actúen como padres de los individuos de la siguiente generación. Habitualmente, si la población tiene un tamaño P , se suelen seleccionar $P/2$ parejas de dos padres que generan 2 individuos hijos cada una, obteniéndose un conjunto de P nuevos individuos, aunque esto no tiene por qué ser siempre así.

Este proceso, que a priori puede parecer muy simple, puede en la práctica realizarse de formas relativamente complejas. La versión más sencilla consistiría en seleccionar cada padre de forma completamente aleatoria de entre el total de individuos de la población, impidiendo que el mismo individuo sea seleccionado dos veces para la misma pareja. Este método se emplea raramente, ya que no tiene en cuenta la calidad de los individuos, determinada como se indica en el apartado 3.1.2.

Otros métodos más frecuentemente empleados son el de la ruleta (en el que se seleccionan aleatoriamente los individuos padre pero teniendo en cuenta de forma proporcional la calidad de cada uno de los individuos seleccionables) o los métodos de torneo (en los que se seleccionan aleatoriamente unos cuantos individuos de la población total que pasan a ser competidores en un torneo, que a su vez puede resolverse de diversas formas, por ejemplo escogiendo al mejor de los individuos competidores, o aplicando el método de la ruleta sobre los competidores). En general, un método de selección debería tener en cuenta de alguna forma los indicadores de calidad de los individuos evaluados previamente, para imitar el paradigma evolutivo en el que se basa el GA, que dice que los individuos más fuertes (soluciones mejores) tienen más probabilidad de reproducirse que los más débiles (soluciones peores).

En la implementación del GA Multi-etapa presentado en [21], el método de selección escogido es el de torneo binario (representado en la Ilustración 12), consistente en seleccionar cada individuo padre como el vencedor de un torneo para el que se seleccionan de forma aleatoria tan solo dos participantes de entre los individuos de la población actual. El vencedor del torneo se selecciona de la siguiente forma:

1. Si para uno de los dos participantes (p. ej. $p1$) el sumatorio de los valores que toman los dos criterios de factibilidad ($\#COL$ y $\#NFZ$, definidos en 2.5.1) es menor que el del otro participante (p. ej. $p2$), se selecciona $p1$ como vencedor. De esta forma, las soluciones que están más cerca de cumplir las restricciones (o que las cumplen totalmente) son preferibles a las que están más lejos.
2. En otro caso (el sumatorio de valores de los dos criterios de factibilidad es similar para los dos participantes $p1$ y $p2$), se toma como vencedor a aquel de los participantes $p1$ cuya tupla de valores para el resto de criterios a optimizar (ET, MYOP, FUEL, SMOOTH, definidos en 2.5.2 a 2.5.5) domine a la del otro participante $p2$. Una tupla $t1$ domina a otra tupla $t2$ si todos los valores de $t1$ son mejores o iguales que los de $t2$ (en este caso, menores o iguales, ya que todos los criterios son de minimización) y al menos uno de los valores de $t1$ es estrictamente mejor que el valor de $t2$ (en este caso, estrictamente menor).
3. En otro caso (ninguno de los individuos participantes domina al otro), se selecciona uno de ellos aleatoriamente.

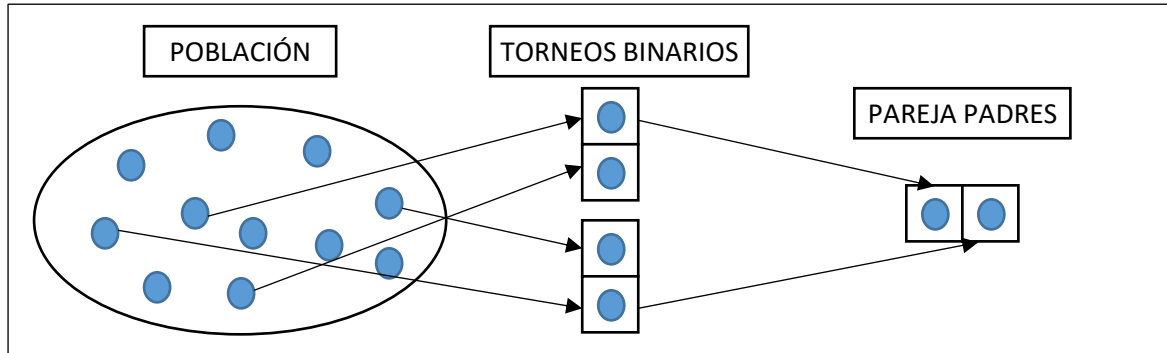


Ilustración 12 - Selección mediante torneo binario

En la implementación de este método, para determinar la relación de dominación entre las tuplas de valores de los criterios (ET, MYOP, FUEL, SMOOTH) para las soluciones $p1$ y $p2$ participantes en el torneo, no se emplean directamente los valores obtenidos para los criterios, sino que se aplica primero un redondeo a dichos valores. El motivo de esto es impedir que, dadas por ejemplo dos soluciones $p1$ y $p2$ para las que los valores de ET, MYOP y FUEL sean mucho mejores (menores) para la solución $p1$, pero el valor de SMOOTH sea ligeramente peor (mayor) para la solución $p1$, el hecho de que la solución $p1$ no domine a $p2$, tan solo por una diferencia pequeña en un criterio secundario como SMOOTH, impida que $p1$ sea seleccionada como padre antes que $p2$. La magnitud de este redondeo es mayor para los criterios accesorios (SMOOTH y FUEL) que para los criterios considerados como fundamentales para el problema MTS (ET y MYOP).

3.1.4 Operador de Cruce

La operación de cruce es el método mediante el que, a partir de una serie de parejas de individuos de la población actual, se generan dos nuevos individuos hijos por cada pareja. Esta operación simula el proceso reproductivo de los seres vivos, en el sentido de que los individuos hijos heredan algunas de sus características de uno de los padres y otras del otro. En el caso del GA, las soluciones hijas heredarán parte de su genoma del genoma de uno de los padres y la otra parte del otro. Habitualmente, cada pareja de individuos padre genera exactamente dos hijos.

Existen varios métodos para realizar esta operación. Los métodos más sencillos son los de corte e intercambio de cadenas del genoma, consistentes en generar un número de puntos de corte situados a lo largo del genoma de los padres, de forma que, para el intervalo del genoma de los hijos entre el principio y el primer punto de corte, el hijo $h1$ recibe el genoma del padre $p1$ y el hijo $h2$ recibe el genoma del padre $p2$, para el intervalo del genoma de los hijos entre el primer y segundo puntos de corte, el hijo $h1$ recibe el genoma del padre $p2$ y el hijo $h2$ recibe el genoma del padre $p1$, y así sucesivamente intercambiando el origen del genoma a cada nuevo punto de corte.

Otra versión de este mismo método consiste en, para cada elemento de la cadena del genoma de los hijos, determinar aleatoriamente de qué padre se obtiene el gen. De esta forma el resultado es el mismo que en el caso anterior, pero sin conocerse de antemano el número de puntos de corte que van a marcar la herencia del genoma de los individuos hijos.

Existen métodos más complejos, como por ejemplo generar cada uno de los genes de las soluciones hijas como una combinación aritmética de los genes de las soluciones de los dos padres.

Nótese que con un método como este, ninguno de los hijos recibe los mismos genes que tenían los padres ya que los propios genes se ven alterados en la operación de cruce.

En general, la elección de un método de cruce u otro depende del conocimiento del dominio del problema, siendo lo más habitual emplear operadores basados en corte más o menos complejos.

En la implementación del GA Multi-etapa para la resolución del problema MTS presentada en [21], el método de cruce empleado es el de corte con un único punto de corte del genoma, y aplicado solo a un cierto porcentaje de los hijos de cada generación (el porcentaje restante de hijos heredan todas sus características de uno solo de sus padres). Esto se hace para permitir al operador de mutación, que se describe en el apartado 3.1.5 y se aplica después del operador de cruce, modificar ligeramente de forma directa algunas de las soluciones seleccionadas por el método del torneo. La Ilustración 13 muestra un ejemplo de la aplicación del método de cruce descrito.




Ilustración 13 - Cruce mediante corte en un único punto de corte

3.1.5 Operador de Mutación

El otro operador que, junto con el operador de cruce, influye en la forma que adopta el genoma de los individuos hijos de cada generación es el de mutación. El fenómeno de la mutación en las poblaciones de seres vivos en la naturaleza resulta mucho más extraño, por poco habitual, que el fenómeno del cruce y herencia de características, pero no por ello es menos importante. En realidad, es un fenómeno complementario a la herencia por cruce, ya que, al consistir en una alteración brusca de una parte, habitualmente pequeña, del genoma del nuevo individuo, permite que dicho individuo presente una característica que tal vez hubiera sido imposible de obtener por herencia de ningún individuo padre de la anterior generación. La mutación es, por ello, un mecanismo que permite explorar características o, en el caso de un GA, zonas del espacio de soluciones, inalcanzables solo mediante cruce y herencia.

La actuación del operador de mutación se basa en dos aspectos o parámetros diferenciados: por una parte, debe decidirse qué elementos de la cadena del genoma del nuevo individuo van a mutar (qué genes van a mutar), y por otra debe decidirse cómo se van a mutar (qué valores van a tener) dichos elementos.

Lo más frecuente es que se desee que la cantidad de genes mutados sea más bien baja, ya que cuando se mutan demasiados se desvirtúa la información genética almacenada en los nuevos individuos hijos, que se supone buena por haber sobrevivido en sus padres en las generaciones

anteriores hasta llegar a la actual. Es frecuente recorrer el genoma de los individuos hijo y decidir, en base a una probabilidad muy baja, si cada gen muta o no. En ocasiones se establece esta probabilidad como el inverso de la longitud del genoma de los individuos, lo cual estadísticamente deriva en que, de media, se mute un único gen de cada individuo.

Por otra parte, la mutación de cada gen puede plantearse de varias formas. La más sencilla sería generar un nuevo valor para el gen de forma aleatoria mediante una distribución uniforme sobre todos los valores posibles del dominio, mientras que en otros casos pueden emplearse distribuciones no uniformes centradas en un determinado punto del dominio (si se conoce que las soluciones pudieran estar cerca de dicho punto), o realizar la mutación de forma incremental, es decir, no generando un nuevo valor absoluto para el gen, sino generando un incremento, positivo o negativo (p. ej. mediante una distribución gaussiana centrada en 0), y aplicando dicho incremento al valor original del gen.

En la implementación del algoritmo GA Multi-etapa realizada en [21], se ha optado por introducir un operador de mutación incremental (cuya representación puede observarse en la Ilustración 14), que en realidad se divide en dos tipos de mutación independientes:

1. Una mutación que se aplica solo a algunos genes, en función de una probabilidad relativamente baja asociada al inverso de la longitud del genoma, y que consiste en incrementar el valor del gen (o decrementarlo) según el valor aleatorio obtenido en una distribución gaussiana g_1 de media nula y varianza σ_1 relativamente alta.
2. Otra mutación que se aplica a todos los genes, y que consiste en incrementar el valor de cada gen (o decrementarlo) según el valor aleatorio obtenido en una distribución gaussiana g_2 de media nula y varianza σ_2 relativamente baja.




Ilustración 14 - Mutación mediante incremento por distribuciones gaussianas

3.1.6 Operador de Recombinación

La última operación dentro del bucle principal de un algoritmo GA es la de la recombinación de las poblaciones de los individuos originales de la anterior generación, y de los individuos nuevos obtenidos por cruce y mutación de los originales, para obtener una nueva población del mismo tamaño que el de la población original. En este aspecto, los GA difieren ligeramente de cómo funcionan las poblaciones naturales de seres vivos, ya que en estas los nuevos individuos van sustituyendo paulatinamente a los originales, mientras que en el GA no suele existir el concepto de edad de las soluciones, por lo que en algunas implementaciones del operador de recombinación

soluciones de generaciones muy anteriores pueden sobrevivir a soluciones nuevas, si son de una mayor calidad.

Antes de aplicar el operador de recombinación propiamente dicho, se realiza una evaluación de la calidad de las soluciones hijas obtenidas por cruce y mutación, empleando los criterios de evaluación como se describe en el apartado 3.1.2.

La forma más sencilla de realizar la recombinación es mediante el método de sustitución generacional, que consiste en descartar todos los individuos de la generación anterior y que la nueva generación se componga exclusivamente de los individuos hijos. Frente a este método, existen otros denominados elitistas, en los que se tiene en cuenta la calidad de los individuos para seleccionar a los supervivientes. La forma más sencilla de método elitista sería emplear a los mejores de los dos conjuntos (población original e hijos) hasta completar el número de individuos para que el tamaño de la población no varíe.

El método recombinatorio que se emplea en la implementación del GA Multi-etapa propuesta en [21] es el método de recombinación del algoritmo NSGA-II cuya aplicación está orientada a problemas multiobjetivo, como es el caso del problema MTS objeto del presente trabajo. Para describir este método conviene describir el concepto de frente de Pareto. Tal y como ya se ha indicado, en problemas como el MTS en el que la calidad de una solución se evalúa en base no solo a uno sino a varios criterios, solo se puede considerar una solución s' mejor que otra s'' en el caso de que s' domine a s'' (es decir, s' es mejor o igual en todos los criterios que s'' , y mejor estrictamente en al menos un criterio). Esta definición formal del concepto de la relación de dominación se muestra en la Expresión (14).

$$s' = (c'_1, c'_2, \dots, c'_n), s'' = (c''_1, c''_2, \dots, c''_n), \forall i \in \{1:N\} c'_i \leq c''_i, \exists j \in \{1:N\} c'_j < c''_j \quad (14)$$

El primer frente de Pareto de un conjunto S de soluciones es aquel subconjunto F'_S del mismo tal que cualquier solución perteneciente a F'_S domina a todas las soluciones de $(S - F'_S)$, pero no domina ni es dominada por ninguna otra perteneciente a F'_S . El segundo frente de Pareto F''_S de S se calcula como el primer frente de Pareto de $(S - F'_S)$, y así sucesivamente.

El algoritmo de recombinación de NSGA-II consiste en ir incluyendo en la población de individuos supervivientes el primer, segundo, tercer, ..., frentes de Pareto del conjunto unión de los individuos de la anterior generación y de los individuos hijos, hasta que uno de los frentes ya no pueda incluirse entero sin superar el tamaño deseado de la nueva población. De este último frente se incluyen solo como supervivientes aquellos individuos con mayor *crowding distance* hasta completar el tamaño de población buscado. La *crowding distance* de cada individuo se calcula como el sumatorio de diferencias de los valores de cada uno de los criterios para dicho individuo con los individuos vecinos por encima y por debajo de él (aquellos cuyas valoraciones del criterio en cuestión están más cerca por encima y por debajo de la valoración del individuo en cuestión). La intención, al seleccionar los individuos con mayor *crowding distance*, es producir la mayor variedad posible dentro del espacio de búsqueda entre aquellos individuos del último frente de Pareto que se incluyen en la población de la nueva generación.

3.1.7 Parada y obtención de la solución

La definición del algoritmo GA se completa estableciendo el criterio de parada que se comprueba tras cada iteración del bucle principal del mismo, y el método para seleccionar el individuo que el GA devolverá como solución.

En la implementación del algoritmo GA Multi-etapa realizada en [21], el GA se detiene al cumplirse cualquiera de los dos siguientes criterios:

1. Se supera un número determinado de generaciones.
2. Se supera un tiempo de computación determinado.

Al terminarse la ejecución del bucle principal del algoritmo GA por cualquiera de los dos criterios indicados, en realidad, se cuenta con una población actual de individuos (soluciones) al problema MTS, no con una solución única. Si se tratase de un problema monoobjetivo, evaluado mediante un único criterio, bastaría con escoger la solución con el mejor valor para dicho criterio de entre la población final. En el caso de problemas multiobjetivo, como el MTS propuesto, la selección de una solución u otra depende del conocimiento del dominio del problema.

En la versión del GA Multi-etapa implementada en [21], se ha optado por calcular el frente de Pareto de la población final de soluciones y, de entre dicho conjunto, escoger la mejor solución priorizando los criterios en este orden: MYOP, ET, SMOOTH y FUEL. Se escogerá como mejor solución, dentro del primer frente de Pareto, aquella cuyo valor redondeado (véase el apartado 3.1.3 acerca del redondeo) de MYOP sea menor. En el caso de que más de una solución tenga el mismo valor redondeado de MYOP, se escogerá de entre ellas aquella cuyo valor redondeado de ET sea mejor, y así sucesivamente con el resto de criterios, hasta obtener una solución considerada mejor. Se aplica conocimiento implícito del problema, ya que se sabe que los criterios MYOP y ET son más relevantes en el problema MTS que SMOOTH y FUEL, y se conoce además que el criterio MYOP informa no solo del total de creencia recogida, al igual que el criterio ET, sino también de la disposición de los UAVs para recoger la creencia restante (de ahí que se anteponga en importancia MYOP a ET al elegir la solución devuelta por el GA).

3.2 Algoritmo GA Multi-etapa

En el apartado 3.1 se ha descrito la estructura general y los operadores empleados en la implementación del GA propuesta como solución inicial al problema MTS en [21]. Sin embargo, en dicha referencia se propone también una solución más eficiente al problema MTS, consistente en descomponerlo en una serie de etapas (de ahí la denominación GA Multi-etapa) cada una de ellas resoluble de forma individual mediante el GA descrito.

En la definición formal del problema MTS, concretamente en el apartado 2.4, se describe que la solución al problema se expresa en una secuencia de T cambios de las variables de control de los UAVs (en la implementación realizada en [21], únicamente de la variable de control de dirección θ de los UAVs). Lo que se propone en la definición del GA Multi-etapa es dividir el

problema a resolver en S subproblemas, en los que la longitud de la secuencia de cambios de las variables de control sea igual a L , de forma que $L = T/S$.

El algoritmo GA Multi-etapa se puede describir en los siguientes pasos:

1. Inicialización: se inicializa una variable s_{MS} con el estado inicial s_0 de los UAVs, una variable b_{MS} con el modelo (mapa) de probabilidad del objetivo inicial b_0 , otra variable de tipo vector c_{MS} con los valores de los criterios de optimización (#COL, #NFZ, MYOP, ET, SMOOTH, FUEL) inicialmente todos a 0, otra variable de tipo vector u_{MS} con la secuencia de variaciones de las señales de control de los UAVs inicialmente vacía, y otra variable p_{MS} con el valor del paso o etapa actual, inicialmente 1, a computar.
2. Ejecución del GA para el subproblema: se ejecuta el algoritmo GA para resolver el problema MTS generando una secuencia de L cambios en las variables de control, empleando s_{MS} como el estado inicial de los UAVs y b_{MS} como el modelo (mapa) de probabilidad del objetivo.
3. Actualización de variables: se actualiza la variable p_{MS} incrementando en 1 su valor. Se actualiza la variable s_{MS} , almacenando en ella los estados finales de los UAVs obtenidos al computar la solución obtenida en la ejecución del GA en el punto 2 mediante el modelo cinemático de los UAVs del apartado 2.4. Se actualiza la variable b_{MS} almacenando en ella el modelo (mapa) de probabilidad del objetivo tras computar la probabilidad de encontrar al mismo, con la solución obtenida en la ejecución del GA en el punto 2, mediante el modelo cinemático de los UAVs del apartado 2.4 y el modelo probabilístico del sensor de los UAVs del apartado 2.3. Se actualiza la variable u_{MS} concatenando a su valor actual la secuencia de variaciones de las variables de control obtenida como solución en el punto 2. Se actualiza la variable c_{MS} incrementando los valores de los criterios de optimización #COL, #NFZ y FUEL con los de la solución obtenida en el punto 2, actualizando el valor de MYOP con el de la solución obtenida en el punto 2, y recalculando el valor de ET y SMOOTH a partir de u_{MS} .
4. Comprobación de parada: se comprueba si p_{MS} ha alcanzado el valor S (número de pasos o etapas del GA Multi-etapa), y en ese caso se pasa al punto 5. En otro caso, se vuelve al punto 2.
5. Fin del GA Multi-etapa: se devuelve como solución la secuencia de variaciones de las variables de control contenida en la variable u_{MS} , conteniendo la variable c_{MS} los valores de los criterios de optimización para dicha solución, la variable s_{MS} el estado final de los UAVs y la variable b_{MS} el mapa de probabilidad o creencia restante (no recogida) por los UAVs a lo largo de la trayectoria obtenida como aplicación de las variaciones de las variables de control contenidas en la variable u_{MS} .

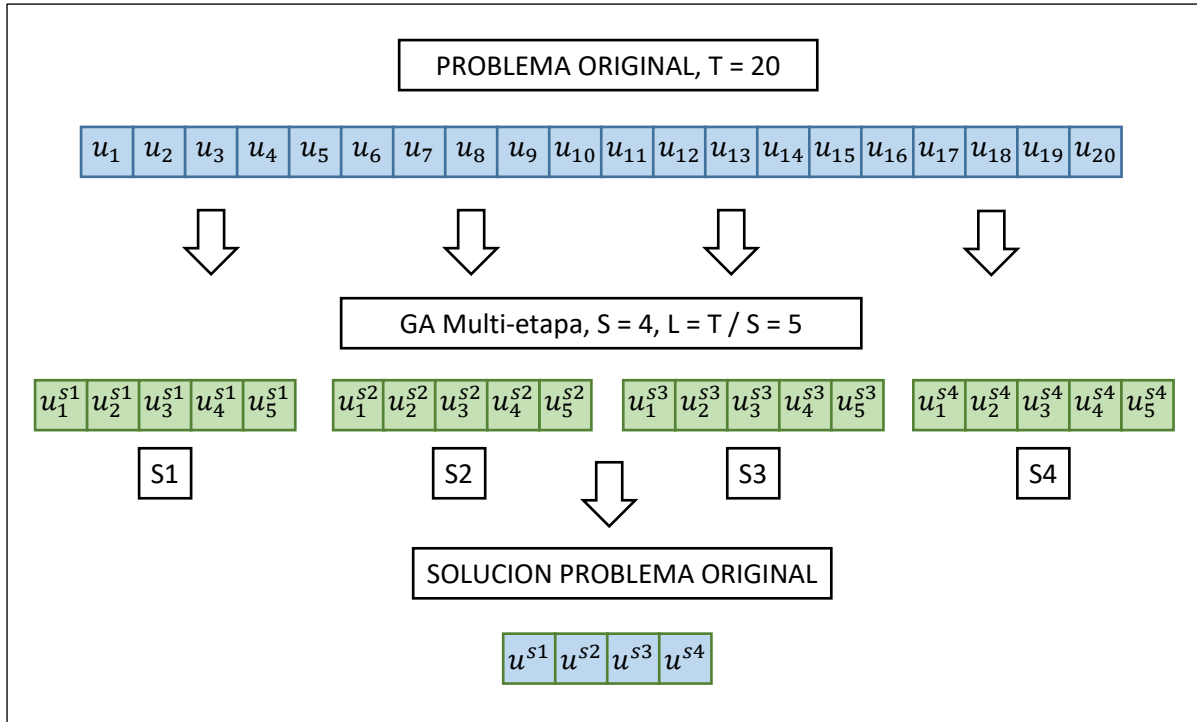


Ilustración 15 - Subdivisión de un problema mediante GA Multi-etapa y composición de la solución al problema original

El objetivo de este algoritmo GA Multi-etapa consiste en descomponer el problema general MTS en S subproblemas de menor tamaño, semejantes en formulación al MTS original, de forma que puedan ser resueltos por el mismo GA diseñado para el problema MTS. Puede observarse en la Ilustración 15 como la solución al problema original se obtiene por concatenación de las soluciones individuales de los S subproblemas en los que se descompone dicho problema original. Al ser la suma de complejidades de los S subproblemas menor que la del problema completo, tal y como se muestra en el análisis estadístico de los resultados recogidos en [21], el algoritmo GA Multi-etapa permite resolverlo con un coste computacional menor que el algoritmo GA.

4 GA Multi-etapa para trayectorias de dirección, velocidad y altura variables

El algoritmo GA Multi-etapa descrito en el capítulo 3 y en [21] permite solucionar el problema MTS para una flota de UAVs controlados mediante cambios de dirección θ , a partir del empleo combinado de una descomposición del problema general en una serie de subproblemas de las mismas características, pero de menor tamaño (descomposición en etapas o tramos), y de un GA para resolver cada uno de estos subproblemas menores.

