



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

ESTUDIO Y OPTIMIZACIÓN DEL CONSUMO ENERGÉTICO DEL FERROCARRIL MEDIANTE REDES NEURONALES Y ALGORITMOS HEURÍSTICOS

DOCTORANDO: PABLO MARTÍNEZ FERNÁNDEZ



Director de Tesis: Prof. Dr. Ricardo Insa Franco

UNIVERSITAT POLITÈCNICA DE VALÈNCIA
ESCUELA DE DOCTORADO

PROGRAMA DE DOCTORADO EN INFRAESTRUCTURAS DE TRANSPORTE Y TERRITORIO

Valencia, noviembre de 2019

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA DE CAMINOS, CANALES Y
PUERTOS

PROGRAMA DE DOCTORADO EN INFRAESTRUCTURAS DE TRANSPORTE Y TERRITORIO



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



TESIS DOCTORAL

STUDY AND OPTIMISATION OF RAILWAYS ENERGY CONSUMPTION BY MEANS
OF NEURAL NETWORKS AND HEURISTIC ALGORITHMS

ESTUDIO Y OPTIMIZACIÓN DEL CONSUMO ENERGÉTICO DEL FERROCARRIL
MEDIANTE REDES NEURONALES Y ALGORITMOS HEURÍSTICOS

DOCTORANDO:

PABLO MARTÍNEZ FERNÁNDEZ

DIRECTOR DE TESIS:

PROF. DR. RICARDO INSA FRANCO

Realizada dentro del Programa de Doctorado en Infraestructuras de Transporte y Territorio
para la obtención del título de Doctor por la Universitat Politècnica de València

Departamento de Ingeniería e Infraestructura de los Transportes

VALENCIA, NOVIEMBRE DE 2019

La ciencia puede divertirnos y fascinarnos, pero es la ingeniería la que cambia el mundo.

Isaac Asimov

PRESENTATION AND SUMMARY OF THE DOCTORAL THESIS

Transport is one of the most fundamental activities of modern societies, but it is also one of the sectors with higher energy consumption and associated emissions. Railways are one of the most efficient transport means, but there is still margin to reduce their energy consumption and to improve their sustainability. One of the most effective ways to do so, particularly in urban railways, is to optimise speed profiles.

Several studies focus on this problem by using simulation and algorithms to identify efficient speed profiles under different scenarios. In this context, the main objective of this doctoral thesis is to contribute to the knowledge regarding tools used to study railways energy consumption in urban railways. The thesis focuses, on the one hand, on studying the potential use of neural networks as simulation tools. On the other hand, the thesis carries out a systematic comparison between some of the most used meta-heuristic optimisation algorithms.

Hence, a driving simulator combined with a neural network has been developed. This simulator takes a set of commands, which represent the output of the ATO system, and calculates the corresponding speed profile, travel time and energy consumed. The simulator has been validated using real data measured in the Valencia metro network, with an average error of 1.43% (time estimation) and 1.49% (energy estimation). Using this simulator, more than 5,800 combinations of ATO commands have been simulated in 32 inter-station stretches selected from the Valencia metro network (considering both directions of travel) and the corresponding real Pareto fronts have been calculated.

Afterwards, five meta-heuristic algorithms (NSGA-II, MOPSO, SPEA-II, MOEA-D and MOACOr) have been used to obtain sets of non-dominated solutions for each of the 64 case studies. The convergence, regularity and diversity of these solution sets have been then evaluated through a series of metrics, applying statistical analysis to determine whether any difference found was significant. The results show that all five algorithms perform similarly in terms of convergence and regularity, but that MOPSO performs significantly better in terms of diversity (and, to a lesser extent, SPEA-II), while the most common algorithm (NSGA-II) yields poorer results. These conclusions aim to offer a guide to choose more effective algorithms for future railways optimisation studies.

PLANTEAMIENTO Y RESUMEN DE LA TESIS DOCTORAL

El transporte es una actividad fundamental en las sociedades modernas, pero también es uno de los sectores que más contribuye al consumo energético y a las emisiones. El ferrocarril es uno de los medios de transporte más eficientes, pero todavía existe un margen de mejorar para reducir su consumo energético y aumentar su sostenibilidad. Uno de los modos más efectivos para lograr esto, especialmente en ferrocarriles de ámbito urbano, es mediante la optimización de marchas.

Existen muchos estudios que afrontan este problema a través de la simulación y el uso de algoritmos que identifican perfiles de conducción eficiente bajo múltiples escenarios. En este contexto, el propósito de la tesis doctoral es contribuir al conocimiento de las herramientas empleadas para estudiar el consumo energético en el ferrocarril de ámbito urbano, centrándose por un lado en estudiar el posible uso de redes neuronales como instrumento de simulación, y por otro lado llevando a cabo una comparativa sistemática de algunos de los algoritmos meta-heurísticos de optimización más usados.

Para ello, se ha desarrollado un simulador de marchas combinado con una red neuronal, el cual parte de una serie de comandos que representan la salida del sistema ATO, y calcula el correspondiente perfil de velocidad, tiempo de viaje y consumo energético. El simulador ha sido validado con datos reales medidos en la red de metro de Valencia, con un error medio del 1,43% en la estimación de tiempo y del 1,49% en la estimación de la energía. Mediante este simulador se han calculado más de 5.800 combinaciones de comandos ATO para 32 tramos de la red de metro de Valencia (considerando ambos sentidos de circulación) y se han calculado los frentes de Pareto reales para cada caso.

A partir de aquí, se han aplicado cinco algoritmos meta-heurísticos (NSGA-II, MOPSO, SPEA-II, MOEA-D y MOACOr) para obtener conjuntos de soluciones no-dominadas en cada uno de los 64 casos de estudio, y se ha evaluado el grado de convergencia, regularidad y diversidad de cada conjunto de soluciones con una serie de métricas, aplicando un análisis estadístico para detectar diferencias significativas. Se ha observado que los cinco algoritmos ofrecen resultados similares en términos de convergencia y regularidad, pero que el algoritmo MOPSO destaca significativamente en términos de diversidad (y, en menor medida, el algoritmo SPEA-II), siendo el algoritmo más habitual (NSGA-II) el que peor resultados presenta en este sentido. Estos resultados pretenden ofrecer una cierta guía para escoger algoritmos más efectivos en futuros estudios de optimización de marchas ferroviarias.

PLANTEJAMENT I RESUM DE LA TESI DOCTORAL

El transport és una activitat fonamental en les societats modernes, però també és un dels sectors que més contribueix al consum energètic i a les emissions. El ferrocarril és un dels mitjans de transport més eficients, però encara hi ha marge per a reduir el seu consum energètic i augmentar la seua sostenibilitat. Un dels modes més efectius per a fer això, especialment en ferrocarrils d'àmbit urbà, es mitjançant l'optimització de marxos.

N'hi ha molts estudis que afronten aquest problema mitjançant la simulació i l'ús d'algoritmes que identifiquen perfils de conducció eficient baix múltiples escenaris. En aquest context, el propòsit d'aquesta tesi doctoral és contribuir al coneixement de les eines utilitzades per a estudiar el consum energètic en el ferrocarril d'àmbit urbà, centrant-se, per una banda, en estudiar l'ús de xarxes neuronals com a instrument de simulació, i per altra fent una comparació sistemàtica d'alguns dels algoritmes meta-heurístics més utilitzats.

Per a fer això, s'ha desenvolupat un simulador de marxos combinat amb una xarxa neuronal que, partint d'uns comandaments que representen l'eixida del sistema ATO, calcula el corresponent perfil de velocitats, temps de viatge i consum energètic. El simulador ha estat validat amb dades reals mesurades en la xarxa de metro de València, amb un error mitjà del 1,43% en l'estimació del temps i del 1,49% en l'estimació de l'energia. Mitjançant aquest simulador s'han calculat més de 5.800 combinacions de comandaments ATO per a 32 trams de la xarxa de metro de València (considerant ambdós sentits de circulació), i s'han calculat els fronts de Pareto reials per a cada cas.

A partir d'ací, s'han aplicat cinc algoritmes meta-heurístics (NSGA-II, MOPSO, SPEA-II, MOEA-D i MOACOr) per a obtenir conjunts de solucions no-dominades en cadascú dels 64 casos d'estudi, i s'ha avaluat el grau de convergència, regularitat i diversitat de cada conjunt de solucions amb una sèrie de mètriques, aplicant un anàlisi estadístic per a detectar diferències significatives. S'ha observat que els cinc algoritmes ofereixen resultats similars pel que fa a convergència i regularitat, però que l'algoritme MOPSO destaca significativament pel que fa a diversitat (i, en menor grau, l'algoritme SPEA-II), mentre que l'algoritme més habitual (NSGA-II) és el que dona pitjor resultats en aquest sentit. Aquests resultats pretenen oferir una mena de guia per a escollir algoritmes més efectius en futurs estudis d'optimització de marxos ferroviàries.

AGRADECIMIENTOS

Cuando uno se plantea por primera vez hacer una tesis doctoral, no es consciente de qué es lo que le espera realmente, de a qué se va a enfrentar durante los tres años (o más) que dura esta odisea. No me refiero al arduo trabajo que supone, pues eso se da por descontado; sino a la cascada de dudas, altibajos, retrocesos y bloqueos que jalonan este período tan singular.

Cualquier doctorando lo sabe: la de veces que te llegas a plantear para qué estás haciendo todo esto, cuántas veces pones en duda todo el trabajo que llevas hecho, cuán a menudo piensas que no vas a conseguir nada y que tanto esfuerzo habrá sido en vano. Y sin embargo sigues adelante, paso a paso, día a día, hasta que por fin te encuentras con un par de cientos de páginas escritas y un puñado extra de canas en la barba. ¡Al fin has terminado!

Todavía no tengo claro qué se siente al terminar la tesis. Alivio, por supuesto, porque por fin la tarea está concluida. Una indefinible fatiga mental, también, fruto de todos esos vaivenes emocionales que has tenido que navegar como buenamente has podido. Y, tal vez, una pizca de satisfacción, porque has sido capaz de llegar al final y, quizás, has aportado un pequeño granito de arena al conocimiento.

Uno casi puede dejarse llevar por el entusiasmo al pensar en todo lo que ha logrado. Pero entonces piensas en la gente que te ha acompañado durante estos tres años (durante toda tu vida, de hecho), y te das cuenta de que, sin ellos, no habrías llegado muy lejos. Por ello, no quiero desperdiciar la oportunidad de mostrar mi gratitud.

En primer lugar, doy las gracias a mi tutor, Ricardo Insa, que me dio la oportunidad de trabajar en el departamento de transportes, me alentó a hacer la tesis, y sin cuya colaboración nunca habría podido completar este viaje.

También quiero dar las gracias a toda mi familia, y en especial a mis padres, Lorenzo y Mercedes. Soy quien soy gracias a ellos, sé que siempre podré contar con su ayuda y confianza, y todo cuanto llegue a ser en esta vida vendrá, en gran medida, de ellos. También quiero mencionar a mis abuelos (Lorenzo, Teresa, Pedro y Jerónima) pues, aunque tres de ellos ya no están, son parte fundamental de mi vida. A todos ellos, así como a mis hermanos (Marcos, Javier y Julia), y al resto de mi familia: os quiero.

Quiero además dar las gracias a todos mis compañeros del departamento, con los que he compartido estos años de trabajo y que me han ayudado mucho, comenzando por mis colegas del grupo ferroviario: Pablo Salvador e Ignacio Villalba, y también a los que ya se fueron: Carla García y Rafael Sánchez. También quiero agradecer especialmente el apoyo de Rosa Arroyo, quien ha soportado con paciencia muchas de mis quejas y protestas durante estos tres años tan singulares. Mi gratitud también para Patricia Mares (quien también se ha llevado su parte de lamentaciones) y para el resto de personas que han pasado por el departamento desde que me incorporé en 2012.

No quiero tampoco olvidarme de aquellos amigos que me han acompañado, no sólo durante los años de tesis sino desde mucho antes: Kike, Vicente, Enrique, Álvaro, Jorge Sánchez, Adrián... y en especial Jorge Molines, a quien conocí el primer día de carrera y que ha sido uno de mis mejores amigos desde entonces. ¡Gracias chicos!

Para finalizar, mi gratitud a todos los que imaginan y crean, en cualquier tiempo y lugar y a través de cualquier medio. Sin todos ellos, esta vida sería muy aburrida.



Doctorando
Pablo Martínez Fernández

ÍNDICE

| | |
|--|-----------|
| PRESENTATION AND SUMMARY OF THE DOCTORAL THESIS | 6 |
| PLANTEAMIENTO Y RESUMEN DE LA TESIS DOCTORAL | 7 |
| PLANTEJAMENT I RESUM DE LA TESI DOCTORAL | 8 |
| AGRADECIMIENTOS | 9 |
| LISTADO DE FIGURAS | 15 |
| LISTADO DE TABLAS | 18 |
| LISTA DE ABREVIATURAS Y SÍMBOLOS | 20 |
| Capítulo I | 24 |
| 1. Introducción | 24 |
| 1.1. Motivación | 25 |
| 1.2. Objetivos | 26 |
| 1.3. Estructura de la tesis..... | 27 |
| Capítulo II | 29 |
| 2. El consumo energético del ferrocarril | 29 |
| 2.1. Introducción..... | 29 |
| 2.2. Sistemas de electrificación ferroviaria..... | 32 |
| 2.2.1. Sistemas de corriente continua | 33 |
| 2.2.2. Sistemas de corriente alterna | 34 |
| 2.3. Factores que influyen en el consumo energético..... | 34 |
| 2.3.1. Dinámica del vehículo | 35 |
| 2.3.2. Conducción y señalización | 37 |
| 2.3.3. Sistemas auxiliares | 38 |
| 2.3.4. Pérdidas de energía | 38 |
| 2.4. Medidas de ahorro energético | 39 |
| 2.4.1. Mejoras en los sistemas auxiliares..... | 40 |
| 2.4.2. Mejoras en la cadena de transmisión | 41 |
| 2.4.3. Mejoras en la resistencia al avance | 42 |
| 2.4.4. Mejoras en la infraestructura | 43 |
| 2.4.5. Conducción eficiente..... | 44 |
| 2.4.6. Freno regenerativo | 46 |
| 2.4.7. Efectividad de las medidas de ahorro | 47 |
| 3. Modelización del consumo energético | 49 |
| 3.1. Introducción..... | 49 |
| 3.2. Enfoque de modelización..... | 51 |
| 3.2.1. Modelos matemáticos exactos | 51 |
| 3.2.2. Simulación determinista paso a paso. | 52 |
| 3.2.3. Otros enfoques | 55 |
| 3.3. Complejidad del modelo. Elementos a considerar | 56 |
| 3.4. Discusión sobre el estado del arte de la modelización | 58 |
| 3.5. Conclusiones | 61 |
| 4. Optimización del consumo energético | 63 |
| 4.1. Introducción..... | 63 |

| | | |
|--------------------------|--|------------|
| 4.2. | Definición del problema de optimización..... | 65 |
| 4.3. | Optimización de marchas en redes de metro..... | 69 |
| 4.3.1. | Planteamiento y objetivos..... | 69 |
| 4.3.2. | Espacio de soluciones..... | 70 |
| 4.3.3. | Convergencia y diversidad..... | 71 |
| 4.4. | Métodos de optimización..... | 72 |
| 4.4.1. | Optimización analítica..... | 72 |
| 4.4.2. | Búsqueda sistemática..... | 73 |
| 4.4.3. | Programación lineal/no-lineal..... | 74 |
| 4.4.4. | Algoritmos meta-heurísticos..... | 76 |
| 4.5. | Discusión sobre el estado del arte de la optimización..... | 91 |
| 4.6. | Conclusiones..... | 95 |
| Capítulo III..... | | 97 |
| 5. | Descripción de la red de metro de Valencia..... | 97 |
| 5.1. | Introducción..... | 97 |
| 5.2. | Red de metro de Valencia..... | 97 |
| 5.2.1. | Visión general..... | 97 |
| 5.2.2. | Descripción de las líneas..... | 98 |
| 5.2.3. | Descripción del material rodante..... | 105 |
| 5.3. | Campaña de toma de datos..... | 108 |
| 5.3.1. | Equipos y montaje..... | 109 |
| 5.3.2. | Toma y procesado de datos..... | 111 |
| 5.4. | Análisis de datos. Tendencias de consumo..... | 113 |
| 5.5. | Ámbito de aplicación del estudio..... | 118 |
| Capítulo IV..... | | 120 |
| 6. | Simulador de marchas..... | 120 |
| 6.1. | Introducción..... | 120 |
| 6.2. | Estructura del simulador de marchas..... | 121 |
| 6.2.1. | Planteamiento..... | 121 |
| 6.2.2. | El sistema ATO..... | 124 |
| 6.2.3. | Características del vehículo..... | 126 |
| 6.2.4. | Control de fases de frenado..... | 132 |
| 6.2.5. | Condicionantes de confort..... | 133 |
| 6.3. | Resultados del simulador de marchas..... | 134 |
| 6.4. | Validación del simulador de marchas..... | 136 |
| 6.5. | Conclusiones..... | 138 |
| 7. | Red neuronal..... | 140 |
| 7.1. | Introducción..... | 140 |
| 7.2. | Estructura..... | 141 |
| 7.3. | Consideraciones para el entrenamiento de la red..... | 143 |
| 7.3.1. | Procesado previo de los datos..... | 144 |
| 7.3.2. | Metodología de entrenamiento..... | 146 |
| 7.3.3. | Criterios de evaluación del entrenamiento..... | 148 |
| 7.4. | Entrenamiento de la red..... | 150 |
| 7.5. | Tamaño de la red..... | 152 |
| 7.6. | Validación de la red..... | 153 |
| 7.7. | Conclusiones..... | 155 |

| | |
|---|------------|
| 8. Algoritmos de optimización..... | 157 |
| 8.1. Introducción..... | 157 |
| 8.2. Selección de algoritmos de optimización | 158 |
| 8.3. Implementación de algoritmos de optimización | 159 |
| 8.3.1. NSGA-II | 159 |
| 8.3.2. MOPSO | 160 |
| 8.3.3. SPEA-II | 161 |
| 8.3.4. MOEA-D | 162 |
| 8.3.5. MOACOr | 163 |
| 8.4. Definición de métricas | 164 |
| 8.4.1. Distancia Generacional (GD) | 164 |
| 8.4.2. Extensión (SPR) | 164 |
| 8.4.3. Espaciamiento (SP)..... | 165 |
| 8.4.4. Hipervolumen Normalizado (NH)..... | 165 |
| 8.5. Metodología de comparación..... | 166 |
| 8.6. Conclusiones | 168 |
| Capítulo V | 170 |
| 9. Resultados y análisis | 170 |
| 9.1. Introducción..... | 170 |
| 9.2. Frentes de Pareto..... | 171 |
| 9.3. Análisis de sensibilidad | 174 |
| 9.3.1. NSGA-II | 175 |
| 9.3.2. MOPSO..... | 177 |
| 9.3.3. SPEA-II | 180 |
| 9.3.4. MOEA-D | 183 |
| 9.3.5. MOACOr | 186 |
| 9.4. Comparativa tramo a tramo | 188 |
| 9.4.1. Líneas 1, 2 y 7 | 188 |
| 9.4.2. Líneas 3, 5 y 7 | 198 |
| 9.4.3. Conclusiones preliminares | 206 |
| 9.5. Comparativa cualitativa global | 207 |
| 9.6. Comparativa estadística..... | 210 |
| 9.6.1. Distancia Generacional (GD) | 212 |
| 9.6.2. Extensión (SPR) | 213 |
| 9.6.3. Espaciamiento (SP)..... | 214 |
| 9.6.4. Hipervolumen Normalizado (NH)..... | 215 |
| 9.7. Conclusiones | 218 |
| Capítulo VI | 221 |
| 10. Conclusiones | 221 |
| 10.1. Conclusiones | 221 |
| 10.2. Limitaciones | 225 |
| 10.3. Futuras líneas de investigación | 227 |
| Referencias | 229 |
| Anexo I. Relación de artículos..... | 236 |
| Anexo II. Conclusions | 237 |

Anexo III. Recopilación de resultados 243

LISTADO DE FIGURAS

| | |
|---|-----|
| <i>Figura 2.1: Reparto de consumos en la línea de Alta Velocidad Madrid-Sevilla. Fuente: Adaptado de (García Álvarez, 2006).</i> | 35 |
| <i>Figura 2.2: Esquema del flujo de energía en un vehículo ferroviario de tracción eléctrica. Fuente: Elaboración propia a partir de Douglas et al. (2015).</i> | 39 |
| <i>Figura 3.1: Esquema básico de un simulador de movimiento y consumo. Fuente: Elaboración propia.</i> | 53 |
| <i>Figura 3.2: Frecuencia de uso de cada enfoque de modelización. Fuente: Elaboración propia.</i> | 60 |
| <i>Figura 4.1: Espacio de soluciones y frente de Pareto en un problema de optimización con dos objetivos contradictorios. Fuente: Elaboración propia.</i> | 66 |
| <i>Figura 4.2: Esquema ilustrativo de los conceptos de convergencia y diversidad en algoritmos de optimización multi-objetivo. Fuente: Elaboración propia.</i> | 71 |
| <i>Figura 4.3: Esquema básico de funcionamiento de un algoritmo genético. Fuente: Elaboración propia.</i> | 78 |
| <i>Figura 4.4: Esquema básico de funcionamiento de un algoritmo SPEA-II. Fuente: Elaboración propia.</i> | 81 |
| <i>Figura 4.5: Esquema básico de funcionamiento de un algoritmo MOEA-D. Fuente: Elaboración propia.</i> | 82 |
| <i>Figura 4.6: Esquema básico de funcionamiento de un algoritmo de enjambre de partículas. Fuente: Elaboración propia.</i> | 85 |
| <i>Figura 4.7: Croquis de funcionamiento del ACO. Fuente: Elaboración propia.</i> | 86 |
| <i>Figura 4.8: Esquema básico de funcionamiento de un algoritmo MOACOr. Fuente: Elaboración propia.</i> | 88 |
| <i>Figura 4.9: Esquema básico de funcionamiento de un algoritmo Tabu Search. Fuente: Elaboración propia.</i> | 89 |
| <i>Figura 4.10: Esquema básico de funcionamiento de un algoritmo TLBO. Fuente: Elaboración propia.</i> | 90 |
| <i>Figura 4.11: Frecuencia de uso de cada enfoque de optimización. Fuente: Elaboración propia.</i> | 93 |
| <i>Figura 5.1: Plano de la red de metro de Valencia. Fuente: FGV.</i> | 99 |
| <i>Figura 5.2: Plano de la línea 1. Fuente: Plano-Metro.com.</i> | 100 |
| <i>Figura 5.3: Plano de la línea 2. Fuente: Plano-Metro.com.</i> | 101 |
| <i>Figura 5.4: Plano de la línea 3. Fuente: Plano-Metro.com.</i> | 101 |
| <i>Figura 5.5: Plano de la línea 4. Fuente: Plano-Metro.com.</i> | 102 |
| <i>Figura 5.6: Plano de la línea 5. Fuente: Plano-Metro.com.</i> | 102 |
| <i>Figura 5.7: Plano de la línea 6. Fuente: Plano-Metro.com.</i> | 103 |
| <i>Figura 5.8: Plano de la línea 7. Fuente: Plano-Metro.com.</i> | 103 |
| <i>Figura 5.9: Plano de la línea 8. Fuente: Plano-Metro.com.</i> | 104 |
| <i>Figura 5.10: Plano de la línea 9. Fuente: Plano-Metro.com.</i> | 105 |
| <i>Figura 5.11: Metro serie 4300. Fuente: Wikipedia.</i> | 106 |
| <i>Figura 5.12: Tranvías series 4200 (izquierda) y 3800 (derecha). Fuente: FGV.</i> | 107 |
| <i>Figura 5.13: Equipo sensor MSAV-DC. Fuente: Mors Smitt.</i> | 109 |
| <i>Figura 5.14: Esquema de medición en el vehículo instrumentado. Fuente: Elaboración propia.</i> | 110 |
| <i>Figura 5.15: Ejemplo de registro obtenido en un servicio Maritim Serrería-Aeroport (línea 5). Fuente: Elaboración propia.</i> | 112 |
| <i>Figura 5.16: Porcentaje de consumo medio de auxiliares respecto al consumo neto en disyuntor (arriba) y consumo medio de auxiliares por hora (abajo) según servicio y hora de salida, para la línea 1. Fuente: Elaboración propia.</i> | 115 |
| <i>Figura 5.17: Porcentaje de consumo medio de auxiliares respecto al consumo neto en disyuntor (arriba) y consumo medio de auxiliares por hora (abajo) según servicio y hora de salida, para la línea 5. Fuente: Elaboración propia.</i> | 116 |
| <i>Figura 6.1: Esquema de circulación en regulación y en deriva-remotor en un mismo tramo. Fuente: Elaboración propia.</i> | 122 |
| <i>Figura 6.2: Esquema de funcionamiento del simulador de marchas. Fuente: Elaboración propia.</i> | 124 |

Figura 6.3: Curvas esfuerzo - velocidad del vehículo. Fuente: FGV. 128

Figura 6.4: Curvas frenado - velocidad del vehículo. Fuente: FGV. 129

Figura 6.5: Curvas frenado - % manipulador del vehículo. Fuente: FGV. 130

Figura 6.6: Efecto de la longitud del tren en el cálculo de la pendiente y curvatura de la vía en cada punto de la ruta. Fuente: Elaboración propia. 131

Figura 6.7: Curva de frenado total: distancia de frenado hasta 0 en función de la velocidad actual. Fuente: Elaboración propia. 133

Figura 6.8: Ejemplo de marchas calculadas por el simulador en el tramo Colón-Alameda (líneas 3-5). Fuente: Elaboración propia. 135

Figura 6.9: Ejemplo de marchas calculadas por el simulador en el tramo Paiporta-Picanya (líneas 1-2). Fuente: Elaboración propia. 136

Figura 6.10: Comparativa entre perfiles medidos y simulados para los cuatro casos de control. Fuente: Elaboración propia. 137

Figura 7.1: Esquema de una red neuronal prealimentada de dos capas. Fuente: Elaboración propia. 142

Figura 7.2: Ejemplo de un registro de potencia de tracción y velocidad. Fuente: Elaboración propia. 145

Figura 7.3: Comparativa entre un fragmento de la señal original de potencia de tracción y su versión filtrada. Fuente: Elaboración propia. 146

Figura 7.4: Esquema del proceso de entrenamiento. Fuente: Elaboración propia. 149

Figura 7.5: ECMr promedio en función del tamaño de la red. Fuente: Elaboración propia. 152

Figura 7.6: Comparativa de potencia de tracción real vs modelizada por la red neuronal para el conjunto de entrenamiento. Fuente: Elaboración propia. 153

Figura 7.7: Comparativa de potencia de tracción real vs modelizada por la red neuronal para el conjunto de test independiente. Fuente: Elaboración propia. 154

Figura 8.1: Esquema del significado de la métrica de Hipervolumen Normalizado. Fuente: Elaboración propia. 166

Figura 8.2: Esquema de la metodología de comparación de algoritmos. Fuente: Elaboración propia. 167

Figura 9.1: Ejemplos de simulación sistemática de marchas y obtención de curvas de Pareto reales. Fuente: Elaboración propia. 173

Figura 9.2: Primer análisis de sensibilidad de NSGA-II: porcentaje de cruce (%C) y porcentaje de mutación (%M) vs métricas. Fuente: Elaboración propia. 175

Figura 9.3: Segundo análisis de sensibilidad de NSGA-II: tamaño de población (N) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia. 176

Figura 9.4: Primer análisis de sensibilidad de MOPSO: coeficientes de aprendizaje ($c=c_1=c_2$), peso inercial (w) y tasa de mutación (TM) vs métricas. Fuente: Elaboración propia. 178

Figura 9.5: Segundo análisis de sensibilidad de MOPSO: tamaño de población (N), tamaño de archivo (ARC) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia. 179

Figura 9.6: Primer análisis de sensibilidad de SPEA-II: porcentaje de cruce (%C), parámetro de cruce (PC) y tasas de mutación (TM) vs métricas. Fuente: Elaboración propia. 181

Figura 9.7: Segundo análisis de sensibilidad de SPEA-II: tamaño de población (N), tamaño de archivo (ARC) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia. 182

Figura 9.8: Primer análisis de sensibilidad de MOEA-D: parámetro de cruce gamma (PCG) y porcentaje de vecindario (%V) vs métricas. Fuente: Elaboración propia. 184

Figura 9.9: Segundo análisis de sensibilidad de MOEA-D: tamaño de población/archivo (N/ARC) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia. 185

Figura 9.10: Primer análisis de sensibilidad de MOACOr: parámetro de pesos (q) y parámetro de evaporación de feromona (ξ) vs métricas. Fuente: Elaboración propia. 186

Figura 9.11: Segundo análisis de sensibilidad de MOACOr: tamaño de población (N) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia. 187

| | |
|---|-----|
| Figura 9.12: Resultados de los cinco algoritmos en el tramo Campanar-Beniferrí (L1/L2). Fuente: Elaboración propia..... | 190 |
| Figura 9.13: Resultados de los cinco algoritmos en el tramo Sant Isidre-Safranar (L1/L2/L7). Fuente: Elaboración propia..... | 192 |
| Figura 9.14: Resultados de los cinco algoritmos en el tramo Empalme-Beniferrí (L1/L2). Fuente: Elaboración propia..... | 194 |
| Figura 9.15: Resultados de los cinco algoritmos en el tramo Pl. Espanya-Jesús (L1/L2). Fuente: Elaboración propia..... | 196 |
| Figura 9.16: Resultados de los cinco algoritmos en el tramo Manises-Salt de l'Aigua (L3/L5). Fuente: Elaboración propia..... | 199 |
| Figura 9.17: Resultados de los cinco algoritmos en el tramo Mislata-Nou d'Octubre (L3/L5). Fuente: Elaboración propia..... | 201 |
| Figura 9.18: Resultados de los cinco algoritmos en el tramo Ayora-Amistat (L5/L7). Fuente: Elaboración propia..... | 203 |
| Figura 9.19: Resultados de los cinco algoritmos en el tramo Àngel Guimerà-Av. del Cid (L3/L5). Fuente: Elaboración propia..... | 205 |
| Figura 9.20: Distribución de la mejor puntuación de cada algoritmo, para cada métrica, en cada uno de los 64 casos de estudio. Fuente: Elaboración propia. | 208 |
| Figura 9.21: Clasificación de cada algoritmo para cada métrica. Fuente: Elaboración propia. | 209 |
| Figura 9.22: Esquema de los test estadísticos aplicados. Fuente: Elaboración propia. | 211 |

LISTADO DE TABLAS

| | |
|--|-----|
| <i>Tabla 2.1: Relación de tensiones nominales DC empleadas en ferrocarriles urbanos. Fuente: Elaboración propia.</i> | 33 |
| <i>Tabla 2.2: Medidas para mejorar la eficiencia energética y su ahorro potencial. Fuente: Elaboración propia a partir de Douglas et al., (2015) y Su et al. (2016).</i> | 48 |
| <i>Tabla 3.1: Error promedio obtenido por diferentes autores de la validación de sus respectivos simuladores. Fuente: Elaboración propia.</i> | 55 |
| <i>Tabla 3.2: Principales factores a incorporar en la modelización. Fuente: Elaboración propia.</i> | 57 |
| <i>Tabla 3.3: Enfoques de simulación y relación de bibliografía consultada. Fuente: Elaboración propia.</i> | 59 |
| <i>Tabla 4.1: Principales enfoques empleados para optimización de marchas. Fuente: Elaboración propia.</i> | 68 |
| <i>Tabla 4.2: Enfoques de optimización y relación de bibliografía consultada. Fuente: Elaboración propia.</i> | 92 |
| <i>Tabla 5.1: Datos de las líneas de metro de Valencia. Fuente: FGV.</i> | 98 |
| <i>Tabla 5.2: Características de la serie 4300. Fuente: FGV.</i> | 106 |
| <i>Tabla 5.3: Características de la serie 3800. Fuente: FGV.</i> | 107 |
| <i>Tabla 5.4: Características de la serie 4200. Fuente: FGV.</i> | 108 |
| <i>Tabla 5.5: Relación de servicios registrados por cada línea. Fuente: Elaboración propia.</i> | 111 |
| <i>Tabla 5.6: Tiempos y consumos globales promedio por servicio y línea. Fuente: Elaboración propia.</i> | 114 |
| <i>Tabla 5.7: Energía promedio disipada y porcentaje sobre consumo neto, por servicio y línea. Fuente: Elaboración propia.</i> | 117 |
| <i>Tabla 6.1: Valores máximos y mínimos de los comandos ATO. Fuente: Elaboración propia.</i> | 126 |
| <i>Tabla 6.2: Parámetros básicos del vehículo (metro serie 4300). Fuente: FGV.</i> | 127 |
| <i>Tabla 6.3: Comparativa entre tiempos de viaje reales y calculados por el simulador. Fuente: Elaboración propia.</i> | 138 |
| <i>Tabla 7.1: Resultados promedio para cada combinación de variables de entrada después de 100 entrenamientos. Fuente: Elaboración propia.</i> | 151 |
| <i>Tabla 7.2: Resultados de ECMr definitivos de la red entrenada. Fuente: Elaboración propia.</i> | 154 |
| <i>Tabla 7.3: Comparativa de consumo global real vs consumo estimado por la red neuronal para diferentes conjuntos de datos. Fuente: Elaboración propia.</i> | 155 |
| <i>Tabla 9.1: Valores máximos, mínimos y variación de los comandos ATO para la simulación sistemática. Fuente: Elaboración propia.</i> | 172 |
| <i>Tabla 9.2: Parámetros de NSGA-II ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.</i> | 177 |
| <i>Tabla 9.3: Parámetros de MOPSO ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.</i> | 180 |
| <i>Tabla 9.4: Parámetros de SPEA-II ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.</i> | 183 |
| <i>Tabla 9.5: Parámetros de MOEA-D ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.</i> | 185 |
| <i>Tabla 9.6: Parámetros de MOACOr ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.</i> | 188 |
| <i>Tabla 9.7: Métricas obtenidas en el tramo Campanar-Beniferrí (L1/L2). Fuente: Elaboración propia.</i> | 191 |
| <i>Tabla 9.8: Métricas obtenidas en el tramo Sant Isidre-Safranar (L1/L2/L7). Fuente: Elaboración propia.</i> | 193 |
| <i>Tabla 9.9: Métricas obtenidas en el tramo Empalme-Beniferrí (L1/L2). Fuente: Elaboración propia.</i> | 195 |
| <i>Tabla 9.10: Métricas obtenidas en el tramo Pl. Espanya-Jesús (L1/L2). Fuente: Elaboración propia.</i> | 197 |
| <i>Tabla 9.11: Métricas obtenidas en el tramo Manises-Salt de l'Aigua (L3/L5). Fuente: Elaboración propia.</i> | 200 |
| <i>Tabla 9.12: Métricas obtenidas en el tramo Mislata-Nou d'Octubre (L3/L5). Fuente: Elaboración propia.</i> | 202 |
| <i>Tabla 9.13: Métricas obtenidas en el tramo Ayora-Amistat (L5/L7). Fuente: Elaboración propia.</i> | 204 |
| <i>Tabla 9.14: Métricas obtenidas en el tramo Àngel Guimerà-Avinguda del Cid (L3/L5). Fuente: Elaboración propia.</i> | 206 |
| <i>Tabla 9.15: Resultados estadísticos para la métrica GD. Fuente: Elaboración propia.</i> | 212 |
| <i>Tabla 9.16: Resultados estadísticos para la métrica SPR. Fuente: Elaboración propia.</i> | 213 |

Tabla 9.17: Intervalos de Bonferroni de la mediana para la métrica SPR. Fuente: Elaboración propia. 214

Tabla 9.18: Resultados estadísticos para la métrica SP. Fuente: Elaboración propia. 215

Tabla 9.19: Resultados estadísticos para la métrica NH. Fuente: Elaboración propia. 216

Tabla 9.20: Intervalos LSD de la media para la métrica NH. Fuente: Elaboración propia. 217

Tabla 9.21: Intervalos de Bonferroni de la mediana para la métrica NH. Fuente: Elaboración propia. 218

LISTA DE ABREVIATURAS Y SÍMBOLOS

| | |
|---------|--|
| AC | Alternating Current (Corriente Alterna) |
| ACO | Ant Colony Optimisation |
| ATO | Automatic Train Operation |
| ATP | Automatic Train Protection |
| CBTC | Communication Based Train Control |
| DAS | Driver Advisory System |
| DC | Direct Current (Corriente Continua) |
| DP | Dynamic Programming |
| DS | Direct Search |
| DT | Decision Theory |
| ECM | Error Cuadrático Medio |
| ECMr | Error Cuadrático Medio relativo |
| ERTMS | European Rail Traffic Management System |
| ETCS | European Train Control System |
| FAP | Frenado Automático Puntual |
| FGV | Ferrocarrils de la Generalitat Valenciana |
| FLP | Fuzzy Linear Programming |
| GD | Generational Distance (Distancia Generacional) |
| GSM-R | Global System for Mobile Communications – Railways |
| MILP | Mixed Integer Linear Programming |
| MPA | Maximum (Minimum) Principle Analysis |
| MOACOr | Multi-Objective Ant Colony Optimisation for Continuous Domains |
| MOEA-D | Multi-Objective Evolutionary Algorithm based on Decomposition |
| MOPSO | Multi-Objective Particle Swarm Optimisation |
| NH | Normalised Hypervolume (Hipervolumen Normalizado) |
| NSGA-II | Non-dominated Sorted Genetic Algorithm |
| PSO | Particle Swarm Optimisation |
| SPEA-II | Strength Pareto Evolutionary Algorithm |
| SP | Spacing (Espaciamiento) |
| SPR | Spread (Extensión) |
| TLBO | Teaching Learning Based Optimisation |
| TS | Tabu Search |

| | |
|-----------|---|
| A | Primer coeficiente de Davis |
| ARC | Tamaño del archivo del algoritmo de optimización |
| Aw | Amortiguamiento del peso inercial (MOPSO) |
| B | Segundo coeficiente de Davis |
| C | Tercer coeficiente de Davis |
| C_{mg} | Coeficiente de masas giratorias |
| I_i | Entrada de la red neuronal |
| IT | Número de iteraciones |
| M | Masa del vehículo |
| N | Tamaño de la población del algoritmo de optimización |
| NI | Número de soluciones encontradas por el algoritmo de optimización |
| O_k | Salida de la red neuronal |
| PC | Parámetro de cruce (SPEA-II) |
| PCG | Parámetro de cruce gamma (MOEA-D) |
| P_{aux} | Potencia consumida en auxiliares |
| P_{dis} | Potencia medida en el disyuntor |
| P_{res} | Potencia consumida en resistencias |
| P_T | Potencia de tracción |
| R | Suma de fuerzas que se oponen al movimiento |
| R_a | Resistencia aerodinámica al avance |
| R_c | Resistencia debida a las curvas |
| R_{cu} | Radio de curvatura |
| R_g | Resistencia debida a la gravedad |
| T | Objetivo de la red neuronal |
| TM | Tasa de mutación |
| a | Aceleración del vehículo |
| c_1 | Coeficiente de influencia personal (MOPSO) |
| c_2 | Coeficiente de influencia global (MOPSO) |
| c_m | Curvatura en planta promedio |
| d | Deceleración final del vehículo (Comando ATO) |
| d_j | Distancia entre cada solución del algoritmo y el frente de Pareto |
| d_m | Valor medio de d_j |
| d_q^e | Distancia entre extremos de la solución del algoritmo y el frente de Pareto |
| k | Número de hormigas (MOACOr) |

| | |
|-------------|---|
| f_c | Factor de curva |
| f_{no}^j | Valor j-ésimo del frente del algoritmo para el objetivo no |
| f_q^j | Valor j-ésimo del frente del algoritmo para el objetivo q |
| f_q^{max} | Valor máximo del frente de Pareto para el objetivo q |
| f_q^{min} | Valor mínimo del frente de Pareto para el objetivo q |
| f_q^{sup} | Valor inmediatamente superior al valor f_q^j para el objetivo q |
| g | Gravedad |
| h | Función de transferencia de la capa oculta de la red neuronal |
| \hat{h} | Función de transferencia de la capa de salida de la red neuronal |
| no | Número de objetivos de optimización |
| o_i | Elemento i-ésimo de la salida de la red neuronal |
| p | Pendiente longitudinal |
| p_g | Mejor solución global (MOPSO) |
| p_i | Mejor solución particular (MOPSO) |
| p_m | Pendiente longitudinal promedio |
| q | Parámetro de pesos (MOACOr) |
| r_1 | Factor aleatorio número 1 (MOPSO) |
| r_2 | Factor aleatorio número 2 (MOPSO) |
| t | Tiempo |
| t_i | Valor i-ésimo objetivo de la red neuronal |
| u | Fuerza por unidad de masa |
| v | Velocidad del vehículo |
| v_d | Velocidad de deriva (Comando ATO) |
| v_h | Velocidad de regulación (Comando ATO) |
| v_i | Velocidad de la partícula i-ésima (MOPSO) |
| v_r | Velocidad de remotorización (Comando ATO) |
| w | Peso inercial (MOPSO) |
| w_i | Peso de la solución i-ésima del archivo (MOACOr) |
| w_{ij} | Pesos entre el input y la capa oculta de la red neuronal |
| w_{2j} | Pesos entre la capa oculta y la capa de salida de la red neuronal |
| x | Posición del vehículo |
| x_i | Posición de la partícula i-ésima (MOPSO) |
| x_m | Individuo antes de la mutación (NSGA-II) |
| x_{p1} | Individuo progenitor 1 (NSGA-II) |

| | |
|------------|--|
| x_{p2} | Individuo progenitor 2 (NSGA-II) |
| y | Individuo descendiente (NSGA-II) |
| y_m | Individuo mutado (NSGA-II) |
| α | Número aleatorio entre 0 y 1 que regula el cruce de individuos (NSGA-II) |
| Δt | Incremento de tiempo |
| Δx | Incremento de espacio |
| ξ | Parámetro de evaporación de feromona (MOACOr) |
| σ | Magnitud de la mutación (NSGA-II) |
| $\%C$ | Porcentaje de cruce (NSGA-II) |
| $\%M$ | Porcentaje de mutación (NSGA-II) |

Capítulo I

1. Introducción

El transporte, bien sea de mercancías o de pasajeros, es un elemento clave de nuestra sociedad, imprescindible para el desarrollo de innumerables actividades. También es, por esta misma razón, un sector de gran impacto en el consumo energético global y en las emisiones de gases de efecto invernadero asociadas. Así, por ejemplo, en la UE-28, el sector del transporte representó alrededor de un tercio (33,2%) del total de energía consumida en el año 2016 (Comisión Europea, 2018a), lo que supuso unas emisiones de más de 930 millones de toneladas de CO₂ equivalente (Comisión Europea, 2018b).

El transporte ferroviario es inherentemente eficiente respecto a otros modos de transporte terrestre. De hecho, a pesar de representar más del 17% del transporte de mercancías y más del 8% del transporte de pasajeros en la UE-28, el transporte ferroviario sólo consume alrededor del 2% del total de la energía empleada anualmente por el sector del transporte europeo (Comisión Europea, 2017). Esta mayor eficiencia del ferrocarril es una de las principales razones del gran impulso que, desde las instituciones comunitarias, se viene dando a este medio de transporte para aumentar su cuota en detrimento del transporte por carretera en toda la Unión. Así queda reflejado en la estrategia a largo plazo de la Comisión Europea para una Europa con huella de carbono cero en el año 2050, así como en el programa Horizonte 2020 y en la iniciativa Shift2Rail.

No obstante, a pesar de su eficiencia inherente, todavía existe un amplio margen de mejora para reducir el consumo energético del ferrocarril, bien sea desde el punto de vista del material rodante (vehículos más eficientes), de la infraestructura (trazados optimizados, mantenimiento mejorado), de la operación o de la conducción (marchas optimiza-

das). A través de la investigación y el desarrollo en éstas y otras facetas del sistema ferroviario, será posible incrementar todavía más su eficiencia y contribuir a un sector del transporte con un menor impacto sobre el medio ambiente, en el marco de una sociedad más sostenible.

1.1. Motivación

De acuerdo a la estrategia a largo plazo de la Comisión Europea para alcanzar una Europa con huella de carbono cero para el año 2050, es imprescindible impulsar un aumento de la cuota del ferrocarril respecto a otros modos de transporte. Esto es especialmente cierto en el caso del transporte de mercancías, ya que el ferrocarril es, a día de hoy, la solución más eficiente desde el punto de vista energético en el rango de media y larga distancia (Comisión Europea, 2018c). En el caso del transporte de viajeros, el ferrocarril también ha demostrado ser una alternativa energéticamente eficiente y, en consecuencia, más sostenible desde el punto de vista de las emisiones de gases de efecto invernadero, especialmente en comparación con el transporte por carretera (García Álvarez, 2007a).

En el ámbito urbano, los ferrocarriles también pueden jugar un papel esencial en la consecución de una movilidad más sostenible, habida cuenta de que más del 70% de la población europea vive en áreas urbanas, y que más del 23% del total de emisiones de CO₂ debidas al transporte se producen en este ámbito (Comisión Europea, 2013). La cuestión de cómo mejorar la movilidad urbana al tiempo que se reduce la congestión, los accidentes y la contaminación en las ciudades es uno de los desafíos a los que se enfrentan las grandes ciudades hoy en día. El impulso al transporte público (incluyendo redes de metro y tranvía) es una de las claves para enfrentarse a este desafío, tal y como recoge la estrategia de la UE-28 (Comisión Europea, 2016).

Sin embargo, esta decidida apuesta por impulsar el ferrocarril, tanto en ámbito urbano como interurbano, no oculta la necesidad de seguir investigando para incrementar su eficiencia energética y su sostenibilidad ambiental. Diversos autores han explorado y analizado múltiples medidas de ahorro energético en el ferrocarril, si bien éstas se pueden agrupar en seis grandes grupos (Douglas et al., 2015):

- Mejoras en los sistemas auxiliares: Desarrollos tecnológicos que permitan lograr sistemas de climatización, refrigeración, ventilación e iluminación más eficientes.
- Mejoras en la cadena de transmisión: Desarrollo de motores y sistemas de transmisión más eficiente, ya sea para vehículos diésel o eléctricos.

- Reducir la resistencia al avance del vehículo, a través de diseños con mejor aerodinámica, nuevos materiales, etc.
- Diseño más eficiente de la infraestructura.
- Implementación de técnicas y perfiles de conducción más eficiente (eco-driving).
- Freno regenerativo y otras medidas asociadas para aprovechar la energía regenerada (sistemas de almacenamiento a bordo, subestaciones reversibles en sistemas de corriente continua, etc.)

De estos seis bloques de medidas, es en el desarrollo y aplicación de marchas más eficientes donde se han centrado buena parte de los esfuerzos en los últimos años. Esto es debido a que, mediante la implementación de eco-driving, se pueden alcanzar importantes ahorros energéticos, del orden del 30% en algunos casos (Douglas et al., 2015), con un coste de aplicación relativamente bajo en comparación con otras medidas más costosas o tecnológicamente complejas. Además, la aplicación de marchas optimizadas en el ferrocarril de ámbito urbano presenta ventajas añadidas, al poder incorporarse como parte de la conducción automatizada del vehículo en aquellas líneas que operan bajo ATO (*Automatic Train Operation*). Existen multitud de estudios, tanto teóricos como de aplicación práctica, centrados en la conducción eficiente del ferrocarril (bien sea de pasajeros o mercancías, de ámbito urbano o interurbano) a través de la simulación y la optimización de marchas bajo múltiples escenarios.

En este contexto, el propósito de esta tesis doctoral es contribuir al conocimiento de las herramientas empleadas para estudiar y optimizar el consumo energético en el ferrocarril, particularmente en el ámbito urbano. Para ello la tesis se centra, por un lado, en la modelización del consumo, explorando la posibilidad de emplear redes neuronales como instrumento de predicción. Por otro lado, la tesis estudia una serie de algoritmos empleados en los últimos años para la optimización de marchas, pertenecientes todos ellos a la familia de los algoritmos meta-heurísticos, y busca realizar una comparativa sistemática entre los más usados para identificar sus debilidades y fortalezas.

1.2. Objetivos

En base a la motivación expuesta en el apartado 1.1., la presente tesis doctoral tiene, como objetivo principal, contribuir a mejorar la eficiencia energética del ferrocarril a través del estudio de las herramientas empleadas para simular y optimizar el consumo energético. Este objetivo principal se traduce en los siguientes objetivos específicos:

- Analizar las principales tendencias de consumo energético en la red de metro de Valencia, marco del presente estudio.
- Modelizar el consumo energético mediante el desarrollo y entrenamiento de redes neuronales y obtener un simulador de marchas validado con datos reales.
- Realizar una simulación sistemática de posibles marchas en cada tramo entre estaciones de las líneas estudiadas y obtener los correspondientes frentes de Pareto.
- Realizar una comparativa entre los algoritmos meta-heurísticos de optimización más habituales para identificar los puntos fuertes y débiles de cada uno en base a una serie de métricas y criterios preestablecidos.

