

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS
INDUSTRIALES Y DE TELECOMUNICACIÓN

UNIVERSIDAD DE CANTABRIA



Trabajo Fin de Grado

**SELECCIÓN DE ANTENAS EN UN SISTEMA
MIMO MASIVO DISTRIBUIDO PARA
COMUNICACIONES 5G UTILIZANDO EL
ALGORITMO DE DANDELION**

Antenna selection in a distributed massive MIMO
system for 5G wireless communications using the
Dandelion algorithm

Para acceder al Título de

Graduado en

Ingeniería de Tecnologías de

Telecomunicación

Autor: Álvaro Santiago Gómez

Marzo – 2024



E.T.S. DE INGENIEROS INDUSTRIALES Y DE TELECOMUNICACION

**GRADUADO EN INGENIERÍA DE TECNOLOGÍAS DE
TELECOMUNICACIÓN**

CALIFICACIÓN DEL TRABAJO FIN DE GRADO

Realizado por: Álvaro Santiago Gómez

Director del TFG: Jesús Ramón Pérez López

Título: “Selección de antenas en un sistema MIMO masivo distribuido para comunicaciones 5G utilizando el algoritmo de Dandelion”

Title: “Antenna selection in a distributed massive MIMO system for 5G wireless communications using the Dandelion algorithm”

Presentado a examen el día: 8 de Marzo de 2024

para acceder al Título de

**GRADUADO EN INGENIERÍA DE TECNOLOGÍAS DE
TELECOMUNICACIÓN**

Composición del Tribunal:

Presidente:

Secretario:

Vocal:

Este Tribunal ha resuelto otorgar la calificación de:

Fdo.: El Presidente

Fdo.: El Secretario

Fdo.: El Vocal

Fdo.: El Director del TFG
(sólo si es distinto del Secretario)

Vº Bº del Subdirector

Trabajo Fin de Grado Nº
(a asignar por Secretaría)

Resumen

El uso de agrupaciones de antenas en el contexto de los así denominados sistemas MIMO (multiple-input multiple-output) masivo, juega un papel determinante en el desarrollo de los nuevos sistemas de comunicaciones móviles de quinta generación (5G). En este trabajo de fin de grado se aplica un método de naturaleza heurística a la optimización del conjunto de antenas a mantener activas en un sistema MIMO distribuido, tomando como referencia los resultados de simulaciones previas realizadas en un entorno de interior de la Universidad de Cantabria. Frente a los esquemas MIMO masivo concentrados (C-mMIMO), donde todos los elementos radiantes se encuentran en el emplazamiento de la estación base, se plantea considerar una configuración con antenas potenciales distribuidas sobre la planta del edificio (D-mMIMO), introduciendo herramientas que permitan optimizar qué antenas, del conjunto inicial, deben mantenerse activas para dar servicio con la misma calidad a un conjunto potencial de usuarios. En definitiva, tomando como referencia los resultados para el sistema C-mMIMO en términos de eficiencia espectral y equidad en el reparto de recursos entre usuarios, se plantea un problema de selección de antenas para el caso distribuido, donde utilizando un algoritmo de optimización deberá encontrarse la configuración óptima de antenas a activar en el D-mMIMO para igualar al sistema C-mMIMO de referencia.

Para resolver este problema, se ha utilizado un método heurístico basado en el algoritmo Dandelion (DO), que se inspira en el fenómeno natural del vuelo y dispersión de las semillas del diente de león. El DO imita a nivel computacional el movimiento iterativo de un conjunto de semillas (cada semilla es un vector binario que representa a una solución potencial de la configuración de antenas del sistema D-mMIMO). El movimiento de las semillas está influenciado por el clima, añadiendo de esta manera aleatoriedad al optimizador y mejorando su capacidad de exploración. Los resultados obtenidos muestran que el DO es capaz de encontrar soluciones óptimas para el sistema D-mMIMO, logrando un rendimiento similar al sistema C-mMIMO, pero con un menor número de antenas activas, conllevando una serie de ventajas, como una mejora de la eficiencia energética de la red y una mayor flexibilidad en su despliegue.

Summary

The use of antenna arrays in the context of so-called massive multiple-input multiple-output (MIMO) systems plays a key role in the development of the new fifth generation (5G) mobile communications systems. In this work, a heuristic method is applied to the optimisation of the set of antennas to be kept active in a distributed MIMO system, taking as a reference the results of previous simulations carried out in an indoor environment at the University of Cantabria. In contrast to concentrated massive MIMO schemes (C-mMIMO), where all the radiating elements are located at the base station site, it is proposed to consider a configuration with potential antennas distributed over the building floor (D-mMIMO), introducing tools to optimise which antennas, from the initial set, should be kept active in order to provide service with the same quality to a potential set of users. In short, taking as a reference the results for the C-mMIMO system in terms of spectral efficiency and fairness in the distribution of resources among users, an antenna selection problem is posed for the distributed case, where, using an optimisation algorithm, the optimal configuration of antennas to be activated in the D-mMIMO must be found in order to match the reference C-mMIMO system.

To solve this problem, a heuristic method based on the Dandelion (DO) algorithm, which is inspired by the natural phenomenon of dandelion seed flight and dispersal, has been used. The DO computationally mimics the iterative movement of a set of seeds (each seed is a binary vector representing a potential solution of the antenna configuration of the D-mMIMO system). The movement of the seeds is influenced by the weather, thus adding randomness to the optimiser and improving its exploration capability. The results obtained show that the DO is able to find optimal solutions for the D-mMIMO system, achieving similar performance to the C-mMIMO system, but with a smaller number of active antennas, leading to several advantages, such as improved energy efficiency of the network and greater flexibility in its deployment.

Agradecimientos

*A mi familia y amigos por su apoyo.
Al grupo de Ingeniería De Sistemas, Antenas Y
Radiopropagación (GISAR) y en especial a Jesús R. Pérez
por su ayuda y dedicación.*

Índice

	Página
Capítulo 1	1
Introducción	1
1.1 Utilidad de los algoritmos metaheurísticos	1
1.2 Objetivos y estructura del documento	3
Referencias	5
Capítulo 2	6
Sistemas 5G y MIMO : características y desafíos	6
2.1 Introducción al 5G	6
2.2 Sistemas MIMO	8
2.3 Rendimiento de los sistemas MIMO	12
2.4 C-mMIMO y D-mMIMO	15
2.5 Planteamiento del problema	16
Referencias	19
Capítulo 3	21
Algoritmo de Dandelion:	21
3.1 Un proceso natural con potencial en la optimización	21
3.2 Optimización de la configuración de antenas	23
3.3 Fundamentos matemáticos del DO	24
3.3.1 Inicialización del DO	24
3.3.2 Fase de ascenso	25
3.3.3 Fase de descenso	30
3.3.3 Fase de aterrizaje	32
3.4 Función de coste	33
3.5 Diagrama de flujo	34
Referencias	36
Capítulo 4	37
Resultados	37
4.1 Escenario de interés	37
4.2 Comparativa de los sistemas MIMO	39

4.3 Parámetros del algoritmo	40
4.3.1 Tamaño de la población	41
4.3.2 Número máximo de iteraciones	42
4.3.3 Otros parámetros	42
4.4 Análisis de los resultados	43
4.4.1 Análisis comparativo de la eficiencia espectral y JFI	43
4.4.2 Análisis cuantitativo de los resultados	47
Referencias	52
Capítulo 5	53
Conclusiones y líneas futuras	53

Figuras

Capítulo 1	1
Figura 1.1 Clasificación de los algoritmos metaheurísticos.	2
Capítulo 2	5
Figura 2.1 Representación gráfica de las características IMT-2020 frente a IMT-advanced.	7
Figura 2.2 Representación gráfica de ambos enfoques.	16
Capítulo 3	21
Figura 3.1 Estructura con detalle de las partes de la semilla.	22
Figura 3.2 Diagrama de flujo simplificado del proceso.	23
Figura 3.3 Evolución del parámetro de acuerdo al número de iteraciones [1].	27
Figura 3.4 Evolución del parámetro de acuerdo al número de iteraciones [1].	29
Figura 3.5 Representación gráfica de la fase de ascenso [1].	30
Figura 3.6 Representación gráfica de la fase de descenso [1].	31
Figura 3.7 Representación gráfica de la fase de aterrizaje [1].	33
Figura 3.8 Diagrama de flujo del DO	35
Capítulo 4	37
Figura 4.1 Vista vertical de la planta 0 de la ETSIIT.	38
Figura 4.2 Entrada principal ETSIIT.	38
Figura 4.3 Pasillo ETSIIT.	38
Figura 4.4 Eficiencia espectral de ambos sistemas con 100 antenas activas.	39
Figura 4.5 Jain's Fairness Index (JFI) de ambos sistemas con 100 antenas activas.	40
Figura 4.6 Curvas de convergencia del algoritmo para distintos tamaños de población. (P=20, P=25, P=30, P=35, P=40)	42
Figura 4.7 Distribución de los usuarios (UTs) en las 4 configuraciones escogidas (20, 15, 10 y 5).	43
Figura 4.8 CDFs de la SE y JFI de los sistemas D-mMIMO optimizado, C-mMIMO y el canal Rayleigh (15 y 20 UTs)	45
Figura 4.9 CDFs de la SE y JFI de los sistemas D-mMIMO optimizado, C-mMIMO y el canal Rayleigh (5 y 10 UTs).	46

Figura 4.10 Curvas de convergencia de las simulaciones para los 4 casos. 49

Figura 4.11 Resultados de la optimización sobre la planta de la ETSIIT . 49

Tablas

Tabla 4.1 Fitness (Mín, Máx y promedio), desviación estándar y tiempo de CPU	47
Tabla 4.2 Valores Máx, Mín y Promedio (Nº de antenas, SE y JFI).....	48

Capítulo 1

Introducción

1.1 Utilidad de los algoritmos metaheurísticos

La optimización ha cobrado gran importancia en las últimas décadas en diferentes ámbitos, entre ellos en múltiples aplicaciones en ingeniería, con métodos muy diversos dedicados a abordar la creciente complejidad y diversidad de problemas que se presentan en la actualidad. Estos desafíos, cada vez más caracterizados por la presencia de una multitud de variables y objetivos, demandan soluciones efectivas abordables únicamente en muchos casos recurriendo a métodos de optimización capaces de explorar espacios multidimensionales y altamente multimodales. A pesar de la existencia de algoritmos tradicionales como el método de Newton, el método del descenso y la programación entera, éstos a menudo quedan atrapados en soluciones locales cuando se enfrentan a problemas complejos. Además, estas técnicas requieren que la función objetivo, único vínculo del problema físico a tratar con el algoritmo, sea continua y diferenciable, limitando así su aplicabilidad en la era actual de la optimización universal [1].

En respuesta a estas limitaciones, la incorporación de tecnología estocástica en los métodos de optimización ha dado lugar a una nueva clase de algoritmos conocidos como algoritmos metaheurísticos [1]. Estos algoritmos se caracterizan por su habilidad para introducir aleatoriedad de manera inteligente en la búsqueda de soluciones óptimas. Esta estrategia, respaldada por sofisticadas estrategias de aprendizaje, les otorga la capacidad de escapar de óptimos locales y adaptarse a problemas en los que se dispone de información limitada sobre la función objetivo. Aunque en cierta medida estos métodos distan de ese gran paraguas bajo el que en amplios sectores tecnológicos se está desarrollando con incipiente auge lo que se conoce como inteligencia artificial (IA), en realidad los métodos metaheurísticos combinan diferentes conceptos de la evolución biológica, de procesos naturales, de la propia IA y de los mecanismos estadísticos.

Los algoritmos metaheurísticos han encontrado aplicaciones en diversas áreas, desde el diseño mecánico y la segmentación de imágenes hasta la optimización de parámetros en el diseño de dispositivos de microondas, aplicaciones muy diversas en electromagnetismo, contribución a la planificación de redes inalámbricas, redes de sensores, el aprendizaje profundo o el seguimiento de video, entre otras.

A continuación, en la Figura 1.1 se muestra la clasificación de los algoritmos metaheurísticos inspirados en imitar a nivel computacional procesos naturales de distinta índole. Se pueden

distinguir cuatro grandes categorías y dentro de cada una se recogen algunos de los principales algoritmos aceptados en la literatura.

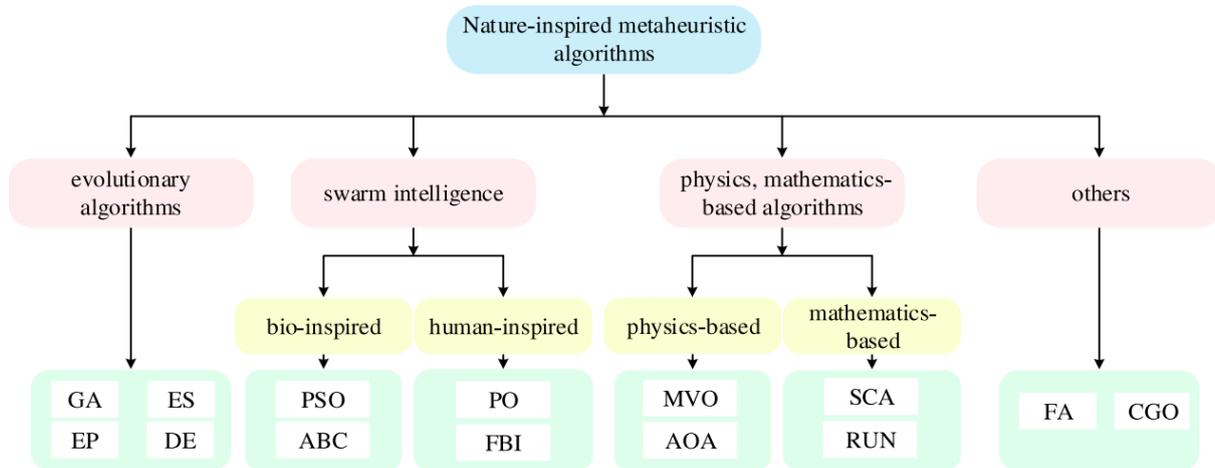


Figura 1.1 Clasificación de los algoritmos metaheurísticos.

La primera categoría que se recoge en la Figura 1.1 incluye los algoritmos evolutivos (AE), que simulan procesos genéticos y de mutación, como los algoritmos genéticos, la programación evolutiva y la evolución diferencial. La segunda categoría abarca los algoritmos de optimización basados en inteligencia colectiva (IC), que se inspiran en comportamientos sociales observados en animales, siendo algunos de los más representativos la optimización por enjambre de partículas (PSO), la colonia artificial de abejas (ABC) y la optimización por colonia de hormigas (ACO). La tercera categoría incluye algoritmos basados en principios físicos o matemáticos, como la optimización multiverso, el algoritmo seno-coseno y el método de la proporción dorada. La cuarta categoría abarca algoritmos inspirados en situaciones de la vida real, como el algoritmo de fuegos artificiales y la optimización del juego del caos [1].

Sin embargo, es importante destacar que los algoritmos metaheurísticos no están exentos de limitaciones. Algunos pueden ser sensibles a problemas de alta dimensionalidad, mostrar convergencia lenta o tener dificultades para equilibrar adecuadamente la exploración y la explotación. Son métodos de búsqueda intensiva donde el tiempo de simulación puede ser el gran inconveniente para su aplicación a problemas que requieran reconfiguraciones o soluciones en tiempo real. Además, el rendimiento final de cada uno de estos algoritmos depende fuertemente de los valores iniciales de los distintos parámetros, tensores que condicionan la búsqueda. De hecho, los “settings” de partida óptimos para su aplicación a diferentes problemas físicos de optimización pueden diferir sensiblemente, lo cual requiere de una puesta a punto del algoritmo para cada problema a tratar. En este contexto, surge la necesidad de desarrollar nuevos algoritmos que mejoren el rendimiento de los ya existentes.

1.2 Objetivos y estructura del documento

En este Trabajo Fin de Grado (TFG) se aborda el estudio y aplicación de métodos heurísticos a la planificación de redes de comunicaciones móviles. En un mundo cada vez más conectado, la comunicación inalámbrica se ha convertido en una columna vertebral de nuestra sociedad. Desde la transmisión de datos a través de dispositivos móviles hasta la implementación de tecnologías emergentes como el Internet de las cosas (IoT) y las redes móviles de quinta generación (5G), la eficiencia y la calidad de las redes de comunicación son fundamentales. En este contexto, las agrupaciones o arrays de antenas desempeñan un papel crítico al permitir una transmisión y recepción de señales más efectivas y confiables.

La optimización de arrays de antenas se ha convertido en un área de investigación crucial para mejorar el rendimiento de las comunicaciones inalámbricas. Como parte de los sistemas de comunicaciones 5G, y frente a los sistemas multiple-input multiple-output (MIMO) clásicos donde las antenas del array están en el emplazamiento de la estación base (BS), recientemente se encuentran trabajos que proponen como alternativa una distribución espacial de las antenas dando lugar a lo que se conoce como cell-free MIMO o, como denominaremos en este TFG, MIMO distribuido (D-mMIMO). Estos sistemas distribuidos están compuestos por múltiples antenas colocadas en ubicaciones estratégicas, lo que ofrece la ventaja de una mayor cobertura y capacidad de procesamiento de señales. Sin embargo, esta ventaja viene acompañada de desafíos significativos en términos de optimización, pudiendo plantear por ejemplo como reto, encontrar aquel conjunto de antenas a mantener activas en un determinado escenario para lograr una calidad de servicio (QoS) preestablecida.

Con todo lo expuesto anteriormente, este TFG se centra en abordar la optimización de arrays de antenas distribuidos, D-mMIMO, mediante el algoritmo Dandelion, con la intención de igualar el rendimiento de un sistema concentrado convencional, consiguiendo de esta manera una reducción del número de antenas activas sin unas pérdidas significativas de rendimiento con respecto al sistema concentrado. El algoritmo Dandelion, de reciente aparición en la literatura técnica, está inspirado en el vuelo a larga distancia de las semillas de diente de león, y ofrece una perspectiva innovadora para resolver problemas de optimización complejos. A diferencia de los enfoques tradicionales, este algoritmo busca un equilibrio entre la exploración y la explotación para encontrar soluciones óptimas en entornos de alta dimensionalidad. La experiencia previa del grupo investigador receptor en la aplicación de métodos de optimización de naturaleza heurística a diversos problemas de síntesis de agrupaciones de antenas e, incluso, con variantes binarias del PSO o de los algoritmos genéticos al problema que se plantea en este TFG, sirven de punto de arranque inicial para afrontar con garantías la aplicación del Dandelion al problema planteado [2].

A lo largo de este trabajo, exploraremos en detalle el algoritmo Dandelion y su aplicación en la optimización de sistemas MIMO distribuidos con el fin de aprovechar sus ventajas frente a los sistemas MIMO concentrados (C-mMIMO). Abordaremos cuestiones cruciales relacionadas con la eficiencia energética, la calidad de señal y otros aspectos fundamentales de las redes de comunicaciones móviles. Además, analizaremos los resultados de nuestras investigaciones y evaluaremos el rendimiento del algoritmo Dandelion en un escenario de

interior, centrando el estudio en el enlace ascendente y en una de las bandas de interés para el despliegue de los sistemas de 5G, la banda de 26 GHz. Considerando como punto de partida los ficheros asociados con simulaciones de ambos sistemas C-mMIMO y D-mMIMO realizadas en el marco de la investigación de otro TFG [3], en este TFG se utilizará esa información de canal para realizar cálculos de eficiencia espectral y desarrollar una función de coste que permita evaluar la calidad de cada solución potencial ofrecida por el algoritmo de Dandelion.

Este TFG no solo busca contribuir al avance de la tecnología, sino también proporcionar una comprensión más profunda de cómo los métodos de optimización inspirados en imitar a nivel computacional procesos de la naturaleza, pueden ayudarnos a abordar desafíos de optimización en aplicaciones prácticas y relevantes. Para dar cumplimiento a los objetivos planteados en el marco de este TFG, el trabajo está organizado en una serie de capítulos distribuidos apropiadamente para tratar los aspectos teóricos y técnicos del mismo. En el Capítulo 2 se incluye una revisión de las características de los sistemas 5G y la teoría asociada con los sistemas MIMO. Como el objetivo central del TFG se centra en aplicar un método metaheurístico al problema bajo estudio, el Capítulo 3 hace una revisión completa del método de Dandelion seleccionado. En el Capítulo 4 se incluyen los resultados más relevantes obtenidos al aplicar la metodología a un problema de referencia. Se incluyen los resultados iniciales dedicados a la parametrización y puesta a punto del algoritmo, así como resultados en los que se intentan comparar, desde diferentes puntos de vista, las prestaciones de los sistemas MIMO concentrado y distribuido, C-mMIMO y D-mMIMO respectivamente. Finalmente, en el capítulo 5 se resumen las principales conclusiones que se pueden extraer de este TFG, así como las líneas futuras que se abren para poder dar continuidad a este trabajo.