En el capítulo de conclusiones de [21] se propone, entre otras ampliaciones, el desarrollo de un GA Multi-etapa extendido, en el sentido de que el GA subyacente permita controlar no solo la variable de dirección θ de los UAVs, sino también su velocidad v y su altura h . Un GA Multi-etapa de estas características debería permitir obtener soluciones en principio mejores que el GA Multi-etapa original, ya que el número de posibles trayectorias que estudiaría es muchísimo mayor al permitir otros dos grados de libertad a los UAVs. Nótese que el conjunto de trayectorias posibles seguiría estando restringido por el modelo cinemático de los UAVs empleados.

Además de ofrecer mejores soluciones en general, un GA Multi-etapa con cambios de dirección, velocidad y altura podría ofrecer soluciones factibles a problemas difícilmente resolubles mediante el GA Multi-etapa original de [21], por ejemplo, problemas en los que una gran densidad de NFZs exigiese a los UAVs una cierta combinación de velocidad y dirección para alcanzar algunas zonas donde pudiera estar el objetivo, o problemas en los que la distribución de zonas de máxima probabilidad de ocurrencia del objetivo requiriese, para completarse en una cantidad de tiempo aceptable, giros a baja velocidad en unos momentos combinados con desplazamientos largos a mayor velocidad en otros. De hecho, las limitaciones de los UAVs en cuanto a capacidad de giro respecto a su velocidad constituyen uno de los principales motivos de la complejidad del problema MTS formulado, por lo que un GA Multi-etapa que explote al máximo las posibilidades de movimiento de los UAVs debería verse beneficiado sobre el GA Multi-etapa original limitado en ese sentido. El desarrollo de este GA Multi-etapa, junto al estudio de la calidad de sus soluciones respecto a las del GA Multi-etapa original, son dos de los principales objetivos del presente trabajo como ya se indicó en el apartado 1.2.

Una de las cuestiones que se plantea al diseñar el nuevo GA Multi-etapa es, como en cualquier otro GA (véase apartado 3.1), la de la codificación de las soluciones del problema en el genoma de los individuos. En el caso de la versión con cambios de dirección, velocidad y altura del GA Multi-etapa que se desea, al aumentarse las posibilidades de manejo de los UAVs de una a tres variables de control, aumentan también las posibilidades de codificación de las soluciones. De aquí nace el otro objetivo prioritario del presente trabajo, que consiste en el diseño e implementación de varias alternativas de codificación de las soluciones, cada una de las cuales en realidad dará lugar a un GA diferente, de forma que el estudio comparativo de resultados se realizará no solo entre el GA Multi-etapa original de [21] y el GA Multi-etapa con cambios de dirección, velocidad y altura, sino también entre las diferentes versiones del segundo.

El diseño de estas codificaciones de soluciones del GA, que se exponen a lo largo del apartado 4.1, se inspira inicialmente en el trabajo realizado en [1], en el que se afrontan diversos problemas relativos al control colaborativo de conjuntos de UAVs (optimización de trayectorias,

evitación de colisiones, ...) empleando técnicas heurísticas como GA o PSO. Entre los algoritmos desarrollados en [1] se incluye una propuesta de codificación a medida de soluciones que contempla trayectorias de los UAVs basadas en modificaciones de dirección, altura y velocidad, si bien de forma más limitada que las codificaciones que se proponen en el apartado 4.1, ya que únicamente permite que cada UAV pueda realizar cambios de una sola variable de control a lo largo de toda su trayectoria (por ejemplo, un UAV puede cambiar de dirección pero no de altura ni velocidad). Por lo tanto, las codificaciones de soluciones diseñadas en este Trabajo de Fin de Máster amplían la propuesta recogida en [1] al permitir que las trayectorias de cada UAV puedan incluir las combinaciones de cambios de dirección θ , altura h y velocidad v que sean necesarias para minimizar el tiempo de búsqueda del problema MTS.

En el anexo 1 de este Trabajo de Fin de Máster se señalan, mediante código de colores allí descrito, las funciones Matlab modificadas y añadidas a la implementación del GA Multi-etapa original para el desarrollo del GA Multi-etapa para trayectorias de dirección, altura y velocidad variables descrito a lo largo de este capítulo.

4.1 Codificación de soluciones

En los siguientes apartados se describen las diferentes codificaciones de soluciones propuestas para el nuevo GA Multi-etapa y el comportamiento del GA que se espera basado en ellas. Las nuevas codificaciones se numeran del 2 al 6, considerándose la codificación del GA original, en el que solo variaba la dirección θ , como la Codificación 1.

Nótese que el empleo de algunas de estas codificaciones afecta también al resto del GA, en el sentido de que algunos operadores (inicialización, mutación, cruce) pueden necesitar modificaciones que permitan garantizar la consistencia del genoma de los nuevos individuos generados por el operador en cuestión. Se hace referencia a estos cambios, en los casos en los que procede, en el apartado 4.2.

4.1.1 Codificación 2 (variaciones de dirección, velocidad o altura)

La primera codificación de soluciones propuesta consiste en extender la codificación original (Codificación 1) para el uso de tres variables de control en lugar de una sola. Si la codificación original consistía en una secuencia de valores reales, cada uno de los cuales equivalía a una variación de la variable de control dirección θ , la Codificación 2 aquí propuesta consiste en una secuencia de valores reales, cada uno de los cuales equivale a una variación de alguna de las tres variables de control dirección θ , velocidad v o altura h .

Se presenta el problema, por lo tanto, de representar en un único valor real (un único gen) dos tipos de información de forma simultánea: por un lado, el significado del gen (cambio de dirección, velocidad o altura) y, por otro, la magnitud de dicho cambio. La forma más sencilla de hacer esto es emplear la parte entera del número real para codificar la variable de control del UAV a modificar, y por otro lado la parte fraccionaria para codificar la magnitud del cambio de la variable de control del UAV.

En la Codificación 1, el valor que podía tomar cada gen (cada número real) de los que estaba formado el genoma completo de un individuo estaba acotado por dos valores reales $max\theta$ y $min\theta$. Estas dos constantes indicaban, de forma absoluta, el máximo cambio de dirección en uno u otro sentido que en una solución del GA se podía solicitar al UAV en un momento dado. En la nueva Codificación 2 no pueden establecerse los límites del valor que pueden tomar los genes de la misma forma, ya que la parte entera del número real en el que consiste cada gen esta “reservada”, por decirlo así, para indicar el tipo de variable modificada en ese instante concreto.

Lo que se propone, en esta Codificación 2, consiste en codificar la variable a modificar en el rango real de $[0,3)$, de forma que un valor cuya parte entera sea 0 indica una modificación de la dirección θ , un valor cuya parte entera sea 1 indica una modificación de la altura h y un valor cuya parte entera sea 2 indica una modificación de la velocidad v . La parte fraccionaria, en cualquiera de los casos, indica el porcentaje de variación dentro del posible rango de variación de la variable en cuestión, rango marcado por una de las parejas de parámetros $[max\theta, min\theta]$, $[maxH, minH]$ y $[maxV, minV]$. La Ilustración 16 muestra un ejemplo de una solución codificada de esta forma. La variación se calcula mediante la Expresión (15) empleando la parte fraccionaria del valor del gen.

$$\Delta(x) = \begin{cases} 0 \leq x < 1 & \rightarrow \Delta\theta = min\theta + fracc(x) \cdot (max\theta - min\theta) \\ 1 \leq x < 2 & \rightarrow \Delta h = minH + fracc(x) \cdot (maxH - minH) \\ 2 \leq x < 3 & \rightarrow \Delta v = minV + fracc(x) \cdot (maxV - minV) \end{cases} \quad (15)$$

El ajuste de los parámetros que establecen el rango de las diferentes variables debe hacerse en función de las posibilidades de maniobra del UAV, predeterminadas por su diseño aerodinámico. Establecer un rango de variación muy amplio para alguna de las variables podría no solo resultar ineficaz por el hecho de que el UAV no pudiera llegar a realizar las variaciones solicitadas, sino que además podría impedir que el GA buscase trayectorias a lo largo del rango real en el que el UAV puede responder eficazmente a los cambios de la variable en cuestión solicitados.

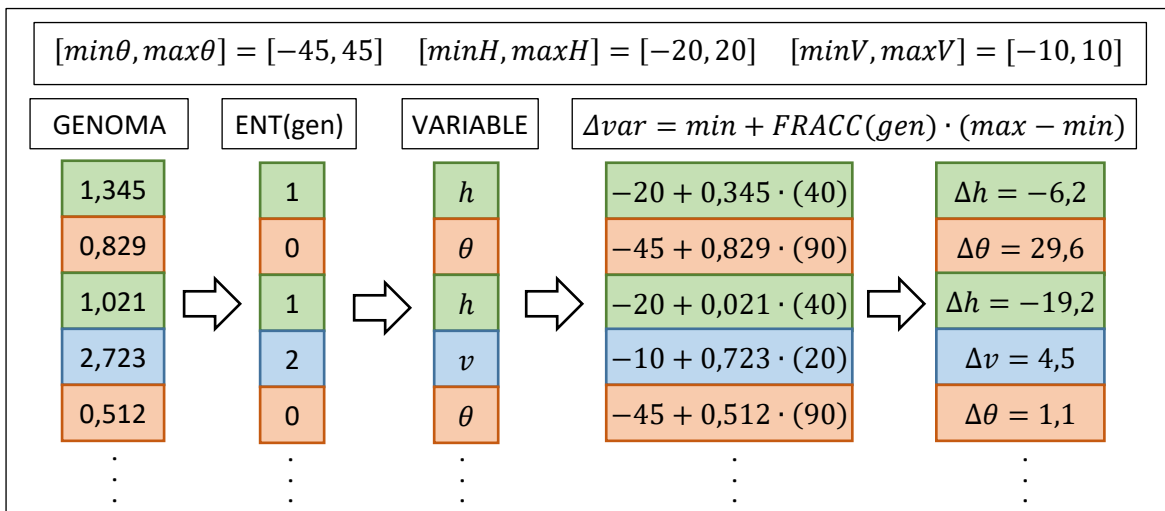


Ilustración 16 - Ejemplo de genoma empleando la Codificación 2

El objetivo de esta representación es el de obtener trayectorias más variadas que las que permite la Codificación 1, por introducir cambios de velocidad y altura además de los de dirección. Al aumentar de forma tan drástica el espacio de búsqueda, de un solo grado de libertad a tres, las soluciones propuestas por el nuevo GA podrían mejorar respecto al original.

4.1.2 Codificación 3 (variaciones de dirección, velocidad o altura y posibilidad de no variación)

La Codificación 3 propuesta resulta ser una ampliación de la descrita en el apartado anterior, motivada por el concepto intuitivo de que, en determinados puntos de una trayectoria y en función del escenario (forma de las NFZs, modelo de probabilidad del objetivo, ...), puede resultar más interesante no modificar ninguna de las variables de control del UAV antes que realizar una modificación en alguna de ellas que pudiera ser contraproducente. Una situación de este tipo sería, por ejemplo, un caso en el que un UAV ya está encarado hacia un punto de máxima probabilidad de presencia del objetivo, volando a la máxima velocidad y a una altura óptima para examinar el punto en cuestión con el sensor.

En general, se puede decir que se trata de una estrategia un poco más conservadora que el caso de la Codificación 2, ya que se obtienen trayectorias y curvas de velocidad más suaves, y por lo tanto una población de soluciones algo más uniforme y menos variada. Esto hace que el algoritmo, en su balance entre la conservación de soluciones buenas, pero que puedan ser mínimos locales, y la búsqueda en otros puntos del espacio de soluciones, tienda más hacia lo primero.

La codificación que se propone en este caso consiste, entonces, en un genoma cuyos elementos (genes) sean números reales en el rango $[0,4)$, de forma que un valor cuya parte entera sea 0 indica una modificación de la dirección θ , un valor cuya parte entera sea 1 indica una modificación de la altura h , y un valor cuya parte entera sea 2 indica una modificación de la velocidad v , mientras que un valor cuya parte entera sea 3 indica que no hay modificación de ninguna variable de control. La magnitud de las variaciones se calcula de forma análoga a la Codificación 2, como se puede ver en la Expresión (16). Se puede ver en la Ilustración 17 un ejemplo de solución empleando esta codificación.

$$\Delta(x) = \begin{cases} 0 \leq x < 1 & \rightarrow \Delta\theta = \min\theta + \text{fracc}(x) \cdot (\max\theta - \min\theta) \\ 1 \leq x < 2 & \rightarrow \Delta h = \min H + \text{fracc}(x) \cdot (\max H - \min H) \\ 2 \leq x < 3 & \rightarrow \Delta v = \min V + \text{fracc}(x) \cdot (\max V - \min V) \\ 3 \leq x < 4 & \rightarrow \Delta\theta = \Delta h = \Delta v = 0 \end{cases} \quad (16)$$

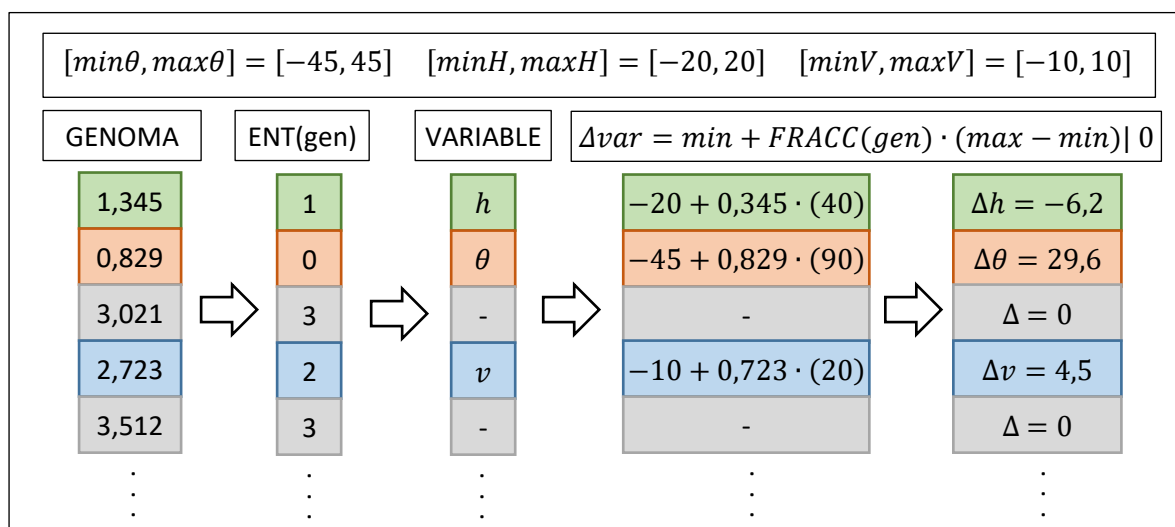


Ilustración 17 - Ejemplo de genoma empleando la Codificación 3

La intención de esta Codificación 3 se centra, entonces, en permitir al GA obtener soluciones consistentes en trayectorias más suaves que en las Codificaciones 1 y 2, permitiendo periodos de vuelo estables sin cambios en las variables de control de los UAVs.

4.1.3 Codificación 4 (variaciones de dirección, velocidad y altura simultáneas)

El planteamiento que se hace en el apartado anterior, respecto a permitir al GA la obtención de trayectorias más suaves que pudieran ser mejores en ciertos escenarios, puede invertirse pensando en el tipo de caso opuesto. En determinadas situaciones, la mejor trayectoria en un determinado punto podría obtenerse tan solo en base a la modificación muy brusca de las variables de control de los UAVs, o tal vez incluso con la modificación simultánea de varias variables de control.

Es importante destacar que el estudio de este tipo de casos, es decir, trayectorias de los UAVs en las que en alguno de los instantes se modifica simultáneamente más de una variable de control, se realiza en este Trabajo de Fin de Máster desde el punto de vista teórico ya que, aunque por diseño los UAVs podrían tener la capacidad de seguir este tipo de trayectorias, en la práctica no realizan cambios simultáneos de más de una de estas magnitudes. En cualquier caso, se considera que explorar esta posibilidad en las codificaciones de soluciones del GA y en el análisis de resultados presentado en el capítulo 5 resulta igualmente interesante ya que puede poner de manifiesto las ventajas que los cambios simultáneos de varias variables de control pueden ofrecer a la resolución del problema MTS.

Un ejemplo relativamente intuitivo de este tipo de situaciones sería el que se muestra en la Ilustración 18, en la que se considera que un UAV vuela a velocidad máxima y altura ideales en paralelo a una NFZ alargada, existiendo un punto de alta probabilidad de presencia del objetivo al final de la NFZ. En este caso ideal, la mejor secuencia de señales de control para el UAV consiste en mantener la velocidad máxima hasta acercarse al final de la NFZ, decelerando bruscamente al llegar al final mientras simultáneamente se realiza el giro necesario para alcanzar el punto de máxima probabilidad.

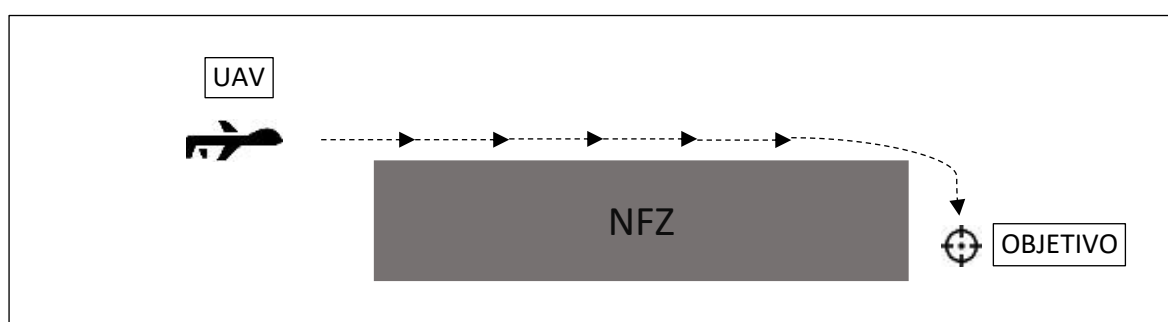


Ilustración 18 - Ejemplo esquemático de punto de máxima probabilidad de presencia del objetivo tras una NFZ

El hecho de permitir la modificación simultánea de varias variables de control del UAV debe resolverse mediante una codificación de las soluciones diferente a las ya propuestas. En las Codificaciones 1 y 2 se propone emplear diferentes partes del número real que corresponde a un

gen para representar diferentes conceptos (la parte entera representa la variable a modificar y la parte fraccionaria la magnitud de modificación). En este caso se propone aplicar el mismo principio, empleando diferentes partes del número real que corresponde a un gen para representar la variación de una variable de control del UAV diferente.

Empleando este método, se propone una codificación en la que el genoma de los individuos se componga de una cadena de números reales (genes) en el rango [0,1], de forma que los primeros n dígitos decimales de mayor orden del número real representen el porcentaje de variación de la variable de control dirección θ , los siguientes n dígitos decimales del número real representen el porcentaje de variación de la variable de control altura h y, por último, los siguientes n dígitos decimales del número real representen el porcentaje de variación de la variable de control velocidad v . El parámetro n puede variarse para obtener una partición más o menos precisa del rango posible de variación de cada una de las tres variables de control del UAV, cuanto mayor sea el valor de n más precisas podrán ser las variaciones de cada una de las variables de control. El cálculo de la variación de las señales de control se realizaría, formalmente, mediante la Expresión (17).

$$\begin{aligned} \Delta\theta(x) &= \min\theta + ((\text{ent}(x \cdot 10^n))/10^n) \cdot (\max\theta - \min\theta) \\ \Delta h(x) &= \min H + (\text{ent}(\text{fracc}(x \cdot 10^n) \cdot 10^n)/10^n) \cdot (\max H - \min H) \\ \Delta v(x) &= \min V + (\text{ent}(\text{fracc}(x \cdot 10^{2n}) \cdot 10^n)/10^n) \cdot (\max V - \min V) \end{aligned} \quad (17)$$

En la Ilustración 19 se muestra un ejemplo de individuo bajo este tipo de codificación, en la que se ha optado por establecer el valor de 3 para el parámetro n , es decir, representar la magnitud de la variación de cada una de las tres variables de control del UAV mediante 3 dígitos decimales.

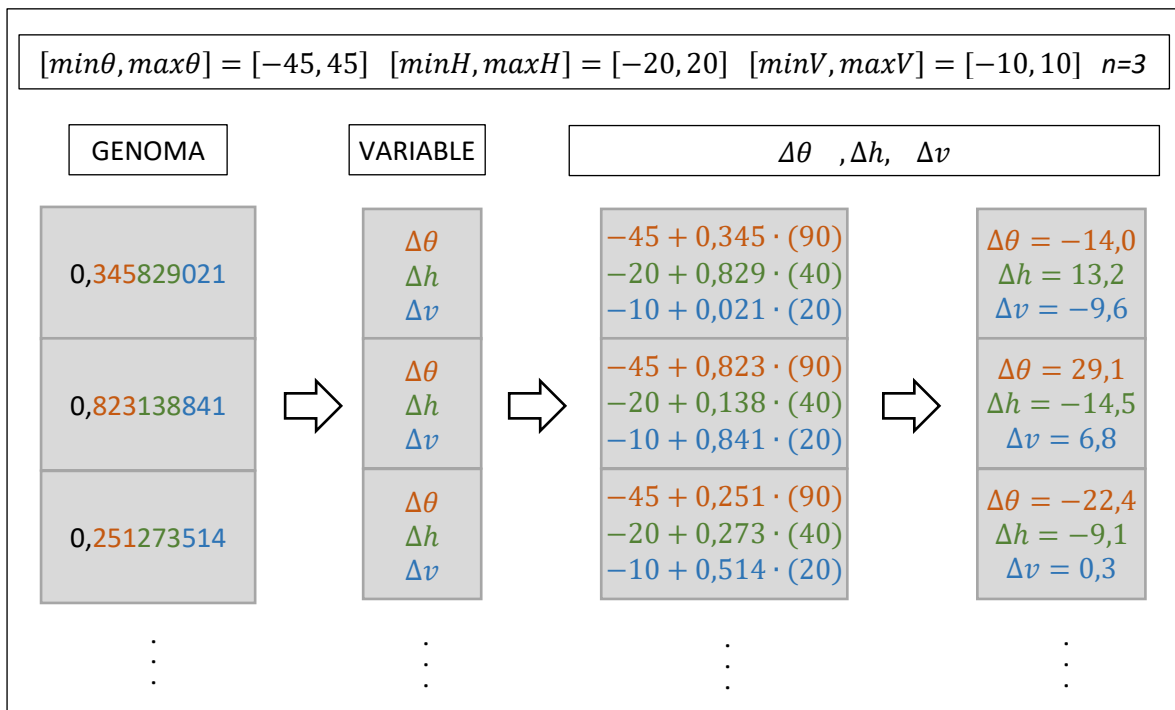


Ilustración 19 - Ejemplo de genoma empleando la Codificación 4

El objetivo de esta Codificación 4 consiste, pues, en obtener soluciones que generen trayectorias más variadas aún que en los casos anteriores, permitiendo una modificación de las tres

variables de control de forma simultánea. Nuevamente se entiende que, en un espacio de soluciones posibles más variado, el GA puede encontrar soluciones mejores.

4.1.4 Codificación 5 (variaciones de combinaciones de dirección, velocidad y altura simultáneas)

La reflexión sobre los conceptos que motivan la Codificación 3 (permitir en algunos instantes de la trayectoria que se mantenga inalterado el vuelo de los UAVs, no modificando ninguna variable de control) y la Codificación 4 (permitir variaciones simultáneas de las tres variables de control) lleva a la cuestión de que tal vez sea interesante proponer otra codificación de soluciones que combine ambas posibilidades, es decir, que permita que en cada instante de la trayectoria se modifique una cierta combinación de las variables de control (por ejemplo, que en un punto de la trayectoria pueda modificarse la dirección θ y la altura h , en otro punto la velocidad v y la altura h , en otro punto solo la velocidad v , ...).

Nótese que, al proponerse nuevamente una codificación que permite variación simultánea de más de una variable de control de los UAVs, se aplica lo ya expuesto en el apartado 4.1.3 acerca de que al tipo de UAVs modelados mediante el modelo cinemático del apartado 2.4 no se le permite en la práctica realizar este tipo de maniobras. Al igual que la Codificación 4, la nueva codificación propuesta en este apartado se estudia solo desde el punto de vista teórico, considerándose que resulta igualmente interesante en el ámbito de este Trabajo de Fin de Máster.