1.3. Estructura de la tesis

La presente tesis doctoral se estructura en seis capítulos, cuyo contenido es el siguiente:

- **Capítulo 1:** Introducción a la tesis, descripción de motivación y objetivos.
- **Capítulo 2:** Revisión bibliográfica. En este capítulo se expone de forma detallada el contexto de la energía en el ferrocarril (consumo, tendencias, factores influyentes, etc.), y se estudia el estado actual del arte respecto a los enfoques, metodologías y herramientas empleadas para simular el consumo energético del ferrocarril, así como de los principales algoritmos y técnicas empleados para optimizar el consumo bajo diferentes supuestos y escenarios.
- **Capítulo 3:** En este capítulo se describe con detalle la red de metro de Valencia, operada por FGV (*Ferrocarrils de la Generalitat Valenciana*), que sirve de marco a los trabajos de la presente tesis. Además, se expone el proceso de obtención y tratamiento de los datos empleados para la calibración y validación del simulador, y las principales tendencias de consumo que se deducen de los mismos.
- **Capítulo 4:** Este capítulo recoge el grueso de la metodología seguida para el desarrollo de la presente tesis. Por una parte, se expone la estructura del modelo de simulación de marchas y se explica el desarrollo, entrenamiento y validación de la red neuronal. Por otra, se describen los algoritmos meta-heurísticos analizados y su implementación, así como las métricas de comparación escogidas y la metodología de análisis empleada.
- **Capítulo 5:** En este capítulo se exponen y analizan los resultados de la tesis, incluyendo la simulación sistemática de marchas en cada uno de los tramos analizados, la obtención de las curvas de Pareto, la aplicación de los diferentes algo-

ritmos y la comparativa entre los resultados de cada uno de ellos a través de las métricas previamente establecidas. También se recoge un análisis de sensibilidad de cada algoritmo frente a sus respectivos parámetros.

- **Capítulo 6:** Conclusiones finales y futuras líneas de investigación.

Además, la tesis incluye los siguientes anexos:

- **Anexo I:** Relación de artículos publicados.
- **Anexo II:** Conclusiones de la tesis en inglés.
- **Anexo III:** Recopilación de resultados (curvas de Pareto, soluciones de los algoritmos) en todos los tramos objeto de estudio.

Capítulo II

2. El consumo energético del ferrocarril

El propósito del Capítulo II es establecer las bases sobre las que se sustenta la presente tesis a través de la revisión de la bibliografía existente y la discusión del estado del arte en todo lo referente al consumo energético en el sector del ferrocarril.

En esta Sección 2 se aborda el consumo energético en líneas generales, exponiendo los diferentes modos en que se suministra energía a las redes ferroviarias, los factores que influyen en el consumo, diferentes tecnologías existentes, flujos de energía, etc. En las Secciones 3 y 4 se aborda la simulación y la optimización del consumo, respectivamente.

2.1. Introducción

Si bien se tiene constancia de algunos ejemplos de transporte guiado en la antigüedad, el transporte ferroviario, entendido como aquél que circula de forma guiada sobre una vía con carriles y traviesas, existe desde mediados del siglo XVI, fundamentalmente en el ámbito minero para transportar el mineral excavado. Estos primeros vagones se impulsaban mediante caballos u otros animales de tiro, mientras que las vías se construían con carriles y traviesas de madera. No es hasta el siglo XVIII que comienzan a usarse carriles metálicos, inicialmente en forma de recubrimiento de chapa de hierro sobre la cabeza del carril de madera.

La revolución industrial del XIX impulsó enormemente el ferrocarril gracias al desarrollo de la máquina de vapor. Al primer prototipo funcional de locomotora de vapor, construido

por Richard Trevithick en 1804, le siguió la *Salamanca* de Matthew Murray (1812) y la *Puffing Billy* de Christopher Blackett y William Hedley (1813). Pero fue la *Rocket* de George Stephenson (1829) la que abrió definitivamente las puertas al transporte ferroviario comercial. Ya en 1830 se abrió la primera línea férrea operada íntegramente con locomotoras de vapor, entre Liverpool y Manchester. Por otra parte, la introducción del procedimiento Bessemer (1856) abarató considerablemente la producción de acero, lo que permitió la fabricación de carriles completamente metálicos, contribuyendo así a la gran expansión del ferrocarril a partir de la década de los 60 del siglo XIX.

El vapor siguió siendo la fuente principal de energía del ferrocarril durante más de un siglo, si bien ya existían prototipos de locomotoras eléctricas desde el año 1837 (Robert Davidson), y Werner von Siemens había demostrado las posibilidades de una línea férrea con energía eléctrica en Berlín (1879). De hecho, la primera línea electrificada de tranvía data del año 1881, en la localidad de Lichterfelde, cerca de la capital alemana; mientras que el metro de Londres, inaugurado en 1863, incorporó electrificación mediante cuarto carril a partir de 1890. A comienzos del siglo XX, la electricidad ya era la opción preferente para ferrocarriles urbanos (tranvías, metros), pero el vapor seguía dominando las líneas interurbanas.

Diferentes desarrollos tecnológicos a lo largo del siglo XX fueron ampliando las posibilidades de la electrificación del ferrocarril. La primera línea completamente electrificada se inauguró en Italia en 1902 (Valtellina, 106 km), alimentada mediante corriente alterna trifásica de 3 kV y 15 Hz. En Francia, tras la Segunda Guerra Mundial, se adoptó la alimentación mediante corriente alterna a 50 Hz, que pronto se convertiría en el estándar para electrificación ferroviaria en todo el mundo.

La otra gran alternativa a la locomotora de vapor vino de la mano del diésel. Las primeras locomotoras diésel funcionaban con un motor de combustión interna, y comenzaron a hacer acto de presencia a principios del siglo XX, destacando el ejemplo de la línea Winterthur-Romanshorn en Suiza (1912), si bien con escaso éxito comercial. En 1914 apareció la primera locomotora diésel-eléctrica, que marcaría la pauta para el uso de este combustible en el ámbito ferroviario, y a partir de la década de los 30 del siglo XX comenzó a producirse de forma gradual el tránsito del vapor al diésel en múltiples redes ferroviarias. El diésel, a pesar de tener inicialmente un coste mayor por unidad de potencia, aportaba grandes ventajas respecto al vapor, incluyendo una menor necesidad de mantenimiento y personal para operar las locomotoras.

De este modo, la tendencia a lo largo del último siglo ha sido la de sustituir la tracción de vapor por tracción eléctrica o diésel. En aquellas regiones donde prima el transporte de pasajeros, como Europa o Japón, se ha apostado por la electrificación, quedando la tracción diésel para líneas secundarias con poco tráfico o como solución temporal en determinados puntos de la red. Por el contrario, allí donde prima el transporte de mercancías, como los Estados Unidos, muchas de las líneas operan con tracción diésel-eléctrica. El diésel es también la opción preferida allí donde la electrificación es demasiado costosa de implantar.

En la actualidad, la electricidad y el diésel son, de largo, las formas de tracción preferentes en el ferrocarril (descontando el uso residual del vapor en determinadas zonas). A nivel global en torno al 30% de los ferrocarriles están electrificados a fecha de 2015 (Agencia Internacional de la Energía, 2017). Este porcentaje aumenta hasta rozar el 50% en China, supera el 60% en Rusia y la India, roza el 70% en Alemania y Japón, y supera el 80% en Corea del Sur e Italia (Agencia Internacional de la Energía, 2017). Por el contrario, en los Estados Unidos, tras alcanzar el máximo de electrificación a finales de los años 30 del siglo XX con cerca de 5000 kilómetros de vía electrificada, se fue produciendo un cambio gradual hacia el diésel, y en la actualidad las líneas electrificadas representan un porcentaje marginal (alrededor del 1%) de su red ferroviaria (SCI Verkehr, 2018).

En base a este contexto histórico, cualquier red ferroviaria actual se puede clasificar, considerando la forma de tracción empleada (descontando usos residuales de otras formas de alimentación), de la siguiente forma (Douglas et al., 2015):

- Diésel-eléctrica: Vehículos equipados con un motor diésel de combustión interna que alimenta un alternador para generar corriente alterna.
- Eléctrica: Vehículos alimentados directamente con corriente eléctrica a través de una infraestructura de suministro que discurren en paralelo (o forma parte de) la vía férrea. Los sistemas de electrificación ferroviaria se pueden clasificar, a su vez, según diferentes criterios:
 - Tipo de corriente: continua (DC) o alterna (AC).
 - Tensión nominal.
 - Tipo de sistema de contacto: Catenaria (flexible o rígida), tercer carril, cuarto carril.

Cabe destacar que la elección del tipo de corriente determina en gran medida los restantes criterios a la hora de materializar el sistema de electrificación. Así, por ejemplo, los

sistemas de corriente continua suelen operar a tensiones más bajas (750 V, 1.500 V, 3.000 V), mientras que los sistemas de corriente alterna operan a tensiones más altas (15 kV, 25 kV), entre otras razones para reducir la intensidad de corriente y las pérdidas de energía. Por otra parte, las redes de corriente alterna siempre se construyen mediante catenaria (ya sea rígida o flexible) ya que el uso de otros sistemas (como un tercer o cuarto carril de contacto) es impracticable a tensiones elevadas, por lo que éstos se limitan a algunos sistemas alimentados mediante corriente continua.

En los siguientes apartados se profundiza con más detalle en los sistemas de electrificación ferroviaria. También se discuten los principales factores que afectan al consumo energético, y diferentes medidas de ahorro que se pueden implementar.

2.2. Sistemas de electrificación ferroviaria

Como se ha expuesto en el apartado anterior, el desarrollo y la implantación de los sistemas de electrificación ferroviaria en todo el mundo ha venido de la mano de los avances tecnológicos en el campo de la ingeniería eléctrica, pero también se ha visto afectado por diferentes condicionantes económicos y políticos. De ahí que existan múltiples variantes y opciones, cada una con sus particulares ventajas e inconvenientes.

La gran mayoría de sistemas de electrificación actuales se alimentan de la red eléctrica general, que funciona con corriente alterna trifásica de alta tensión. Esta corriente alterna se transforma en corriente continua para alimentar los motores de tracción del vehículo (que, a su vez, pueden ser motores de corriente continua o de corriente alterna, precisando en este segundo caso de una transformación adicional de continua a alterna trifásica). Por ello, la elección entre un sistema de electrificación de corriente continua o alterna consiste, esencialmente, en escoger en qué punto del sistema se transforma la corriente alterna de la red general de suministro en corriente continua: si a nivel de la subestación que alimenta al sistema ferroviario o en el propio vehículo. En el primer caso se trataría de un sistema de electrificación ferroviaria de corriente continua, y en el segundo caso sería un sistema de corriente alterna.

La elección entre una corriente u otra determina en gran medida las restantes características del sistema (ya sea la tensión nominal, la infraestructura específica de suministro o el tipo de material rodante). Por otra parte, esta elección viene a su vez condicionada por criterios técnicos (costes, eficiencia energética, pérdidas) pero también por las condiciones pre-existentes (como puede ser las características de la red eléctrica en la zona, o la simple inercia histórica del gestor de la infraestructura ferroviaria).

2.2.1. Sistemas de corriente continua

Los sistemas ferroviarios con electrificación en corriente continua requieren de una transformación y rectificación de la energía suministrada por la red general en forma de corriente alterna trifásica. Este proceso para adaptar la corriente a las condiciones de suministro de la red ferroviaria se realiza en las subestaciones de tracción.

En la actualidad existen todavía muchas líneas de ferrocarril que operan con corriente continua, generalmente con tensiones de 1,5 o 3 kV. Por ejemplo, varias de las líneas férreas japonesas (exceptuando las de alta velocidad) operan con 1,5 kV DC, así como algunas de las líneas de la antigua FEVE en España. Por otra parte, la red ferroviaria belga opera en su mayor parte (de nuevo descontando la alta velocidad) con 3 kV DC, al igual que las redes de Marruecos o Sudáfrica. Sin embargo, la tendencia general en líneas interurbanas y para largas distancias (así como el estándar más habitual para la alta velocidad), es la de adaptarse a la corriente alterna.

Por el contrario, los sistemas ferroviarios de transporte urbano (metros y tranvías) operan de forma mayoritaria en corriente continua, con diversos niveles de tensión que van desde los 600 hasta los 1.500 V DC. En este sentido, la Tabla 2.1 recoge algunos ejemplos de los principales estándares de tensión en corriente continua empleados en ferrocarriles urbanos en todo el mundo.

| Tensión nominal | Ejemplo |
|-----------------|-----------------------------------|
| 600 V DC | Metro de Madrid (España) |
| | Tranvía de Melbourne (Australia) |
| 750 V DC | Metro de Río de Janeiro (Brasil) |
| | Metro de Génova (Italia) |
| | Tranvía de Valencia (España) |
| 1.200 V DC | Metro de Barcelona (España) |
| 1.500 V DC | Metro de Valencia (España) |
| | Metro de Madrid (España) |
| | Metro de Buenos Aires (Argentina) |
| | Metro de Medellín (Colombia) |
| | Metro de Roma (Italia) |

Tabla 2.1: Relación de tensiones nominales DC empleadas en ferrocarriles urbanos. Fuente: Elaboración propia.

Por otra parte, si bien la opción habitual para suministrar la energía al vehículo es mediante una catenaria (ya sea flexible o rígida), en sistemas de electrificación en corriente continua hasta 1.500 V existen alternativas tales como un tercer carril (Metro de Helsinki, tranvía de Burdeos) o incluso un cuarto carril (como es el caso del Metro de Londres), pero se trata de opciones minoritarias.

2.2.2. Sistemas de corriente alterna

Los sistemas de corriente alterna se han convertido en el estándar más habitual en líneas interurbanas, especialmente para alta velocidad. El principal motivo, como ya se ha comentado, es que permiten operar a tensiones más altas, reduciendo así las pérdidas de energía por transmisión. Existen fundamentalmente dos variantes de electrificación con corriente alterna: 15 kV AC y 25 kV AC. La primera variante, más antigua, representa el estándar de electrificación en países como Alemania, Austria, Noruega o Suecia, y si bien presenta algunas desventajas (como transformadores más pesados y complejos), se sigue empleando de forma generalizada en dichos países debido a los elevados costes que supondría una conversión completa.

Por otra parte, la electrificación a 25 kV AC se ha convertido en el estándar ferroviario por excelencia, definido en la norma EN 50163:2005 (Aplicaciones ferroviarias. Tensiones de Alimentación de las redes de tracción), y bajo el que operan todas las líneas de alta velocidad en la actualidad, además de muchas otras líneas en países como Australia, China, Hungría, Reino Unido, Portugal, Francia, Corea del Sur o México. Esta alimentación en corriente alterna puede suministrarse a 50 o 60 Hz, en función de la frecuencia que opera en la red general de suministro de cada país. Existen además algunas variantes dignas de mención, tales como el sistema 2x25 kV, en el que la salida de la subestación se produce a 50 kV (para así reducir aún más las pérdidas por transmisión) pero los vehículos se alimentan a 25 kV.

En cuanto a la forma de suministrar la energía al vehículo, en sistemas de corriente alterna se emplea exclusivamente catenaria (ya sea flexible o rígida), ya que la resistencia por unidad de longitud en un tercer carril o similar sería demasiado elevada a tensiones tan altas.

2.3. Factores que influyen en el consumo energético

La energía que consume una línea férrea electrificada se destina a diversos usos. El más evidente, y el que tiene un mayor peso en el consumo total, es la tracción de los vehícu-

los. Sin embargo, parte de la energía se destina a alimentar los servicios auxiliares de los propios vehículos (climatización, iluminación, etc.), las necesidades de las instalaciones o, simplemente, se pierde por efecto de la resistencia eléctrica o por ineficiencias de los equipos. A modo de ejemplo, la Figura 2.1 muestra el reparto del consumo energético en la línea de Alta Velocidad Madrid-Sevilla.

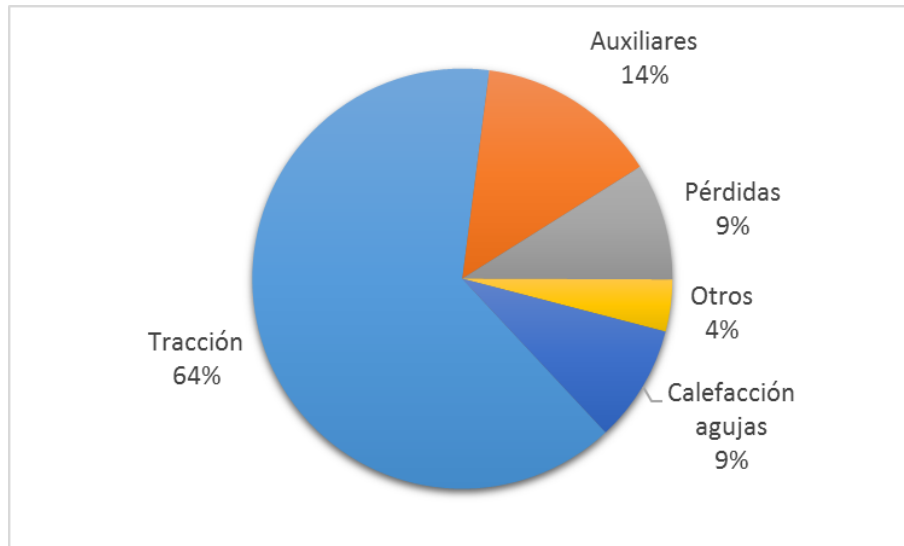


Figura 2.1: Reparto de consumos en la línea de Alta Velocidad Madrid-Sevilla. Fuente: Adaptado de (García Álvarez, 2006).

Como se ve en la figura, el consumo eléctrico de los vehículos (ya sea para tracción o para servicios auxiliares) representa el grueso del consumo de cualquier red ferroviaria, pudiendo alcanzar el 90% del total (García Álvarez, 2006). Por ello, en los siguientes apartados se discuten los principales factores que influyen en dicho consumo, centrándose en los propios del material rodante y su operación e ignorando los debidos a instalaciones e infraestructura.

2.3.1. Dinámica del vehículo

Ya que el consumo energético para tracción representa la fracción principal, con diferencia, de todo el consumo de un sistema ferroviario, es evidente que todos los factores que afecten a la dinámica del vehículo influirán en dicho consumo. De forma simplificada, el movimiento de un tren puede expresarse a través de la Segunda Ley de Newton:

$$F_T - R = M \cdot a \quad (2.1)$$

Donde F_T es la fuerza de tracción, R es la suma de las fuerzas que se oponen al movimiento, M es la masa del vehículo y a es la aceleración. Centrándonos en la masa (M), resulta claro que éste es un factor de gran importancia en el consumo, ya que determina las necesidades de tracción y, consecuentemente, la energía consumida.

En trenes de viajeros, la masa total puede variar notablemente entre un tren vacío y otro lleno, especialmente en el caso de metros y tranvías que se definen, precisamente, por su reducido peso en vacío. Así, por ejemplo, un metro de la serie 4300 (Vossloh) como los que operan en la red de metro de Valencia incrementa su masa total en un 45% cuando se encuentra completamente lleno, respecto a su peso sin pasaje.

Otro factor a tener en cuenta, de acuerdo a la ecuación (2.1), es la suma de fuerzas que se oponen al movimiento (R), que incluyen la resistencia al avance (por rozamiento mecánico y aerodinámico) y el empuje gravitatorio (en pendientes y rampas). En líneas generales, la resistencia al avance (en recta y en llano) se suele modelizar de acuerdo a la denominada ecuación de Davis (García Álvarez, 2007b):

$$R_a = A + B \cdot v + C \cdot v^2 \quad (2.2)$$

Donde v es la velocidad del vehículo, y A , B y C son coeficientes relacionados con el rozamiento y la resistencia aerodinámica. De forma más específica, el coeficiente A define la resistencia mecánica por rozamientos internos de la maquinaria del vehículo, y por ello no depende de la velocidad (en cambio, sí depende de la masa del tren). Por otra parte, el coeficiente B rige la resistencia al avance debida a la entrada de aire en el vehículo, mientras que el coeficiente C rige la resistencia aerodinámica propiamente dicha. El valor de estos tres coeficientes, que influye directamente en el consumo energético, depende de las características específicas del material rodante.

Las otras componentes fundamentales de la suma de resistencias al avance (R) son las debidas al empuje gravitatorio y al efecto de las curvas. Estas dos componentes dependen, por tanto, del trazado geométrico de la vía. La componente gravitatoria afecta al movimiento del vehículo cuando éste circula por tramos en pendiente o rampa y, al contrario que la resistencia al avance recogida en la ecuación (2.2), puede oponerse al movimiento (rampa) o contribuir al mismo (pendiente). Se expresa, de forma habitual, de acuerdo a la siguiente ecuación (García Álvarez, 2007b):

$$R_g = M \cdot g \cdot p \quad (2.3)$$

Donde R_g es la resistencia por efecto de la gravedad, M es la masa del tren, g es el valor de la aceleración gravitatoria y p es la pendiente longitudinal. Por otra parte, la resistencia debida a las curvas se define de acuerdo a la siguiente ecuación empírica (García Álvarez, 2007b):

$$R_c = M \cdot \frac{f_c}{R_{cu}} \quad (2.4)$$

Donde R_c es la resistencia debida a la curva, M es la masa del tren, R_{cu} es el radio de la curva y f_c es un factor cuyo valor, para vías de ancho internacional, es 600 (García Álvarez, 2007b). Para concluir, otros factores que pueden afectar a la dinámica del vehículo (y por tanto a su consumo energético) son la adherencia rueda-carril y la inercia de las masas giratorias (esto es, los cambios de velocidad de giro de elementos tales como las ruedas o los ejes).

2.3.2. Conducción y señalización

La forma en la que se opera el vehículo, y las restricciones al movimiento (en forma de limitaciones de velocidad, paradas por señalización, pasos a nivel, etc.) son también un factor a tener en cuenta a la hora de analizar el consumo energético de una red ferroviaria. Para un mismo trazado, y dado un tiempo de viaje predefinido, el consumo de energía debido a tracción puede variar notablemente según el perfil de velocidades aplicado. Ésta es la base de la llamada conducción eficiente, o *eco-driving*, la cual se discute con más detalle en el apartado 2.4, así como en la Sección 4.

Por otra parte, los sistemas de señalización existentes en la vía, así como la posible presencia de sistemas de ayuda a la conducción, o DAS (*Driver Advisory System*), pueden influir también en el consumo energético, bien por su contribución a una conducción más económica de los vehículos o por aumentar la eficiencia en la operación de la línea (por ejemplo, a través de un aumento de la capacidad). Aquí cabe destacar el sistema europeo ERTMS (*European Rail Traffic Management System*), un sistema de control, comunicaciones y bloqueo que pretende convertirse en el estándar para toda la red ferroviaria europea (especialmente para líneas de alta velocidad).

El sistema ERTMS comprende un sistema de control del tren denominado ETCS (*European Train Control System*) y un sistema de comunicaciones denominado GSM-R (*Global*

System for Mobile Communications - Railways) que facilita la transmisión de datos vía-vehículo. En función del grado de implementación de ambos subsistemas se definen cuatro niveles de implantación del sistema ERTMS, desde ERTMS-0 (sin ETCS, con bloqueo mediante cantones de vía) hasta ERTMS-3 (con comunicación directa en tiempo real entre vía y vehículo y bloqueo móvil basado en la posición del vehículo). La implantación de éste y otros sistemas también puede ser un factor en el consumo energético, y si bien la configuración actual del ERTMS no está diseñada ex profeso para contribuir al ahorro energético, podría adaptarse como medida de ahorro y eficiencia.

2.3.3. Sistemas auxiliares

Los sistemas auxiliares en un vehículo ferroviario son todos aquéllos no relacionados con la tracción pero que resultan imprescindibles para ofrecer un servicio seguro y confortable para los pasajeros (o bien son necesarios para la correcta conservación de la carga en el caso de transporte de mercancías). Son sistemas auxiliares la climatización, iluminación, megafonía, paneles informativos, apertura y cierre automático de puertas, etc.

El consumo energético debido a auxiliares es extremadamente variable, ya que depende enormemente del tipo de línea, de las condiciones particulares del servicio y de la climatología, entre otros factores. Por ejemplo, para una línea interurbana el consumo en auxiliares puede oscilar entre el 10% y el 20% del consumo total (Douglas et al., 2015), mientras que en una red de metro este porcentaje puede aumentar hasta un 30% (Douglas et al., 2015; Su et al., 2016), e incluso hasta el 45% en algunos casos (Martínez Fernández et al., 2015). En cualquier caso, queda claro que, descontando el consumo de tracción, representan en su conjunto el mayor consumo relacionado con el material rodante.

2.3.4. Pérdidas de energía

La tracción eléctrica presenta rendimientos bastante elevados en comparación con la tracción diésel, con un valor promedio de entre el 80 y el 87% de aprovechamiento de la energía suministrada al vehículo, frente a un 25-35% en vehículos diésel (Douglas et al., 2015; García Álvarez, 2006). No obstante, por muy eficiente que sea, cualquier sistema de transmisión y uso de energía eléctrica va a experimentar un cierto grado de pérdidas debidas a la resistencia óhmica y a otros factores. En este sentido, la Figura 2.2 muestra de forma esquemática el flujo de energía de un vehículo ferroviario con tracción eléctrica.




Figura 2.2: Esquema del flujo de energía en un vehículo ferroviario de tracción eléctrica.
Fuente: Elaboración propia a partir de Douglas et al. (2015).

Así pues, las pérdidas pueden suponer entre un 10 y un 15%, e incluso hasta un 20% del total de energía suministrada al vehículo, por lo que son un factor a tener en cuenta. En función de su causa, se pueden agrupar en las siguientes categorías (López-López et al., 2014):

- Pérdidas en la cadena de transmisión: es decir, pérdidas debidas a las propias ineficiencias de los motores eléctricos al transformar energía eléctrica en mecánica (o viceversa en el caso de actuar como freno regenerativo), a la electrónica que regula los cambios de intensidad y/o tensión, etc.
- Pérdidas mecánicas: es decir, pérdidas debidas al rozamiento mecánico, que quedan recogidas en la formulación de Davis (2.2) de la resistencia al avance.
- Pérdidas en conductores: debidas a la resistencia al paso de la corriente eléctrica de acuerdo a la ley de Ohm.
- Pérdidas en el reóstato: es decir, la componente de energía regenerada durante las fases de frenado que, de no ser aprovechada por el propio vehículo para alimentar sus sistemas auxiliares, o por vehículos cercanos para tracción (o devuelta a la red general en caso de ser posible) se disipa en el freno reostático.

2.4. Medidas de ahorro energético

Una vez establecidos los principales factores que influyen en el consumo energético del ferrocarril, es posible explorar la implantación de diferentes medidas enfocadas al ahorro de energía, con el objetivo de incrementar la eficiencia del ferrocarril y hacerlo más sos-

tenible y competitivo. Existen múltiples medidas que se han ido estudiando y probando a lo largo de las últimas décadas y que, como es lógico, se enfocan por lo general a modificar alguno de los factores descritos en el apartado 2.3.

Algunas medidas son específicas de determinado tipo de línea o sistema de electrificación, mientras que otras son aplicables a cualquier tipo de ferrocarril. Algunas cuentan ya con una amplia experiencia de aplicación en múltiples redes ferroviarias, mientras que otras son todavía experimentales y aún no han probado por completo su efectividad. En líneas generales, todas ellas pueden clasificarse en una de las siguientes seis categorías (Douglas et al., 2015):

- Mejoras en los sistemas auxiliares: Todas aquellas medidas enfocadas a reducir el consumo de los sistemas de climatización, refrigeración, ventilación e iluminación del material rodante.
- Mejoras en la cadena de transmisión: Todas aquellas medidas relacionadas con el desarrollo de motores y sistemas de transmisión más eficientes, que reduzcan las pérdidas y aumenten el rendimiento.
- Mejoras enfocadas en reducir la resistencia al avance del vehículo, a través de diseños con mejor aerodinámica, nuevos materiales, etc.
- Mejoras en la infraestructura: Todas aquellas medidas que se centren en el diseño de la propia vía férrea, especialmente en cuanto a su geometría.
- Conducción eficiente: Todas aquellas medidas relacionadas con la Implementación de técnicas y perfiles de conducción con un menor consumo energético.
- Medidas de reaprovechamiento energético: Todas aquellas medidas relacionadas con la aplicación del freno regenerativo para aprovechar la energía regenerada durante el frenado.

En los siguientes apartados se explora cada una de estas seis categorías, si bien se pone especial énfasis en todo lo relacionado con la conducción eficiente y el freno regenerativo, ya que tienen mayor relación con el objeto de la presente tesis.

2.4.1. Mejoras en los sistemas auxiliares

Como se vio en el apartado 2.3, los sistemas auxiliares de un vehículo ferroviario (climatización, iluminación, megafonía, etc.) suponen un porcentaje destacado del consumo total de energía en una red ferroviaria, por lo que centrar esfuerzos en mejorar la eficiencia de estos sistemas puede contribuir notablemente al ahorro energético global de la red.

La mayor parte del consumo en auxiliares es debido a la climatización y ventilación del vehículo, por lo que un cuidadoso ajuste de la temperatura puede reducir el consumo energético de climatización en un 30% (Douglas et al., 2015). Por otra parte, regular correctamente la ventilación del vehículo y limitar aperturas y cierres de puertas también puede contribuir al ahorro energético en este ámbito. Por ejemplo, incorporando sistemas que regulen la toma de aire en función del nivel de CO₂ en el interior del vehículo pueden lograrse ahorros de hasta el 20% en líneas interurbanas (Kokken, 2003) y del 30% en líneas de metro (Amri et al., 2011).

La mejora de los propios equipos de climatización para incrementar su eficiencia (a través de la inclusión de tecnologías como bombas de calor) puede también tener un gran impacto en el consumo de auxiliares, si bien a costa de una mayor inversión. Por otra parte, nuevos y mejores materiales de aislamientos también pueden contribuir a mejorar la eficiencia de la climatización, ya sea en el diseño de nuevos vehículos o en la renovación de material rodante en servicio.

En comparación con la climatización, otros servicios auxiliares tienen un impacto mínimo en el consumo energético. La iluminación, por ejemplo, apenas supone un 2% del consumo total de auxiliares (Douglas et al., 2015), si bien también existen posibles tecnologías a implementar para reducir aún más este consumo, tales como luces más eficientes (LEDs) o sistemas inteligentes que regulen el encendido y apagado de la iluminación y su intensidad.

2.4.2. Mejoras en la cadena de transmisión

Como se ha visto en el apartado 2.3, en la cadena de transmisión de energía se producen una serie de pérdidas que pueden alcanzar entre un 10% y un 15% del total de energía consumida para tracción (Douglas et al., 2015). Estas pérdidas se deben a diferentes elementos de la cadena, como la electrónica que regula los cambios de intensidad y voltaje necesarios (por ejemplo, para cambiar de corriente alterna a corriente continua), los sistemas auxiliares del equipo de tracción (por ejemplo, compresores o refrigeración del motor), o la ineficiencia inherente al propio motor (pérdidas por rozamiento, rendimiento del motor de combustión en el caso de tracción diésel-eléctrica, etc.).

De todos estos factores, la ineficiencia del motor es la mayor fuente de pérdidas de energía, por lo que el diseño y adaptación de motores más eficientes es una medida evidente de ahorro. En la actualidad el tipo de motor más habitual para vehículos ferroviarios de

tracción eléctrica es el motor asíncrono de corriente alterna, con una eficiencia en torno al 92-94% (Kondo, 2010), valor que podría incrementarse a través de diseños novedosos y nuevos materiales. Otra alternativa es la adopción de motores más avanzados, como puede ser el motor síncrono de imán permanente, con una eficiencia del 97% (Kondo, 2010). Esta clase de motores son más pequeños y ligeros pero su coste es bastante elevado, si bien pueden ser comercialmente viables y ya se han incorporado en algunas líneas de alta velocidad en Japón, con ahorros del 7% (Sato et al., 2010).

Otras opciones de ahorro energético relacionadas con la cadena de transmisión pueden incluir sistemas más avanzados de control electrónico y otras mejoras de software que regulen el funcionamiento de los motores y adopten la tracción a la demanda con mayor precisión (por ejemplo, mediante la conexión o desconexión de grupos de tracción). Esta clase de medidas ofrecen ahorros moderados, del orden del 5% para vehículos de tracción eléctrica (González-Gil et al., 2014) y hasta un 7% de ahorro de combustible en vehículos de tracción diésel-eléctrica (Lu et al., 2011), pero tienen un coste de implantación mucho menor.

2.4.3. Mejoras en la resistencia al avance

La dinámica del tren se puede expresar, de forma simplificada, a través de la Segunda Ley de Newton (ecuación (2.1)), de la cual se desprende que, si se reduce la masa del vehículo o se actúa sobre las fuerzas que se oponen al movimiento, será posible reducir la fuerza de tracción necesaria y, por tanto, la energía consumida.

En el primer caso, el desarrollo de nuevos materiales que aúnen resistencia y ligereza permitiría reducir la masa total de los vehículos, influyendo por tanto en su consumo energético. El propio desarrollo de nuevos motores, más ligeros y compactos (tal y como se ha visto en el apartado 2.4.2) también contribuiría a la eficiencia energética en este sentido. Los principales fabricantes de material rodante llevan años investigando sobre la aplicación de nuevos materiales, como por ejemplo materiales compuestos ligeros (Grasso et al., 2015; Keating et al., 2017) o fibra de carbono (Wang, 2017), además de nuevas configuraciones modulares que permitan reducir el peso global del vehículo (Winnett et al., 2017).

En cuanto a las fuerzas que se oponen al movimiento, la resistencia ofrecida por la gravedad cuando se circula en pendiente (así como la resistencia debida a las curvas) depende de la geometría de la vía, por lo que su impacto en el consumo energético se dis-

cute en el apartado 2.4.4, correspondiente a la infraestructura. En cuanto a la resistencia al avance en recta y llano, ésta viene regida, como ya se comentó en el apartado anterior, por la ecuación de Davis (2.2), que comprende tanto rozamientos internos del vehículo como la resistencia aerodinámica.

Por ello, una de las maneras de actuar sobre la resistencia al avance es mediante el diseño aerodinámico del vehículo. Esto tiene menor impacto en vehículos que circulan a velocidades relativamente bajas (metros, cercanías) donde la resistencia aerodinámica es de poca entidad. En cambio, en vehículos de alta velocidad el diseño aerodinámico puede influir significativamente en el consumo energético, habida cuenta de que la resistencia aerodinámica aumenta con el cuadrado de la velocidad. Por no hablar de las implicaciones de seguridad que conllevan las elevadas presiones generadas por el movimiento del vehículo en túneles (Faramehr and Hemida, 2016). Mejoras en el diseño aerodinámico pueden centrarse en la geometría del morro del vehículo y su sección transversal, donde un diseño optimizado puede reducir la resistencia aerodinámica hasta un 20% (Wang et al., 2011); o en elementos particulares tales como los bogies, con reducción en el entorno de un 3% mediante diseños novedosos (Zhang et al., 2018).

Por otra parte, los trenes de mercancías, si bien tienden a circular a velocidades moderadas, también pueden mejorar su aerodinámica para reducir el consumo. Por ejemplo, la instalación de elementos que reduzcan la resistencia aerodinámica en vagones abiertos (de transporte de carbón u otras mercancías a granel) puede reducir el consumo de combustible hasta un 20% (Paul, 2016).

2.4.4. Mejoras en la infraestructura

Tal y como se expuso en el apartado 2.3, el trazado de la vía, y más concretamente, su alineación vertical, influyen directamente en la resistencia al avance del vehículo, y por tanto en el consumo energético. Por ello, incorporar criterios de eficiencia energética durante la fase de diseño de la infraestructura puede tener un gran impacto en el futuro consumo de la red. Evidentemente, el diseño de un nuevo trazado ferroviario viene condicionado por multitud de factores (no sólo puramente ingenieriles sino también económicos e incluso políticos) por lo que no siempre será posible aplicar criterios de eficiencia.

Un enfoque geométrico que contribuye al ahorro energético trata de situar pendientes en los tramos en los que el vehículo va a acelerar y rampas en los tramos en los que el vehículo va a decelerar. De este modo se aprovecha la contribución de la gravedad al

movimiento del vehículo y se maximiza el tiempo que éste circula en deriva. Esta clase de enfoque de diseño se ha estudiado en redes urbanas de metro, con ahorros en el consumo energético que pueden rondar el 5,6% (Xin et al., 2014); pero también se ha aplicado a líneas de alta velocidad (Feng, 2011; Lv et al., 2013).

Por otra parte, debido a que cualquier modificación de un trazado ya existente supone un elevado coste (muy especialmente en redes de metro, por la gran inversión que cualquier obra subterránea implica), esta clase de enfoque se suele limitar al diseño de nuevas líneas, y muy rara vez se tiene en cuenta a la hora de abordar la eficiencia energética en líneas en servicio.

Otro elemento de la infraestructura a considerar es el sistema de señalización. La implementación de sistemas más sofisticados que permiten una operación más eficiente de la línea, aumentando la capacidad de la misma y permitiendo mayores frecuencias de paso, pueden ofrecer además un beneficio en forma de ahorro energético (Zhao et al., 2012). De hecho, a nivel europeo la adopción del sistema ERTMS como un estándar para toda la red continental, si bien aspira fundamentalmente a mejorar la interoperabilidad y capacidad de las líneas férreas europeas, también podría adaptarse para reducir el consumo energético y las emisiones asociadas.

No obstante, la eficacia de una señalización más avanzada en términos de ahorro energético está estrechamente ligada al modo de conducción (aspecto que se trata en el apartado 2.4.5). La adopción de sistemas más avanzados de señalización puede permitir operar la línea mediante DAS o incluso automatizar la conducción completamente con un sistema ATO (*Automatic Train Operation*), lo cual puede contribuir a una conducción más eficiente. Por otra parte, algunos estudios (Quaglietta y Punzo, 2013; Zhao et al., 2012) apuntan que una combinación de conducción optimizada y sistema de señalización más simple puede alcanzar un ahorro energético similar al que se obtendría con la implantación de un sistema de señalización más complejo y costoso.

2.4.5. Conducción eficiente

Por regla general el perfil de velocidades de un vehículo ferroviario entre dos paradas consecutivas consta de una fase de aceleración, una fase de mantenimiento de velocidad y una fase de deceleración, a las que habría que sumar una o varias fases intermedias en deriva, en la que el vehículo corta la tracción y su velocidad viene condicionada exclusivamente por la gravedad y la resistencia al avance. Este enfoque de conducción (regula-

ción y/o deriva) es, en la mayoría de los casos, el más eficiente desde el punto de vista energético (Albrecht et al., 2016a, 2016b).

Existe una amplia literatura centrada en cómo configurar estas distintas fases para lograr un perfil óptimo de velocidad, teniendo en cuenta diferentes tipos de vehículo y línea, diferentes condicionantes externos y diversos escenarios de operación. Así, por ejemplo, se ha estudiado la optimización de perfiles en líneas de metro (Domínguez et al., 2010; Fernández et al., 2015), líneas de alta velocidad (Frilli et al., 2016; Sicre et al., 2012), líneas convencionales o mercancías (Lukaszewicz, 2001).

En general, cualquier reducción en el consumo energético conllevará un cierto aumento en el tiempo de viaje, por lo que el ahorro que se puede lograr mediante la implementación de un determinado perfil de velocidad (o una familia de perfiles) es muy variable y depende, en última instancia, del balance entre tiempo y energía. Se trata, por tanto, de un problema de optimización multi-objetivo, para el que no existe una solución única. Este aspecto se trata con mayor profundidad en las Secciones 3 y 4 del presente Capítulo.

En cualquier caso, la implementación de una conducción más eficiente, o *eco-driving*, puede aportar ahorros en el consumo energético entre el 15% y el 35% en algunos casos (Douglas et al., 2015), con un coste de implantación relativamente bajo. Esto explica el hecho de que se hayan dedicado tantos esfuerzos a investigar y profundizar en la forma de conducción, y se haya aplicado en tantos tipos de líneas y servicios: es una medida de gran potencial y bajo coste, en comparación con muchas de las otras medidas expuestas en apartados anteriores.

La forma en la que se aplica efectivamente un esquema de conducción eficiente a una línea puede limitarse a ofrecer formación a los conductores, o a introducir sistemas de apoyo a la conducción de tipo DAS que ofrecen al maquinista la mejor ruta y la velocidad óptima en base a la posición del vehículo, el horario previsto y las características de la vía. La implantación de esta clase de sistemas en servicios interurbanos puede aportar ahorros de hasta el 22% (Coleman et al., 2010).

Un paso más allá en la implantación de una conducción más eficiente es la automatización completa del servicio mediante ATO. Esta clase de sistema opera el vehículo de forma autónoma (por lo que no es necesario un maquinista) y ya está en uso en muchas redes ferroviarias, particularmente en líneas de metro. El sistema ATO se puede programar para que elija entre una serie de marchas predefinidas optimizadas para cada tramo

de la línea, y su implementación puede lograr ahorros de energía de entre el 10% y el 20% (Domínguez et al., 2008; González-Gil et al., 2014).

Cabe destacar, además, que muchos sistemas de ATO sólo permiten escoger entre un pequeño número de posibles perfiles de velocidad a la salida de cada estación, debido a las limitaciones de los sistemas de comunicación vía-vehículo. No obstante, con el desarrollo de tecnologías de comunicación más sofisticadas que permiten introducir sistemas CBTC (*Communication Based Train Control*), es posible actualizar el sistema ATO en tiempo real, lo que abre enormemente el abanico de posibles soluciones optimizadas a considerar en cada tramo (Carvajal-Carreño et al., 2014; Fernández et al., 2015).

2.4.6. Freno regenerativo

El freno regenerativo es una tecnología que permite convertir parte de la energía generada al frenar el vehículo en energía eléctrica que puede ser reaprovechada, disminuyendo así el consumo neto del sistema y contribuyendo a su eficiencia. Esta tecnología se basa en la capacidad de los motores eléctricos para actuar como generadores, y está ya plenamente implementada en muchos de los vehículos ferroviarios actualmente en servicio.

Como la cantidad de energía regenerada viene en función del perfil de velocidad del vehículo a lo largo de la ruta, la eficacia del freno regenerativo como medida de ahorro está estrechamente ligada a la forma de conducción, y por tanto se suele analizar en el marco de la implementación de perfiles de conducción más eficiente. Otra cuestión diferente es cómo aprovechar esta energía para contribuir al ahorro energético, ya que la energía que no se usa de forma efectiva acaba disipándose en las resistencias que forman el freno reostático, y por tanto se pierde.

Uno de los usos más habituales de la energía regenerada es el de cubrir parte de la demanda de los sistemas auxiliares (González-Gil et al., 2014). Cualquier exceso de energía regenerada no consumido por estos sistemas podría ser devuelto a la catenaria. En redes de corriente alterna esto no ofrece ninguna complicación, ya que la energía devuelta se puede volcar de nuevo en la red general de suministro. En redes de corriente continua, en cambio, no es posible devolver energía a la red general salvo que las subestaciones que suministran al sistema de electrificación ferroviario sean de tipo reversible. De lo contrario, sólo es posible devolver energía a la catenaria si hay otro vehículo en las proximidades que esté traccionando en ese mismo momento. Esto es factible en redes

densas con frecuencias elevadas, pero incluso así parte de la energía regenerada se perderá.

Existen tres enfoques principales para mejorar el reaprovechamiento de la energía regenerada. El primero, exclusivo de redes de corriente continua, es la ya mencionada transformación de las subestaciones en reversibles, lo que conlleva una elevada inversión. Mediante la conversión de las subestaciones se podrían lograr ahorros energéticos rondando el 11% según una experiencia prototipo (Ibaiondo y Romo, 2010).

Otra posibilidad es la instalación de sistemas de almacenamiento que permitan acumular la energía regenerada para su uso posterior. Esta clase de sistemas pueden emplearse tanto en tracción eléctrica como diésel-eléctrica, y pueden instalarse a bordo del vehículo (única posibilidad en el caso de vehículos diésel) o en puntos fijos a lo largo de la ruta. Su uso todavía presenta ciertas dificultades técnicas (como su elevado peso cuando van embarcados, o la durabilidad y fiabilidad de las baterías), pero podrían permitir ahorros importantes de energía: En líneas de metro, desde un 10% en escenarios con frecuencias bajas (Domínguez et al., 2012) hasta un 30% (Steiner et al., 2007); en líneas convencionales con vehículos de tracción diésel-eléctrica, hasta un 35% (Steiner et al., 2007).

Por último, una manera de reaprovechar de forma más eficiente la energía regenerada tiene que ver con la optimización de gráficos. En redes de metro, donde las frecuencias son elevadas y en cada línea existen muchas paradas en distancias relativamente cortas (y por tanto se producen muchos eventos de frenado), pequeñas modificaciones en los gráficos de circulación que permitan sincronizar fases de frenado y aceleración de trenes próximos pueden suponer un notable ahorro de energía. También se puede actuar sobre los tiempos de parada en estaciones. A nivel global se podrían alcanzar ahorros del 10-14% (Nasri et al., 2010; Su et al., 2015).

2.4.7. Efectividad de las medidas de ahorro

A modo de resumen, la Tabla 2.2 recoge potenciales ahorros de energía derivados de la implementación de las diferentes medidas expuestas en los apartados anteriores. Esta tabla no pretende ofrecer una visión exhaustiva y precisa del impacto de cada medida, sino aportar un cierto orden de magnitud para cada una de las seis categorías previamente definidas. Los datos recogidos en la tabla se basan en los trabajos de Douglas et al., 2015 y Su et al., 2016. Por simplicidad, y para ajustar el contenido de la tabla al objeto de

la tesis, los ahorros estimados se refieren solamente a la aplicación de las medidas al ferrocarril de ámbito urbano, con tracción eléctrica.

| Categoría | Medida | Ahorro estimado (%) |
|-------------------------------|--------------------------------------|---------------------|
| Auxiliares | Mejores aislamientos | 1-5 |
| | Gestión de temperatura y ventilación | 1-7 |
| | Climatización más eficiente | 1-5 |
| Cadena de transmisión | Mejoras en motores | 5-10 |
| | Nuevos motores | 10-20 |
| Resistencia al avance | Reducción de masa | 7-14 |
| | Diseño aerodinámico | 1-5 |
| Mejoras en la infraestructura | Diseño geométrico | 1-5 |
| Conducción eficiente | Eco-driving | 15-35 |
| | DAS | 5-20 |
| | ATO | 6-30 |
| Freno regenerativo | Subestaciones reversibles | 10-20 |
| | Sistemas de almacenamiento a bordo | 15-35 |

Tabla 2.2: Medidas para mejorar la eficiencia energética y su ahorro potencial. Fuente: Elaboración propia a partir de Douglas et al., (2015) y Su et al. (2016).

Como se puede ver en la tabla, las medidas con mayor potencial de ahorro son las relacionadas con formas más eficientes de conducción y con el aprovechamiento del freno regenerativo. Sólo las mejoras en la eficiencia de los motores y la reducción de la masa del vehículo ofrecen resultados similares. Éste es uno de los factores que explican por qué esta clase de medidas son las más estudiadas, y las primeras que se suelen aplicar para mejorar la eficiencia de una red ferroviaria, ya que su implementación tiene un coste relativamente bajo en comparación con otras medidas de ahorro (Douglas et al., 2015), y por tanto el balance entre ahorro y coste es bastante favorable respecto a otras medidas.

3. Modelización del consumo energético

En esta sección del Capítulo II se aborda la descripción del estado del arte en lo referente a la modelización del consumo energético ferroviario, evaluando los principales enfoques existentes para determinar el más apropiado como herramienta para el posterior desarrollo de la tesis.

3.1. Introducción

Tal y como se ha expuesto en apartados precedentes, existe todavía un notable margen de mejora en cuanto a la eficiencia energética del ferrocarril, a pesar de su desempeño comparativamente superior respecto a otros medios de transporte. La necesidad de lograr una movilidad más sostenible, y el impulso consiguiente a la expansión del ferrocarril tanto en ámbito urbano como interurbano, llevan aparejados un gran número de investigaciones y estudios para mejorar la caracterización del consumo energético ferroviario y desarrollar medidas y técnicas de ahorro.

Dicho esto, en la actualidad muchas redes ferroviarias todavía se gestionan sin que el operador tenga un conocimiento preciso y detallado del consumo energético de su material rodante. En general, sólo el consumo energético global es conocido, no así qué fracción se debe a tracción, auxiliares, etc., tanto menos cuál es el consumo de cada servicio en tiempo real. Esta carencia es especialmente visible en redes no electrificadas, en las que, a menudo, el control del consumo de diésel se limita a medir el nivel de combustible en el depósito antes y después de cada servicio, ya sea en vehículos de media distancia (Salvador Zuriaga et al., 2014) o en mercancías (Baumel, 2011).

En el caso de líneas electrificadas, por lo general la compañía responsable del suministro eléctrico factura al gestor de la infraestructura según la energía suministrada a nivel de subestación, por lo que el gestor (y, en su caso, el operador del servicio) sólo conoce el consumo energético agregado, sin poder discriminar entre tracción, sistemas auxiliares o consumo de instalaciones (García Álvarez y Martín Cañizares, 2012).

Afortunadamente, esto está cambiando lentamente, y en los últimos años se han desarrollado proyectos de investigación que incluyen la instalación de equipos de medición a bordo de vehículos y la recolección de datos de consumo, tanto en trenes diésel (Salvador Zuriaga et al., 2014) como eléctricos (Martínez Fernández et al., 2015). Por otra parte, cada vez son más las compañías que equipan su material rodante con sistemas de medición de consumo energético en tiempo real, espoleadas por la necesidad de mejorar su eficiencia y reducir costes. En este sentido, cabe destacar el ejemplo de los ferrocarriles alemanes (DB), que han desarrollado sus propios equipos de medida a bordo (Weiland, 2004).

En cualquier caso, una vez se dispone de datos fiables de consumo es posible no sólo analizar la eficiencia energética de una determinada línea o red ferroviaria, sino evaluar la efectividad de medidas de ahorro como las expuestas en el apartado 2.4. Más aún, sin datos fiables no es posible desarrollar modelos de consumo validados, que a su vez permitan expandir los límites de cualquier estudio y evaluar alternativas y escenarios diferentes a los reales.