Referencias

- [1] Shijie Zhao, Tianran Zhang, Shilin Ma, Miao Chen, “Dandelion Optimizer: A nature-inspired metaheuristic algorithm for engineering applications”, *Engineering Applications of Artificial Intelligence*, Volume 114, 2022, 105075, ISSN 0952-1976, <https://doi.org/10.1016/j.engappai.2022.105075>.
- [2] Jesús R. Pérez, Rafael P. Torres, Luis Valle, Lorenzo Rubio, Vicent M. Rodrigo, Juan Reig, “Selección de antenas mediante algoritmos genéticos en sistemas MIMO masivo distribuido”, XXXVIII Simposio Nacional de la Unión Científica Internacional de Radio (URSI), Cáceres 13-15 septiembre 2023.
- [3] Javier Merino Polidura, “Análisis comparativo de las tecnologías Massive MIMO concentrado y distribuido en entornos de interiores mediante trazado de rayos”, Trabajo Fin de Grado, Universidad de Cantabria, septiembre 2021.

Capítulo 2

Sistemas 5G y MIMO : características y desafíos

2.1 Introducción al 5G

Desde los humildes comienzos de la primera generación (1G) de sistemas de comunicaciones móviles terrestres, que se centraba en comunicaciones de voz con tecnología analógica, hasta la actualidad en la que la quinta generación (5G) ha emergido como una realidad omnipresente, la evolución tecnológica y los servicios ofrecidos al usuario final han experimentado cambios casi inimaginables hace varias décadas. Esta transformación tecnológica ha llevado a un cambio de paradigma, donde las comunicaciones de voz han cedido terreno a servicios multimedia de alta demanda, como el streaming de vídeo y los videojuegos en tiempo real. Estos nuevos usos plantean desafíos sustanciales, desencadenando un período de cambios profundos para los desarrolladores y operadores móviles. El aumento del tráfico de datos, el incremento de las velocidades en las celdas y la baja latencia se erigen como retos significativos en este panorama en constante evolución [1].

En términos cuantitativos, la magnitud del aumento en el tráfico móvil es asombrosa. Nos encontramos ante la realidad de que el tráfico móvil se ha duplicado en los últimos dos años. Este incremento en el tráfico está mayoritariamente impulsado por los dispositivos móviles, especialmente los smartphones.

De acuerdo con las proyecciones más recientes, se anticipa que el 5G va a convertirse en la tecnología líder en términos de suscripciones móviles a nivel global para el año 2027. En ese momento, se espera que aproximadamente la mitad de todas las suscripciones móviles en el mundo sean de 5G, abarcando al 75% de la población global y contribuyendo con el 62% del tráfico total de smartphones a nivel mundial. No obstante, el desafío que afronta esta generación de sistemas de comunicaciones móviles no se limita únicamente al incremento del tráfico. El crecimiento del número de dispositivos conectados también jugará un papel fundamental. Este crecimiento se relaciona con el auge de la tecnología M2M (Machine to Machine), previendo que para el año 2025 haya 16.500 millones de dispositivos conectados [2].

Los pilares esenciales en torno a los cuales se construye el despliegue de la tecnología 5G son el crecimiento exponencial del tráfico de datos y la proliferación de dispositivos conectados.

Sin embargo, surge la pregunta de cuáles son las características que una red debe poseer para ser considerada de quinta generación. Estas especificaciones, que forman parte del estándar de la tecnología 5G, están definidas por la Unión Internacional de Telecomunicaciones (UIT) en el documento IMT-2020. Algunos aspectos de estas especificaciones también se encuentran en la recomendación ITU-R M.2083 publicada en 2015.

Adentrándonos en las características funcionales esenciales de la tecnología 5G, podemos destacar [3]:

- Velocidad máxima Downstream soportable: 20 Gbps
- Velocidad máxima en el Uplink soportable: 10 Gbps
- Velocidad de Downstream en escenarios urbanos el 95% del tiempo: 100 Mbps
- Velocidad en el Uplink en escenarios urbanos el 95% del tiempo: 50 Mbps
- Latencia inferior a 1 ms
- Máxima velocidad de desplazamiento del dispositivo móvil: 500 km/h
- Densidad máxima de dispositivos: 10^6 por km^2 .

A continuación, en la Figura 2.1 se presentan en un diagrama las principales especificaciones de la quinta generación y se subraya el significativo salto tecnológico requerido con respecto a los sistemas de cuarta generación (4G) [3].

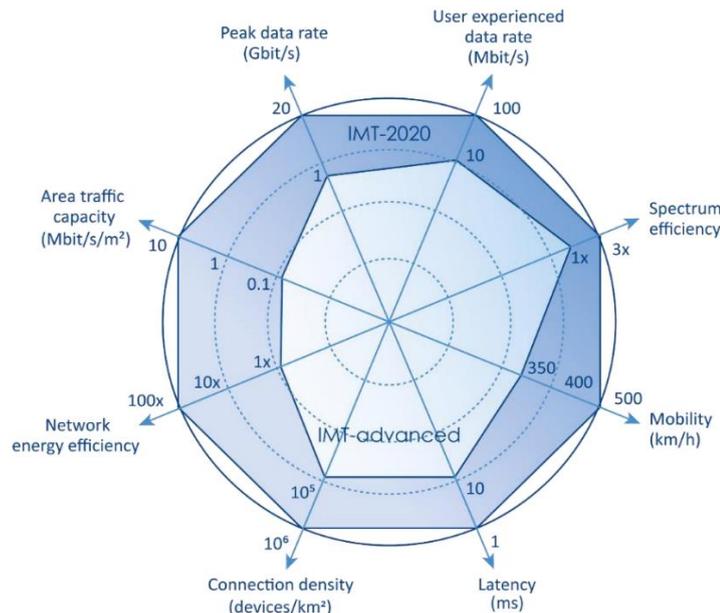


Figura 2.1 Representación gráfica de las características IMT-2020 frente a IMT-advanced [1].

En la evolución de los sistemas de comunicación móvil, al igual que en otros sectores, el avance tecnológico va de la mano de la definición de escenarios de uso que fundamentan y justifican dicho desarrollo. En el caso de la quinta generación, la UIT, a través de la recomendación ITU-R M.2083, ha establecido distintos escenarios de uso que la tecnología 5G deberá atender tras su implementación. A continuación, de manera resumida, se presentan estos tres escenarios:

- eMBB (Enhanced Mobile Broadband): Este escenario se caracteriza por una alta tasa de transferencia de datos generados por una gran densidad de usuarios distribuidos en la celda. Para cumplir con los requisitos de este escenario, se debe lograr una alta eficiencia espectral y eficiencia energética.
- mMTC (Massive Machine-type Communications): Este escenario se enfoca en el Internet de las cosas (IoT), con una gran densidad de conexiones simultáneas de dispositivos de bajo consumo.
- URLLC (Ultra-reliable and Low Latency Communications): Este escenario se centra en la minimización de la latencia, lo que permite una alta movilidad de dispositivos y está orientado a aplicaciones críticas que requieren alta fiabilidad.

La tecnología 5G introduce la idea de utilizar nuevas bandas de frecuencias, algunas de ellas ubicadas mucho más arriba de los 6 GHz, como una estrategia para evitar la congestión en las bandas más bajas, que a menudo están saturadas con otros servicios. Esta congestión dificulta alcanzar las altas velocidades propuestas para el 5G. Por lo tanto, la industria se ve impulsada a buscar nuevas bandas con más espectro libre. Además, es crucial garantizar la compatibilidad de la nueva tecnología 5G con las tecnologías móviles preexistentes.

En resumen, la sección 2.1 proporciona una visión integral de la evolución de las tecnologías móviles, los desafíos a los que se enfrenta el 5G, las especificaciones clave y la importancia de la caracterización del canal radioeléctrico, así como la exploración de nuevas bandas de frecuencias. Estos elementos conforman el panorama tecnológico en constante transformación que define la era del 5G.

2.2 Sistemas MIMO

Debemos destacar la importancia de caracterizar el canal radioeléctrico en la planificación de sistemas de radiocomunicación, especialmente en entornos móviles celulares donde el canal se comporta como un medio altamente dispersivo. El conocimiento preciso del canal desempeña un papel fundamental en el estudio y la planificación de estos sistemas.

En consonancia con los objetivos de la tecnología 5G, uno de los puntos clave es mejorar la eficiencia espectral en un factor de 3x [1], lo cual requiere utilizar el espectro disponible de manera óptima. Esto, a su vez, depende en gran medida de la caracterización precisa del canal radioeléctrico.

El avance hacia la tecnología 5G implica la necesidad de adaptar los métodos de análisis y medición del canal en comparación con las generaciones anteriores, que se centraban en frecuencias por debajo de 6 GHz. La principal mejora radica en la exploración del canal en tres dimensiones, lo que amplía las posibilidades de investigación y desarrollo de técnicas como MIMO y beamforming [4].

La caracterización experimental del canal de radio involucra el procesamiento de datos de medidas del canal para obtener conclusiones sobre el escenario en estudio o desarrollar modelos empíricos que contribuyan al análisis del canal en esos entornos. Un punto de partida importante es el estudio de las pérdidas de propagación del canal, que pueden ayudar a definir modelos de pérdida o perfiles de potencia en función del retardo. Estos perfiles proporcionan información sobre la variabilidad temporal y la capacidad del canal para transmitir diferentes frecuencias, lo que es crucial para sistemas basados en MIMO masivo. Además, en la planificación de nuevos sistemas, es esencial considerar la capacidad y la eficiencia espectral del canal de radio.

La tecnología MIMO (Multiple-Input Multiple-Output) emerge como un componente esencial del 5G, ya que permite cumplir con los altos requisitos de esta quinta generación y maximizar la eficiencia espectral. La caracterización 3D del canal radio se vuelve crucial en sistemas MIMO avanzados, donde la propagación multicamino y su caracterización adecuada son esenciales para aprovechar al máximo las diferentes bandas de frecuencias de interés.

Se pueden identificar tres áreas de investigación para mejorar la eficiencia espectral en las comunicaciones inalámbricas, según la referencia [5]. Estas son:

1. Aprovechamiento de espectro libre o subutilizado.
2. Despliegue de un mayor número de puntos de acceso o células para cubrir áreas más pequeñas, lo que lleva a despliegues de red ultra densos.
3. Utilización de nodos o estaciones base y terminales móviles equipados con múltiples antenas.

En este contexto, si se desea utilizar el espectro radioeléctrico disponible en frecuencias por encima de los 6 GHz [6], la utilización de estas nuevas bandas de frecuencia requeriría el despliegue de más células o transmisores debido a la menor cobertura de las ondas milimétricas.

El término MIMO es el acrónimo en inglés de Multiple-Input Multiple-Output, que se refiere a la utilización de múltiples antenas en la transmisión (Multiple Input) y la recepción (Multiple Output). La primera tecnología MIMO que surgió fueron los sistemas MIMO punto a punto, en la que las múltiples antenas estaban concentradas en los dos extremos del enlace (estación base y terminal de usuario). Esta idea posteriormente evolucionó hacia los sistemas MIMO multiusuario. En este último caso, un número relativamente elevado de antenas conforman un extremo del array, estación base, mientras que los usuarios provistos de una o más antenas conforman el otro extremo del sistema MIMO. La idea del sistema MIMO multiusuario tiene dificultades de implementación sobre todo cuando, como es lo usual, los usuarios no colaboran entre sí. La utilización de un número muy elevado de antenas en la estación base a dando origen a la idea de MIMO masivo, que ha permitido llevar a la práctica el concepto MIMO multiusuario de forma relativamente sencilla, sobre todo a lo que respecta al procesado de la señal.

Una de las características más prometedoras de la tecnología MIMO masivo, que la diferencia de las tecnologías previamente mencionadas, es su capacidad de escalabilidad. Esta característica permite la adición de un número ilimitado de antenas, lo cual siempre aporta mejoras al rendimiento del sistema. A través de esta tecnología, se logra la reducción de la potencia requerida, lo que resulta en una mejora del servicio en toda la celda, al mismo tiempo que simplifica el procesamiento de las señales. En los sistemas de MIMO masivo, el número de antenas en las estaciones base supera significativamente el número de usuarios a los que se pretende brindar servicio [1].

Además, a través de este sistema se ha logrado una mayor fiabilidad, dado que la extensa cantidad de antenas reduce el impacto que se experimentaría en caso de que alguna de ellas presentara algún fallo. También, se requiere un nivel de potencia menor en comparación con otros sistemas, gracias a la cantidad de antenas empleadas y al procesamiento que se realiza con las mismas.

Otra ventaja a destacar de esta tecnología radica en la mejora de la cobertura, lo que permite que los usuarios disfruten de una experiencia uniforme en toda la red, incluso en las zonas periféricas de la célula.

El MIMO masivo evoluciona a partir del MIMO multiusuario y se convierte en una tecnología más avanzada y práctica. A diferencia de las tecnologías previamente estudiadas, el MIMO masivo añade a la multiplexación por división en tiempo o y en frecuencia, la multiplexación espacial, de forma que cierto número de usuarios reutilizan los mismos bloques tiempo-frecuencia, es decir, diferentes bloques de datos comparten tanto el tiempo como la frecuencia. El MIMO masivo emplea la multiplexación por división espacial. Un elemento fundamental que contribuye a la escalabilidad de esta tecnología es el uso de estimaciones directas del canal de radio para la multiplexación y demultiplexación de las señales, en lugar de depender de suposiciones previas sobre la naturaleza del canal. Esta utilización de mediciones específicas del canal para la multiplexación, junto con la implementación de un gran número de antenas, permite que los sistemas de MIMO masivo aprovechen la capacidad conocida como Beamforming o conformación de haz [1].

Beamforming es la capacidad de aprovechar la multiplexación espacial para enviar señales al usuario de la manera más eficiente posible. En un entorno con línea de visión directa, esto implica que el conjunto de antenas transmitirá en la dirección exacta del usuario. En entornos más complejos, donde los componentes dominantes del canal no se encuentran en línea de visión directa, el concepto de beamforming se vuelve más sofisticado. En estos casos, el beamforming no necesariamente se enfoca directamente en el receptor, sino que busca identificar múltiples caminos que contribuyan a una mejor respuesta constructiva [1].

El beamforming se utiliza para enfocar o dirigir la potencia de transmisión o recepción de una antena en una dirección específica, lo que puede mejorar la calidad de la comunicación y reducir la interferencia. La dirección en la que se enfoca el beamforming generalmente se determina mediante técnicas de "direction sensing," que pueden implicar el uso de información del canal, patrones de antena o algoritmos de procesamiento de señales para

identificar la dirección de la señal deseada.

Como características clave del beamforming encontramos:

1. Dirección del Haz: El beamforming permite dirigir la señal de transmisión o recepción en una dirección específica.
2. Mejora de la Ganancia: Al enfocar el haz en una dirección determinada, se logra una ganancia direccional que aumenta la intensidad de la señal en esa dirección.
3. Reducción de la interferencia: El beamforming puede reducir la interferencia de señales no deseadas, ya que se minimiza la energía radiada en direcciones no deseadas.
4. Mejora del Rendimiento de la Red: En aplicaciones de comunicación, el beamforming puede mejorar la calidad de la señal y aumentar la capacidad de la red al enfocar la energía hacia los usuarios activos.
5. Adaptabilidad: Los sistemas de beamforming pueden adaptarse a cambios en el entorno o en las condiciones del canal para mantener la calidad de la señal.
6. Supresión de Fuentes de Interferencia: El beamforming también se utiliza para suprimir fuentes de interferencia.
7. Mayor Alcance: Al enfocar la energía en una dirección específica, el beamforming puede extender el alcance de la comunicación inalámbrica.

Como hemos visto anteriormente, los sistemas MIMO masivos tienen grandes prestaciones, pero no quedan exentos de algunas desventajas como es el caso de la contaminación de señales piloto.

La contaminación de piloto ocurre cuando las señales piloto, que se utilizan para estimar el canal de radio y llevar a cabo el procesamiento de beamforming, pueden ser interferidas o corrompidas por señales piloto transmitidas desde otras celdas o estaciones base vecinas. Esta interferencia puede introducir errores en las estimaciones del canal y afectar negativamente el rendimiento del sistema. Algunas razones por las que la contaminación de pilotos puede ser una desventaja son:

1. Interferencia de celdas vecinas: En entornos donde múltiples celdas o estaciones base operan en proximidad, las señales piloto de una celda pueden interferir con las señales piloto de celdas vecinas. Esto puede llevar a estimaciones de canal inexactas y, en última instancia, a una degradación del rendimiento.
2. Dificultad en la separación de señales: Identificar y separar las señales piloto de diferentes celdas o estaciones base puede ser un desafío en entornos densos. La contaminación de

pilotos puede dificultar la discriminación precisa de las señales piloto deseadas de las interferentes.

3. Impacto en el rendimiento del beamforming: El beamforming eficiente se basa en estimaciones precisas del canal, y la contaminación de pilotos puede afectar la capacidad del sistema para enfocar el haz de manera óptima.

Para abordar esta desventaja, se requieren técnicas avanzadas de mitigación de interferencia y gestión de señales piloto en sistemas MIMO masivo. Estas técnicas pueden incluir la asignación de secuencias piloto únicas, el uso de técnicas de procesamiento de señales avanzadas y la coordinación entre celdas vecinas para reducir la contaminación de pilotos. La investigación en este campo está en curso para mejorar la eficiencia y la fiabilidad de los sistemas de comunicación MIMO masivo en presencia de contaminación de pilotos.

2.3 Rendimiento de los sistemas MIMO

Centrando el análisis en el enlace ascendente, el sistema MIMO masivo considerado es un sistema celular simple donde la estación base (BS) está equipada con M antenas. El número máximo de usuarios activos es Q , y cada terminal de usuario (UT) está equipada con una sola antena. Se asume que los usuarios transmiten una potencia total P . Además, se asume que la BS conoce el canal y que los UTs no están colaborando entre sí. Además, consideramos un sistema OFDM con N_f subportadoras, que corresponden a los tonos medidos.

Considerando este modelo, la forma vectorial de la señal recibida en la BS para la k -ésima subportadora cuando los Q usuarios están activos será dada por:

$$\mathbf{y}[k] = \sqrt{SNR} \mathbf{G}[k] \cdot \mathbf{s}[k] + \mathbf{n}[k]; \quad k = 1, 2, \dots, N_f, \quad (2.1)$$

Donde $\mathbf{y}[k]$ es un vector columna con M elementos correspondientes a la k -ésima subportadora; $\mathbf{G}[k]$ es la matriz del canal de orden $M \times Q$, en la que cada una de sus columnas corresponde con el canal de banda estrecha del q -ésimo usuario $\mathbf{g}_q[k]$ de orden $M \times 1$; $\mathbf{s}[k]$ ($Q \times 1$) es el vector que representa el vector de señales transmitidas desde los UTs y normalizado de tal manera que $E\{\|\mathbf{s}\|^2\} = 1$, donde $E\{\cdot\}$ representa la media o valor esperado; y $\mathbf{n}[k]$ es un vector de ruido gaussiano complejo con elementos de varianza unitaria independientes e idénticamente distribuidos (i.i.d.). Finalmente, el SNR representa la relación señal a ruido media en el receptor.