Esta nueva codificación debe permitir, por un lado, especificar qué variables se modifican y, por otro, en qué magnitud lo hacen. Una vez más, se opta por emplear diferentes partes del número real en el que se codifica un gen para representar diferentes conceptos. En la Codificación 4 se emplean una serie de dígitos de la parte fraccionaria del número real para representar cada una de las magnitudes de variación de las variables de control, pero en realidad no se emplea la parte entera del número real para representar nada, de ahí que el intervalo empleado sea el [0,1). En la Codificación 5 se emplea, entonces, la parte entera del número real para indicar qué variables se modifican, mientras que la parte fraccionaria se emplea para indicar la magnitud de las variaciones, empleando un número determinado de dígitos de la parte fraccionaria para cada una de las variables que se modifican, como se hace en la Codificación 4.

La Codificación 5 se propone entonces como una secuencia de números reales pertenecientes al intervalo [0,8), de forma que la parte entera del número indica la combinación de variables de control que se modifican siguiendo el criterio que se muestra en la Tabla 1. Los primeros n dígitos decimales de mayor orden del número real representan el porcentaje de variación de la primera variable de control modificada (de haberla) siguiendo el orden de variables indicado en la Tabla 1, los siguientes n dígitos decimales del número real el de la segunda (de haberla), y los siguientes n dígitos decimales del número real el de la tercera (de haberla). La Ilustración 20 muestra un ejemplo de solución codificada de esta forma.

Parte Entera del gen	Variables modificadas	Dígitos fraccionarios empleados ($n=4$)
0	θ	0,dddddddddddddd...
1	h	1,dddddddddddddd...
2	v	2,dddddddddddddd...

3	θ, h	3, d d d d d d d d d d d d d d d d...
4	θ, v	4, d d d d d d d d d d d d d d d d...
5	h, v	5, d d d d d d d d d d d d d d d d...
6	θ, h, v	6, d d d d d d d d d d d d d d d d...
7	-	7, d d d d d d d d d d d d d d d d...

Tabla 1 - Codificación de las variables de control modificadas en la Codificación 5

No se incluye la expresión matemática completa del cálculo del incremento de las variables de control en función del valor del gen por su aparatosidad. Se trata de una expresión similar a la Expresión (17), pero particularizando el cálculo de las variaciones a cada uno de los casos expuestos en la Tabla 1. La Expresión (17) refleja de manera precisa, concretamente, el caso de la Tabla 1 en el que la parte entera del número real es 6.

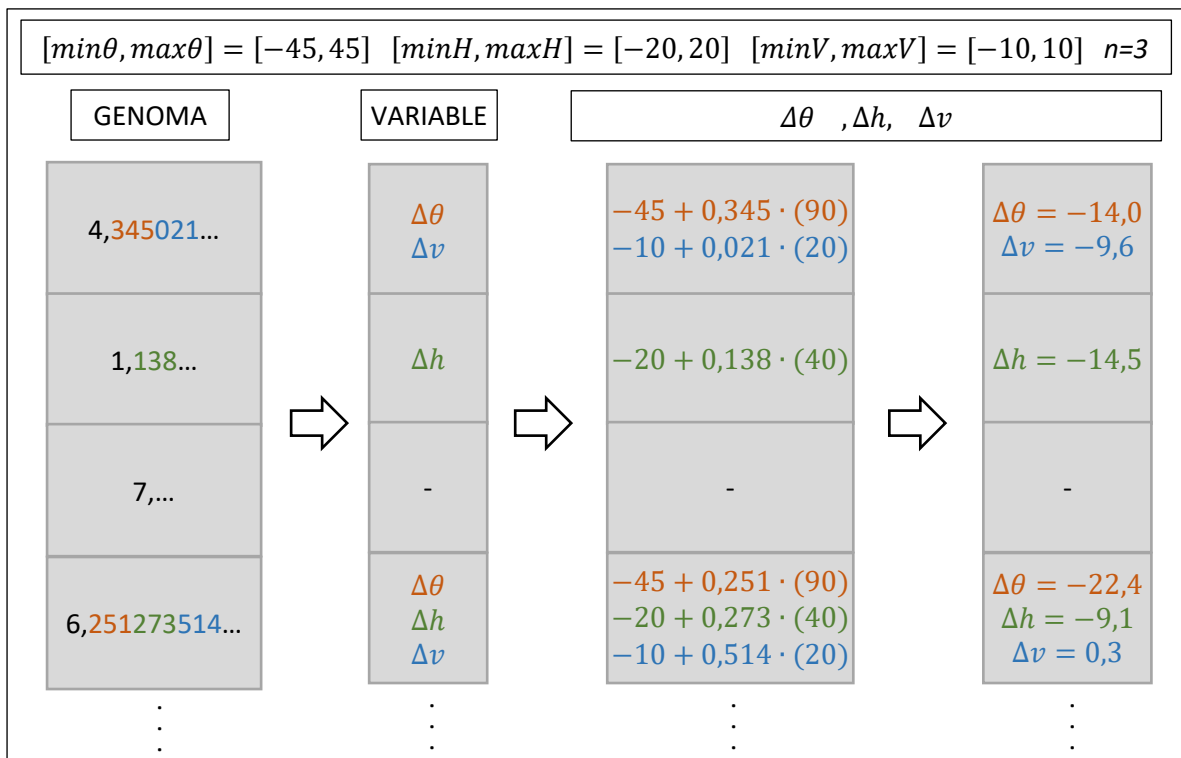


Ilustración 20 - Ejemplo de genoma empleando la Codificación 5

La finalidad de esta codificación es, avanzando en la línea de las Codificaciones 3 y 4, ampliar el espacio de búsqueda de soluciones del GA para obtener soluciones que puedan resolver simultáneamente de forma satisfactoria casos como los descritos en los apartados 4.1.3 y 4.1.4.

4.1.5 Codificación 6 (variaciones de dirección, velocidad o altura en subsecuencias)

El conocimiento específico derivado del dominio del problema puede permitir diseñar algunos aspectos del GA adaptados de forma concreta al tipo de problema en cuestión. Una faceta del problema MTS que se puede emplear en este sentido es el hecho de que se conoce que las soluciones consisten en secuencias de señales de control para gobernar una trayectoria, y que además dicha trayectoria está sujeta a las limitaciones típicas de un UAV que vuela de la misma

forma en la que lo hace un avión tradicional, es decir, sujeto a algunas restricciones en función de su modelo cinemático.

La principal restricción de este tipo de vuelo consiste en la limitación a la rapidez con la que el UAV puede modificar cada uno de los tres parámetros que rigen su manejo, lo cual a su vez impide variaciones bruscas de la trayectoria. Este hecho lleva a pensar que, en muchos de los posibles casos a abordar, las trayectorias óptimas deberían ser poco erráticas, es decir, consistir en secuencias de variaciones de las tres variables de control del UAV que se subdividan a su vez, en subsecuencias más o menos largas de variación de una única variable de control (dirección, altura o velocidad) del UAV, de forma que en cada una de dichas subsecuencias solo se ajuste una variable de control concreta.

Por ejemplo, en algunas ocasiones, la trayectoria óptima del UAV se obtiene ajustando primero su velocidad mediante una subsecuencia de varias correcciones a la misma hasta que se alcanza una velocidad de giro adecuada, después ajustando el giro mediante otra subsecuencia de varias correcciones al mismo hasta que se alcanza una curva adecuada para pasar por encima de la zona de probabilidad de ocurrencia del objetivo pero quedando encarado hacia la siguiente zona, seguida de otra subsecuencia de cambios en la velocidad para acelerar el UAV, etc.

La idea detrás de la Codificación 6 se resume, pues, en generar una representación de las soluciones que, apoyada en operadores específicos si hace falta, favorezca que el GA explore soluciones compuestas de subsecuencias más o menos largas de variaciones de la misma variable de control.

La Codificación 6 propuesta consiste, entonces, en un genoma formado por una secuencia de números reales en la que cada gen es un número real en el intervalo $[0,4)$, de forma que la parte entera del número real indica si se modifica una variable de control del UAV nueva o se sigue modificando la misma variable que hasta entonces, mientras que la parte fraccionaria indica, como en las codificaciones anteriores, el porcentaje de variación de la variable en cuestión sobre el rango máximo posible de variación de dicha variable. Un valor de 0 en la parte entera indica que la modificación se aplica a la misma variable de control que se estuviera modificando en el gen anterior, cualquiera que fuese, mientras que los valores de 1, 2 o 3 en la parte entera indican que se pasa a modificar una nueva variable de control, dirección θ , altura h o velocidad v respectivamente. Se puede ver en la Ilustración 21 un ejemplo de solución que emplea esta codificación.

Dada esta codificación, no todas las secuencias de números reales en el rango $[0,4)$ representan individuos de forma consistente. Concretamente, solo resultan secuencias consistentes aquellas secuencias en las que:

1. El primer número real de la secuencia pertenece al intervalo $[1,4)$ ya que, si la parte entera de este primer número fuese 0, quedaría indefinida la variable de control que se está modificando al principio del individuo.
2. No existen dos números reales consecutivos en la secuencia (obviando aquellos cuya parte entera sea 0) cuya parte entera sea para ambos 1, 2, o 3.

Por ello, es importante que los operadores del GA que generan nuevos individuos (inicialización, cruce) o que los alteran (mutación) tengan en cuenta las especificidades de esta codificación para que los individuos nuevos o alterados sean consistentes con ella. Conviene además que, en la ejecución del GA, a lo largo de las generaciones, los individuos mantengan en general una cierta cantidad y longitud de subsecuencias de cambios de una determinada variable de control o, dicho de otra forma, que no se produzca excesiva fragmentación o aglomeración de subsecuencias en los nuevos individuos, ya que esto iría en contra de lo que se desea obtener con este tipo de codificación. En el apartado 4.2 se presentan los operadores de las diferentes versiones del GA Multi-etapa y se especifican las decisiones que se han tomado en el desarrollo de los operadores de la Codificación 6 para garantizar que esto se cumple.

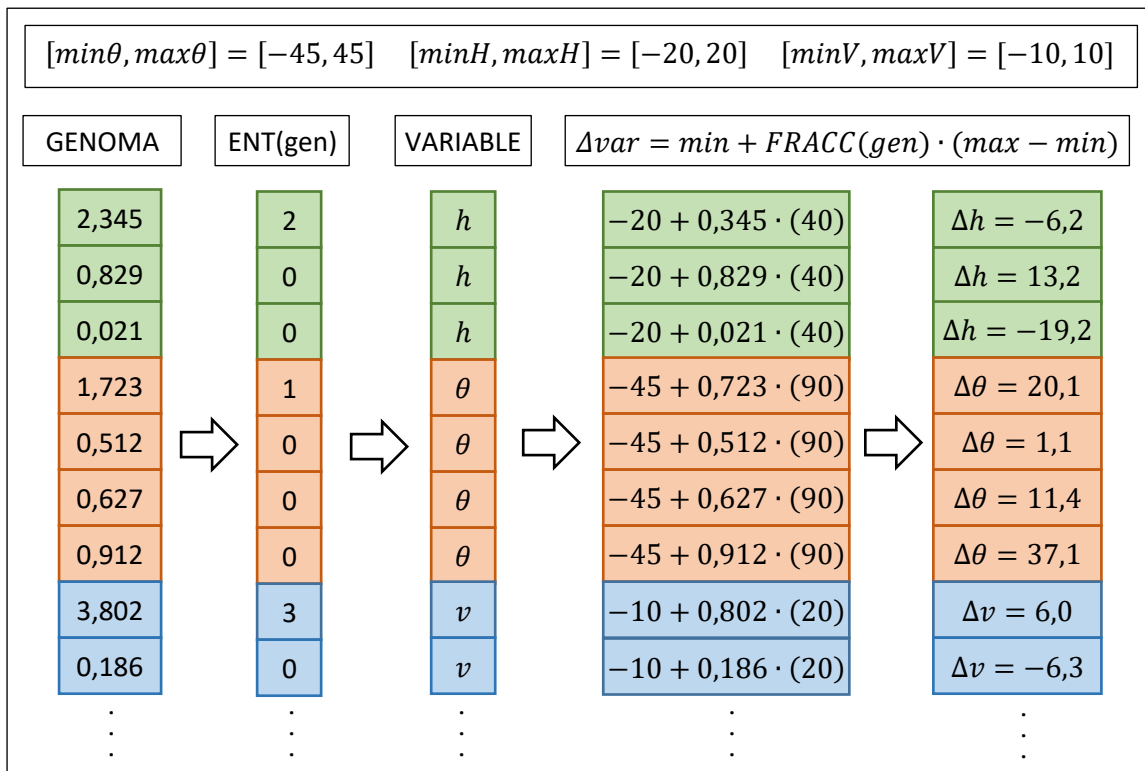


Ilustración 21 - Ejemplo de genoma empleando la Codificación 6

El objetivo de la Codificación 6 propuesta consiste, entonces, en orientar la búsqueda del GA dentro del espacio de soluciones del algoritmo hacia aquellas soluciones compuestas de varias subsecuencias más o menos largas de variaciones de la misma variable de control, ya que se considera que este tipo de soluciones pueden presentar mejores valores para los criterios de optimización del algoritmo que las soluciones de tipo más errático, en las que se modifican variables de control dispares continuamente.

4.1.6 Referencia de codificaciones

Se incluye en este apartado a modo de referencia y a la vez resumen la Tabla 2, en la que se indican las características tanto de la Codificación 1 (codificación original) como de las Codificaciones 2 a 6 presentadas en los apartados anteriores.

Se indica en la tabla, para cada codificación, las variaciones de las variables de control de los UAVs que pueden producirse en un instante determinado de la trayectoria, es decir, aquellas que están codificadas en un único gen. Se incluye también el significado de la parte entera y de la parte fraccionaria del valor contenido en cada gen empleando la codificación en cuestión.

Cod.	Descripción de variación en un instante	Variación en un instante	Parte entera del valor del gen	Parte fraccionaria del valor del gen
1	<i>Solo dirección</i>	$\Delta\theta$	<i>Magnitud de la variación (absoluta)</i>	
2	<i>Dirección, velocidad o altura</i>	$\Delta\theta \Delta v \Delta h$	<i>Variable de control que varía</i>	<i>Magnitud de la variación (%)</i>
3	<i>Dirección, velocidad, altura o ninguna</i>	$\Delta\theta \Delta v \Delta h \emptyset$	<i>Variable de control que varía</i>	<i>Magnitud de la variación (%)</i>
4	<i>Dirección, velocidad y altura</i>	$\Delta\theta, \Delta v, \Delta h$	-	<i>Magnitud de las variaciones (%)</i>
5	<i>Combinación de dirección, velocidad y altura</i>	$\Delta\theta, \Delta v, \Delta h $ $\Delta\theta, \Delta v $ $\Delta\theta, \Delta h $ $\Delta v, \Delta h $ $\Delta\theta $ $\Delta v $ $\Delta h $ \emptyset	<i>Combinación de variables de control que varían</i>	<i>Magnitud de las variaciones (%)</i>
6	<i>Dirección, velocidad, altura o variable anterior</i>	$\Delta\theta \Delta v \Delta h \Delta var_{ant}$	<i>Variable de control que varía</i>	<i>Magnitud de la variación (%)</i>

Tabla 2 - Referencia de codificaciones de soluciones del GA

4.2 Desarrollo del GA Multi-etapa para trayectorias de dirección, velocidad y altura variables

La transformación del GA Multi-etapa original de [21] en un GA Multi-etapa que permita trayectorias de los UAVs en las que se pueda variar dirección, velocidad y altura requiere una serie de modificaciones en los operadores del GA para adaptarlo a estas necesidades ampliadas, modificaciones que se describen en los sucesivos subapartados de este apartado 4.2.

Las diferentes codificaciones propuestas de las soluciones al problema, además de la necesidad de respetar el funcionamiento de la Codificación 1 ya existente de soluciones con solo variaciones de dirección, hacen que la modificación de cada operador del GA tenga que tener en cuenta casos diversos. Este objetivo de implementar seis algoritmos en un solo sistema (cinco

nuevas codificaciones de soluciones además de la codificación original) es posible tan solo gracias al buen diseño y gran modularidad de la implementación original del GA Multi-etapa propuesto en [21].

Las modificaciones aquí comentadas conciernen a operadores del GA descritos en el capítulo 3 y, en algún caso, al modelado de elementos del problema descritos en el capítulo 2, sin afectar de forma significativa a la estructura del propio GA Multi-etapa, al estar éste situado en una capa superior al GA subyacente.

4.2.1 Modelo cinemático de los UAVs

La implementación en *Simulink* del modelo cinemático descrito en el apartado 2.4 y cuya estructura interna puede apreciarse en la Ilustración 6, en su versión inicial, ya estaba preparada para un tratamiento realista de las señales de control de la velocidad y altura del UAV (además de la dirección) y de su efecto en las variables de salida del modelo (dirección, velocidad y altura reales, trayectoria, consumo de combustible).

Sin embargo, los módulos de entrada del modelo estaban preparados solamente para recibir un valor único de velocidad y de altura deseados. Para la implementación del GA Multi-etapa se modifican dichos módulos para que acepten un vector de velocidades y un vector de alturas de longitud variable. Esto permite emplear el modelo cinemático para las versiones del GA que se basan en las nuevas Codificaciones 2 a 6, las cuales producen secuencias de señales de control de altura h y velocidad v , además de dirección θ , permitiendo a la vez compatibilidad con la versión original del GA que se basa en la Codificación 1, caso en el cual se invoca a la nueva versión del modelo pasando como parámetros, además de las señales de control de dirección θ , vectores de señales de control de alturas h y velocidades v con valores constantes a lo largo del vector.

4.2.2 Criterios de evaluación de soluciones

Los criterios de evaluación de las soluciones del GA no se ven afectados en general en la implementación del GA Multi-etapa basado en las nuevas codificaciones de las soluciones, con la excepción del criterio SMOOTH cuya definición está fuertemente relacionada con la codificación original de soluciones del problema (Codificación 1).

El criterio SMOOTH, cuya definición se puede ver en el apartado 2.5.4, tiene como objetivo en la versión original del GA basado en la Codificación 1 penalizar aquellas variaciones de la variable de control dirección θ que sean consecutivas y de signo opuesto, en función del cuadrado de su diferencia. Cuanto mayor sea esta diferencia, mayor valor toma el criterio SMOOTH (recuérdese que es un criterio a minimizar, como todos los del problema) y más se penaliza por tanto la solución por considerarse una trayectoria errática.

Esta idea no puede aplicarse de forma directa a las nuevas Codificaciones 2 a 6, sencillamente porque ya que no se componen únicamente de variaciones de dirección θ . Se puede plantear un criterio SMOOTH modificado estudiando cada caso particular de codificación de las soluciones:

- Codificaciones 2, 3 y 6: al no modificarse necesariamente la misma variable (dirección, altura, velocidad) en cada pareja de genes consecutivos, en muchos casos no hay forma directa de juzgar si la combinación de dos variaciones consecutivas puede ser errática.
- Codificaciones 4 y 5: se podría aplicar un criterio SMOOTH independiente para cada una de las tres variables de control (como ya se define en el apartado 2.5.4), ya que en estas codificaciones es factible que en cada instante (en cada gen) se modifiquen las tres variables.

Al no ser SMOOTH un criterio de los más relevantes para el problema MTS, se ha optado por neutralizarlo en la versión del GA basada en las nuevas Codificaciones 2 a 6. Se ha tenido en cuenta además que, para las Codificaciones 4 y 5 en las que se podrían emplear tres criterios SMOOTH independientes (uno para cada variable de control de los UAVs), esto podría llegar a ser contraproducente por complicar la relación de dominación entre soluciones. Cuanto más crece el número de criterios a evaluar, aumentan las posibilidades de que soluciones con buenos valores en los criterios más importantes (ET, MYOP, #COL, #NFZ) no puedan dominar a otras con peores valores en dichos criterios, pero con mejores valores en los criterios secundarios (SMOOTH, FUEL).

4.2.3 Inicialización

Al contemplarse en la nueva versión del GA Multi-etapa las nuevas Codificaciones 2 a 6 de las soluciones al problema MTS, cada una de ellas establece una estructura de genoma diferente para los individuos del GA. Esto conlleva una adaptación del operador de inicialización de la población, para que los individuos que genere sean consistentes con la codificación.

En la mayoría de las nuevas codificaciones, esto se limita a generar genomas formados por números reales en el rango que se define en la codificación. El único caso más complejo es el de la Codificación 6, en la que se generan individuos de una forma más dirigida, con el objetivo de generar subsecuencias de variaciones de la misma variable de control (véase definición de la Codificación 6 en el apartado 4.1.5).

La forma de implementar el operador de inicialización en función de la codificación sería la siguiente:

- Codificación 2: se genera el genoma de cada individuo como una cadena de números reales cada uno de ellos obtenido como muestra de una distribución aleatoria uniforme en el rango [0,3).
- Codificación 3: idéntica forma que la Codificación 2, pero empleando una distribución aleatoria uniforme en el rango [0,4).
- Codificación 4: idéntica forma que la Codificación 2, pero empleando una distribución aleatoria uniforme en el rango [0,1).
- Codificación 5: idéntica forma que la Codificación 2, pero empleando una distribución aleatoria uniforme en el rango [0,8).

- Codificación 6: se decide, para cada gen del individuo, si corresponde a un cambio de subsecuencia o no (véase el apartado 4.1.5) en función de una probabilidad establecida como parámetro del GA. El primer gen de cada individuo es siempre un cambio de subsecuencia. Se generan los genes que corresponden a un cambio de subsecuencia empleando una muestra de una distribución aleatoria uniforme en el rango [1,4), y los genes que no corresponden a un cambio de subsecuencia empleando una muestra de una distribución aleatoria uniforme en el rango [0,1). Resulta interesante definir un valor relativamente bajo para el parámetro de la probabilidad de que a un gen le corresponda un cambio de subsecuencia, a fin de obtener individuos con subsecuencias más bien largas, que es lo que se pretende en el diseño de esta codificación.

4.2.4 Evaluación de soluciones

En la versión original del GA Multi-etapa, empleando la Codificación 1, la evaluación de los individuos consistía en la obtención de los valores s_i^j del estado de los UAVs a lo largo de los T instantes de su trayectoria mediante el modelo cinemático descrito en el apartado 2.4, tomando para ello como entrada directamente la secuencia de variaciones de la variable dirección θ del genoma del individuo, para luego emplear los valores de dichos estados s_i^j y los modelos probabilísticos del objetivo y del sensor de los UAVs para obtener los valores de los diferentes criterios de calidad de las soluciones descritos en los apartados 2.5.1 al 2.5.5.

En el nuevo GA Multi-etapa basado en las nuevas Codificaciones 2 a 6, al no estar las variaciones de las variables de control codificadas de forma absoluta en el genoma de los individuos (como si lo estaban en la Codificación 1), se hace necesaria una transformación de los genomas de los individuos en secuencias de valores absolutos de variaciones de las variables de control, dentro del rango de variación permitido para cada una de las tres variables (dirección, altura, velocidad), para emplear dichas secuencias como entradas al modelo cinemático. En los apartados 4.1.1 al 4.1.5 se describe, junto a cada codificación, el método que se emplea para traducir el genoma de los individuos a variaciones de las variables de control de los UAVS.

Por otra parte, y como se indicó en el apartado 4.2.2, en el nuevo GA Multi-etapa no se evalúa el criterio SMOOTH para las Codificaciones 2 a 6, manteniéndose la evaluación de dicho criterio para la Codificación 1.

4.2.5 Operador de Cruce

El operador de cruce empleado en la versión original del GA Multi-etapa descrito en el apartado 3.1.4 es, por tratarse de un operador bastante genérico, válido en casi todos los casos para su aplicación en el GA Multi-etapa basado en las nuevas Codificaciones 2 a 6. Concretamente, en el caso de las Codificaciones 2 a 5, los individuos hijos que se obtienen empleando este operador (corte por un único punto del genoma e intercambio de cadenas del mismo entre los individuos padre) son siempre consistentes con la codificación en la que están basados.