Centrándonos en el ámbito de estudio de la presente tesis, un modelo fiable que sea capaz de simular el perfil de velocidad de un vehículo ferroviario a partir de una serie de parámetros o factores operativos, y que proporcione el tiempo de viaje y el consumo energético con un margen de error admisible, es una herramienta imprescindible para poder estudiar formas económicas de conducción y ahondar en la optimización de marchas. De hecho, prácticamente cualquier estudio enfocado en este campo en los últimos veinte años desarrolla o adopta un modelo de simulación, de mayor o menor complejidad, ya sea en líneas urbanas de metro (Domínguez et al., 2012, 2008), servicios de mercancías (Lukaszewicz, 2001) o líneas alta velocidad (Cucala et al., 2012; Sicre et al., 2010).

En este sentido, la abrumadora mayoría de bibliografía revisada apuesta por un simulador paso a paso basado en ecuaciones deterministas, preferentemente construido en base a la ecuación de Davis que rige la resistencia al avance del vehículo (véase ecuación 2.2). Sobre esta formulación básica, diferentes autores han ido incorporando más

elementos que aumentan el alcance y la complejidad del simulador, por lo que es necesario establecer un equilibrio entre el grado de precisión que se desea lograr (o bien qué aspectos concretos es necesario modelizar y cuáles no) y el nivel de sofisticación del simulador (y sus correspondientes costes de computación y dificultad de aplicación). No obstante, cabe mencionar otros enfoques más minoritarios que pueden tener su interés, ya sea en solitario o como complemento al modelo determinista más habitual, tales como redes neuronales (Açikbas and Soylemez, 2008), modelos de lógica difusa (Sicre et al., 2014) o modelos estocásticos (Davydov et al., 2018).

En los siguientes apartados se profundiza con mayor detalle en los diferentes enfoques de simulación aplicados en los últimos años, para establecer el marco en el que se basa el modelo de simulación empleado en la presente tesis.

3.2. Enfoque de modelización

3.2.1. Modelos matemáticos exactos

Uno de los primeros enfoques empleados para modelizar el movimiento de un vehículo ferroviario es mediante una formulación matemática resuelta de forma analítica. En el contexto de la optimización del consumo energético ferroviario, esta clase de aproximación está estrechamente ligada a la aplicación de la Teoría de Control Óptimo, desarrollada por Pontryagin y Bellman en los años 50 del siglo XX (véase la sección 4 en el presente Capítulo). Así, por ejemplo, Khmelnitsky (2000) y Howlett et al. (2009) emplearon una ecuación general del movimiento del tren para llevar a cabo sus estudios de optimización del perfil de velocidades a través del Principio de Pontryagin. Su formulación considera el vehículo como una masa puntual y asume su posición (x) como variable independiente, siendo el tiempo (t) y la velocidad (v) variables dependientes:

$$\begin{cases} t' = \frac{1}{v} \\ v' = \frac{u(x) - r(v) + g(x)}{v} \end{cases} \quad (3.1)$$

Donde t y v son función de x (posición del tren), t' y v' son sus respectivas derivadas respecto a x (esto es, $t'=dt/dx$ y $v'=dv/dx$), u es la fuerza por unidad de masa, $r(v)$ es la función de resistencia por unidad de masa, y $g(x)$ es la componente de aceleración debida a al gradiente de la vía.

Franke et al. (2000) también aplicaron este enfoque exacto, si bien formularon el movimiento del tren en términos energéticos en vez de cinemáticos. Más recientemente, conviene citar los trabajos de Albrecht et al. (2016), en los que se aplica un enfoque muy similar al de los anteriores trabajos, pero incorporando la regeneración de energía durante el frenado.

En cualquier caso, esta clase de formulación matemática conlleva la búsqueda de una solución analítica exacta, lo cual es, a priori, una ventaja, ya que se conoce perfectamente el movimiento del vehículo. Sin embargo, obtener dicha solución puede ser extremadamente complejo (o, en determinados casos, impracticable) por lo que es necesario asumir importantes simplificaciones en cuanto a la geometría de la vía, características del vehículo, modos de conducción, etc., para que el problema sea resoluble. De ahí que su aplicabilidad a casos reales sea, cuanto menos, discutible, y en los últimos años se haya optado por otros enfoques más flexibles.

3.2.2. Simulación determinista paso a paso.

El enfoque más habitual con diferencia (Cucala et al., 2012; Domínguez et al., 2011; Huang et al., 2015; Lu et al., 2016; Sicre et al., 2010; Tian et al., 2015) a la hora de modelizar el movimiento y el consumo energético de un vehículo ferroviario es mediante un simulador determinista, basado en ecuaciones simples que se resuelven de forma discreta, bien sea dividiendo el dominio del tiempo (Domínguez et al., 2011; Tian et al., 2015), o bien la longitud del recorrido del vehículo (Lu et al., 2013; Yang et al., 2015).

Así, de forma simplificada, esta clase de simulación se basa en establecer de forma iterativa la aceleración (a) de vehículo en cada paso a partir de la Segunda Ley de Newton:

$$a = \frac{F_T - R_a - R_g}{M} \quad (3.2)$$

Donde F_T es la fuerza de tracción, M es la masa del vehículo, R_a es la resistencia al avance (modelada de acuerdo a la ecuación de Davis, (2.2)) y R_g es la resistencia gravitatoria debida a la pendiente de la vía. En cada iteración del simulador se fija el objetivo de velocidad a alcanzar, se establece la aceleración necesaria, se calcula la fuerza de tracción a aplicar y se actualiza la posición y velocidad del vehículo (o bien se calcula el tiempo transcurrido, en caso de discretización espacial). Una vez conocida la fuerza de tracción en cada paso se puede calcular también el consumo energético.

La ventaja de este enfoque respecto a la modelización matemática exacta es que, con una adecuada discretización, se puede obtener un modelo razonablemente preciso (aunque la solución obtenida no sea al cien por cien exacta) sin tener que asumir las importantes simplificaciones requeridas por la modelización matemática para ser resoluble. Así, con esta clase de simulador se puede considerar la masa y longitud real del tren (en vez de asimilar éste a una masa puntual), incorporar la geometría real de la vía o simular formas de conducción más variadas y complejas. Este enfoque también desliga la simulación de la optimización, lo que permite emplear el simulador con diferentes algoritmos y métodos de optimización.

Esta clase de aproximación suele tomar una forma modular, de manera que se van incorporando elementos al modelo para simular determinados aspectos de la dinámica del vehículo, formas de conducción, sistemas auxiliares, regeneración de energía, etc., en función del grado de complejidad que se desee alcanzar (independientemente de la forma en que se modelice cada uno de estos aspectos específicos). La forma más básica de esta clase de simulador viene representada en la Figura 3.1.

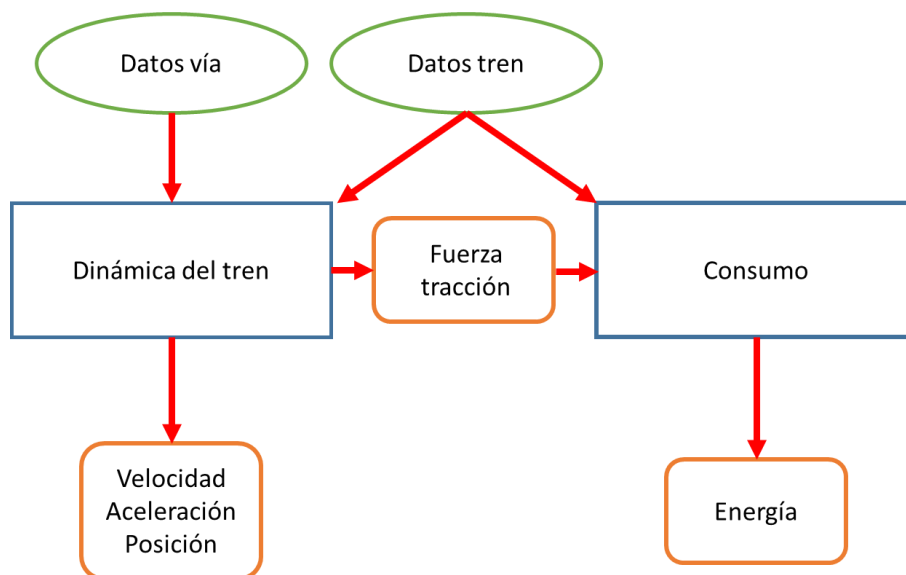


Figura 3.1: Esquema básico de un simulador de movimiento y consumo. Fuente: Elaboración propia.

De acuerdo a este esquema, el simulador consistiría en un primer bloque, basado en la ecuación (3.2), que modeliza la dinámica del vehículo ferroviario, calculando la aceleración a partir del balance de fuerzas (fuerza de tracción, resistencia aerodinámica, resistencia de curva y pendiente, etc.) y fijando su posición y velocidad en cada paso de tiempo.

po Δt (o espacio, Δx). Un segundo bloque modeliza el consumo energético también en cada paso de la simulación. Esto se puede hacer de forma simplificada asumiendo una tensión constante y multiplicándola por la intensidad de corriente en cada paso, obtenida a partir de una curva corriente-velocidad (Domínguez et al., 2008), o bien a partir de la fuerza de tracción obtenida del módulo de dinámica del tren en cada iteración.

A partir de este modelo básico se puede incorporar otro módulo que permitan simular aspectos más específicos de la dinámica ferroviaria, tales como el modo de conducción. Así, por ejemplo, para líneas operadas de forma automática se puede acoplar un modelo del sistema ATO que fije la consigna de aceleración o frenado a aplicar en cada Δt (o Δx) como input para el módulo de dinámica del tren (Domínguez et al., 2008). Por el contrario, para vehículos con conducción manual, es posible incorporar un modelo que simule, hasta cierto punto, las decisiones del maquinista y sus estrategias de conducción (Sicre et al., 2012, 2010).

Por otra parte, la dinámica del vehículo se puede descomponer de manera que se simule por una parte el comportamiento del motor (para así calcular con más precisión el balance de fuerzas y la fuerza de tracción realmente aplicada en cada paso) y por otra el cálculo dinámico que actualice la posición y velocidad del tren. Esta clase de esquema favorece un cálculo más preciso de la fuerza de tracción, y por tanto del consumo energético (Domínguez et al., 2011, 2010).

En general, con este enfoque de simulación paso a paso se logra una estimación bastante precisa tanto del movimiento del vehículo (y, más concretamente, de su perfil de velocidad y el tiempo de viaje) como de su consumo energético. En varios de los trabajos revisados, los autores han podido validar sus simuladores con datos reales, obteniendo errores promedio reducidos. Así, por ejemplo, Domínguez et al. (2011) alcanza un error promedio del 4,2% en cuanto a la estimación de energía y un 1% en cuanto a tiempos de viaje con su simulador para líneas de metro operadas con ATO. Empleando un simulador muy similar, sólo que aplicado a trenes de alta velocidad, Cucala et al. (2012) logran un error en el consumo energético menor al 0,5%.

Por otra parte, Jong y Chang (2005) han validado su simulador en una línea de servicio regional en Taiwan, y si bien sólo modelizan el perfil de velocidades (no el consumo energético), obtienen un error del 0,15% en tiempos de viaje. Salvador Zuriaga et al. (2017), con un simulador desarrollado para trenes diésel en líneas de cercanías/regional, alcanzan un error del 4% en consumo de combustible y menor del 1% en tiempo de viaje.

La Tabla 3.1 recoge éstos y otros ejemplos de los errores promedio obtenidos por diferentes autores para sus respectivos simuladores paso a paso.

| Referencia | % Error (promedio) en tiempos de viaje | % Error (promedio) en consumo energético |
|---------------------------------|--|--|
| (Domínguez et al., 2011) | 1 | 4,2 |
| (Cucala et al., 2012) | N/A | 0,5 |
| (Jong and Chang, 2005) | 0,15 | N/A |
| (Salvador Zuriaga et al., 2017) | 1 | 4,1 |
| (Huang et al., 2015) | N/A | 0,5-10% |
| (Wang and Rakha, 2017) | N/A | 2% |

Tabla 3.1: Error promedio obtenido por diferentes autores de la validación de sus respectivos simuladores. Fuente: Elaboración propia.

Como se ve, en general esta clase de simulador ofrece una precisión bastante elevada, lo que también explica la preferencia de muchos autores por este enfoque de modelización.

3.2.3. Otros enfoques

Existen otros enfoques a la hora de modelizar el movimiento de un vehículo ferroviario y su consumo energético, si bien son claramente minoritarios en comparación con el uso de simuladores y la formulación exacta. Esto es probablemente debido a que estas dos opciones mayoritarias (y muy especialmente la simulación paso a paso) ofrecen buenos resultados en la mayoría de situaciones. No obstante, estos enfoques alternativos de modelización pueden ser de utilidad en determinadas circunstancias, bien en solitario o en combinación con un simulador como el descrito en el apartado 3.2.2. Por ejemplo, se pueden incorporar formulaciones probabilísticas para modelizar determinadas incertidumbres del sistema, tales como retrasos o variaciones en el pasaje, a través de modelos estocásticos (Davydov et al., 2018) o bien mediante lógica difusa (Cucala et al., 2012; Sicre et al., 2014).

Otra herramienta alternativa digna de destacar es el uso de redes neuronales. Estos modelos computacionales, empleados de forma extensa en campos tan diversos como la química, las finanzas o la medicina, se han aplicado de forma muy limitada en el sector de la ingeniería ferroviaria (y menos aún en el ámbito de modelización del movimiento y el consumo), pero existen algunos ejemplos a destacar.

Así, por ejemplo, Açıkbaz y Soylemez (2008) emplearon redes neuronales para generar escenarios de conducción diferentes mediante los que optimizar puntos de inicio de deriva a lo largo de la ruta de un tren, un trabajo similar al realizado por Chuang et al. (2009). Por otra parte, Komyakov et al. (2015) emplearon redes neuronales para modelizar el consumo energético de una red ferroviaria completa, en vez de un único tren en movimiento, mientras que Chen et al. (2016) recurrieron a esta clase de modelos para determinar la posición de múltiples trenes.

Otros autores han empleado redes neuronales como un complemento a su simulador paso a paso, lo cual les permite modelizar determinados aspectos difíciles de incorporar mediante ecuaciones deterministas simples. Así, Huang et al. (2016) las utilizaron para incorporar curvas de frenado complejas a su simulador, mientras que Dündar y Şahin (2013) modelizaron el comportamiento del operador ferroviario a la hora de modificar gráficos de circulación mediante una red neuronal entrenada a partir de datos reales de resolución de conflictos de circulación en los ferrocarriles turcos.

La principal ventaja de las redes neuronales es que no requieren de un conocimiento previo que permita formular un determinado fenómeno de forma explícita, ni dependen de la definición de múltiples parámetros. Por el contrario, para entrenar satisfactoriamente una red neuronal es necesario contar con datos fiables sobre las variables a modelizar, para que la red sea capaz de aprender las tendencias subyacentes a dichos datos.

3.3. Complejidad del modelo. Elementos a considerar

Una vez examinados los diferentes enfoques empleados hasta la fecha para modelizar la dinámica y el consumo energético de vehículos ferroviarios, cabe centrarse en un aspecto fundamental de cualquier modelo: su nivel de complejidad. Todo modelo es, en esencia, una explicación simplificada de un fenómeno real, y a la hora de concebir el modelo es necesario determinar qué elementos de dicho fenómeno reproducir con detalle y cuáles simplificar o ignorar sin perjuicio de la precisión que se desee alcanzar. En suma, se trata de alcanzar un equilibrio, teniendo en cuenta que un modelo demasiado simple no reproducirá correctamente el fenómeno que se desea estudiar, mientras que un modelo demasiado complejo puede ser impracticable, requerir demasiado tiempo de cálculo o resultar directamente irresoluble.

A la hora de modelizar el movimiento de un vehículo ferroviario y su consumo energético son muchos los elementos que pueden ser tenidos en cuenta. Algunos son específicos de determinados tipos de línea o servicio, mientras que otros son aplicables a cualquier

red férrea. Por otra parte, la manera en la que algunos de estos factores se integran en el modelo general puede variar enormemente, desde un simple parámetro añadido hasta un modelo auxiliar relativamente complejo de por sí. En este sentido, la bibliografía consultada muestra una gran disparidad de posibilidades.

La Tabla 3.2 recoge algunos de los factores de mayor interés que pueden incorporarse a la modelización de la dinámica ferroviaria, con algunos ejemplos de aplicación encontrados en la bibliografía revisada. Es de destacar que la mayoría de casos estudiados se corresponden con simuladores paso a paso, si bien esto no significa que algunos de estos factores no puedan incorporarse a otros enfoques de modelización.

| Factor | Referencia |
|--|--------------------------|
| Freno regenerativo | (Wang and Rakha, 2017) |
| Sistema de almacenamiento de energía a bordo | (Lu et al., 2016) |
| Variaciones en la masa del tren | (Fernández et al., 2015) |
| Retrasos inesperados | (Cucala et al., 2012) |
| Acceso de pasajeros durante paradas | (Huang et al., 2017) |
| Comportamiento del maquinista | (Sicre et al., 2014) |
| Consumo de sistemas auxiliares | (Liu et al., 2018) |

Tabla 3.2: Principales factores a incorporar en la modelización. Fuente: Elaboración propia.

De todos los factores mostrados en la tabla, dos de los que han despertado más interés hasta la fecha son el freno regenerativo y los sistemas de almacenamiento de energía a bordo del vehículo. Incorporar la presencia de freno regenerativo al modelo puede tener un gran impacto en su nivel de error, ya que, por ejemplo, Wang y Rakha (2017) obtenían errores en la predicción del consumo energético cercanos al 30% sin incorporar la regeneración. Este nivel de error se reducía al 15% cuando incorporaron una versión simplificada de la regeneración de energía, y mejoró hasta un 2% cuando su simulador incluyó una forma más detallada de simulación del freno regenerativo.

En cuanto a la simulación de sistemas de almacenamiento a bordo, se trata de una de las medidas de ahorro energético más prometedoras en líneas alimentadas con corriente continua, donde la energía regenerada sólo puede ser devuelta a la catenaria cuando hay otro tren cercano traccionando, y de lo contrario se disipa en las resistencias. Varios autores han introducido este elemento en sus simuladores para estudiar su eficacia como medida de ahorro energético (Domínguez et al., 2010; Lu et al., 2016).

Otro elemento de interés es el consumo de los sistemas auxiliares (climatización, iluminación, etc.). Si bien algunos autores ignoran este elemento (Domínguez et al., 2008), o lo simplifican con una tasa fija de consumo energético (Domínguez et al., 2012), otros han tratado de introducir una simulación más realista de la energía consumida por estos sistemas, para mejorar así sus estimaciones de consumo energético (Liu et al., 2018).

Por otra parte, diferentes factores que puedan afectar a la simulación realista del tiempo de viaje también se pueden incluir en la modelización de la dinámica ferroviaria, tales como el impacto de retrasos inesperados en el consumo (Cucala et al., 2012), o el tiempo de acceso de viajeros al vehículo durante las paradas (Huang et al., 2017). Relacionado con esto último, otro factor que tiene gran importancia en el consumo energético pero que resulta complejo de modelizar es la variación de la masa del vehículo debida al trasiego de pasajeros, factor que varios autores han tratado de incorporar a sus respectivos simuladores (Carvajal-Carreño et al., 2014; Fernández et al., 2015; Liu et al., 2018).

Por último, si bien la mayoría de los trabajos revisados se centran en la simulación de la dinámica y el consumo energético de un solo vehículo, también es posible establecer un simulador que tenga en cuenta la interacción de varios vehículos circulando por la misma red (Tian et al., 2015) y el consumo a nivel de subestación (Domínguez et al., 2012).

3.4. Discusión sobre el estado del arte de la modelización

Queda claro que la gran mayoría de los autores revisados han optado por emplear un simulador determinista, ya sea con discretización temporal o espacial, debido a su mayor flexibilidad y su razonable precisión. La segunda alternativa más empleada (la formulación matemática exacta), si bien es más rígida y dependiente de múltiples simplificaciones para su resolución, también cuenta con varios ejemplos de uso. Otros enfoques alternativos son minoritarios.

En este sentido, la Tabla 3.3 recoge los principales enfoques de modelización expuestos en los apartados anteriores, con la relación de referencias encontradas que aplican uno u otro para modelizar el movimiento y consumo de un vehículo ferroviario. Como se puede ver, destacan claramente los enfoques deterministas, y muy especialmente los basados en simulación paso a paso.

| Enfoque básico | Formulación | Referencias |
|----------------|---------------------------------|---|
| Determinista | Formulación exacta | (Khmelnitsky, 2000) (Franke et al., 2000) (Liu and Golovitcher, 2003) (Howlett et al., 2009) (Su et al., 2013) (Wang and Zhu, 2014) (Albrecht et al., 2016a) |
| | Simulador paso a paso | (Jong and Chang, 2005) (Domínguez et al., 2008) (Sicre et al., 2010) (Domínguez et al., 2010) (Domínguez et al., 2011) (Kang, 2011) (Cucala et al., 2012) (Domínguez et al., 2012) (Sicre et al., 2012) (Lu et al., 2013) (Domínguez et al., 2014) (Carvajal-Carreño et al., 2014) (Sicre et al., 2014) (Huang et al., 2015) (Tian et al., 2015) (Yang et al., 2015) (Zhao et al., 2015) (Fernández et al., 2015) (Lu et al., 2016) (Salvador Zuriaga et al., 2017) (Wang and Rakha, 2017) (Ahmadi et al., 2018) |
| | Otros | (Kim et al., 2010) (Yang et al., 2012) (Brenna et al., 2016) (He and Xiong, 2018) (Liu et al., 2018) |
| Probabilístico | Modelos estocásticos | (Davydov et al., 2018) |
| Aprendizaje | Redes Neuronales | (Açikbas and Soylemez, 2008) (Komyakov et al., 2015) (Chen et al., 2016) |
| Combinaciones | Determinista + Redes Neuronales | (Chuang et al., 2009) (Y. Huang et al., 2016) |

Tabla 3.3: Enfoques de simulación y relación de bibliografía consultada. Fuente: Elaboración propia.

En total se han revisado más de 40 trabajos relacionados con la modelización del consumo energético ferroviario, que cubren aproximadamente los últimos 20 años. La gran mayoría de estos trabajos están estrechamente relacionados con la optimización del consumo (tal y como se expondrá en la Sección 4 de la presente tesis) porque, como ya se ha explicado, la modelización es un paso a menudo imprescindible a la hora de plantear y resolver un problema de optimización de marchas.

La distribución de cada uno de los principales enfoques de simulación comentados más arriba se puede ver en la Figura 3.2.




Figura 3.2: Frecuencia de uso de cada enfoque de modelización. Fuente: Elaboración propia.

Como se ve en la figura, los enfoques basados en ecuaciones deterministas conforman la gran mayoría de los casos revisados (un 85% del total), siendo el simulador paso a paso la opción mayoritaria con un 56%, seguida de la formulación matemática exacta con un 17%. De los enfoques minoritarios, el uso de redes neuronales es el más destacado, bien en solitario (un 7%) o en combinación con un simulador paso a paso.

La preponderancia en el uso de enfoques basados en un simulador determinista paso a paso se explica por las razones anteriormente expuestas, que incluyen su mayor flexibilidad y su razonable precisión a la hora de modelizar tanto el tiempo de viaje como el consumo energético. Su mayor desventaja es la necesidad de contar con un conocimiento previo que permita establecer las diferentes ecuaciones que rigen cada una de las partes del simulador, y definir con precisión los múltiples parámetros de los que depende el modelo. Así, por ejemplo, el simulador descrito por Domínguez et al. (2011), que es la base

de varios trabajos sucesivos con diferentes modificaciones y ampliaciones (Carvajal-Carreño et al., 2014; Domínguez et al., 2014; López-López et al., 2014), requiere hasta 12 parámetros para su correcto funcionamiento, algunos de los cuales pueden no ser fácilmente accesibles en algunos casos (tales como los coeficientes de resistencia al avance del vehículo, o la masa rotatoria).

Por otra parte, si bien aumentar la complejidad del simulador mediante modelos auxiliares adicionales es relativamente sencillo, la manera en la que se modeliza cada uno de estos aspectos particulares (como puede ser los retrasos o las variaciones de masa) puede ser bastante dificultosa, y no siempre se puede conseguir de forma práctica a través de ecuaciones deterministas sencillas. En este sentido, la combinación de un simulador paso a paso con modelos no deterministas se presenta como una alternativa muy atractiva, que ha sido relativamente poco explorada hasta el momento.

3.5. Conclusiones

Teniendo en cuenta toda la bibliografía revisada en lo referente a la modelización del movimiento de un vehículo ferroviario y su consumo energético, se pueden establecer las siguientes conclusiones sobre el estado del arte:

- La simulación paso a paso es el enfoque de modelización más empleado, con amplia diferencia, debido a su flexibilidad y razonable precisión.
- Diferentes autores han validado sus simuladores con datos reales, obteniendo errores promedio inferiores al 1% en cuanto a tiempos de viaje, y por debajo del 5% en cuanto a consumo energético (con valores incluso menores en algunos casos).
- Es posible incorporar a la modelización multitud de factores para mejorar la estimación del consumo energético y estudiar diferentes medidas de ahorro energético, pero los más estudiados hasta la fecha son el freno regenerativo y el modo de aprovechar la energía regenerada.
- De los enfoques de modelización alternativos, las redes neuronales parecen las más prometedoras (si bien su uso es minoritario y secundario). De los pocos ejemplos de uso de redes neuronales encontrados, casi todos las emplean como complemento para modelizar determinados aspectos auxiliares del problema.

Teniendo en cuenta estas conclusiones, para desarrollar un modelo que permita calcular el perfil de velocidades, tiempo de viaje y consumo energético de diferentes alternativas

de conducción (herramienta imprescindible para el estudio de la optimización del consumo energético a través de la conducción), se ha optado, en el marco de la presente tesis, por emplear un simulador paso a paso con discretización temporal combinado con una red neuronal para calcular el consumo energético.

La decisión de explorar el uso de redes neuronales como complemento al simulador viene motivada por el hecho de que se trata de una opción apenas explorada hasta la fecha pero que tiene un interesante potencial, especialmente para modelizar ciertos elementos cuando se carece de información lo bastante detallada como para definir ecuaciones deterministas que los regulen. En el Capítulo IV se profundiza con más detalle en la motivación, estructura y características del simulador empleado.

4. Optimización del consumo energético

En esta sección del Capítulo II se aborda la descripción del estado del arte en lo referente a la optimización del consumo energético ferroviario, partiendo de la formulación del problema y los diferentes enfoques aplicados, hasta llegar a las diversas familias de algoritmos empleados para obtener soluciones optimizadas. Si bien se plantea esta revisión en términos generales, la bibliografía examinada se centra fundamentalmente en la optimización de marchas, al ser éste el ámbito de aplicación de la presente tesis.

4.1. Introducción

Como ya se ha explicado en apartados anteriores, existe desde hace años un impulso por incrementar la eficiencia energética del ferrocarril, para así contribuir a un transporte más sostenible y con un menor impacto en las emisiones de CO₂. Una manera de contribuir a esta mejora en la eficiencia es a través de estudios de optimización, que buscan analizar de forma sistemática determinados elementos del servicio ferroviario en busca de configuraciones más eficientes que reduzcan el consumo de energía. Esta clase de estudios de optimización están muy relacionados con algunas de las medidas de ahorro expuestas en la Sección 2.

Desde el punto de vista del ahorro de energía, es posible optimizar la geometría del trazado ferroviario (Huang et al., 2015), el reaprovechamiento de la energía regenerada en el caso de que los vehículos cuenten con freno regenerativo (Wang y Rakha, 2017), o la configuración de los gráficos de circulación (Watanabe y Koseki, 2015). Sin embargo, la gran mayoría de estudios se centran en el llamado *eco-driving*, esto es, en la búsqueda de formas de conducción más eficiente, ya que este enfoque es, con diferencia, el que

ofrece mejores resultados a la hora de reducir el consumo energético de una red ferroviaria con un coste de implantación relativamente bajo (Douglas et al., 2015).

Así pues, diversos autores han tratado de optimizar la conducción en líneas de alta velocidad (Sicre et al., 2010), líneas de metro (Fernández et al., 2015) o líneas de mercancías (Lukaszewicz, 2001). Algunos estudios se centran en conducción manual (Sicre et al., 2012) mientras que otros buscan optimizar las marchas programadas en redes operadas automáticamente mediante ATO (Brenna et al., 2016). Por otra parte, si bien la mayoría de autores analizan el problema de la optimización de marchas desde el punto de vista de un único tren, otros tienen en cuenta varios trenes al unísono, para así incorporar a su estudio las posibles interacciones entre ellos (Komaki et al., 2016; Tian et al., 2015).

Una vez establecido el ámbito de aplicación del estudio, es necesario plantear con detalle el problema de optimización: cuáles son las variables objetivo, qué factores se tendrán en cuenta, que condicionantes se aplican, etc. En cuanto a los factores a considerar, éstos están estrechamente ligados al enfoque de modelización empleado, tal y como se ha explicado en la Sección 3: Para cualquier estudio que pretenda evaluar alternativas y escenarios diferentes a los que ya existan en una determinada red ferroviaria, es imprescindible contar con un modelo que calcule tiempos y consumos. Según el modelo escogido incluya, por ejemplo, freno regenerativo (Tian et al., 2015), sistemas de almacenaje de energía a bordo (Domínguez et al., 2010) o una simulación de las variaciones de masa debidas al trasiego de pasajeros (Fernández et al., 2015), se podrán buscar perfiles de conducción optimizados que tengan en cuenta estos u otros factores.

Por otra parte, dependiendo de las características de la red objeto de estudio y de los diferentes condicionantes existentes, es posible que existan sólo un puñado de soluciones posibles, o bien que el espacio de soluciones adquiera un gran tamaño. En el primer caso sería posible evaluar explícitamente todas las soluciones posibles y escoger las óptimas de acuerdo a unos criterios previamente establecidos. En el segundo caso, en cambio, sería necesario recurrir a algún procedimiento que permita filtrar las soluciones y hallar las mejores en un tiempo razonable. Aquí entran en juego los diferentes métodos y algoritmos de optimización.

Existen diversas metodologías para resolver un problema de optimización. Las más sencillas consisten en la búsqueda directa sistemática antes mencionada, cuando el espacio de soluciones es reducido (Domínguez et al., 2008). Esta búsqueda puede complementarse mediante el establecimiento de una serie de reglas de selección basadas en Teoría

de Decisión (Domínguez et al., 2010). Por otra parte, si el problema se ha planteado en términos matemáticos exactos, es posible llevar a cabo una optimización analítica a través de la Teoría de Control Óptimo y el Principio de Pontryagin (Albrecht et al., 2016b; Howlett et al., 2009; Khmelnitsky, 2000). Otros enfoques empleados en algunos problemas de optimización se pueden enmarcar en la Programación Lineal Difusa (Sicre et al., 2012), la Programación Dinámica (Liu et al., 2018) o la Programación Lineal de Enteros (Liu et al., 2015; Lu et al., 2016), si bien se trata de opciones menos exploradas en el ámbito que nos ocupa.

De hecho, las herramientas más habituales para la optimización de marchas son las pertenecientes a la familia de los algoritmos meta-heurísticos, que permiten encontrar soluciones óptimas (si bien no se garantiza que sean las mejores posibles) con un coste de computación asumible. Pertenecientes a esta categoría cabe destacar los algoritmos genéticos (Dündar y Şahin, 2013; Watanabe y Koseki, 2015), los algoritmos de enjambre de partículas (Yang et al., 2015) o algoritmos de colonia de hormigas (Lu et al., 2013).

En los siguientes apartados se analiza el estado del arte referido a la optimización de marchas en el ámbito ferroviario, partiendo de la definición del problema y de los factores y condicionantes a tener en cuenta, hasta el estudio de las diferentes metodologías de optimización empleadas. Se presta especial atención a los algoritmos de tipo meta-heurístico, cuya comparativa es uno de los objetivos de la presente tesis.

4.2. Definición del problema de optimización

El primer paso imprescindible en cualquier estudio de optimización es la formulación precisa del problema, esto es, la definición de qué se pretende optimizar y en base a qué criterios y objetivos. También es necesario determinar el alcance del problema y su complejidad, lo que de nuevo supone alcanzar un equilibrio entre representatividad (es decir, que el problema formulado sea lo bastante próximo a la realidad como para que las soluciones obtenidas sean útiles) y practicidad (es decir, que el problema se pueda resolver con un coste de computación asumible).

Un problema de optimización se puede plantear en base a un único objetivo, o varios. En el primer caso, se trata de optimizar una única variable (sea ésta discreta o continua), por lo que, en general, existirá una única solución óptima en base a los criterios y condicionantes específicos del problema.

Por otra parte, cuando se definen varios objetivos a optimizar (que pueden ser contradictorios entre sí, de manera que mejorar uno suponga empeorar otro), por lo general no existe una única solución óptima que simultáneamente satisfaga todos los objetivos, sino que se pueden hallar un número teóricamente infinito de soluciones que conforman la frontera óptima de todas las posibles. Cada una de estas soluciones se denomina solución de Pareto o solución no-dominada ya que, para cada una, no existe ninguna otra solución que mejore simultáneamente todos los objetivos. Además, en ausencia de otros criterios o condicionantes, todas ellas son igualmente válidas. La frontera que conforman todas las soluciones no-dominadas se denomina frente (o curva) de Pareto (véase Figura 4.1).

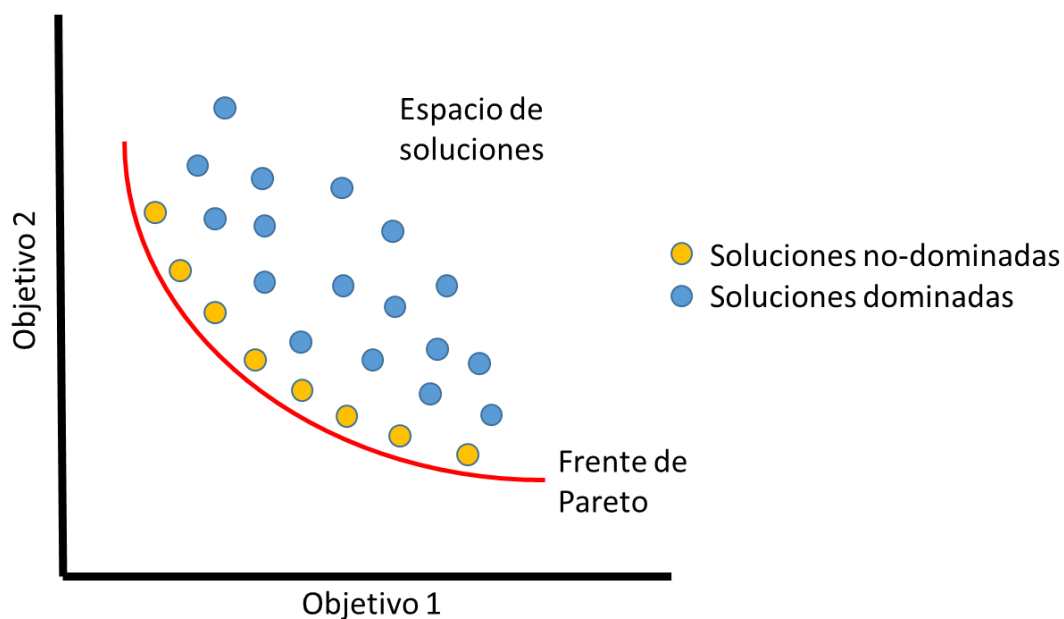


Figura 4.1: Espacio de soluciones y frente de Pareto en un problema de optimización con dos objetivos contradictorios. Fuente: Elaboración propia.

En el ámbito de la optimización ferroviaria, algunos autores han planteado problemas con un único objetivo, como puede ser reducir el consumo energético en base al perfil de velocidad para un tiempo de circulación prefijado (Khmelnitsky, 2000), la minimización de retrasos en una línea de mercancías sin considerar su coste energético (Salim y Cai, 1995) o los intervalos de tiempo entre la salida de trenes consecutivos para minimizar el pico de consumo energético (Kim et al., 2010). No obstante, el planteamiento más habitual en la literatura revisada es considerar al menos dos objetivos: tiempo de viaje y consumo energético.

La manera precisa en la que se formulan estos objetivos, y cómo se plantea el problema específico a optimizar (es decir, qué variable(s) de control se optimiza(n) efectivamente para cumplir con los objetivos) ofrece múltiples posibilidades. Así, por ejemplo, Eaton et al. (2017) estudiaron cómo optimizar el reajuste de horarios en un cruce ferroviario teniendo en cuenta no solo la reducción de retrasos, sino también la limitación del consumo energético debido a la reorganización del gráfico de circulación.

Centrándonos en la optimización de marchas, es evidente que ambos objetivos (tiempo y energía) resultan contradictorios: perfiles con menor consumo energético conllevarán un mayor tiempo de viaje, y viceversa. Además, el tiempo de viaje es una variable restringida entre un mínimo físico (la denominada marcha tendida) y un máximo que vendrá prefijado por condiciones de la explotación. La búsqueda de marchas óptimas (esto es, pertenecientes al frente de Pareto) en base a estos dos objetivos puede plantearse de diferentes maneras.

Algunos autores plantean la definición de los perfiles de velocidad a través de la identificación de los puntos del recorrido donde el vehículo debe comenzar a circular en deriva (Chang y Sim, 1997; Khmel'nitsky, 2000; Yang et al., 2012). Otra posibilidad similar es la de definir velocidades objetivo en determinados puntos de la ruta, un enfoque bastante habitual para líneas de larga distancia (Lu et al., 2013) o mercancías (Y. Huang et al., 2016), si bien también es aplicable a líneas de metro (He y Xiong, 2018).

Un enfoque más elaborado pasa por articular el perfil de velocidad en base no solamente a velocidades o puntos de deriva, sino a una serie de comandos más variados (por ejemplo, instrucciones de frenado, de aceleración o de deriva) establecidos en diferentes puntos de la ruta (Sicre et al., 2012). Por último, en líneas operadas automáticamente, algunos autores plantean el problema a través de la optimización de los comandos del sistema ATO (Carvajal-Carreño et al., 2014; Domínguez et al., 2010; Liu et al., 2015), que a su vez determinan el perfil de velocidad a aplicar en el tramo.

La Tabla 4.1 recoge los principales enfoques hallados en la bibliografía para optimizar tiempo y energía de forma combinada a través de las marchas, con ejemplos de aplicación.

| Variable(s) optimizadas | Referencia |
|--|--------------------------|
| Puntos de deriva | (Yang et al., 2012) |
| Velocidad objetivo en puntos del recorrido | (Lu et al., 2013) |
| Comandos de conducción manual | (Sicre et al., 2012) |
| Comandos ATO | (Domínguez et al., 2010) |

Tabla 4.1: Principales enfoques empleados para optimización de marchas. Fuente: Elaboración propia.

Otro aspecto destacable es el alcance del problema de optimización, esto es, si se enfoca la optimización a un único tren, o a varios en la misma línea, o a toda la red. Muchos de los trabajos revisados se centran en optimizar la marcha de un único vehículo y para un único tramo, ya sea un trayecto completo en una línea de larga distancia (Sicre et al., 2012; Yang et al., 2015) o bien cada uno de los tramos inter-estación en una línea de metro (Carvajal-Carreño et al., 2014; Domínguez et al., 2010).

Otra posibilidad, en una línea con varias paradas intermedias, es optimizar la distribución del margen de tiempo global de la línea (entendido como la diferencia entre el tiempo comercial exigido y el tiempo resultante de circular a marcha tendida) entre los diferentes tramos inter-estación (Cucala et al., 2012; Sicre et al., 2010; Watanabe y Koseki, 2015). Por último, algunos autores extienden la optimización a varios trenes simultáneamente para tener en cuenta la interacción entre ellos, y plantean la eficiencia energética en términos de toda la red, por ejemplo a través de la energía suministrada por las subestaciones (Ahmadi et al., 2018; Domínguez et al., 2012).

Por otra parte, si bien la opción más habitual, como ya se ha dicho, es plantear el problema de optimización de marchas en base a los objetivos de tiempo y energía, algunos autores han incorporado un tercer objetivo a sus estudios: el confort de los viajeros. Este tercer objetivo se suele incorporar de forma indirecta, normalmente introduciendo ciertos condicionantes en el simulador de marchas que restrinjan los niveles de sobre-aceleración (*jerk*), limiten los ciclos de deriva o, en suma, impidan cualquier otro comportamiento del vehículo que afecte al confort.

También se puede incorporar el objetivo de confort como un criterio de selección *a posteriori*, de manera que las soluciones de Pareto obtenidas tras el proceso de optimización se filtren para eliminar aquéllas que incumplan alguno de los criterios fijados (Domínguez et al., 2010, 2008). Por último, cabe la posibilidad de establecer el confort como un tercer

objetivo explícito, en igualdad de condiciones con la limitación de consumo energético y tiempo de viaje, a través de uno o varios índices que se evalúen para cada uno de los perfiles de velocidad considerados (He y Xiong, 2018).

4.3. Optimización de marchas en redes de metro

En este apartado se particulariza la formulación del problema de la optimización a las redes de metro, particularmente aquéllas operadas automáticamente mediante ATO, al ser éste el ámbito de aplicación de la presente tesis.

4.3.1. Planteamiento y objetivos

Un vehículo equipado con un sistema ATO recibe una serie de comandos que configuran su marcha para cada tramo entre dos estaciones. Estos comandos pueden ser la aceleración máxima a aplicar, la deceleración de frenado final, la velocidad a mantener durante la ruta, los puntos de deriva, etc.

La combinación de estos comandos marca el perfil de velocidad que el vehículo desarrolla en el tramo. Diferentes perfiles suponen diferentes consumos energéticos y tiempos de viaje, siendo éstos dos objetivos contradictorios: por lo general, a mayor tiempo de viaje, menor consumo, y viceversa. Por lo tanto, la optimización de marchas en un sistema ATO es un problema multi-objetivo en el que se buscan combinaciones de los comandos ATO que resulten en perfiles de velocidad con un consumo energético reducido sin comprometer los márgenes de tiempo establecidos por condiciones de explotación comercial.

Los sistemas ATO más convencionales cuentan con un número limitado de valores discretos para cada uno de los comandos (debido a las limitaciones de ancho de banda de los sistemas de comunicación vía-vehículo), y se suelen diseñar de antemano cuatro perfiles para cada tramo inter-estación (Domínguez et al., 2010, 2008): un perfil de marcha tendida, un perfil de máximo tiempo de viaje admisible (dentro de los márgenes de explotación comercial establecidos) y dos perfiles intermedios, de modo que el sistema seleccione uno u otro según las necesidades del servicio.

El perfil de marcha tendida representa el límite inferior del tiempo de viaje, ya que es la marcha más rápida posible: el tren acelera hasta la máxima velocidad, y mantiene dicha velocidad durante el mayor tiempo posible (respetando obviamente las limitaciones de velocidad existentes en el tramo) hasta frenar antes de alcanzar la siguiente estación con la máxima deceleración de servicio admisible. El límite superior del tiempo de viaje lo fijan, como ya se ha dicho, las condiciones de explotación comercial. La optimización de

marchas consiste en buscar, entre estos dos extremos de tiempo, las marchas con menor consumo energético, de manera que, para cada tramo inter-estación, el sistema ATO pueda escoger entre una serie de opciones energéticamente eficientes.

4.3.2. Espacio de soluciones

Como se mostraba en la Figura 4.1, para un problema de optimización con dos objetivos contradictorios, el espacio de soluciones toma la forma de una nube de puntos en la que se aprecia una frontera conformada por las soluciones no-dominadas, es decir, aquellas soluciones para las que ninguna otra posible mejora ambos objetivos simultáneamente. En el caso que nos ocupa, esto significa que, para cada tiempo de viaje posible entre el correspondiente a la marcha tendida y el tiempo máximo admisible, existe una combinación de comandos ATO que minimiza el consumo energético.

En un sistema ATO convencional, con las limitaciones antes mencionadas, el espacio de soluciones posibles es relativamente limitado. Por ejemplo, en el caso del metro de Madrid (Domínguez et al., 2008), las posibles configuraciones de cada comando ATO dan lugar a 220 perfiles de velocidad por cada tramo inter-estación, por lo que es perfectamente factible representar al completo todos ellos, delimitar cuáles forman el frente de Pareto y escoger los cuatro a programar en el sistema ATO. Esta elección se hace normalmente aplicando criterios adicionales, como por ejemplo que los cuatro perfiles estén distribuidos regularmente a lo largo del frente (Domínguez et al., 2010). En todo caso, en esta clase de problemas es de aplicación una búsqueda sistemática de soluciones.

Sin embargo, en redes de metro que incorporen sistemas de comunicación y señalización más modernos de tipo CBTC, el sistema ATO es capaz de manejar muchos más valores posibles para los diferentes comandos que suministra al tren, lo que extiende enormemente el espacio de soluciones (Domínguez et al., 2014) y abre la posibilidad de predefinir un mayor número de perfiles a aplicar en cada tramo, e incluso actualizar perfiles en tiempo real en función de la carga de pasaje (Carvajal-Carreño et al., 2014), de la interacción con otros trenes (Domínguez et al., 2012) o de la aparición de retrasos inesperados (Fernández et al., 2015).

En cualquier caso, un espacio de soluciones amplio implica, como ya se ha comentado, el uso de algoritmos que permitan rastrear y filtrar dicho espacio y hallar un conjunto de soluciones óptimas. Muchos de estos algoritmos no garantizan encontrar todo el frente de Pareto (ni siquiera que las soluciones obtenidas pertenezcan realmente al mismo), pero

sí proporcionan un conjunto de soluciones razonablemente próximas al frente de Pareto real. Hasta qué punto esto es así determina el grado de convergencia del algoritmo y la diversidad de sus soluciones.

4.3.3. Convergencia y diversidad

A la hora de evaluar el rendimiento de cualquier algoritmo de optimización multi-objetivo, se suelen tener en cuenta tres factores (Coello Coello et al., 2004):

- Que la distancia entre el frente formado por las soluciones proporcionadas por el algoritmo y el frente de Pareto real sea mínima. Esto se conoce por convergencia.
- Que el conjunto de soluciones encontradas cubra todo el frente de Pareto. Esto se conoce por diversidad.
- Que el mayor número posible de soluciones proporcionadas por el algoritmo pertenezca efectivamente al frente de Pareto real.

Además, también se busca que el frente proporcionado por el algoritmo esté uniformemente distribuido, lo que se conoce por regularidad. Así pues, un algoritmo de optimización multi-objetivo debe ser capaz, rastreando un amplio espacio de soluciones en un tiempo razonable, de proporcionar un frente de Pareto muy próximo al real y bien distribuido entre los casos extremos posibles (Figura 4.2).




Figura 4.2: Esquema ilustrativo de los conceptos de convergencia y diversidad en algoritmos de optimización multi-objetivo. Fuente: Elaboración propia.

Para evaluar estos factores existen una serie de métricas diversas, que se discuten con mayor detalle en el Capítulo IV, Sección 8.

4.4. Métodos de optimización

En este apartado se van a revisar los principales métodos de optimización empleados hasta la fecha para incrementar la eficiencia energética en el ferrocarril a través de la forma de conducción. Si bien se presta especial atención a los algoritmos de tipo meta-heurísticos, al ser éstos objeto de interés de la presente tesis, también se discuten otros enfoques diferentes.

4.4.1. Optimización analítica

La optimización analítica parte, como ya se explicó en la Sección 3, de plantear la dinámica y el consumo energético del ferrocarril a través de un sistema de ecuaciones diferenciales, lo que permite posteriormente buscar los mínimos de dicho sistema de ecuaciones de forma analítica. La principal ventaja de esta metodología es que la solución o soluciones obtenidas son matemáticamente exactas. Su principal desventaja es su rigidez, ya que el sistema de ecuaciones precisa de importantes simplificaciones para que la optimización sea resoluble, lo que resta representatividad a las soluciones obtenidas. Dicho de otro modo, mediante esta metodología se pueden encontrar soluciones exactas para una aproximación simplificada de la realidad.

En el ámbito que nos ocupa, la mayoría de autores que optan por una optimización analítica se basan en la Teoría de Control Óptimo, ya explicada en el apartado 3.2 de la presente tesis. Así, se parte de formular las ecuaciones diferenciales que rigen la dinámica del vehículo y su consumo energético, bien considerando el tiempo (Howlett et al., 2009) o el espacio (Khmelnitsky, 2000) como variable independiente. Por otra parte, si bien lo más habitual es usar la velocidad del vehículo como variable de estado (Howlett et al., 2009; Liu y Golovitcher, 2003), también se puede formular el problema a través de la energía cinética (Khmelnitsky, 2000).

En cualquier caso, una vez establecida la formulación matemática, es necesario determinar que, en efecto, existe una estrategia óptima de conducción que minimice el consumo energético para un tiempo dado (Albrecht et al., 2016a). A partir de ahí se puede buscar minimizar el trabajo mecánico de tracción, lo que no es estrictamente lo mismo que minimizar el consumo de energía o combustible, ya que intervienen factores de rendimiento de los motores (Albrecht et al., 2016a). La optimización propiamente dicha se hace a tra-

vés del análisis Hamiltoniano (Albrecht et al., 2016a; Howlett, 2000) y el Principio de Pontryagin. Éste establece que cualquier estrategia de control que maximice el Hamiltoniano formulado a partir de las ecuaciones que rigen la dinámica del vehículo, sujeto a determinados condicionantes, es una estrategia de control óptimo (Albrecht et al., 2016a; Khmelnitsky, 2000). De este punto en adelante, denominaremos a este enfoque de optimización como *Maximum (o Minimum) Principle Analysis (MPA)*.