La matriz en (2.1) está normalizada de tal manera que verifica:

$$E\{\|\mathbf{G}\|_F^2\} = M \cdot Q, \quad (2.2)$$

Donde $\|\cdot\|_F$ es la norma de Frobenius. Además, la matriz \mathbf{G} se obtiene de la matriz de las mediciones del canal en bruto (\mathbf{G}^{raw}) por medio de:

$$\mathbf{G}_{M \times Q} = \mathbf{G}_{M \times Q}^{raw} \mathbf{J}_{Q \times Q}. \quad (2.3)$$

La matriz de normalización \mathbf{J} es una matriz diagonal de orden $Q \times Q$. Se pueden considerar diferentes normalizaciones, siempre que verifiquen (2.2), lo que garantiza la conservación de la potencia total transmitida. Siguiendo la propuesta y la nomenclatura en [7], consideramos dos normalizaciones que denominaremos como normalización 1 (N1) y normalización 2 (N2). Por un lado, en caso de usar N1, la matriz de normalización \mathbf{J} es una matriz diagonal de orden $Q \times Q$, cuyos elementos (j_{qq}) se dan por

$$j_{qq} = \sqrt{\frac{M}{\frac{1}{N_f} \sum_{k=1}^{N_f} \|\mathbf{g}_q^{raw}[k]\|^2}}; \quad q = 1, \dots, Q. \quad (2.4)$$

Los elementos de la matriz de normalización \mathbf{J} toman diferentes valores para que todas las columnas en \mathbf{G} estén normalizadas a uno; en consecuencia, se elimina el desequilibrio de potencia entre los canales correspondientes a cada UT, aunque se mantienen las variaciones de canal entre las antenas dentro del conjunto de receptores y los tonos de frecuencia. La matriz normalizada resultante, \mathbf{G} , puede interpretarse como la asociada a un sistema en el que se realiza un control de potencia ideal. En este caso, la potencia total disponible transmitida por los usuarios no se distribuye de manera igualitaria, sino que a cada UT se le asigna la potencia necesaria para que todos los UT lleguen a la BS con la misma potencia media.

Por otro lado, N2 se define de tal manera que todos los elementos de la matriz diagonal \mathbf{J} son iguales y, por lo tanto, la operación en (2.3) es equivalente a multiplicar la matriz por un escalar.

$$j_{qq} = \sqrt{\frac{MQ}{\frac{1}{N_f} \sum_{k=1}^{N_f} \|\mathbf{G}^{raw}[k]\|_F^2}}; \quad q = 1, \dots, Q. \quad (2.5)$$

Esta normalización mantiene la diferencia entre la potencia recibida de diferentes UTs, antenas receptoras y tonos de frecuencia.

Ambas normalizaciones, N1 y N2, tienen sus pros y contras. N2 preserva la estructura original del canal y el efecto que el desequilibrio de potencia puede tener en el sistema. Sin embargo, si el objetivo es aislar el efecto del desequilibrio de potencia y analizar exclusivamente la ortogonalidad del canal, por ejemplo, a través del número de condición, es obligatorio usar N1 [7].

La SE que los sistemas MIMO masivos pueden lograr depende en gran medida del grado en que se cumpla la condición de “propagación favorable”, que depende de la medida en que los canales de los diferentes usuarios sean ortogonales [7-8]. Una métrica comúnmente aceptada utilizada para sopesar la ortogonalidad de las columnas de una matriz es el número de condición, κ , que también es una medida de la dispersión de los valores singulares de la matriz. El número de condición de una matriz \mathbf{G} se define por la relación:

$$\kappa = \frac{\max\{\text{eigenvalue}(\mathbf{G}^H\mathbf{G})\}}{\min\{\text{eigenvalue}(\mathbf{G}^H\mathbf{G})\}} \quad (2.6)$$

Según (2.6), un valor de κ igual a uno corresponde a una matriz de canal en la que todas sus columnas son ortogonales. Por el contrario, los valores altos de κ indican que al menos dos columnas de la matriz serán prácticamente colineales. Es más adecuado interpretar los resultados utilizando el inverso del número de condición (ICN), que varía entre 1 (máxima ortogonalidad) y 0 (ortogonalidad cero). Para tener una medida directa de la bondad del canal, calculamos la capacidad de suma. Bajo la hipótesis de un conocimiento perfecto del canal en la BS, podemos obtener la capacidad de suma del sistema MIMO-OFDM masivo mediante la descomposición en valores singulares de la matriz del canal como:

$$C[k] = \sum_{q=1}^Q \log_2 \left(1 + \frac{SNR}{Q} \lambda_q[k] \right); \quad k = 1, 2, \dots, N_f, \quad (2.7)$$

en el cual λ_q representa el q-ésimo valor propio de la matriz $\mathbf{G}^H\mathbf{G}$, es decir, el cuadrado del q-ésimo valor singular de la matriz \mathbf{G} . Bajo condiciones de propagación favorables, a medida que aumenta el número de antenas receptoras M y para un número fijo de transmisores Q , la capacidad del canal de enlace ascendente tenderá asintóticamente al límite superior [8]:

$$C_b = Q \cdot \log_2 \left(1 + \frac{M \cdot SNR}{Q} \right). \quad (2.8)$$

La capacidad de suma obtenida del sistema concentrado versus el distribuido permite hacer una comparación global del comportamiento de ambos sistemas.

Además, el análisis de la eficiencia espectral del canal proporciona información adicional para comparar ambos sistemas C-mMIMO y D-mMIMO. En este sentido, se calculan tanto la SE individual para cada usuario como la SE de suma. Consideremos que la señal recibida se procesa en el receptor mediante un método de combinación lineal como el método ZF, que está definido por la matriz \mathbf{V} y se expresa como:

$$\mathbf{V} = \mathbf{G}(\mathbf{G}^H\mathbf{G})^{-1}. \quad (2.9)$$

Entonces, la señal procesada en el receptor puede expresarse como:

$$\hat{\mathbf{s}}[k] = \mathbf{V}^H[k]\mathbf{y}[k], \quad (2.10)$$

Donde $\hat{\mathbf{s}}[k]$ es un vector columna con Q elementos que representa la estimación de las señales transmitidas por los Q usuarios activos en el tono de frecuencia k -th.

La relación señal a interferencia más ruido (SINR) del q-ésimo usuario en el subportador k -th se da por:

$$\text{SINR}_q [k] = \frac{\frac{\text{SNR}}{Q} |\mathbf{v}_q^H \mathbf{g}_q|^2}{\sum_{i=1, i \neq q}^Q \frac{\text{SNR}}{Q} |\mathbf{v}_q^H \mathbf{g}_i|^2 + |\mathbf{v}_q|^2}. \quad (2.11)$$

Usando (2.11), se calcula la SE individual de cada UT activo de la siguiente manera:

$$SE_q[k] = \log_2 (1 + \text{SINR}_q [k]). \quad (2.12)$$

Finalmente, el sumatorio SE se expresa cómo:

$$SE[k] = \sum_{q=1}^Q SE_q[k]. \quad (2.13)$$

Otro factor útil disponible para comparar ambos sistemas C-mMIMO y D-mMIMO es la equidad del usuario dada por el Índice de Equidad de Jain (JFI) [9]. Esta métrica se utiliza para analizar la equidad del canal para repartir la SE total entre los UTs activos, y se da por:

$$JFI = E \left\{ \frac{\left(\sum_{q=1}^Q SE_q[k] \right)^2}{Q \sum_{q=1}^Q SE_q^2[k]} \right\}, \quad (2.14)$$

donde $E\{\cdot\}$ representa la expectativa matemática evaluada sobre todos los tonos de frecuencia N_f . El JFI toma valores entre $1/Q$ y 1 , de modo que el valor 1 corresponde a la máxima equidad entre los valores de SE de los UTs activos.

2.4 C-mMIMO y D-mMIMO

En el contexto de MIMO masivo, hay dos enfoques clave en cuanto a la distribución de las antenas:

1. MIMO masivo Concentrado (C-mMIMO): En un sistema de MIMO masivo concentrado, todas las antenas se encuentran físicamente ubicadas en un solo lugar o en una matriz compacta en la estación base. Este enfoque se centra en la agrupación de todas las antenas en un solo punto, lo que facilita la implementación y el procesamiento, pero puede requerir una mayor potencia y complejidad de hardware en ese único punto.

2. MIMO masivo Distribuido (D-mMIMO): En contraste, en un sistema de MIMO masivo distribuido, las antenas se distribuyen físicamente en diferentes ubicaciones en la estación base o en un área geográfica más amplia. Esto permite una mayor flexibilidad y la posibilidad de utilizar antenas distribuidas en diversas ubicaciones para mejorar la cobertura y la capacidad de la red. Sin embargo, esto también puede presentar desafíos adicionales en términos de sincronización y procesamiento de señales distribuido.

En la Figura 2.2 se muestran como ejemplo la idea de las dos configuraciones de red para ambos sistemas MIMO masivo.

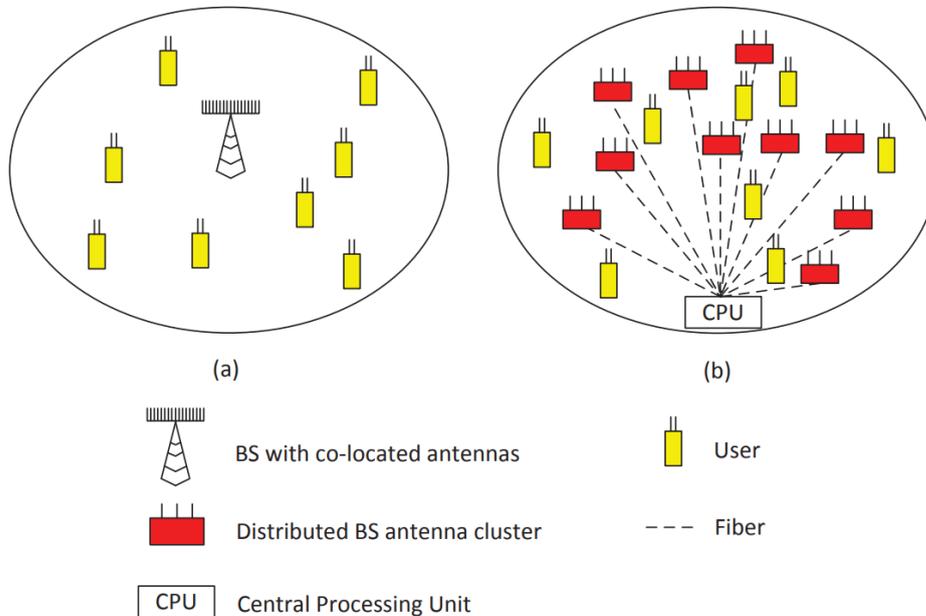


Figura 2.2 Representación gráfica de ambos enfoques [10].

Como podemos observar, en la primera configuración, todas las antenas están ubicadas en el mismo lugar mientras que en la segunda, las antenas están distribuidas en diferentes ubicaciones; estas antenas remotas se conectan a una unidad central de procesamiento a través de una conexión de fibra óptica.

2.4 Planteamiento del problema

Este Trabajo de Fin de Grado (TFG) se enfoca en un desafío específico que surge al comparar los sistemas MIMO concentrados y distribuidos.

Los sistemas MIMO distribuidos tienen ciertas ventajas sobre los concentrados. Al dispersar las antenas, se pueden evitar problemas de desvanecimiento de la señal y proporcionar una cobertura más uniforme. Además, los sistemas MIMO distribuidos pueden manejar más usuarios simultáneamente, lo que aumenta la capacidad del sistema.

No obstante, tener un gran número de antenas activas en un sistema MIMO distribuido puede llevar a un mayor consumo de energía y a un aumento de la complejidad del sistema. Por lo tanto, surge la pregunta de cuántas antenas podríamos desactivar en un sistema MIMO distribuido sin sufrir una pérdida significativa de rendimiento.

La elección entre MIMO masivo concentrado y MIMO masivo distribuido depende de las necesidades específicas de la red y las limitaciones del entorno. Cada enfoque tiene sus ventajas y desventajas, y la elección adecuada se basa en consideraciones como la topología

de la red, la capacidad de hardware disponible y los requisitos de rendimiento.

En la práctica, algunas redes pueden combinar elementos de ambos enfoques para aprovechar sus respectivas fortalezas. Sin embargo, varios estudios han ilustrado las ventajas de los sistemas D-mMIMO en comparación con los C-mMIMO. En concreto, en [11,12] se llevó a cabo una evaluación comparativa de las capacidades de los canales C-mMIMO y D-mMIMO en un entorno de interiores de grandes dimensiones, utilizando datos obtenidos a través de un simulador de canal basado en trazado de rayos [13]. En [11,12], el análisis se centró en el enlace ascendente (UL), en el que se consideraron 100 elementos radiantes tanto para el array de la estación base como un máximo de 20 usuarios activos (UA). Los resultados demostraron de manera concluyente la superioridad del sistema distribuido, con una capacidad promedio del canal que era 11 bits/s/Hz mayor en el sistema distribuido en comparación con el concentrado.

Los estudios muestran que los sistemas distribuidos pueden ofrecer un rendimiento similar al de los sistemas concentrados con un número de antenas receptoras menor. Esto puede suponer una ventaja en términos de coste y complejidad.

Por tanto, es un hecho conocido que los sistemas MIMO distribuidos superan a los concentrados en términos de capacidad y cobertura. De esta manera aparece un problema de selección de antenas que genera la siguiente cuestión: ¿Cuántas antenas podríamos desactivar en un sistema MIMO distribuido y aún así mantener un rendimiento o calidad similar a un sistema MIMO concentrado?

Para responder a esta pregunta, es necesario considerar varios factores. En primer lugar, debemos tener en cuenta la calidad de la señal. Si desactivamos demasiadas antenas, la calidad de la señal puede degradarse, lo que resultaría en una menor capacidad de datos y una menor calidad de servicio. En segundo lugar, debemos considerar la cobertura del sistema. Si desactivamos antenas en áreas con poca cobertura, podríamos dejar a algunos usuarios sin servicio.

La selección de antenas en un sistema MIMO distribuido es un problema de optimización que requiere un equilibrio entre la calidad de la señal, la cobertura del sistema y el consumo de energía.

Basándonos en los estudios realizados [11,12], planteamos un problema similar, en el cual partimos de dos sistemas constituidos cada uno por un array de i elementos radiantes representados por vectores binarios de dimensión $1 \times i$, un 1 en la posición X_i representa que el elemento radiante correspondiente a esa posición se encuentra activo mientras que un 0 representa que se encuentra apagado.

Buscando un enfoque diferente vamos a utilizar una metodología distinta; en esta ocasión hemos optado por utilizar un optimizador metaheurístico denominado Algoritmo de Dandelion, este optimizador posee grandes capacidades de exploración y explotación del

espacio de búsqueda y ha demostrado obtener resultados prometedores en diferentes estudios [13]. Para llevar a cabo el análisis, adaptaremos este optimizador a la casuística de nuestro problema, formulando una versión binaria de este.

Para realizar la comparativa de ambos sistemas utilizaremos como métricas: la eficiencia espectral (SE), el índice de equidad de Jain (JFI) y el número de antenas activas. Estos tres parámetros serán unificados en una función de coste que aplicaremos y nos permitirá cuantificar la calidad del sistema.

Referencias

- [1] P. A. González (2020, 23 octubre). “Caracterización del canal MIMO masivo en interiores mediante trazado de rayos para comunicaciones 5G”, UCREA Repositorio abierto de la Universidad de Cantabria. <http://hdl.handle.net/10902/19544>
- [2] Ericsson Press Release: Ericsson Mobility Report: Mobile data traffic increased almost 300-fold over 10 years, 2022.
- [3] IMT Vision – “Framework and overall objectives of the future development of IMT for 2020 and beyond”, ITU-R M.2083-0 (09/2015), disponible en octubre de 2020 en <https://www.itu.int/rec/R-REC-M.2083-0-201509-I/es>.
- [4] A. R. Aparicio (2020, Julio). “Análisis del canal radio interior para sistemas 5G: parámetros de banda ancha y eficiencia espectral”, UCREA Repositorio abierto de la Universidad de Cantabria. <http://hdl.handle.net/10902/19553>
- [5] T. L. Marzetta, “Massive MIMO: An Introduction”, in Bell Labs Technical Journal, vol. 20, pp. 11-22, 2015, doi: 10.15325/BLTJ.2015.2407793.
- [6] Y. Wang, J. Li, L. Huang, Y. Jing, A. Georgakopoulos and P. Demestichas, “5G Mobile: Spectrum Broadening to Higher-Frequency Bands to Support High Data Rates”, in IEEE Vehicular Technology Magazine, vol. 9, no. 3, pp. 39-46, Sept. 2014, doi: 10.1109/MVT.2014.2333694.
- [7] Gao, X.; Edfors, O.; Rusek, F.; Tufvesson, F. Massive MIMO performance evaluation based on measured propagation data. IEEE Trans. Wirel. Commun. 2015, 14, 3899–3911.
- [8] Rusek, F.; Persson, D.; Lau, B.K.; Larsson, E.G.; Marzetta, T.L.; Edfors, O.; Tufvesson, F. Scaling up MIMO: Opportunities and challenges with very large arrays. IEEE Signal Process. Mag. 2013, 30, 40–60.
- [9] Jain, R.K.; Chiu, D.-M.W.; Hawe, W.R. A Quantitative Measure of Fairness and Discrimination; Eastern Research Laboratory, Digital Equipment Corporation: Hudson, MA, USA, 1984.
- [10] CITY UNIVERSITY OF HONG KONG. (2014, octubre). “To Co-locate or to Distribute: A Comparative Study on the Asymptotic Downlink Performance of MIMO Cellular Networks with Massive Base-station Antennas”. http://www.ee.cityu.edu.hk/~lindai/Thesis_Zhiyang
- [11] J. Merino, J. R. Pérez, R. P. Torres, L. Valle, Ó. Fernández, L. Rubio, V. M. Rodrigo and J. Reig, “Comparativa entre canales MIMO masivo concentrado y distribuido a 26 GHz”, in Proc. URSI 2022 - XXXVII Simposio Nacional de la Unión Científica Internacional de Radio, Málaga, Spain, Sep. 2022.

[12] J. R. Pérez, R. P. Torres, L. Valle, Ó. Fernández, L. Rubio, V. M. Rodrigo and J. Reig, "A Comparison Between Concentrated and Distributed Massive MIMO Channels at 26 GHz in a Large Indoor Environment using Ray-Tracing", *IEEE Access*, vol. 10, pp. 65623-65635, Jun. 2022

[13] O. Fernández, L. Valle, M. Domingo and R. P. Torres, "Flexible rays", *IEEE Veh. Technol. Mag.*, vol. 3, no. 1, pp. 18-27, Mar. 2008.

Capítulo 3

Algoritmo de Dandelion

A lo largo de este capítulo vamos a presentar un algoritmo de optimización inspirado en la inteligencia colectiva de la naturaleza (metaheurística), llamado Optimizador Dandelion (DO), diseñado para resolver problemas de optimización continua. El DO imita el comportamiento de las semillas del diente de león durante su desplazamiento impulsadas por el viento. A nivel computacional, este algoritmo imita el proceso natural mediante tres etapas relacionadas con el desplazamiento de las semillas: ascenso, descenso y aterrizaje. En la etapa de ascenso, las semillas se elevan en espiral debido a las corrientes de aire o se agrupan localmente dependiendo de las condiciones climáticas. En la etapa de descenso, las semillas van bajando continuamente ajustando su rumbo. La etapa de aterrizaje culmina con el descenso de las semillas en lugares aleatorios para su germinación. Como herramienta de optimización, el DO establece relaciones entre el citado movimiento de los dandelion y la exploración de un espacio de soluciones multidimensional y altamente multimodal, con suficiente potencial como para poder escapar de soluciones locales y promover la convergencia de un problema de referencia hacia una solución global.

3.1 Un proceso natural con potencial en la optimización

El diente de león, científicamente conocido como *Herba taraxaci*, es una hierba perenne de la familia Asteraceae. Estas plantas pueden alcanzar más de 20 cm de altura, las semillas están compuestas por cientos de filamentos crestados. Cuando las semillas maduran, el viento las transporta a nuevos lugares para reproducirse.

Los filamentos juegan un papel crucial en la dispersión de las semillas de Asteraceae ya que prolongan su descenso. Estos filamentos permiten que el viento las desplace a grandes distancias, llegando incluso a viajar decenas de kilómetros. El diente de león es una de las plantas más representativas que dependen del viento para la propagación de sus semillas. En su desplazamiento aéreo, una semilla de diente de león forma dos vórtices que crean una fuerza de empuje ascendente. A velocidades más bajas, los vórtices se agrandan y se vuelven simétricos. Un vórtice simétrico asegura un descenso estable de la semilla; es decir, el filamento está nivelado con el suelo y la semilla apunta hacia abajo.