Sin embargo, en el caso de la Codificación 6, en la que las variaciones de las variables de control de los UAVs se agrupan en subsecuencias de cambios de la misma variable (véase apartado 4.1.5), un operador de corte sencillo en el que el corte pueda producirse en cualquier punto del genoma podría deparar los siguientes efectos no deseables:

- Genoma inconsistente: podrían generarse individuos hijos con dos subsecuencias consecutivas en las que la variable de control modificada (definida por la parte entera del primer gen de la subsecuencia) fuera la misma, lo cual es inconsistente con la definición de la Codificación 6. Se podría incluir en el operador una unificación o fusión de las dos subsecuencias consecutivas, pero, aunque esto arreglase el problema de la inconsistencia, la repetición de esta situación con el paso de las generaciones derivaría en subsecuencias muy largas de cambios de la misma variable de control.
- Fragmentación de las subsecuencias: si el punto de corte se encuentra en medio de una subsecuencia en uno de los individuos padres, la segunda parte de dicha subsecuencia se incorpora al nuevo individuo hijo sin un primer gen que defina la variable que se modifica en dicha subsecuencia. Se podría modificar el primer gen en esta segunda parte de la subsecuencia al incorporarla al individuo hijo, pero esto produciría fragmentación de las subsecuencias a lo largo de las generaciones.
- Alteración del genoma: de producirse lo indicado en el punto anterior, pero decidiéndose no modificar el primer gen de la segunda parte de la subsecuencia al incorporarla al individuo hijo, esta segunda parte de la subsecuencia mantendría la magnitud de las variaciones, pero en realidad la variable (dirección, velocidad, altura) modificada dependería de la parte anterior del genoma al que se incorporase pudiendo producirse una situación tal que, por ejemplo, una variación de altura en un padre pase a ser una variación de la misma magnitud, pero de velocidad en lugar de altura, en el individuo hijo, lo cual altera el significado del genoma, algo más propio del operador de mutación que del de cruce.

Por estos posibles problemas, se decide implementar un operador de cruce que, en el caso de la Codificación 6, compruebe si el punto de corte generado de forma aleatoria produce alguno de los problemas mencionados arriba en los individuos hijos. En ese caso, se selecciona otro punto de corte diferente. Este proceso continúa hasta que se encuentra un punto de corte válido para la pareja de padres o se agotan los posibles puntos de corte, caso en el que se concluye que el cruce no es posible y se toman a los dos individuos padres como resultado del cruce sin alterar su genoma.

4.2.6 Operador de Mutación

El operador de mutación descrito en el apartado 3.1.5, empleado en la versión original del GA Multi-etapa basado en la Codificación 1, no es en general aplicable a ninguna de las Codificaciones 2 a 6 propuestas en este capítulo 4 para el GA Multi-etapa con variación de dirección, velocidad y altura en las trayectorias.

Este operador de mutación original tiene carácter incremental, ya que mediante su empleo los elementos del genoma de los individuos mutados se ven ligeramente incrementados o decrementados empleando valores obtenidos a partir de dos variables aleatorias, ambas basadas en distribuciones gaussianas de media nula, pero la segunda con una desviación típica más grande que la primera. La finalidad de este tipo de mutación consiste en modificar los genes del individuo

mutado, pero de forma que los valores de los genes mutados se encuentren relativamente cerca de los valores originales.

El problema en la aplicación de este operador a individuos cuyo genoma se haya generado empleando las Codificaciones 2 a 6 consiste en que, en todas estas codificaciones, los números reales correspondientes a los genes de los individuos no representan valores absolutos de variación de las variables de control de los UAVs. Además, algunas partes del número real que representa a un gen no se emplean con un significado cuantitativo, sino cualitativo, como por ejemplo la parte entera del gen, que en casi todas las codificaciones indica la variable de control a la que se aplica la modificación. Por ello, un operador incremental puede tener efectos inesperados, variando por completo el significado de un gen o incluso corrompiéndolo, llevando su valor más allá de los límites permitidos por la codificación en la que está basado.

Por ejemplo, un gen de un individuo representado mediante la Codificación 2 (véase apartado 4.1.1) que tuviese el valor 2,95 (valor que en dicha codificación representa una variación porcentual de 0,95 sobre los límites definidos para la variable velocidad v) y que al mutar recibiese un incremento de 0,2 resultaría en un gen de valor 3,15 que resulta inconsistente con la definición de la Codificación 2.

Por ello, para el desarrollo del GA Multi-etapa basado en las Codificaciones 2 a 6, se opta por implementar nuevos operadores de mutación adaptados a las especificidades de cada codificación:

- Codificaciones 2 a 5: para todas estas codificaciones, en las que los genes tienen establecidos unos rangos de posibles valores muy reducidos, se implementa un operador de mutación absoluto, que en función de una probabilidad relativamente baja (parametrizable) modifica el gen asignándole un nuevo valor obtenido por distribución aleatoria uniforme dentro del intervalo posible de valores que marca la codificación, descartándose por completo el valor original del gen sin que tenga influencia en el nuevo valor mutado del mismo. Por ejemplo, en la Codificación 2, en la que el valor de los genes está en el intervalo $[0,3)$, la mutación de un gen consiste en la generación de un nuevo valor mediante la distribución aleatoria uniforme en dicho intervalo $[0,3)$. En todas estas codificaciones la mutación de un gen puede equivaler a que cambie la variable/s de control que se modifican en el instante de la trayectoria correspondiente al gen, a que cambie la magnitud/es en las que se modifican dichas variables de control en dicho instante, o a ambas cosas simultáneamente, dependiendo de la diferencia entre los valores original y mutado del gen en cuestión.
- Codificación 6: para esta última codificación, caracterizada porque el genoma de los individuos se divide en subsecuencias de variaciones de una misma variable de control de los UAVs, se implementa un operador de mutación que actúa a dos niveles en función de dos probabilidades parametrizables por separado. Por una parte, el operador puede mutar la parte fraccionaria del valor de un único gen (es decir, modificar la magnitud de la variación, pero no la variable de control del UAV indicada por el gen), mientras que por otra el operador puede mutar una subsecuencia entera de genes, asignando nuevos valores aleatorios de entre el

rango permitido por la codificación a todos los genes de la subsecuencia (es decir, modificar la variable de control del UAV a la que se aplica la subsecuencia, y la magnitud de la variación de dicha variable en todos los genes de la subsecuencia). En este tipo de mutación es deseable que la probabilidad de la mutación de secuencias completas de genes sea inferior a la probabilidad de mutación individual de genes.

5 Resultados

Se incluyen en este capítulo la presentación de los escenarios diseñados y los resultados obtenidos en la realización de pruebas tanto de la versión original del GA Multi-etapa para trayectorias de dirección variable presentado en el capítulo 3 como de las diferentes versiones del GA Multi-etapa para trayectorias de dirección, altura y velocidad variables basadas en las codificaciones de soluciones propuestas en el capítulo 4.

Inicialmente, se presenta un escenario complejo y se muestra gráficamente el resultado de la resolución de dicho escenario mediante las diferentes versiones del GA Multi-etapa, así como las variaciones de las variables de control de los UAVs generadas por cada versión del algoritmo, con la doble finalidad de comprobar que las señales de control generadas son válidas y, además, que el tipo de trayectorias coinciden con lo esperado para cada una de las codificaciones diseñadas.

A continuación, se muestra el análisis de resultados obtenidos en una serie de pruebas de carácter cuantitativo, cada una de ellas realizada sobre un escenario diferente, consistentes en la ejecución de cada uno de los algoritmos un total de 20 veces sobre dicho escenario. Se expone para cada prueba la matriz de comparación entre algoritmos, que indica cuales de las versiones del GA Multi-etapa diseñado devuelven de forma consistente soluciones mejores que otros.

5.1 Pruebas cualitativas

Se presentan en este apartado los resultados obtenidos mediante el empleo de cada una de las versiones del GA Multi-etapa para la resolución del escenario mostrado en la Ilustración 22, que presenta un problema complejo con varias zonas dispersas de alta probabilidad de presencia del objetivo de diversa morfología (zonas circulares puntuales con mayor probabilidad en el centro, zonas lineales con mayor probabilidad en el centro, zonas circulares amplias con idéntica probabilidad en toda la zona). Por otra parte, presenta un alto número de NFZs que dificultan el acceso a las zonas de posible presencia del objetivo, con el fin de poner a prueba las capacidades de las diferentes versiones del GA Multi-etapa. La posición y orientación de partida del único UAV del escenario se indica con una flecha gris.




Ilustración 22 - Escenario con diferentes tipos de zonas de alta probabilidad de presencia del objetivo y varias NFZs

Para este escenario se parametriza el algoritmo de forma que la trayectoria del UAV debe constar de un total de 42 acciones de control, es decir, $T = 42$, siendo T el número de instantes a lo largo de la trayectoria del UAV en los que se pueden variar las señales de control del mismo. Como se indica en el apartado 3.2, el GA Multi-etapa resuelve el problema MTS descomponiéndolo en varios subproblemas similares, pero de un horizonte temporal menor. Por lo tanto, en este escenario, se parametriza el algoritmo para que el número de subproblemas o etapas S sea de 3, por lo que la longitud L de la secuencia de acciones de control de cada subproblema es de 14, ya que $L = T/S = 42/3 = 14$. Por otra parte, se establece que el intervalo de tiempo transcurrido entre dos lecturas consecutivas del sensor con el que está equipado el UAV (8 segundos) es el mismo que entre dos acciones de control consecutivas, luego $N = T = 42$, es decir, se realizan 42 lecturas del sensor en total, 14 de ellas en cada una de las 3 etapas.

Las dimensiones del escenario se definen en base a la rejilla G sobre la que se define a su vez el modelo probabilístico del objetivo (véase apartado 2.2). En este escenario, se establece una rejilla G de 30x30 celdas, siendo cada una de ellas un cuadrado de 200 metros de lado. Por ello, el área de búsqueda queda definida como un cuadrado de 6000 metros de lado.

En lo relativo a la parametrización del GA, se decide que la población de soluciones en cada generación sea de 50 individuos, y que el criterio de parada del GA sea de 60 generaciones o 60 segundos de cómputo. Esto quiere decir que el GA se detendrá (en cada una de las 3 etapas) cuando se alcance la primera de estas dos condiciones, sea la que sea.

La Tabla 3, mostrada a continuación, contiene un resumen de los diferentes valores de los parámetros generales del escenario y del GA Multi-etapa ya mencionados, además de algunos otros relativos a los operadores del GA subyacente, como por ejemplo probabilidades de los diferentes tipos de mutación, rangos de variación de las variables de control, etc., referenciándose para cada uno de ellos las codificaciones a las que se aplica.

GA Multi-etapa			Escenario	
Parámetro	Valor		Parámetro	Valor
T (instantes totales)	42		Tamaño G (celdas)	30x30
S (etapas)	3		Tamaño celda (m)	200
L (instantes/etapa)	14		Δt modelo cinemático (s)	1
GA			Nº de UAVs	1
Parámetro	Valor	Codificaciones	UAV 1	
Tamaño de la población	50	1, 2, 3, 4, 5, 6	Dirección inicial	180
Máximo generaciones	60	1, 2, 3, 4, 5, 6	Altura Inicial	1000
Máximo tiempo (s)	60	1, 2, 3, 4, 5, 6	Velocidad Inicial	70
Porcentaje individuos que no se cruzan	0,2	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(3600, 200)
Desviación estándar mutación incremental 1	0,5	1	Δt entre señales control (s)	8
Desviación estándar mutación incremental 2	0,1	1	Δt entre lecturas sensor (s)	8
Probabilidad mutación	0,2	2, 3, 4, 5		

Probabilidad de nueva subsecuencia por gen en inicialización	0,2	6		
Probabilidad mutación de un gen	0,2	6		
Probabilidad de mutación de una subsecuencia	0,04	6		
Rango $\Delta\theta$ (min θ , max θ)	(-180, 180)	1, 2, 3, 4, 5, 6		
Rango Δh (minH, maxH)	(-30, 30)	2, 3, 4, 5, 6		
Rango Δv (minV, maxV)	(-5, 5)	2, 3, 4, 5, 6		
Dígitos fraccionarios por variable de control	6	4, 5		

Tabla 3 - Parametrización del GA Multi-etapa y del escenario para las pruebas cualitativas

En los siguientes apartados se muestra para cada una de las versiones del algoritmo basadas en las Codificaciones 1 a 6 una trayectoria obtenida como resultado de la ejecución de dicha versión para el escenario descrito. Se incluye, primeramente, la representación gráfica de la trayectoria seguida por el UAV en cada una de las 3 etapas en las que el GA Multi-etapa divide el problema inicial y, a continuación, en forma de tabla, la secuencia de señales de control generada en cada una de las 3 etapas resaltándose en un color diferente cada una de las variables de control del UAV.

No se tiene en cuenta en estas pruebas el resultado en sí mismo, es decir, el valor de ET de la mejor solución devuelta por el GA Multi-etapa, ya que la obtención de un mejor resultado en una prueba aislada no garantiza que un algoritmo sea en general mejor que otro. Dicho estudio se realiza en el apartado 5.2 en el que se ejecutan un mayor número de pruebas y se emplea un método estadístico para dilucidar si algún algoritmo es mejor que los otros.

5.1.1 Codificación 1

La Ilustración 23 muestra la trayectoria obtenida en la resolución del problema empleando la versión original del GA Multi-etapa basada en la Codificación 1, en la que solo se permite a los UAVs modificar su dirección θ , siendo la altura h y la velocidad v constantes en todo momento. Se aprecia en la Ilustración que, como es de esperar, la trayectoria es bastante sinuosa, lo cual en algunas situaciones seguramente no es la mejor opción, como por ejemplo al final de la etapa 2 y principio de la etapa 3, o al final de la etapa 3, momentos en los que sería mejor seguir una trayectoria recta hasta la siguiente zona de alta probabilidad de presencia del objetivo.

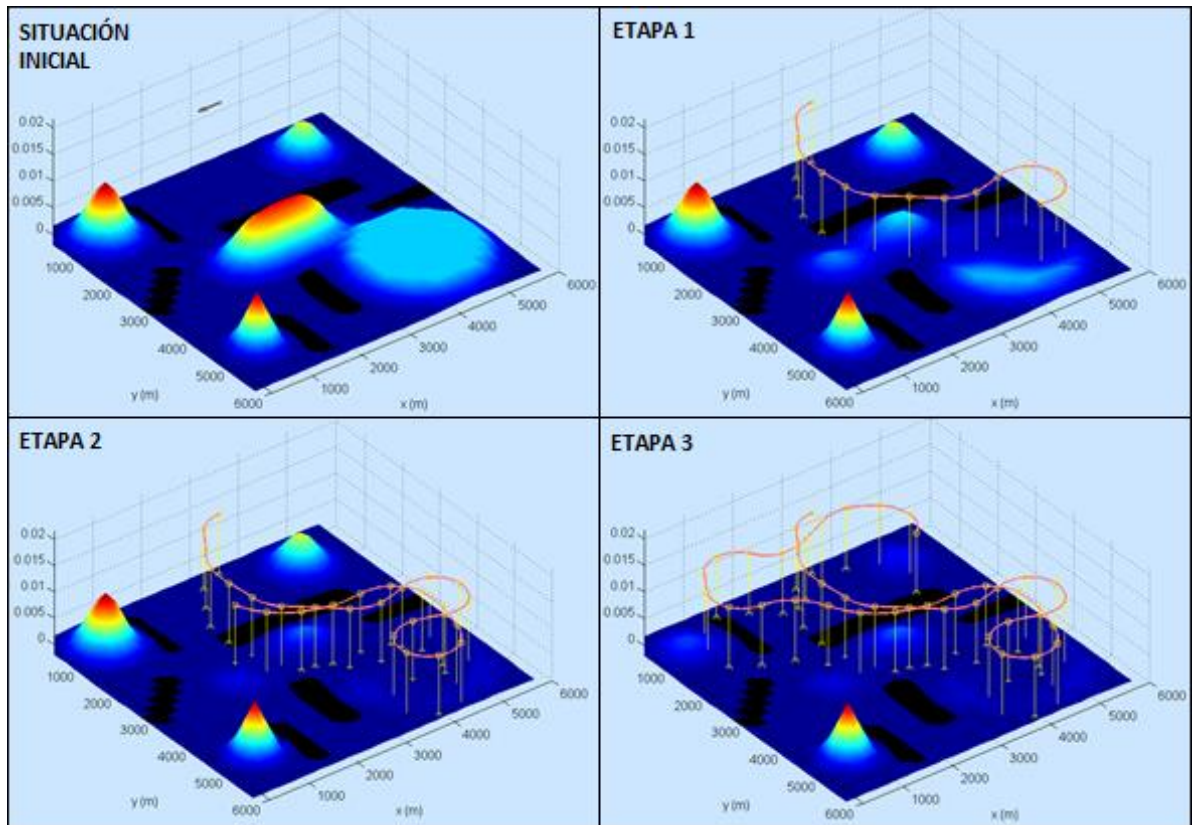


Ilustración 23 - Trayectoria empleando la Codificación 1

Como se puede ver en la Tabla 4, en todos los 14 instantes de las 3 etapas varía la dirección θ del UAV y se mantienen constantes la altura h y velocidad v en los valores de la situación inicial del UAV, ya que no se produce ninguna variación en las mismas.

	ETAPA 1			ETAPA 2			ETAPA 3		
	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv
1	-52	-	-	-10	-	-	-25	-	-
2	0	-	-	-57	-	-	-35	-	-
3	-22	-	-	-57	-	-	53	-	-
4	-20	-	-	-58	-	-	57	-	-
5	1	-	-	-57	-	-	6	-	-
6	-43	-	-	-25	-	-	52	-	-
7	-2	-	-	-7	-	-	57	-	-
8	-2	-	-	-20	-	-	-45	-	-
9	-45	-	-	-46	-	-	-33	-	-
10	-13	-	-	-39	-	-	-1	-	-
11	46	-	-	15	-	-	35	-	-
12	58	-	-	14	-	-	31	-	-
13	57	-	-	24	-	-	46	-	-
14	96	-	-	18	-	-	58	-	-

Tabla 4 - Señales de control del UAV empleando la Codificación 1

5.1.2 Codificación 2

La trayectoria obtenida mediante el empleo de la versión del GA Multi-etapa basado en la Codificación 2, primera de las codificaciones diseñadas en este Trabajo de Fin de Máster, puede verse en la Ilustración 24. Al permitir esta codificación la variación de las tres variables de control del UAV (dirección θ , altura h , velocidad v), se aprecia como en algunos momentos de la trayectoria, especialmente en las etapas 1 y 2, el UAV establece un rumbo hacia la siguiente zona de alta probabilidad más interesante y posteriormente realiza ajustes de velocidad y altura mientras se acerca a dicha zona, lo que deriva en trayectorias mucho menos erráticas que en el ejemplo mostrado en la Ilustración 23 empleando la Codificación 1.

Este tipo de trayectoria permite que el UAV pueda “recolectar” más creencia, lo cual se refleja en que quedan menos restos de probabilidad (zonas azul claro) donde había zonas de alta probabilidad a lo largo de la trayectoria del UAV. Además, este finaliza dicha trayectoria mucho más cerca de la última zona de alta probabilidad no explorada que en el caso anterior mediante la Codificación 1.

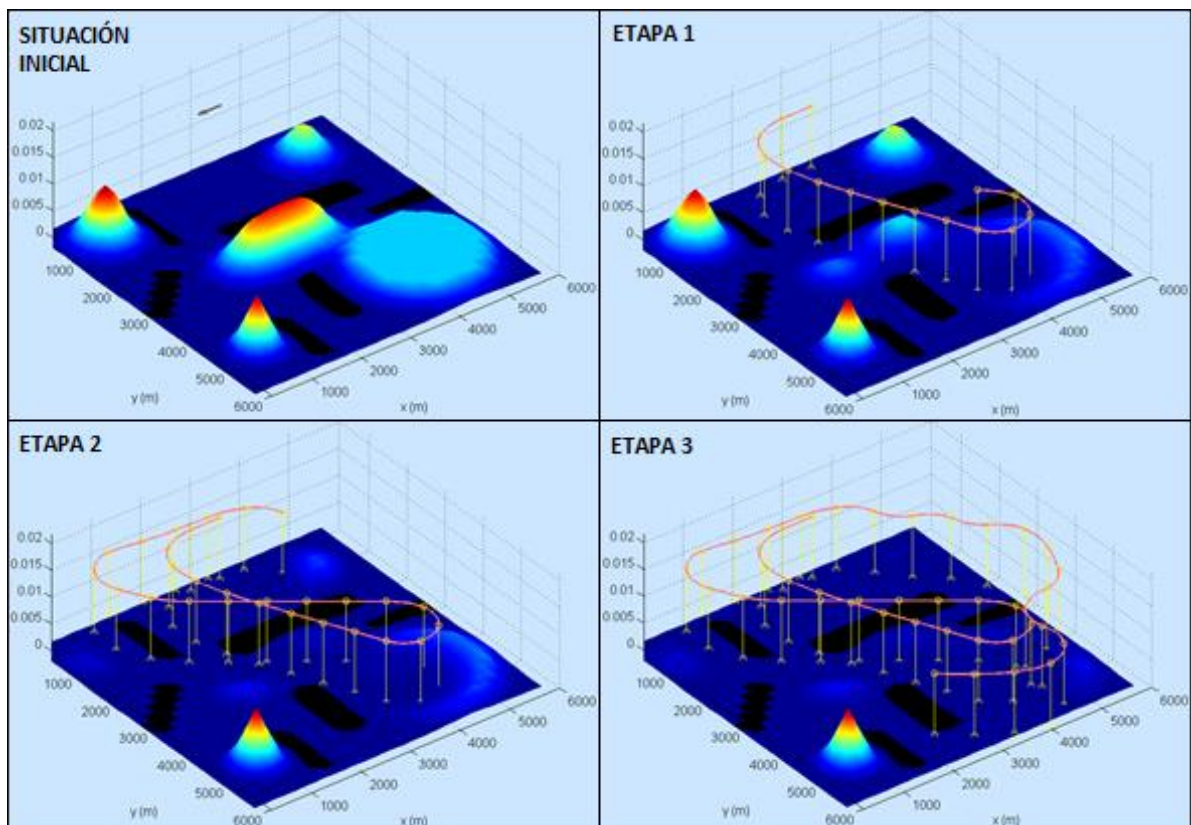


Ilustración 24 - Trayectoria empleando la Codificación 2

La Tabla 5 muestra las variaciones de las señales de control del UAV generadas por el algoritmo a lo largo de las 3 etapas, destacando principalmente sobre el ejemplo realizado empleando la Codificación 1 en el apartado anterior que, en este caso, varían las tres señales de control, una (y solo una) de ellas en cada instante de la trayectoria.

Cabe destacar que el UAV tiende a orientarse hacia la siguiente zona de alta probabilidad de presencia del objetivo, y después a disminuir la altura, para alcanzar una determinada altitud a

la que el sensor sea más eficaz. También resulta interesante ver que el UAV reduce velocidad antes de algunos giros y la aumenta después, cuando debe recorrer una distancia mayor.

	ETAPA 1			ETAPA 2			ETAPA 3		
	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv
1	-	-	4,2	-	-29	-	-93	-	-
2	-63	-	-	-	-22	-	-171	-	-
3	-52	-	-	-	-18	-	174	-	-
4	-	-23	-	-	-	-1,5	142	-	-
5	-	-26	-	-	-29	-	-	20	-
6	-	-14	-	38	-	-	-	12	-
7	-	-25	-	-7	-	-	145	-	-
8	-	-	-2,6	179	-	-	97	-	-
9	-	-16	-	-	-	0,5	-	-	0,3
10	-	-18	-	-67	-	-	-142	-	-
11	-144	-	-	-	-26	-	-	-	4,8
12	-83	-	-	-	-	1,4	-	27	-
13	-	-	5	45	-	-	-	8	-
14	-	-	2,6	60	-	-	-	-16	-

Tabla 5 - Señales de control del UAV empleando la Codificación 2

5.1.3 Codificación 3

En la Ilustración 25 puede verse el resultado de la ejecución del GA Multi-etapa empleando la Codificación 3 sobre el escenario de prueba. Como puede verse en la Tabla 2 (tabla de referencia de las codificaciones de soluciones del GA Multi-etapa) se trata de una codificación similar a la Codificación 2, pero permitiéndose en este caso que en un instante determinado pueda no modificarse ninguna de las variables de control del UAV. La trayectoria que el algoritmo genera con esta codificación tiene características similares a la generada empleando la Codificación 2, en el sentido de que se aprecian tramos de la trayectoria poco sinuosos, en las etapas 1 y 3 principalmente, en los que el algoritmo selecciona una solución en la que se hacen varios ajustes de velocidad y de altura entre los diferentes giros que realiza el UAV.

Resulta interesante destacar que en este ejemplo el UAV recorre las zonas de máxima probabilidad de presencia del objetivo en un orden diferente al de las dos pruebas anteriores. En los casos mostrados en los apartados previos empleando las Codificaciones 1 y 2, la solución generada por el algoritmo recorría primero la zona de alta probabilidad alargada del centro del escenario y después la zona de probabilidad menor, pero más amplia, de la parte derecha, mientras que en este caso empleando la Codificación 3 se visita primero la zona puntual de la izquierda del escenario. Esto constituye un buen ejemplo de que el comportamiento de un GA es estocástico, es decir, no solo no devuelve siempre el mismo resultado, sino que en casos como este puede devolver resultados bastante diversos. Por ello es necesario realizar pruebas cuantitativas de carácter estadístico como las mostradas en el apartado 5.2, basadas en un número de ejecuciones alto, para obtener medidas eficaces de la calidad de este tipo de algoritmos.