El análisis detallado del MPA es bastante complejo y queda fuera del ámbito de estudio de la presente tesis, por lo que no se incidirá más sobre él. Cabe destacar, no obstante, que esta línea de trabajo sobre optimización de marchas sigue vigente y que, a pesar de precisar de simplificaciones importantes para su resolución, a lo largo de los últimos años ha sido posible incorporar a la modelización elementos tales como regeneración de energía a través del frenado (Albrecht et al., 2016a), o una definición de la geometría vertical de la vía más acorde al trazado real (Howlett et al., 2009; Liu y Golovitcher, 2003).

4.4.2. Búsqueda sistemática

En aquellos casos en los que el espacio de soluciones posibles es relativamente pequeño, y por tanto el número de soluciones de Pareto practicables es limitado, es posible analizar todas ellas de forma sistemática y escoger las mejores sin necesidad de recurrir a algoritmos o metodologías de selección complejas.

Éste es el caso, por ejemplo, de líneas operadas con ATO en las que el sistema fija los comandos que configuran la marcha al inicio de cada tramo inter-estación entre un número limitado de posibilidades, normalmente debido a limitaciones en las tecnologías de comunicación tren-vía y el reducido ancho de banda (Domínguez et al., 2008). En casos así es perfectamente asumible calcular todas las marchas posibles, obtener el espacio de soluciones al completo, delimitar el frente de Pareto y escoger en cada caso las marchas óptimas según convenga. Es lo que, a efectos de la presente tesis, vamos a denominar Búsqueda Directa o *Direct Search (DS)*.

En el caso de que el número de soluciones no-dominadas aumente en cierta medida, pero todavía sea razonable a efectos de tiempo de computación calcular el espacio de soluciones al completo, es posible incorporar a esta metodología una serie de criterios de selección que ayuden a escoger entre las soluciones del frente de Pareto. Estos criterios se fijan en base a la Teoría de Decisión, o *Decision Theory (DT)*, y pueden consistir en la búsqueda de soluciones no-dominadas (esto es, que pertenezcan al frente de Pareto),

localizadas en un área concreta del frente o que estén distribuidas equitativamente a lo largo del mismo. También se pueden incorporar criterios de confort (Domínguez et al., 2011, 2010).

Este enfoque de optimización cuenta con la ventaja de su simplicidad y facilidad de uso, pero queda limitado, como ya se ha dicho, a determinados problemas en los que las restricciones existentes limitan enormemente el espacio de soluciones posibles.

4.4.3. Programación lineal/no-lineal

En este apartado se agrupan los métodos de optimización basados en programación lineal o dinámica. Se trata de enfoques de optimización matemática que parten de simplificar un problema complejo en elementos más simples, y que en algunos casos permiten incorporar ciertas incertidumbres a la formulación del problema.

Programación Dinámica (DP)

La programación dinámica o *Dynamic Programming* (DP) es una metodología de optimización matemática consistente en simplificar un problema complejo en una serie de problemas más simples que se desarrollan secuencialmente, de manera que existe una relación recursiva entre las soluciones óptimas de cada problema simple y la solución óptima del problema mayor. La existencia de esta clase de relación, basada en el Principio de Optimalidad de Bellman, es necesaria para que un problema sea resoluble mediante DP.

Un problema a resolver con DP se plantea, por lo general, mediante una ecuación de Bellman que establece la relación secuencial entre los diferentes sub-problemas, en un proceso recursivo conocido como inducción hacia atrás. La ecuación de Bellman se establece en aquellos casos en los que el problema se plantea de forma discreta, el equivalente en problemas continuos es una ecuación en derivadas parciales conocida como Ecuación de Hamilton-Jacobi-Bellman.

En el ámbito de la optimización de marchas, el enfoque DP se ha empleado para enfrentarse a problemas no-lineales que resultaban demasiado complejos de resolver mediante el enfoque MPA. Así, por ejemplo, Lu et al. (2013) aplicaron DP para buscar el perfil de velocidades más eficiente para un tiempo dado de viaje, mediante la optimización de la velocidad en determinados puntos de la ruta. Por otra parte, Liu et al. (2018) aplicaron una modificación de DP para optimizar gráficos de circulación en una línea de metro.

Programación Lineal de Enteros Mixtos (MILP)

La programación lineal de enteros es una metodología de optimización matemática lineal, es decir, que busca optimizar una función objetivo lineal sujeta a restricciones lineales. Además, se define por el hecho de que algunas o todas las variables se restringen a valores enteros. Si algunas de las variables no son discretas, entonces se trata de programación lineal de enteros mixtos, o *Mixed-Integer Linear Programming* (MILP).

Los problemas definibles como MILP son de tipo NP-complejo, lo que supone que muchos de ellos son irresolubles de forma exacta, y por tanto requieren de aplicar métodos aproximados de tipo heurístico, incluyendo alguno de los algoritmos meta-heurísticos explicados en los siguientes apartados.

El enfoque MILP se ha aplicado de forma limitada a la optimización de marchas en el ámbito ferroviario. Así, Lu et al. (2016) plantearon mediante MILP un problema de optimización energética del perfil de velocidades en base a valores de velocidad en puntos fijos de la ruta, probando diferentes condicionantes tales como límites de velocidad o variaciones de gradiente de la vía. Por otra parte, Kim et al. (2010) trataron de reducir el pico de energía de tracción que ocurre cuando varios vehículos traccionan a la vez en una red de metro a través de un modelo MILP, resuelto por dos vías: una exacta basada en el método de ramificación y poda, y otra heurística simplificada de diseño propio.

Programación Lineal Difusa (FLP)

La programación lineal difusa, o *Fuzzy Linear Programming* (FLP), es una metodología de optimización lineal que incorpora una cierta evaluación de incertidumbre a través del uso de lógica difusa (*fuzzy logic*). En contraste con la optimización más tradicional, que busca maximizar o minimizar una función objetivo sujeta a determinadas restricciones, la optimización mediante FLP define algunas de estas restricciones e incluso la propia función objetivo con una componente de incertidumbre o 'vaguedad', de manera que se admite un cierto grado de violación de las restricciones impuestas para la optimización.

Este enfoque apenas se ha empleado en el ámbito que nos ocupa, con un único ejemplo encontrado (Cucala et al., 2012) en el que se usa para optimizar horarios en líneas de alta velocidad, en combinación con una optimización de marchas resuelta mediante algoritmo genético. Este modelo FLP incorpora el consumo energético debido a retrasos y al comportamiento del maquinista, introduciendo así incertidumbre en el problema a través de números difusos.

4.4.4. Algoritmos meta-heurísticos

Los algoritmos meta-heurísticos empleados en optimización son una serie de procedimientos para hallar rápidamente soluciones aproximadas a un problema para el cual los métodos tradicionales no funcionan o requieren demasiado tiempo de computación, o bien cuando la información disponible respecto al problema definido es imperfecta o incompleta. La filosofía tras estos algoritmos es la de obtener soluciones que, si bien no serán las mejores posibles, son lo suficientemente buenas como para resolver el problema y se pueden alcanzar con medios limitados. En cierto sentido, se pueden considerar que esta clase de algoritmos representan un atajo, o bien una renuncia a cierto grado de precisión o exactitud a cambio de rapidez.

Los algoritmos meta-heurísticos son especialmente adecuados cuando el espacio de soluciones es demasiado amplio como para poder analizarlo por completo, ya que permiten muestrear dicho espacio y localizar soluciones óptimas de una manera más rápida y eficiente que otros métodos de optimización. De ahí que se hayan empleado extensamente en los últimos años para afrontar problemas de optimización de marchas en el ámbito ferroviario.

Existen multitud de algoritmos meta-heurísticos diferentes, clasificables en función de diferentes criterios. En el ámbito que nos ocupa, los principales algoritmos encontrados en la bibliografía se pueden definir como basados en una población, es decir, operan a través de un conjunto de soluciones-candidato que se van modificando iterativamente hasta alcanzar un subconjunto de soluciones óptimas. El funcionamiento específico de muchos de estos algoritmos viene inspirado por algún proceso natural que sirve de marco conceptual a su formulación matemática.

Dicho esto, en líneas generales, los algoritmos meta-heurísticos empleados en la optimización de marchas se pueden clasificar en dos grandes grupos:

- **Algoritmos evolutivos:** Se trata de algoritmos inspirados por el proceso biológico de la evolución, en el que cada solución-candidato se asimila a un individuo dentro de una población, definido por una serie de parámetros (su genoma) que 'muta' y se 'transmite' a la siguiente generación. Este proceso iterativo se extiende durante varias generaciones, de manera que los mejores individuos de cada generación (escogidos en base a algún criterio predeterminado) son los que se cruzan para aportar su genoma a sus descendientes. Pertenecen a este grupo los

llamados algoritmos genéticos (Chang y Sim, 1997; Dündar y Şahin, 2013; Sicre et al., 2010).

- Algoritmos de inteligencia de enjambre: Estos algoritmos se inspiran en el comportamiento colectivo de sistemas auto-organizados tales como las colonias de ciertos insectos. En este caso las soluciones-candidato se asimilan a individuos del enjambre que interactúan localmente con su entorno, y colectivamente con el resto de miembros del enjambre, para ‘rastrear’ el espacio de soluciones en busca de puntos óptimos. Pertenecen a este grupo los algoritmos de enjambre de partículas (Domínguez et al., 2014; Fernández et al., 2015) y colonia de hormigas (Eaton et al., 2017; Zhao et al., 2015).

Existen otros meta-heurísticos empleados en optimización de marchas que no pertenecen a estas dos categorías, si bien su uso es más limitado. Cabe mencionar el algoritmo de Búsqueda Tabú o *Tabu Search* (TS), un método de búsqueda local (Huang et al., 2017; Liu et al., 2015); y el algoritmo basado en aprendizaje y enseñanza, o *Teaching Learning Based Optimisation* (TLBO), inspirado por la influencia que un profesor experto tiene en el aprendizaje de una clase (Huang et al., 2015).

A continuación se exponen con más detalles las principales características de las diferentes variantes de meta-heurísticos empleados en la literatura revisada, así como algunas otras opciones que podrían ser de interés para su aplicación a la optimización de marchas.

Algoritmo genético

Los algoritmos genéticos representan con diferencia la opción más estudiada, no sólo en lo que a algoritmos evolutivos se refiere sino en relación a todos los meta-heurísticos basados en población. Introducidos en los años 60 del siglo XX por John Holland y David Goldberg, se inspiran en los mecanismos que rigen la evolución de los seres vivos, y han sido empleados en múltiples campos.

En líneas generales, su funcionamiento se puede resumir del siguiente modo: se parte de una población inicial (ya sea generada aleatoriamente o en base a algún conocimiento previo) en la que cada individuo viene caracterizado por un genoma, esto es, una serie de valores numéricos descriptivos del problema a optimizar (por ejemplo, los comandos dados por un sistema ATO). Parte de los individuos de esta población inicial sufren una mutación (es decir, una variación aleatoria de su genoma) y parte son seleccionados para

cruzarse y combinar sus genomas, dando así lugar a una nueva generación. El proceso de cruce se puede establecer de acuerdo a la siguiente relación:

$$y = \alpha \cdot x_{p1} + (1 - \alpha) \cdot x_{p2} \quad (4.1)$$

Donde x_{p1} y x_{p2} son los dos progenitores, y es el descendiente, y α es un número aleatorio entre 0 y 1. Esta forma de cruce reparte el genoma de los progenitores de forma aleatoria entre los descendientes, pero también es posible emplear otras reglas de reparto, o seleccionar más de dos progenitores. Por otra parte, el mecanismo de mutación se puede expresar del siguiente modo:

$$y_m(j) = x_m(j) + \sigma \quad (4.2)$$

Donde y_m es el individuo mutado, x_m es el individuo antes de mutar, j denota el j -ésimo elemento del genoma y σ es la magnitud de la mutación. Por otra parte, la tasa de mutación (TM) determinará qué elementos del genoma se mutan y cuáles no. Del mismo modo que ocurría con el mecanismo de cruce, el proceso de mutación también admite diferentes variantes o formulaciones alternativas a la aquí propuesta. En todo caso, este proceso de mutación y cruce se repite generación tras generación durante un número predeterminado de iteraciones, o bien hasta que se cumple algún criterio de finalización previamente establecido (Figura 4.3).

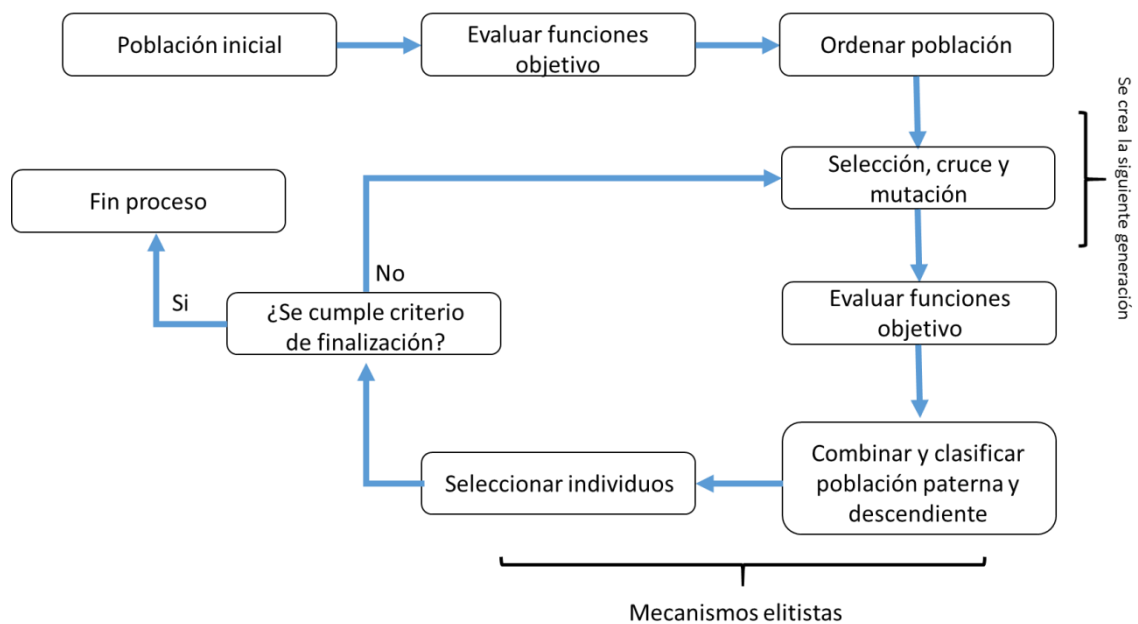


Figura 4.3: Esquema básico de funcionamiento de un algoritmo genético. Fuente: Elaboración propia.

Sobre este esquema básico existen múltiples variantes en función de cómo se determina la mutación, bajo qué criterios se selecciona a los individuos que se cruzarán y tendrán descendencia, etc. No obstante, la versión empleada mayoritariamente en el ámbito que nos ocupa (Brenna et al., 2016; Carvajal-Carreño et al., 2014; He y Xiong, 2018; Kang, 2011; Sicre et al., 2012; Wong y Ho, 2004) es la denominada NSGA-II, o *Non-dominated Sorted Genetic Algorithm*, donde el número II indica la segunda versión de este algoritmo, diseñado para considerar dos objetivos de optimización (por ejemplo, tiempo y energía).

El algoritmo NSGA-II es una variante elitista del algoritmo genético, ya que incorpora un mecanismo para evaluar, en cada generación, qué individuos son mejores y por tanto son candidatos a tener descendencia. El criterio seguido es, precisamente, el de no-dominación, ya comentado para identificar soluciones de Pareto, de ahí la denominación *Non-dominated Sorted* ('clasificado por no-dominación').

Por otra parte, es habitual complementar el algoritmo con un mecanismo que ayude a preservar la diversidad de las soluciones, esto es, que favorezca la proliferación no sólo de soluciones no-dominadas, sino además de soluciones que se distribuyan uniformemente a lo largo del frente de Pareto. Un mecanismo muy efectivo en este sentido es el denominado *Crowding Distance*, consistente en un segundo criterio de clasificación que favorece aquellas soluciones no-dominadas que se encuentran a mayor distancia de las demás. Este mecanismo puede incorporarse al NSGA-II (Carvajal-Carreño et al., 2014), pero también a otros meta-heurísticos tales como el enjambre de partículas (Domínguez et al., 2014).

Algoritmo evolutivo de Frente de Pareto

El algoritmo evolutivo de Frente de Pareto, o *Strength Pareto Evolutionary Algorithm* (SPEA), es una variante de algoritmo evolutivo desarrollada por Eckart Zitzler y Lothar Thiele en 1998. Al pertenecer a la misma categoría que el NSGA-II, su funcionamiento se basa en los mismos mecanismos de cruce y mutación. La principal diferencia que aporta el SPEA es la introducción de mecanismos elitistas propios, en la forma de un archivo externo en el que se almacenan las mejores soluciones tras cada generación (en oposición al NSGA-II que considera una única población en la que se mezclan progenitores y progenie).

La forma más básica del SPEA se inicia con una población inicial (ya sea generada aleatoriamente o en base a información previa sobre el problema) y un archivo vacío. En cada

iteración se van incorporando al archivo las soluciones no-dominadas y se eliminan las dominadas o duplicadas. Las soluciones del archivo se clasifican en función del número de miembros de la población total dominados por cada uno de los miembros del archivo. Tras cada actualización del archivo se aplican los procesos de mutación y cruce, para los que se toman individuos tanto del archivo como de la población general, si bien los primeros tienen mayor probabilidad de ser escogidos. Por otra parte, el archivo tiene un tamaño máximo prefijado, por lo que en caso de llenarse se eliminan las soluciones sobrantes con algún mecanismo (ej. *Clustering*) que evite pérdida de diversidad.

Esta formulación del SPEA presenta algunas limitaciones, entre ellas la forma en la que se clasifican los miembros del archivo respecto a la población ya que, por ejemplo, si en el archivo sólo hay un individuo, toda la población se clasifica con el mismo rango respecto a ese único individuo. Esto perjudica al mecanismo de selección de progenitores, que pasa a ser aleatorio. Por otra parte, al limitar el tamaño del archivo se induce una pérdida de diversidad, incluso con los mecanismos que el algoritmo tiene implementados para evitar este problema.

Para combatir estas deficiencias, los mismos autores del SPEA original propusieron una variante denominada SPEA-II (Thiele y Zitzler, 1999) que introduce las siguientes modificaciones:

- El archivo siempre se llena, de manera que, en caso de no haber bastantes soluciones no-dominadas en una iteración, se completa con soluciones dominadas. Esto evita las variaciones de tamaño del archivo.
- El mecanismo para truncar el archivo y eliminar soluciones sobrantes se ha mejorado para limitar aún más la pérdida de diversidad.
- Incorpora una técnica de estimación de densidad de vecinos que mejora la eficiencia de la búsqueda por el espacio de soluciones.
- Sólo se escogen miembros del archivo para el cruce en cada iteración.

La Figura 4.4 recoge un esquema básico del funcionamiento del SPEA-II.

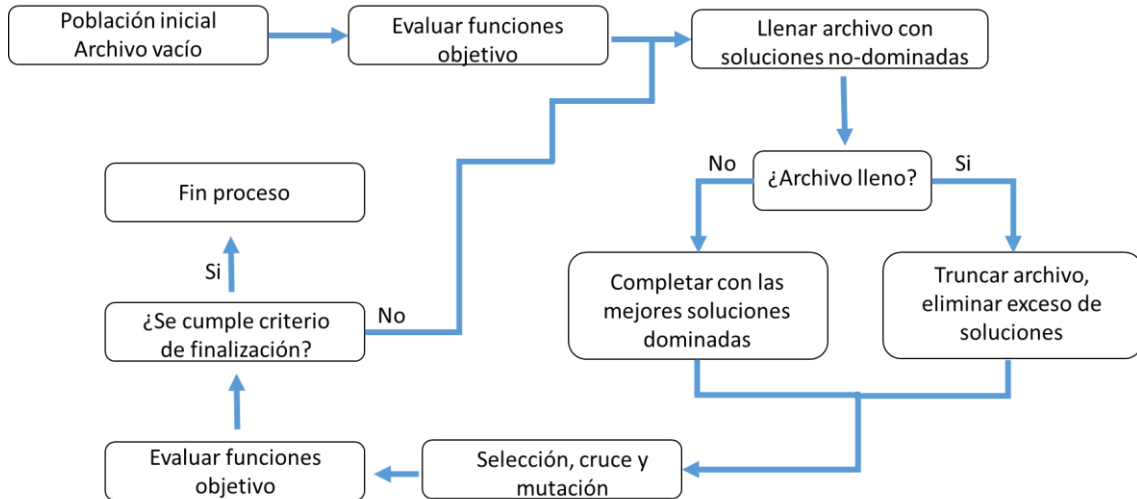


Figura 4.4: Esquema básico de funcionamiento de un algoritmo SPEA-II. Fuente: Elaboración propia.

En cuanto a su uso para la optimización de marchas, cabe decir que el SPEA-II es una opción muy minoritaria. Sólo se ha encontrado un ejemplo de uso (He y Xiong, 2018), en el que se compara su funcionamiento con el más común NSGA-II, arrojando este último un mejor resultado con menos tiempo de cálculo, si bien la comparativa se basa en un único caso teórico con pequeñas variaciones en los parámetros de ambos algoritmos.

Algoritmo evolutivo basado en descomposición

Esta variante de algoritmo evolutivo incorpora una estrategia básica a la hora de afrontar problemas de optimización multi-objetivo: la descomposición. Esta estrategia consiste en dividir el problema en cuestión en un número N de problemas mono-objetivo que se resuelven simultáneamente. Cada uno de los problemas auxiliares resulta en una única solución óptima, hallada a partir exclusivamente de la información que se extrae de los problemas vecinos, y el conjunto de las N soluciones de los N problemas auxiliares es la solución global del problema multi-objetivo.

Propuesto por Zhang y Li (2007) con la denominación de *Multi-Objective Evolutionary Algorithm based on Decomposition* (MOEA-D), según sus autores este algoritmo puede ofrecer un rendimiento similar al más habitual NSGA-II en problemas de optimización multi-objetivo con variables continuas con un menor coste computacional.

El funcionamiento del MOEA-D para cada uno de los sub-problemas en los que se divide el problema multi-objetivo global es, fundamentalmente, el mismo que el de cualquier

algoritmo genético. Es decir, que para cada sub-problema se establece una población inicial en su entorno, y esta población se va modificando generación tras generación mediante los mecanismos habituales de cruce y mutación. La mejor solución hallada en cada iteración para cada sub-problema se va almacenando en un archivo, y cuando finaliza el proceso (bien tras un número determinado de generaciones o de acuerdo a algún otro criterio preestablecido) las soluciones de este archivo constituyen la solución global al problema (Figura 4.5).

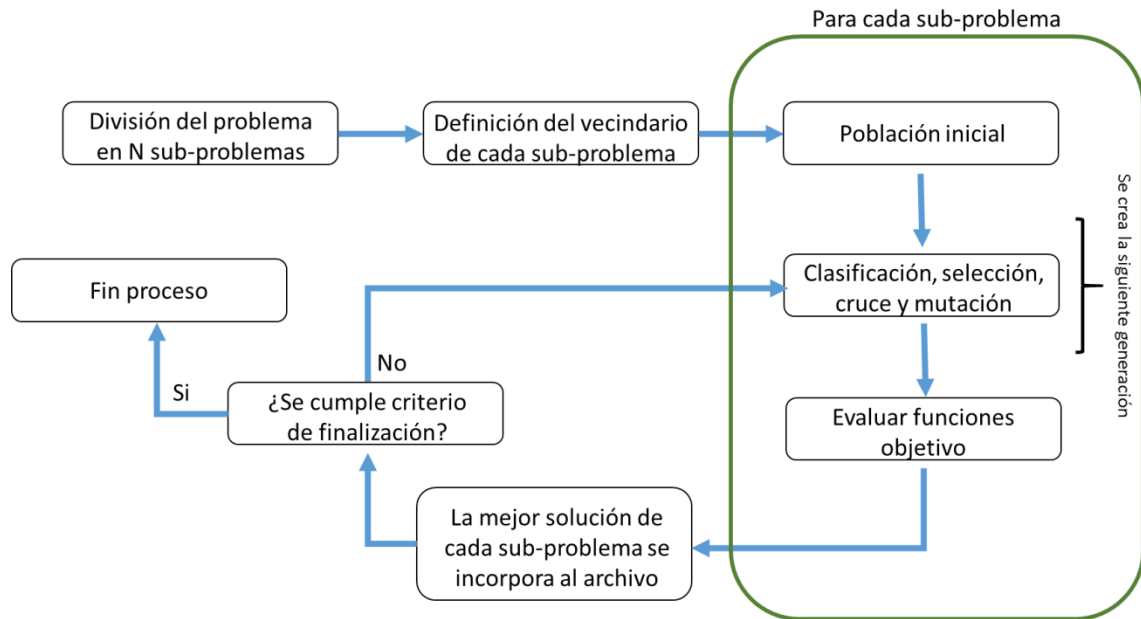


Figura 4.5: Esquema básico de funcionamiento de un algoritmo MOEA-D. Fuente: Elaboración propia.

Por tanto, la verdadera clave del MOEA-D estriba en el modo en que se realiza la división del problema global y en el grado de influencia que cada sub-problema tiene en sus vecinos inmediatos. En cuanto a lo segundo, el algoritmo establece unos pesos que marcan, para cada sub-problema, el tamaño de su vecindario, esto es, cuáles de los sub-problemas vecinos le influyen. Un vecindario muy reducido limita la capacidad del algoritmo para explorar eficazmente nuevas zonas para resolver cada sub-problema, mientras que un vecindario demasiado amplio perjudica la propia división del problema, ya que se superponen en exceso los diferentes sub-problemas.

En cuanto al mecanismo de división, los autores originales proponen tres enfoques posibles (Zhang y Li, 2007), si bien existen otros muchos aplicables, siempre que se consiga un número razonablemente grande de divisiones equitativamente distribuidas:

- Suma ponderada: Como su propio nombre indica, este enfoque consiste en considerar el problema como una suma ponderada de soluciones particulares, en base a un vector de pesos previamente establecido. Es un método de división sencillo que puede funcionar correctamente si el frente de Pareto es perfectamente cóncavo (o convexo en caso de un problema de maximización), pero que no asegura una buena división en problemas con un frente más irregular.
- Enfoque de Tchebycheff: Una variación del anterior en el que, además de definir un vector de pesos, se definen también unos puntos de referencia que sirven como polos sobre los que articular cada división. De este modo se facilita el cubrir mejor el frente de Pareto. Por el contrario, este enfoque conlleva que la agregación de los diferentes sub-problemas para reconstruir el problema global no sea una función suave, lo que resulta inconveniente en problemas en los que las variables son continuas.
- Intersección de frontera: Este enfoque comprende diferentes metodologías de tipo geométrico, específicamente diseñadas para problemas multi-objetivo con variables continuas. En esencia, se buscan los puntos de intersección entre una familia de líneas y el dominio de aplicación del problema global, de manera que cada intersección genera una división del mismo. Si las líneas están regularmente distribuidas, es de esperar que la partición resultante cubra correctamente todo el frente de Pareto, incluso aunque éste no tenga una forma regular cóncava (o convexa en caso de ser un problema de maximización).

Por otra parte, en cuanto a su uso para optimizar marchas, cabe decir que no se ha encontrado ningún ejemplo de aplicación del MOEA-D en la literatura revisada. No obstante, es de destacar el interés de este tipo de algoritmo evolutivo al incorporar una estrategia de resolución (la descomposición) que está ausente en los restantes meta-heurísticos revisados.

Enjambre de partículas

El enjambre de partículas es uno de los principales algoritmos de optimización pertenecientes a la rama de inteligencia de enjambre. Desarrollado originalmente en los años 90 por James Kennedy, Russel Eberhart y Yuhui Shi como una herramienta para simular el comportamiento social, pronto se demostró que una versión simplificada de este algoritmo podía emplearse como herramienta de optimización.

El funcionamiento básico de enjambre de partículas es el siguiente: se define una población inicial de partículas (ya sea generada aleatoriamente o en base a algún conocimiento previo), que se desplazan sobre el espacio de soluciones buscando aquellas zonas que arrojan un mejor valor de la función objetivo. Este mejor valor puede ser el mínimo de la función o, en el caso de problemas multi-objetivo, zonas que generan soluciones no-dominadas.

Cada partícula viene definida por vector de posición (x_i) y un vector velocidad (v_i) asociado que rige su futuro desplazamiento. En cada iteración se actualiza la velocidad de cada partícula y su posición, en base tanto a su propia experiencia en iteraciones anteriores como a la experiencia acumulada por todo el enjambre, tal y como expresan las siguientes ecuaciones:

$$\vec{v}_i(t) = w \cdot \vec{v}_i(t-1) + c_1 \cdot r_1 \cdot (\vec{p}_i - \vec{x}_i(t-1)) + c_2 \cdot r_2 \cdot (\vec{p}_g - \vec{x}_i(t-1)) \quad (4.3)$$

$$\vec{x}_i(t) = \vec{x}_i(t-1) + \vec{v}_i(t) \quad (4.4)$$

Donde c_1 y c_2 son constantes positivas que regulan, respectivamente, la influencia de la mejor solución encontrada hasta el momento por esa partícula en concreto (p_i) y la mejor solución encontrada por todo el enjambre (p_g). Por su parte, r_1 y r_2 son valores aleatorios entre 0 y 1, y w es el denominado peso inercial, que regula el desplazamiento de la partícula. Normalmente el peso inercial se modifica a lo largo del proceso, con un valor elevado al inicio para alentar a las partículas a cubrir un área mayor del espacio de soluciones, que luego se va reduciendo para estimular una búsqueda más local y refinada de valores óptimos.

En cada iteración del algoritmo se actualizan las mejores soluciones de cada partícula (p_i) así como la mejor solución global (p_g), todas ellas almacenadas en un repositorio independiente. Este archivo, normalmente con un tamaño determinado, va incorporando nuevas soluciones en sustitución de algunas de las ya existentes en función de criterios de no-dominación y otros mecanismos que mejoren la convergencia y diversidad de las soluciones (como, por ejemplo, el mecanismo de *Crowding Distance*). Cuando termina el proceso iterativo (bien tras un número prefijado de iteraciones o cuando se cumpla algún otro criterio de finalización), el archivo resultante representa el conjunto de soluciones no-dominadas halladas por el algoritmo (Figura 4.6).

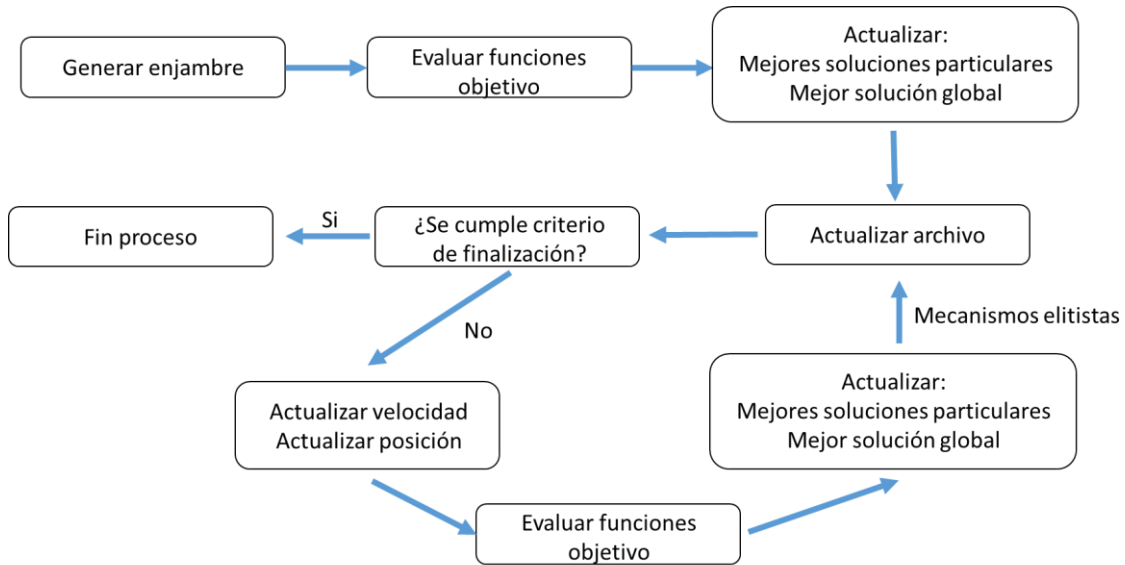


Figura 4.6: Esquema básico de funcionamiento de un algoritmo de enjambre de partículas.
Fuente: Elaboración propia.

En el ámbito de estudio que nos ocupa, la variante de enjambre de partículas empleada es la denominada MOPSO: *Multi-Objective Particle Swarm Optimisation*, preparada para acometer problemas multi-objetivo (Fernández et al., 2015; Yang et al., 2015). No obstante, cabe decir que es una opción de optimización muy poco empleada en comparación con el más popular NSGA-II, si bien algunos autores defienden que arroja resultados mejores en términos tanto de convergencia (esto es, cercanía al frente de Pareto real) como diversidad (Domínguez et al., 2014).

Colonia de hormigas

El algoritmo de colonia de hormigas, o *Ant Colony Optimisation* (ACO), es un meta-heurístico perteneciente a la categoría de inteligencia de enjambre, inspirado por el comportamiento de estos insectos en su búsqueda de comida. Propuesto inicialmente por Marco Dorigo en 1991, en su forma más habitual es una técnica probabilística para resolver problemas de optimización asimilables a buscar caminos óptimos en una estructura de grafos. Los elementos del algoritmo ('hormigas') recorren los diferentes caminos disponibles y marcan los mejores de acuerdo al objetivo a optimizar, alentando a otras hormigas a que las sigan hasta definir una ruta óptima (Figura 4.7). Este marcaje se realiza a través de un parámetro denominado 'feromona', de manera que, en cada nodo del grafo, la intensidad de la feromona (τ_{ij}) viene definida por:

$$\tau_{ij} = \rho \cdot \tau_{ij} + \Delta\tau_{ij} \quad (4.5)$$

Donde ρ es un coeficiente que regula la evaporación del rastro de feromona, y $\Delta\tau_{ij}$ es la suma de la aportación de feromona que realiza cada hormiga que ha pasado por ese nodo. Esta formulación básica de ACO no sirve para resolver problemas multi-objetivo, ni para problemas con variables continuas, pero se ha usado extensamente para resolver problemas de optimización de tipo combinatorio.

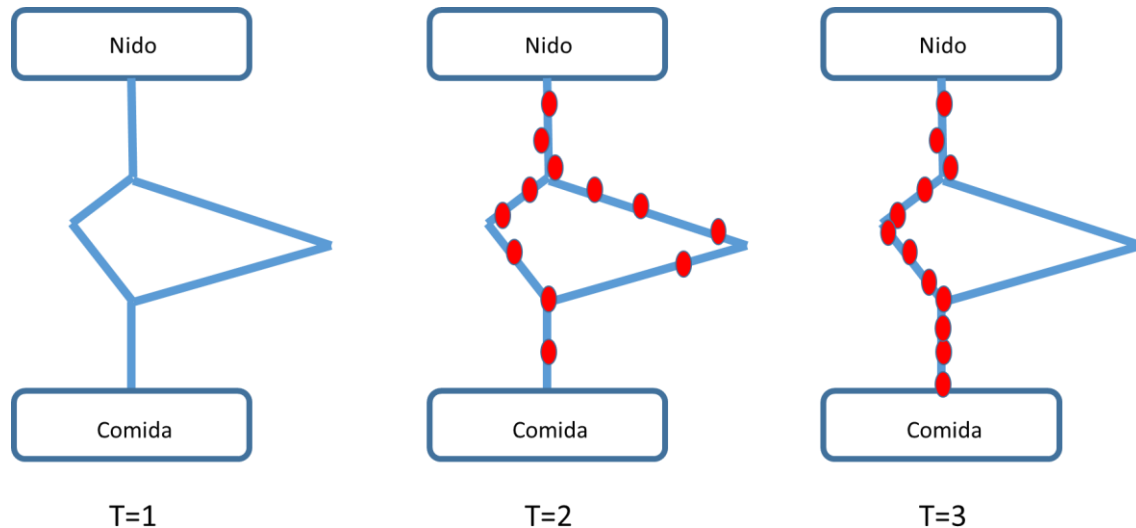


Figura 4.7: Croquis de funcionamiento del ACO. Fuente: Elaboración propia.

Debido a estas limitaciones, no resulta fácil aplicar el ACO a la optimización de marchas. No obstante, existen algunos casos dignos de mención. Así, por ejemplo, Lu et al. (2013) plantearon un problema consistente en definir la velocidad óptima en determinados puntos de una ruta, dado un tiempo prefijado de viaje, y escogiendo entre valores discretos de velocidad en cada punto. De este modo el problema podía asimilarse a un grafo cuyos nudos eran los puntos discretos de velocidad, y pudieron aplicar el ACO para encontrar la ruta óptima, esto es, la configuración de velocidades con menor consumo energético para el tiempo de viaje dado. Un planteamiento muy similar al empleado por Zhao et al. (2015).

A partir del algoritmo ACO básico, a lo largo de los últimos años se han ido realizando modificaciones que amplían sus posibilidades de uso. Una de las más notables es la versión propuesta por Socha y Dorigo (2008), denominada ACO_r (*Ant Colony Optimisation for Continuous Domains*) que permite resolver problemas de optimización con variables continuas. Para ello, el algoritmo se plantea de manera que cada hormiga, en vez de es-

coger entre opciones discretas, elige su camino en base a una función de densidad de probabilidad (generalmente una función Gaussiana, si bien se pueden emplear otras). Además, el algoritmo cuenta con un archivo de soluciones donde, tras cada ciclo, se almacenan y clasifican las mejores obtenidas, para ser escogidas de forma estocástica por cada hormiga para construir su solución en la siguiente iteración. Cada solución del archivo tiene un peso asignado w_l igual a:

$$w_l = \frac{1}{qk\sqrt{2\pi}} e^{\frac{(l-1)^2}{2q^2k^2}} \quad (4.6)$$

Donde k es el número de hormigas y q es un parámetro que regula la selección de soluciones. A un menor valor de q las mejores soluciones del archivo tienen mayor probabilidad de ser escogidas por cada hormiga, mientras que a mayor valor de q la probabilidad de escoger una u otra solución del archivo es más uniforme. La probabilidad p_l de cada solución se formula como:

$$p_l = \frac{w_l}{\sum_{r=1}^k w_r} \quad (4.7)$$

Para cada una de las dimensiones (esto es, cada variable del problema), cada hormiga muestrea la función de distribución previamente escogida, por lo que es necesario definir sus parámetros representativos. En el caso más habitual de una función gaussiana, estos parámetros serán la media y la desviación típica, siendo esta última formulada como:

$$\sigma^i = \xi \sum_{e=1}^k \frac{|s_e^i - s_l^i|}{k-1} \quad (4.8)$$

Donde el parámetro ξ tiene la misma función que la feromona del ACO clásico, es decir, cuanto mayor sea su valor, menor es la velocidad de convergencia del algoritmo, pero más amplio es el frente de búsqueda. Esta variante del ACO permite aplicar este algoritmo a problemas con variables continuas, pero sigue sin ser válido para problemas multi-objetivo.

Un enfoque para poder extender el ACO a varios objetivos de optimización es el propuesto por Garcia-Najera y Bullinaria (2007), denominado MOACOr (*Multi-Objective Ant Colony Optimisation for Continuous Domains*). Esta variante parte del ACO, pero modifica los criterios por los que se van incorporando soluciones al archivo de manera que, en vez de escoger las mejores en base a un único objetivo, se seleccionan aquellas que

cumplen criterios de no-dominación en base a dos o más objetivos. Además, se pueden incorporar también criterios de diversidad como el *Crowding Distance* para mejorar la distribución de las soluciones del archivo en todo el frente de Pareto. De este modo, en cada iteración se incorporan al archivo soluciones no-dominadas, y cuando el archivo se llena en exceso se eliminan las soluciones que ofrecen peor diversidad (Figura 4.8).

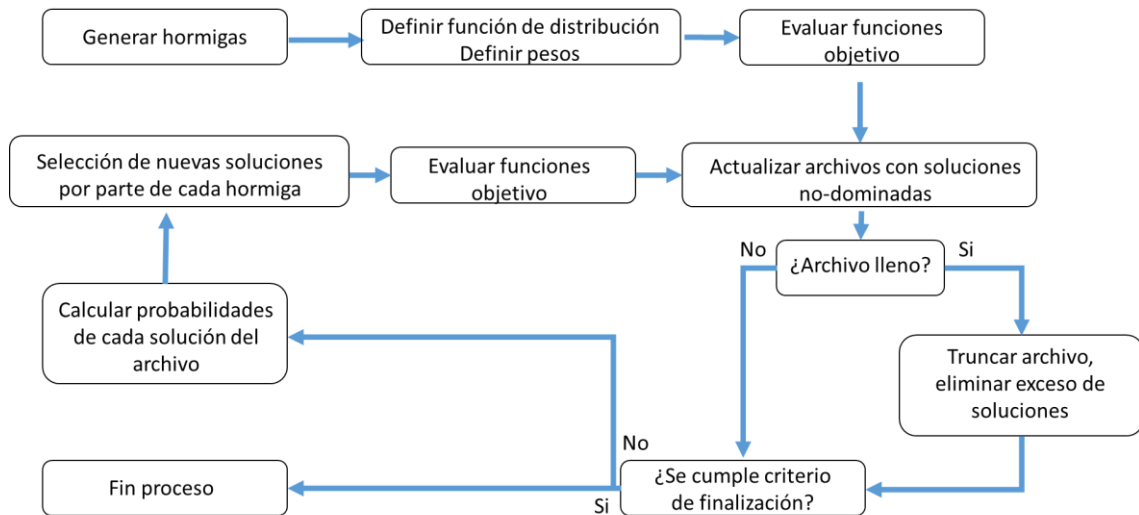


Figura 4.8: Esquema básico de funcionamiento de un algoritmo MOACOr. Fuente: Elaboración propia.

Como se ha expuesto más arriba, existen algunos ejemplos de aplicación del ACO clásico a la optimización de marchas, en problemas simplificados para poder ser representados como grafos con un único objetivo a optimizar. Por otra parte, Eaton et al. (2017) abordaron un problema de optimización de gráficos de circulación en un cruce ferroviario con varios objetivos a través de una variante MOACO que combina varias colonias de hormigas (una por cada objetivo) pero operando sobre variables discretas. En toda la literatura revisada no se ha encontrado ningún ejemplo de uso de la variante MOACOr para optimizar tiempo y energía simultáneamente en un problema planteado con variables continuas.

Búsqueda Tabú

El algoritmo de búsqueda Tabú, o *Tabu Search* (TS), es un meta-heurístico de tipo búsqueda local. Esta clase de algoritmos toman una potencial solución del problema y rastrean su inmediato vecindario buscando una que mejore, siquiera ligeramente, dicha so-

lución. Este proceso se repite sucesivamente hasta hallar una solución óptima en comparación con su entorno.

El principal inconveniente de la optimización a través de búsqueda local es que esta clase de algoritmos tienen una tendencia a quedar bloqueados en un mínimo local, de manera que se detienen sin haber alcanzado una solución verdaderamente óptima. La variante TS, propuesta inicialmente por Fred Glover en 1986, afronta este problema modificando la regla básica de la búsqueda local: en cada iteración, es posible aceptar una solución peor a la candidata actual si en su entorno no se encuentra ninguna que la mejore, lo cual permite escapar de un mínimo local (Figura 4.9).

Por otra parte, el algoritmo introduce prohibiciones (o tabúes) que impiden que la búsqueda regrese a zonas del espacio de soluciones ya exploradas, a través de una serie de reglas predefinidas. Así, por ejemplo, si una solución potencial ya ha sido considerada, se marca como tabú y el algoritmo no la vuelve a tomar en consideración, al menos hasta transcurrido un número determinado de iteraciones.

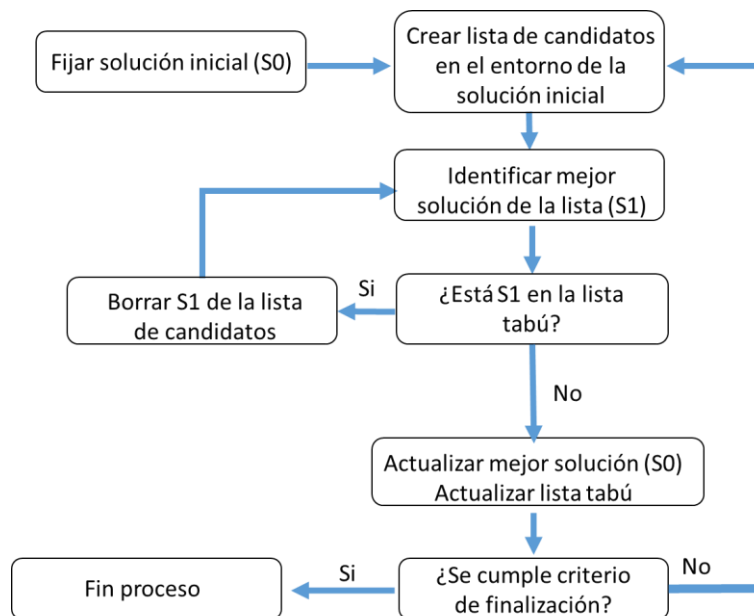


Figura 4.9: Esquema básico de funcionamiento de un algoritmo Tabu Search. Fuente: Elaboración propia.

El método TS es un método de optimización sólo aplicable a problemas con un único objetivo, ya que encuentra una única solución óptima. En el ámbito que nos ocupa, este algoritmo se ha usado de forma esporádica, si bien cabe destacar el ejemplo de Huang et

al. (2017), que plantearon la optimización de gráficos de circulación en una red de metro combinando objetivos de puntualidad y consumo energético a nivel de toda la red en un único índice, lo que les permitió aplicar TS para obtener soluciones óptimas para cada línea.

Algoritmo basado en aprendizaje y enseñanza

La optimización basada en aprendizaje y enseñanza, o *Teaching Learning Based Optimization* (TLBO), es un meta-heurístico basado en población propuesto por Rao et al. (2011), inspirado en la dinámica de aprendizaje que se genera entre un profesor y sus alumnos. El funcionamiento básico del TLBO se estructura en base a una población de soluciones iniciales que se asimila a los ‘estudiantes’, de modo que cada estudiante aprende unas determinadas materias (las variables a optimizar) y obtiene unas notas (los valores de la función objetivo). El mejor estudiante en cada iteración es el profesor.

Una vez definida la población inicial de estudiantes y profesor, el algoritmo TLBO consta de dos fases (Figura 4.10). En la primera, o fase del profesor, el nivel de todos los estudiantes (esto es, la media de sus respectivas funciones objetivos, o ‘notas’) se mejora a partir del nivel de profesor, con un componente aleatorio. Esta fase representa la influencia que un profesor experimentado tiene sobre los alumnos.

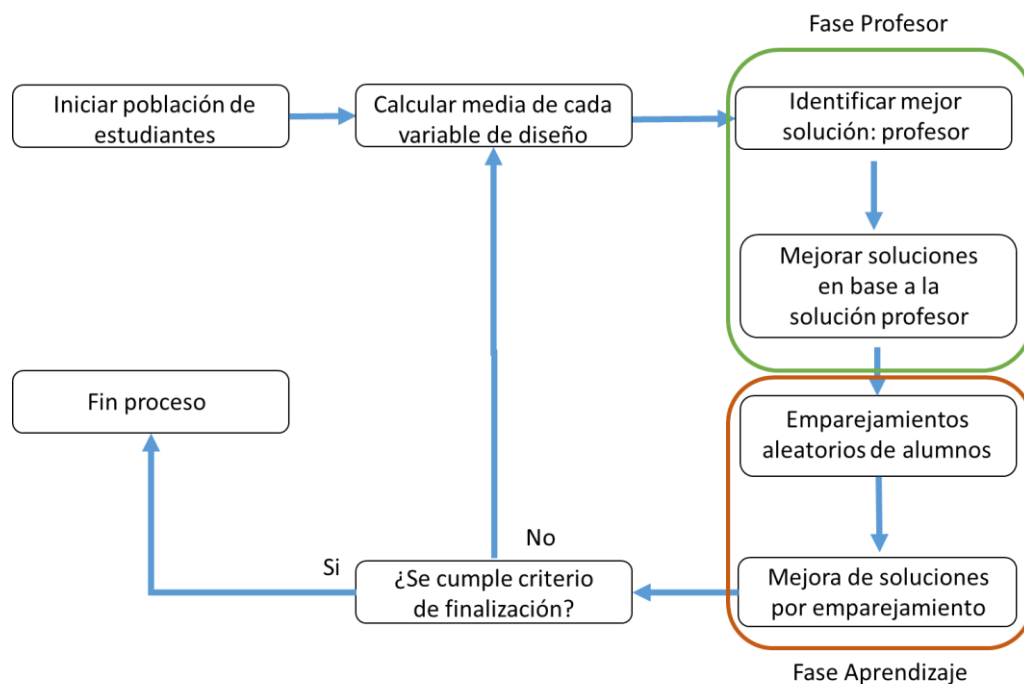


Figura 4.10: Esquema básico de funcionamiento de un algoritmo TLBO. Fuente: Elaboración propia.

Durante la segunda fase, o fase de aprendizaje, los estudiantes interactúan aleatoriamente entre ellos de tal modo que, en cada cruce entre dos alumnos, el alumno con mejor nivel contribuye a mejorar el nivel de su compañero más rezagado. Esta fase representa el aprendizaje derivado del intercambio de conocimiento entre los propios alumnos. Por otra parte, cabe destacar que, si bien la formulación inicial del algoritmo TLBO está diseñada para acometer problemas de optimización con un único objetivo, existen modificaciones del mismo para abordar problemas multi-objetivo.

Al igual que ocurre con otros algoritmos revisados, el TLBO apenas se ha aplicado a la optimización de marchas. En toda la literatura revisada se ha encontrado un único ejemplo (Huang et al., 2015), en el que se aborda la optimización del consumo energético en una ruta con un tiempo de viaje prefijado, a través de la modificación del valor de aceleración instantánea en cada segundo del viaje.