El conjunto formado por la unión de todos los filamentos se denomina corona, y la consistencia de la corona de filamentos regula con precisión la estabilidad en el vuelo de cada semilla. Para que las semillas de diente de león vuelen largas distancias, deben mantenerse a cierta altitud; de esta manera los vórtices se mantienen simétricos y a una distancia fija de la corona del diente de león. Los filamentos crestados están constituidos a su vez de filamentos aún más delgados que irradian desde un mango central, similares a los radios de una rueda,

manteniendo en todo momento una simetría radial (véase Figura 3.1). Estas semillas tienen entre 90 y 110 radios. Esta consistencia es la clave para la estabilidad de los vórtices sobre cada semilla de diente de león, lo que ayuda a la semilla a permanecer estable durante el vuelo en largas distancias.

A continuación, en la Figura 3.1 se presenta la estructura de las semillas del diente de león, así como los vórtices que se generan al iniciar el vuelo. En la figura se aprecian las diferentes partes que constituyen el cuerpo completo de la semilla, mencionados anteriormente: filamentos crestados, mango central y semilla.

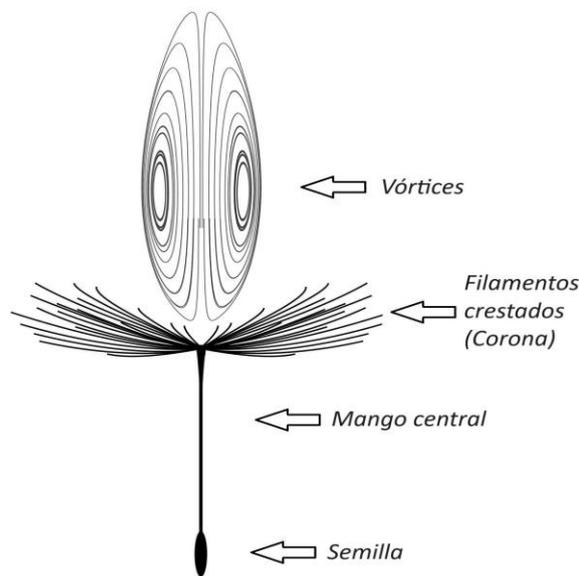


Figura 3.1 Estructura con detalle de las partes de la semilla del diente de león.

La velocidad del viento y el clima son los dos factores principales que afectan a la dispersión de las semillas de diente de león. La velocidad del viento determina si una semilla vuela distancias largas o cortas. El clima controla si las semillas pueden volar e influye en la capacidad del diente de león para crecer en espacios cercanos o lejanos.

Como ya se mencionó brevemente en la introducción del capítulo, las semillas de diente de león atraviesan tres etapas desde el inicio del vuelo hasta el aterrizaje:

- *Ascenso*: En esta etapa se generan unos vórtices sobre la semilla y ésta se eleva bajo la acción de una fuerza de empuje con tiempo soleado y viento. En cambio, si el clima es lluvioso, no hay vórtices sobre las semillas. En este caso, el desplazamiento (lo que equivaldría en términos del optimizador a búsqueda sobre el espacio de soluciones) sólo se puede realizar localmente a una distancia reducida.
- *Descenso*: Después de que las semillas alcanzan cierta altura, caen de manera constante.
- *Aterrizaje*: Finalmente, las semillas de diente de león aterrizan aleatoriamente en un lugar bajo la influencia del viento y el clima para formar nuevos dientes de león.

Las tres etapas anteriores, traducidas a nivel computacional, tienen el objetivo de conferir al DO la capacidad de explorar un espacio de soluciones, dirigiendo en función de ciertos operadores la búsqueda y la convergencia. El DO utiliza una población para explorar el espacio de soluciones, que se corresponderá con un conjunto de dientes de león y su desplazamiento evolutivo, mediante la transmisión de semillas a la siguiente generación (iterativamente) [1].

3.2 Optimización de la configuración de antenas

Como introdujimos anteriormente, el estudio se plantea como un problema de selección de antenas, en el cual partimos de un sistema D-mMIMO sin optimizar, este sistema se debe ajustar para lograr obtener un rendimiento similar al de un sistema concentrado convencional en el mismo entorno y bajo los mismos requisitos, dando servicio al mismo número de usuarios.

Estos sistemas serán representados como un array binario en los que cada elemento radiante será representado con un 1 o un 0, siendo 1 el estado “antena activa” y 0 “antena inactiva” respectivamente. En una primera instancia partiremos de una población inicial constituida por un conjunto de vectores binarios o configuraciones D-mMIMO, diferentes entre sí, cada una de estas configuraciones serán soluciones potenciales de nuestro problema. Para nuestro optimizador, cada una de las configuraciones es una semilla, que deberá atravesar cada una de las etapas descritas anteriormente, ser evaluada tras los cambios, discriminando entre los mejores individuos y los peores.

En la Figura 3.2 se muestra un diagrama con el proceso descrito anteriormente.

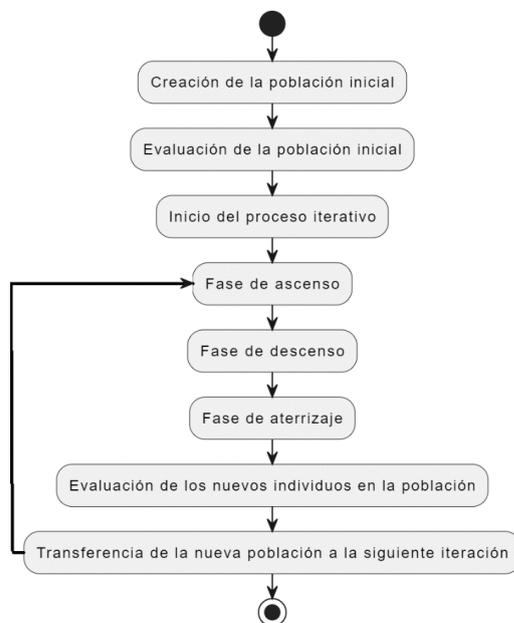


Figura 3.2 Diagrama de flujo simplificado del proceso de optimización.

Como podemos observar en la Figura 3.2, una vez que obtenemos la nueva población al final de una iteración se evalúa y se somete de nuevo iterativamente a las fases del algoritmo. Para

llevar a cabo esta evaluación iterativa de los individuos o semillas necesitaremos una función de coste que servirá como nexo de unión entre nuestro problema físico en el que tenemos un conjunto de arrays de antenas con diferentes configuraciones y el mundo del optimizador. Este proceso de desplazamiento evolutivo se realizará hasta alcanzar un criterio de parada que deberá ser escogido adecuadamente cuando el algoritmo sea capaz de alcanzar soluciones de calidad muy cercanas al óptimo global.

3.3 Fundamentos matemáticos del DO

El algoritmo de diente de león se implementa iterativamente, utilizando una población de soluciones potenciales (posición de las semillas en el argot del DO) que, generadas aleatoriamente, representan con mayor a menor calidad al problema bajo análisis. La evolución se hace repitiendo las tres etapas descritas anteriormente hasta que se alcanza la convergencia hacia una solución global de calidad.

3.3.1 Inicialización del DO

Durante la primera iteración se genera aleatoriamente una población inicial de soluciones potenciales; en nuestro caso esta población está constituida por pop individuos, y estos individuos tal y como describimos son vectores binarios que representan cada uno una configuración del array de antenas, siendo representado el encendido y el apagado de cada antena por un 1 o un 0 respectivamente en cada posición del vector.

En (3.1) se muestra la estructura de la matriz en la que vamos a almacenar la población con la que trabaja el DO iterativamente, representando cada fila una solución potencial al problema.

$$\text{Población} = \begin{bmatrix} x_1^1 & \dots & x_1^{Dim} \\ \vdots & \ddots & \vdots \\ x_{pop}^1 & \dots & x_{pop}^{Dim} \end{bmatrix} \quad (3.1)$$

El tamaño de la población se representa mediante pop . La dimensión de la variable (individuo o número de antenas del array D-mMIMO) se representa mediante Dim . Cada elemento radiante (X_i) se genera aleatoriamente entre el límite superior (UB) y el límite inferior (LB) del problema dado, siendo en nuestro caso el límite inferior (LB) = 0 y el límite superior (UB) = 1, es decir antena activa o inactiva respectivamente. La expresión del i -ésimo individuo X_i es:

$$X_i = rand \times (UB - LB) + LB \quad (3.2)$$

En otras palabras, se genera una población de pop soluciones candidatas, cada una de las cuales tiene Dim dimensiones. Cada elemento radiante se genera aleatoriamente entre UB y LB, que son los límites superior e inferior del problema dado, una vez se genera cada elemento X_i , se les aplica redondeo, obteniendo así su estado: 0 o 1.

Durante la inicialización, DO considera al individuo con el mejor fitness como la élite inicial, la élite inicial representa la posición en la cual es más probable que la semilla de diente de león prospere. La expresión matemática de la élite inicial X_{elite} viene dada como:

$$f_{bestfitness} = \min(fitness(X_i)) \quad (3.3)$$

$$X_{elite} = X \left(find \left(f_{bestfitness} == fitness(X_i) \right) \right) \quad (3.4)$$

Esta solución candidata se considera la más prometedora para resolver el problema de optimización, una vez obtenida, el algoritmo almacena esta solución candidata como referencia. Tras esto, el algoritmo itera a través de la población, mejorando las soluciones candidatas. El algoritmo termina cuando se encuentra una solución satisfactoria o cuando se alcanza un límite de iteraciones establecido.

3.3.2 Fase de ascenso

Una vez se lleva a cabo la inicialización comienza el ciclo iterativo inherente del DO, empezando con la fase de ascenso de las semillas. En la etapa de ascenso, las semillas de diente de león necesitan alcanzar una cierta altura antes de poder flotar y desplazarse. Durante la etapa de elevación, las semillas de diente de león dependen de las condiciones climáticas para alcanzar la altura necesaria para liberarse de su tallo. La velocidad del viento, la humedad del aire y otros factores ambientales influyen en la trayectoria de las semillas y en la altura a la que pueden ascender [1].

Bajo la influencia de la velocidad del viento y la humedad del aire, las semillas de diente de león ascienden a diferentes alturas. Aquí, el clima se divide en las siguientes dos situaciones:

- En clima soleado, la velocidad del viento se puede considerar como una distribución normal logarítmica $\ln Y \sim N(\mu, \sigma^2)$. Con esta distribución, los números se distribuyen a lo largo del eje y , lo que aumenta la probabilidad de que las semillas de diente de león viajen a regiones más lejanas. En este caso, el DO enfatiza la exploración, las semillas de diente de león son arrastradas aleatoriamente a varias ubicaciones por el viento. La altura de elevación de una semilla de diente de león está determinada por la velocidad del viento, cuando el viento es más fuerte, el diente de león volará más alto y consecuentemente mayor distancia se desplazarán las semillas. Además, los vórtices encima de las semillas de diente de león se ajustan constantemente para que se eleven en forma de espiral, la expresión matemática que representa esta situación viene dada como:

$$X_{t+1} = X_t + \alpha * v_x * v_y * \ln Y * (X_s - X_t) \quad (3.5)$$

Donde $\ln Y$ representa la distribución normal logarítmica con media $\mu = 0$ y varianza $\sigma^2 = 1$. Cuya expresión viene dada por:

$$\ln Y = \begin{cases} \frac{1}{y\sqrt{2\pi}} \exp \left[-\frac{1}{2\sigma^2} (\ln y)^2 \right] & y \geq 0 \\ 0 & y < 0 \end{cases} \quad (3.6)$$

Siendo y en la ecuación 3.6, una distribución normal definida como $N(0, 1)$.

En (3.5), α representa el tamaño del paso de búsqueda, es decir, la distancia que recorren las semillas de diente de león en cada etapa. La forma en que se ajusta α depende de la calidad de la posición actual de la semilla de diente de león. La fórmula matemática utilizada para el ajuste es:

$$\alpha = rand () * \left(\frac{1}{T^2} t^2 - \frac{2}{T} t + 1 \right) \quad (3.7)$$

α es una perturbación aleatoria para alternar entre la búsqueda global y la búsqueda local.

A continuación, podemos observar en la Figura 3.3, como α se reduce gradualmente de manera no lineal hasta llegar a 0, lo que asegura que el algoritmo realice una búsqueda global completa al principio y luego se concentre en la búsqueda local para refinar la solución a medida que aumenta el número de iteraciones [1].

Además, debemos tener en cuenta los coeficientes de elevación v_x y v_y , que intervienen en la expresión (3.5), representando la fuerza de elevación que ejerce el viento sobre la semilla de diente de león.

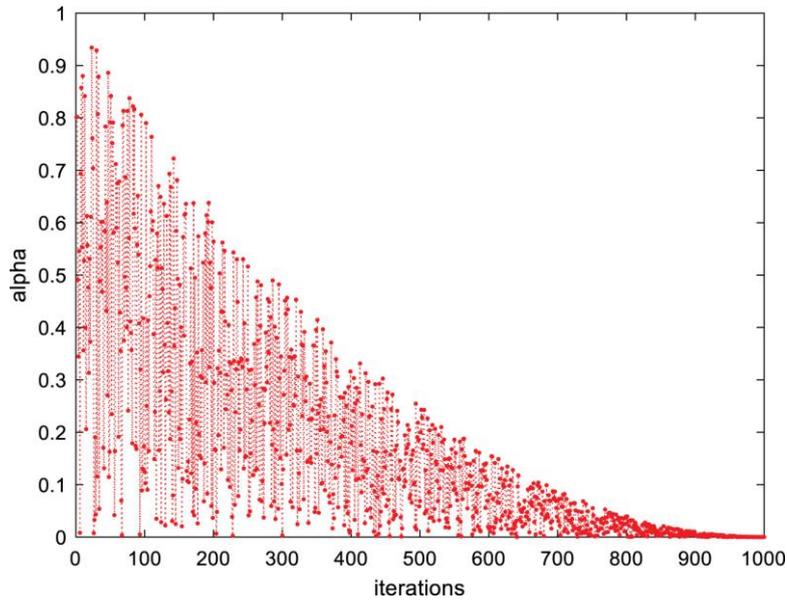


Figura 3.3 Evolución del parámetro α de acuerdo al número de iteraciones [1].

Mediante las ecuaciones (3.8)-(3.10) se calcula la fuerza en la dimensión variable, es decir, la fuerza que impulsa a la semilla de diente de león a moverse:

$$r = \frac{1}{e^\theta} \quad (3.8)$$

$$v_x = r * \cos \theta \quad (3.9)$$

$$v_y = r * \sin \theta \quad (3.10)$$

Siendo θ un número aleatorio entre $[-\pi, \pi]$.

Por último, la posición de la semilla de diente de león durante la iteración t se representa mediante el símbolo X_t en (3.5), y la posición aleatoriamente seleccionada en el espacio de búsqueda durante la iteración t se representa mediante el símbolo X_s y se genera tal y como vemos en (3.11):

$$X_s = rand(1, Dim) * (UB - LB) + LB \quad (3.11)$$

Sintetizando, podemos decir que, en un día soleado, la distribución de la velocidad del viento es más dispersa en el eje y , lo que aumenta la probabilidad de que las semillas de diente de león viajen a regiones remotas. El DO aprovecha esta distribución para enfatizar la exploración. Las semillas de diente de león son arrastradas aleatoriamente por el viento, y su altura de elevación está determinada por la velocidad del viento. Los vórtices sobre las semillas de diente de león se ajustan constantemente para que se eleven en forma de espiral. Esta forma de movimiento aumenta la probabilidad de que las semillas exploren diferentes regiones del espacio de búsqueda [1].

- En clima lluvioso, las semillas de diente de león ya no pueden ser arrastradas por el viento a grandes distancias como ocurría con clima soleado. En un día lluvioso, las condiciones climáticas adversas, la fuerza del viento y la resistencia del aire aumenta. Esto hace que sea más difícil para las semillas de diente de león ascender y mantenerse en el aire. Además, la humedad en el aire puede hacer que las semillas de diente de león se peguen entre sí o a otras superficies, lo que también dificulta su movimiento. Como consecuencia de estas condiciones adversas, las semillas de diente de león se limitan a explorar soluciones locales en un día lluvioso. Esto significa que se mueven a distancias más cortas y se enfocan en áreas más cercanas a su posición inicial.

El DO tiene en cuenta estas condiciones adversas al ajustar el dominio de búsqueda local o paso de búsqueda local. El dominio de búsqueda local es el área del espacio de búsqueda que una semilla de diente de león puede explorar en una sola iteración. En un día lluvioso, el dominio de búsqueda local se reduce [1].

La ecuación (3.12) se utiliza para calcular el dominio de búsqueda local en un día lluvioso. Esta ecuación tiene en cuenta la calidad de la posición actual de la semilla de diente de león y la intensidad de la lluvia:

$$X_{t+1} = X_t * k \quad (3.12)$$

Donde k se utiliza para modular el dominio de búsqueda y viene dado por las siguientes expresiones:

$$q = \frac{1}{T^2-2T+1}t^2 - \frac{2}{T^2-2T+1}t + 1 + \frac{1}{T^2-2T+1} \quad (3.13)$$

$$k = 1 - rand () * q \quad (3.14)$$

En la Figura 3.4 podemos ver como el parámetro k va evolucionando con cada iteración. Inicialmente k toma valores más grandes. En las primeras etapas (iteraciones), nos interesa que este dominio de búsqueda o paso de búsqueda sea de mayor tamaño ya que nos permite llevar a cabo una búsqueda global de soluciones, sin embargo, a medida que aumente el número de iteraciones y nos acerquemos más a las soluciones, es necesario disminuir el paso logrando de esta manera mejorar la explotación local del algoritmo. A medida que avanzan las iteraciones, el algoritmo reduce gradualmente la exploración global y aumenta la explotación local, concentrando las semillas de diente de león en áreas cercanas a las soluciones óptimas. Esto permite al algoritmo refinar y mejorar las soluciones existentes, convergiendo finalmente a la solución óptima.

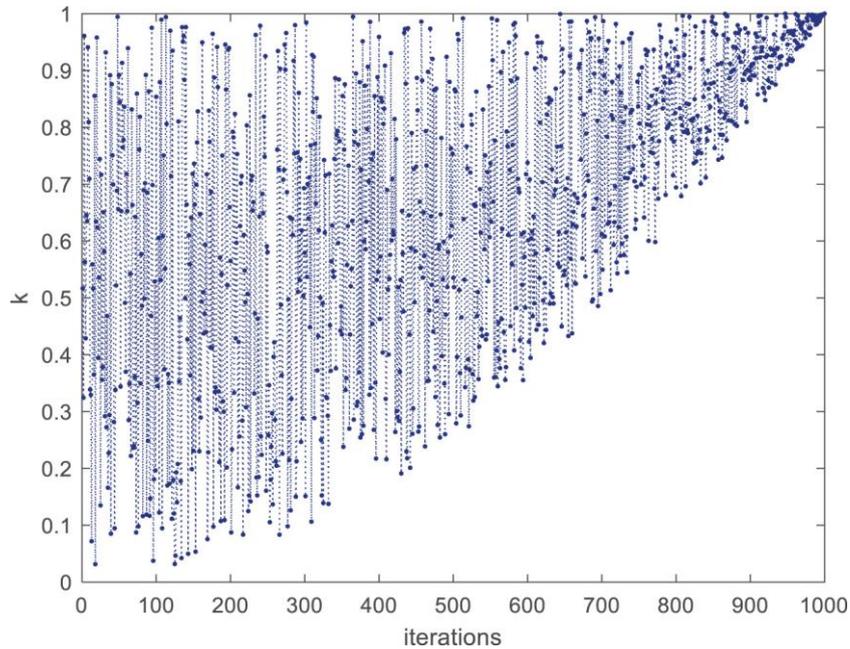


Figura 3.4 Evolución del parámetro k de acuerdo al número de iteraciones [1].