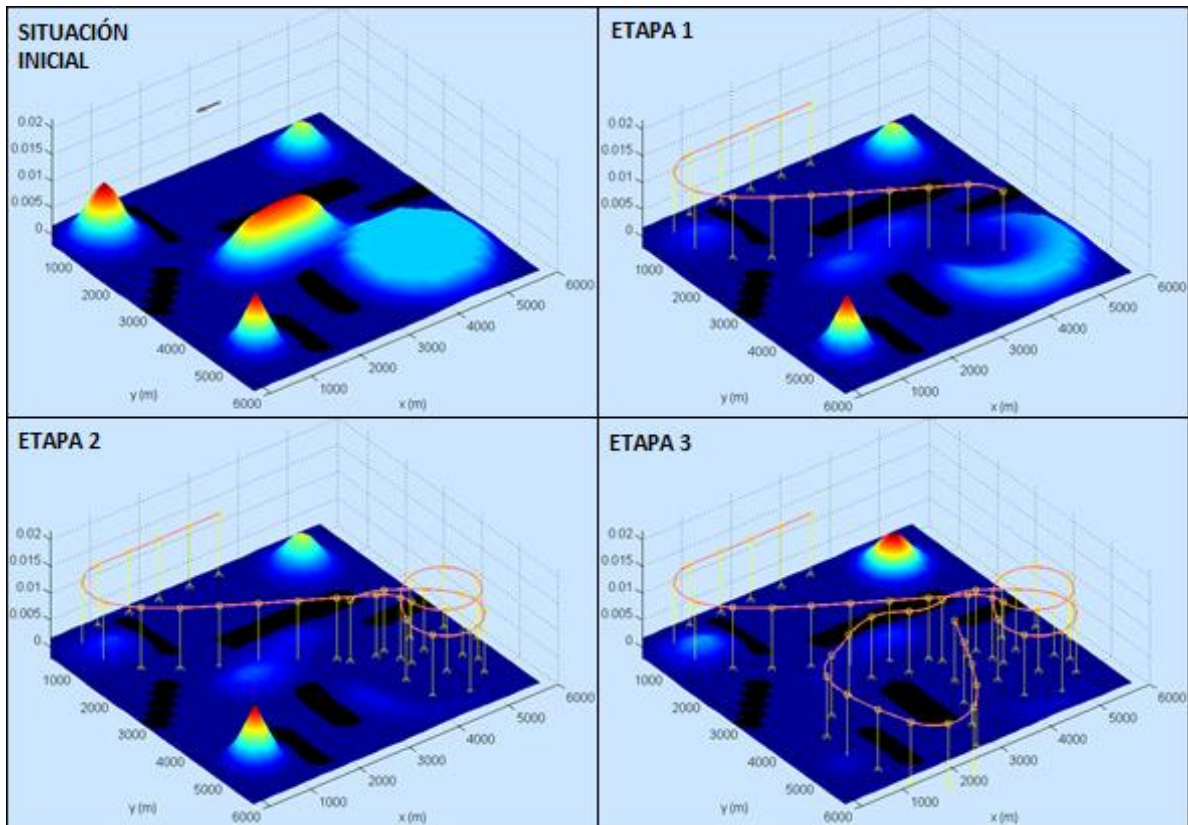


Ilustración 25 - Trayectoria empleando la Codificación 3

La secuencia de variaciones de señales de control del UAV, mostrada en la Tabla 6, permite observar que, como se espera de esta codificación, en la mejor solución seleccionada por el GA Multi-etapa, para algunos instantes de la trayectoria, no se modifica ninguna de las variables de control (instantes 12 y 13 de la etapa 2, e instantes 3, 10 y 11 de la etapa 3).

	ETAPA 1			ETAPA 2			ETAPA 3		
	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv
1	-	-	4,7	-179	-	-	107	-	-
2	-	-	3,2	-	-10	-	-137	-	-
3	-	-	-2,9	-87	-	-	-	-	-
4	-	-	3,8	-72	-	-	31	-	-
5	-156	-	-	-	-	2,6	-97	-	-
6	6	-	-	-	-15	-	-	-26	-
7	-	-25	-	-	-	0,2	-	-	0,4
8	-	-23	-	-161	-	-	-	-11	-
9	-	-14	-	-	-	2,5	-135	-	-
10	-	-	1,5	-100	-	-	-	-	-
11	-	-	-1,4	-	-23	-	-	-	-
12	-	-26	-	-	-	-	-	-	-1,5
13	-	-17	-	-	-	-	-	-	3,5
14	118	-	-	-83	-	-	-	-	-2,6

Tabla 6 - Señales de control del UAV empleando la Codificación 3

5.1.4 Codificación 4

En la Ilustración 26 se puede ver la trayectoria obtenida mediante el GA Multi-etapa basado en la Codificación 4 (véase la Tabla 2, de referencia de codificaciones de soluciones del GA). Como se indica en el apartado 4.1.3, esta codificación permite que se modifique más de una variable de control del UAV en el mismo instante de la trayectoria, lo cual contraviene los métodos de vuelo establecidos en la actualidad para UAVs como el que se modela en este caso, por lo que los resultados que aquí se muestran se analizan desde un punto de vista teórico.

La trayectoria mostrada recorre las zonas de alta probabilidad de presencia del objetivo en el mismo orden que se hace en la prueba de la Codificación 3, pero en este caso la trayectoria resulta mucho más sinuosa ya que en todos los instantes se produce alguna variación de la dirección θ del UAV, igual que en las trayectorias generadas mediante la Codificación 1. Sin embargo, en el caso de la Codificación 4, el espacio de soluciones explorado por el GA es mucho mayor que en el de la Codificación 1, ya que todos los cambios de dirección θ se ven acompañados de cambios de altura h , que pueden ayudar al UAV a alcanzar altitudes más adecuadas para el funcionamiento de su sensor, y de cambios de velocidad v que pueden permitir un mejor ajuste de los giros para alcanzar las zonas del escenario deseadas.

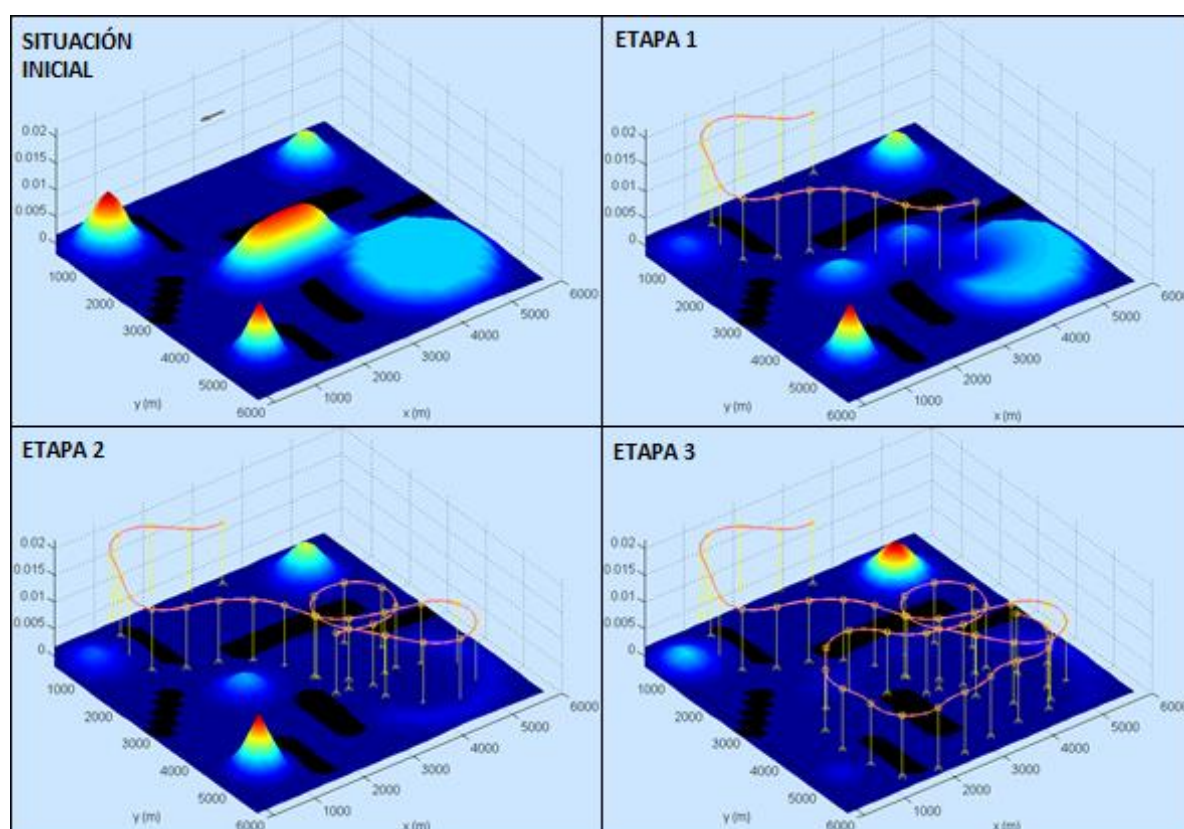


Ilustración 26 - Trayectoria empleando la Codificación 4

En la Tabla 7, tal y como se espera de la Codificación 4, se observa que en todos los instantes de la trayectoria varían las tres señales de control del UAV.

	ETAPA 1			ETAPA 2			ETAPA 3		
	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv

1	85	-26	3,9	-6	-20	1,8	77	13	3,5
2	-57	-23	4,5	116	-16	-4,2	147	-23	-1,1
3	-145	-2	-1,4	104	-26	0,8	19	-8	-3,4
4	24	15	0,8	24	30	1,4	47	-17	-2,4
5	35	5	-3,9	4	-25	0,8	-111	-18	-0,9
6	-16	-10	-0,8	-16	-1	2,5	111	-4	4,9
7	-135	-10	-2,5	-13	-12	-1,4	-153	-28	3
8	19	-19	-0,4	85	6	0,7	-70	-28	2,1
9	51	17	-0,4	98	23	-2,5	130	-2	0,1
10	13	-20	-2,2	-2	17	2,8	-106	-12	-1,1
11	34	22	-0,2	100	-21	2,6	143	15	1,6
12	-32	9	3,1	54	-15	-3	169	-15	4,2
13	-62	11	1,2	16	-29	-0,1	-42	-21	-1,2
14	16	2	4,9	-13	-21	2,8	32	18	1,1

Tabla 7 - Señales de control del UAV empleando la Codificación 4

5.1.5 Codificación 5

La Ilustración 27 muestra la trayectoria resultante al ejecutar la versión del GA Multi-etapa basada en la Codificación 5 la cual, al igual que la Codificación 4, permite generar soluciones en las que, en un determinado punto de la trayectoria, puede modificarse más de una variable de control, por lo que no resulta aplicable en un UAV que esté obligado a cumplir los estándares de vuelo actuales.

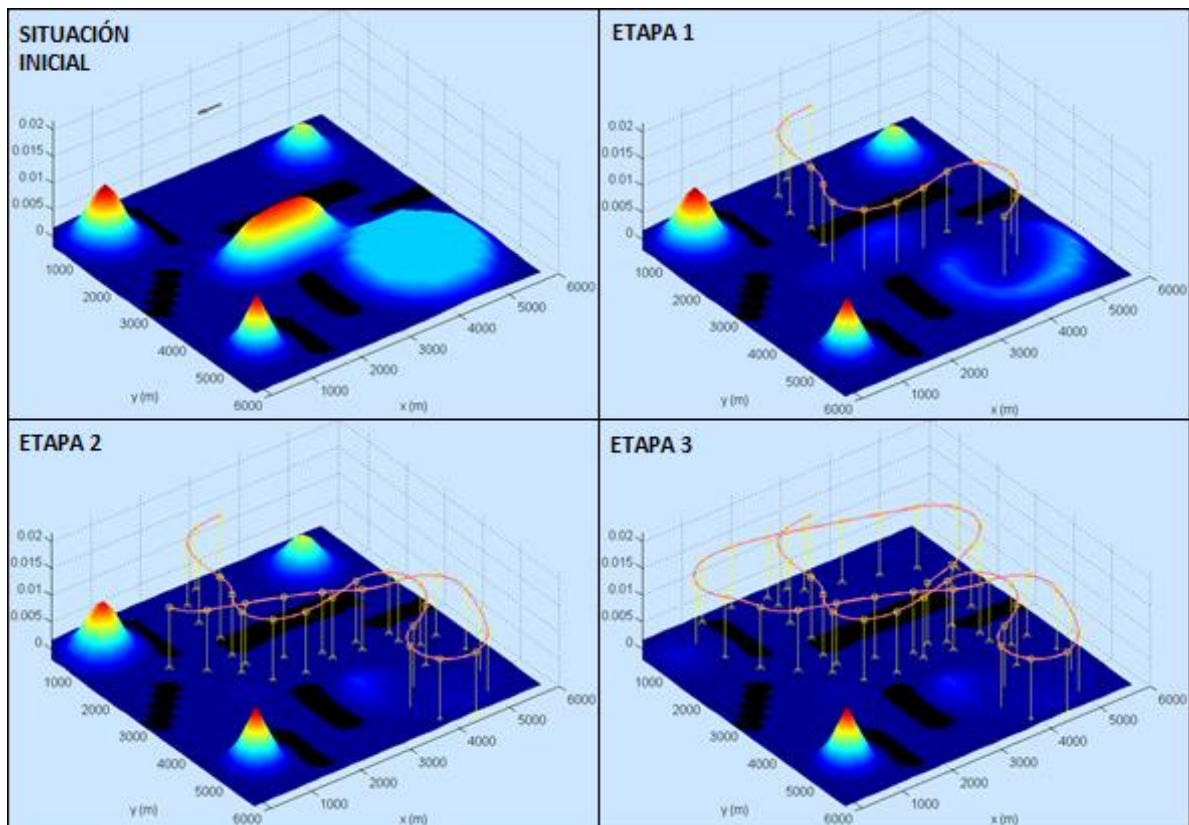


Ilustración 27 - Trayectoria empleando la Codificación 5

Se observa en la Ilustración 27 una trayectoria algo menos sinuosa en ciertos momentos (p. ej. en la segunda parte de la etapa 2 o en la etapa 3), ya que esta codificación (véase la Tabla 2, de referencia de codificaciones) no implica que se modifique la dirección θ en todos los instantes del vuelo.

En la Tabla 8, que se muestra a continuación, se puede ver que la trayectoria que es considerada como la mejor solución según la versión del GA Multi-etapa basado en esta codificación corresponde con lo esperado, es decir, en cada instante de la trayectoria se varía una combinación diferente de variables de control, en teoría la más favorable según la situación del UAV en cada momento. La señal de control que más veces se varía es la velocidad v que se modifica 25 veces, frente a las 19 de la dirección θ y las 17 de la altura h . Esto parece indicar la importancia del ajuste continuo de la velocidad para que tanto los giros del UAV como sus transiciones entre zonas de alta probabilidad alejadas entre sí se realicen de la mejor forma posible.

	ETAPA 1			ETAPA 2			ETAPA 3		
	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv
1	-27	-	-4,6	-160	-	-3	-44	-23	
2	-70	-24	-0,9	-	-	3,5	168	13	2,9
3	-	-19	4,3	-75	-	-	-	-22	4,7
4	-	-22	-0,7	-	-27	3	-	-27	-
5	81	-	-	-	-29	-	-	-	1,4
6	-113	-	-	-	-	-1,4	-	-23	-
7	-68	-	4,3	-124	-	0,3	-	-18	-
8	-	-	-	-	-	-	-	-	-
9	-	-	3	81	-	-	-	-	-
10	-	-18	0,4	-40	-	-3,8	79	-	3,3
11	169	-	-	-	7	1,1	112	25	2,7
12	-	-	2,2	-	-21	2,8	-47	27	4,8
13	-	-	-	-	-	-3,9	6	18	3,1
14	22	-	1,8	115	-	-	-	-	-

Tabla 8 - Señales de control del UAV empleando la Codificación 5

5.1.6 Codificación 6

En la Ilustración 28 se puede observar como la trayectoria obtenida aplicando la secuencia de señales de control correspondiente a la solución devuelta por la versión del GA Multi-etapa basada en la Codificación 6 parece adaptarse a la intención con la que se diseña esta codificación.

La combinación de la codificación (véase Tabla 2, de referencia de codificaciones) con los operadores de inicialización, cruce y mutación del GA diseñados específicamente, genera una trayectoria basada en subsecuencias de variaciones más o menos largas de la misma variable de control, en la que el UAV se desplaza siguiendo trayectorias rectas (sin variación de la dirección θ) entre las zonas de alta probabilidad de presencia del objetivo alejadas entre sí, mientras que recorre estas zonas, cuando son extensas como la amplia zona circular de la parte derecha del escenario, realizando un giro continuo muy cerrado.

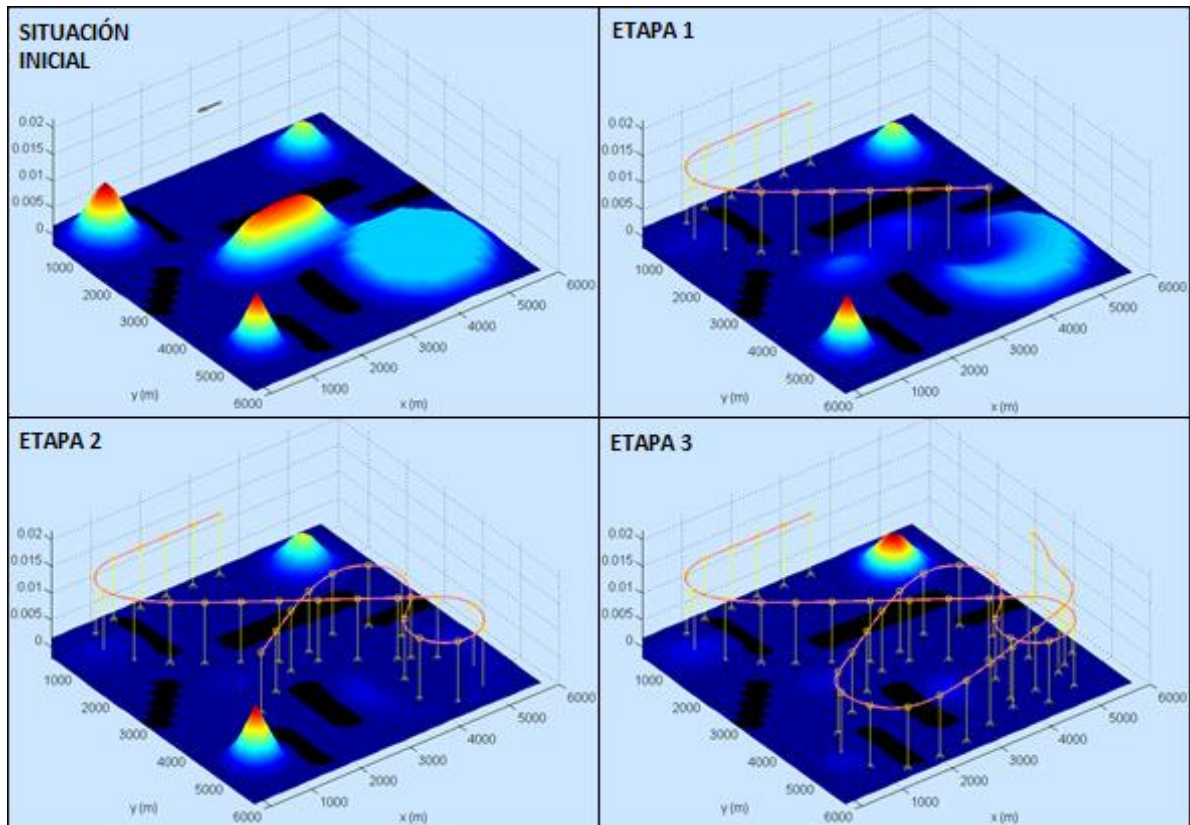


Ilustración 28 - Trayectoria empleando la Codificación 6

Las secuencias de variaciones de las señales de control que muestra la Tabla 9 confirman que la solución generada por el GA Multi-etapa basado en la Codificación 6 se compone de una serie de subsecuencias relativamente largas (en función de una probabilidad que se puede establecer como un parámetro del sistema) de la misma variable de control. Se pueden apreciar, por ejemplo, la subsecuencia de 8 cambios de dirección θ que en la etapa 2 permite explorar la zona amplia de probabilidad de la derecha del escenario, o la subsecuencia de 5 cambios de velocidad v en la etapa 1 que permite al UAV acelerar su vuelo en línea recta para alcanzar más rápidamente dicha zona amplia de probabilidad de la parte derecha.

	ETAPA 1			ETAPA 2			ETAPA 3		
	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv	$\Delta\theta$	Δh	Δv
1	-	-	-3,2	-	-30	-	-	-	-2,9
2	-	-18	-	95	-	-	-104	-	-
3	-	-29	-	50	-	-	3	-	-
4	-	-29	-	111	-	-	-65	-	-
5	-73	-	-	28	-	-	-	-19	-
6	-72	-	-	81	-	-	-	27	-
7	-	-	3,7	-111	-	-	-	-28	-
8	-	-	2,3	-37	-	-	-	13	-
9	-	-	-3,7	-104	-	-	-	-4	-
10	-	-	4	-	-	1	-	-21	-
11	-	-	4,7	-	-	2,8	-55	-	-
12	-	-29	-	-	-	-0,4	-43	-	-
13	-	-	3,6	-	11	-	80	-	-

14	-	-	2,3	-	24	-	-80	-	-
----	---	---	-----	---	----	---	-----	---	---

Tabla 9 - Señales de control del UAV empleando la Codificación 6

5.2 Pruebas cuantitativas

La comparación de resultados entre diferentes algoritmos (o diferentes versiones de un mismo algoritmo, como es el caso de este Trabajo de Fin de Máster) es una cuestión lo suficientemente compleja como para requerir un estudio de los métodos de comparación en sí mismos, como puede verse en el análisis realizado en [7] respecto a qué métricas pueden ser las más adecuadas para comparar algoritmos que resuelvan un problema como el MTS propuesto en el capítulo 3.

Una de las propuestas que se hacen en [7] es el empleo de métricas no dependientes del problema, como por ejemplo el test de Mann-Whitney, también conocido como el test de Wilcoxon. Se trata de una prueba que permite comparar dos distribuciones aleatorias en función de una serie de muestras de las mismas, y determinar si es esperable que los valores aleatorios obtenidos empleando una de ellas sean menores o mayores que los valores aleatorios obtenidos empleando la otra.

Este procedimiento se puede emplear para la comparación de resultados de dos algoritmos, si se dispone de una serie de muestras de los resultados de cada uno de ellos. Los resultados de un cierto algoritmo siguen una distribución aleatoria determinada, desconocida a priori, motivo por el cual no se puede establecer que un algoritmo es mejor o peor que otro en función de una única pareja de resultados de ambos. Sin embargo, y aunque no se conozcan los parámetros de las distribuciones aleatorias correspondientes a los algoritmos a comparar, generando una muestra lo suficientemente grande de soluciones de cada uno, se puede emplear el test de Mann-Whitney/Wilcoxon para comparar dichas distribuciones. Este procedimiento es el que se emplea en este Trabajo de Fin de Máster para comparar las diferentes versiones de los GA Multi-etapa descritos en los capítulos 3 y 4.

El test de Mann-Whitney/Wilcoxon puede aplicarse de varias formas para comparar la misma pareja de conjuntos de soluciones de dos algoritmos, en función de qué operador se desee emplear para decidir si una solución determinada es mejor que otra o no. Cualquier operador que tome como entrada una pareja de soluciones y devuelva si una de ellas es mejor que la otra, es teóricamente válido. En el caso de soluciones al problema MTS definido en el capítulo 2, existen en principio dos formas potencialmente interesantes de establecer si una de estas soluciones es mejor o no que otra:

- Comparación del valor de ET: la forma más sencilla consiste en comparar directamente los valores del criterio ET, siendo mejor aquella solución con un valor de ET más bajo.
- Dominación empleando #COL, #NFZ, ET, MYOP, FUEL, SMOOTH: otro método consiste en emplear la relación de dominación aplicando los seis criterios definidos en el capítulo 2, de forma que una solución A es mejor que otra B si la domina, es decir, si todos los valores de

todos los criterios son mejores o iguales para A que para B, y al menos uno de los valores de los criterios es estrictamente mejor para A que para B.