4.5. Discusión sobre el estado del arte de la optimización

Como ya se ha comentado, existen múltiples metodologías a la hora de abordar problemas de optimización relacionados con la dinámica ferroviaria y el consumo energético, en función de la definición del problema, los objetivos a optimizar, los condicionantes y restricciones considerados, etc. No obstante, en lo que a optimización de marchas se refiere, existen ciertas tendencias en la bibliografía revisada que vale la pena destacar.

Así, se puede decir que la mayoría de autores revisados apuestan por el uso de meta-heurísticos, y entre éstos destacan significativamente los algoritmos genéticos. La optimización analítica mediante la aplicación del MPA es otra línea de trabajo bastante importante, mientras que otras opciones resultan minoritarias. La Tabla 4.2 recoge todas las opciones encontradas en la bibliografía, con su correspondiente relación de referencias.

| Familia | Algoritmo | Referencias |
|------------------------|--|--|
| Optimización analítica | Maximum Principle Analysis (MPA) | (Khmelnitsky, 2000) (Franke et al., 2000) (Liu and Golovitcher, 2003) (Howlett et al., 2009) (Su et al., 2013) (Wang and Zhu, 2014) (Albrecht et al., 2016a) |
| Búsqueda sistemática | Direct Search (DS) | (Domínguez et al., 2008) |
| | Decision Theory (DT) | (Domínguez et al., 2008) (Domínguez et al., 2010) (Domínguez et al., 2011) (Domínguez et al., 2012) (Y. Huang et al., 2016) |
| Programación lineal | Dynamic Programming (DP) | (Lu et al., 2013) (Liu et al., 2018) |
| | Mixed Integer Linear Programming (MILP) | (Kim et al., 2010) (Lu et al., 2016) |
| | Fuzzy Linear Programming (FLP) | (Cucala et al., 2012) |
| Meta-heurísticos | Algoritmo genético (NSGA-II y similares) | (Salim and Cai, 1995) (Chang and Sim, 1997) (Wong and Ho, 2004) (Bocharnikov et al., 2007) (Açikbas and Soylemez, 2008) (Kang, 2011) (Cucala et al., 2012) (Sicre et al., 2012) (Yang et al., 2012) (Lu et al., 2013) (Dündar and Şahin, 2013) (Carvajal-Carreño et al., 2014) (Domínguez et al., 2014) (Sicre et al., 2014) (Zhao et al., 2015) (Watanabe and Koseki, 2015) (J. Huang et al., 2016) (Brenna et al., 2016) (He and Xiong, 2018) (Ahmadi et al., 2018) |
| | SPEA-II | (He and Xiong, 2018) |
| | Enjambre de partículas (PSO) | (Domínguez et al., 2014) (Yang et al., 2015) (Fernández et al., 2015) |
| | Colonia de Hormigas (AC) | (Lu et al., 2013) (Zhao et al., 2015) (Eaton et al., 2017) |
| | Tabu Search (TS) | (Liu et al., 2015) (Huang et al., 2017) |
| | TLBO | (Huang et al., 2015) |

Tabla 4.2: Enfoques de optimización y relación de bibliografía consultada. Fuente: Elaboración propia.

En total se han revisado más de 40 trabajos relacionados con la optimización en el sector ferroviario, la gran mayoría de los cuales se centran en la optimización multi-objetivo de marchas. La predilección por el uso de meta-heurísticos es clara, con más del 60% de los trabajos revisados apostando por esta clase de herramientas (Figura 4.11). La segunda opción más común se relaciona con la búsqueda sistemática de soluciones a través de DS y DT (un 13%) si bien ésta queda restringida a casos donde el espacio de soluciones es pequeño, y se limita mayoritariamente a una línea de trabajo desarrollada por un único equipo de autores. Un porcentaje similar de estudios (otro 13%) optan por la optimización sistemática a través de MPA, aunque en este caso encontramos diversos autores cubriendo un período de dieciséis años.




Figura 4.11: Frecuencia de uso de cada enfoque de optimización. Fuente: Elaboración propia.

De este análisis de la bibliografía queda clara la apuesta mayoritaria por el uso de meta-heurísticos, debido a su gran flexibilidad a la hora de abordar problemas multi-objetivo con un espacio de soluciones muy amplio, un planteamiento muy común en los diferentes estudios de optimización de marchas revisados. Por otra parte, es evidente la prevalencia

de los algoritmos genéticos, que representan un 40% del total de los estudios revisados, frente a otras opciones como ACO (un 7%), PSO (otro 7%) o TS (un 4%).

Una de las razones más probables de esta preponderancia es que los algoritmos genéticos se cuentan entre los primeros algoritmos evolutivos desarrollados (Domínguez et al., 2014), y se han venido aplicando con buenos resultados en múltiples campos desde hace más de veinte años, incluyendo en el ámbito que nos ocupa (Chang y Sim, 1997; Salim y Cai, 1995). De hecho, los algoritmos genéticos están tan asentados como opción preferente a la hora de afrontar una optimización de marchas mediante meta-heurísticos que varios autores los han empleado como estándar de comparación frente a otros algoritmos más novedosos (Domínguez et al., 2014; He y Xiong, 2018; Lu et al., 2013).

En este punto, cabe ahondar en las diferencias reales de rendimiento entre los diferentes algoritmos meta-heurísticos, particularmente en cuanto a requisitos de computación y en cuanto a su grado de convergencia y diversidad. La gran preponderancia del algoritmo genético (fundamentalmente su variante NSGA-II) impide hacer una comparación extensa, pero algunos autores han tratado de estudiar estos aspectos comparando el rendimiento de NSGA-II con alguna otra opción. La comparación se realiza normalmente a través de una serie de métricas que tratan de evaluar de forma objetiva tanto la proximidad de la solución obtenida al frente de Pareto como su distribución a lo largo del mismo (para una discusión más detallada de estas métricas, véase Capítulo IV, Sección 8).

Así, Lu et al. (2013) defiende que su algoritmo ACO converge más fácilmente que NSGA-II, si bien recomienda el uso combinado de varios algoritmos para cubrir el espacio de soluciones al completo. En cambio, Zhao et al. (2015) no encuentran diferencias claras entre ACO y NSGA-II. Por otra parte, Domínguez et al. (2014) comparan NSGA-II con MOPSO y muestran que este último converge más rápido y ofrece una solución con mayor diversidad. Fernández (2018) realiza una comparativa similar, y también obtiene un mejor resultado del algoritmo MOPSO en términos de diversidad. Por último, al comparar el rendimiento de NSGA-II frente a SPEA-II, He y Xiong (2018) muestran que el algoritmo genético ofrece menor tiempo de cálculo y mejores resultados.

En cualquier caso, y a pesar de los ejemplos mencionados, cabe decir que los trabajos que comparan el rendimiento de diferentes meta-heurísticos son escasos, y normalmente limitados al análisis de dos algoritmos (uno de los cuales es invariablemente NSGA-II) aplicados a un único caso de estudio real (Domínguez et al., 2014; Fernández, 2018) o a un ejemplo teórico (He y Xiong, 2018). Si bien en otros campos más relacionados con el

propio desarrollo y estudio de algoritmos sí que existen comparativas más detalladas y extensas entre algoritmos (Antoniucci y Bentley, 2016), éstas se aplican sobre problemas-tipo que poco tienen que ver con la optimización de marchas en el ferrocarril. En base a la bibliografía revisada, no existe una comparativa sistemática de varios algoritmos meta-heurísticos en el ámbito de estudio que nos ocupa.

4.6. Conclusiones

Teniendo en cuenta toda la bibliografía revisada en lo referente a la optimización en el marco de la ingeniería ferroviaria (y especialmente la optimización multi-objetivo de marchas), pueden establecerse las siguientes conclusiones sobre el estado del arte:

- El planteamiento más habitual consiste en la optimización de perfiles de velocidad que minimicen el consumo energético sin comprometer tiempos de viaje. Este análisis puede hacerse sobre un único vehículo o considerando la interacción entre varios en una línea, o incluso en toda la red. Por otra parte, también es posible incorporar al estudio objetivos adicionales de confort o calidad de servicio, ya sea directa o indirectamente (como un criterio de selección a posteriori).
- En aquellos problemas de optimización en los que existen diversas restricciones que limitan notablemente el espacio de soluciones, es posible analizar de forma exhaustiva dicho espacio, hallar directamente el frente de Pareto y escoger las soluciones óptimas en cada caso. Este planteamiento deja de ser aplicable conforme aumenta el número de posibles soluciones.
- Algunos autores han apostado por una optimización matemática exacta, basada en la aplicación del Principio de Pontryagin. Este enfoque plantea un problema relativamente simplificado (porque de lo contrario no sería resoluble) pero obtiene soluciones exactas a dicho problema.
- En todo caso, la opción con diferencia más empleada en la literatura es el uso de algoritmos meta-heurísticos, que suponen un planteamiento opuesto a la optimización matemática: obtener soluciones aproximadas a un problema más próximo a la realidad.
- De entre todos los meta-heurísticos empleados para la optimización de marchas, los algoritmos genéticos (y muy especialmente la variante NSGA-II) son los más utilizados con gran diferencia debido a su fiabilidad y buen funcionamiento. El uso de otros algoritmos es bastante minoritario, si bien algunos autores defienden un mejor comportamiento de algoritmos tales como colonia de hormigas o enjambre de partículas.

- En cualquier caso, apenas hay ejemplos en la literatura de comparaciones entre algoritmos, y las encontradas se limitan por lo general a dos opciones (una de las cuales es invariablemente NSGA-II) cuyo rendimiento se evalúa en base a un único caso de estudio o a un ejemplo teórico.

En base a estas conclusiones, queda de manifiesto el interés en llevar a cabo una comparativa exhaustiva de varios algoritmos meta-heurísticos en cuanto a su capacidad para resolver problemas de optimización de marchas. Esta clase de comparativa contribuiría a evaluar las posibles ventajas de recurrir a alguno de los algoritmos más novedosos o menos empleados frente al más popular NSGA-II.

Capítulo III

5. Descripción de la red de metro de Valencia

5.1. Introducción

Las aportaciones de la presente tesis se aplican sobre la red de metro de Valencia (España), operada por FGV (*Ferrocarrils de la Generalitat Valenciana*), por lo que en este apartado se pretende dar una visión detallada de la red y de sus principales características, incluyendo una descripción de las líneas y del material rodante. Por otra parte, es sobre esta red que se han recopilado los datos de consumo empleados como base para el desarrollo, calibración y validación del modelo de simulación y la red neuronal, por lo que en este apartado se expone el proceso de toma de datos y las principales tendencias de consumo energético identificadas a partir de los mismos.

5.2. Red de metro de Valencia

5.2.1. Visión general

FGV es una empresa pública dependiente de la Generalitat Valenciana, constituida en 1986. FGV es responsable no sólo de la red de metro de Valencia (bajo la marca *Metrovalencia*) sino también de la red de Alicante (bajo la marca *TRAM Metropolitano de Alicante*). En conjunto, FGV gestiona un total de 267,020 km de vías férreas (sumando metro, tranvía y tren ligero) y 206 estaciones, con una demanda de viajeros en 2017 de más de 74 millones (FGV, 2017). Centrándonos en la red de metro de Valencia, ésta cuenta con 9 líneas y un total de 156,388 kilómetros, 137 estaciones y apeaderos, 106 vehículos

(sumando metros y tranvías) y una demanda para el año 2017 cercana a los 64 millones (FGV, 2017). A nivel de consumo energético, la red de metro de Valencia consumió 77,668 GWh durante todo el año 2017, con unas emisiones estimadas de 22.698,70 toneladas de CO₂ equivalentes (FGV, 2017).

5.2.2. Descripción de las líneas

En la Figura 5.1 se muestra el plano de la red de metro de Valencia. La red comprende 9 líneas y 156,388 kilómetros de vías férreas, de los cuales 27,303 km discurren en túnel y los restantes 129,084 en superficie. La red cuenta con 138 estaciones y apeaderos, de las cuales 35 se ubican bajo tierra y 103 en superficie (FGV, 2017).

Tres de las nueve líneas existentes son de tranvía (líneas 4, 6 y 8), alimentadas en corriente continua a 750 V. Las restantes son líneas de metro (con alimentación a 1.500 V) que discurren por túnel en el centro de la ciudad, y en superficie en los tramos que conectan con el área metropolitana, hasta Bétera, Llíria y Rafelbunyol por el norte (líneas 1, 2 y 3 respectivamente), Riba-roja de Túria por el oeste (línea 9) y Villanueva de Castellón y Torrent por el sur (líneas 1 y 2-7 respectivamente). Por el oeste, las líneas 3 y 5 llegan también al aeropuerto de Manises, en un tramo completamente subterráneo. Por el este, las líneas 5 y 7 terminan en la estación subterránea de Marítim-Serrería, donde conectan con las líneas 6 y 8 de tranvía. La Tabla 5.1 recoge los principales datos de cada una de las líneas.

| Línea | Longitud (km) | Estaciones/paradas |
|---------|---------------|--------------------|
| Línea 1 | 72,145 | 40 |
| Línea 2 | 39,445 | 33 |
| Línea 3 | 24,691 | 26 |
| Línea 4 | 16,999 | 33 |
| Línea 5 | 13,293 | 18 |
| Línea 6 | 3,571 | 21 |
| Línea 7 | 15,497 | 16 |
| Línea 8 | 1,230 | 4 |
| Línea 9 | 24,859 | 23 |

Tabla 5.1: Datos de las líneas de metro de Valencia. Fuente: FGV.



Figura 5.1: Plano de la red de metro de Valencia. Fuente: FGV.

LÍNEA 1

La línea 1 (Figura 5.2) discurre de norte a sur, desde el municipio de Bétera hasta Villanueva de Castellón, atravesando la ciudad de Valencia. Es, con diferencia, la línea más extensa de la red, con más de 72 kilómetros de longitud y 40 estaciones (de las cuales 11 son apeaderos con parada facultativa).



Figura 5.2: Plano de la línea 1. Fuente: Plano-Metro.com.

La línea 1 cuenta con un tramo en común con la línea 2 entre las estaciones de Empalme y Torrent y con la línea 7 entre las estaciones de Jesús y Torrent. Además, tiene conexión con las líneas 3, 5 y 9 en la estación de Àngel Guimerà y con la línea 4 de tranvía en Empalme. Por otra parte, la línea 1 cuenta con un tramo subterráneo entre las estaciones de Empalme y Sant Isidre. Este tramo, y su prolongación entre Sant Isidre y València Sud, se opera mediante ATO. En el resto de la línea (es decir, entre València Sud y Villanueva de Castellón, así como entre Empalme y Bétera) la línea se opera mediante conducción manual asistida con sistema ATP (*Automatic Train Protection*) o FAP (Frenado Automático Puntual).

LÍNEA 2

La línea 2 (Figura 5.3) discurre también de norte a sur, desde Llíria hasta Torrent, atravesando Valencia por el tramo subterráneo común con la línea 1 entre las estaciones de Empalme y Torrent, para luego continuar hasta la parada de Torrent Avinguda. Es la segunda línea con mayor extensión, con casi 40 kilómetros de longitud y 33 estaciones (de las cuales 8 son apeaderos con parada facultativa).




Figura 5.3: Plano de la línea 2. Fuente: Plano-Metro.com.

Las conexiones con el resto de la red son las mismas que las referidas para la línea 1, ya que se localizan en el tramo común subterráneo. Además, al igual que ocurría con la línea 1, la línea 2 se opera con ATO entre Empalme y València Sud, y con conducción manual más ATP/FAP en el resto de la línea (entre València Sud y Torrent Avinguda y entre Empalme y Llíria).

LÍNEA 3

La línea 3 (Figura 5.4) discurre de este a oeste, desde Rafelbunyol hasta el aeropuerto de Manises. Tiene una longitud de 24,691 kilómetros y 26 estaciones.



Figura 5.4: Plano de la línea 3. Fuente: Plano-Metro.com.

Esta línea tiene buena parte de su trazado en común con la línea 9, de la que sólo difiere en su tramo final entre las estaciones de Rosas y Aeroport. También comparte trazado con la línea 5, concretamente entre las estaciones de Alameda y Aeroport. Por otra parte, la línea 3 conecta con las líneas 4 y 6 de tranvía en la estación de Benimaclet, con la línea 7 en la estación de Alameda y con las líneas 1 y 2 en la estación de Àngel Guimerà.

La línea 3 es subterránea durante buena parte de su recorrido, desde Aeroport hasta Alboraya-Peris Aragó. En todo este tramo se opera mediante ATO. Desde su salida a la superficie en Alboraya-Peris Aragó hasta su final en Rafelbunyol se opera manualmente con ATP/FAP.

LÍNEA 4

La línea 4 (Figura 5.5) es una de las tres líneas de tranvía existentes en la red de metro de Valencia. Discurre por superficie desde Mas del Rosari (con salidas también desde Terramelar y Fira València), a lo largo del norte de la ciudad hasta alcanzar la costa, donde traza un bucle con extremo en Dr. Lluch. La línea tiene una longitud de 16,999 kilómetros y 33 paradas.

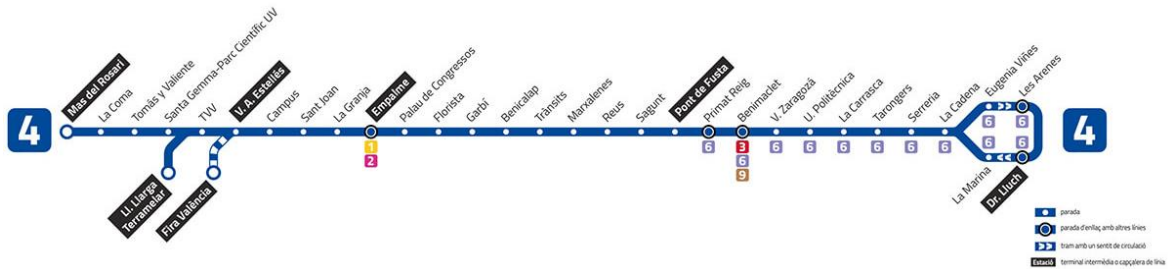


Figura 5.5: Plano de la línea 4. Fuente: Plano-Metro.com.

Esta línea conecta con las líneas 1 y 2 de metro en Empalme, y con las líneas 3 y 9 en Benimaclet. Además, comparte una parte de su trazado con la línea 6, entre Primat Reig y el bucle entre La Cadena y Dr. Lluch. La línea opera en su totalidad con conducción manual, con sistema de hombre muerto como única protección.

LÍNEA 5

La línea 5 (Figura 5.6) discurre de este a oeste, desde la estación de Marítim-Serrería hasta el aeropuerto de Manises. Es una línea completamente subterránea, con una longitud de 13,293 kilómetros y 18 estaciones.




Figura 5.6: Plano de la línea 5. Fuente: Plano-Metro.com.

La línea conecta con las líneas 8 y 4 de tranvía en Marítim-Serrería y con las líneas 1 y 2 en Àngel Guimerà. Por otra parte, comparte parte de su trazado con la línea 7 (entre Marítim-Serrería y Colón), con la línea 3 (entre Colón y Aeropuerto) y con la línea 9 (entre Co-

lón y Rosas). Al ser un trazado subterráneo en su totalidad, la línea 5 se opera enteramente mediante ATO.

LÍNEA 6

La línea 6 (Figura 5.7) es otra de las tres líneas tranviarias de la red. Discurre desde Tosca del Rei hasta la costa, donde traza el mismo bucle que la línea 4, pero cuenta además con un ramal que termina en Marítim-Serrería, donde conecta con las líneas 5 y 7 del metro. Cuenta con una longitud de 3,571 kilómetros y 21 paradas.




Figura 5.7: Plano de la línea 6. Fuente: Plano-Metro.com.

Esta línea comparte parte de su trazado con la línea 4, como ya se ha explicado. También tiene un tramo común entre Grau-Canyamelar y Marítim-Serrería con la línea 8, y conecta con las líneas 3 y 9 de metro en Benimaclet. Se opera de forma manual, con el mismo nivel de protección especificado para la línea 4.

LÍNEA 7

La línea 7 (Figura 5.8) parte de la estación de Marítim-Serrería, próxima al puerto de Valencia, y discurre hasta Torrent (estación de Torrent Avinguda) en un trazado de 15,497 kilómetros con 16 paradas.



Figura 5.8: Plano de la línea 7. Fuente: Plano-Metro.com.

La línea 7 comparte su trazado entre Marítim-Serrería y Colón con la línea 5, y entre Jesús y Torrent con las líneas 1 y 2 (hasta Torrent Avinguda con la línea 2). Sólo el corto

tramo de conexión entre Colón y Jesús (con la parada intermedia de Bailén) es exclusivo de esta línea. Por otra parte, la línea 7 discurre por túnel desde Marítim-Serrería hasta Sant Isidre, y opera en ATO en todo este tramo y hasta la estación de València Sud. Desde aquí hasta Torrent Avinguda (final de línea), se opera manualmente con ATP.

LÍNEA 8

Esta línea (Figura 5.9) es la más corta de toda la red, con una longitud de 1,230 kilómetros y sólo 4 paradas. Se trata de un tramo de conexión entre Marítim-Serrería y la Marina Real Juan Carlos I.




Figura 5.9: Plano de la línea 8. Fuente: Plano-Metro.com.

La mayor parte de la línea 8 (entre Marítim-Serrería y Grau-Canyamelar) es coincidente con la línea 6, siendo el tramo entre Grau-Canyamelar y la Marina Real el único exclusivo de esta línea. Como las demás líneas de tranvía, se opera bajo conducción manual con hombre muerto.

LÍNEA 9

La línea 9 (Figura 5.10) discurre desde Alboraya-Peris Aragó hasta Riba-roja de Túria, con una longitud de 24,859 kilómetros y 23 parada. No obstante, la mayor parte de su trazado es coincidente con el de la línea 3. De hecho, esta línea se proyectó como una prolongación de la línea 3 desde la estación de Rosas, siguiendo el antiguo trazado de vía de ancho ibérico entre Valencia y Riba-roja de Túria, suprimido en 1985.



Figura 5.10: Plano de la línea 9. Fuente: Plano-Metro.com.

Por esta razón, la línea 9 sólo tiene como trazado exclusivo el que se inicia en la estación de Rosas y discurre por La Cova, La Presa y Masía de Traver hasta Riba-roja de Túria. Las conexiones con otras líneas son las mismas referidas para la línea 3. En cuanto a su operación, la línea 9 funciona con ATO en todo el tramo subterráneo, desde Alboraya-Peris Aragó hasta Rosas. Desde Rosas la línea circula en superficie y opera manualmente con ATP.

5.2.3. Descripción del material rodante

En este apartado se describe el material rodante que opera en la red de Metro de Valencia. Cabe distinguir entre los vehículos de metro que operan en las líneas 1, 2, 3, 5, 7 y 9 y los tranvías que operan en las líneas 4, 6 y 8.

Las líneas de metro se operan en su totalidad con unidades de la serie 4300, fabricadas por Vossloh y puestas en servicio a partir del año 2007 (Figura 5.11). En los últimos años han ido sustituyendo gradualmente a las antiguas unidades de la serie 3900 hasta conformar la totalidad del material rodante de metro.



Figura 5.11: Metro serie 4300. Fuente: Wikipedia.

Existen dos composiciones, una de cuatro coches (Motor-Remolque-Remolque-Motor) y otra de cinco coches (M-R-M-R-M). Actualmente operan 42 unidades de cuatro coches y 20 de cinco coches. La Tabla 5.2 muestra las principales características técnicas de estas unidades.

| Variable | Valor |
|---|----------------------------------|
| Tensión (V) | 1.500 |
| Velocidad máxima (km/h) | 80 |
| Aceleración inicial (m/s ²) | 1,1 |
| Deceleración (m/s ²) | 1,2 |
| Máxima deceleración con freno de urgencia (m/s ²) | 1,2 |
| Máxima deceleración con freno de emergencia (m/s ²) | 2 |
| Potencia (kW) | 1.480 |
| Pendiente máxima (‰) | 30 |
| Peso en vacío (t) | 122,85 |
| Longitud (m) | (4 coches) 60,49 / (5 coches) 75 |
| Capacidad (pasajeros) | (4 coches) 588 / (5 coches) 750 |

Tabla 5.2: Características de la serie 4300. Fuente: FGV.

Las unidades de la serie 4300 cuentan con freno electromagnético, freno de urgencia neumático y freno de servicio eléctrico regenerativo. No obstante, no disponen de sistema de almacenamiento de energía a bordo, por lo que la energía regenerada sólo puede ser aprovechada por otro tren cercano que esté traccionando en ese mismo momento. Tampoco es posible devolver la energía a la red de suministro, ya que el metro de Valencia opera con corriente continua (1.500 V de tensión nominal) y no dispone de subestaciones reversibles.

Las líneas de tranvía, que funcionan en corriente continua a 750 V de tensión nominal, se operan con dos clases de vehículo (Figura 5.12): La serie 3800 de CAF-Siemens-Alsthom (incorporadas al servicio en 1994) y la serie 4200 de Bombardier (incorporadas al servicio en 2006).



Figura 5.12: Tranvías series 4200 (izquierda) y 3800 (derecha). Fuente: FGV.

Las unidades de la serie 3800, si bien más antiguas, han pasado por un proceso de renovación desde el año 2014. Actualmente operan 25 unidades, cuyas características se muestran en la Tabla 5.3. Su composición es de tres coches (M-R-M).

| Variable | Valor |
|-------------------------|-------|
| Tensión (V) | 750 |
| Velocidad máxima (km/h) | 65 |
| Potencia (kW) | 432 |
| Peso en vacío (t) | 29,7 |
| Longitud (m) | 23,78 |
| Capacidad (pasajeros) | 201 |

Tabla 5.3: Características de la serie 3800. Fuente: FGV.

Por su parte, en la actualidad hay 19 unidades de la serie 4200 en servicio. Pertenecen a la gama *Flexity Outlook* de Bombardier, y cuentan con una configuración de 5 coches (M-R-M, los coches 2 y 4 no tienen bogies). La Tabla 5.4 recoge sus principales características.

| Variable | Valor |
|-------------------------|--------|
| Tensión (V) | 750 |
| Velocidad máxima (km/h) | 70 |
| Potencia (kW) | 420 |
| Peso en vacío (t) | 41 |
| Longitud (m) | 32,366 |
| Capacidad (pasajeros) | 277 |

Tabla 5.4: Características de la serie 4200. Fuente: FGV.

5.3. Campaña de toma de datos

El Grupo de Investigación en Ingeniería Ferroviaria (GIIF) de la UPV llevó a cabo, entre julio y octubre del año 2014, una extensa campaña de medición en la red de metro de Valencia, en colaboración con FGV, con el objetivo de medir los consumos energéticos del material rodante y analizar las principales tendencias de consumo de la red. Esta campaña se enmarcaba dentro del Proyecto de Investigación Fundamental no orientada titulado “Estrategias para el diseño y la explotación energéticamente eficiente de infraestructuras ferroviarias y tranviarias”, financiado por el Ministerio de Economía y Competitividad (TRA2011-26602).

El referido proyecto tenía como objetivo recabar datos sobre el consumo energético en diferentes tipos de explotación ferroviaria, incluyendo cercanías y media distancia, mercancías y ferrocarril de ámbito urbano (metro y tranvía), para posteriormente analizar dichos datos, evaluar las tendencias de consumo de cada tipo de explotación y desarrollar estrategias tanto de diseño como de operación que contribuyeran a reducir el consumo energético. La campaña de toma de datos en la red de metro de Valencia formaba parte de las tareas de este proyecto.

A continuación se expone el proceso seguido para recopilar, procesar y analizar estos datos de consumo, que han servido de base para desarrollar, entrenar y validar la red neuronal y el modelo de simulación de marchas. Es importante destacar que todas las actividades recogidas en este apartado no forman parte de la tesis, sino que la preceden

como parte del proyecto antes mencionado, pero se consignan aquí de todos modos para ofrecer un contexto sobre los datos empleados en los siguientes capítulos.

5.3.1. Equipos y montaje

La campaña de toma de datos en la red de metro de Valencia tenía los siguientes objetivos específicos:

- Conocer el consumo bruto, energía devuelta y consumo neto por servicio y por tramos de subestaciones.
- Conocer el consumo de equipos auxiliares por servicio.
- Conocer la energía disipada en las resistencias de frenado, por servicio y por tramos de subestaciones.
- Estimar la diferencia de consumos y tiempos de viaje en los tramos de la red por los que se circula en ATO, respecto a aquéllos con conducción manual bajo ATP.

Para cumplir estos objetivos, se decidió registrar las siguientes variables:

- Consumo en el pantógrafo (disyuntor).
- Consumo de los equipos auxiliares.
- Energía disipada en el freno reostático.
- Velocidad del tren.

Para ello se instrumentó una unidad serie 4300 de cuatro coches, equipándola con tres sensores de tensión e intensidad de corriente continua (Figura 5.13), modelo MSAV-DC (Mors Smitt), que cumplieran con la norma EN 50463-1:2013: Aplicaciones ferroviarias. Medición de la energía a bordo de los trenes.



Figura 5.13: Equipo sensor MSAV-DC. Fuente: Mors Smitt.

De estos tres sensores, uno se colocó en el disyuntor, justo bajo el pantógrafo del coche motor 2, para registrar la energía bruta que se suministra al vehículo desde la catenaria (signo positivo) o que el vehículo devuelve a la misma (signo negativo). Cabe destacar que, durante toda la campaña de medición, se garantizó que el vehículo instrumentado sólo operase con el pantógrafo instrumentado (esto es, el del coche motor 2) para asegurar que se registraba correctamente el flujo de energía catenaria-vehículo.

Otro sensor se instaló en el convertidor de equipos auxiliares del coche motor 2, que alimenta todos los sistemas auxiliares de los coches motor 2 y remolque 2. De acuerdo a la información suministrada por FGV y por el fabricante, se asumió que el consumo total de auxiliares sería 1,5 veces el valor registrado, para contabilizar el de los equipos auxiliares del coche motor 1 y coche remolque 1.

Por último, se colocó el tercer sensor a la entrada del freno reostático del coche motor 2, para contabilizar la energía disipada durante las fases de frenado, que no se aprovecha por los auxiliares o se devuelve a la catenaria a través del pantógrafo. La Figura 5.14 muestra de forma esquemática la colocación de los tres sensores y los flujos de energía esperados, tanto durante la fase de tracción como durante el frenado.

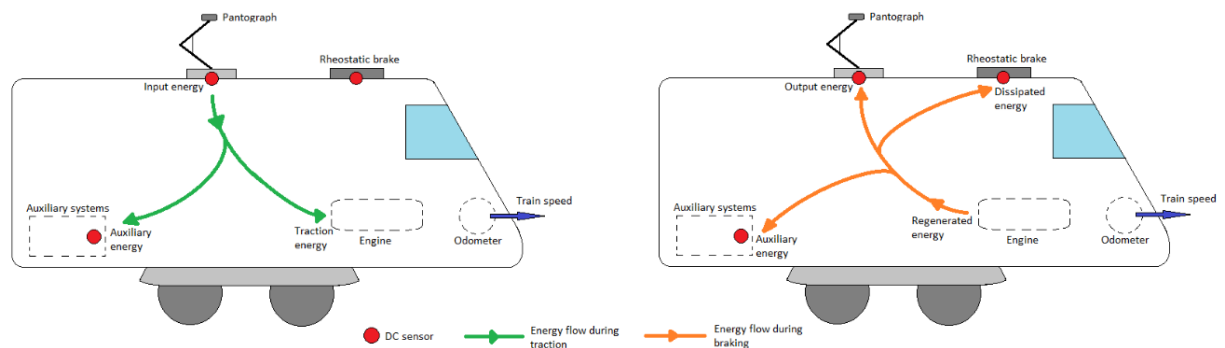


Figura 5.14: Esquema de medición en el vehículo instrumentado. Fuente: Elaboración propia.

Por otra parte, para registrar la velocidad, se aprovechó la sonda que el propio vehículo llevaba instalada en uno de los ejes del coche remolque 2 (sonda Knorr modelo BB04576881100). La señal tanto de los tres sensores de corriente continua como de la sonda de velocidad se recogió en un equipo de adquisición de datos y se almacenó en un ordenador embarcado en la cabina del coche motor 2.

5.3.2. Toma y procesado de datos

El tren instrumentado operó con normalidad a lo largo de las líneas 1, 2, 3, 5 y 7 durante varios días entre julio y octubre de 2014 (cabe recordar que la línea 9 todavía no estaba en servicio en ese momento). En total se monitorizaron 229 servicios completos, lo que supone más de 230 horas de registros. De estos 229 servicios, 115 se tomaron con gráfico de días intermedios (sábados y laborables de verano) y 114 con gráfico de días laborables. Durante cada servicio se registró:

- Intensidad de corriente, tensión y potencia en cada uno de los tres sensores MSAV-DC a una frecuencia de 1 Hz.
- Velocidad del vehículo a una frecuencia de 100 Hz.

La relación de servicios registrados para cada una de las líneas se recoge en la Tabla 5.5.

| Línea | Número de servicios registrados |
|---------|---------------------------------|
| Línea 1 | 67 |
| Línea 2 | 55 |
| Línea 3 | 26 |
| Línea 5 | 41 |
| Línea 7 | 40 |

Tabla 5.5: Relación de servicios registrados por cada línea. Fuente: Elaboración propia.

Como se puede ver en la Tabla 5.5, se trata de una muestra bastante representativa de todas las líneas de metro. Los 229 registros se procesaron posteriormente en MATLAB 8.5.0 (The MathWorks, Inc.) para obtener, para cada servicio, los siguientes datos:

- Velocidad (km/h).
- Aceleración (m/s^2).
- Tiempo de viaje (s).
- Intensidad (A), tensión (V) y potencia (kW) en el disyuntor (de signo positivo cuando el flujo va de la catenaria al vehículo, y negativo en sentido contrario).
- Intensidad (A), tensión (V) y potencia (kW) en los equipos auxiliares.
- Intensidad (A), tensión (V) y potencia (kW) en el freno reostático.
- Potencia (kW) de tracción.

- Energía total consumida en el viaje (kWh).
- Energía total consumida en auxiliares (kWh).
- Energía total disipada en el freno reostático (kWh).

También se calculó la energía disipada (kWh) en cada sección de la línea alimentada por una subestación eléctrica diferente. En cuanto a la potencia y energía de tracción, se calcularon a partir de la diferencia entre la energía total suministrada al vehículo y la fracción de energía consumida por auxiliares y disipada en el freno reostático. Al hacer este cálculo no se tuvieron en cuenta las pérdidas por resistencia óhmica ya que son, por lo general, de poca magnitud y pueden despreciarse sin incurrir en un error elevado.

Cabe también mencionar que, además de los datos de consumo y velocidad medidos, se disponía de información detallada sobre el trazado geométrico (pendientes y radios de curvatura, además de limitaciones de velocidad existentes) de las líneas 1, 2, 3, 5, y 7 (salvo el tramo de conexión entre las estaciones de Colón y Jesús).

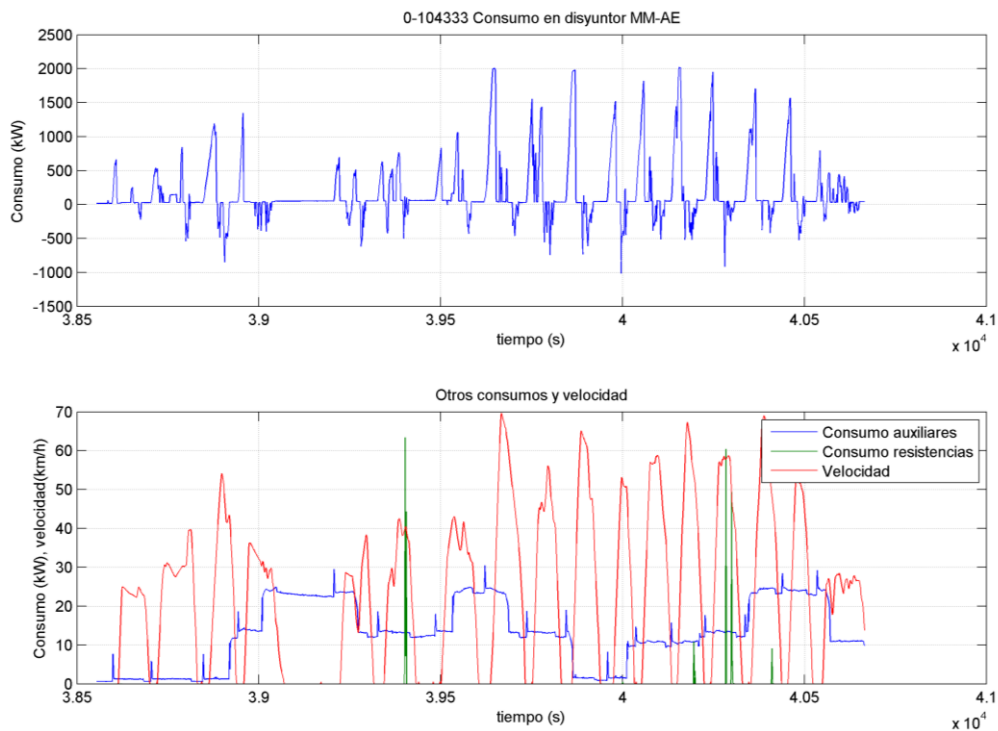


Figura 5.15: Ejemplo de registro obtenido en un servicio Marítim Serrería-Aeroport (línea 5). Fuente: Elaboración propia.

La Figura 5.15 muestra un ejemplo de los registros obtenidos una vez procesados los datos. Se puede apreciar el perfil de velocidades completo, con las diferentes paradas

intermedias, el flujo de energía en el disyuntor (gráfica superior), el consumo de auxiliares y los picos de energía consumida en el freno reostático. En el siguiente apartado se exponen algunas de las conclusiones obtenidas del análisis de estos datos.

5.4. Análisis de datos. Tendencias de consumo

A partir del análisis de los datos obtenidos durante la campaña de medición, fue posible extraer algunas conclusiones sobre las principales tendencias de consumo energético en la red. En este apartado se pretende exponer algunas de estas conclusiones para establecer un cierto contexto sobre la red de metro de Valencia, ya que éste es el escenario sobre el que se han desarrollado las principales actividades de la presente tesis. No obstante, como el propio análisis de los datos pertenece a un proyecto de investigación que precede a la tesis, se evitará profundizar excesivamente en el mismo.

Para comenzar, la Tabla 5.6 muestra los tiempos y consumos promedio registrados para cada una de las líneas, donde se entiende por consumo bruto en disyuntor el total de energía transmitida desde la catenaria al vehículo en cada servicio, y por consumo neto la diferencia entre el consumo bruto y el total de energía devuelta a la catenaria para ser consumida por otros vehículos en las proximidades. Nótese que, para cada línea, se distingue entre los diferentes trayectos posibles (ya que algunos servicios no recorren la totalidad de la línea) y entre ambos sentidos de circulación.

| Línea | Trayecto | Tiempo de viaje (min) | Consumo bruto (kWh) | Consumo neto (kWh) | Ratio neto/bruto | Consumo neto/km |
|---------|----------------------------------|-----------------------|---------------------|--------------------|------------------|-----------------|
| Línea 1 | Villanueva de Castellón-Bétera | 103,40 | 532,49 | 453,49 | 85,16% | 6,29 |
| | Bétera-Villanueva de Castellón | 100,89 | 464,98 | 373,50 | 80,31% | 5,18 |
| | Villanueva de Castellón-Seminari | 96,78 | 445,98 | 365,94 | 82,05% | 5,70 |
| | Seminari-Villanueva de Castellón | 94,10 | 444,22 | 366,93 | 82,56% | 5,72 |
| | Torrent-Bétera | 49,01 | 234,09 | 168,65 | 72,05% | 5,94 |
| | Bétera-Torrent | 46,20 | 243,86 | 176,06 | 72,11% | 6,20 |
| | Torrent-Seminari | 38,99 | 189,82 | 127,96 | 67,22% | 6,26 |
| | Seminari-Torrent | 40,26 | 179,06 | 121,04 | 67,65% | 5,92 |
| Línea 2 | Torrent Av.-Llíria | 69,80 | 355,34 | 277,52 | 78,04% | 6,90 |
| | Llíria-Torrent Av. | 70,71 | 311,24 | 220,50 | 70,67% | 5,48 |
| | Torrent Av.-Paterna | 42,91 | 157,95 | 110,60 | 70,00% | 5,61 |
| | Paterna-Torrent Av. | 40,80 | 141,38 | 94,67 | 67,08% | 4,80 |
| Línea 3 | Aeroport-Rafelbunyol | 55,68 | 213,25 | 169,15 | 79,19% | 6,87 |
| | Rafelbunyol-Aeroport | 54,29 | 228,01 | 180,98 | 79,06% | 7,35 |
| Línea 5 | Aeroport-Marítim Serrería | 34,39 | 102,63 | 74,35 | 72,28% | 5,59 |
| | Marítim Serrería-Aeroport | 34,21 | 130,40 | 105,84 | 81,33% | 7,96 |
| Línea 7 | Torrent Av.-Marítim Serrería | 32,71 | 128,53 | 87,46 | 68,10% | 5,51 |
| | Marítim Serrería-Torrent Av. | 33,02 | 145,23 | 109,92 | 75,68% | 6,92 |

Tabla 5.6: Tiempos y consumos globales promedio por servicio y línea. Fuente: Elaboración propia.

Como se puede ver en la Tabla 5.6, todos los trayectos de la línea 1 presentan un consumo por kilómetro promedio entre 5,2 y 6,3 kWh, y no hay diferencias claras para cada trayecto según el sentido de la marcha. En la línea 2, en cambio, sí se aprecia un aumento del ratio entre consumo neto y bruto en los trenes ascendentes (esto es, sentido Llíria) respecto a los descendentes, probablemente debido a que el perfil del trazado es ascendente hacia Llíria, lo que contribuye al frenado en estaciones y por tanto se usa menos el freno regenerativo. El consumo neto es también claramente superior en sentido ascendente. Este mismo impacto del trazado se observa en la línea 3, con un consumo mayor

hacia Aeroport (de nuevo, con perfil ascendente), y en la línea 5. Por su parte, en la línea 7, el mayor consumo se observa en los trayectos sentido Torrent Avinguda, de nuevo por influencia clara del trazado. Tomando el conjunto de todas las líneas, se observa que el consumo por kilómetro oscila entre 4,8 y 7,9 kWh/km, mientras que la proporción entre consumo bruto y consumo neto se mueve entre el 67% y el 85%.

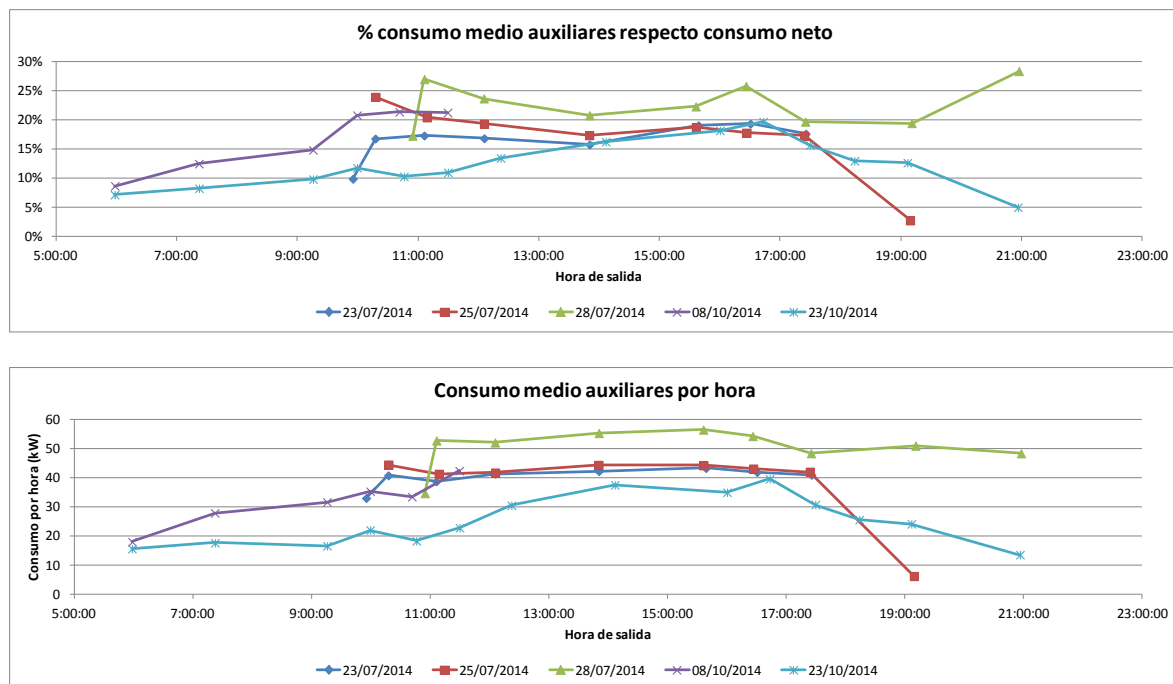


Figura 5.16: Porcentaje de consumo medio de auxiliares respecto al consumo neto en disyuntor (arriba) y consumo medio de auxiliares por hora (abajo) según servicio y hora de salida, para la línea 1. Fuente: Elaboración propia.

Por otra parte, para evaluar el consumo de auxiliares, la Figura 5.16 muestra el porcentaje promedio de consumo de auxiliares respecto al consumo neto en disyuntor, para diferentes trayectos según el día y la hora de salida. También se representa el consumo de auxiliares en términos absolutos. Ambas gráficas corresponden a servicios en la línea 1. Se puede observar cómo el consumo de auxiliares varía entre el 5% y el 30%, con una media del 20%. También se observa cómo los valores más elevados de consumo de auxiliares se dan en los días de verano (mediciones durante el mes de julio) y en las horas centrales del día, por las mayores necesidades de refrigeración. Cabe destacar que la línea 1 discurre en su mayor parte en superficie, por lo que los vehículos están más expuestos a las variaciones climáticas.

Para comparar, la Figura 5.17 muestra los correspondientes resultados de auxiliares para la línea 5, cuyo trazado es completamente subterráneo. En este caso las diferencias de consumo en términos absolutos entre los registros tomados en julio y en octubre son mucho menores. Las variaciones según la hora de salida a lo largo del día también son menores. Por el contrario, se puede observar cómo el porcentaje de consumo de auxiliares respecto al consumo neto en disyuntor oscila entre el 10% y el 45%, con un efecto zigzag entre los trenes que circulan en sentido ascendente y los que circulan en sentido descendente. Esta variación no se debe tanto al consumo de los sistemas auxiliares como a las variaciones en el consumo neto debidas al trazado ascendente (hacia Aeroport) o descendente (hacia Marítim-Serrería).

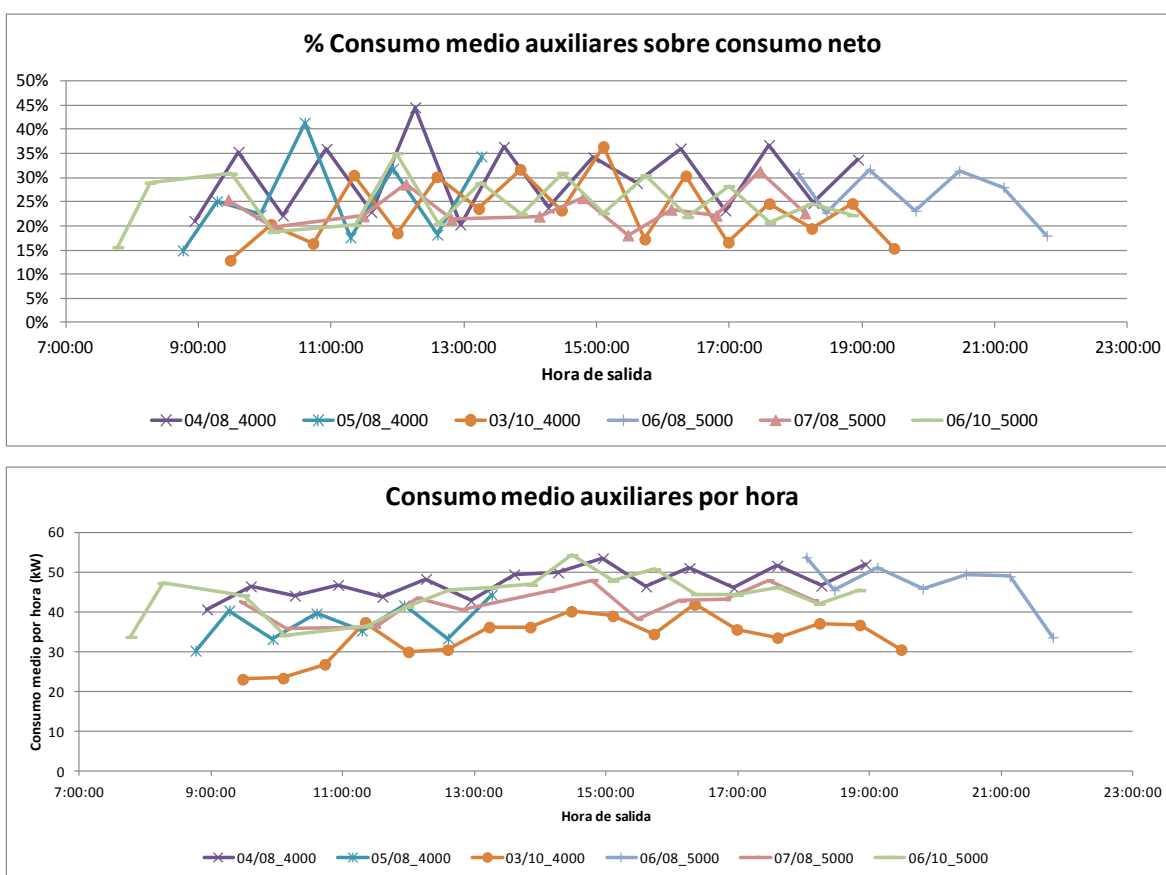


Figura 5.17: Porcentaje de consumo medio de auxiliares respecto al consumo neto en disyuntor (arriba) y consumo medio de auxiliares por hora (abajo) según servicio y hora de salida, para la línea 5. Fuente: Elaboración propia.