Sintetizando todo el contenido de esta subsección podemos decir que, en la etapa de ascenso, las semillas de diente de león experimentan una serie de cambios dinámicos impulsados por la fuerza ascendente del viento y las condiciones climáticas cambiantes. La expresión matemática 3.15 junta en una sola expresión la totalidad de sucesos probables en la fase de ascenso que se han determinado en el algoritmo, es decir, clima soleado o lluvioso, estos sucesos se darán en cada iteración de manera aleatoria siguiendo una distribución normal, modelando el comportamiento de las semillas de diente de león durante esta fase.

$$X_{t+1} = \begin{cases} X_t + \alpha * v_x * v_y * \ln Y * (X_s - X_t) & \text{randn} < 1.5 \\ X_t * k & \text{else} \end{cases} \quad (3.15)$$

Por último, en la Figura 3.5 se ilustra gráficamente mediante un esquema, cómo las semillas de diente de león se comportan bajo las diferentes condiciones climáticas:

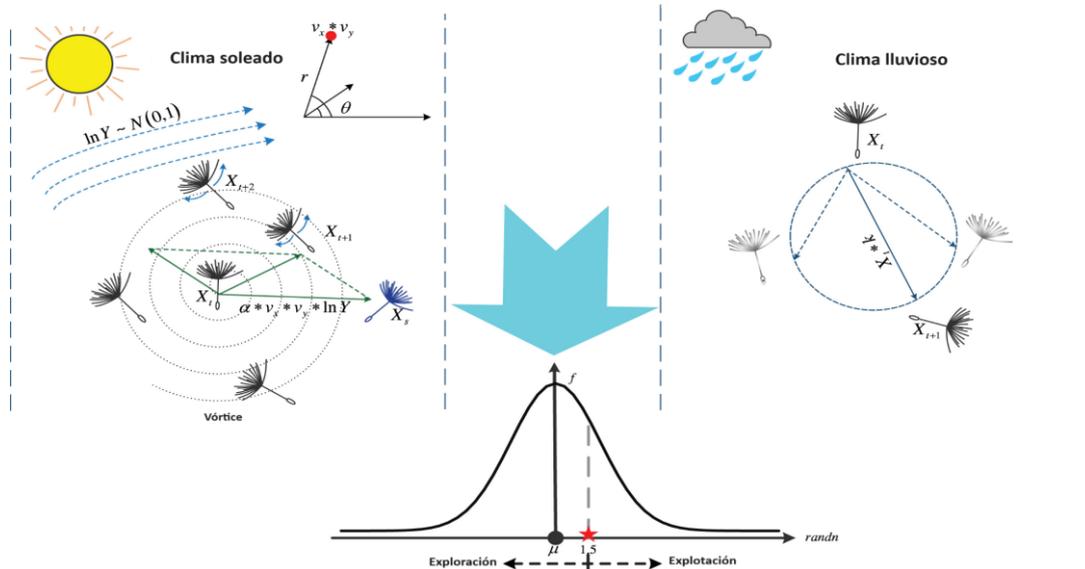


Figura 3.5 Representación gráfica de la fase de ascenso [1].

3.3.3 Fase de descenso

La etapa de descenso del algoritmo DO es una continuación de la etapa de ascenso. En esta etapa, las semillas de diente de león continúan explorando el espacio de búsqueda, pero lo hacen de una manera más estable y dirigida.

El movimiento browniano se utiliza para simular la trayectoria de movimiento de las semillas de diente de león. El movimiento browniano es el movimiento aleatorio que se observa en las partículas que se hallan en un medio fluido o gaseoso, como resultado de choques contra las moléculas de dicho medio. Este fenómeno de transporte recibe su nombre en honor al escocés Robert Brown, biólogo y botánico, quien lo observó por primera vez en 1827 al observar granos de polen suspendidos en agua bajo un microscopio [2]. El movimiento browniano es un movimiento aleatorio que se rige por una distribución normal. Las semillas de diente de león tienen una mayor probabilidad de moverse en una dirección en la que ya se están moviendo, y una menor probabilidad de moverse en una dirección en la que no se están moviendo.

La información de posición media posterior a la etapa de ascenso se utiliza para reflejar la estabilidad del descenso de las semillas de diente de león. Esta información se utiliza para calcular el valor medio de la posición de todas las semillas de diente de león en la etapa de ascenso. Las semillas de diente de león en la etapa de descenso se mueven hacia la dirección de esta posición media.

Esta combinación de movimiento browniano e información de posición media permite al algoritmo DO explorar el espacio de búsqueda de manera efectiva y consecuentemente converger a soluciones prometedoras.

A continuación, veremos la expresión matemática que modela esta fase de descenso:

$$X_{t+1} = X_t - \alpha * \beta_t * (X_{mean_t} - \alpha * \beta_t * X_t) \quad (3.16)$$

En esta expresión matemática utilizada para modelar la fase de descenso de las semillas de diente de león, β_t representa el movimiento browniano y es un número aleatorio de la desviación estándar de la distribución normal (Einstein, 1956) [1].

Esta expresión refleja la naturaleza aleatoria del movimiento browniano, en el que las semillas de diente de león tienen una mayor probabilidad de moverse en una dirección en la que ya se están moviendo, y una menor probabilidad de moverse en una dirección distinta.

En (3.16), X_{mean_t} representa la información de posición media posterior a la etapa de ascenso, reflejando la estabilidad del descenso de las semillas de diente de león. Las semillas de diente de león en la etapa de descenso se mueven hacia la dirección de esta posición media.

Esta posición media viene dada por:

$$X_{mean_t} = \frac{1}{pop} \sum_{i=1}^{pop} X_i \quad (3.17)$$

En la Figura 3.6 se representa gráficamente cómo las semillas de diente de león se mueven de manera irregular durante el descenso, guiándose por la información de la posición media de la población y el movimiento browniano.

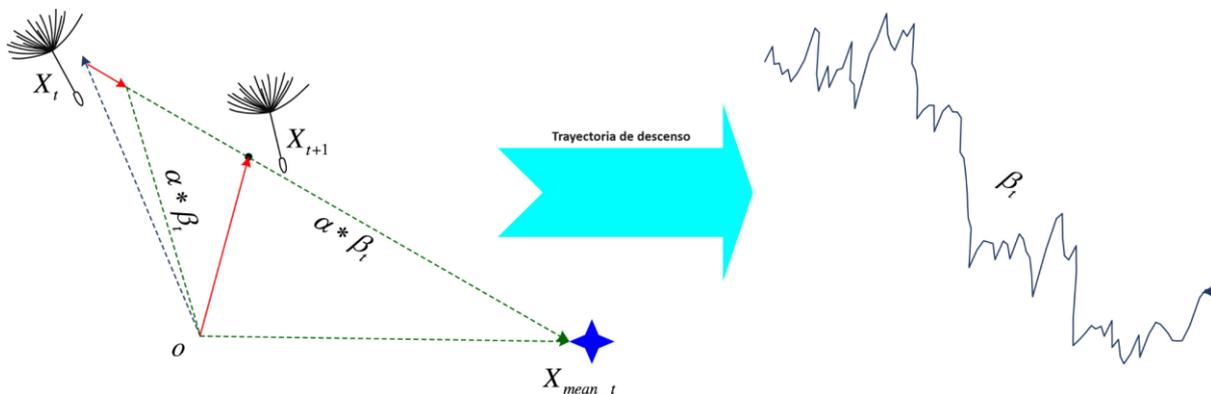


Figura 3.6 Representación gráfica de la fase de descenso [1].

El movimiento irregular ayuda a los individuos a explorar el espacio de búsqueda, mientras que la información de la posición media les ayuda a converger a soluciones prometedoras.

3.3.4 Fase de aterrizaje

En esta etapa, el algoritmo DO se centra en refinar la solución encontrada en las etapas anteriores. Las semillas de diente de león escogen aleatoriamente ubicaciones para aterrizar y, dependiendo del lugar de aterrizaje, las semillas tendrán más posibilidades de prosperar; es decir las semillas que aterricen en regiones que se ajusten mejor a nuestra función de coste, prosperarán y pasan a la siguiente iteración del algoritmo. De esta manera, a medida que el algoritmo avanza, las semillas se acercan cada vez más a la solución óptima global.

La expresión matemática que modela esta última fase del ciclo iterativo del DO viene dada de la siguiente manera:

$$X_{t+1} = X_{elite} + levy(\lambda) * \alpha * (X_{elite} - X_t * \delta) \quad (3.18)$$

X_{elite} representa la posición de la mejor semilla en la iteración i , $levy(\lambda)$ representa la función de vuelo de Lévy que se utiliza para modelar el movimiento aleatorio de las semillas de diente de león en el algoritmo DO. Esta función se calcula utilizando la ecuación (3.19) [1]. La ecuación (3.19) refleja la naturaleza aleatoria del vuelo de Lévy, en el que las semillas de diente de león tienen una mayor probabilidad de moverse en una dirección en la que ya se están moviendo, y una menor probabilidad de moverse en una dirección en la que no se están moviendo.

$$Levy(\lambda) = s \times \frac{w \times \sigma}{|t|^{\frac{1}{\beta}}} \quad (3.19)$$

La variable β representa un número aleatorio entre 0 y 2. Durante todo el estudio realizado en este TFG se han realizado las simulaciones con un valor específico de β de 1.5. La variable S es una constante fija de 0,01. Las variables W y t también son números aleatorios, con un rango es de 0 a 1. Por último, σ se obtiene mediante la siguiente expresión matemática (3.20):

$$\sigma = \left(\frac{\Gamma(1+\beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \times \beta \times 2} \right) \quad (3.20)$$

La Figura 3.7 representa gráficamente la fase final del algoritmo:

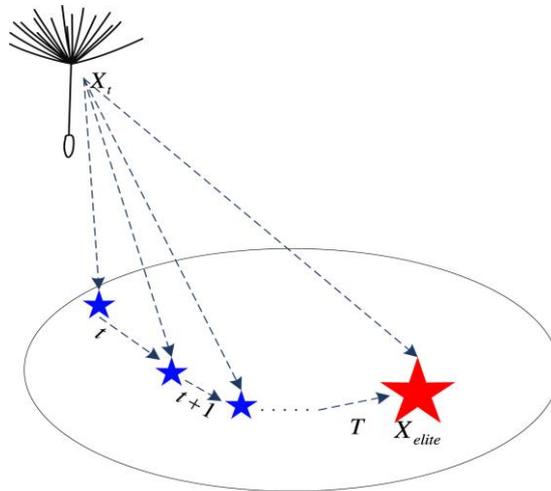


Figura 3.7 Representación gráfica de la fase de aterrizaje [1].

En la fase final del algoritmo, el agente de búsqueda se actualiza gradualmente hacia la solución óptima global. Para evitar que el agente converja prematuramente a un óptimo local, se utiliza una función lineal creciente para aumentar la amplitud de los pasos de movimiento de los individuos. Esto permite a los agentes explorar nuevas regiones del espacio de búsqueda, lo que aumenta la probabilidad de encontrar la solución óptima global [1].

Una vez finaliza la fase de descenso, cada semilla de diente de león (en nuestro caso cada vector que representa un array de antenas) se organiza en orden ascendente según el valor de fitness. El individuo con el coste mínimo es el individuo élite de la siguiente generación de la población, y la población ordenada es la población inicial de la siguiente iteración. Con este método de clasificación evitamos la pérdida de información valiosa. El algoritmo finaliza el proceso de optimización al alcanzar el número máximo de iteraciones.

3.4 Función de coste

Como hemos visto a lo largo de este capítulo, se ha abordado este problema de selección de antenas utilizando un método heurístico, partiendo de los estudios previamente realizados por el grupo de Ingeniería De Sistemas, Antenas Y Radiopropagación (GISAR) de la UC [10], que basaron el estudio en algoritmos genéticos.

En este caso, se utiliza una versión binaria del Algoritmo de Dandelion. Cada semilla S es un vector de longitud M (véase en 3.21), en el que cada posición indica si una antena está activa (estado $\rightarrow 1$) o no (estado $\rightarrow 0$).

$$S = (s_1, \dots, s_m, \dots, s_M) \tag{3.21}$$

Sin embargo, necesitamos una función que unifique nuestro problema físico con el optimizador, a través de la cual cuantificar la calidad de los individuos y discriminarlos, es por eso que como métrica para valorar la calidad de cada semilla o solución, iteración tras

iteración, necesitamos una función de coste. Durante la presente investigación se ha utilizado la función de coste propuesta en [3] por el grupo de Ingeniería De Sistemas, Antenas Y Radiopropagación, ya que la naturaleza del problema nos lo permite.

Esta función de coste viene dada como:

$$F_C = w_1 \left| \sum_{k=1}^{N_f} (SE_C(k) - SE_D(k)) \right| + \left| \sum_{k=1}^{N_f} (JFI_C(k) - JFI_D(k)) \right| + \sum_{m=1}^M S(m) \quad (3.22)$$

La función de coste a minimizar (3.22) incluye la eficiencia espectral total, la igualdad entre la eficiencia espectral de los usuarios (fairness), así como el número de antenas receptoras activas.

En el primer sumando se calcula el error cometido en el ajuste de la eficiencia espectral, es decir el ajuste del sistema D-mMIMO sobre el C-mMIMO, SE_C (SE del sistema D-mMIMO) se calcula según [4] y SE_D se obtiene calculando la eficiencia espectral de cada individuo o semilla.

En el primer sumando w_1 representa el peso del error de la eficiencia espectral en el conjunto de los sumandos. Esta constante se utiliza para valorar de manera equitativa el peso de este sumando sobre el resto, en este trabajo se ha mantenido el peso utilizado en los estudios anteriores en [3] del grupo GISAR, fijándolo en 0.002, se podrían añadir distintos pesos a los siguientes sumandos en caso de que fuese necesario para nuestros intereses.

En el segundo sumando se calcula el error cometido en el ajuste del JFI, en otras palabras, el error de ajuste entre el sistema D-mMIMO y el C-mMIMO en términos de JFI. Tanto JFI_C como JFI_D son calculados según [5].

Por último, el tercer sumando calcula el número de antenas activas en cada solución o semilla, de esta manera, se recompensará con un menor valor a las soluciones cuanto menor sea el número de antenas activas.

3.5 Diagrama de flujo

En la Figura 3.8 se resume con un diagrama de flujo la adaptación y aplicación del DO al problema de optimización planteado en este TFG.

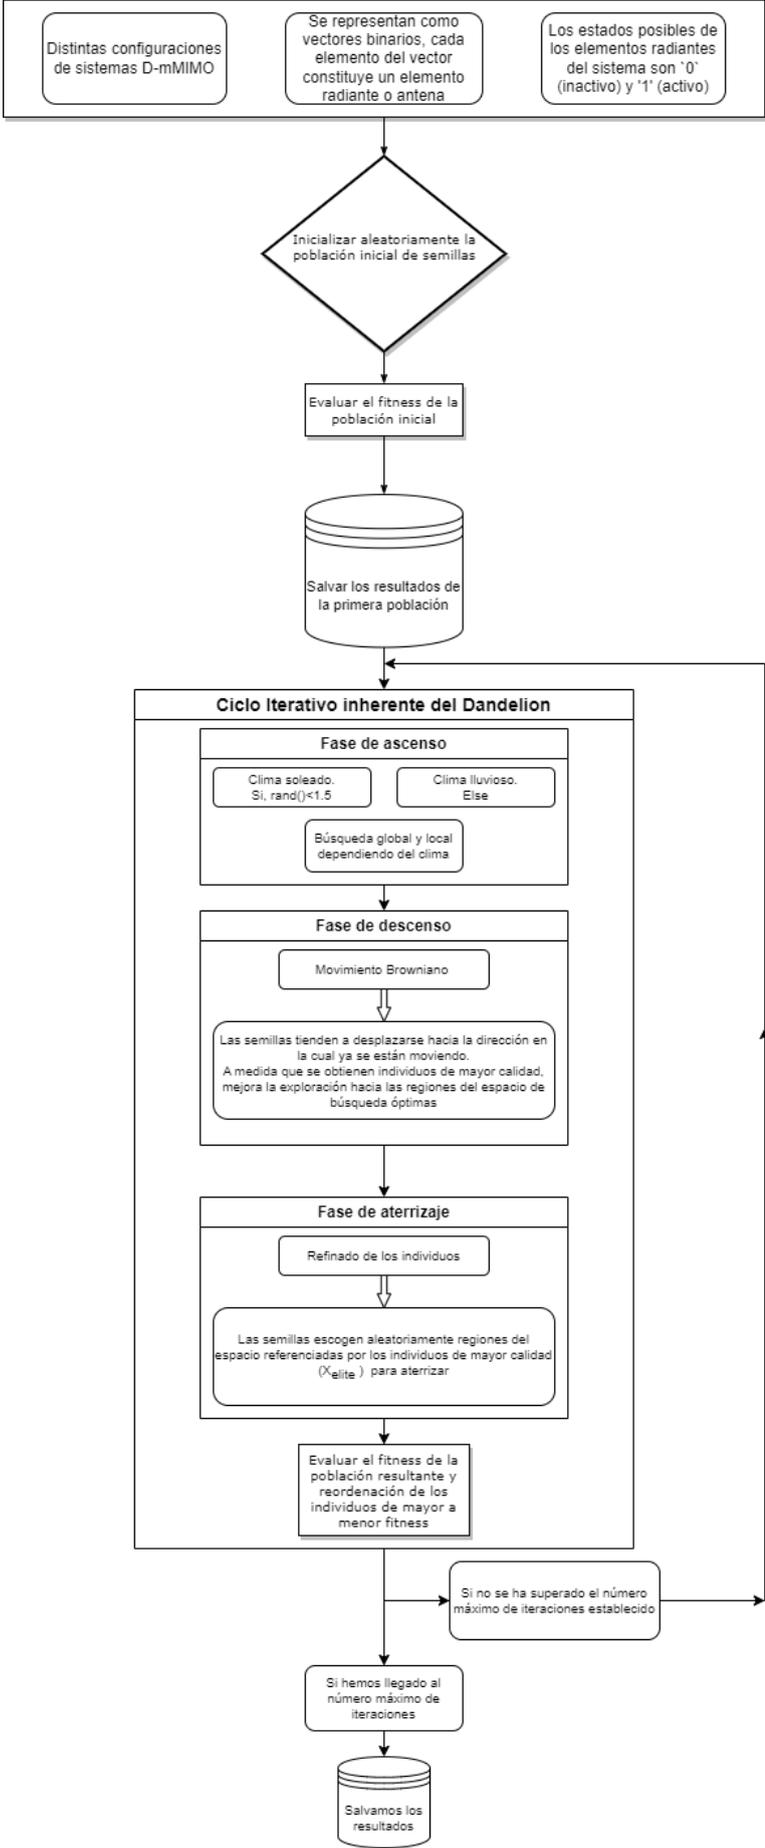


Figura 3.8 Diagrama de flujo del DO.

Referencias

- [1] Shijie Zhao, Tianran Zhang, Shilin Ma, Miao Chen, "Dandelion Optimizer: A nature-inspired metaheuristic algorithm for engineering applications", *Engineering Applications of Artificial Intelligence*, Volume 114, 2022, 105075, ISSN 0952-1976, <https://doi.org/10.1016/j.engappai.2022.105075>.
- [2] Feynman, Richard (1970). "The Feynman Lectures on Physics Vol I". Addison Wesley Longman. ISBN 978-0-201-02115-8.
- [3] J. R. Pérez, R. P. Torres, L. Valle, Ó. Fernández, L. Rubio, V. M. Rodrigo and J. Reig, "Selección de antenas mediante algoritmos genéticos en sistemas MIMO masivo distribuido", I+D+i PID2020-119173RB-C21 y PID2020-119173RB-C22, Jun. 2020.
- [4] M. Benmimoune, E. Driouch, W. Ajib and D. Massicotte, "Novel transmit antenna selection strategy for massive MIMO downlink channel", *Wireless Networks*, vol. 3, no. 8, pp. 2473-2484, Nov. 2017.
- [5] P. Zhu, Z. Sheng, J. Bao and J. Li, "Antenna selection for full-duplex distributed massive MIMO via the Elite Preservation genetic algorithm", *IEEE Comm. Letters*, vol. 26, no. 4, Apr. 2022

Capítulo 4

Resultados

En este capítulo se incluyen, para un escenario de interior, los resultados más representativos que permiten validar la aplicación del método de optimización al problema planteado. El análisis se realizará apoyándonos en gráficos y tablas con el objetivo dual de ajustar los parámetros del optimizador y comparar objetivamente los sistemas MIMO concentrado y distribuido en diferentes situaciones. En lo que respecta a la estructura del capítulo, inicialmente se abordará la descripción del escenario en el cual se llevaron a cabo estas simulaciones; a continuación, se presentará la comparativa en rendimiento de ambos sistemas (D-mMIMO y C-mMIMO), en igualdad de condiciones y con el mismo número potencial de antenas activas para, posteriormente, exponer los resultados y las conclusiones de las simulaciones realizadas.