El empleo del segundo método (relación de dominación entre soluciones) tiende a ofrecer resultados menos definidos que el primero (comparación del ET) ya que, lógicamente, al tener que cumplirse más condiciones para poder afirmar que una solución es mejor que otra, menos soluciones serán efectivamente mejores que otras y más probabilidades hay de que el test de Mann-Whitney/Wilcoxon determine que no se puede establecer que algoritmo (distribución de soluciones) es mejor. En el análisis de los resultados de las pruebas cuantitativas realizado en el apartado 5.2.2, en lugar de optarse por uno solo de estos dos métodos, se decide emplear ambos. Sin embargo, a la vista de que los resultados del segundo método (relación de dominación entre soluciones) resultan muy poco concluyentes y, por el contrario, los del primer método (comparación del ET) son mucho más claros, se opta por presentar solamente los resultados en función de la comparación directa del ET.

Nótese que, mediante el test de Mann-Whitney/Wilcoxon, solo se pueden comparar los resultados obtenidos para cada versión del GA Multi-etapa por parejas, no establecer una ordenación total de las mismas comparándolas todas a la vez con todas. Por ello, los resultados se presentan en forma de matrices de comparación entre el conjunto de algoritmos como la mostrada en la Ilustración 29. En ellas, si el algoritmo i es mejor que el algoritmo j , se representa en color blanco el elemento (i, j) de la matriz, siendo i la fila y j la columna. En caso contrario, es decir, si el algoritmo i no es mejor que el algoritmo j (lo cual no implica necesariamente que i sea peor que j , ya que es perfectamente posible que la relación entre algoritmos quede indefinida) se representa dicho elemento de la matriz en color negro. El índice de los algoritmos en las matrices de comparación mostradas corresponde a la numeración de codificaciones de la solución en las diferentes versiones del GA Multi-etapa presentadas en el capítulo 4 (Codificaciones 2 a 6). Se incluye también en las pruebas realizadas en este apartado la versión original del GA Multi-etapa para trayectorias solo de dirección variable, que emplea la que se considera Codificación 1 de la solución del GA. Por ello, los índices de los elementos de las matrices de comparación varían desde el 1 hasta el 6.




Ilustración 29 - Ejemplo de matriz de comparación entre algoritmos

En la matriz de comparación que se muestra en la Ilustración 29 se observa, por ejemplo, que el resultado del GA Multi-etapa basado en la Codificación 6 es mejor que los basados en las Codificaciones 1, 2, 3 y 5, porque los elementos (6,1), (6,2), (6,3) y (6,5) de la matriz son blancos. Desde el punto de vista opuesto, puede decirse que, por ejemplo, el algoritmo basado en la Codificación 5 es peor que los algoritmos basados en las Codificaciones 4 y 6, ya que los elementos (4,5) y (6,5) son blancos. Es decir, los elementos en blanco de la fila i indican las codificaciones peores que la codificación i , mientras que los elementos en blanco de la columna j indican las codificaciones mejores que la codificación j . Los elementos de la diagonal principal de la matriz siempre son negros ya que un algoritmo no puede ser mejor ni peor que sí mismo.

En los siguientes apartados se definen una serie de escenarios presentando casos del problema MTS de casuística variada, en cuanto a número y morfología de zonas de alta probabilidad de presencia del objetivo, disposición y número de las NFZs, y número y situación inicial de los UAVs. Se presenta además la parametrización precisa de cada uno de ellos (del escenario propiamente dicho y del GA Multi-etapa que se ejecuta en cada caso) principalmente por cuestión de referencia, ya que no es la finalidad de las pruebas cuantitativas realizadas en este apartado estudiar la mejor parametrización de los algoritmos, sino comparar el rendimiento de las diferentes codificaciones de soluciones diseñadas en este Trabajo de Fin de Máster. La optimización de la parametrización del GA Multi-etapa se plantea en el capítulo 6 como una de las posibles líneas a seguir como ampliación de este trabajo. Los valores de parametrización empleados en los escenarios creados para estas pruebas cuantitativas son similares, en general, a los de los escenarios presentados en [21], con algunos cambios orientados a permitir que los UAVs puedan explorar todas las zonas de alta probabilidad de cada escenario en los límites temporales establecidos en cada caso.

Sobre cada uno de estos escenarios se realiza un número alto de ejecuciones de cada versión del GA Multi-etapa (20 ejecuciones) y, con la muestra de resultados generada, se aplica el test de Mann-Whitney/Wilcoxon para comparar los algoritmos entre sí empleando los dos métodos de comparación de soluciones ya mencionados. Los resultados obtenidos se presentan de forma conjunta en el apartado final de este capítulo.

5.2.1 Descripción de escenarios

En los siguientes apartados se presentan en detalle los seis escenarios diseñados para la realización de las pruebas cuantitativas. Se muestra para cada uno de ellos el modelo de probabilidad del objetivo, en el que las zonas altas en colores cálidos representan las zonas de máxima probabilidad de presencia del mismo, mientras que las zonas bajas en colores fríos representan las zonas de baja probabilidad. Se proporciona además la parametrización precisa del escenario, de los UAVs, y del algoritmo GA Multi-etapa en cada caso.

5.2.1.1 Escenario 1

El primer escenario sobre el que se realizan pruebas cuantitativas, como muestra la Ilustración 30, consiste en un caso en el que la búsqueda se realiza por parte de un único UAV, orientado en la dirección que indica la flecha gris en el instante inicial. Las zonas de mayor probabilidad del objetivo son circulares y más bien puntuales, con una zona de mayor probabilidad principal en el centro, dos zonas de probabilidad media en un extremo y otras dos de probabilidad

más baja en el otro. No se definen NFZs. Se trata de un escenario que ninguno de los algoritmos debería tener especial problema en resolver.




Ilustración 30 - Escenario 1

La parametrización del escenario y del algoritmo empleadas se muestran a continuación en la Tabla 10.

GA Multi-etapa			Escenario	
Parámetro	Valor		Parámetro	Valor
T (instantes totales)	75		Tamaño G (celdas)	30x30
S (etapas)	3		Tamaño celda (m)	200
L (instantes/etapa)	25		Δt modelo cinemático (s)	1
GA			Nº de UAVs	1
Parámetro	Valor	Codificaciones	UAV 1	
Tamaño de la población	50	1, 2, 3, 4, 5, 6	Dirección inicial	180
Máximo generaciones	60	1, 2, 3, 4, 5, 6	Altura Inicial	1000
Máximo tiempo (s)	60	1, 2, 3, 4, 5, 6	Velocidad Inicial	70
Porcentaje individuos que no se cruzan	0,2	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(4600, 200)
Desviación estándar mutación incremental 1	0,5	1	Δt entre señales control (s)	4
Desviación estándar mutación incremental 2	0,1	1	Δt entre lecturas sensor (s)	4
Probabilidad mutación	0,2	2, 3, 4, 5		
Probabilidad de nueva subsecuencia por gen en inicialización	0,2	6		
Probabilidad mutación de un gen	0,2	6		

Probabilidad de mutación de una subsecuencia	0,04	6		
Rango $\Delta\theta$ (min θ , max θ)	(-180, 180)	1		
Rango $\Delta\theta$ (min θ , max θ)	(-90, 90)	2, 3, 4, 5, 6		
Rango Δh (minH, maxH)	(-30, 30)	2, 3, 4, 5, 6		
Rango Δv (minV, maxV)	(-5, 5)	2, 3, 4, 5, 6		
Dígitos fraccionarios por variable de control	6	4, 5		

Tabla 10 - Parametrización del GA Multi-etapa y del Escenario 1

5.2.1.2 Escenario 2

El segundo escenario de prueba propuesto en este apartado se puede ver a continuación en la Ilustración 31. Incluye un segundo UAV y varias zonas puntuales de alta probabilidad de presencia del objetivo.




Ilustración 31 - Escenario 2

En este escenario, la distribución de las zonas de probabilidad se ha combinado de forma expresa con las posiciones iniciales de los UAVs para presentar dificultades adicionales a los algoritmos. La situación inicial muestra a los UAVs encarados hacia las zonas cuya exploración es menos interesante, de forma que se presenta la doble dificultad de que los algoritmos deben reconducir a los UAVs hacia las zonas de mayor probabilidad de presencia del objetivo, tratando además de que las examinen coordinadamente para obtener el mejor ET (tiempo estimado de búsqueda).

En la Tabla 11, que se muestra a continuación, se pueden ver los parámetros empleados en el escenario, incluyendo en esta ocasión dos UAVs en lugar de uno.

GA Multi-etapa			Escenario	
Parámetro	Valor		Parámetro	Valor
T (instantes totales)	30		Tamaño G (celdas)	30x30
S (etapas)	3		Tamaño celda (m)	200
L (instantes/etapa)	10		Δt modelo cinemático (s)	1
GA			Nº de UAVs	2
Parámetro	Valor	Codificaciones	UAV 1	
Tamaño de la población	50	1, 2, 3, 4, 5, 6	Dirección inicial	225
Máximo generaciones	60	1, 2, 3, 4, 5, 6	Altura Inicial	1000
Máximo tiempo (s)	60	1, 2, 3, 4, 5, 6	Velocidad Inicial	70
Porcentaje individuos que no se cruzan	0,2	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(3500, 1000)
Desviación estándar mutación incremental 1	0,5	1	Δt entre señales control (s)	4
Desviación estándar mutación incremental 2	0,1	1	Δt entre lecturas sensor (s)	4
Probabilidad mutación	0,2	2, 3, 4, 5	UAV 2	
Probabilidad de nueva subsecuencia por gen en inicialización	0,2	6	Dirección inicial	260
Probabilidad mutación de un gen	0,2	6	Altura Inicial	1000
Probabilidad de mutación de una subsecuencia	0,04	6	Velocidad Inicial	70
Rango $\Delta\theta$ (min θ , max θ)	(-180, 180)	1	Posición inicial (x, y) (m)	(2500, 5000)
Rango $\Delta\theta$ (min θ , max θ)	(-90, 90)	2, 3, 4, 5, 6	Δt entre señales control (s)	4
Rango Δh (minH, maxH)	(-30, 30)	2, 3, 4, 5, 6	Δt entre lecturas sensor (s)	4
Rango Δv (minV, maxV)	(-5, 5)	2, 3, 4, 5, 6		
Dígitos fraccionarios por variable de control	6	4, 5		

Tabla 11 - Parametrización del GA Multi-etapa y del Escenario 2

5.2.1.3 Escenario 3

En la Ilustración 32, mostrada a continuación, se expone el tercero de los escenarios de prueba propuestos. Como se puede ver, en este caso se han definido zonas de alta probabilidad de presencia del objetivo de forma estrecha y alargada, con dirección variable y en uno de los casos (zona de la izquierda del escenario) ramificada, con la intención de poner a prueba la capacidad del algoritmo de generar trayectorias estables a lo largo de ellas.




Ilustración 32 - Escenario 3

Nuevamente se ha parametrizado que la búsqueda se realice mediante dos UAVs, en este caso cada uno de ellos encarado inicialmente, aunque de forma lateral, hacia cada una de las dos zonas de máxima probabilidad de presencia del objetivo. La parametrización del escenario y el algoritmo se muestra en la Tabla 12.

GA Multi-etapa			Escenario	
Parámetro	Valor		Parámetro	Valor
T (instantes totales)	30		Tamaño G (celdas)	30x30
S (etapas)	3		Tamaño celda (m)	200
L (instantes/etapa)	10		Δt modelo cinemático (s)	1
GA			Nº de UAVs	2
Parámetro	Valor	Codificaciones	UAV 1	
Tamaño de la población	50	1, 2, 3, 4, 5, 6	Dirección inicial	225
Máximo generaciones	60	1, 2, 3, 4, 5, 6	Altura Inicial	1000
Máximo tiempo (s)	60	1, 2, 3, 4, 5, 6	Velocidad Inicial	70
Porcentaje individuos que no se cruzan	0,2	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(5500, 500)
Desviación estándar mutación incremental 1	0,5	1	Δt entre señales control (s)	4
Desviación estándar mutación incremental 2	0,1	1	Δt entre lecturas sensor (s)	4
Probabilidad mutación	0,2	2, 3, 4, 5	UAV 2	
Probabilidad de nueva subsecuencia por gen en inicialización	0,2	6	Dirección inicial	45
Probabilidad mutación de un gen	0,2	6	Altura Inicial	1000

Probabilidad de mutación de una subsecuencia	0,04	6	Velocidad Inicial	70
Rango $\Delta\theta$ (min θ , max θ)	(-180, 180)	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(500, 5000)
Rango Δh (minH, maxH)	(-30, 30)	2, 3, 4, 5, 6	Δt entre señales control (s)	4
Rango Δv (minV, maxV)	(-5, 5)	2, 3, 4, 5, 6	Δt entre lecturas sensor (s)	4
Dígitos fraccionarios por variable de control	6	4, 5		

Tabla 12 - Parametrización del GA Multi-etapa y del Escenario 3

5.2.1.4 Escenario 4

El cuarto escenario diseñado para poner a prueba las diferentes versiones del GA Multi-etapa se muestra en la Ilustración 33. Puede observarse que la intención en este caso es la opuesta al escenario descrito en el apartado anterior, y que consiste en probar la capacidad de los algoritmos de obtener buenas trayectorias para realizar la búsqueda sobre áreas de alta probabilidad del objetivo en general extensas, sin puntos determinados en los que la probabilidad sea máxima. Se definen dos UAVs como en los anteriores escenarios, con el fin de probar también la capacidad de los algoritmos de coordinar la búsqueda empleando simultáneamente los dos UAVs.




Ilustración 33 - Escenario 4

La parametrización completa del escenario, del algoritmo GA Multi-etapa y de los dos UAVs introducidos en el escenario puede consultarse en la Tabla 13, que se muestra a continuación.

GA Multi-etapa		Escenario	
Parámetro	Valor	Parámetro	Valor
T (instantes totales)	30	Tamaño G (celdas)	30x30
S (etapas)	3	Tamaño celda (m)	200
L (instantes/etapa)	10	Δt modelo cinemático (s)	1

GA			Nº de UAVs	2
Parámetro	Valor	Codificaciones	UAV 1	
Tamaño de la población	50	1, 2, 3, 4, 5, 6	Dirección inicial	90
Máximo generaciones	60	1, 2, 3, 4, 5, 6	Altura Inicial	1000
Máximo tiempo (s)	60	1, 2, 3, 4, 5, 6	Velocidad Inicial	70
Porcentaje individuos que no se cruzan	0,2	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(5900, 100)
Desviación estándar mutación incremental 1	0,5	1	Δt entre señales control (s)	4
Desviación estándar mutación incremental 2	0,1	1	Δt entre lecturas sensor (s)	4
Probabilidad mutación	0,2	2, 3, 4, 5	UAV 2	
Probabilidad de nueva subsecuencia por gen en inicialización	0,2	6	Dirección inicial	270
Probabilidad mutación de un gen	0,2	6	Altura Inicial	1000
Probabilidad de mutación de una subsecuencia	0,04	6	Velocidad Inicial	70
Rango $\Delta\theta$ (min θ , max θ)	(-180, 180)	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(100, 5900)
Rango Δh (minH, maxH)	(-30, 30)	2, 3, 4, 5, 6	Δt entre señales control (s)	4
Rango Δv (minV, maxV)	(-5, 5)	2, 3, 4, 5, 6	Δt entre lecturas sensor (s)	4
Dígitos fraccionarios por variable de control	6	4, 5		

Tabla 13 - Parametrización del GA Multi-etapa y del Escenario 4

5.2.1.5 Escenario 5

En el quinto escenario de los diseñados para la realización de pruebas cuantitativas se persigue un objetivo diferente de los anteriores: en este caso, se propone un escenario cuya disposición favorezca el empleo de una trayectoria estable por parte del único UAV presente, una trayectoria que visite una a una las zonas de máxima probabilidad de presencia del objetivo empezando por la mayor (en la parte superior de la Ilustración 34) y terminando por la más pequeña (en la parte de debajo de la misma ilustración). Dicho de otra forma, se trata de un escenario en el que el GA Multi-etapa basado en la Codificación 6, que genera trayectorias formadas por subsecuencias de variaciones de la misma variable de control, podría ofrecer mejores resultados que el resto de algoritmos, ya que la mejor trayectoria en este caso se compone claramente de varios tramos rectos relativamente largos alternados con giros bruscos entre ellos.




Ilustración 34 - Escenario 5

La parametrización del escenario y del GA Multi-etapa se puede observar en la Tabla 14, en la que se aprecian las mayores dimensiones de la zona de búsqueda y las probabilidades de mutación aumentadas para la Codificación 6, valores establecidos con el fin de crear unas condiciones para las que dicha codificación parece especialmente adecuada.

GA Multi-etapa			Escenario	
Parámetro	Valor		Parámetro	Valor
T (instantes totales)	60		Tamaño G (celdas)	60x60
S (etapas)	2		Tamaño celda (m)	200
L (instantes/etapa)	30		Δt modelo cinemático (s)	1
GA			Nº de UAVs	1
Parámetro	Valor	Codificaciones	UAV 1	
Tamaño de la población	50	1, 2, 3, 4, 5, 6	Dirección inicial	270
Máximo generaciones	60	1, 2, 3, 4, 5, 6	Altura Inicial	500
Máximo tiempo (s)	90	1, 2, 3, 4, 5, 6	Velocidad Inicial	70
Porcentaje individuos que no se cruzan	0,2	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(11500, 7500)
Desviación estándar mutación incremental 1	0,5	1	Δt entre señales control (s)	5
Desviación estándar mutación incremental 2	0,1	1	Δt entre lecturas sensor (s)	5
Probabilidad mutación	0,2	2, 3, 4, 5		
Probabilidad de nueva subsecuencia por gen en inicialización	0,2	6		
Probabilidad mutación de un gen	0,4	6		

Probabilidad de mutación de una subsecuencia	0,08	6		
Rango $\Delta\theta$ (min θ , max θ)	(-90, 90)	1, 2, 3, 4, 5, 6		
Rango Δh (minH, maxH)	(-30, 30)	2, 3, 4, 5, 6		
Rango Δv (minV, maxV)	(-5, 5)	2, 3, 4, 5, 6		
Dígitos fraccionarios por variable de control	6	4, 5		

Tabla 14 - Parametrización del GA Multi-etapa y del Escenario 5

5.2.1.6 Escenario 6

El último escenario empleado en la realización de las pruebas cuantitativas es precisamente el diseñado para las pruebas cualitativas presentadas en el apartado 5.1, que por la variedad de situaciones que presenta (NFZs, diferentes tipos de zonas de máxima probabilidad de presencia del objetivo, accesos difíciles a dichas zonas) resulta igualmente interesante para poner a prueba las capacidades generales de las versiones del GA Multi-etapa basadas en las diferentes codificaciones de soluciones diseñadas. El escenario se muestra a continuación en la Ilustración 35.




Ilustración 35 - Escenario 6

La parametrización empleada se muestra en la Tabla 15. Nótese la variación del parámetro del rango de modificación de la variable de control dirección θ para las versiones del algoritmo basadas en las Codificaciones 2 a 6, que en esta ocasión vale (-90, 90), respecto al empleado en las pruebas cualitativas en las que el mismo parámetro tomaba el valor (-180, 180). Esta modificación se realiza tras comprobarse en la realización de algunas pruebas en este escenario que el nuevo rango (-90, 90) mejora los resultados obtenidos mediante las Codificaciones 2 a 6, ya que permite explorar más exhaustivamente el rango real de variación de dirección θ de los UAVs. No se cumple lo mismo para la Codificación 1 en la que, por no poder modificarse la velocidad v del UAV, habitualmente se necesita emplear trayectorias basadas en cambios de dirección más bruscos, por lo que se opta por mantener el valor de (-180, 180) únicamente para esta codificación.

GA Multi-etapa			Escenario	
Parámetro	Valor		Parámetro	Valor
T (instantes totales)	42		Tamaño G (celdas)	30x30
S (etapas)	3		Tamaño celda (m)	200
L (instantes/etapa)	14		Δt modelo cinemático (s)	1
GA			Nº de UAVs	1
Parámetro	Valor	Codificaciones	UAV 1	
Tamaño de la población	50	1, 2, 3, 4, 5, 6	Dirección inicial	180
Máximo generaciones	60	1, 2, 3, 4, 5, 6	Altura Inicial	1000
Máximo tiempo (s)	60	1, 2, 3, 4, 5, 6	Velocidad Inicial	70
Porcentaje individuos que no se cruzan	0,2	1, 2, 3, 4, 5, 6	Posición inicial (x, y) (m)	(3600, 200)
Desviación estándar mutación incremental 1	0,5	1	Δt entre señales control (s)	8
Desviación estándar mutación incremental 2	0,1	1	Δt entre lecturas sensor (s)	8
Probabilidad mutación	0,2	2, 3, 4, 5		
Probabilidad de nueva subsecuencia por gen en inicialización	0,2	6		
Probabilidad mutación de un gen	0,2	6		
Probabilidad de mutación de una subsecuencia	0,04	6		
Rango $\Delta\theta$ (min θ , max θ)	(-180, 180)	1		
Rango $\Delta\theta$ (min θ , max θ)	(-90, 90)	2, 3, 4, 5, 6		
Rango Δh (minH, maxH)	(-30, 30)	2, 3, 4, 5, 6		
Rango Δv (minV, maxV)	(-5, 5)	2, 3, 4, 5, 6		
Dígitos fraccionarios por variable de control	6	4, 5		

Tabla 15 - Parametrización del GA Multi-etapa y del Escenario 6

5.2.2 Resultados cuantitativos

Se presentan y analizan a continuación los resultados obtenidos mediante la realización de las pruebas cuantitativas sobre los seis escenarios descritos. Dado que dos de las codificaciones de soluciones del GA Multi-etapa diseñadas (Codificaciones 4 y 5) se estudian en este trabajo de Fin de Máster desde un punto de vista teórico por las razones indicadas en los apartados 4.1.3 y 4.1.4 en los que se definen estas codificaciones, se ha optado por analizar los resultados primero desde un punto de vista global, en el apartado 5.2.2.1, y posteriormente excluyendo estas dos codificaciones, en el apartado 5.2.2.2.

5.2.2.1 Comparativa general de codificaciones

La realización de las pruebas cuantitativas de las diferentes versiones del GA Multi-etapa basadas en las Codificaciones 1 a 6, empleando el test de Mann-Whitney/Wilcoxon para juzgar la relación entre las distribuciones de soluciones de cada versión, arroja como resultado el conjunto de matrices de comparación mostradas en la Ilustración 36.

Tal y como se indica al inicio del apartado 5.2, el test de Mann-Whitney/Wilcoxon toma como uno de sus parámetros un operador que permita comparar directamente dos soluciones diferentes y devolver si una es mejor o no que la otra. En dicho apartado se proponen dos posibles funciones que realicen esta comparación de soluciones para el caso concreto del problema MTS, por una parte, la comparación directa del ET (tiempo estimado de búsqueda) y, por otro lado, la relación de dominación entre soluciones empleando todos los criterios definidos en el capítulo 2 (#COL, #NFZ, ET, MYOP, SMOOTH, FUEL).

Las matrices de comparación entre algoritmos que se muestran en la Ilustración 36 son las obtenidas aplicando el test de Mann-Whitney/Wilcoxon mediante la comparación directa del ET. No se incluye el conjunto de matrices obtenidas empleando la relación de dominación basada en el conjunto completo de criterios del problema MTS ya que, como se advierte al inicio del apartado 5.2, este segundo método ofrece resultados mucho menos definidos, en los que se dan muy pocos casos de algoritmos mejores que otros. En cualquier caso, se entiende que la comparación única del ET devuelve resultados representativos, teniendo en cuenta que el principal objetivo que se persigue en el problema MTS consiste en la optimización del ET, y considerando que el funcionamiento de todas las versiones del GA Multi-etapa ya penaliza lo suficientemente los criterios #COL y #NFZ como para que la probabilidad de que una ejecución de cualquiera de dichas versiones devuelva una solución que incluya colisiones o invasiones de NFZs sea muy escasa.

La Tabla 16 muestra las cantidades totales de veces en las que cada versión del algoritmo basada en una de las codificaciones es mejor o peor que otra, de acuerdo con los resultados expuestos en la Ilustración 36.