En términos globales, el consumo de auxiliares supone entre el 15% y el 45% del consumo total neto, con valores absolutos entre los 15 y los 60 kWh. Los mayores consumos de auxiliares están relacionados con la temperatura exterior (y de ahí que se aprecien

mayores cambios según la hora del día en las líneas que discurren mayoritariamente en superficie) y la afluencia de viajeros. Por otra parte, del consumo total de auxiliares, entre un 75% y un 85% corresponde a climatización.

Por último, en lo que se refiere a la energía disipada en resistencias, ésta no supera en promedio el 3% del consumo neto total, lo que indica que buena parte de la energía regenerada se aprovecha, bien en alimentar los sistemas auxiliares o bien en tracción para otros vehículos cercanos (Tabla 5.7).

| Línea | Trayecto | Energía promedio disipada (kWh) | % sobre consumo total neto |
|---------|----------------------------------|---------------------------------|----------------------------|
| Línea 1 | Villanueva de Castellón-Bétera | 14,93 | 3,29% |
| | Bétera-Villanueva de Castellón | 16,21 | 4,34% |
| | Villanueva de Castellón-Seminari | 14,93 | 4,08% |
| | Seminari-Villanueva de Castellón | 12,25 | 3,34% |
| | Torrent-Bétera | 1,55 | 0,92% |
| | Bétera-Torrent | 4,14 | 2,35% |
| | Torrent-Seminari | 1,09 | 0,85% |
| | Seminari-Torrent | 0,90 | 0,75% |
| Línea 2 | Torrent Av.-Lliria | 5,11 | 1,84% |
| | Lliria-Torrent Av. | 5,14 | 2,33% |
| | Torrent Av.-Paterna | 0,91 | 0,82% |
| | Paterna-Torrent Av. | 0,26 | 0,27% |
| Línea 3 | Aeroport-Rafelbunyol | 2,88 | 1,70% |
| | Rafelbunyol-Aeroport | 2,18 | 1,21% |
| Línea 5 | Aeroport-Marítim Serrería | 0,82 | 1,10% |
| | Marítim Serrería-Aeroport | 0,62 | 0,59% |
| Línea 7 | Torrent Av.-Marítim Serrería | 1,00 | 1,14% |
| | Marítim Serrería-Torrent Av. | 0,89 | 0,81% |

Tabla 5.7: Energía promedio disipada y porcentaje sobre consumo neto, por servicio y línea. Fuente: Elaboración propia.

Como se ve en la Tabla 5.7, los mayores valores se alcanzan en aquellos servicios de mayor longitud y menor frecuencia (esto es, trenes de la línea 1 a Bétera y Villanueva de Castellón, y en menor medida trenes de la línea 2 a Lliria), que además se corresponden

con tramos periféricos de la red en vía única. En los tramos y líneas con mayores frecuencias y doble vía, la energía consumida en resistencias no suele sobrepasar el 1,5% del consumo total neto en disyuntor. Los tramos concretos donde se detectan mayores cantidades de energía disipada son Massalavés-Alginet (74,11 MWh/año), La Canyada-Benaguasil 1r (64,64 MWh/año) y Talleres de Machado-Museros (58,92 MWh), todos ellos de vía única.

Para concluir, se pueden extraer las siguientes tendencias de consumo de la red a partir de los registros obtenidos de la campaña de medición.

- El consumo por kilómetro oscila entre 4,8 y 7,9 kWh, según el perfil de la línea y el número de paradas.
- La relación consumo bruto/consumo neto se mueve en el rango 67%-85%.
- Los consumos de auxiliares representan, en promedio, entre un 15% y un 45% del consumo total neto en disyuntor, con una clara influencia de la estación del año y la hora del día en los tramos en superficie.
- El consumo en resistencias supone, en promedio, un 3% del consumo neto total, si bien los mayores porcentajes se dan en ciertos tramos periféricos de la red, con bajas frecuencias y vía única. En los tramos centrales de la red, el porcentaje no suele superar el 1,5%.

5.5. Ámbito de aplicación del estudio

El ámbito concreto de aplicación de la presente tesis se circunscribe a la red de metro de Valencia, cuyas características se han expuesto en el presente Capítulo. Más concretamente, el estudio se centra en las líneas de metro (ya que no se contaba con datos de consumo de las líneas 4, 6 y 8 de tranvía) en sus tramos subterráneos, donde la operación está automatizada mediante ATO.

El motivo principal para descartar los tramos con conducción manual es que el simulador se ha desarrollado teniendo en mente la conducción automática, con una modelización del sistema ATO (véase Capítulo IV), y se ha considerado que, con vistas a realizar el análisis comparativo entre algoritmos de optimización, convenía centrar el estudio en un único escenario de operación que además es cada vez más habitual en líneas de metro. Por ello se han descartado los tramos operados manualmente, ya que tienen un carácter más propio de un tren cercanías que conecta la ciudad con las poblaciones circundantes

(en superficie, con conducción manual y frecuencias más bajas). Por lo tanto, el estudio que se desarrolla en los siguientes Capítulos de la tesis se aplica en:

- Las líneas 1 y 2 en su tramo común subterráneo entre Empalme y València Sud: 10 tramos inter-estación.
- La línea 3 entre Aeroport y Alboraya-Peris Aragó: 18 tramos inter-estación.
- La línea 5 en su totalidad: 17 tramos inter-estación.
- La línea 7 en su totalidad, excepto el tramo de conexión entre las estaciones de Colón y Jesús (por carencia de datos geométricos fiables): 12 tramos inter-estación.

Considerando que algunas de las líneas tienen tramos coincidentes, el estudio comprende 32 tramos entre estaciones. Esto supone, al tener en cuenta ambos sentidos de circulación, un total de 64 casos de estudio.

Capítulo IV

6. Simulador de marchas

En el Capítulo IV se aborda el desarrollo y validación de la herramienta de simulación de marchas y consumo energético que se emplea como base para la comparación de algoritmos meta-heurísticos de optimización. Para ello, en esta Sección 6 se detalla la formulación del simulador de marchas que calcula el perfil de velocidades del vehículo. Posteriormente, en la Sección 7 se expone el entrenamiento de la red neuronal que emplea dicho perfil de velocidades para obtener el consumo energético. Finalmente, en la Sección 8 se comenta la implementación de los algoritmos a comparar y la definición de la metodología de comparación.

6.1. Introducción

Como se vio en el Capítulo II, la opción preferida por la mayoría de autores a la hora de modelizar la dinámica de un vehículo ferroviario es emplear un simulador paso a paso basado en ecuaciones deterministas, debido a su flexibilidad y fiabilidad. Este es el enfoque escogido para la presente tesis, si bien con una salvedad: el simulador desarrollado en los siguientes apartados se centra exclusivamente en la modelización de la marcha del vehículo, mientras que el consumo energético se simula a través de una red neuronal (véase Sección 7 para una justificación de esta decisión).

El simulador de marchas aquí presentado se basa en las ecuaciones básicas de la mecánica newtoniana y la ecuación de Davis, con un enfoque de discretización temporal y un bloque que simula el sistema de comandos ATO. Además, si bien la estructura fundamental del simulador es relativamente simple, éste incluye una serie de condicionantes tanto de seguridad (por ejemplo, las limitaciones de velocidad de la línea) como de con-

fort del pasaje (por ejemplo, restricciones a la sobre-aceleración). En líneas generales, se trata de un simulador bastante similar al desarrollado por otros autores, cuyo único aspecto innovador es, precisamente, el uso de una red neuronal para la estimación del consumo energético. Por otra parte, cabe destacar que el simulador se ha implementado en MATLAB 8.5.0 (The MathWorks, Inc.).

En los siguientes apartados se expone la estructura, desarrollo y validación del simulador de marchas propiamente dicho.

6.2. Estructura del simulador de marchas

6.2.1. Planteamiento

En líneas generales el simulador de marchas desarrollado en el marco de la presente tesis se inspira en los realizados por varios de los autores revisados en el Capítulo II, con mención especial al trabajo de Domínguez et al. (2011), si bien adaptado y modificado en base a las particularidades de nuestro ámbito de estudio y con algunas simplificaciones y limitaciones.

La base del simulador es la segunda ecuación de Newton (2.1) y la ecuación de Davis (2.2), reformuladas y ampliadas en la siguiente ecuación (García Álvarez, 2007b) que expresa la fuerza de tracción aplicada:

$$F_T = a \times M \times C_{mg} - M \times g \times p + A + B \times v + C \times v^2 + M \times \frac{f_c}{R_{cu}} \quad (6.1)$$

Donde F_T es la fuerza de tracción del vehículo, a es la aceleración del vehículo, M es su masa, C_{mg} es el coeficiente de masas giratorias, g es la gravedad, p es la pendiente longitudinal, v es la velocidad del vehículo, R_{cu} es el radio de curvatura en planta y A , B y C son los coeficientes de Davis. Por otra parte, la resistencia debida a curvas se asimila a una resistencia por pendiente adicional a través del factor de curva f_c , cuyo valor se ha fijado empíricamente en 514 para ancho de vía métrico (Instituto de Investigación Tecnológica, 2010).

A través de la ecuación (6.1) se rige la dinámica del vehículo, de manera que, en cada paso de tiempo Δt , se calculan las fuerzas que se oponen al movimiento y se define la fuerza de tracción a aplicar en función de la aceleración real que se desee alcanzar. Por supuesto, sobre este esquema simple se incorporan diferentes aspectos tales como la fuerza de tracción real que puede aplicar el vehículo (en función de sus curvas velocidad-

esfuerzo), la capacidad del sistema de frenado, la existencia de limitaciones de velocidad, condicionantes de confort, etc.

Por otra parte, ya que el ámbito de estudio consiste en líneas operadas automáticamente mediante ATO, el simulador incorpora una modelización de dicho sistema, que es el que determina de antemano qué tipo de perfil se pretende alcanzar y marca los objetivos de aceleración a desarrollar en cada paso de tiempo Δt .

Para no complicar en exceso el simulador, y en base a lo establecido en la bibliografía revisada, se ha optado por simular sólo dos clases de perfil que el sistema ATO fija de antemano para el vehículo: uno de regulación, en el que el vehículo acelera hasta una velocidad fija, la mantiene el máximo tiempo posible y luego frena hasta detenerse en la siguiente estación; y otro de deriva-remotor, en el que el vehículo acelera hasta una velocidad fija, y luego circula alternando ciclos de deriva y remotorización entre dos umbrales de velocidad para finalmente frenar y detenerse en la siguiente estación (Figura 6.1).




Figura 6.1: Esquema de circulación en regulación y en deriva-remotor en un mismo tramo. Fuente: Elaboración propia.

Estas dos familias de perfiles de velocidad, Regulación (R) y Deriva-Remotor (D-R), son las más habituales empleadas en la definición de marchas en líneas de metro, ya que diversos estudios han demostrado que se encuentran entre las más eficientes energéticamente para líneas urbanas y suburbanas (Albrecht et al., 2016a, 2016b). De hecho, algunos sistemas ATO (como el de metro de Madrid) están diseñados en base a estos dos tipos de perfiles (Domínguez et al., 2010). Por ello se ha optado por centrarse sólo en

estos dos modelos de perfil, excluyendo combinaciones de los mismos u otras opciones menos comunes, ya que sólo con las múltiples variaciones posibles de ambos es suficiente para establecer un espacio de soluciones muy extenso y fundamentar la comparación entre algoritmos de optimización objeto de la presente tesis.

Así pues, el simulador parte del sistema ATO, que define qué tipo de perfil a aplicar (R o D-R) y fija el valor de una serie de comandos (véase apartado 6.2.2). En base a estos comandos, el simulador determina, en cada paso de tiempo Δt , en qué fase del perfil de velocidad se encuentra en ese momento (aceleración, mantenimiento, deriva, frenado, etc.) y cuál es la aceleración a alcanzar, tras lo que va resolviendo la ecuación (6.1), aplicando los condicionantes específicos de cada fase, hasta alcanzar la siguiente estación y completar el trayecto.

Para perfiles R, se establecen las siguientes fases posibles a lo largo del trayecto:

- Fase de aceleración inicial.
- Fase de mantenimiento de velocidad.
- Fase de frenado final.
- Fases de aceleración-frenado debidas a limitaciones de velocidad.

Por otra parte, para perfiles D-R, se establecen las siguientes fases posibles a lo largo del trayecto:

- Fase de aceleración inicial.
- Fases de deriva.
- Fases de remotorización.
- Fase de frenado final.
- Fases de aceleración-frenado debidas a limitaciones de velocidad.

En ambos casos, el simulador va saltando de una a otra fase según sea necesario a lo largo del recorrido, en función de diferentes criterios. Así, por ejemplo, la fase de aceleración inicial se desarrolla hasta alcanzar la velocidad de regulación (en perfiles R) o la velocidad de deriva (en perfiles D-R), pero si el simulador detecta la proximidad de una limitación de velocidad más restrictiva que la velocidad actual, salta a una fase de frenado parcial. Por otra parte, en todo Δt se chequea la distancia al final del recorrido, y en función de la velocidad en ese punto, se puede activar o no la fase de frenado final y detención, que restringe a las demás. En cualquier caso, independientemente de la fase (que

básicamente determina el objetivo de aceleración aplicable en cada paso de tiempo), el cálculo del balance de fuerzas se realiza siempre mediante la ecuación (6.1).

La Figura 6.2 recoge de forma esquemática el funcionamiento del simulador, con las diferentes fases que se activan a lo largo del trayecto.

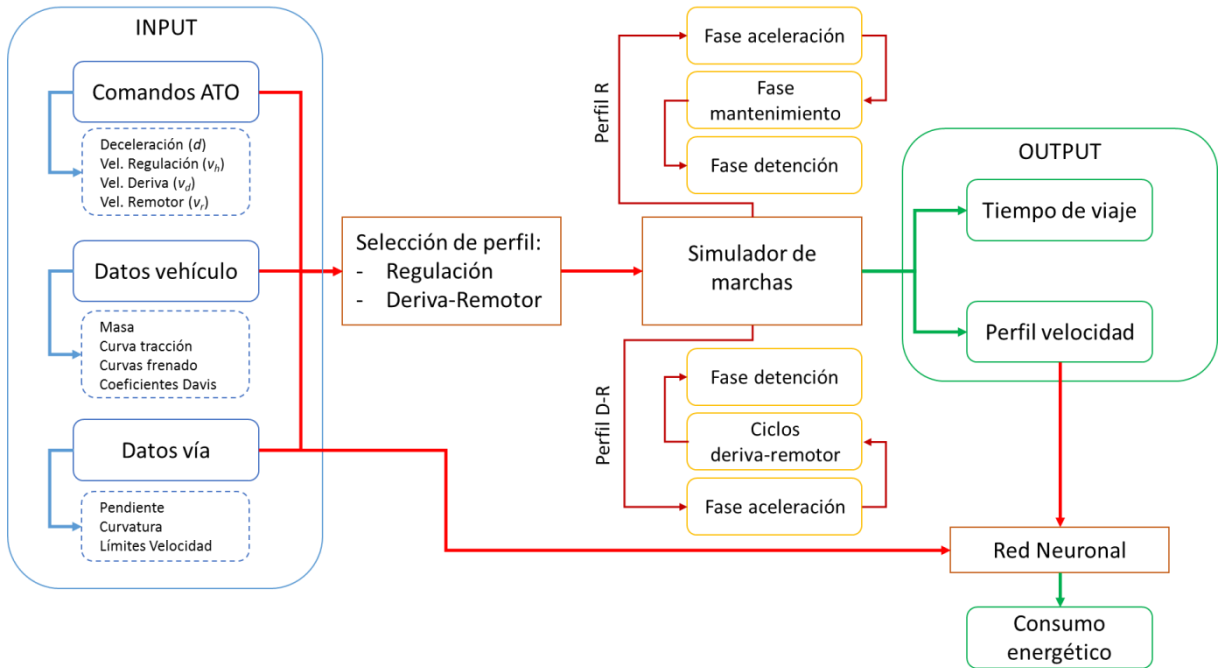


Figura 6.2: Esquema de funcionamiento del simulador de marchas. Fuente: Elaboración propia.

En los siguientes apartados se desgana con más detalle el funcionamiento de los diferentes aspectos del simulador mostrados en el anterior esquema.

6.2.2. El sistema ATO

Como ya se ha explicado, parte de la red de metro de Valencia se opera automáticamente mediante un sistema ATO, por lo que se decidió incorporar dicho sistema al simulador para así contar con un modelo más próximo a la realidad. No obstante, así como se disponía de información suficiente respecto a la infraestructura y el material rodante como para configurar el simulador con bastante precisión, no se contaba con datos precisos respecto al sistema ATO y su funcionamiento.

Esto suponía un serio inconveniente a la hora de desarrollar el simulador. Como solución de compromiso, se optó por plantear un modelo simplificado del ATO basado en el siste-

ma existente en el metro de Madrid, tal y como lo describen varios de los autores revisados en el Capítulo II (Domínguez et al., 2014, 2011). De este modo, se incorporaba hasta cierto punto la lógica del sistema ATO al simulador, y se podía plantear la optimización en base a sus comandos.

Si bien esto supone una desviación respecto a la realidad que perjudicaría a un estudio específico de optimización de marchas en la red de metro de Valencia, se considera suficiente y apropiado para el estudio que nos ocupa, en el que la comparativa entre algoritmos de optimización precisa de un marco realista y equitativo, pero no necesariamente exacto. O, en otras palabras, aunque este modelo sea mejorable como representación estricta de la red de metro Valencia, es suficientemente cercano a una versión idealizada de una red de metro similar a la de Valencia como para servir de base al estudio comparativo.

Así pues, el simulador incorpora el sistema ATO bajo la forma de un input específico que delimita el perfil de velocidad a aplicar (R o D-R) y, por tanto, la consigna de aceleración en cada paso de tiempo Δt . En base al sistema del metro de Madrid (Domínguez et al., 2014), se definen cuatro comandos ATO para aportar como input al simulador:

- Deceleración final de llegada a estación (d): este valor fija la deceleración que el vehículo ha de aplicar en cuanto se activa la fase final de frenado y detención.
- Velocidad de regulación (v_h): en perfiles R, este valor fija el objetivo de velocidad a alcanzar y mantener por el vehículo.
- Velocidad de deriva (v_d): en perfiles D-R, este valor fija el objetivo de velocidad a alcanzar antes de iniciar cada ciclo de deriva.
- Velocidad de remotorización (v_r): en perfiles D-R, este valor fija el umbral de velocidad que, una vez alcanzado tras una fase de deriva, indica al vehículo que debe volver a acelerar de nuevo hasta alcanzar otra vez la velocidad de deriva.

El primer comando (d) es común tanto a perfiles R como D-R. Los restantes comandos, en cambio, se aplican sólo en uno u otro caso. Así, si se desea aplicar un perfil R, el comando ATO consistirá en un valor d y un valor v_h , siendo los valores v_d y v_r nulos. Por el contrario, en el caso de un perfil D-R, el comando ATO consistirá en un valor d , un valor v_d y un valor v_r , siendo el valor v_h nulo. Además, el valor v_d debe ser por fuerza superior al valor v_r . De este modo, sólo con la configuración de los comandos ATO el simulador ya es capaz de determinar si se aplica un comando R o D-R.

La Tabla 6.1 recoge los valores máximos y mínimos considerados para cada uno de estos cuatro comandos, en base a las características del material rodante en servicio en la red de metro de Valencia.

| | Deceleración d (m/s ²) | Velocidad regulación v_h (km/h) | Velocidad deriva v_d (km/h) | Velocidad remotor v_r (km/h) |
|--------------|---|--------------------------------------|----------------------------------|-----------------------------------|
| Valor máximo | 0,80 | 80 | 80 | 60 |
| Valor mínimo | 0,55 | 25 | 40 | 20 |

Tabla 6.1: Valores máximos y mínimos de los comandos ATO. Fuente: Elaboración propia.

Por otra parte, cabe destacar que la aceleración inicial se ha fijado en todo caso en el valor máximo alcanzable por el material rodante a plena tracción (con un valor tope de 1,1 m/s²) por criterios de eficiencia energética ya establecidos (Albrecht et al., 2016a).

6.2.3. Características del vehículo

Como se ha comentado en apartados anteriores, el simulador calcula, en cada paso de tiempo, la fuerza de tracción/frenado a aplicar en función de la aceleración/deceleración objetivo en ese punto de la ruta. No obstante, el material rodante tiene unas limitaciones en cuanto a la máxima fuerza de tracción o de frenado que es capaz de movilizar, en función de sus características técnicas y de la velocidad a la que circule. Este conocimiento debe ser incorporado al simulador para modelizar con mayor exactitud la dinámica del vehículo.

Como se vio en el Capítulo III, el material rodante que opera en las líneas de metro de Valencia es un automotor serie 4300 de Vossloh, con una configuración de cuatro coches (Motor-Remolque-Remolque-Motor). Existe también una configuración de cinco coches, pero no se ha tenido en cuenta en la simulación ya que los datos obtenidos durante la campaña de medición se tomaron en una unidad de cuatro coches. El operador de la red de metro (FGV) facilitó una serie de datos técnicos de este tipo de vehículo, para ser incorporados al simulador.

Para empezar, la Tabla 6.2 recoge los valores de una serie de parámetros básicos del vehículo, necesarios para resolver la ecuación (6.1) en cada paso de tiempo. De especial interés es el valor de la masa del vehículo que, como se ve en la tabla, es variable en función del grado de ocupación, y determina algunos de los restantes valores. Por otra parte, nótese que el coeficiente de masas giratorias C_{mg} de la ecuación (6.1) se incorpora

de forma indirecta a través del valor de masas rotatorias, que se suma a la masa estática para determinar la masa total del vehículo.

| Caso carga | Masa estática (t) | Masa rotatoria (t) | Masa total (t) | A (N) | B (N/km/h) | C (N/(km/h) ²) |
|---|-------------------|--------------------|----------------|----------|------------|----------------------------|
| AW0 (tara) | 120,70 | 12,25 | 132,90 | 2.943,85 | 18,61 | 0,57 |
| AW2 (4 p/m ²) | 152,90 | 12,25 | 165,10 | 3.153,15 | 23,11 | 0,57 |
| AW3 (6 p/m ²) | 163,90 | 12,25 | 176,20 | 3.225,30 | 24,67 | 0,57 |
| AW4 (8 p/m ²) | 174,90 | 12,25 | 187,20 | 3.296,80 | 26,21 | 0,57 |
| Otros parámetros | | | | | | |
| Velocidad máxima (km/h) | 80 | | | | | |
| Aceleración máxima (m/s ²) | 1,10 | | | | | |
| Deceleración máxima (m/s ²) | 1,20 | | | | | |
| Longitud del vehículo (m) | 60,50 | | | | | |

Tabla 6.2: Parámetros básicos del vehículo (metro serie 4300). Fuente: FGV.

En un vehículo ferroviario ligero como es este tipo de metro, la masa total puede variar hasta un 45% entre el caso del tren completamente vacío y el caso a carga completa. Si bien se ha incorporado al simulador la posibilidad de variar la masa entre las categorías que se muestran en la Tabla 6.2 (y por tanto todos los parámetros y curvas asociados a cada categoría, como se verá a continuación), a efectos del presente estudio se optó por fijar la categoría AW2 (4 personas/m²) por ser un caso intermedio de ocupación de los cuatro disponibles.

Por otra parte, la capacidad de tracción del vehículo viene limitada por la potencia del motor, y es función de la velocidad de circulación, tal y como se ve en la Figura 6.3. Por ello, si en alguno de los ciclos del simulador la fuerza de tracción requerida supera a la máxima posible para la velocidad actual, se aplica dicho valor máximo y se corrige a la baja la aceleración resultante.




Figura 6.3: Curvas esfuerzo - velocidad del vehículo. Fuente: FGV.

Ocurre lo mismo con la capacidad de los frenos del vehículo, tal y como se aprecia en la Figura 6.4. De nuevo, si durante una fase de frenado la fuerza a aplicar supera las posibilidades del vehículo, se aplica la máxima fuerza de frenado posible y se corrige la deceleración a la baja. Esto es especialmente importante a la hora de definir las curvas de frenado y detectar la proximidad del fin del recorrido (o la cercanía de una limitación de velocidad) ya que, de no implementarse correctamente, el vehículo simulado tardaría más en frenar de lo previsto y sobrepasaría el punto de detención.




Figura 6.4: Curvas frenado - velocidad del vehículo. Fuente: FGV.

En lo referente al frenado, existe otro aspecto a tener en cuenta. Así como en tracción se asume que el vehículo aplica el máximo esfuerzo en función de la velocidad actual, de acuerdo a las curvas de la Figura 6.3, durante el frenado es posible aplicar sólo un porcentaje de la fuerza disponible. Esto viene determinado por las curvas mostradas en la Figura 6.5, en las que se puede observar la relación entre esfuerzo de frenado aplicado y porcentaje del manipulador (esto es, posición del mando de frenado entre el punto neutro y el punto de frenado máximo).

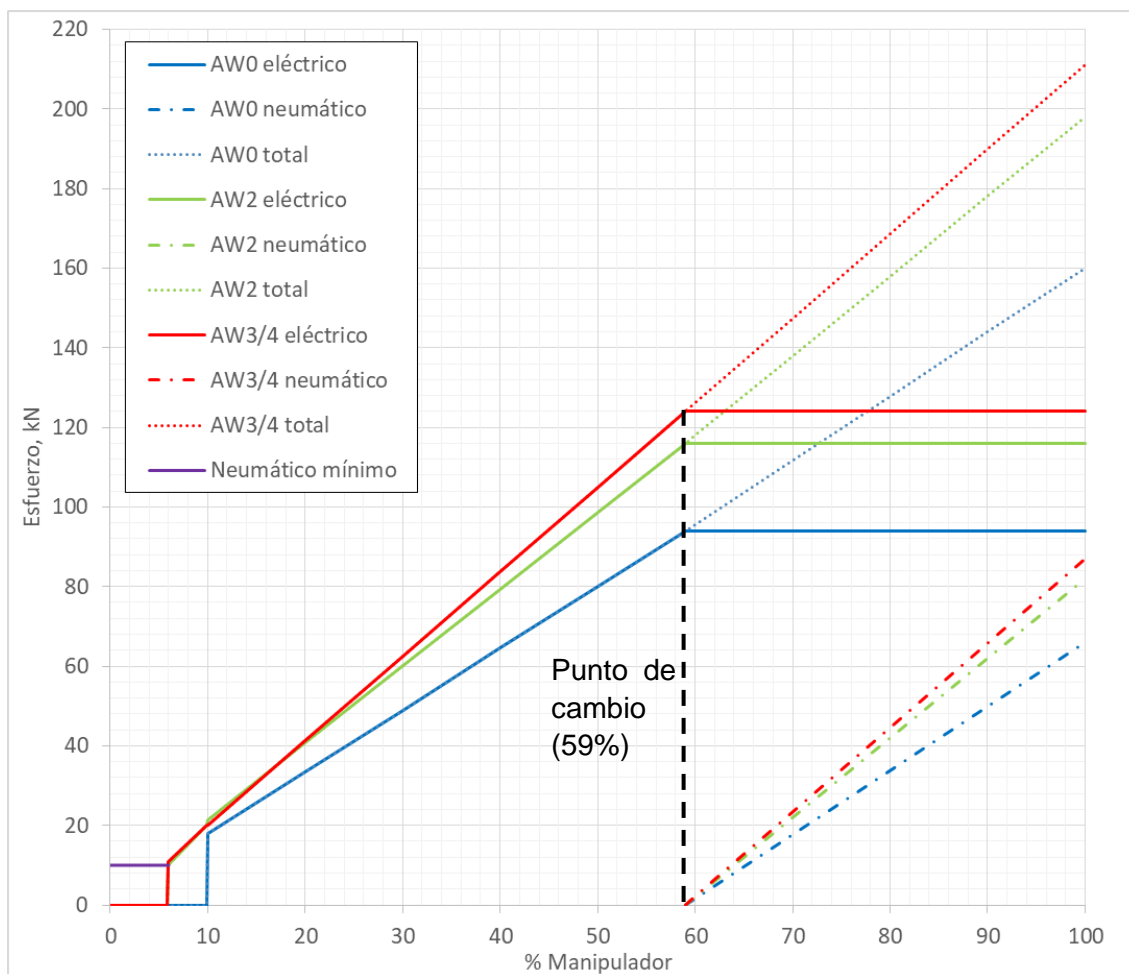


Figura 6.5: Curvas frenado - % manipulador del vehículo. Fuente: FGV.

Si se comparan la Figura 6.4 y la Figura 6.5 se observa que, cuando se aplica un porcentaje del freno inferior al 59% sólo se activa el freno eléctrico, con un valor variable en función de la velocidad. Por encima del 60%, a velocidades superiores a 12 km/h, el freno eléctrico aporta un valor constante de esfuerzo de frenado, y se activa el freno neumático de forma creciente conforme el manipulador se aproxima al máximo. Por otra parte, a bajas velocidades (por debajo de 5-6 km/h) el freno eléctrico no opera y el freno neumático aporta un esfuerzo constante de 10 kN.

Toda esta información se ha incorporado al simulador para regir las fases de frenado. Además, cabe destacar que, como criterio para asegurar una frenada en condiciones de servicio y confort, el simulador trata de aplicar sólo un 59% del esfuerzo de frenado en primera instancia, para evitar el uso del freno neumático. En casos extremos (por ejemplo, en una llegada a estación en pendiente pronunciada) en los que el 59% no permita

desarrollar una deceleración suficiente, se admite hasta un 80% del mando de frenado, pero en ningún caso se supera este porcentaje.

Otro aspecto a considerar es que, si bien la ecuación (6.1) se aplica sobre el centro de masas del vehículo, éste tiene una longitud determinada, de manera que, en un momento dado de la ruta, parte de mismo puede estar dentro del trazado de una curva y otra parte en recta. O, a efectos de pendiente longitudinal, los coches delanteros pueden estar en una rampa mientras los traseros todavía se encuentran en llano (Figura 6.6).

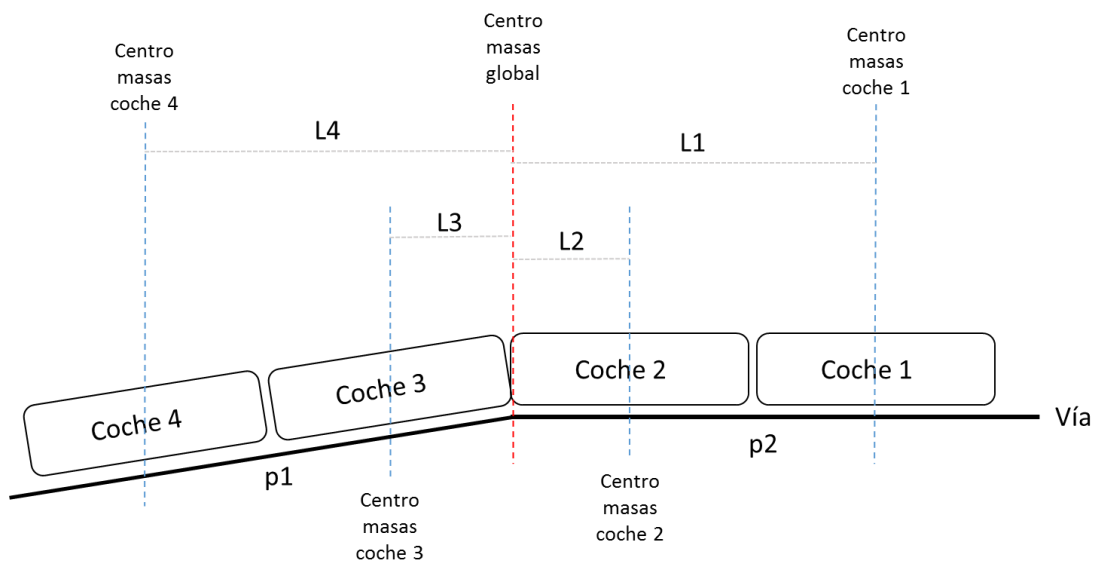


Figura 6.6: Efecto de la longitud del tren en el cálculo de la pendiente y curvatura de la vía en cada punto de la ruta. Fuente: Elaboración propia.

Para tener en cuenta este efecto, los valores de pendiente y curvatura introducidos en la ecuación (6.1) en cada paso de tiempo Δt se calculan promediando los valores en la vertical del centro de masas de cada uno de los cuatro coches que componen el vehículo, en base a la longitud entre dichos centros de masa parciales y el centro de masas global:

$$p_m = \frac{p(L1) + p(L2) + p(L3) + p(L4)}{4} \quad (6.2)$$

$$c_m = \frac{c(L1) + c(L2) + c(L3) + c(L4)}{4} \quad (6.3)$$

Donde p_m es la pendiente promedio, c_m es la curvatura promedio y $p(Li)$ y $c(Li)$ son, respectivamente, la pendiente longitudinal y la curvatura en planta en la vertical del centro de masas del coche i -ésimo. De este modo, se introduce la longitud real del vehículo en el

simulador y su efecto sobre el cálculo del esfuerzo de tracción, compensando así en parte el efecto diferencial comentando más arriba respecto a la geometría de la vía.

6.2.4. Control de fases de frenado

Independientemente del tipo de perfil a desarrollar (R o D-R), el simulador de marchas controla en cada paso de tiempo Δt si es necesario frenar, bien sea porque se aproxima una limitación de velocidad más restrictiva que la velocidad actual o porque se acerca el final del trayecto. Para llevar a cabo esta comprobación, en cada paso de tiempo el simulador evalúa la velocidad actual, comprueba la distancia hasta la próxima estación (o, en su caso, la distancia hasta la próxima limitación) y consulta unas curvas de frenado previamente calculadas para determinar si es necesario activar una fase de frenado o todavía hay margen.

Estas curvas de frenado se calculan al inicio del simulador, para servir de referencia en las comprobaciones que se realizan en cada paso de tiempo. Existen dos curvas: una de frenado total para la deceleración y detención en estación, y otra de frenado parcial para regular las frenadas frente a limitaciones de velocidad.

La curva de frenado total se calcula como un vector en el que cada valor es la distancia necesaria para frenar desde una velocidad dada hasta cero, teniendo en cuenta la deceleración d introducida como comando por el sistema ATO. Este vector se calcula considerando velocidades desde 80 km/h (la máxima posible en la red) hasta 0 km/h, con intervalos de 1 km/h, y teniendo en cuenta las limitaciones de frenado a baja velocidad expuestas en el apartado 6.2.3. La Figura 6.7 muestra un ejemplo de curva de frenado obtenida para una d de 0,8 m/s².




Figura 6.7: Curva de frenado total: distancia de frenado hasta 0 en función de la velocidad actual. Fuente: Elaboración propia.

Del mismo modo se calcula una curva de frenado parcial bajo la forma de una matriz triangular con diagonal nula, donde cada valor no nulo indica la distancia de frenado necesaria para pasar de la velocidad indicada por la fila hasta la velocidad indicada por la columna. Al igual que en el caso anterior, se plantea la curva desde una velocidad máxima de 80 km/h hasta una velocidad mínima de 5 km/h, con intervalos de 1 km/h, y se tienen en cuenta las limitaciones de frenado a baja velocidad del vehículo. Por el contrario, la deceleración a emplear se fija como un 60% del valor del comando d del ATO, con un tope máximo de $0,5 \text{ m/s}^2$, para que las frenadas durante la ruta sean más confortables.

6.2.5. Condicionantes de confort

Para mejorar la validez del simulador y trabajar con un espacio de soluciones que incluya marchas realistas y aceptables para una red de metro, se han implementado algunos aspectos de confort a la simulación que modifican el cálculo del perfil de velocidades. Algunos de estos aspectos ya se han comentado en los apartados precedentes, pero se listan aquí para una mayor claridad. La lista completa de condicionantes debidos al confort es la siguiente:

- Limitación de esfuerzo de frenado en detención al 59% del mando del manipulador (en condiciones excepcionales, se admite hasta el 80%).
- Reducción de deceleración frente a limitaciones de velocidad al 50% del comando de deceleración d del sistema ATO.
- Diferencia mínima entre v_d y v_r de 20 km/h, para evitar que los perfiles D-R se ejecuten con un exceso de ciclos cortos deriva-remotorización.
- Limitación de sobre-aceleración (*jerk*) de 0,5 m/s²/s. Esto supone que los cambios de aceleración bruscos (por ejemplo, al inicio de la marcha, o cuando se pasa de una fase de regulación a otra de frenado) se laminan en el tiempo con una variación máxima restringida a dicho valor.

6.3. Resultados del simulador de marchas

En base a todos los aspectos expuestos en el apartado anterior, queda definido el simulador de marchas empleado en la presente tesis. Este simulador recibe los cuatro comandos ATO y desarrolla el perfil completo de velocidad en el tramo dado, además de calcular el tiempo total de viaje. Más concretamente, las entradas y salidas del simulador son:

Entradas

- Comandos ATO (d , v_h , v_d , v_r).
- Datos del vehículo (masa, curvas de tracción y frenado, coeficientes de Davis).
- Datos de la línea (distancia del trayecto, pendiente, curvatura, limitaciones de velocidad).

Salidas

- Perfil de velocidad (km/h).
- Perfil de aceleración (m/s²).
- Distancia acumulada (m).
- Esfuerzo de tracción/frenado instantáneo (kN).
- Porcentaje del esfuerzo aplicado sobre el máximo disponible en cada instante.
- Tiempo acumulado (s) y tiempo de viaje total (min).

De este modo, el simulador aporta uno de los dos valores necesarios para plantear el proceso de optimización de marchas: el tiempo de viaje. Para obtener el otro valor (esto es, el consumo energético total), se emplea la red neuronal desarrollada en la Sección 7,

que toma los resultados del simulador y los datos geométricos de la vía para calcular la energía consumida.

La Figura 6.8 muestra varios ejemplos de simulación de marchas realizados con el simulador en el tramo Colón-Alameda de las líneas 3-5 (con una longitud de 566 metros). Se trata de dos perfiles R (con una velocidad objetivo de 80 km/h y 50 km/h respectivamente) y un perfil D-R (con 50 km/h de velocidad de deriva y 30 km/h de velocidad de remotorización).

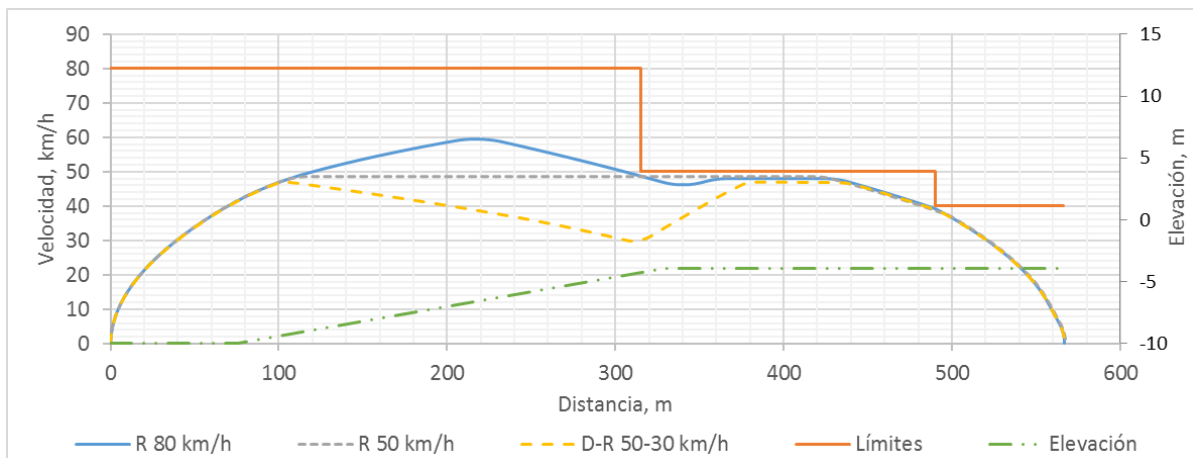


Figura 6.8: Ejemplo de marchas calculadas por el simulador en el tramo Colón-Alameda (líneas 3-5). Fuente: Elaboración propia.

Como se puede ver, el simulador reproduce correctamente el perfil de velocidades y es capaz de adaptarse a las limitaciones de velocidad existentes. En el caso del perfil D-R, se aprecia un ciclo completo de deriva-remotorización, y el inicio de un segundo ciclo que queda cortado por la fase de frenado final y detención.

Por otra parte, la Figura 6.9 muestra dos ejemplos (uno R con velocidad objetivo 80 km/h y otro D-R con velocidad de deriva 50 km/h y velocidad de remotorización 30 km/h) en el tramo Paiporta-Picanya de las líneas 1-2 (1.709 metros de longitud) en el que no existen limitaciones de velocidad por debajo de 80 km/h y el perfil de la línea es prácticamente recto y con pendientes moderadas.




Figura 6.9: Ejemplo de marchas calculadas por el simulador en el tramo Paiporta-Picanya (líneas 1-2). Fuente: Elaboración propia.

En este caso el perfil R se desarrolla completamente al no existir limitaciones. Por otra parte, el perfil D-R completa un primer ciclo de deriva-remotorización que cubre buena parte del trayecto, ya que la velocidad apenas disminuye durante los primeros 500 metros (debido a que esa parte del tramo discurre en una leve rampa). La fase de remotorización es breve, y el segundo ciclo de deriva se ejecuta durante unos 180 metros con un descenso de velocidad muy leve antes de que se inicie la fase de frenado final y detención. En líneas generales, el simulador ofrece un resultado acorde con lo esperado.

6.4. Validación del simulador de marchas

Una vez completado el simulador y comprobado que funciona dentro de los parámetros previstos, es preciso validar los resultados que ofrece. Para ello se han escogido una serie de casos de control a partir de los datos recopilados en la campaña de medición descrita en el Capítulo III y se ha comprobado hasta qué punto se ajusta el perfil simulado con el perfil real. También se ha comprobado el error del simulador en la estimación del tiempo total de viaje. Los perfiles de control son:

- Control 1: Tramo Amistat-Aragón (Línea 5). Asimilable a perfil R.
- Control 2: Tramo Patraix-Safranar (Líneas 1-2). Asimilable a perfil D-R.
- Control 3: Tramo Àngel Guimerà-PI. Espanya (Líneas 1-2). Asimilable a perfil D-R.
- Control 4: Tramo Picanya-Paiporta (Líneas 1-2). Asimilable a perfil R.

Es preciso destacar que, como se comentó en el apartado 6.2.2, no se tiene información precisa del sistema ATO real que opera en la red de metro de Valencia. Por ello, para

cada uno de estos casos de control, si bien se tienen registros del perfil de velocidad y del tiempo de viaje, no es posible conocer los comandos ATO aplicados (o si tan siquiera siguen la misma estructura que los empleados por el simulador). Por ello, cada uno de los casos de control se ha asimilado aproximadamente a un perfil R o D-R y se han estimado los comandos ATO correspondientes, afinándolos hasta lograr el mejor ajuste con los datos medidos de velocidades y tiempos. No obstante, debido a esta circunstancia, se asume un cierto margen de error en la validación, particularmente en el ajuste del perfil de velocidad. Así, la Figura 6.10 muestra la comparación entre el perfil de velocidad medido en cada uno de los cuatro casos de control y el perfil calculado por el simulador.

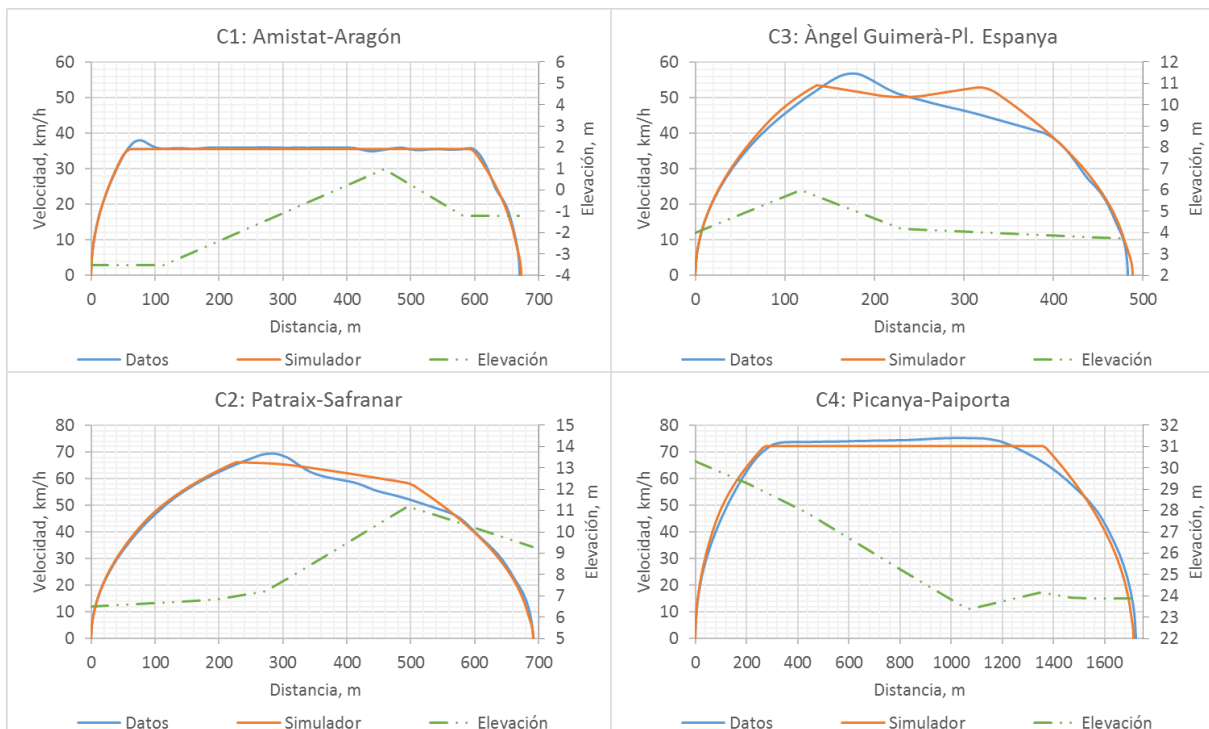


Figura 6.10: Comparativa entre perfiles medidos y simulados para los cuatro casos de control. Fuente: Elaboración propia.

De acuerdo a estos resultados, se observa que, en los casos de control que se corresponden claramente con un perfil R (casos 1 y 4) el ajuste con perfil del simulador es bastante bueno. Por el contrario, el ajuste con los casos que se han supuesto asimilables a perfiles D-R (casos 2 y 3) el ajuste es algo peor por los motivos antes mencionados.

En todo caso, el principal interés del simulador no es tanto la simulación exacta de cada instante del perfil de velocidades como la estimación precisa del tiempo total de viaje. En

este sentido, la Tabla 6.3 muestra la comparativa entre el tiempo de viaje real y el simulado para cada uno de los cuatro casos de control.

| Conjunto de datos | Tiempo real (s) | Tiempo simulado (s) | Diferencia (%) |
|---------------------------------------|-----------------|---------------------|----------------|
| Control 1 (Amistat-Aragón) | 81 | 84,70 | 4,57 |
| Control 2 (Patria-Safranar) | 66 | 66,10 | 0,15 |
| Control 3 (Àngel Guimerà-Pl. Espanya) | 55 | 56,50 | 2,73 |
| Control 4 (Picanya-Paiporta) | 119 | 118,30 | 0,59 |
| Error medio | | | 1,43 |

Tabla 6.3: Comparativa entre tiempos de viaje reales y calculados por el simulador. Fuente: Elaboración propia.

Como se aprecia en la tabla, salvo en un caso en el que el error aumenta hasta el 4,5%, en general el simulador es capaz de ajustar con bastante precisión el tiempo total de viaje, con un error medio del 1,43% y errores inferiores al 1% en los casos 2 y 4. Este porcentaje de error es un poco superior al alcanzado por otros autores con sus simuladores (véase Tabla 3.1 en la Sección 3) pero, considerando que la comparativa viene sesgada, como se ha indicado, por la falta de conocimiento del sistema ATO real, se considera que el simulador queda validado a efectos de la presente tesis.

6.5. Conclusiones

En la presente Sección se ha expuesto el desarrollo, características y validación de un simulador de marchas capaz de modelizar el perfil de velocidades y estimar el tiempo de viaje total en cada tramo inter-estación a partir de una serie de comandos que representan el funcionamiento de un sistema ATO. Este simulador representa la primera parte de la herramienta para calcular tiempos de viaje y consumo energético, necesaria como función de coste en la comparativa de algoritmos de optimización a desarrollar en el Capítulo V de la presente tesis. En la Sección 7 se abordará la segunda parte, correspondiente a la red neuronal.

El simulador desarrollado se inspira en los presentados por otros autores, si bien con adaptaciones y limitaciones debidas al ámbito concreto en el que se desarrolla el presente estudio. De forma particular, el simulador se ha equipado con una versión simplificada de un sistema ATO inspirado en el que opera en la red de metro de Madrid, al carecer de información suficiente respecto al sistema ATO que opera realmente en la red de metro

de Valencia. Esta limitación, si bien comprometería la capacidad del simulador para ser empleado en un estudio de optimización de marchas efectivo en el metro de Valencia, es aceptable en el marco de comparación de algoritmos objeto de la tesis.