4.1 Escenario de interés

El análisis se ha llevado a cabo en el entorno representado en la Figura 4.1, que se corresponde con la planta principal de la Escuela Técnica Superior de Ingenieros Industriales y de Telecomunicación de la Universidad de Cantabria [1]-[2]. En la Figura 4.1, se detallan aspectos del entorno y la disposición de los 20 terminales de usuario (UTs) o transmisores considerados en la investigación y la ubicación de las agrupaciones de antenas o arrays receptores para los sistemas C- y D-mMIMO. En el caso del array C-mMIMO, éste se configura como un array cuadrado situado a una altura de 2,5 m del suelo, compuesto por 10×10 dipolos $\lambda/2$ uniformemente espaciados en ambas dimensiones con una separación de $0,536 \lambda$ a 26 GHz, banda de frecuencia de interés en el estudio. Por otro lado, en el caso del sistema distribuido, D-mMIMO, las 100 antenas se distribuyen uniformemente en toda la planta del edificio. Las simulaciones para obtener la matriz de canal en ambos sistemas se realizaron utilizando CINDOOR, una herramienta software que aúna técnicas de trazado de rayos basadas en una implementación tridimensional completa de óptica geométrica y teoría uniforme de la difracción (3D GO/UTD) [1], [3]. Estas simulaciones se llevaron a cabo en la banda n258, con un ancho de banda de 500 MHz (25,75-26,25 GHz), considerando un espaciado de 60 kHz entre subportadoras, en línea con uno de los espaciados en OFDM considerados en los estándares, con $N_f=8334$ tonos en frecuencia y centrando el análisis en el enlace ascendente [1].

En lo que respecta a los detalles concretos del escenario, éste tiene una entrada principal con un Hall amplio, tal y como se muestra en la Figura 4.2, con escaleras y ascensor para acceder a las demás plantas del edificio. A la derecha de la entrada se encuentra la conserjería, y a la izquierda, la secretaría. En la parte derecha de la entrada, como se muestra en la Figura 4.3, hay un pasillo curvo que da acceso a ocho aulas, escaleras, dos ascensores y baños.

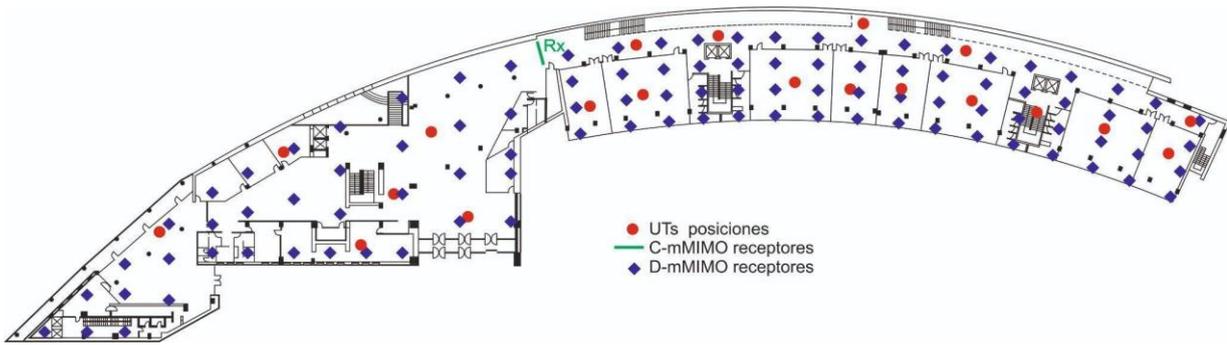


Figura 4.1 Vista vertical de la planta 0 de la ETSIT.



Figura 4.2 Entrada principal ETSIT.



Figura 4.3 Pasillo ETSIT.

4.2 Comparativa de los sistemas MIMO

En esta subsección realizamos una comparación de los canales C-mMIMO y D-mMIMO en términos de los valores representativos y estadísticas de parámetros como la eficiencia espectral (SE) y el factor de equidad de Jain (Jain's Fairness Index, JFI). Para ello representaremos las funciones de distribución acumulada (CDF) de la eficiencia espectral y JFI de ambos sistemas, con las 100 antenas activas. De esta manera podemos observar el rendimiento de ambos sistemas en una primera configuración sin aplicar el método de optimización, pudiendo poner en valor el margen de mejora disponible para poder enjuiciar posteriormente de una forma más fiable los resultados obtenidos y el papel que desempeña el método de optimización. Los resultados de este análisis preliminar se muestran en la Figura 4.4.

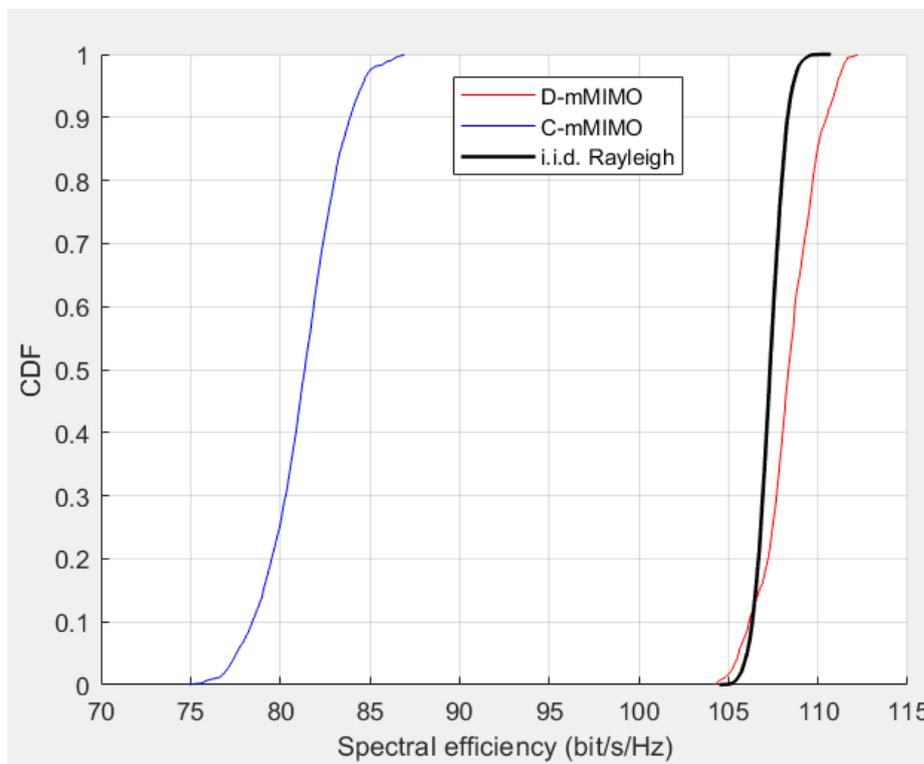


Figura 4.4 Eficiencia espectral de ambos sistemas con las 100 antenas activas.

Como podemos observar en la Figura 4.4, para las CDFs asociadas con los sistemas C- y D-mMIMO cuando los 20 UTs están activos, en términos de eficiencia espectral el sistema MIMO masivo distribuido permite alcanzar valores de SE mucho mayores que en el caso del sistema concentrado, con diferencias que para el valor mediano superan los 25 bit/s/Hz.

La distribución espacial de las antenas en el caso D-mMIMO contribuye a una mayor diversidad y a lograr los valores propuestos. Al tener antenas ubicadas en diferentes puntos del entorno, se mejora la probabilidad de que al menos una antena tenga una buena línea de visión con un usuario en particular. Esto se traslada a la matriz de canal y a los resultados de SE.

Otro de los parámetros que interviene en la función de coste como métrica para evaluar el rendimiento de ambos sistemas MIMO es el JFI. Como ya se planteó en el segundo capítulo de este TFG, el índice de equidad de Jain o JFI, es una métrica utilizada para evaluar la equidad en la asignación de recursos. El índice varía de 0 a 1, donde 0 indica una asignación totalmente desigual (un usuario recibe todos los recursos) y 1 indica una asignación perfectamente equitativa. Cuando se aplica al contexto de sistemas MIMO, ya sean distribuidos o concentrados, el JFI se puede adaptar para evaluar la equidad en la asignación de recursos (SE en nuestro caso) a los diferentes usuarios o nodos en el sistema.

En la Figura 4.5 se incluyen, en un análisis preliminar, las CDFs del JFI para ambos sistemas mMIMO, concentrado y distribuido, considerando de nuevo los 20 UTs y las 100 antenas activas. Los resultados dejan entrever de nuevo la superioridad del D-mMIMO, con margen para “apagar” antenas, o dicho de otro modo, el optimizador podrá explorar el espacio de soluciones eliminando parte de esas 100 antenas para relajar el JFI hasta el umbral del sistema concentrado. Hay que hacer constar, que las CDFs de ajuste del sistema concentrado que se han utilizado como objetivo de referencia podrían ser sustituidas por cualesquiera otros valores de SE y JFI que se marcasen para el diseño/optimización del sistema D-mMIMO.

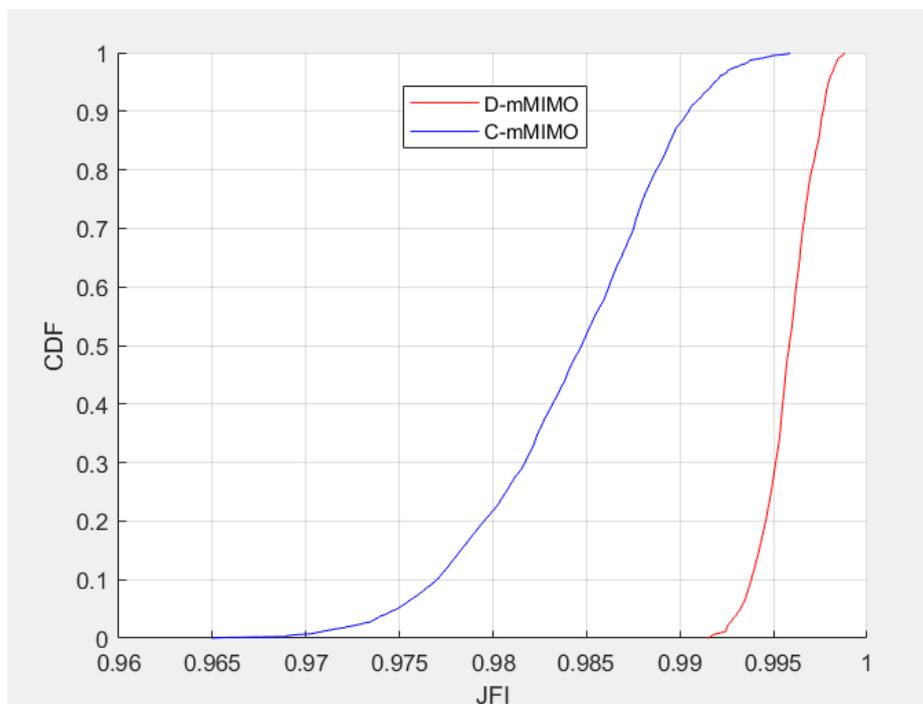


Figura 4.5 Jain's Fairness Index (JFI) de ambos sistemas con 100 antenas activas.

4.3 Parámetros del algoritmo

En esta subsección se detallan los parámetros específicos del algoritmo Dandelion (DO) utilizados para la optimización del encendido y apagado de antenas en nuestro array. La elección adecuada de estos parámetros es esencial para el rendimiento y la convergencia efectiva del algoritmo. Hay que hacer constar que la puesta a punto del algoritmo Dandelion, como ocurre con el resto de métodos de optimización de naturaleza heurística, variará en

muchos según el problema físico al que se aplica.

En el desarrollo del algoritmo Dandelion es esencial destacar la naturaleza influyente de diferentes parámetros, muchos de los cuales están intrínsecamente vinculados a variables aleatorias. Esta conexión con la aleatoriedad desempeña un papel fundamental en la mejora de la exploración y explotación del algoritmo, evitando que éste pueda quedarse atrapado en mínimos locales. La aleatoriedad se introduce en varias facetas del algoritmo para fomentar la diversidad de soluciones y evitar una convergencia prematura hacia regiones específicas del espacio de búsqueda. Esto es particularmente crucial en estos problemas de optimización, donde la presencia de múltiples soluciones locales de calidad similar podría obstaculizar la búsqueda de la solución global.

Como vimos en el capítulo anterior, son muchos los parámetros que intervienen en el algoritmo DO, pero debido a la búsqueda de aleatoriedad se seleccionaron como parámetros “sintonizables”, el tamaño de la población y el número máximo de iteraciones.

4.3.1 Tamaño de la población

El tamaño de la población, P , determina el número de soluciones candidatas (dandelions) que coexisten en cada iteración del algoritmo. Este parámetro influye en la diversidad y exploración del espacio de búsqueda. En nuestro caso, se estableció en un valor de 40 para equilibrar la exploración (en las iteraciones iniciales) y la explotación (acelerar convergencia según avanza la búsqueda) de forma eficiente. Para llegar a este valor, se realizó un estudio mediante simulaciones del algoritmo, barriendo un número elevado de valores de P hasta encontrar el valor de ajuste óptimo. Se llevaron a cabo simulaciones para los valores de población de: 15, 20, 25, 30, 35, 40, 45, 50, 55 y 60 dandelions. Siempre partiendo de unas condiciones iniciales iguales para cada simulación, es decir, mismos parámetros en todas las simulaciones; hasta llegar a una selección de valores con los cuales alcanzamos soluciones más satisfactorias. En la Figura 4.6 se incluyen las curvas de convergencia del DO para una realización aislada del algoritmo tomada como ejemplo con cada tamaño de población.

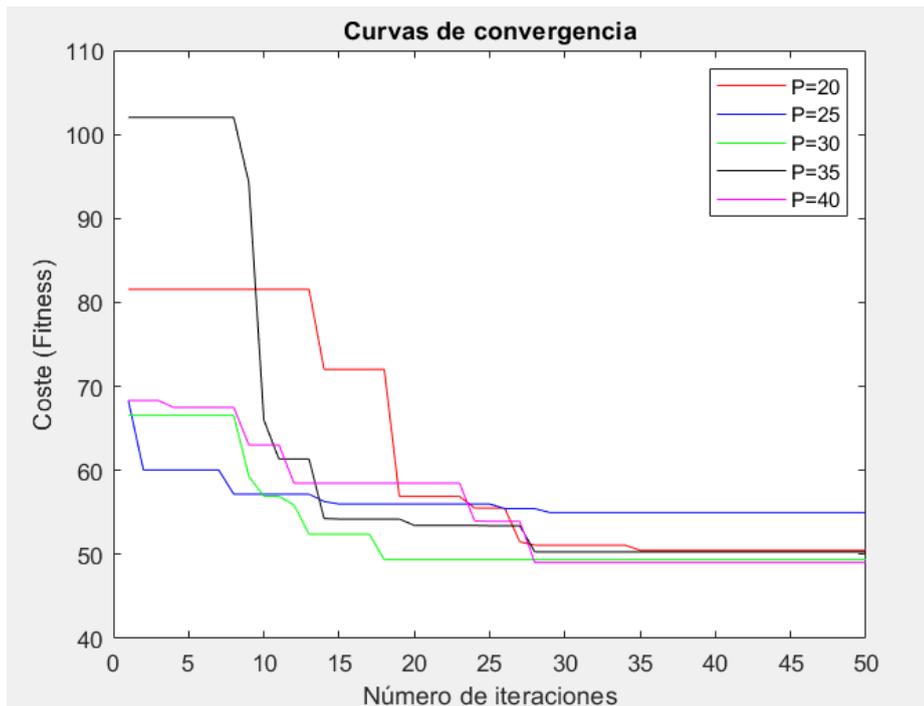


Figura 4.6 Curvas de convergencia del algoritmo para distintos tamaños de población. ($P=20$, $P=25$, $P=30$, $P=35$, $P=40$)

Como observamos en la Figura 4.6, tenemos 3 valores de P que destacan sobre los 5 seleccionados, en cuanto al coste mínimo alcanzado tras la convergencia del algoritmo. De esta manera se seleccionó tal y como comentamos en el inicio de esta subsección el valor de $P=40$, ya que obtenemos de media un coste inferior al resto de valores, con una velocidad de convergencia similar en todos los casos analizados.

4.3.2 Número máximo de iteraciones

El número máximo de iteraciones, denotado como *Maxiteration*, indica cuántas veces se realiza el ciclo principal inherente del algoritmo Dandelion. Este parámetro controla la duración total de la optimización. Para nuestro estudio, se fijó en un valor de 50 iteraciones para garantizar una búsqueda y convergencia adecuada, pero, a la vez, sin alargar innecesariamente los tiempos de ejecución.

Para llegar a este valor se realizó un estudio, en el cual se realizaron un número elevado de simulaciones con distintas semillas y tamaños de población, hasta encontrar un valor de iteraciones que nos ha permitido visualizar de manera correcta la convergencia del algoritmo en todas las ejecuciones del mismo.

4.3.3 Otros parámetros

Además de los parámetros estándar del algoritmo Dandelion, se introdujeron parámetros específicos del problema relacionados con la optimización y selección de antenas. Estos incluyen los pesos a aplicar en la función de coste para ponderar adecuadamente los efectos de los errores de ajuste cometidos tanto en la SE como en el JFI. En este sentido, se han considerado para el sumando de error asociado al término de SE, un peso de 0.002 y, para el

término que recoge los errores en el JFI, un valor de 1.0. Estos parámetros se ajustaron experimentalmente para lograr un rendimiento óptimo en el problema de aplicación.

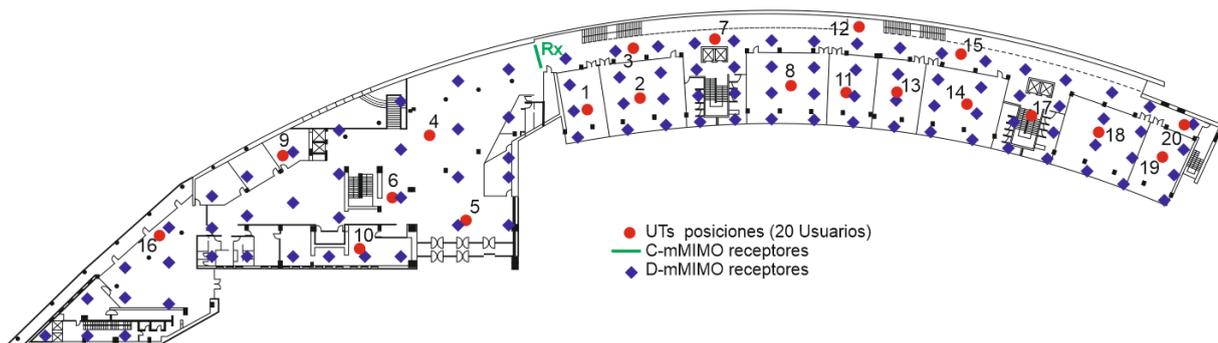
La elección cuidadosa de estos parámetros se basó en pruebas y análisis exhaustivos realizados para garantizar que el algoritmo Dandelion convergiese eficientemente hacia soluciones óptimas.