Codificación	Mejor que otra	Peor que otra
1	1	28
2	11	13
3	7	17
4	25	0
5	19	6
6	12	12

Tabla 16 - Resultados totales de comparación entre todas las versiones del GA Multi-etapa

Se observa en los valores totales de la Tabla 16 que la versión del algoritmo GA Multi-etapa que mejores resultados ofrece es sin ninguna duda la basada en la Codificación 4 (variaciones simultáneas de las tres variables de control de los UAVs), ya que es mejor que otras versiones un total de 25 veces (el valor máximo que se podría obtener es de 30) y nunca es peor que otra versión. Por otra parte, la versión que peores resultados ofrece es la basada en la codificación original

(Codificación 1, variaciones sólo de dirección de los UAVs), que solo es mejor que otra versión en 1 ocasión y es peor que otras versiones un total de 28 veces.

Resulta interesante incluir, a modo informativo, las trayectorias obtenidas como resultado de la ejecución de la mejor versión del algoritmo (la basada en la Codificación 4). Sin embargo, al realizarse un total de 20 ejecuciones para cada uno de los escenarios, no es posible mostrar una representación gráfica de todas las soluciones, por lo que se ha optado por incluir únicamente una solución correspondiente a cada uno de los escenarios, las cuales pueden verse en el anexo 2.

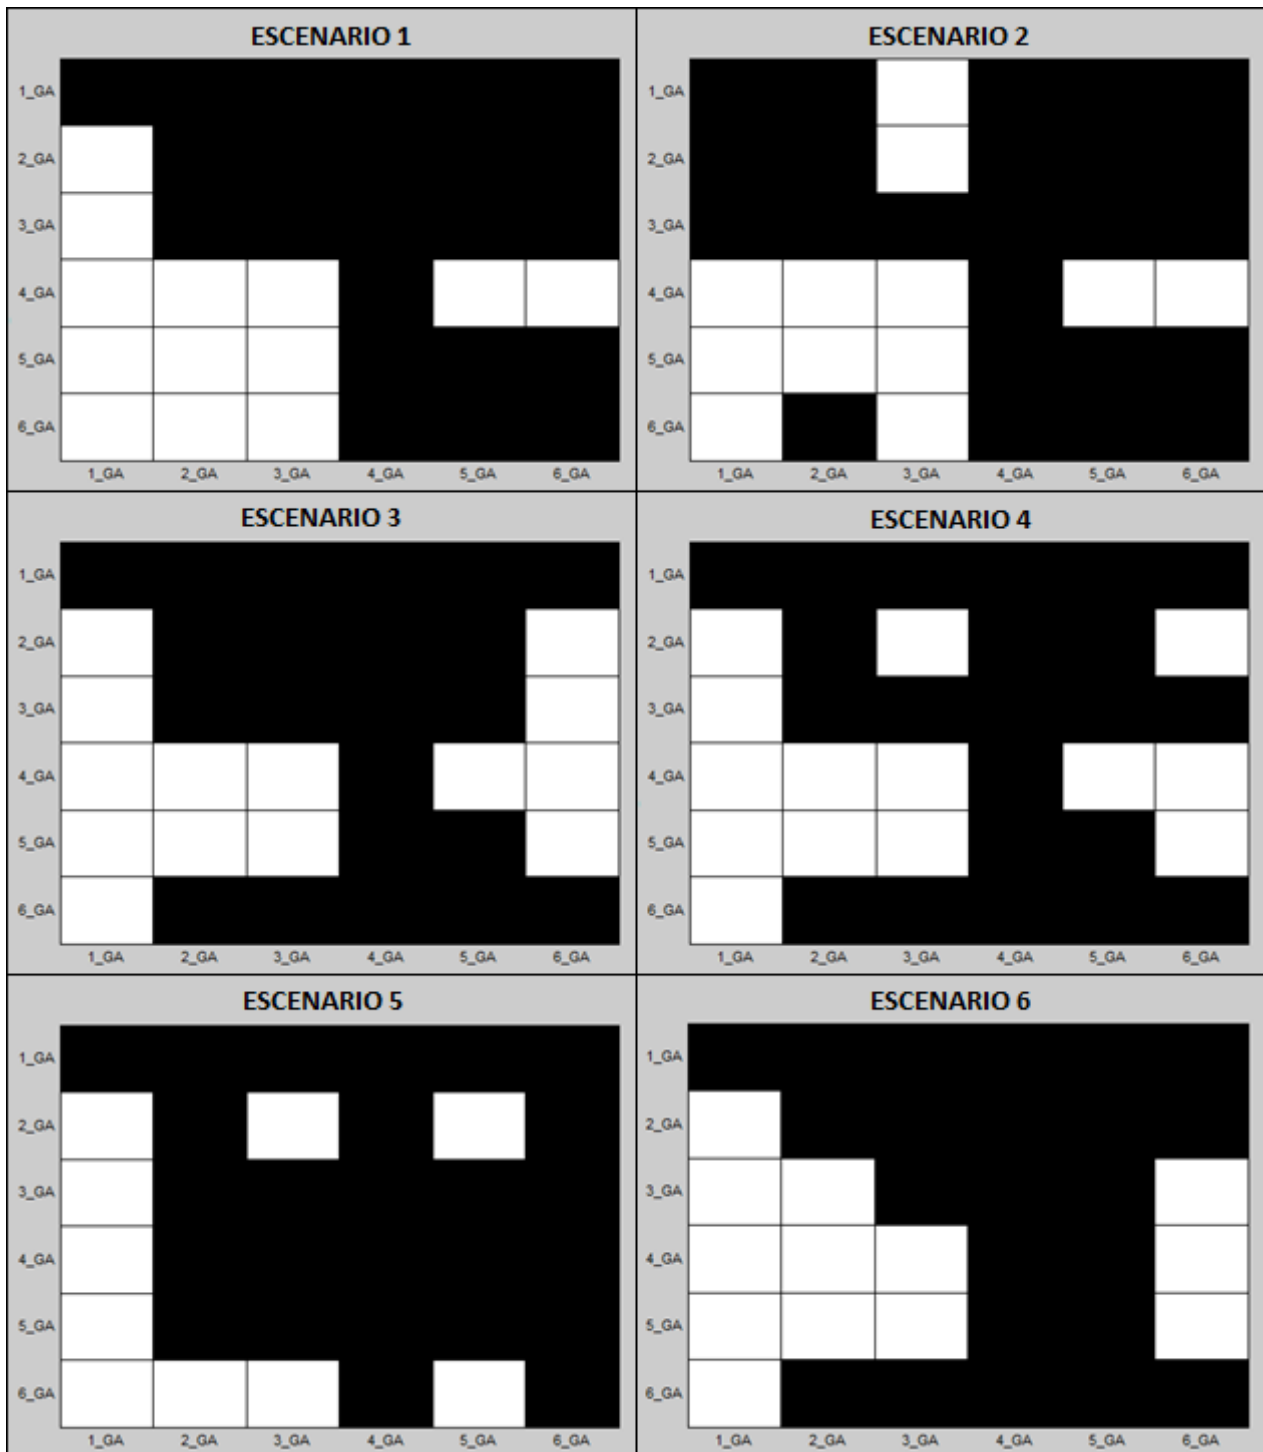


Ilustración 36 - Matrices de comparación obtenidas en las pruebas cuantitativas

Tal y como ya se indicaba en los apartados 4.1.3 y 4.1.4, las Codificaciones 4 y 5 se estudian en este Trabajo de Fin de Máster desde un punto de vista teórico ya que la forma estándar de vuelo del tipo de UAVs modelado en esta versión del problema MTS no contempla la posibilidad de modificar de forma simultánea más de una de las tres variables de control (dirección θ , altura h , velocidad v) del UAV. Es destacable que los resultados mostrados en la Tabla 16 indican que la segunda mejor versión del algoritmo, por detrás de la basada en la Codificación 4, es precisamente la que se basa en la Codificación 5, que es mejor que las otras versiones 19 veces y solo es peor en 6 ocasiones.

Dada esta circunstancia, se considera de interés realizar una nueva evaluación de los resultados totales sin incluir en ellos las codificaciones estudiadas solo desde el punto de vista teórico (es decir, las Codificaciones 4 y 5). Los resultados de este segundo análisis se muestran en el siguiente apartado.

5.2.2.2 Comparativa de codificaciones sin variaciones simultáneas de variables de control

Se muestra a continuación la Tabla 17, en la que se pueden ver las cantidades totales de veces que las versiones del algoritmo basadas en las Codificaciones 1, 2, 3 y 6 son mejores o peores que alguna otra de ellas. Estas cuatro codificaciones, a diferencia de las Codificaciones 4 y 5, solo permiten la variación de una de las variables de control del UAV en cada instante.

Codificación	Mejor que otra	Peor que otra
1	1	16
2	10	3
3	7	7
6	11	4

Tabla 17 - Resultados totales de comparación entre las versiones del GA Multi-etapa basadas en codificaciones no teóricas

En este otro caso, se observa que las versiones basadas en las Codificaciones 2 y 6 obtienen unos resultados muy similares, haciendo imposible en principio seleccionar una de ellas como la mejor. Se decide desglosar los resultados de las Codificaciones 2 y 6 por escenario, como se puede ver en la Tabla 18.

Codificación	Escenario	Mejor que otra	Peor que otra
2	1	1	1
	2	1	0
	3	2	0
	4	3	0
	5	2	1
	6	1	1
6	1	3	0
	2	2	0
	3	1	2

	4	1	1
	5	3	0
	6	1	1

Tabla 18 – Resultados por escenario de las versiones del GA Multi-etapa basadas en las Codificaciones 2 y 6

Se puede ver en la Tabla 18 que la versión del algoritmo basada en la Codificación 2 destaca especialmente en los escenarios 3 y 4, mientras que la versión basada en la Codificación 6 resulta mejor en los escenarios 1, 2 y 5. Los escenarios 3 y 4 se caracterizan por zonas de alta probabilidad de presencia del objetivo muy alargadas y muy anchas respectivamente, mientras que por el contrario los escenarios 1, 2 y 5 presentan zonas de alta probabilidad de presencia del objetivo puntuales y bastante separadas.

Esto parece coincidir con el hecho de que la versión basada en la Codificación 2, al permitir todo tipo de variaciones de las variables de control de los UAVs en cualquier punto de la trayectoria, puede ofrecer a estos la libertad de movimiento necesaria para explorar zonas en general amplias de alta probabilidad de presencia del objetivo como las de los escenarios 3 y 4. Por otra parte, el tipo de trayectorias basadas en subsecuencias generadas mediante la versión basada en la Codificación 6 parece resultar más apropiado para explorar escenarios con zonas puntuales y distantes entre sí de alta probabilidad de presencia del objetivo, como las de los escenarios 1, 2 y 5, que deben visitarse una tras otra. La Codificación 6 permite generar trayectorias formadas por subsecuencias de cambios de velocidad v o altura h en tramos de la trayectoria rectos que vayan desde una de estas zonas puntuales de alta probabilidad a otra, combinadas con subsecuencias de cambios de dirección θ para encarar el UAV hacia la siguiente zona una vez se haya recogido toda la creencia de la zona anterior.

Cabe pensar, por tanto, que los algoritmos basados en las versiones 2 y 6 puedan ofrecer cada uno de ellos un mejor rendimiento que el otro en función de las características del escenario y que de alguna manera sean complementarios, si bien la demostración de este hecho requiere un estudio más amplio basado en un mayor número de escenarios y en la variación de la parametrización de los mismos, lo que excede el ámbito de este Trabajo de Fin de Máster. En cualquier caso, los resultados de la Tabla 17 permiten ver que la mejoría en las soluciones ofrecidas por cualquiera de estas dos nuevas codificaciones sobre la codificación original (Codificación 1), en la que solo se permitían variaciones de la variable de control dirección θ , es muy grande.

6 Conclusiones

En este capítulo final se revisa primeramente, en base al trabajo realizado y presentado en esta documentación, el grado de consecución de los objetivos que se fijaron para este Trabajo de Fin de Máster en el apartado 1.2. Se exponen luego las conclusiones alcanzadas mediante el análisis de los resultados de las pruebas presentadas en el capítulo 5, proponiéndose por último algunas líneas de trabajo futuras que podría resultar interesante abordar.

6.1 Consecución de objetivos

Se considera que se han cumplido los objetivos marcados al inicio del Trabajo de Fin de Máster tanto en la adaptación del GA Multi-etapa como en la propuesta y análisis de las diferentes codificaciones de soluciones. En concreto:

- Se ha realizado un análisis en profundidad de los diferentes elementos que componen el problema MTS, así como de la solución inicial desarrollada (GA Multi-etapa para trayectorias de dirección variable) y de su implementación existente en el lenguaje Matlab. Este estudio, presentado en los capítulos 2 y 3, constituía un requisito de imprescindible cumplimiento para poder desarrollar los siguientes objetivos.
- Se ha abordado con éxito el desarrollo de un nuevo GA Multi-etapa para trayectorias de dirección, velocidad y altura variables, así como su implementación en el lenguaje Matlab, lo cual ha permitido dar un paso más en la resolución del problema MTS en cuanto al aprovechamiento de todas las capacidades de los UAVs que realizan la búsqueda. Los nuevos operadores de este GA Multi-etapa y las modificaciones a los operadores ya existentes se exponen en el apartado 4.2.
- Se han propuesto e implementado un total de 5 codificaciones de soluciones del problema MTS diferentes para el nuevo GA Multi-etapa, cuya definición se muestra en el apartado 4.1, cumpliéndose por una parte el objetivo de carácter teórico de estudiar la influencia de las codificaciones de soluciones en los resultados de un GA, y afianzándose por otra parte el objetivo práctico ya expuesto de explotar lo máximo posible las posibilidades de manejo de los UAVs.
- Por último, se considera también alcanzado el objetivo final de la realización de pruebas de las soluciones diseñadas y el análisis de sus resultados, al haberse podido extraer conclusiones de dicho análisis de forma cuantitativa. Estas conclusiones, obtenidas a partir del estudio de los resultados de las pruebas presentadas en el capítulo 5, se presentan en el apartado 6.2.

6.2 Conclusiones obtenidas

Los resultados obtenidos en la realización de las pruebas empleando las diferentes versiones del GA Multi-etapa demuestran que los métodos de codificación utilizados en el diseño de un GA influyen decisivamente en la calidad de las soluciones obtenidas. Se puede considerar

que, en realidad, emplear codificaciones diferentes del mismo tipo de solución a un mismo problema equivale a emplear dos algoritmos diferentes, y por tanto la calidad de los resultados ofrecidos debe ser estudiada como si de algoritmos diferentes se tratase a fin de elegir la mejor codificación para el problema en cuestión.

Las mejores versiones del GA Multi-etapa desarrollado han resultado ser con mucha diferencia aquellas basadas en codificaciones que incumplen la forma estándar de vuelo de los UAVs empleados en la versión del problema MTS propuesta (Codificaciones 4 y 5), ya que generan trayectorias basadas en modificaciones simultáneas de varias de las variables de control de los UAVs. Cabe plantear si en la práctica puede resultar interesante permitir a los UAVs realizar este tipo de maniobras a fin de obtener unos mejores tiempos estimados de búsqueda en la resolución del problema MTS, sobre todo teniendo en cuenta que esto implica eliminar una restricción operativa, no inherente al diseño de los UAVs.

Por otro lado, los resultados obtenidos en las pruebas cuantitativas expuestas en el capítulo 5 por el resto de versiones del GA Multi-etapa, que cumplen los estándares de vuelo de los UAVs empleados en esta versión del problema MTS, indican que puede ser interesante aplicar en la práctica una versión u otra del algoritmo (Codificación 2 o Codificación 6) en función del tipo de escenarios que se deban resolver.

En cualquier caso, los resultados de las pruebas evidencian que las versiones del GA Multi-etapa basadas en las nuevas codificaciones que permiten generar trayectorias de dirección, altura y velocidad variables mejoran a la codificación original y resultan por lo tanto más útiles para su aplicación práctica.

6.3 Líneas de trabajo futuras

Se proponen a continuación las siguientes posibles ampliaciones de este Trabajo de Fin de Máster, que permitirían extender o reforzar los resultados obtenidos:

- Estudio de la influencia de la parametrización de los escenarios y del GA Multi-etapa en los resultados obtenidos por las diferentes codificaciones: la influencia de los parámetros que pueden configurarse, tanto a nivel del GA Multi-etapa como del propio escenario de búsqueda, en los resultados que devuelven las diferentes versiones del algoritmo, puede constituir un motivo de estudio en sí mismo. Dada la gran cantidad de combinaciones posibles de parámetros, sería posible que una automatización del análisis devolviese más resultados como los que se extraen en este Trabajo de Fin de Máster acerca de la idoneidad de las codificaciones 2 y 6 para cierto tipo de escenarios.
- Diseño de métricas de escenarios para selección de una versión del algoritmo: en la línea de la ampliación anterior, se podría estudiar el desarrollo de métricas que permitiesen decidir, dado un escenario determinado, qué versión del algoritmo emplear para su resolución. Por ejemplo, una métrica que decidiese si es mejor el empleo de la codificación 2 o de la 6 en función de la topología del modelo probabilístico del objetivo y de la distribución de las NFZs.

- Ampliación o modificación de los criterios heurísticos de evaluación de soluciones del problema MTS: al aumentar la complejidad de las soluciones al problema MTS que generan las nuevas versiones del GA Multi-etapa, por incluir cambios de las tres variables de control de los UAVs, o incluso cambios simultáneos de dichas variables, aumentan también las posibilidades de definir nuevos criterios heurísticos o modificar los ya existentes para valorar dichas soluciones, que pueden emplearse para obtener un GA más eficaz. Dos ejemplos en esta línea serían la ampliación de los criterios SMOOTH y MYOP para que tuvieran en cuenta las nuevas variables de control introducidas (altura h y velocidad v). En el caso de SMOOTH, esto consistiría en penalizar las oscilaciones de estas dos variables durante la trayectoria de la misma forma en la que ya se hace con las de la dirección θ , mientras que MYOP podría ser modificado añadiendo heurísticas que tuviesen en cuenta el estado final de las variables altura h y velocidad v y su influencia en la capacidad del UAV de recolectar la creencia restante del escenario.
- Estudio de codificaciones similares basadas en números enteros: los números reales representados mediante el método de mantisa y exponente solo pueden ofrecer una precisión limitada o, dicho de otra forma, muchos de los números reales sencillamente no son representables mediante este método. Esto hace que el empleo de las partes fraccionarias de este tipo de números, o de una cierta cantidad de dígitos de dichas partes fraccionarias, para codificar las variaciones o incrementos de las variables de control de los UAVs dentro de un rango determinado, produzca un espacio de posibles incrementos no uniforme. El empleo de codificaciones de filosofía similar a las diseñadas en este Trabajo de Fin de Máster, pero estructuradas de forma compacta mediante números enteros de cuya representación binaria se emplee una serie de bits para codificar las variables de control a modificar y otra serie de bits para codificar la magnitud de las variaciones, podría ser una línea a seguir que eliminase los problemas relativos al empleo de números reales en las codificaciones de las soluciones.

Bibliografía

- [1] Alejo Teissière, D., Heredia Benot, G., Ollero Baturone, A., *Planning and coordination of multiple UAVs*, Tesis Doctoral, Universidad de Sevilla, Dpto. Ingeniería de Sistemas y Automática (2015)
- [2] Arce, F., López Orozco, J. A., Besada Portas, E., *Búsqueda de objetivos estáticos en tiempo mínimo mediante programación genética*, TFM, Universidad Complutense de Madrid, Dpto. Arquitectura de Computadores y Automática (2015)
- [3] Barlow, G. J., Oh, C.K., Grant, E., *Incremental evolution of autonomous controllers for unmanned aerial vehicles using multi-objective genetic programming*, Proc. IEEE Int. Conf. on Robotics and Automation (2005)
- [4] Berger, J., Barkaoui, M., *Genetic Algorithm for In-Theatre Military Logistics Search-and-Delivery Path Planning*, International Journal of Computer, Electrical, Automation, Control and Information Engineering, Vol. 7 (11), p. 103-111 (2013)
- [5] Berger J., Jabeur K., Boukhtouta A., Guitouni, A., Ghanmi, A., *A hybrid genetic algorithm for rescue path planning in uncertain adversarial environment*, IEEE Congress on Evolutionary Computation 2010: 1-8 (2010)
- [6] Bernstein, D. S., Givan, R., Immerman, N., Zilberstein, S., *The complexity of decentralized markov decision processes*, Operations Research, 27:819-840 (2002)
- [7] Besada Portas, E., De la Torre, L., Moreno, A., Risco Martín, J. L., *On the performance comparison of multi-objective evolutionary UAV path planners*, Information Sciences Journal, Volume 238, July 2013, p. 111–125 (2013)
- [8] Brown, S. S., *Optimal Search for a Moving Target in Discrete Time and Space*, Operations Research 28:1275-1289 (1980)
- [9] Chaari, I., Koubâa, A., Bennaceur, H., Ammar, A., Al-Shalfan, K., *smartPATH: An Efficient Hybrid ACO-GA Algorithm for Solving the Global Path Planning Problem of Mobile Robots*, International Journal of Advanced Robotic Systems (IJARS), Volume 11, Issue 94 (2014)
- [10] Ding, Y. F., Pan, Q., *Path Planning for Mobile Robot Search and Rescue Based on Improved Ant Colony Optimization Algorithm*, Applied Mechanics and Materials, Vols. 66-68, p. 1039-1044 (2011)
- [11] Eagle, J. N., Yee, J. R., *An Optimal Branch-and-Bound Procedure for the Constrained Path, Moving Target Search Problem*, Operations Research 38(1):110-114 (1990)
- [12] Goldberg, D. E., *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley Longman Publishing (1989)

- [13] Guitouni, A., Belfares, L., *Comparison and Evaluation of Multi-Objective Genetic Algorithms for Military Planning and Scheduling Problems: Applied to Course of Action Planning*, DRDC-VALCARTIER-TR-2003-372 (2008)
- [14] Huertos, F. J., Besada Portas, E., Pérez Carabaza, S., *Optimización de trayectorias de UAVs para la rápida localización de objetivos mediante algoritmos de colonias de hormigas*, TFM, Universidad Complutense de Madrid, Dpto. Arquitectura de Computadores y Automática (2016)
- [15] Lanillos, P., Besada Portas, E., López Orozco, J. A., De la Cruz, J. M., *Minimum Time Search in Uncertain Dynamic Domains with Complex Sensorial Platforms*, Sensors (Basel) 2014 August 4;14(8):14131-14179 (2014)
- [16] Lanillos, P., Besada Portas, E., Pajares, G., Ruz, J. J., *Minimum time search for lost targets using cross entropy optimization*. In Intelligent Robots and Systems (IROS), 2012 IEEE/RSJ International Conference on, pages 602-609. (2012).
- [17] Lanillos P., Gan S. K., Besada Portas, E., Pajares, G., Sukkarieh, S., *Multi-UAV target search using decentralized gradient-based negotiation with expected observation*, Information Sciences Journal, Volume 282, October 2014, p. 92–110 (2014)
- [18] Lanillos, P., Yañez, J., Ruz, J. J., Besada-Portas, E., *A bayesian approach for constrained multi-agent minimum time search in uncertain dynamic domains*, Proc. of the 15th Conf. on Genetic and Evolutionary Computation (GECCO), p. 391-398, July (2013)
- [19] Mitchell, M., *An Introduction to Genetic Algorithms (Complex Adaptive Systems)*, A Bradford Book (1998)
- [20] Morin, M., Lamontagne, L., Abi-Zeid, I., Maupin, P., *The Ant Search Algorithm: An Ant Colony Optimization Algorithm for the Optimal Searcher Path Problem with Visibility*, Proceedings of the 23rd Canadian conference on Advances in Artificial Intelligence, p. 196-207, Ottawa, Canada, May-June (2010)
- [21] Pérez Carabaza, S., Besada Portas, E., López Orozco, J. A., De la Cruz, J. M., *A Real World Multi-UAV Evolutionary Planner for Minimum Time Target Detection*, Proceedings of the Genetic and Evolutionary Computation Conference 2016, p. 981-988 (2016)
- [22] Poli R., Langdon W. B., McPhee N. F., *A Field Guide to Genetic Programming*, Creative Commons (2008)
- [23] Richards, M. D., Whitley, D., Beveridge, J. R., *Evolving cooperative strategies for UAV teams in Proc. Genetic and Evolutionary Computation Conf. - GECCO (2005)*
- [24] Ruini, F., Cangelosi, A., Zetule, F., *Individual and Cooperative Tasks performed by Autonomous MAV Teams driven by Embodied Neural Network Controllers*, Proceedings of International Joint Conference on Neural Networks, Atlanta, Georgia, USA, June 14-19 (2009)

- [25] Sáez, E., Besada Portas, E., López Orozco, J. A., *Sistema de rescate de náufragos basado en redes neuronales para la coordinación de vehículos aéreos*, TFM, Universidad Complutense de Madrid, Dpto. Arquitectura de Computadores y Automática (2012)
- [26] Stewart, T. J., *Experience with a Branch-and-Bound Algorithm for Constrained Searcher Motion*, Plenum Press, New York (1980)
- [27] Stone, L. D., *Theory of optimal search*, Academic Press, New York (1975)
- [28] Stone, L. D., *What's Happened in Search Theory Since the 1975 Lanchester Prize?*, Operations Research 37(3):501-506 (1989)
- [29] Trummel, K. E., Weisinger, J. R., *The complexity of the optimal searcher path problem*, Operations Research, 34(2):324-327 (1986)
- [30] Washburn, A. R., *Search for a Moving Target: the FAB Algorithm*, Operations Research 31:739-751 (1983)
- [31] Wei, X., *Robot Path Planning Based on Simulated Annealing and Artificial Neural Networks*, Research Journal of Applied Sciences, Engineering and Technology Vol. 6 (1):149-155 (2013)
- [32] Xiang, T., Pan, D., *An Improved Particle Swarm Optimization for Vehicle Routing Problem*, International Journal of Emerging Technology and Advanced Engineering, Volume 6, Issue 5, May (2016)
- [33] Yáñez, F. J., Besada-Portas, E., Lanillos, P., *Técnicas Heurísticas para la Búsqueda en Tiempo Mínimo (Comparativa)*, TFM, Universidad Complutense de Madrid, Dpto. Arquitectura de Computadores y Automática (2014)
- [34] Yavuz, K., *Multi-Objective Mission Route Planning Using Particle Swarm Optimization*, Thesis, Air Force Institute of Technology Graduate School of Engineering and Management, R.N. AFIT/GCE/ENG/02M-04 (2002)

Siglas, abreviaturas y acrónimos

MTS: búsqueda en tiempo mínimo (Minimum Time Search)

UAV: vehículo aéreo no tripulado (Unmanned Aerial Vehicle)

NFZs: zonas de vuelo prohibido (Non-Flying Zones)

GA: algoritmo genético (Genetic Algorithm)

MSGGA: algoritmo genético multi-etapa (Multi-Stepped Genetic Algorithm)

GP: programación genética (Genetic Programming)

NN: redes neuronales (Neural Networks)

ACO: optimización de colonia de hormigas (Ant Colony Optimization)

BOA: algoritmo de optimización Bayesiana (Bayesian Optimization Algorithm)

EDA: algoritmo de estimación de distribución (Estimation of Distribution Algorithm)

CEO: optimización de entropía cruzada (Cross-Entropy Optimization)

ET: tiempo estimado de detección (Expected detection Time)

MYOP: miopía (MYOPia)

Anexo 1 - Correspondencia de funciones Matlab

Se señalan en color azul las funciones modificadas y en rojo las funciones añadidas en el desarrollo del GA Multi-etapa para trayectorias de dirección, altura y velocidad variables descrito en el capítulo 4.