El simulador desarrollado funciona dentro de los parámetros esperados, es capaz de calcular el perfil de velocidad respetando limitaciones de velocidad y otros condicionantes (seguridad de frenado, confort) y ha quedado validado en comparación con registros reales, con un error medio de predicción del tiempo de viaje del 1,43%. Esta cifra es algo superior a la alcanzada por otros autores (cuyos simuladores estiman el tiempo de viaje con un error alrededor del 1% o incluso inferior) pero se considera aceptable considerando las limitaciones en su implementación, fundamentalmente en relación con el sistema ATO.

7. Red neuronal

En esta sección se expone el desarrollo, entrenamiento y validación de una red neuronal capaz de calcular el consumo energético debido a tracción a partir del perfil de velocidad proporcionado por el simulador de marchas.

7.1. Introducción

Tal y como se ha explicado en la introducción del presente Capítulo, la estrategia de modelización de marchas y consumo escogida en el marco de la tesis comprende dos elementos: un simulador paso a paso de marchas que proporcione el perfil de velocidad y el tiempo total de viaje a partir de unos comandos ATO dados; y una red neuronal que tome dicho perfil de velocidad y proporcione el consumo energético de tracción correspondiente.

Como se vio en la revisión bibliográfica del Capítulo II, este enfoque de simulación difiere en parte del empleado por la mayoría de autores, que optan por calcular el consumo energético de forma directa a través de ecuaciones deterministas integradas en sus simuladores. La decisión de separar la modelización del consumo del modelo de marchas y plantearla a través de una red neuronal se justifica por varios motivos.

El primero se deriva de la información disponible sobre la que construir el simulador. Si bien se contaba con información suficiente sobre el material rodante empleado en la red de metro de Valencia para plantear un simulador de marchas (incluyendo curvas de frenado y tracción o coeficientes aerodinámicos) en cambio no se disponía de información relativa al sistema de tracción (rendimientos del motor, curvas consumo-velocidad, etc.), imprescindible para plantear las ecuaciones que calculasen el consumo energético en cada iteración del simulador.

Por el contrario, sí se disponía de abundantes datos de consumo registrados en condiciones reales de servicio durante la campaña de medición detallada en el Capítulo III. Estos datos contienen, de manera implícita, el conocimiento necesario para modelizar el consumo energético, y una red neuronal es una herramienta muy potente para detectar y representar la tendencia subyacente a dichos datos. De hecho, una red neuronal correctamente entrenada no depende de parámetros ni de conocimientos previos, no disponibles en este caso, y es capaz de modelizar relaciones no lineales de gran complejidad con precisión arbitraria y un coste de computación reducido (Bishop, 1995).

El otro motivo para emplear redes neuronales viene determinado por uno de los objetivos de la presente tesis, que es precisamente el de explorar el uso de esta clase de herramienta en la modelización del consumo energético. Como se vio en el Capítulo II, las redes neuronales se han empleado profusamente en otros campos, pero son una opción en la que apenas se ha profundizado en el ámbito que nos ocupa. Pocos autores han incorporado redes neuronales a sus planteamientos para resolver problemas de simulación y optimización de marchas y consumo energético en el ferrocarril, y los que lo han hecho las han empleado como elementos auxiliares. La presente tesis pretende contribuir al conocimiento relativo al uso de redes neuronales incorporándolas como un componente fundamental de la simulación.

En los siguientes apartados se detalla la estructura de red neuronal empleada, el proceso de entrenamiento y validación seguido y su integración con el simulador desarrollado en la Sección 6.

7.2. Estructura

Las redes neuronales artificiales son modelos computacionales inspirados conceptualmente por la estructura de los sistemas nerviosos biológicos. En líneas generales consisten en una serie de elementos simples (denominados neuronas) interconectados entre sí y que operan en paralelo, capaces de aprender a llevar a cabo determinadas tareas sin necesidad de proporcionarles rutinas o conocimientos específicos previos. En otras palabras, una red neuronal es capaz de formarse a sí misma e identificar tendencias o detectar soluciones en contextos donde una programación convencional explícita no es posible o resulta demasiado compleja.

Existen múltiples variantes y estructuras para una red neuronal, en gran medida dependientes de la clase de problema para la que va a ser empleada. Así, por ejemplo, se pueden usar redes neuronales para reconocimiento de patrones (por ejemplo, en aplicacio-

nes de visión artificial o reconocimiento de voz), para realizar predicciones temporales (por ejemplo, en aplicaciones bursátiles o predicción meteorológica), para procesamiento avanzado de datos (por ejemplo, para filtrado de señales y compresión de datos) o para ajustar funciones.

Es precisamente este último caso el que nos ocupa, ya que el objetivo es desarrollar una red que, alimentada con una serie de datos de entrada o input (como puede ser el perfil de velocidad de un vehículo y la geometría de la vía), sea capaz de proporcionar el consumo energético como salida u output. La estructura concreta escogida para tal fin es una red prealimentada de dos capas (*two-layer feed-forward*) tal y como se muestra en la Figura 7.1.

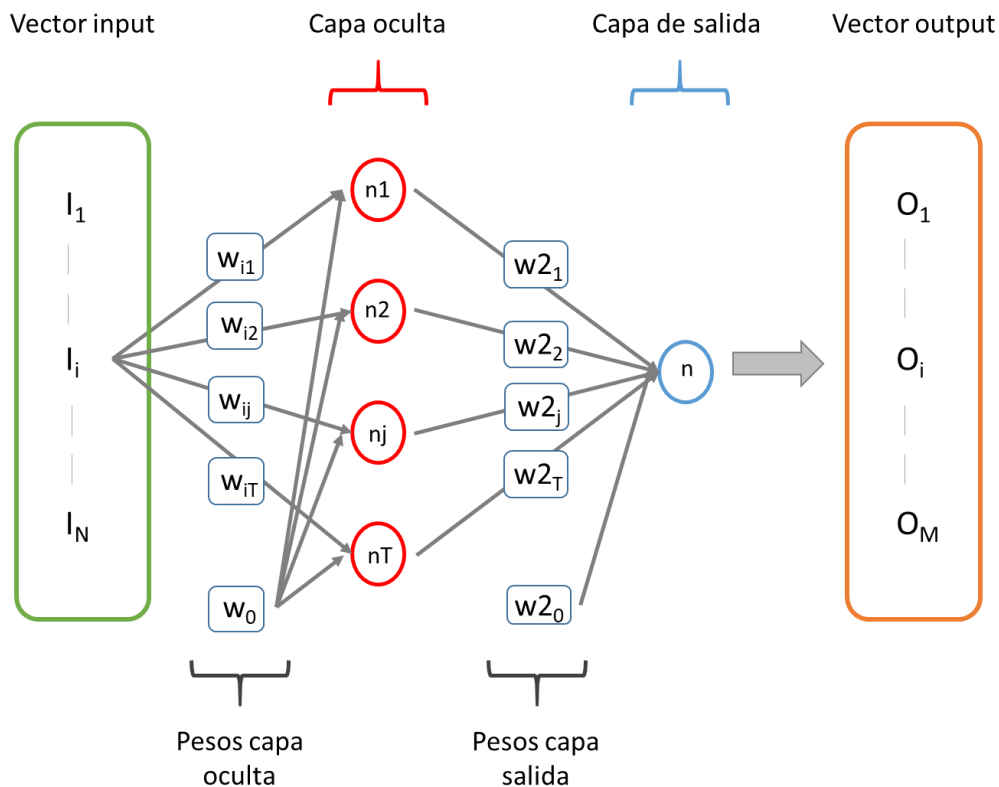


Figura 7.1: Esquema de una red neuronal prealimentada de dos capas. Fuente: Elaboración propia.

Esta clase de estructura ha sido empleada de forma muy extensa para el ajuste de funciones, y ha demostrado un gran potencial (Bishop, 1995). El vector de datos de entrada o input se transmite a la primera capa de neuronas (conocida como capa oculta o *hidden layer*), la cual contiene un número predeterminado de elementos. La definición de este

número (esto es, el tamaño de la red) es uno de los aspectos más importantes del proceso de creación y entrenamiento, tal y como se expone en el apartado 7.4.

Cada una de las neuronas de la capa oculta lleva asociada una función de transferencia que regula su salida, habitualmente una función log-sigmoide. La señal de cada neurona de esta primera capa se transmite a la segunda capa, o capa de salida (*output layer*), formada por una única neurona con una segunda función de transferencia, generalmente de tipo lineal. La salida de esta única neurona es el output global de la red neuronal. Nótese que algunos autores consideran el input de la red neuronal como una tercera capa, pero esta distinción es puramente semántica y no se emplea en la presente tesis.

Todo este proceso que constituye el funcionamiento de la red neuronal se puede expresar a través de la siguiente ecuación:

$$O_k = \hat{h}\left(\sum_{j=0}^M w_{2j} \cdot h\left(\sum_{i=0}^N w_{ij} \cdot I_i\right)\right) \quad (7.1)$$

Donde O_k es la salida de la red, M es el número de variables de salida, I_i es el input, N es el número de variables de entrada, h es la función de transferencia de las neuronas de la capa oculta, y \hat{h} es la función de transferencia de la neurona de la capa de salida. Por otra parte, los elementos w_{ij} y w_{2j} son los pesos que rigen las conexiones entre el input y la capa oculta, y entre ésta y la capa de salida, respectivamente. Existen además unos valores únicos w_0 y w_{20} , denominados sesgos o *bias*, que contribuyen a cada neurona de su respectiva capa. El ajuste del valor de estos pesos y sesgos es, precisamente, el elemento básico del proceso de entrenamiento de la red, tal y como se verá en el apartado 7.3. En cualquier caso, con este tipo de estructura, una red neuronal bien entrenada es capaz de identificar y aprender cualquier relación no lineal entre los datos de entrada y salida con precisión arbitraria (Bishop, 1995; Hagan et al., 2014).

7.3. Consideraciones para el entrenamiento de la red

En este apartado se trata el proceso de entrenamiento de la red neuronal, empleando para ello parte de los datos recopilados durante la campaña de medición detallada en el Capítulo III. Se definen los criterios y metodología empleados, y se discuten algunos factores claves tales como el tamaño de la red. Es importante destacar que todo el proceso de entrenamiento, validación y test de la red neuronal se realizó en el entorno de MATLAB 8.5.0 (The MathWorks, Inc.).

7.3.1. Procesado previo de los datos

Los datos de velocidad y consumo energético registrados en las líneas 1, 2, 3, 5 y 7 del metro de Valencia, así como los datos geométricos de dichas líneas proporcionados por el gestor de la infraestructura (FGV), constituyen la base sobre la que se lleva a cabo el entrenamiento de la red neuronal. Los registros de datos concretos disponibles consisten, para cada uno de los 229 servicios monitorizados, en:

- Registros de velocidad (en km/h).
- Registros de aceleración (en m/s²), obtenidos a partir de la velocidad.
- Potencia eléctrica neta en disyuntor (en kW).
- Potencia consumida en auxiliares (en kW).
- Potencia consumida en el freno reostático (en kW).

Además, para cada una de las líneas se cuenta con planos detallados de la pendiente longitudinal (en mm/m), curvatura en planta (en m⁻¹) y localización de las limitaciones de velocidad. De todos estos registros se toma como variable objetivo de la red la potencia eléctrica empleada para tracción, obtenida a partir de la diferencia entre la potencia neta de disyuntor y la potencia derivada a auxiliares y resistencias, de acuerdo a la siguiente ecuación:

$$P_T = P_{dis} - 1,5 \cdot P_{aux} - 2 \cdot P_{res} \quad (7.2)$$

Donde P_T es la potencia de tracción, P_{dis} es la potencia neta en el disyuntor, P_{aux} es la potencia consumida en auxiliares y P_{res} es la potencia disipada en las resistencias. Se aplica un coeficiente de 1,5 a la potencia de auxiliares y de 2 a la potencia de resistencias para tomar en consideración el hecho de que sólo se instalaron sensores en una de las dos cabinas de la unidad, tal y como se explicó en el Capítulo III. De acuerdo a información proporcionada por el operador de la línea, resulta razonable asumir que la energía regenerada sobrante se envía por igual a los dos frenos reostáticos (de ahí el factor 2) mientras que los dos sistemas auxiliares no funcionan al mismo nivel en todo momento (de ahí un factor de sólo 1,5).

De los 229 registros disponibles se toman seis de forma aleatoria, con el único condicionante de que haya al menos un registro de cada una de las líneas. De la combinación de estos seis registros aleatorios se obtiene un conjunto de datos (para cada una de las variables consideradas) con 22.162 elementos, más que suficiente para que la red sea ca-

paz de aprender las tendencias de consumo subyacentes a los datos. Este es el denominado conjunto de entrenamiento, si bien, como se verá en el apartado 7.3.2, no se emplea en su totalidad para este fin. La Figura 7.2 muestra un ejemplo de uno de los seis registros del conjunto de entrenamiento, correspondiente a la variable objetivo (potencia de tracción) y a una de las posibles variables input (velocidad).




Figura 7.2: Ejemplo de un registro de potencia de tracción y velocidad. Fuente: Elaboración propia.

Además, y con el objetivo de contar con otro conjunto de datos independiente para la validación, se toman y combinan otros tres registros aleatorios, que conforman un conjunto de 7.564 elementos. Este es el conjunto de test secundario, ya que el proceso de entrenamiento incluye un test primario, como se explicará en el apartado 7.3.2.

No obstante, antes de iniciar el proceso de entrenamiento, los datos precisan de un cierto tratamiento. Para empezar, al revisar los registros de potencia de tracción se observa un cierto nivel de ruido, particularmente en las fases de regeneración de energía donde la variable toma valor negativo y oscila notablemente (en comparación con las fases de aceleración, donde se observan picos claros de potencia). Esto es probablemente debido a que, mientras que el tren acelera de forma continuada, el frenado tiende a ser más irregu-

lar, y depende no sólo del sistema eléctrico sino también del sistema neumático, de modo que sólo una fracción variable de la energía cinética del vehículo es convertida en energía eléctrica regenerada.

En cualquier caso, esta irregularidad en las fases de frenado y regeneración puede afectar al proceso de entrenamiento de la red neuronal, de modo que los registros de potencia de tracción se tratan mediante un filtro de Butterworth paso-bajo. Se probaron diferente número de polos para el filtro (de 1 a 4) y diferentes frecuencias de corte (entre 0,05 y 2 Hz), pero finalmente se optó por un filtro con cuatro polos y una frecuencia de corte de 0,15 Hz ya que esta configuración es la que elimina una mayor componente del ruido sin afectar a los picos de la señal. La Figura 7.3 muestra un ejemplo de una parte de la señal original y su correspondiente versión filtrada.




Figura 7.3: Comparativa entre un fragmento de la señal original de potencia de tracción y su versión filtrada. Fuente: Elaboración propia.

Finalmente, todos los registros (tanto los de potencia de tracción como los de velocidad, aceleración o geométricos) se normalizan dentro del rango $[-1, 1]$, para evitar la saturación de la función log-sigmoide. Esto es práctica habitual en el proceso de entrenamiento de redes neuronales (Bishop, 1995).

7.3.2. Metodología de entrenamiento

La metodología seguida para entrenar la red neuronal es la denominada retropropagación o *backpropagation*, que consiste en un ciclo iterativo en el que se van modificando los valores de los pesos en función del resultado que va obteniendo la red y su grado de

error. En cada iteración se compara la salida de la red con el registro de datos objetivo, se evalúa el error y esta información se propaga hacia atrás, es decir, hacia las neuronas de la capa oculta, de manera que se modifica el peso de cada una en función de su contribución a la salida de la red.

La función de error empleada es el Error Cuadrático Medio (ECM) definido de acuerdo a la siguiente ecuación:

$$ECM = \frac{1}{N} \sum_{i=1}^N (t_i - o_i)^2 \quad (7.3)$$

Donde N es el número de datos, t_i es el valor objetivo y o_i es la salida de la red. El algoritmo específico empleado para el entrenamiento es el denominado Levenberg-Marquardt, que busca minimizar el valor del ECM en función de los valores de pesos y sesgo de la red neuronal. Se trata de un algoritmo potente y eficiente que se ha empleado extensivamente para el entrenamiento de redes neuronales (Bishop, 1995).

Por otra parte, uno de los principales problemas que pueden afectar a la efectividad de una red neuronal es el denominado sobre-aprendizaje u *overfitting*, consistente en que la red neuronal, durante su aprendizaje, adquiera los sesgos y errores particulares del conjunto de datos empleados para su entrenamiento, en vez de la tendencia general subyacente a los mismos. Una red sobre-aprendida da un ajuste aparentemente muy bueno respecto a los datos empleados para su entrenamiento, que se torna en errores excesivos cuando se la expone a otro conjunto de datos con sesgos diferentes.

El sobre-aprendizaje está fuertemente influenciado por el tamaño de la red: una red con un gran número de neuronas ajustará mejor los datos de entrenamiento pero tendrá un mayor riesgo de sobre-aprender, mientras que una red demasiado pequeña no tendrá los grados de libertad necesarios para modelizar correctamente el fenómeno en cuestión. Por lo tanto, es necesario determinar el número óptimo de neuronas en la capa oculta.

Si bien existen algunas reglas empíricas sencillas para ello, su uso no es recomendable ya que no están convenientemente validadas (Hagan et al., 2014). El enfoque más habitual es emplear la metodología de detención temprana o *early stopping*, que consiste en chequear el entrenamiento paso a paso y detenerlo cuando se detecta que la red está empezando a sobre-aprender (Bishop, 1995; Hagan et al., 2014).

La detención temprana se lleva a cabo dividiendo aleatoriamente el conjunto de datos de entrenamiento en tres subconjuntos: Un primer subconjunto (*training*), correspondiente al 70% de los datos, se emplea para el proceso de entrenamiento propiamente dicho. Un segundo subconjunto (*validation*, el 15% de los datos) se emplea para comprobar el resultado de la red en cada iteración de manera que, si el ECM respecto al subconjunto de validación empieza a aumentar (aunque el ECM del conjunto de entrenamiento siga estable o bajando) se considera que la red está sobre-aprendiendo y se detiene el proceso de entrenamiento. En ese punto se emplea el tercer subconjunto (*test*, el 15% restante) para comprobar el rendimiento final de la red.

Aplicando el método de detención temprana se evita hasta cierto punto el problema del sobre-aprendizaje, de tal modo que no hay un límite *a priori* para el tamaño de la red neuronal: cuantas más neuronas haya en la capa oculta, mejor (Tetko et al., 1995). Sin embargo, también es conveniente obtener una red neuronal lo más simple posible, tanto para reducir la carga de computación como por el principio de parsimonia. Para ello, es conveniente empezar el proceso de entrenamiento con un número limitado de neuronas (en nuestro caso, 10) e ir incrementando el tamaño en busca de un mejor ajuste. Cada versión de la red se emplea después con el conjunto de test secundario antes mencionado, y cuando se observa que redes de mayor tamaño no mejoran el ajuste con este conjunto adicional de datos, se dejan de añadir neuronas a la capa oculta.

Por último, el otro aspecto a determinar durante el entrenamiento es la selección de las variables de entrada a emplear. Se consideraron hasta cuatro variables diferentes (velocidad y aceleración del vehículo, y pendiente y curvatura de la línea) y sus diferentes combinaciones hasta hallar el conjunto que daba un mejor ajuste con los datos objetivo, teniendo en cuenta los aspectos de sobre-aprendizaje y tamaño antes mencionados.

7.3.3. Criterios de evaluación del entrenamiento

Para poder evaluar el proceso de entrenamiento de la red neuronal, determinar la mejor combinación de variables de entrada y el número óptimo de neuronas en la capa oculta, se fijan una serie de criterios. Además de minimizar en términos absolutos el ECM tal y como se formula en la ecuación (7.3), también se define el llamado Error Cuadrático Medio relativo, o ECM_r, de acuerdo a la siguiente expresión:

$$ECMr = \frac{ECM}{Var(T)} \tag{7.4}$$

Donde $Var(T)$ es la varianza de la variable objetivo, es decir, la potencia de tracción. El propósito de este indicador es medir la proporción de la varianza de los datos no explicada por el modelo, lo que permite evaluar la dependencia que la red neuronal tiene de los datos concretos utilizados para su entrenamiento (Molines et al., 2018).

En base a este criterio, se establece el siguiente proceso de entrenamiento (véase Figura 7.4), basado en el trabajo de Molines et al. (2018): Cada una de las cuatro posibles variables de entrada se emplea por separado como único input para una red neuronal diferente. Cada una de estas cuatro redes se somete a 100 procesos de entrenamiento, para evitar el efecto que la división aleatoria del conjunto de datos pueda tener en el proceso, y se calcula el valor promedio del ECMr de cada una de las tres fases de entrenamiento con detención temprana (esto es, entrenamiento propiamente dicho, validación y test).

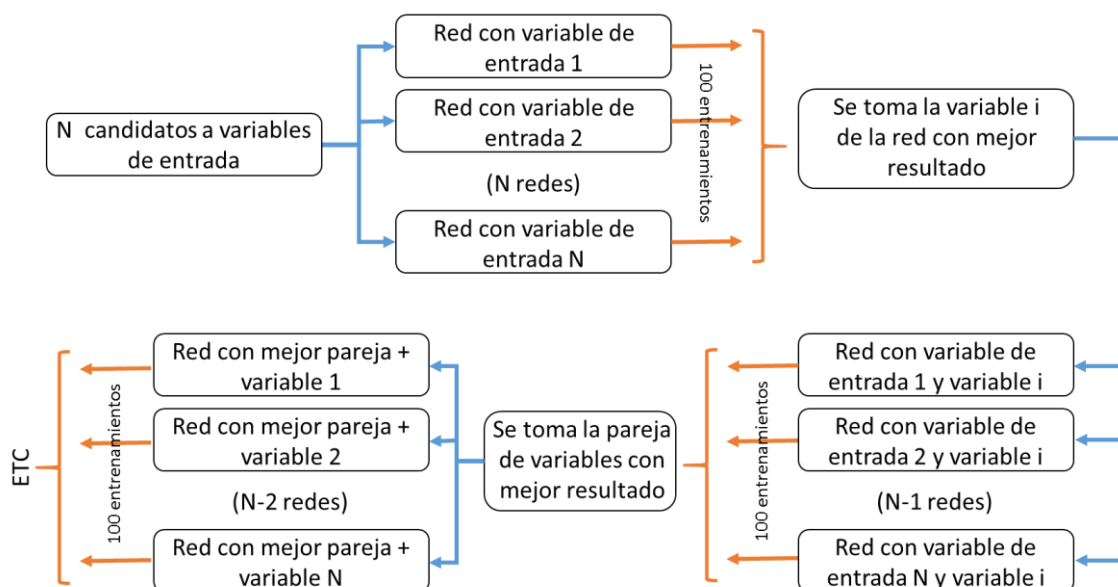


Figura 7.4: Esquema del proceso de entrenamiento. Fuente: Elaboración propia.

La variable de entrada con un menor valor de ECMr para las tres fases se empareja con las restantes para entrenar nuevas redes, cada una con dos variables de entrada en este caso. Se repite de nuevo el proceso de 100 entrenamientos, y la pareja con mejor resultado se combina con cada una de las variables restantes para un nuevo ciclo de entrenamiento, y así sucesivamente mientras el hecho de añadir variables de entrada aporte mejoras en el ajuste de los datos objetivo.

Una vez determinadas las variables de entrada, se evalúa el tamaño de la red teniendo en cuenta las consideraciones mencionadas en el apartado 7.3.2. Finalmente, como crite-

rio último de aceptación, se establece un valor máximo del ECMr en todas las fases del proceso igual a 0,25, es decir, que la red neuronal completamente entrenada debe ser capaz de explicar un 75% o más de la varianza de los datos empleados para su entrenamiento. Este umbral de aceptación es en cierto modo arbitrario, pero está en línea con lo que otros autores (Molines et al., 2018; Molines y Medina, 2014) han considerado aceptable al entrenar sus redes neuronales.

7.4. Entrenamiento de la red

En este apartado se recogen los resultados del proceso de entrenamiento de la red neuronal, en base a la metodología y criterios establecidos en el apartado 7.3. Como ya se explicó en dicho apartado, el primer paso del proceso de entrenamiento comprende la selección de las variables de entrada de la red en base al procedimiento iterativo resumido en la Figura 7.4. En este sentido, la Tabla 7.1 recoge los resultados obtenidos para cada una de las posibles combinaciones de variables de entrada, donde cada valor es un promedio de 100 entrenamientos y se incluye el resultado con el conjunto independiente de test secundario (denominado como test 2).

| Variable | Entrenamiento | | Validación | | Test | | Test 2 | |
|-------------------------------|---------------|--------------|-------------|--------------|-------------|--------------|-------------|--------------|
| | R | ECMr | R | ECMr | R | ECMr | R | ECMr |
| Primera ronda | | | | | | | | |
| Velocidad | 0,30 | 0,908 | 0,30 | 0,908 | 0,30 | 0,908 | 0,26 | 0,934 |
| Aceleración | 0,74 | 0,460 | 0,73 | 0,460 | 0,73 | 0,466 | 0,75 | 0,445 |
| Pendiente | 0,27 | 0,928 | 0,27 | 0,926 | 0,26 | 0,931 | 0,18 | 0,974 |
| Curvatura | 0,09 | 0,992 | 0,09 | 0,990 | 0,08 | 0,996 | 0,04 | 1,000 |
| Segunda ronda | | | | | | | | |
| Aceleración + Velocidad | 0,87 | 0,237 | 0,87 | 0,240 | 0,87 | 0,238 | 0,92 | 0,156 |
| Aceleración + Pendiente | 0,77 | 0,411 | 0,76 | 0,416 | 0,77 | 0,414 | 0,79 | 0,373 |
| Aceleración + Curvatura | 0,74 | 0,458 | 0,73 | 0,465 | 0,73 | 0,461 | 0,75 | 0,439 |
| Tercera ronda | | | | | | | | |
| Acel. + Velocidad + Pendiente | 0,89 | 0,203 | 0,89 | 0,208 | 0,89 | 0,204 | 0,93 | 0,131 |
| Acel. + Velocidad + Curvatura | 0,87 | 0,236 | 0,87 | 0,241 | 0,87 | 0,237 | 0,92 | 0,157 |
| Última ronda | | | | | | | | |
| Cuatro variables combinadas | 0,89 | 0,201 | 0,90 | 0,200 | 0,89 | 0,201 | 0,93 | 0,132 |

Tabla 7.1: Resultados promedio para cada combinación de variables de entrada después de 100 entrenamientos. Fuente: Elaboración propia.

Como se ve en la Tabla 7.1, resulta evidente que la aceleración del vehículo es la más influyente de las cuatro variables consideradas, ya que arroja valores de ECMr claramente inferiores al resto. La tabla también muestra el coeficiente de correlación de Pearson (R) entre la salida de la red y la variable objetivo, siendo el valor más elevado el obtenido por la red configurada con la aceleración como variable de entrada. Por todo ello, se toma la aceleración como primera variable de entrada y se empareja con las otras tres durante la segunda ronda del proceso.

El mejor de estos emparejamientos resulta ser la combinación de aceleración y velocidad, una combinación que ya logra un valor de ECMr por debajo del 25% tanto en las tres fases de entrenamiento como en la comprobación adicional. Añadir la pendiente como tercera variable aporta también una cierta mejora (un ECMr en el test secundario del 13% en vez del 16%). Por último, si bien incorporar la curvatura apenas modifica el resultado, al final se optó por emplear las cuatro variables de entrada ya que sí ofrecen un resultado

algo mejor en otros test independientes que se realizaron durante la validación (véase apartado 7.6).

Por tanto, en lo que a variables de entrada se refiere, la red neuronal queda fijada con cuatro inputs: velocidad y aceleración del vehículo, y pendiente y curvatura de la vía.

7.5. Tamaño de la red

Como se ha comentado en el apartado 7.3, el tamaño de la red (esto es, el número de neuronas en su capa oculta) es uno de los aspectos clave en el proceso de creación y entrenamiento. Para determinar este parámetro, se parte de una red neuronal con cuatro inputs y 10 neuronas y se la somete a 100 ciclos de entrenamiento, obteniendo los valores de ECMr promedio correspondientes a cada etapa del proceso. A continuación se incrementa el número de neuronas y se repiten los 100 ciclos de entrenamiento, y así sucesivamente. La Figura 7.5 recoge los resultados de este proceso.




Figura 7.5: ECMr promedio en función del tamaño de la red. Fuente: Elaboración propia.

Como se ve en la figura, los valores promedio de ECMr para el entrenamiento propiamente dicho tienden a disminuir conforme aumenta el tamaño de la red, mientras que los valores correspondientes a la validación y test tienden a estabilizarse en torno al 20%. Esto pone de manifiesto cómo una mayor complejidad del modelo (en la forma de más neuronas y por tanto más grados de libertad) es capaz de un ajuste mejor de los datos, y cómo el método de detención temprana limita en parte el riesgo de sobre-aprendizaje (ya que de lo contrario los valores de ECMr de validación y test aumentarían a partir de cierto punto).

Sin embargo, el valor del ECMr obtenido de enfrentar la red neuronal al segundo conjunto de test independiente muestra una cierta tendencia a aumentar, que se dispara especialmente a partir de las 120 neuronas, para superar el ECMr de entrenamiento por encima de 160 neuronas. Esto puede indicar un cierto sobre-aprendizaje, de modo que, teniendo en cuenta este resultado y el objetivo de obtener un modelo lo más simple posible, el tamaño óptimo de la red se fija en 50 neuronas en la capa oculta. Esta configuración arroja un ECMr de entrenamiento del 19% y un ECMr de test secundario del 14%, valores ambos por debajo del umbral prefijado del 25%.

7.6. Validación de la red

Una vez fijadas tanto las variables de entrada como el tamaño óptimo de la red, se procede a su proceso de entrenamiento definitivo. En este sentido, la Figura 7.6 muestra la comparación entre la salida de la red completamente entrenada y el registro de potencia de tracción empleado para su entrenamiento (incluyendo los subconjuntos de validación y test).




Figura 7.6: Comparativa de potencia de tracción real vs modelizada por la red neuronal para el conjunto de entrenamiento. Fuente: Elaboración propia.

Como se ve en la figura, la red neuronal ofrece un buen ajuste global de la potencia de tracción del vehículo, y es especialmente precisa a la hora de modelizar los picos de potencia cuando el tren está traccionando. Por el contrario, la red neuronal tiene a minusvalorar los picos de regeneración de energía, probablemente por la irregularidad en los datos comentada en el apartado 7.3.1, si bien la diferencia es asumible. De hecho, la Tabla 7.2 recoge el resultado definitivo de los valores de ECMr de la red finalmente entrenada, y todos ellos se encuentran por debajo del requisito del 25%.

| | Entrenamiento | Validación | Test | Test 2 |
|------|---------------|------------|------|--------|
| ECMr | 0,19 | 0,20 | 0,20 | 0,14 |

Tabla 7.2: Resultados de ECMr definitivos de la red entrenada. Fuente: Elaboración propia.

La Figura 7.7 muestra la comparación entre datos objetivo y salida de la red correspondiente al conjunto independiente de datos empleado como test secundario. De nuevo se observa el mismo buen ajuste general, mejor en los picos de tracción y algo peor en las fases de regeneración durante la frenada.




Figura 7.7: Comparativa de potencia de tracción real vs modelizada por la red neuronal para el conjunto de test independiente. Fuente: Elaboración propia.

En último término, el propósito de esta red neuronal es modelizar el consumo energético resultante de un determinado trayecto entre dos estaciones, por lo que nos interesa validar su efectividad a la hora de estimar este valor global, en vez del valor instantáneo de potencia eléctrica. Para ello, la Tabla 7.3 recoge el valor de consumo global real y el estimado por la red neuronal para el conjunto de datos de entrenamiento, el conjunto independiente de test y los 4 casos de control empleados para validar el simulador de marchas (véase Sección 6).

| Conjunto de datos | Consumo real (kWh) | Consumo estimado (kWh) | Diferencia (%) |
|--|--------------------|------------------------|----------------|
| Entrenamiento | 573,51 | 562,04 | 2,00 |
| Test secundario | 267,40 | 291,72 | 9,09 |
| Control 1 (Amistat-Aragón) | 3,59 | 3,17 | 11,70 |
| Control 2 (Patriaix-Safranar) | 6,74 | 6,89 | 2,23 |
| Control 3 (Àngel Guimerà-Pl. Espanya) | 3,22 | 3,27 | 1,55 |
| Control 4 (Picanya-Paiporta) | 6,60 | 6,80 | 3,03 |
| Error medio | | | 1,49 |

Tabla 7.3: Comparativa de consumo global real vs consumo estimado por la red neuronal para diferentes conjuntos de datos. Fuente: Elaboración propia.

Como se puede ver en la tabla, si bien en un caso el error en la estimación del consumo global aumenta hasta cerca del 12% (probablemente al tratarse de un tramo en el que la regeneración de energía cobra mayor importancia, o por el pico de velocidad que se da al inicio del tramo y que el simulador no registra) por lo general la red neuronal ofrece una buena aproximación al valor de consumo energético debido a tracción, con un error medio del 1,49%, cercano al nivel que otros autores han logrado alcanzar con sus simuladores (véase Tabla 3.1 en la Sección 3).

También es importante considerar que, dado que el objetivo principal de la tesis es comparar la efectividad de diferentes algoritmos de optimización, y no realizar una verdadera optimización de marchas en la red de metro de Valencia, se puede asumir un cierto grado de error en la estimación del consumo, ya que éste afectará a todos los algoritmos por igual y no influirá en la comparativa.

Por todo ello, se considera que la red neuronal ha quedado validada como herramienta para calcular el consumo energético de los perfiles de velocidad calculados con el simulador desarrollado en la Sección 6.

7.7. Conclusiones

En la presente sección se ha abordado la creación, entrenamiento y validación de una red neuronal capaz de calcular el consumo energético de tracción a partir del perfil de velocidad modelizado por el simulador de marchas. Se ha desarrollado una red de 50

neuronas en su capa oculta, con cuatro variables de entrada (velocidad y aceleración del vehículo, y pendiente longitudinal y curvatura de la vía) y una única variable de salida (potencia instantánea de tracción).

La red se ha entrenado de forma exhaustiva, y cumple con los requisitos preestablecidos de aceptación: su Error Cuadrático Medio relativo a la varianza de los datos objetivo (ECMr) ronda el 20%, lo que implica que la red, como modelo de predicción, es capaz de explicar hasta un 80% de la varianza de los datos de potencia de tracción empleados para su entrenamiento, validación y comprobaciones adicionales.

En términos de predicción de consumo energético global, la red da un error medio del 1,49% respecto a los datos reales, cifra del mismo orden de magnitud que la alcanzada por otros autores con sus simuladores de consumo, por lo que se considera que la red está correctamente entrenada y podrá cumplir con su función como componente del modelo de marchas y consumo desarrollado.

8. Algoritmos de optimización

En la presente sección se aborda la formulación de los algoritmos de optimización escogidos para su comparación, así como la definición de las métricas y criterios elegidos para evaluar el rendimiento de cada uno.

8.1. Introducción

Como se expuso en el Capítulo I, uno de los principales objetivos de la presente tesis es llevar a cabo una comparativa sistemática del rendimiento y la eficiencia de diferentes algoritmos meta-heurísticos de optimización empleados para resolver problemas de optimización de marchas en el ámbito de la ingeniería ferroviaria.

El problema de optimización específico a resolver, que sirve de marco para esta comparativa, se define en base a los criterios discutidos en el Capítulo II, Sección 4, así como a las características de la red de metro de Valencia expuestas en el Capítulo III (apartado 5.5). Así pues, el estudio se centra en las líneas 1, 2, 3, 5 y 7 de la red de metro Valencia, en sus tramos operados automáticamente mediante ATO.

Dicho sistema ATO se ha modelizado (véase Sección 6 del presente Capítulo IV) de tal manera que fija cuatro comandos para cada vehículo a la salida de cada estación: deceleración final de llegada a estación (d), velocidad de regulación (v_h), velocidad de deriva (v_d) y velocidad de remotorización (v_r). Estos cuatro comandos condicionan el perfil de velocidad a aplicar en cada tramo inter-estación en las cinco líneas consideradas.

El objetivo es optimizar los valores de estos cuatro comandos para definir perfiles de velocidad que minimicen el consumo energético y no comprometan el tiempo de viaje. Lo

que se espera de cada algoritmo de optimización es que rastree el espacio de soluciones y encuentre configuraciones de los comandos ATO que definan soluciones no-dominadas, es decir, que ofrezcan una aproximación al frente de Pareto real para cada uno de los tramos inter-estación de las líneas consideradas. La comparativa se centrará en evaluar hasta qué punto y con qué eficacia cada algoritmo logra cumplir esta tarea.

8.2. Selección de algoritmos de optimización

Tal y como se explicó en la Sección 4, Capítulo II, existen multitud de algoritmos diferentes dentro de la categoría de meta-heurísticos, pero sólo algunos de ellos (con sus diversas variantes) se han empleado con cierta asiduidad para resolver problemas de optimización de marchas ferroviarias como el que nos ocupa. Para seleccionar los algoritmos que se van a someter a la comparativa objeto de la presente tesis, se han establecido los siguientes criterios:

- Se escogerán algoritmos cuyo uso esté asentado y hayan demostrado su efectividad (sea o no en el ámbito concreto de la optimización de marchas ferroviarias).
- Deberán ser algoritmos que ofrezcan algún aspecto novedoso o particularidad que los diferencie de los restantes escogidos.
- Se tratará de cubrir de forma equitativa al menos las principales sub-categorías de algoritmos meta-heurísticos.

De acuerdo a estos criterios, se han escogido los siguientes algoritmos:

- Algoritmo Genético No-dominado Clasificado (**NSGA-II**): Como se vio en el Capítulo II, este algoritmo es, con diferencia, el más utilizado, hasta el punto de que suele emplearse como estándar para evaluar las posibles ventajas de otros algoritmos. Por este mismo motivo se ha escogido para la presente comparativa.
- Algoritmo Multi-Objetivo de Enjambre de Partículas (**MOPSO**): Este algoritmo es el más habitual de la subcategoría de inteligencia de enjambre, y si bien no hay muchos ejemplos de su aplicación a la optimización de marchas, algunos autores defienden su mejor rendimiento respecto al convencional NSGA-II, de ahí su elección.
- Algoritmo Evolutivo de Frente de Pareto (**SPEA-II**): Se trata de una variante de algoritmo evolutivo apenas empleada en la optimización de marchas, pero que ofrece un enfoque alternativo al incorporar mecanismos elitistas diferentes de los usados con el NSGA-II. Por eso se ha escogido para la presente comparativa.

- Algoritmo Evolutivo basado en Descomposición (**MOEA-D**): Otra variante de algoritmo evolutivo que, de acuerdo a la revisión bibliográfica (véase Capítulo II), no se ha empleado hasta la fecha para la optimización de marchas, pero sí se ha usado con éxito en otros campos. El principal motivo para escogerlo es que incorpora una estrategia de resolución de problemas de optimización (la descomposición) que ninguno de los restantes algoritmos emplea de forma explícita.
- Algoritmo Multi-Objetivo de Colonia de Hormigas (**MOACOr**): Si bien sí se ha usado la versión más convencional de este algoritmo (ACO) en algún problema de optimización en el ámbito ferroviario, no se han encontrado ejemplos en la bibliografía de uso de la variante multi-objetivo para dominios continuos. El motivo para escoger este algoritmo es el de incorporar un segundo representante de la categoría de algoritmos de inteligencia de enjambre, así como probar el potencial de esta variante multi-objetivo menos conocida.

En el siguiente apartado se resume la implementación específica de cada uno de estos cinco algoritmos.

8.3. Implementación de algoritmos de optimización

Los cinco algoritmos escogidos se han implementado en MATLAB 8.5.0 (The MathWorks, Inc.). En los cinco casos se ha partido de un código abierto (*open source*) descargado del repositorio *www.yarpiz.com*, que se ha modificado convenientemente para adaptarlo al problema concreto de optimización que nos ocupa.

Es importante destacar que todos y cada uno de los cinco algoritmos dependen de la definición de una serie de parámetros (tales como tamaño de población, número de iteraciones u otros). Si bien se ha tratado de explorar la bibliografía para determinar en qué rangos se suelen fijar estos parámetros, al final se optó por llevar a cabo un análisis de sensibilidad de cada algoritmo, en base a las métricas de funcionamiento definidas en el apartado 8.4. El resultado de este análisis de sensibilidad y el valor definitivo de los diferentes parámetros de cada algoritmo puede verse en el Capítulo V.

8.3.1. NSGA-II

La versión del algoritmo genético empleado es la bien conocida NSGA-II, que incorpora mecanismos elitistas para clasificar las soluciones que el algoritmo va encontrando en función de criterios de no-dominación. El código base ha sido modificado para incorporar el simulador de marchas y consumo (mediante red neuronal) como función de coste, y

también incorpora un criterio de *Crowding Distance* para mejorar la diversidad de las soluciones.

El algoritmo incorpora mecanismos de cruce de individuos (con dos progenitores) y de mutación aleatoria. El genoma de cada individuo del algoritmo consiste en el valor de los cuatro comandos del sistema ATO (d, v_h, v_d, v_r). Durante las fases de cruce y mutación, se ha incorporado un mecanismo para evitar que se generen soluciones incompatibles con el simulador de marchas (esto es, soluciones que combinen valores no nulos de las tres velocidades simultáneamente, o valores de velocidad de remotorización superiores a la velocidad de deriva).

Los principales parámetros definitorios del algoritmo NSGA-II son:

- Tamaño de la población (N): Es decir, el número de individuos que componen la población a evolucionar.
- Número de iteraciones (IT): Este valor determina el criterio de finalización del algoritmo.
- Porcentaje de cruce ($\%C$): Este parámetro determina qué fracción de cada generación se escoge para su cruce.
- Porcentaje de mutación ($\%M$): Este parámetro determina qué fracción de cada generación sufre una mutación.
- Tasa de mutación (TM): Este parámetro determina el grado de la mutación que sufren los individuos mutados.

8.3.2. MOPSO

El MOPSO es uno de los algoritmos de inteligencia de enjambre más populares. El código base ha sido modificado para incorporar el simulador de marchas y consumo (mediante red neuronal) como función de coste, mientras que cada partícula se define a través de los cuatro comandos del sistema ATO (d, v_h, v_d, v_r). Por otra parte, la versión del MOPSO empleada incluye también una componente aleatoria de mutación para mejorar la distribución de las soluciones halladas. Al igual que ocurría con el NSGA-II, se han incorporado mecanismos para evitar que se generen soluciones incompatibles con el simulador de marchas y consumo durante cada ciclo del algoritmo.

Los principales parámetros definitorios del algoritmo MOPSO son:

- Tamaño de la población (M): Es decir, el número de partículas que componen el enjambre.
- Número de iteraciones (IT): Valor que determina el criterio de finalización del algoritmo.
- Tamaño del archivo (ARC): Es decir, el número de soluciones no-dominadas que se almacenan en cada iteración, y que constituyen la solución final del algoritmo.
- Peso inercial (w): parámetro que regula el vuelo de cada partícula por el espacio de soluciones.
- Amortiguamiento del peso inercial (Aw): Parámetro que regula la atenuación del peso inercial conforme se desarrolla el algoritmo.
- Coeficiente personal ($c1$): parámetro que controla la influencia de la mejor solución personal en el vuelo de la partícula.
- Coeficiente global ($c2$): parámetro que controla la influencia de la mejor solución global en el vuelo de la partícula.
- Tasa de mutación (TM): Este parámetro determina el grado de la mutación que sufren los individuos mutados.

8.3.3. SPEA-II

El algoritmo SPEA-II es una variante de algoritmo evolutivo con mecanismos elitistas. Siguiendo el mismo proceso que con los restantes algoritmos, el código base ha sido modificado para incorporar el simulador de marchas y consumo (mediante red neuronal) como función de coste. Por otra parte, al igual que en NSGA-II, el genoma de cada individuo incorpora los cuatro comandos del sistema ATO (d, v_h, v_d, v_r), y se han incluido mecanismos que eviten combinaciones incompatibles de dichos comandos.

La principal diferencia entre SPEA-II y NSGA-II es que el primero incorpora un archivo que almacena las mejores soluciones en cada iteración, y sólo los individuos pertenecientes a dicho archivo se escogen para su cruce (en vez de seleccionar entre toda la población). Además, el mecanismo de cruce se basa en torneo binario en vez de en selección aleatoria como en el NSGA-II, y el porcentaje de mutación se define en base al porcentaje de cruce en vez de ser un parámetro independiente.

Los principales parámetros definitorios del algoritmo SPEA-II son:

- Tamaño de la población (M): Es decir, el número de individuos que componen la población a evolucionar.

- Número de iteraciones (IT): Valor que determina el criterio de finalización del algoritmo.
- Tamaño del archivo (ARC): Es decir, el número de soluciones no-dominadas que se almacenan en cada iteración, y que constituyen la solución final del algoritmo.
- Porcentaje de cruce ($\%C$): Este parámetro determina qué fracción de cada generación se escoge para su cruce.
- Parámetro de cruce (PC): Este parámetro determina la distribución del genoma de cada progenitor en el descendiente. Si bien también se aplica una componente aleatoria, este parámetro condiciona en parte el proceso de cruce, en vez de ser completamente aleatorio como en el NSGA-II.
- Tasa de mutación (TM): Este parámetro determina el grado de la mutación que sufren los individuos mutados.

8.3.4. MOEA-D

El algoritmo MOEA-D es otra variante de algoritmo evolutivo que incorpora el mecanismo de descomposición del problema multi-objetivo en varios problemas de un único objetivo para su resolución. Una vez más, el código base ha sido modificado para incorporar el simulador de marchas y consumo (mediante red neuronal) como función de coste. Por otra parte, al igual que en NSGA-II, el genoma de cada individuo incorpora los cuatro comandos del sistema ATO (d, v_h, v_d, v_r), y se han incluido mecanismos que eviten combinaciones incompatibles de dichos parámetros.

El enfoque de descomposición del problema está basado en el método de *Boundary Intersection*, ya que es el más apropiado para problemas continuos como el que nos ocupa (véase Capítulo II, Sección 4). Por otra parte, el método de definición del vecindario para cada sub-problema se basa en delimitar un porcentaje de los vecinos más próximos, con un valor máximo de 15 y mínimo de 2.

Los principales parámetros definitorios del algoritmo MOEA-D son:

- Tamaño de la población (N): En este caso, este parámetro es equivalente al número de subdivisiones en que se descompone el problema multi-objetivo global.
- Número de iteraciones (IT): Valor que determina el criterio de finalización del algoritmo.
- Tamaño del archivo (ARC): Es decir, el número de soluciones no-dominadas que se almacenan en cada iteración, y que constituyen la solución final del algoritmo.

- Parámetro de cruce gamma (PCG): Este parámetro regula la distribución del genoma de cada progenitor tras un cruce, de un modo similar a lo visto en el algoritmo SPEA-II.
- Porcentaje de definición de vecindario ($\%V$): Este parámetro determina el alcance del vecindario de cada sub-problema.

8.3.5. MOACOr

El MOACOr constituye una variante del algoritmo de Colonia de Hormigas (ACO) modificado para acometer problemas multi-objetivos con variables continuas. En este caso, el código base se corresponde con un algoritmo ACO_r (con distribución Gaussiana), de manera que puede lidiar con variables continuas, pero no con un enfoque multi-objetivo. Por ello, dicho código se ha modificado siguiendo las recomendaciones de Garcia-Najera y Bullinaria (2007) para lograr una variante MOACOr. Para ello se ha incorporado un archivo en el que se almacenan las mejores soluciones en base a criterios de no-dominación y *Crowding Distance*.

Al igual que en los casos anteriores, el algoritmo incorpora el simulador de marchas y consumo como función de coste, define cada hormiga en base a los cuatro comandos ATO e incorpora mecanismos para evitar soluciones incompatibles con el simulador.

Los principales parámetros definatorios del algoritmo MOACOr son:

- Tamaño de la población (M): En este caso, este parámetro representa el número de hormigas que rastrean el espacio de soluciones.
- Número de iteraciones (IT): Valor que determina el criterio de finalización del algoritmo.
- Tamaño del archivo (ARC): Es decir, el número de soluciones no-dominadas que se almacenan en cada iteración, y que constituyen la solución final del algoritmo.
- Parámetro de pesos (q): Este parámetro regula el proceso de selección de soluciones ya encontradas que cada hormiga realiza para buscar nuevas soluciones.
- Parámetro de evaporación de feromona (ξ): Este parámetro determina en la práctica el equilibrio entre convergencia del algoritmo y amplitud del frente de búsqueda.

8.4. Definición de métricas

Para evaluar el rendimiento de cada algoritmo y poder realizar una comparación bien fundamentada, se han definido una serie de métricas en base a los trabajos de Coello Coello et al. (2004) y Jiménez et al. (2013). El propósito último de estas métricas es evaluar las dos principales características de las soluciones proporcionadas por cada algoritmo de optimización, tal y como se vio en el Capítulo II, Sección 4: convergencia (esto es, proximidad al frente de Pareto real) y diversidad (esto es, distribución por todo el frente). También se busca medir la regularidad del conjunto de soluciones aportado, es decir, cuán uniformemente distribuido está dicho conjunto, una característica que se relaciona con la diversidad.

Además de las métricas aquí consignadas, también se ha tenido en cuenta como criterio de comparación el tiempo de ejecución de cada algoritmo.

8.4.1. Distancia Generacional (GD)

La Distancia Generacional, o *Generational Distance* (GD), mide la proximidad de las soluciones proporcionadas por el algoritmo al frente de Pareto real (y por tanto precisa que dicho frente sea conocido). Esta métrica se define en base a la siguiente ecuación:

$$GD = \frac{\sqrt{\sum_{j=1}^{NI} d_j^2}}{NI} \quad (8.1)$$

Donde d_j es la distancia Euclídea entre la j -ésima solución y el punto más próximo perteneciente al frente de Pareto real, y NI es el número de soluciones encontradas por el algoritmo. Cuanto más próximo a cero sea el valor de GD, mayor convergencia entre la solución del algoritmo y el frente real.