4.4 Análisis de los resultados

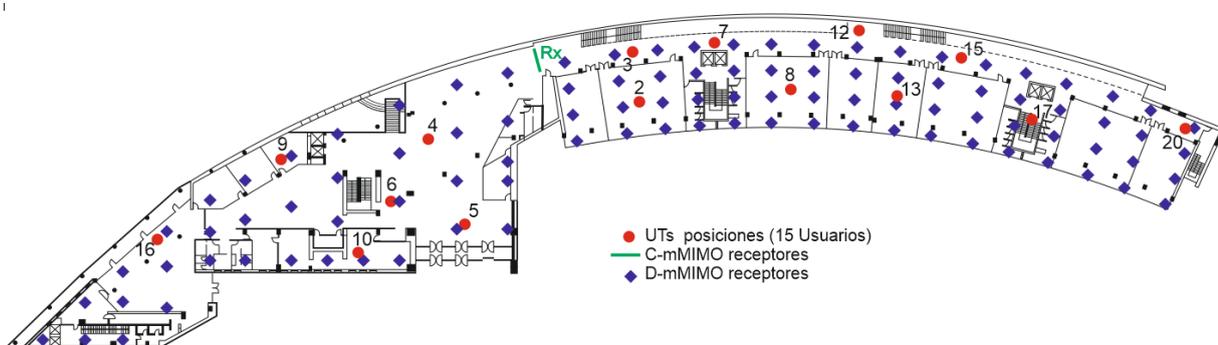
4.4.1 Análisis comparativo de la eficiencia espectral y JFI

En esta sección se lleva a cabo un detallado análisis comparativo de la eficiencia espectral y del JFI obtenidos con los dos sistemas mMIMO, y considerando diferentes conjuntos de usuarios activos. Además de los citados resultados obtenidos con el DO, se incluyen como referencia los resultados asociados con un canal Rayleigh. El objetivo principal es evaluar el desempeño de estos sistemas bajo diferentes cargas de usuarios (UTs), considerando configuraciones distintas, con 20, 15, 10 y 5 UTs, de acuerdo con la distribución que para caso se muestra en la Figura 4.7.

Este enfoque nos permitirá examinar las soluciones que aporta el DO para el sistema D-mMIMO en diferentes casos. Para llevar a cabo el análisis se realizaron 10 simulaciones para cada una de las cargas de usuarios, partiendo de los mismos parámetros iniciales para el DO.



(a)



(b)

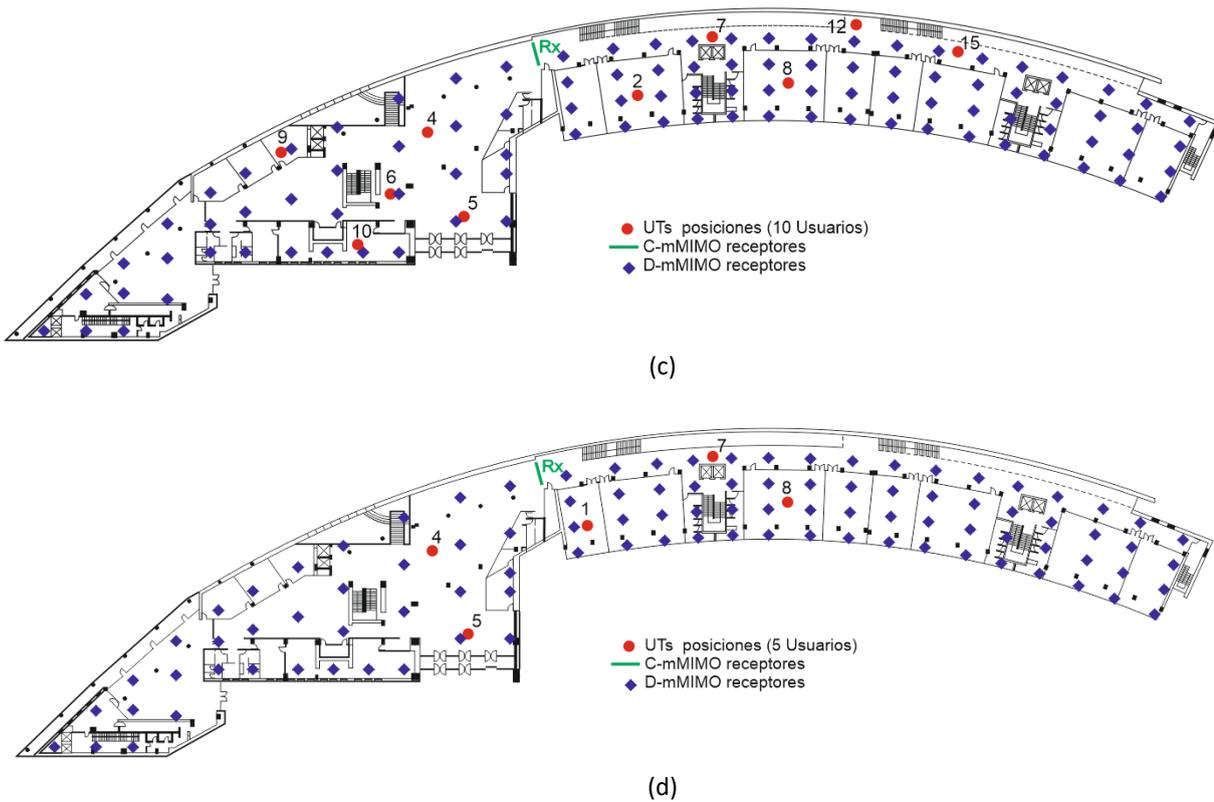


Figura 4.7 Distribución de los usuarios (UTs) en las 4 configuraciones escogidas (20, 15, 10 y 5).

En la Figura 4.7 los UTs considerados en cada uno de los 4 casos bajo estudio están representados por puntos (en rojo) dispersos sobre la planta del edificio. Además, se han marcado con rombos (en azul) los emplazamientos potenciales de los receptores D-mMIMO y con una línea (en verde) el array receptor C-mMIMO. Posteriormente veremos reflejado sobre estos gráficos el efecto de la optimización.

Para analizar la precisión del ajuste se utilizarán las CDFs de la SE y el JFI. Estas funciones ofrecen una representación de la probabilidad de alcanzar ciertos valores, permitiendo comparaciones detalladas entre los diferentes escenarios. El análisis de las CDFs nos permitirá identificar tendencias, patrones y trade-offs en el desempeño del sistema optimizado bajo condiciones variables.

Tomando como referencia en el ajuste las CDFs del sistema concentrado, en la Figura 4.8 se incluyen los resultados de la optimización para el sistema D-mMIMO en términos de ajuste de la calidad de la solución para 20 y 15 UTs y, en la Figura 4.9, los resultados asociados con los casos de 10 y 5 UTs activos.

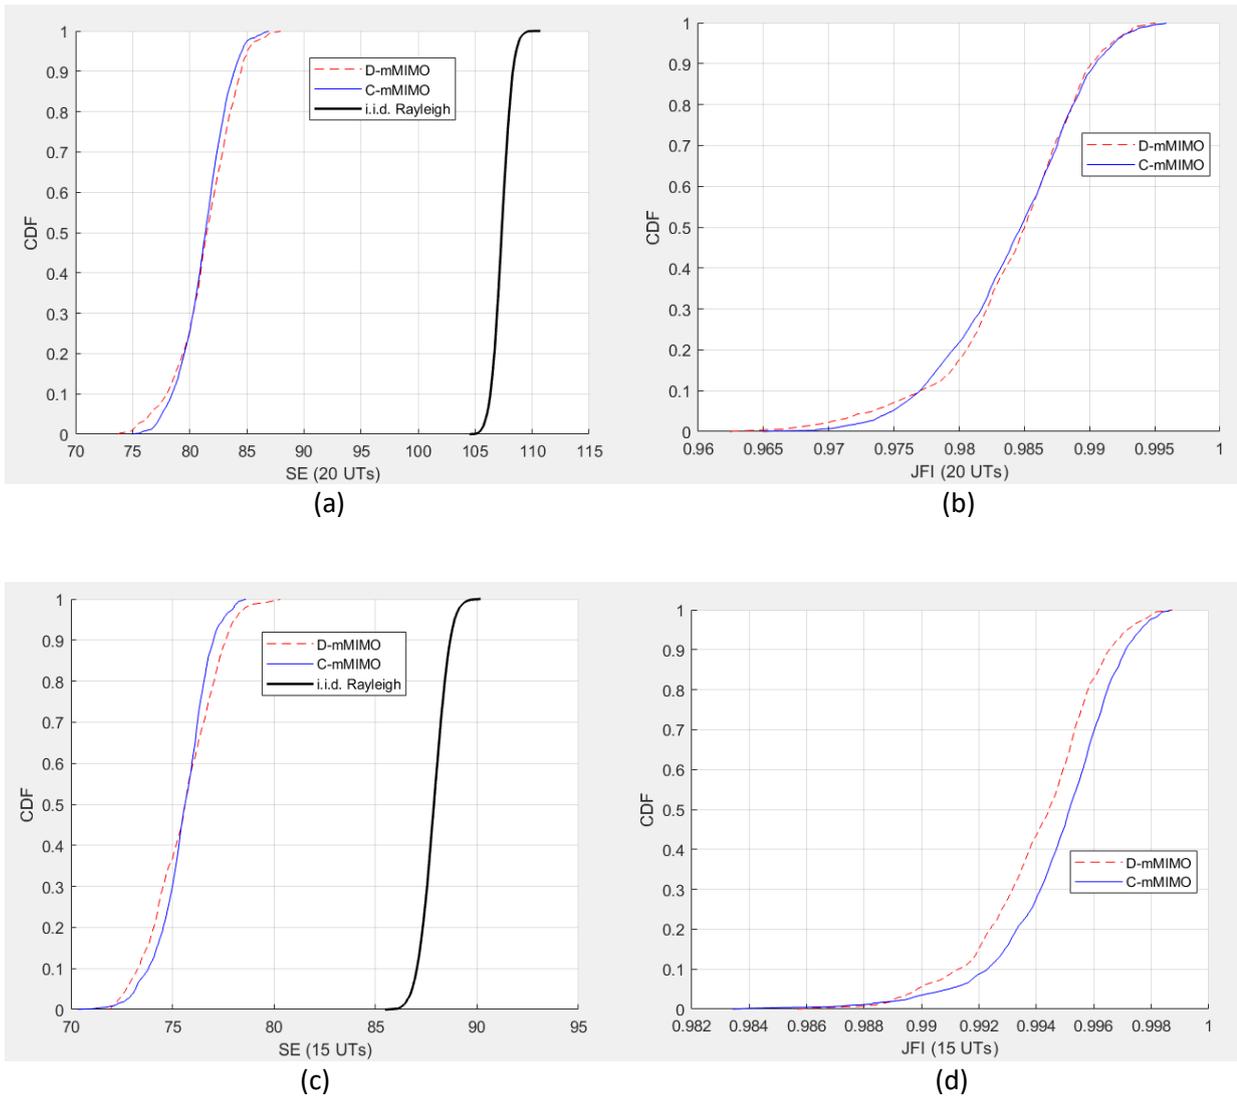


Figura 4.8 CDFs de la SE y JFI de los sistemas D-mMIMO optimizado, con detalle del ajuste alcanzado sobre el sistema objetivo y de referencia, el C-mMIMO. Resultados obtenidos para una de las semillas de arranque del DO. Se incluye en la comparativa a efecto orientativo el canal Rayleigh. (a) SE, 20 UTs, (b) JFI, 20 UTs, (c) SE, 15 UTs, (d) JFI, 15 UTs.

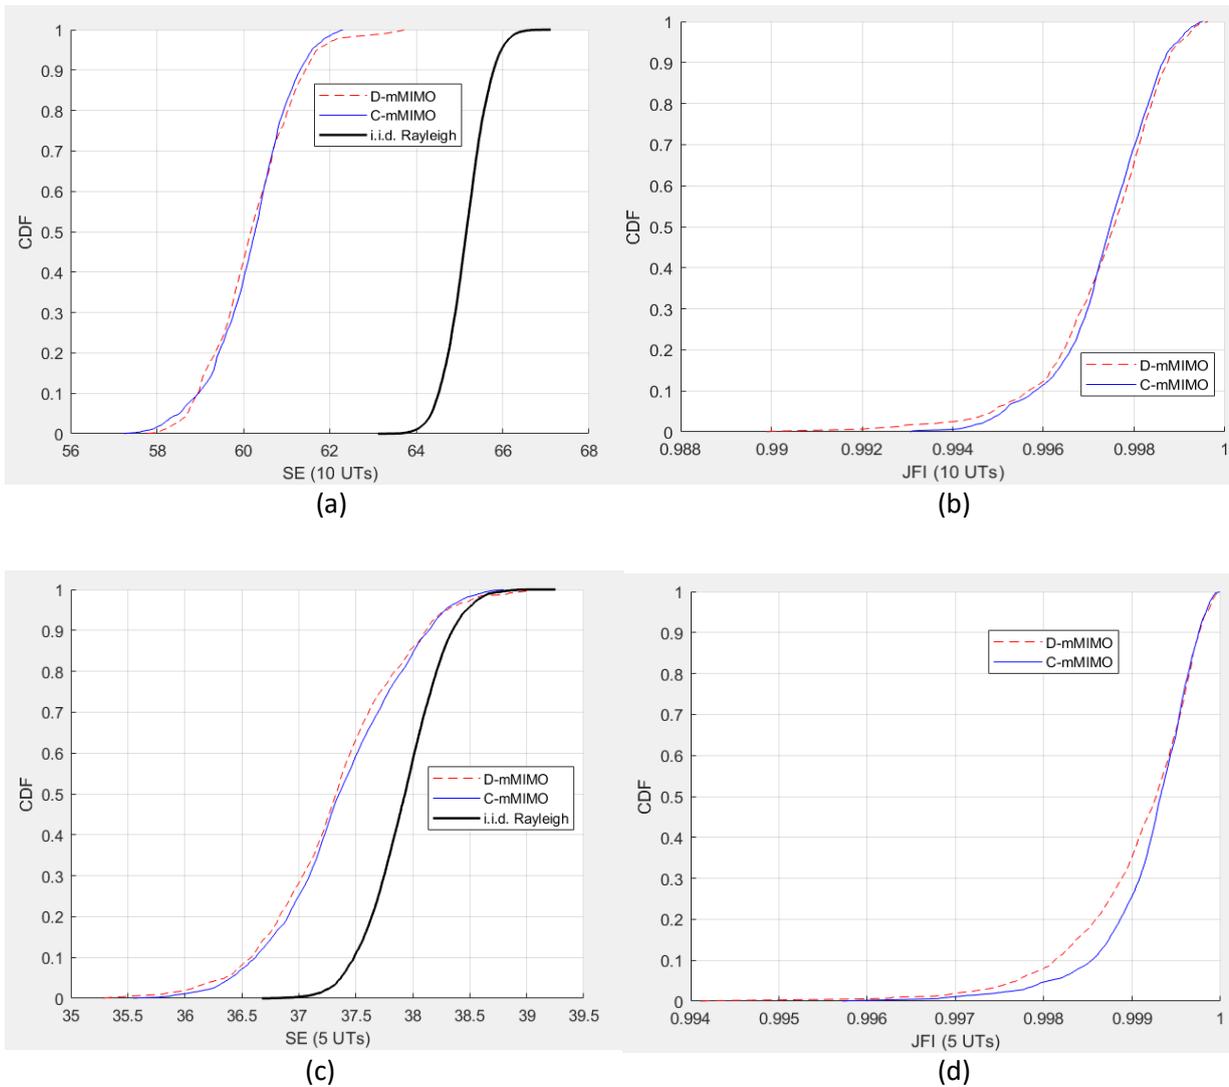


Figura 4.9 CDFs de la SE y JFI de los sistemas D-mMIMO optimizado, con detalle del ajuste alcanzado sobre el sistema objetivo y de referencia, el C-mMIMO. Resultados obtenidos para una de las semillas de arranque del DO. Se incluye en la comparativa a efecto orientativo el canal Rayleigh. (a) SE, 10 UTs, (b) JFI, 10 UTs, (c) SE, 5 UTs, (d) JFI, 5 UTs.

La notable precisión evidenciada en el ajuste de las CDFs, tanto en la SE suma como en el factor de equidad valida la eficacia de la metodología propuesta en términos de calidad del ajuste.

Como complemento a la calidad del ajuste, resta analizar qué pasa con el array D-mMIMO en términos del número de antenas que propone activar el algoritmo en cada caso. En este sentido, ya se adelanta que el número de antenas en el sistema D-mMIMO se reduce respecto a las 100 antenas del array concentrado, confirmando la utilidad de la metodología, y los beneficios tangibles para la red móvil. Esta disminución en el número de antenas se traduce en una reducción del procesamiento de señal y un aumento consiguiente en la eficiencia energética del sistema, contribuyendo así a una optimización más generalizada del rendimiento de la red.

4.4.2 Análisis cuantitativo de los resultados

Para llevar a cabo un análisis más completo de los resultados, necesitamos contemplar otros parámetros con los cuales podemos valorar eficazmente los resultados de la optimización. De manera complementaria, vamos a analizar aspectos que mezclan la calidad de la solución con los tiempos de simulación y el desempeño general del algoritmo Dandelion.

Para las cuatro configuraciones de usuarios propuestas, la Tabla 4.1 incluye detalles estadísticos de las 10 simulaciones realizadas en cada caso. En concreto, en la Tabla 4.1 se incluyen los valores de coste (fitness) mínimo, máximo y promedio obtenidos entre todas las simulaciones para cada carga de usuarios. Analizando los resultados observamos como los valores del fitness mejoran a medida que aumenta la carga de usuarios tanto para los valores máximos como los mínimos, con esto nos damos cuenta de que el algoritmo es capaz de ajustar con mayor precisión cuando trabaja con una carga de usuarios mayor, donde aprovecha la diversidad en mejor medida al tener una cantidad de emplazamientos superior.

Una justificación más objetiva de los valores del fitness alcanzado tiene que ver con la situación de partida en la optimización. Es decir, al igual que para el caso de 20 UTs las Figuras 4.4 y 4.5 permiten ver el gran margen que tiene el algoritmo para “apagar” antenas e igualar al sistema concentrado, si hiciéramos el mismo estudio para las otras tres configuraciones, veríamos cómo a medida que se reduce el número de UTs las diferencias a igualdad de antenas del array activas (100 tanto en C- como en D-mMIMO) los márgenes de ajuste cada vez son más estrechos. Esto implica que al optimizar, el DO se debe ver forzado a dejar cada vez más antenas activas según baja el número de UTs. Los valores del fitness promedio que se muestran en la Tabla 4.1 dejan entrever este hecho, pues en las últimas iteraciones del algoritmo, por la tipología de función de fitness utilizada, lo que más afecta al residuo del coste total es el número de antenas activas. Estas afirmaciones y conclusiones se corroborarán a continuación al analizar las soluciones planteadas en cada caso por el DO en términos de antenas activas.

Tabla 4.1 Fitness (Mín, Máx y promedio), desviación estándar y tiempo de CPU.

Nº UTs	Fitness (Mín)	Fitness (Máx)	Fitness (Promedio)	Desviación estándar (σ)	Tiempo de CPU Promedio (s)
5	94.156	96.438	94.819	0.683	9625.887
10	73.742	79.970	78.226	1.884	11647.404
15	65.428	74.462	69.656	3.687	16923.789
20	48.755	53.748	50.501	1.702	25095.551

En el caso del tiempo de CPU promedio, tal y como esperábamos, aumenta a medida que aumenta la carga de usuarios ya que a pesar de que para el algoritmo sea más difícil el ajuste para una menor carga de usuarios y conlleva un mayor número de iteraciones como veremos en esta sección, los cálculos inherentes de la función “Fitness” se simplifican considerablemente.

En la Tabla 4.2 se incluye un análisis de las soluciones en términos del número de antenas a activar en el sistema D-mMIMO. En realidad, se incluyen detalles de cómo contribuyen al fitness total los tres sumandos que conforman dicha función de coste. Para las 10 simulaciones realizadas con cada configuración de UTs se incluyen los valores mínimo, máximo y promedio de cada término.

Tabla 4.2 Valores Máx, Mín y Promedio (Nº de antenas, SE y JFI).

Nº UTs	Nº de antenas			Error (SE) Peso = 0.002			Error (JFI) Peso = 1		
	Nº antenas (Mín)	Nº antenas (Máx)	Nº antenas (Promedio)	SE (Mín)	SE (Máx)	SE (Promedio)	JFI (Mín)	JFI (Máx)	JFI (Promedio)
5	90	93	91	0.04	4.86	1.51	1.04	1.90	1.38
10	73	75	73	0.30	1.21	0.90	0.37	4.78	4.00
15	58	62	60	0.21	2.37	0.95	3.95	12.65	8.00
20	46	49	47	0.28	4.07	1.71	0.22	4.26	1.54

Para el caso del número de antenas nos encontramos con un mayor número en promedio para cargas de usuarios menores, es decir va disminuyendo el número de antenas a medida que aumenta el número de UTs, lo cual refuerza nuestra afirmación anterior. Cuando la carga de usuarios es baja, el algoritmo tiene poco margen para rebajar de 100 el número de antenas necesarias para igualar las CDFs de referencia del sistema concentrado y, esto hace que sea más difícil encontrar una distribución de emplazamientos que satisfaga las necesidades de todos los usuarios. Como resultado, el algoritmo consigue reducir el número de antenas activas, pero en menor grado en casos de baja carga de usuarios aunque aun considerando esto, consigue una mejora notable respecto del sistema C-mMIMO que para un rendimiento semejante mantendrá sus 100 antenas activas.