Modelos de elementos del problema MTS

Modelo	Función/es Matlab
Modelo del objetivo	<i>Models/Targets/Belief/*.m</i>
Modelo del sensor	<i>Models/UAVs/Payload/*.m</i>
Modelo cinemático de los UAVs	<i>Models/UAVs/Motion/UAVSimple/AvionSencilloP.mdl</i> <i>Models/UAVs/Motion/UAVSimple/AvionSencilloPMultiVariable.mdl</i> <i>Models/UAVs/Motion/UAVSimple/simUAV_P.m</i>
Criterio ET	<i>Strategies/JletNew.m</i>
Criterio MYOP	<i>Strategies/JletNew.m</i>
Criterio #COL	<i>Algorithm/Continuous/Common/Problem/evaluate_samples.m</i>
Criterio #NFZ	<i>Algorithm/Continuous/Common/Problem/evaluate_samples.m</i>
Criterio FUEL	<i>Algorithm/Continuous/Common/Problem/evaluate_samples.m</i>
Criterio SMOOTH	<i>Algorithm/Continuous/Common/Problem/evaluate_samples.m</i>
Definición del problema MTS	<i>Data/Scenarios/M/*.m</i>

Tabla 19 - Modelos de elementos del problema MTS

Operadores de los GA Multi-etapa

Operador	Función/es Matlab
Configuración de parámetros	<i>Algorithms/Continuous/GA/AlgorithmContinuous_GA_Config.m</i>
Bucle principal	<i>Algorithms/Continuous/GA/Problem/AlgorithmContinuous_GA_Main.m</i>
Operador de Inicialización	<i>Algorithms/Continuous/GA/Problem/AlgorithmContinuous_GA_Main.m</i>
Evaluación de individuos	<i>Algorithm/Continuous/Common/Problem/evaluate_samples.m</i>
Operador de Selección	<i>Algorithm/Continuous/GA/Toolbox/Selection/GASelectionMTS.m</i> <i>Algorithms/Continuous/Common/Problem/preprocessValues.m</i>
Operador de Cruce	<i>Algorithm/Continuous/GA/Toolbox/Crossover/GACrossoverPoint.m</i> <i>Algorithm/Continuous/GA/Toolbox/Crossover/GACrossoverPointKeepingSequences.m</i>
Operador de Mutación	<i>Algorithm/Continuous/GA/Toolbox/Mutation/GAMutation.m</i> <i>Algorithm/Continuous/GA/Toolbox/Mutation/GAMutationClassic.m</i> <i>Algorithm/Continuous/GA/Toolbox/Mutation/GAMutationKeepingSequences.m</i>
Operador de Recombinación	<i>Algorithm/Continuous/GA/Toolbox/Selection/GARecombineMTS.m</i>

Tabla 20 - Operadores de los GA Multi-etapa

Anexo 2 - Ejemplos de soluciones a los escenarios de las pruebas cuantitativas empleando la Codificación 4

Se muestra a continuación un ejemplo de trayectoria solución obtenida mediante la mejor versión del GA Multi-etapa, basada en la Codificación 4, para cada uno de los escenarios diseñados para la realización de las pruebas cuantitativas.

Escenario 1

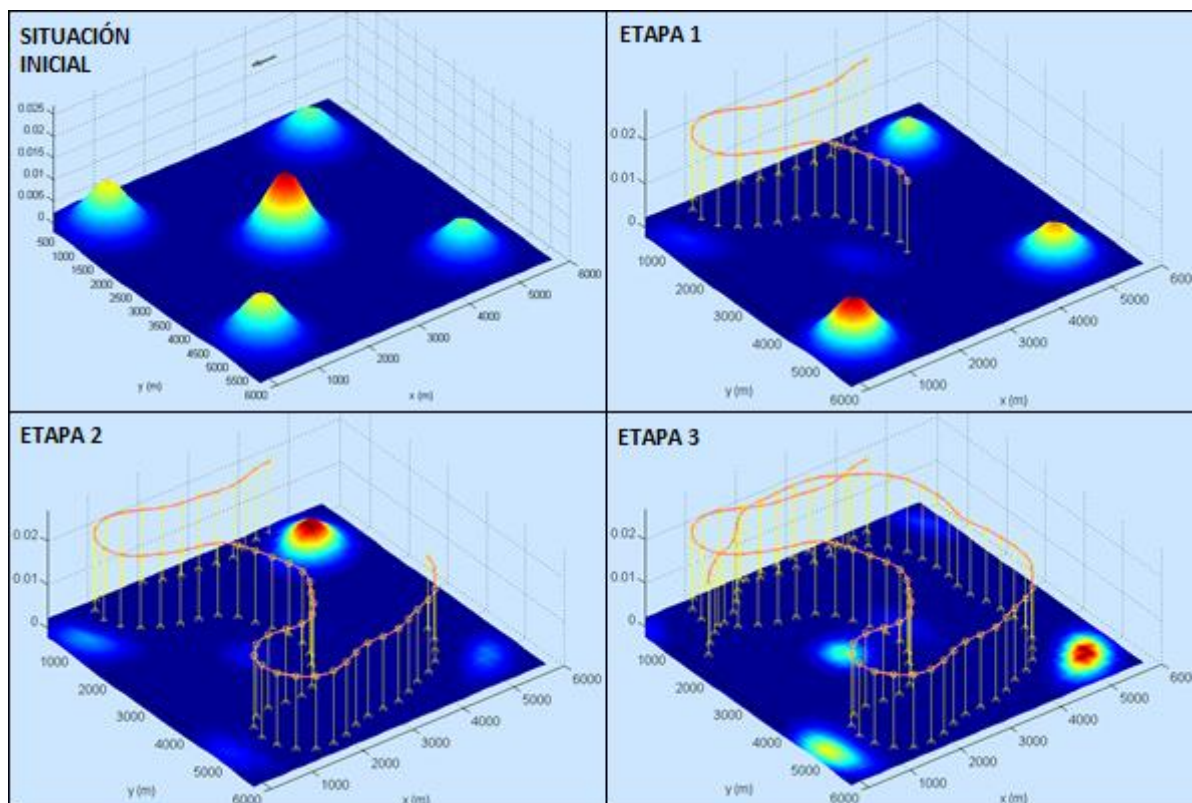


Ilustración 37 - Ejemplo de solución al Escenario 1

Escenario 2

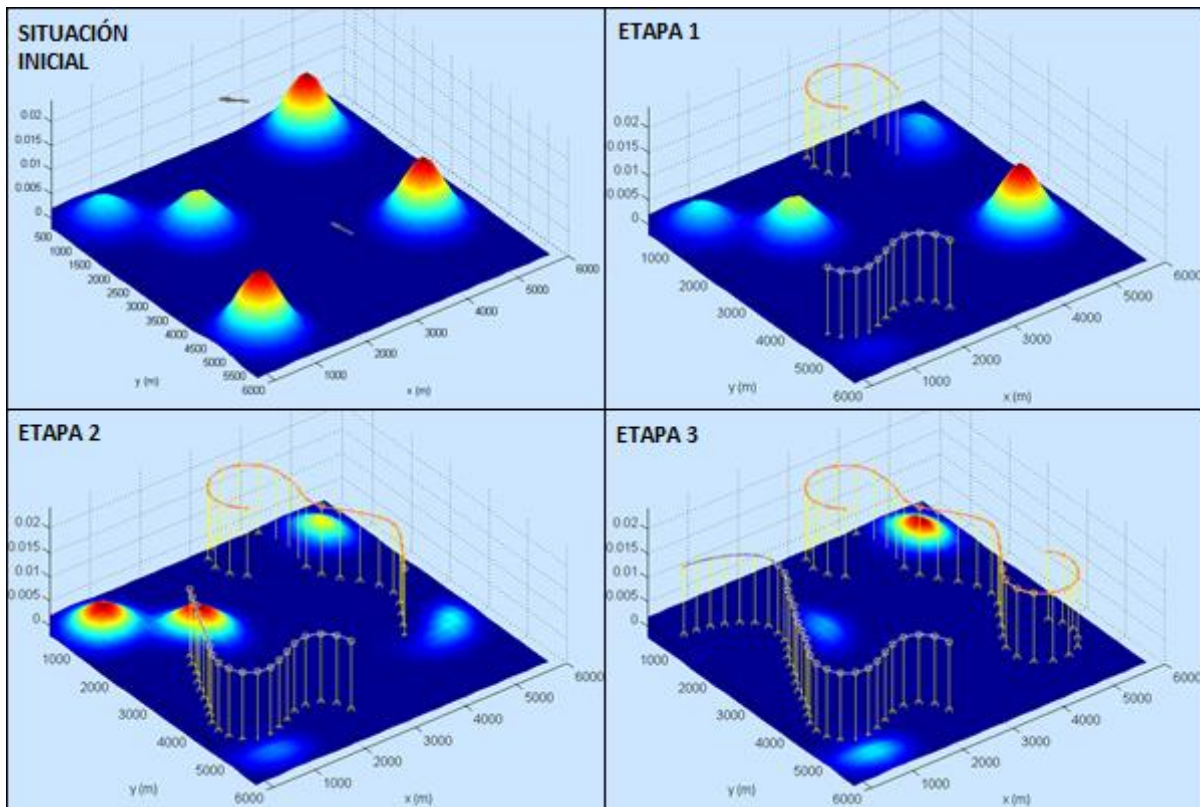


Ilustración 38 - Ejemplo de solución al Escenario 2

Escenario 3

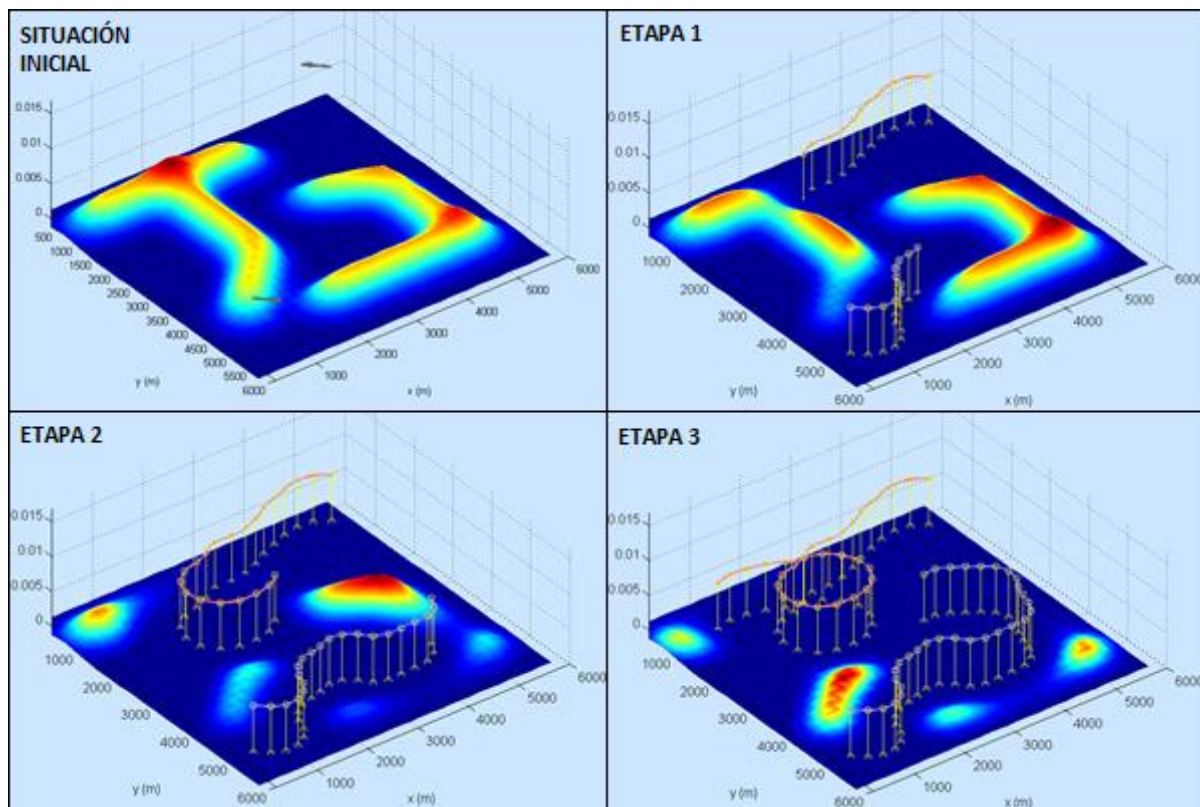


Ilustración 39 - Ejemplo de solución al Escenario 3

Escenario 4

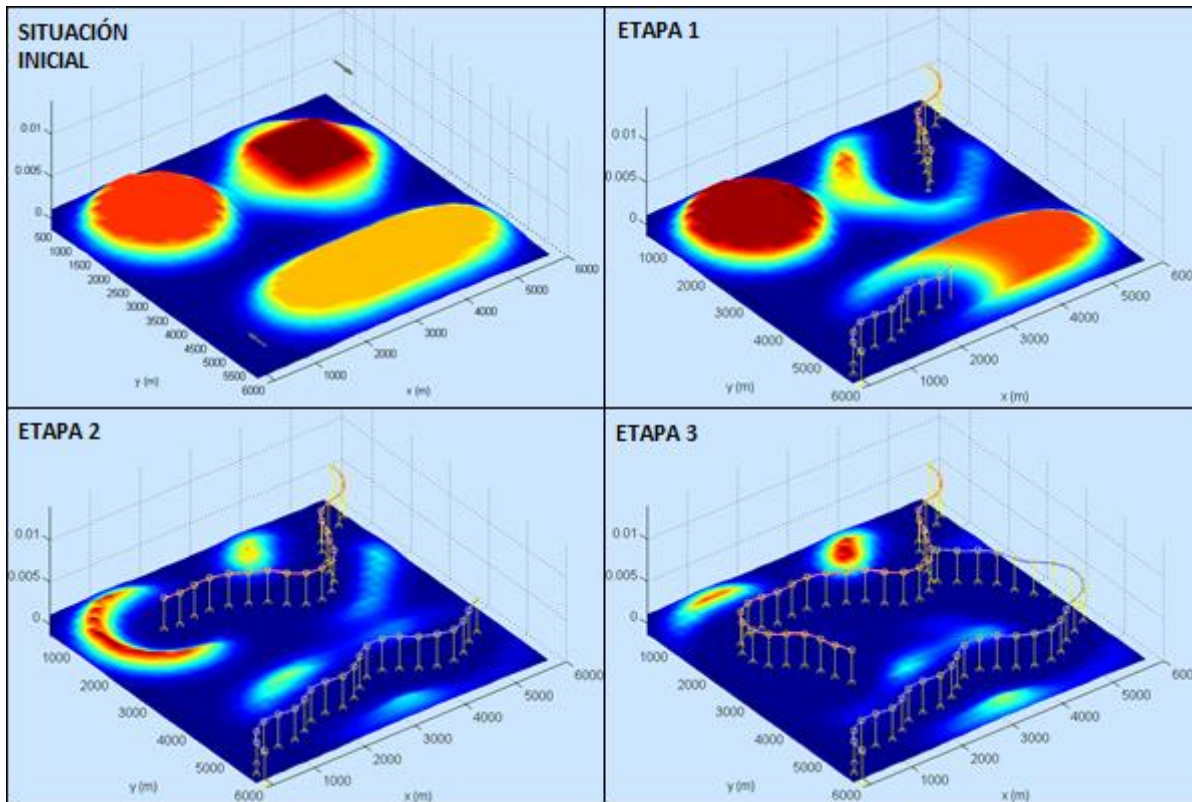


Ilustración 40 - Ejemplo de solución al Escenario 4

Escenario 5

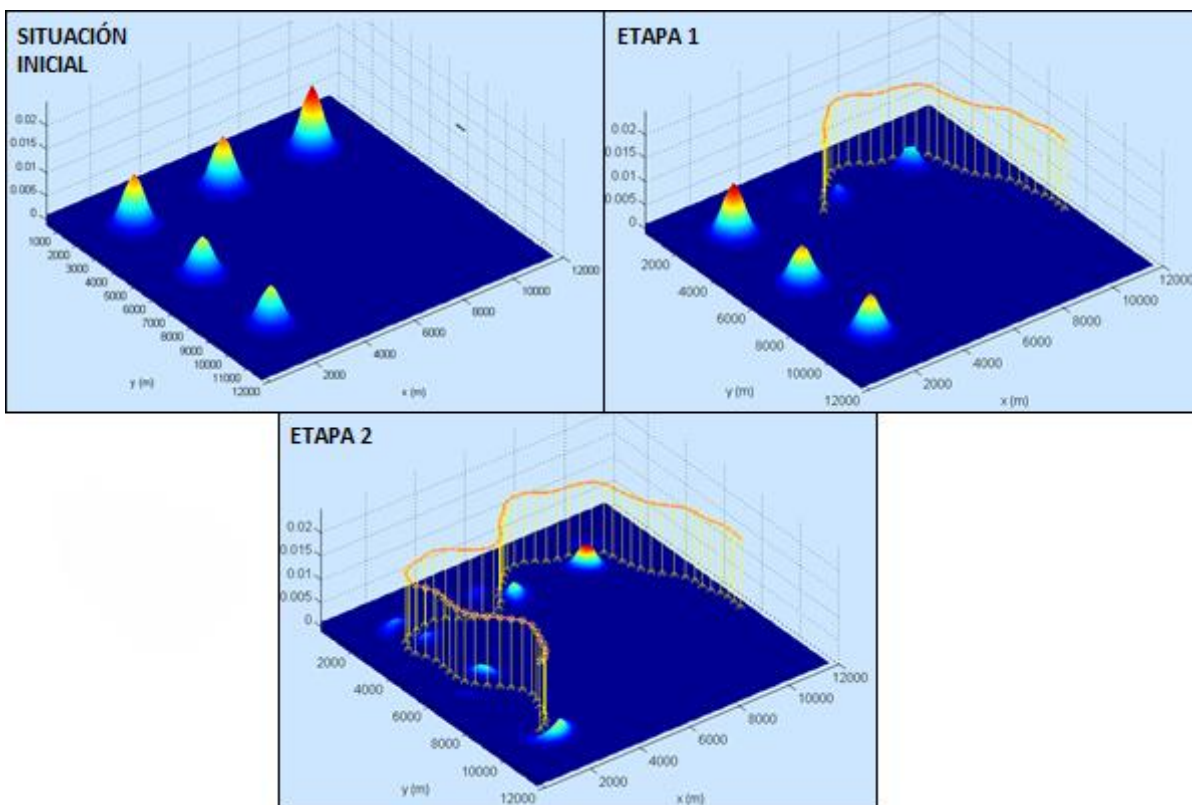


Ilustración 41 - Ejemplo de solución al Escenario 5

Escenario 6

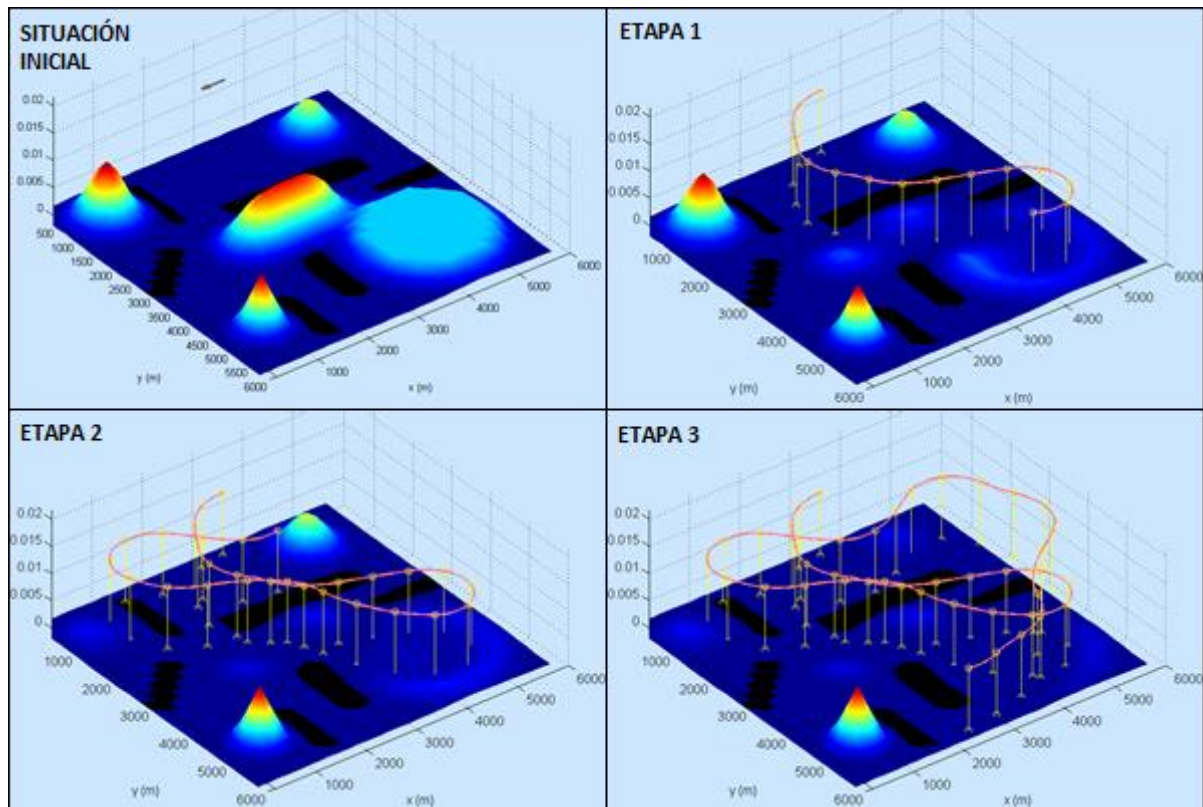


Ilustración 42 - Ejemplo de solución al Escenario 6