En cuanto al error de la eficiencia espectral, debemos tener en cuenta el peso que este tiene sobre nuestra función de coste, en este estudio se establece un peso de 0.002 para el error de la eficiencia espectral. Tras recopilar los datos de las simulaciones y analizarlos, no observamos un patrón claro ya sea creciente o decreciente a medida que aumentamos la carga de usuarios, si bien es cierto que todos mantienen un valor promedio cercano a la unidad. La idea es que

en las iteraciones iniciales, este término del fitness sea el que domine la búsqueda, de tal forma que aún ponderando los errores con 0.002, el error de este sumando domina y condiciona la exploración inicial del espacio de soluciones.

Por último, en la tabla 4.2 se representa el error del JFI, para el estudio se ha establecido un peso de valor 1. En este caso, al igual que con la eficiencia espectral no encontramos un patrón creciente o decreciente en el valor promedio del error a medida que aumenta el número de UTs, sin embargo, podemos observar valores de error más elevados, lo cual es razonable teniendo en cuenta el peso que se ha establecido para el JFI en nuestra función de coste.

Con el fin de complementar la información de las Tablas 4.1 y 4.2, en la Figura 4.10 se incluyen para las 10 simulaciones y para cada configuración de UTs, las curvas de convergencia con la evolución del fitness. Se representan las curvas de convergencia de las 40 simulaciones realizadas (en rojo) y su promedio (en azul).

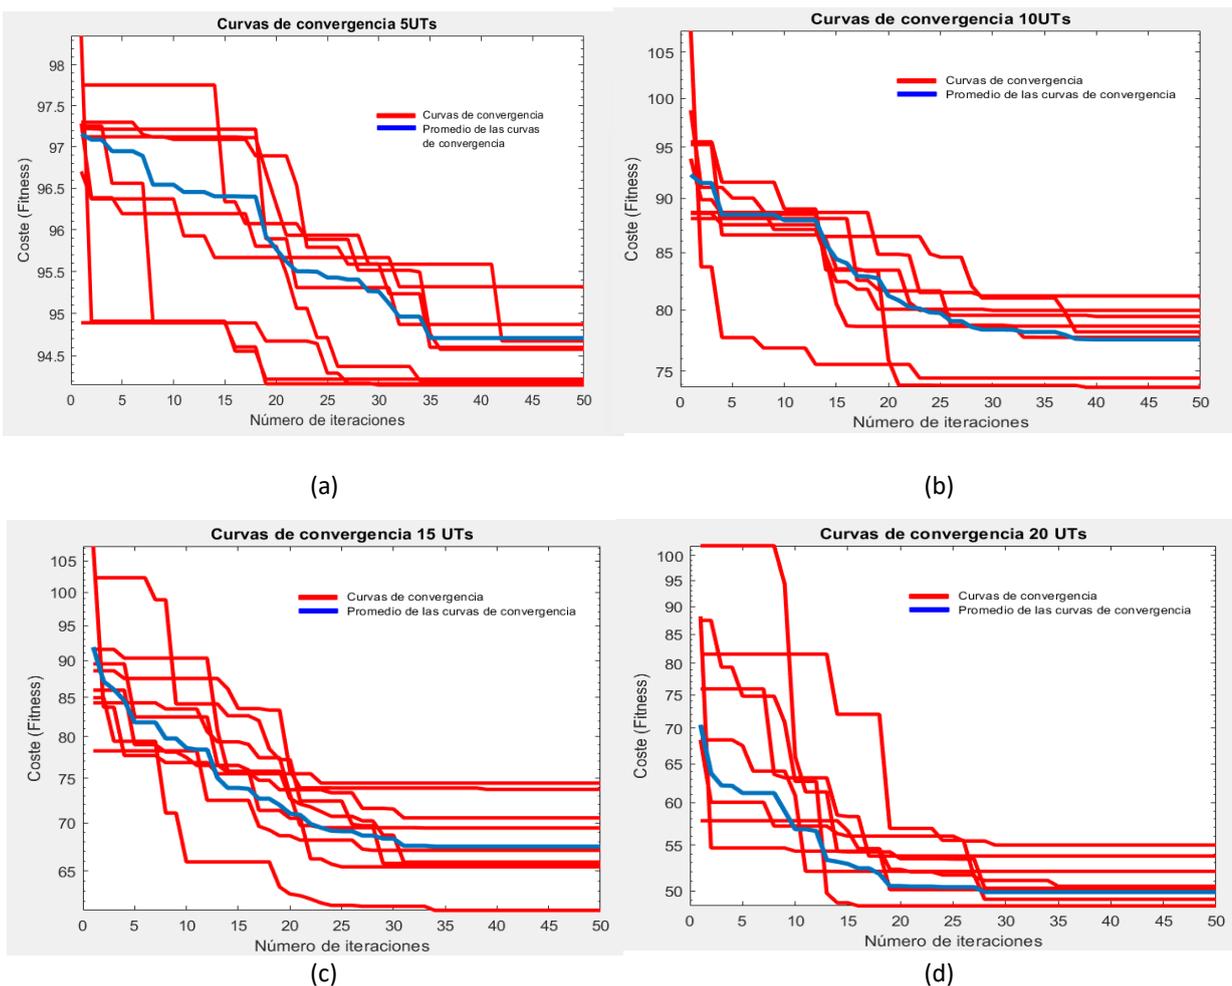
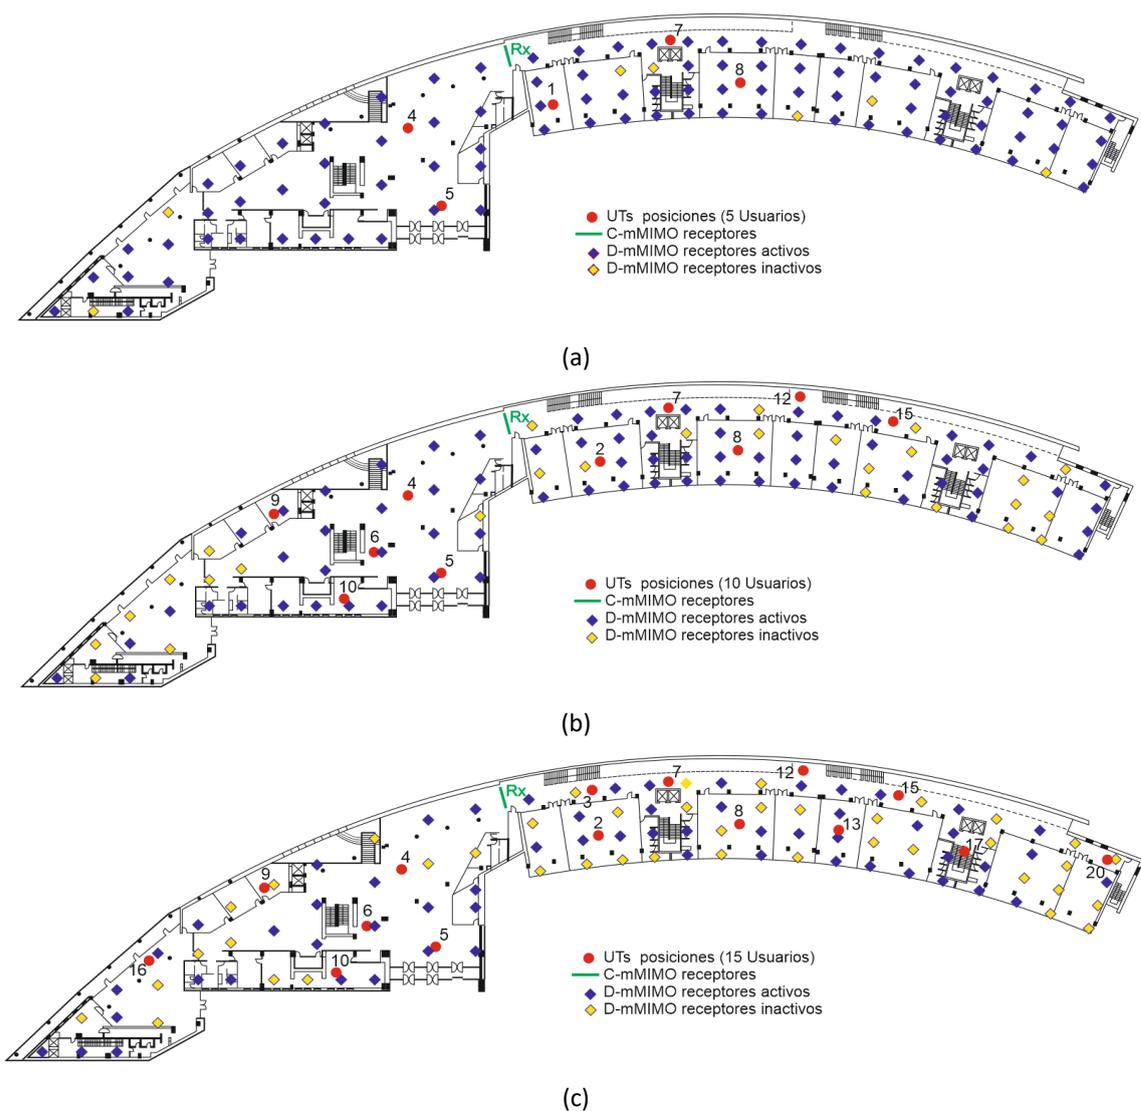


Figura 4.10 Curvas de convergencia de las simulaciones bajo estudio para los 4 casos. (a) 5 UTs, (b) 10 UTs, (c) 15 UTs, (d) 20 UTs.

En la figura 4.9 (a) se muestran las curvas de convergencia de las 10 simulaciones para 5 usuarios (UTs), y se observa que en promedio el algoritmo necesita alrededor de 40 iteraciones para converger y estancarse en torno a una solución. En la Figura 4.10 (b), para el caso de 10 usuarios, en promedio se necesitan 35 iteraciones para converger. En la Figura 4.10 (c) se

muestran las curvas de convergencia para una carga de 15 usuarios y siguiendo el mismo patrón decreciente se reduce el número de iteraciones promedio para converger a 30. Por último, en la Figura 4.10 (d) se muestran las curvas de convergencia de las 10 simulaciones correspondientes a 20 UTs, en las cuales el algoritmo necesita en promedio unas 25 iteraciones para converger.

Se observa, tal y como se mencionó anteriormente, que para el algoritmo es más complejo llegar a una solución satisfactoria cuando trabaja con un número de usuarios más reducido, necesitando un mayor número de iteraciones para converger. Además, gracias a la representación de las curvas podemos apreciar la desviación estándar del fitness que visualmente coincide con los datos numéricos representados en las tablas. Por último, en la Figura 4.11 se incluyen los resultados de la optimización en términos de las antenas que propone activar el DO en cada caso (5, 10, 15 y 20 UTs) sobre el escenario de prueba, y tomando como ejemplo la mejor simulación de cada caso en términos de coste:



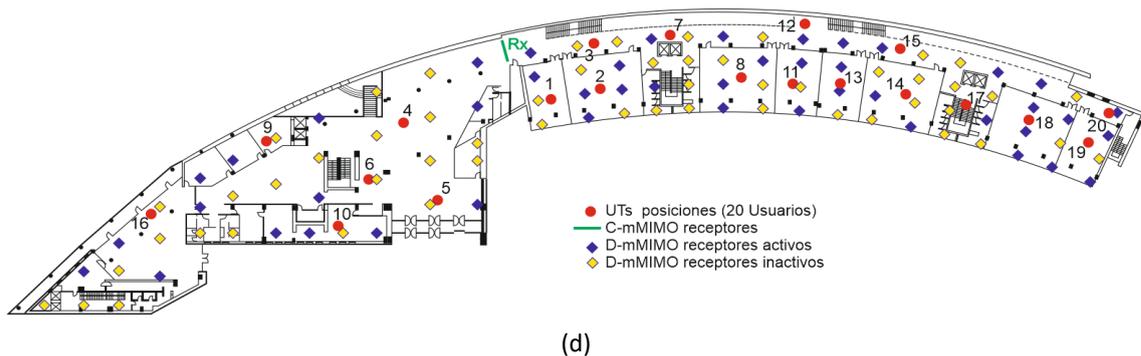


Figura 4.11 Resultados de la optimización sobre la planta de la ETSIT para los 4 casos. (a) 5 UTs, (b) 10 UTs, (c) 15 UTs, (d) 20 UTs. Detalle de la mejor solución del Do en cada caso con detalle de las antenas que se deben activar en el sistema distribuido.

La Figura 4.11 incluye para cada una de las cuatro configuraciones de usuarios, la distribución espacial de los UTs (en rojo), los receptores D-mMIMO activos tras la optimización (marcados con rombos en azul), los receptores inactivos (marcados con rombos en amarillo) y con una línea (en verde) la posición del array receptor para el caso del C-mMIMO.

En la Figura 4.11 (a) se encuentra el mejor resultado que de entre las 10 simulaciones se obtiene para el caso con 5 UTs, para la cual obtenemos un fitness de 94.156, con 93 antenas activas, un error de la SE de 0.110 y un error del JFI de 1.045. Si bien es cierto que aunque respecto al pool inicial de 100 posibles antenas potenciales la reducción de antenas activas no es tan notable, si existe una ligera mejora respecto al sistema C-mMIMO.

En la Figura 4.11 (b) se representa el mejor resultado obtenido para 10 usuarios, con un fitness de 73.742 , 73 antenas activas, un error de la SE de 0.370 y un error del JFI de 0.370.

En la Figura 4.11 (c) se representa el mejor resultado de las simulaciones con 15 usuarios activos, en la cual obtuvimos un fitness de 65.428, 59 antenas activas, un error de la SE de 0.320 y un error del JFI de 6.107.

Por último, en la Figura 4.11 (d) se muestra el mejor resultado en de las simulaciones para 20 usuarios, obteniendo un fitness de 48.755, 46 antenas activas, un error de la SE de 1.566 y un error del JFI de 0.879.

Referencias

- [1] J. Merino, J. R. Pérez, R. P. Torres, L. Valle, Ó. Fernández, L. Rubio, V. M. Rodrigo and J. Reig, “Comparativa entre canales MIMO masivo concentrado y distribuido a 26 GHz,” in Proc. URSI 2022 - XXXVII Simposio Nacional de la Unión Científica Internacional de Radio, Málaga, Spain, Sep. 2022.
- [2] Javier Merino Polidura, “Análisis comparativo de las tecnologías Massive MIMO concentrado y distribuido en entornos de interiores mediante trazado de rayos”, Trabajo Fin de Grado, Universidad de Cantabria, septiembre 2021.
- [3] O. Fernández, L. Valle, M. Domingo and R. P. Torres, “Flexible rays,” IEEE Veh. Technol. Mag., vol. 3, no. 1, pp. 18-27, Mar. 2008.

Capítulo 5

Conclusiones y líneas futuras

El objetivo de este Trabajo de Fin de Grado ha sido estudiar la optimización de arrays de antenas distribuidos (D-mMIMO) mediante el algoritmo Dandelion. La investigación se ha centrado en abordar el problema de la selección de antenas, con el fin de igualar el rendimiento de un sistema concentrado de MIMO masivo, consiguiendo de esta manera una reducción del número de antenas activas sin unas pérdidas significativas de rendimiento con respecto al sistema concentrado.

Los resultados obtenidos muestran que el algoritmo Dandelion es capaz de encontrar soluciones óptimas al problema de selección de antenas en D-mMIMO. En concreto, se ha demostrado que el algoritmo es capaz de reducir el número de antenas activas en un sistema D-mMIMO aprovechando el margen existente entre el sistema C-mMIMO convencional y el D-mMIMO en términos de SE y JFI en igualdad de condiciones para igualar el rendimiento de los sistemas.

En concreto, los resultados obtenidos en este trabajo se pueden resumir en las siguientes conclusiones:

- El algoritmo Dandelion es capaz de encontrar soluciones óptimas al problema de selección de antenas en D-mMIMO, manteniendo un alto rendimiento (similar al del sistema convencional) en términos de eficiencia espectral y JFI.
- El número de antenas activas necesarias en un sistema D-mMIMO para igualar el rendimiento de un sistema C-mMIMO depende de la carga de usuarios. En general, obtenemos un mejor ajuste (en proporción) del número de antenas cuando aumenta el número de UTs, es decir, se requiere un menor número de antenas activas (en proporción) en sistemas con una mayor carga de usuarios, ya que se aprovecha la diversidad de emplazamientos.
- La reducción del número de antenas activas en un sistema D-mMIMO conlleva una serie de ventajas, como una reducción del coste de implementación, una mejora de la eficiencia energética y una mayor flexibilidad en el despliegue.

En general, los resultados obtenidos en este trabajo demuestran que el algoritmo Dandelion es una herramienta eficaz para la optimización de arrays de antenas distribuidos. El algoritmo

es capaz de encontrar soluciones óptimas al problema, manteniendo un alto rendimiento y conllevando una serie de ventajas frente a los sistemas C-mMIMO.

Por otra parte, este TFG abre una serie de líneas de investigación futuras. En concreto, sería interesante estudiar el rendimiento del algoritmo Dandelion en escenarios más complejos, como sistemas con una mayor cantidad de usuarios o sistemas con condiciones de propagación más difíciles.

El algoritmo Dandelion se ha probado en este TFG en un escenario de interior amplio, con un número reducido de usuarios y condiciones de propagación favorables. Sin embargo, sería interesante estudiar el rendimiento del algoritmo en escenarios más complejos, pudiendo optar por grandes centros comerciales.

En concreto, sería interesante estudiar el rendimiento del algoritmo Dandelion en sistemas con una mayor cantidad de usuarios, sistemas con condiciones de propagación más difíciles, o sistemas con movilidad de los usuarios.

Además de las líneas de investigación mencionadas anteriormente, también sería interesante estudiar otros aspectos relacionados con la optimización del sistema D-mMIMO. En concreto, sería interesante estudiar los siguientes aspectos:

- *Estrategias de selección de antenas más eficientes.* El algoritmo Dandelion es una herramienta eficaz para la optimización del sistema distribuido, como hemos podido demostrar en el trabajo, pero es posible que existan estrategias de selección de antenas más eficientes.
- *Inclusión de otros factores en la función de coste.* La función de coste utilizada en este TFG tiene en cuenta la eficiencia espectral y el JFI. Sin embargo, sería posible incluir otros factores en la función de coste, como la cobertura, la fiabilidad o la eficiencia energética, de esta manera, con una métrica más compleja podríamos valorar en otros aspectos el rendimiento del sistema optimizado. No es descartable pensar en la posibilidad de abordar el problema con técnicas de optimización multiobjetivo que dejen abiertas más posibilidades, dado que introducir más sumandos en la función de coste puede hacer que, si no se pondera adecuadamente su influencia, el algoritmo pierda eficacia en la búsqueda de soluciones óptimas.
- *Aplicación de la selección de antenas a otros sistemas:* La selección de antenas también puede aplicarse a otros sistemas, como los sistemas MIMO convencionales. Podría pensarse incluso en combinar y/o comparar los resultados de este método con otras algorítmicas más cercanas a la cada más en auge inteligencia artificial.
- *Una vez que se ha desarrollado el software y probado el funcionamiento del algoritmo DO,* queda abierto su uso futuro a cualesquiera problemas de optimización que en el campo de las comunicaciones móviles considere el grupo investigador. El requisito para su uso eficiente es encontrar una función de coste a minimizar que pueda ser

utilizada por el Dandelion para dirigir la búsqueda y que constituye el único nexo de unión entre el optimizador y el problema físico a modelar.

En definitiva, este TFG abre una serie de líneas de investigación futuras que pueden contribuir a mejorar el rendimiento de los sistemas D-mMIMO y fomentar su implementación en diversos ámbitos aprovechando las evidentes ventajas demostradas.