8.4.2. Extensión (SPR)

La Extensión o *Spread* (SPR) mide de forma combinada hasta qué punto la solución aportada por el algoritmo está espaciada de forma regular y qué fracción del frente Real cubre. Es, por tanto, una medida combinada de diversidad y regularidad. Esta métrica se define en base a la siguiente ecuación:

$$SPR = \frac{\sum_{q=1}^{no} d_q^e + \sum_{j=1}^{NI} |d_j - d_m|}{\sum_{q=1}^{no} d_q^e + NI \cdot d_m} \quad (8.2)$$

Donde d_q^e es la distancia Euclídea entre las soluciones más extremas proporcionadas por el algoritmo y las soluciones extremas del frente de Pareto real, d_j es la distancia Euclídea entre soluciones adyacentes, d_m es el valor medio de d_j , NI es el número de soluciones halladas por el algoritmo y no es el número de objetivos a optimizar (dos en nuestro caso: tiempo y energía). Cuanto más próximo a cero sea el valor de SPR, más diversa y más regularmente distribuida es la solución proporcionada por el algoritmo.

8.4.3. Espaciamiento (SP)

El Espaciamiento o *Spacing* (SP) es una medida de la regularidad de la solución aportada por el algoritmo, ya que mide hasta qué punto las soluciones están espaciadas regularmente a lo largo del frente. La principal ventaja de esta medida es que no necesita de conocimiento previo del frente de Pareto real. El Espaciamiento se define en base a la siguiente ecuación:

$$SP = \sqrt{\frac{1}{NI - 1} \sum_{j=1}^{NI} (d_m - d_j)^2} \quad (8.3)$$

Donde d_j es la distancia Euclídea entre soluciones adyacentes, d_m es el valor medio de d_j y NI es el número de soluciones halladas por el algoritmo. Cuanto más próximo a cero sea el valor de SP, más regular es la solución proporcionada por el algoritmo.

8.4.4. Hipervolumen Normalizado (NH)

El Hipervolumen Normalizado, o *Normalised Hypervolume* (NH) mide la fracción del espacio objetivo no-dominada por ninguna de las soluciones obtenidas, tal y como se muestra en la Figura 8.1. Al igual que el SPR, es una medida combinada que aporta información tanto sobre la convergencia como sobre la diversidad de la solución obtenida por el algoritmo.

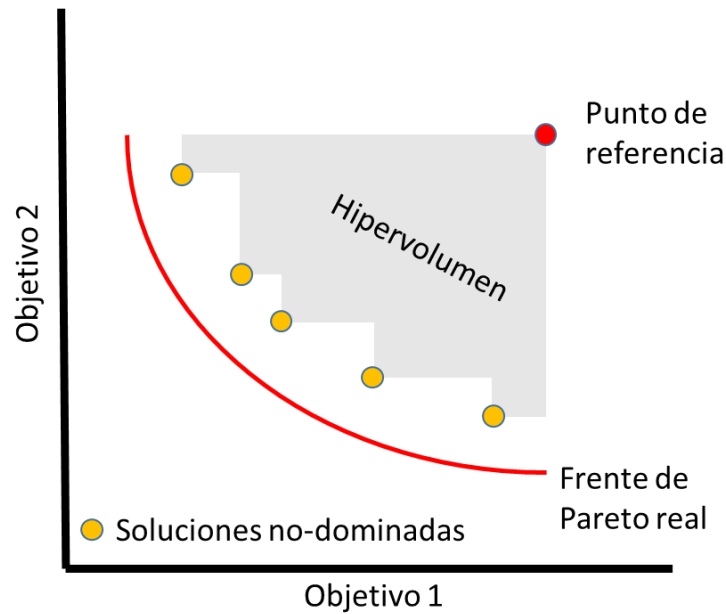


Figura 8.1: Esquema del significado de la métrica de Hipervolumen Normalizado. Fuente: Elaboración propia

El NH se define en base a la siguiente ecuación:

$$NH = 1 - \frac{\sum_j^{NI} ((f_q^{max} - f_{no}^j) \prod_{q=1}^{no-1} (f_q^{sup} - f_q^j))}{\prod_{q=1}^{no} (f_q^{max} - f_q^{min})} \quad (8.4)$$

Donde NI es el número de soluciones halladas por el algoritmo, no es el número de objetivos a optimizar (2 en nuestro caso: tiempo y energía), f_q^{max} y f_q^{min} son los valores máximos y mínimos del frente de Pareto real para cada objetivo q , f_q^j es el valor j -ésimo de la solución obtenida por el algoritmo para el objetivo q , f_q^{sup} es el valor inmediatamente superior a f_q^j , y f_{no}^j es el valor j -ésimo de la solución obtenida por el algoritmo para el objetivo no . A menor valor de NH, más se aproxima al frente de Pareto Real la solución proporcionada por el algoritmo. O, alternativamente, se puede calcular el NH del frente de Pareto real de manera que, cuanto menor diferencia haya entre éste y el NH del frente calculado por el algoritmo, mayor es la convergencia y diversidad de la solución.

8.5. Metodología de comparación

Para comparar de forma sistemática el rendimiento de los cinco algoritmos meta-heurísticos de optimización seleccionados, se ha definido el siguiente procedimiento (Figura 8.2): En primer lugar, se emplea el simulador de marchas y consumo para calcular, en cada uno de los 64 casos de estudio considerados (32 tramos inter-estación co-

rrespondientes a las líneas 1, 2, 3, 5 y 7 de la red de metro de Valencia, considerando ambos sentidos de circulación, véase Capítulo III), una nube de puntos tiempo-consumo lo bastante extensa como para poder calcular el frente de Pareto real, evaluando para ello múltiples combinaciones de cada uno de los cuatro comandos ATO (véase Capítulo V para más detalles).

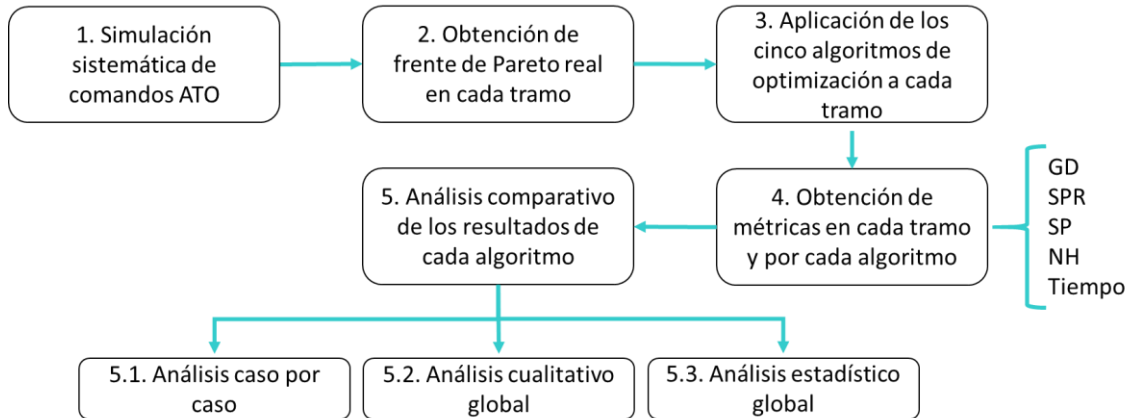


Figura 8.2: Esquema de la metodología de comparación de algoritmos. Fuente: Elaboración propia

Una vez obtenido el frente de Pareto real en los 64 tramos considerados, se aplica cada uno de los cinco algoritmos para obtener un frente de Pareto aproximado en cada uno de los 64 tramos, y se calculan las cuatro métricas resultantes en todos los casos, además del tiempo de ejecución de cada algoritmo. También se calculan las métricas SPR, SP y NH correspondientes a cada frente de Pareto real, para servir de comparación con las obtenidas por los frentes calculados por cada algoritmo.

Por tanto, una vez terminado este proceso, para cada algoritmo se cuenta con 64 series de cinco valores, correspondientes a las métricas GD, SPR, SP y NH más el tiempo de ejecución. Con estos datos disponibles, se plantean tres fases de comparación:

- Un análisis caso por caso, observando el resultado de cada algoritmo en cada uno de los 64 escenarios disponibles. De este modo se puede evaluar si algún algoritmo destaca en algún aspecto determinado (sea convergencia, diversidad o tiempo de ejecución), y si esto ocurre en base a alguna característica particular del escenario en cuestión (por ejemplo, en algún caso en el que el frente de Pareto real sea incompleto por causa de restricciones de circulación).

- Un análisis cualitativo global, con el que se busca identificar si algún algoritmo destaca de forma mayoritaria respecto a alguna de las métricas. También se busca evaluar si se repiten o no jerarquías entre los diferentes algoritmos (por ejemplo, si algún algoritmo es consistentemente primero o segundo, o tiene un resultado irregular).
- Un análisis estadístico global. El objetivo de este último análisis es evaluar si las diferencias observadas en su caso en el análisis cualitativo son estadísticamente significativas o no, y establecer posibles diferencias a nivel poblacional entre los rendimientos de los diferentes algoritmos. Para ello se emplean técnicas de estadística tanto paramétrica (ANOVA para diferencia de medias y test de Levene para diferencia de varianzas), como no-paramétrica (test de Kruskal-Wallis y Mood para diferencia de medianas) ya que, como se verá más adelante, por lo general las muestras comparadas no siguen distribuciones normales.

Los resultados de este triple análisis, que constituyen uno de los núcleos fundamentales de la presente tesis, se muestran en el Capítulo V.

8.6. Conclusiones

En esta Sección del Capítulo IV se han escogido los algoritmos meta-heurísticos a comparar, en base tanto a su grado de uso establecido en la literatura como a su aporte diferencial respecto al resto, especialmente en comparación con el mayoritariamente empleado algoritmo genético NSGA-II. Los cinco algoritmos escogidos son:

- NSGA-II.
- MOPSO.
- SPEA-II.
- MOEA-D.
- MOACOr.

Cada uno de estos algoritmos se ha implementado en MATLAB 8.5.0 (The MathWorks, Inc.) con sus correspondientes particularidades, adaptándolo al problema de optimización de marchas que nos ocupa a partir de códigos de acceso libre. Por otra parte, se han definido las métricas a emplear para evaluar y comparar el rendimiento de cada algoritmo, buscando cubrir los dos principales criterios que se siguen a la hora de determinar la bondad de la solución aportada por un algoritmo de optimización: convergencia y diversidad (y, de forma relacionada con esta última, regularidad). Las métricas adoptadas son:

- Distancia Generacional (GD).
- Extensión (SPR).
- Espaciamiento (SP).
- Hipervolumen Normalizado (NH).
- Tiempo de ejecución.

En base a estas métricas, se establece un proceso de comparación que engloba tres aproximaciones: una comparación caso a caso para cada uno de los 64 tramos considerados (incluyendo ambos sentidos de circulación), una comparación cualitativa global y una comparación estadística global.

Capítulo V

9. Resultados y análisis

El Capítulo V recoge los principales resultados obtenidos del estudio de comparación de algoritmos meta-heurísticos de optimización realizado con las herramientas (y en base a la metodología) desarrolladas en el Capítulo IV. Aquí se expone la simulación sistemática de marchas para obtener los frentes de Pareto real de cada uno de los 64 tramos de estudio, el análisis de sensibilidad realizado a cada uno de los cinco algoritmos para ajustar sus parámetros definitorios, la aplicación de dichos algoritmos a los 64 tramos y la comparativa y análisis del rendimiento de cada uno en función de las métricas y criterios previamente establecidos.

9.1. Introducción

Como se expuso en las motivaciones de la presente tesis, desgranadas en el Capítulo I, uno de los principales objetivos de la misma es llevar a cabo una comparación bien fundamentada del rendimiento de algunos de los algoritmos meta-heurísticos más empleados (y de otros menos usados, pero con un potencial apreciable) para resolver problemas de optimización de marchas.

Para ello se han desarrollado las herramientas de modelización descritas en el Capítulo IV (esto es, el simulador de marchas y la red neuronal que predice el consumo energético) y se ha planteado un marco de estudio basado en la red de metro de Valencia. Como el objetivo no es realizar una optimización efectiva de las marchas en dicha red, sino analizar el funcionamiento de los algoritmos empleados para tal fin, se ha buscado que este marco sea, ante todo, realista y representativo de la casuística de cualquier red de metro

convencional, aunque esto suponga algunas desviaciones menores respecto a las características específicas de la red operada por FGV.

No obstante, antes de llevar a cabo la comparación propiamente dicha, es necesario realizar dos tareas preliminares. La primera es calcular los frentes reales de Pareto (o al menos una aproximación lo más precisa posible a dichos frentes) en cada uno de los 64 casos de estudio (esto es, 32 tramos inter-estación en ambos sentidos de marcha) mediante la simulación sistemática. Conocer de antemano dichos frentes de Pareto es imprescindible para evaluar el rendimiento de cada algoritmo de optimización, ya que varias de las métricas definidas en la Sección 8 se basan precisamente en comparar el frente aproximado por el algoritmo con el frente de Pareto real.

La segunda tarea consiste en ajustar los parámetros que rigen el funcionamiento de cada uno de los cinco algoritmos (véase Capítulo IV, Sección 8) a través de un análisis de sensibilidad, usando como criterio las mismas métricas que posteriormente se emplearán para evaluar su comportamiento (si bien también se han tenido en cuenta los valores empleados en los trabajos revisados en el Capítulo II). De especial interés es determinar los tamaños de población con los que funciona cada algoritmo, así como el número de iteraciones a desarrollar.

Una vez completadas ambas tareas, es posible aplicar cada algoritmo a cada uno de los 64 casos de estudio, obtener las correspondientes métricas y llevar a cabo el análisis comparativo en base a la metodología y criterios expuestos en el apartado 8.5.

9.2. Frentes de Pareto

Cuando se plantea un problema de optimización de marchas en una red ferroviaria, en condiciones en las que el espacio de soluciones es muy amplio, se recurre a algoritmos de optimización meta-heurísticos precisamente por su capacidad para rastrear dicho espacio de forma eficiente y hallar una aproximación aceptable al frente de Pareto real, que es desconocido.

Sin embargo, en nuestro caso es preciso conocer de antemano el frente de Pareto real para emplearlo como vara de medida del funcionamiento de los algoritmos de optimización. Para ello, se ha empleado el simulador de marchas y la red neuronal para calcular, en cada uno de los 64 casos de estudio, un número de marchas posibles lo bastante elevado como para cubrir todo el espacio de soluciones y delimitar la curva de Pareto. Este proceso se ha realizado mediante un cálculo de pares de valores tiempo-consumo en

base a una variación sistemática de los cuatro comandos ATO que sirven de entrada al simulador. Dichos comandos (d , v_h , v_d , v_r) se han variado entre sus valores máximos y mínimos de acuerdo a lo establecido en la Tabla 9.1.

| | Deceleración d (m/s ²) | Velocidad regulación v_h (km/h) | Velocidad deriva v_d (km/h) | Velocidad remotor v_r (km/h) |
|--------------|---|--------------------------------------|----------------------------------|-----------------------------------|
| Valor máximo | 0,80 | 80 | 80 | 60 |
| Valor mínimo | 0,55 | 25 | 40 | 20 |
| Variación | 0,05 | 0,5 | 1 | 1 |

Tabla 9.1: Valores máximos, mínimos y variación de los comandos ATO para la simulación sistemática. Fuente: Elaboración propia.

Teniendo en cuenta que los perfiles de tipo Regulación o R (con v_d y v_r nulos) y los perfiles de tipo Deriva-Remotor o D-R (con v_h nulo) son incompatibles entre sí, la configuración de la Tabla 9.1 arroja, para cada uno de los 64 casos de estudio, un total de 5.832 posibles combinaciones de comandos ATO, de los cuales 666 corresponden a perfiles R y 5.166 a perfiles D-R. Nótese que existen muchas más combinaciones posibles de parámetros para los perfiles D-R, incluso teniendo en cuenta que se fijó una diferencia mínima entre v_d y v_r de 20 km/h.

Así, en cada tramo de estudio se han simulado 5.832 marchas posibles, obteniéndose igual número de pares tiempo-consumo. De este modo queda configurado el espacio de soluciones, y es posible determinar la curva de Pareto real aplicando criterios de no-dominación. La Figura 9.1 muestra varios ejemplos de curvas de Pareto obtenidas mediante este procedimiento.

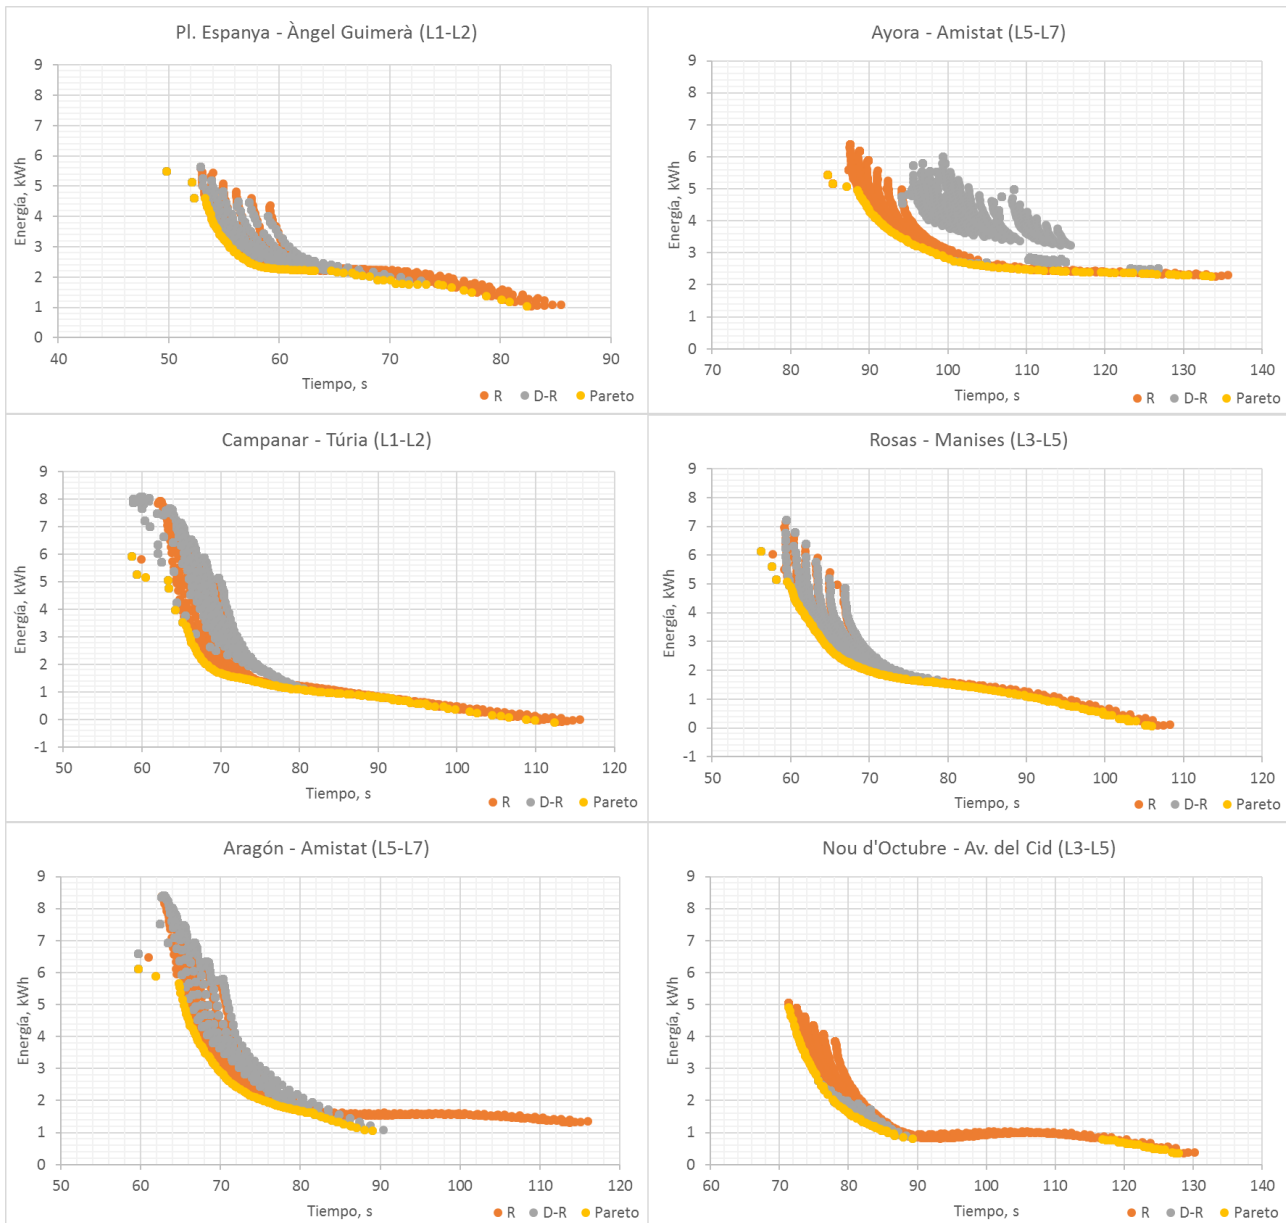


Figura 9.1: Ejemplos de simulación sistemática de marchas y obtención de curvas de Pareto reales. Fuente: Elaboración propia.

Como se puede ver en la Figura 9.1, en algunos casos la curva de Pareto comprende tanto soluciones R como D-R, mientras que en otros (véase el ejemplo Ayora-Amistat) los perfiles R parecen destacar y copar el frente de soluciones óptimas. Por otra parte, en ocasiones (Nou d'Octubre-Av. del Cid) la curva obtenida no es completa, debido a que las propias restricciones del tramo (de velocidad, geométricas, etc.) limita el desarrollo pleno de algunas de las alternativas de conducción simuladas. La relación completa de curvas de Pareto obtenidas en cada uno de los 64 casos de estudio puede verse en el Anexo III.

Por supuesto, sería posible realizar una discretización todavía mayor de los cuatro comandos ATO que la mostrada en la Tabla 9.1 y obtener así un espacio de soluciones más poblado. Esto implica que el frente de Pareto obtenido no es, estrictamente hablando, el real, pero se considera una aproximación suficiente para el propósito del presente estudio, habida cuenta de que incrementar el número de simulaciones también habría disparado los tiempos de computación.

9.3. Análisis de sensibilidad

Una vez obtenidos los frentes de Pareto reales para cada uno de los 64 casos de estudio, y antes de proceder a aplicar los cinco algoritmos de optimización escogidos a cada uno de dichos tramos, es preciso llevar a cabo un análisis de sensibilidad que permita ajustar los parámetros característicos de cada algoritmo. Es importante destacar aquí que la mayoría de la bibliografía consultada (véase Capítulo II) no entra a discutir el valor de la mayoría de los parámetros de los algoritmos que emplean. Como mucho presentan algunas pruebas relativas al número de iteraciones y el tamaño de la población (Açikbas y Soylemez, 2008; Carvajal-Carreño et al., 2014; Domínguez et al., 2014; Fernández, 2018), pero emplean valores fijos del resto de parámetros, sin justificar explícitamente su elección.

Para evaluar la sensibilidad de los algoritmos a sus diferentes parámetros, se ha empleado como criterio la minimización de las métricas definidas en el Capítulo IV, Sección 8, en base a un tramo de prueba escogido de entre los 64 casos disponibles. El tramo seleccionado es el Aragón-Amistat de las líneas 5-7, debido a que ofrece pocas restricciones que afecten al pleno desarrollo de los perfiles de velocidad simulados: no existen limitaciones de velocidad y el tramo es completamente recto y con pocas variaciones de pendiente. Además, en dicho tramo se ha obtenido una curva de Pareto completa que incluye perfiles tanto R como D-R (véase Figura 9.1).

La metodología del análisis de sensibilidad para los cinco algoritmos es la misma: en primer lugar, se ha fijado un número bajo de iteraciones, de población y de archivo en su caso, y se han afinado los valores de los demás parámetros (porcentajes de mutación y cruce, pesos inerciales, parámetro de feromona, etc.). Una vez hecho esto, se han ajustado las variables de tamaño y número de iteraciones, si bien con el criterio adicional de fijar un mismo número de ambos en todos los algoritmos salvo que los resultados del análisis indiquen claramente lo contrario, para que la comparación entre algoritmos sea justa. En todos los casos se han llevado a cabo seis ejecuciones del algoritmo y se han

calculado los valores promedio de cada métrica, para así reducir el efecto de la componente aleatoria intrínseca a los algoritmos meta-heurísticos. A continuación se exponen los resultados del análisis de sensibilidad para cada uno de los cinco algoritmos escogidos.

9.3.1. NSGA-II

En el caso del algoritmo genético NSGA-II, los parámetros a afinar son el tamaño de la población (M), el número de iteraciones (IT) y los porcentajes de cruce ($\%C$) y mutación ($\%M$). Por simplicidad, y en base a la bibliografía consultada (Açikbas y Soylemez, 2008; Carvajal-Carreño et al., 2014; Dündar y Şahin, 2013; Zhao et al., 2015), se decidió fijar la tasa de mutación (TM) en 0,02.

Tal y como se ha comentado anteriormente, en un paso inicial se han fijado los valores de población y número de iteraciones en 10 para ajustar los porcentajes de cruce y mutación. El parámetro de cruce ($\%C$) se ha variado entre 0,2 y 0,6, mientras que el parámetro de mutación ($\%M$) se ha variado entre 0,15 y 0,5. La Figura 9.2 muestra los resultados obtenidos de este primer análisis.

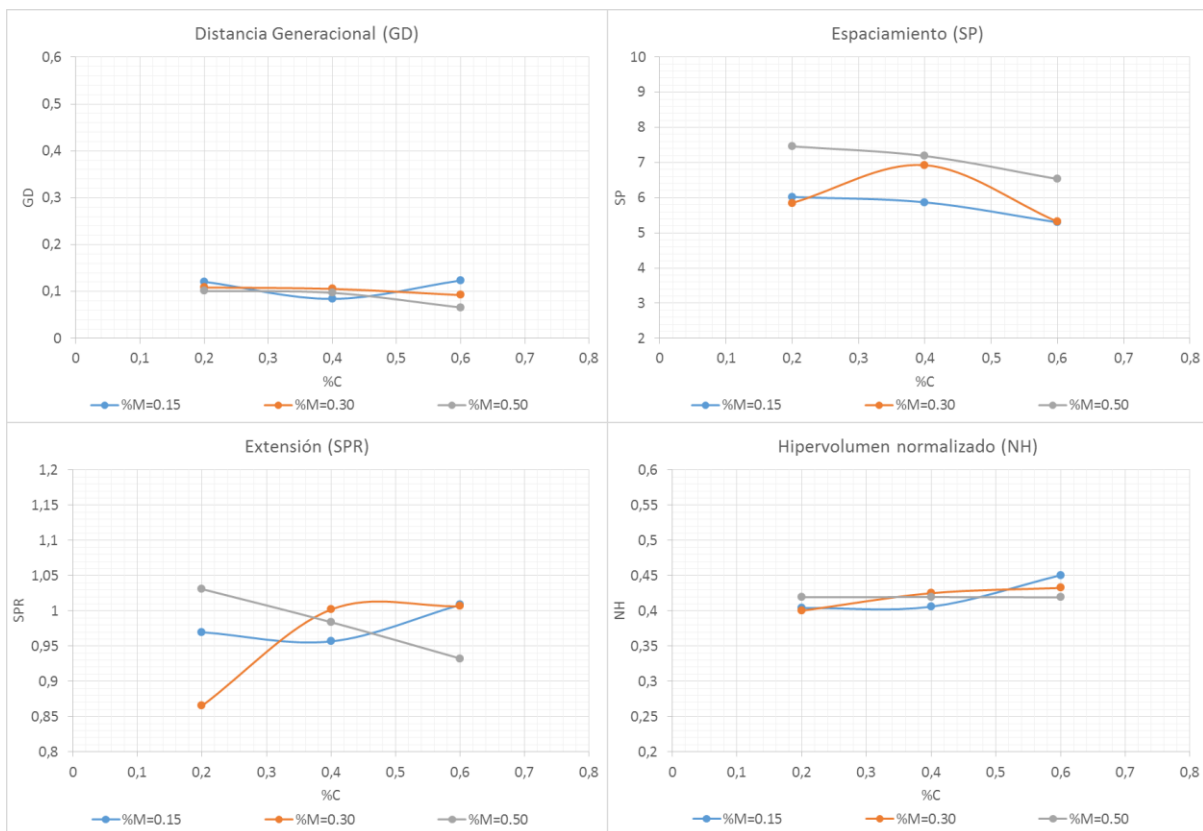


Figura 9.2: Primer análisis de sensibilidad de NSGA-II: porcentaje de cruce ($\%C$) y porcentaje de mutación ($\%M$) vs métricas. Fuente: Elaboración propia.

Como se puede ver, los resultados presentan una cierta irregularidad, especialmente en cuanto a la métrica de Extensión (si bien esta irregularidad se mueve en un rango de valores muy estrecho). La métrica de Espaciamiento muestra una cierta tendencia a la baja conforme aumentan los valores tanto de %C como de %M. Por el contrario, de acuerdo a la métrica NH esta tendencia es ligeramente al alza, si bien de nuevo el rango de valores es muy reducido. Teniendo en cuenta estos resultados, se han fijado los valores de %C en 0,5 y de %M en 0,15.

Una vez determinados estos valores, se procede a analizar el tamaño de la población (N) y el número de iteraciones (IT). La Figura 9.3 muestra los resultados obtenidos en este segundo análisis.

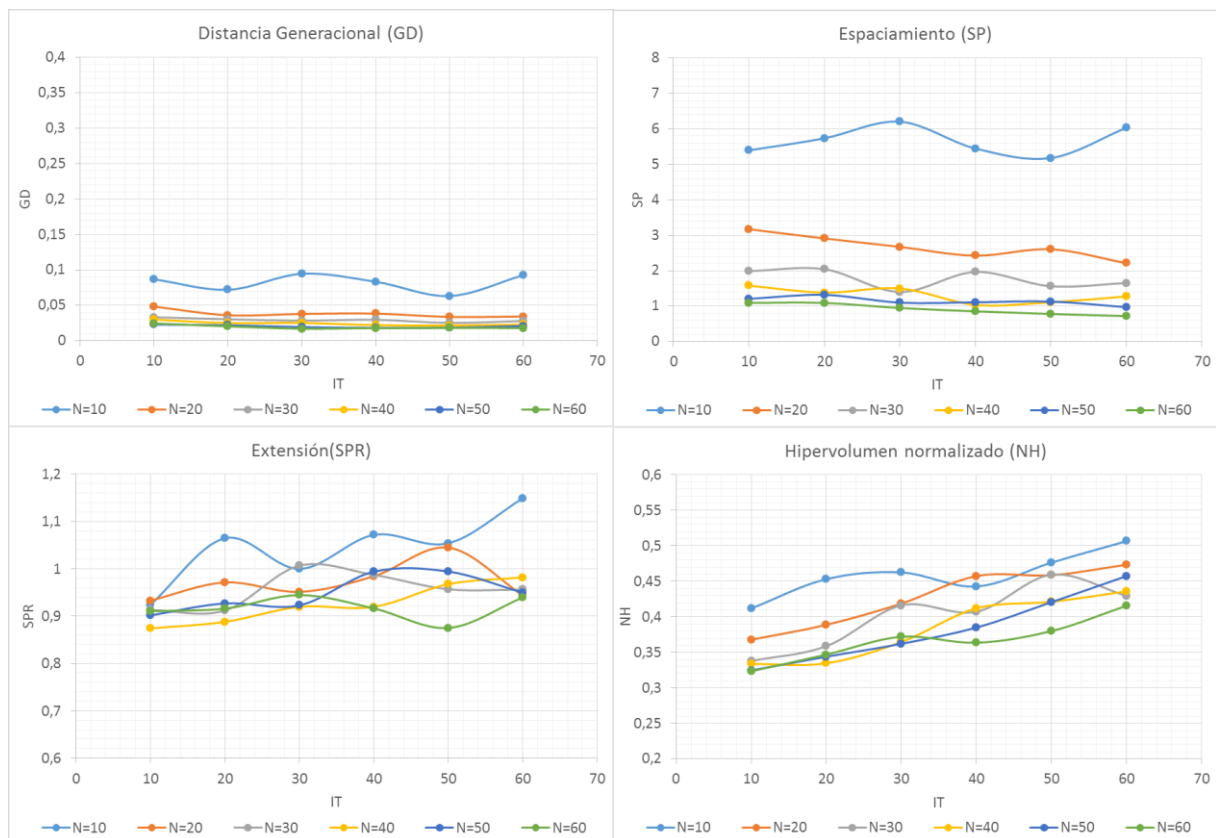


Figura 9.3: Segundo análisis de sensibilidad de NSGA-II: tamaño de población (N) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia.

En este caso, salta a la vista que, conforme aumenta el tamaño de población, se consigue un mejor resultado en todas las métricas, si bien a partir de cierto punto esta mejora es escasa. Por otra parte, en general el número de iteraciones no parece alterar demasiado el resultado, en el rango de valores ensayados (salvo en el caso de la métrica NH,

en la que sí parece haber una tendencia a empeorar si el número de iteraciones aumenta por encima de 40).

Tomando en consideración estos resultados, y el hecho de que interesa limitar dentro de lo posible el tiempo de ejecución del algoritmo, se ha fijado un tamaño de población de 30 y un número de iteraciones igual a 25. Por lo tanto, los parámetros del NSGA-II han quedado completamente ajustados, tal y como recoge la Tabla 9.2.

| Parámetro | Tamaño población (N) | Número de iteraciones (IT) | Porcentaje cruce ($\%C$) | Porcentaje mutación ($\%M$) | Tasa mutación (TM) |
|-----------|--------------------------|--------------------------------|----------------------------|-------------------------------|------------------------|
| Valor | 30 | 25 | 0,50 | 0,15 | 0,02 |

Tabla 9.2: Parámetros de NSGA-II ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.

9.3.2. MOPSO

En el caso del algoritmo MOPSO, los parámetros a afinar son el tamaño de la población (N), el número de iteraciones (IT), el tamaño del archivo (ARC), el peso inercial (w), los coeficientes de aprendizaje personal y global ($c1$ y $c2$ respectivamente) y la tasa de mutación (TM). Por simplicidad, y en base a lo observado en la bibliografía revisada (Domínguez et al., 2014; Fernández et al., 2015) se ha decidido fijar el mismo valor de $c1$ y $c2$ en todo caso, y emplear un amortiguamiento del peso inercial (Aw) igual a 0,9.

Repitiendo el proceso anteriormente descrito, inicialmente se han fijado los valores de población (N) a 20, de archivo (ARC) a 10 y de número de iteraciones (IT) a 10. En este caso se ha optado por aumentar N hasta 20 para evitar la excesiva variabilidad observada en el caso del NSGA-II. Con estos valores fijados, se ha estudiado la sensibilidad del algoritmo a variaciones de los coeficientes de aprendizaje ($c1=c2$) entre 1 y 2, peso inercial (w) entre 0,5 y 0,9, y tasa de mutación (TM) entre 0,1 y 0,5. La Figura 9.4 recoge los resultados de este primer análisis.

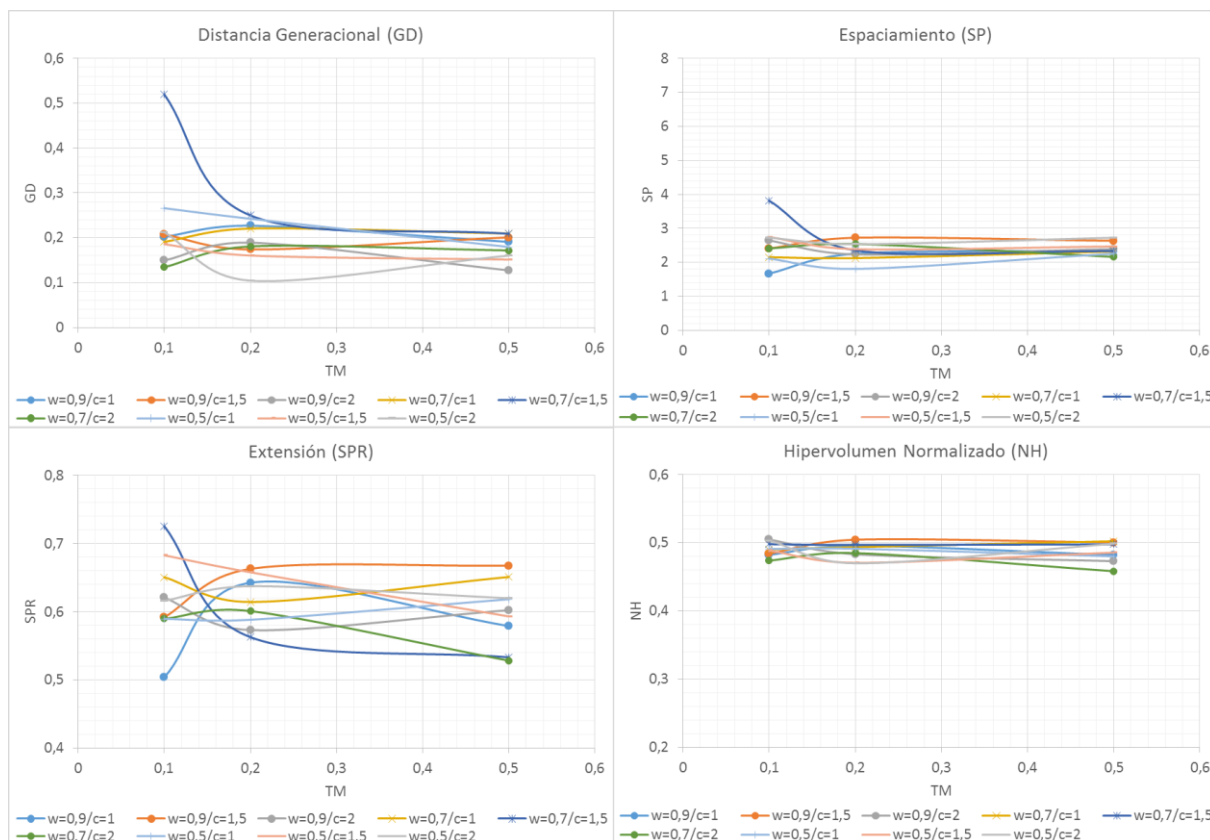


Figura 9.4: Primer análisis de sensibilidad de MOPSO: coeficientes de aprendizaje ($c1=c2$), peso inercial (w) y tasa de mutación (TM) vs métricas. Fuente: Elaboración propia.

Como se puede ver en este caso, de acuerdo a tres de las métricas (GD, SP y SPR) se puede excluir un valor de tasa de mutación por debajo de 0,2, y un valor de peso inercial por debajo de 0,9. Por otra parte, de acuerdo a la métrica NH, valores demasiado elevados de la tasa de mutación tampoco son deseables. Teniendo en cuenta todos los resultados, se ha fijado el valor de los coeficientes de aprendizaje (tanto $c1$ como $c2$) en 1, el valor del peso inercial (w) en 0,9 y el valor de la tasa de mutación (TM) en 0,1.

Una vez fijados estos parámetros, se procede a analizar la sensibilidad del algoritmo ante las variaciones en el tamaño de la población (N), el tamaño del archivo (ARC) y el número de iteraciones (IT). Sin embargo, como también se busca realizar una comparativa justa entre algoritmos, se tratará de fijar el mismo número de iteraciones que se ha escogido para el NSGA-II (25) y el mismo tamaño de la solución (30) salvo que el análisis de sensibilidad indique claramente lo contrario. En el caso del tamaño, el valor a fijar no sería la población (N) del MOPSO sino el archivo (ARC), ya que éste representa la solución final del algoritmo.

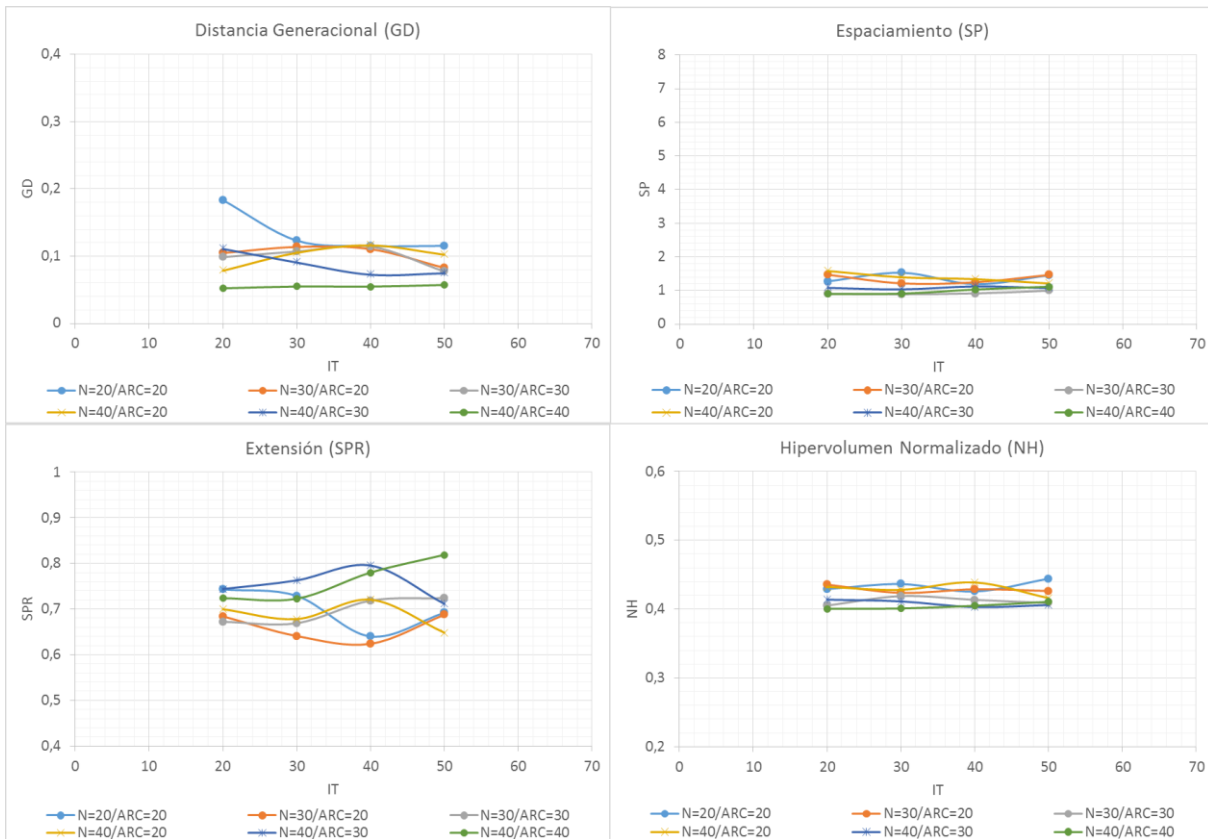


Figura 9.5: Segundo análisis de sensibilidad de MOPSO: tamaño de población (N), tamaño de archivo (ARC) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia.

La Figura 9.5 recoge los resultados de este segundo análisis de sensibilidad. Como se puede ver, respecto a las métricas NH y SP apenas hay diferencias apreciables en cuanto a la variación de tamaño de población (N), archivo (ARC) o número de iteraciones (IT). Respecto a SP sí se observa una cierta mejora con mayor número de iteraciones y un archivo de 30 o 40 elementos. El resultado respecto a SPR es más irregular, si bien los mejores valores se obtienen con un número de iteraciones no superior a 40.

Tomando en consideración estos resultados, y el criterio de similitud de tamaño y número de iteraciones entre algoritmos, se ha fijado un tamaño de población de 30, un tamaño de archivo de 30 y un número de iteraciones igual a 25. Por lo tanto, los parámetros del MOPSO han quedado completamente ajustados, tal y como recoge la Tabla 9.3.

| Parámetro | Tamaño población (N) | Número de iteraciones (IT) | Tamaño archivo (ARC) | Coefficientes aprendizaje ($c1, c2$) | Peso inercial (w) | Tasa mutación (TM) |
|-----------|--------------------------|--------------------------------|--------------------------|--|-----------------------|------------------------|
| Valor | 30 | 25 | 30 | 1 | 0,9 | 0,1 |

Tabla 9.3: Parámetros de MOPSO ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.

9.3.3. SPEA-II

Por lo que se refiere al algoritmo SPEA-II, los parámetros a ajustar son el tamaño de la población (N), el número de iteraciones (IT), el tamaño del archivo (ARC), el porcentaje de cruce ($\%C$), el parámetro de cruce (PC) y la tasa de mutación (TM). Como este algoritmo apenas se ha usado en el campo que nos ocupa (véase Capítulo II), no contamos con referencias previas sobre los valores que pueden tomar estos parámetros, por lo que se han tomado los valores por defecto que venían definidos en el código base y se han probado variaciones dentro de un rango razonable.

En cualquier caso, se ha repetido el mismo procedimiento, fijando los valores de población (N) a 20, de archivo (ARC) a 20 y de número de iteraciones (IT) a 10, se ha procedido a estudiar la sensibilidad del algoritmo a sus parámetros $\%C$, PC y TM . En este sentido, se ha variado el parámetro $\%C$ entre 0,3 y 0,7, el parámetro PC entre 0,1 y 0,5 y el parámetro TM entre 0,1 y 0,5. La Figura 9.6 recoge los resultados de este primer análisis.

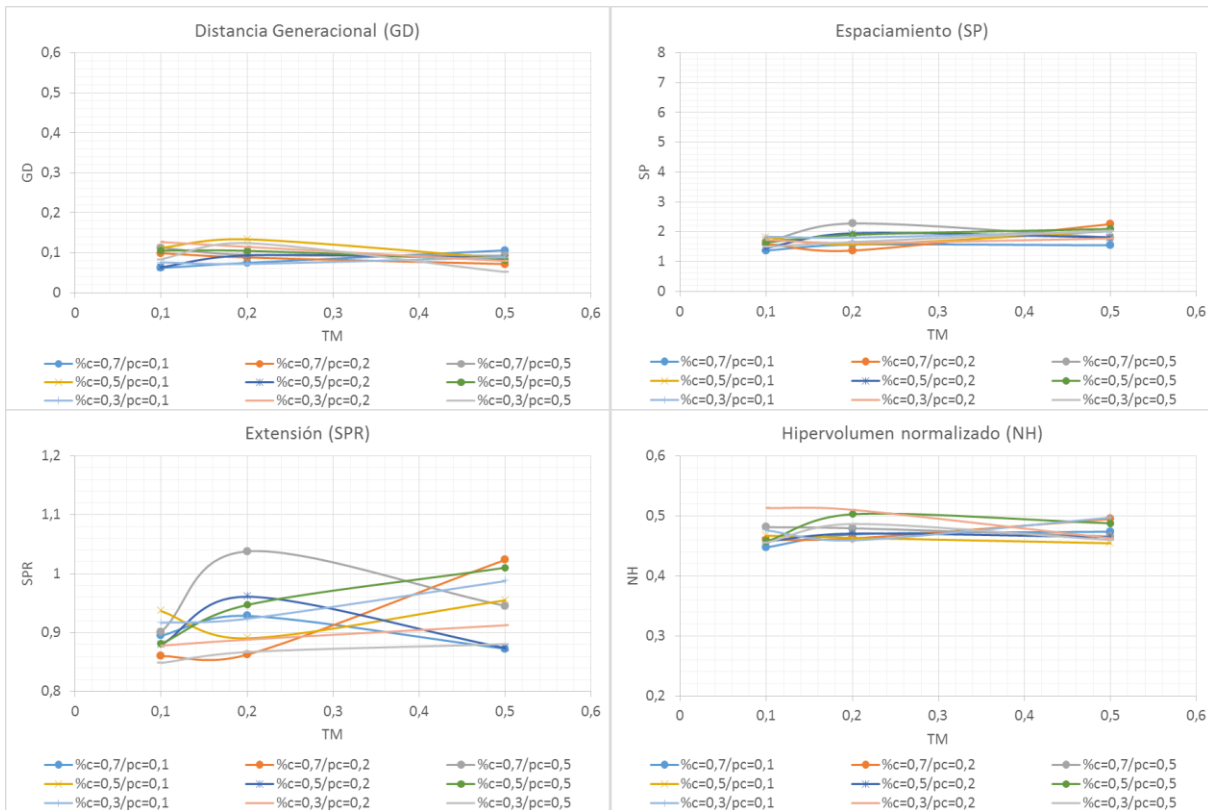


Figura 9.6: Primer análisis de sensibilidad de SPEA-II: porcentaje de cruce (%C), parámetro de cruce (PC) y tasas de mutación (TM) vs métricas. Fuente: Elaboración propia.

Como se puede ver, la única métrica en la que se aprecia cierta influencia respecto a la variación de estos parámetros es la Extensión (SPR), para la que sería conveniente un parámetro de cruce reducido (por debajo de 0,2). Además, según aumenta la tasa de mutación, la dispersión de los resultados también aumenta. Teniendo en cuenta estos resultados, se ha fijado el valor del porcentaje de cruce (%C) en 0,7, el parámetro de cruce (PC) en 0,1 y la tasa de mutación (TM) en 0,15.

Una vez fijados estos parámetros, se procede a analizar la sensibilidad del algoritmo ante las variaciones en el tamaño de la población (M), el tamaño del archivo (ARC) y el número de iteraciones (IT), respetando además los resultados obtenidos para los anteriores algoritmos. Como ocurría en el caso del MOPSO, el valor del archivo (ARC) es el que determina realmente el tamaño de la solución, y no el valor de población (M).

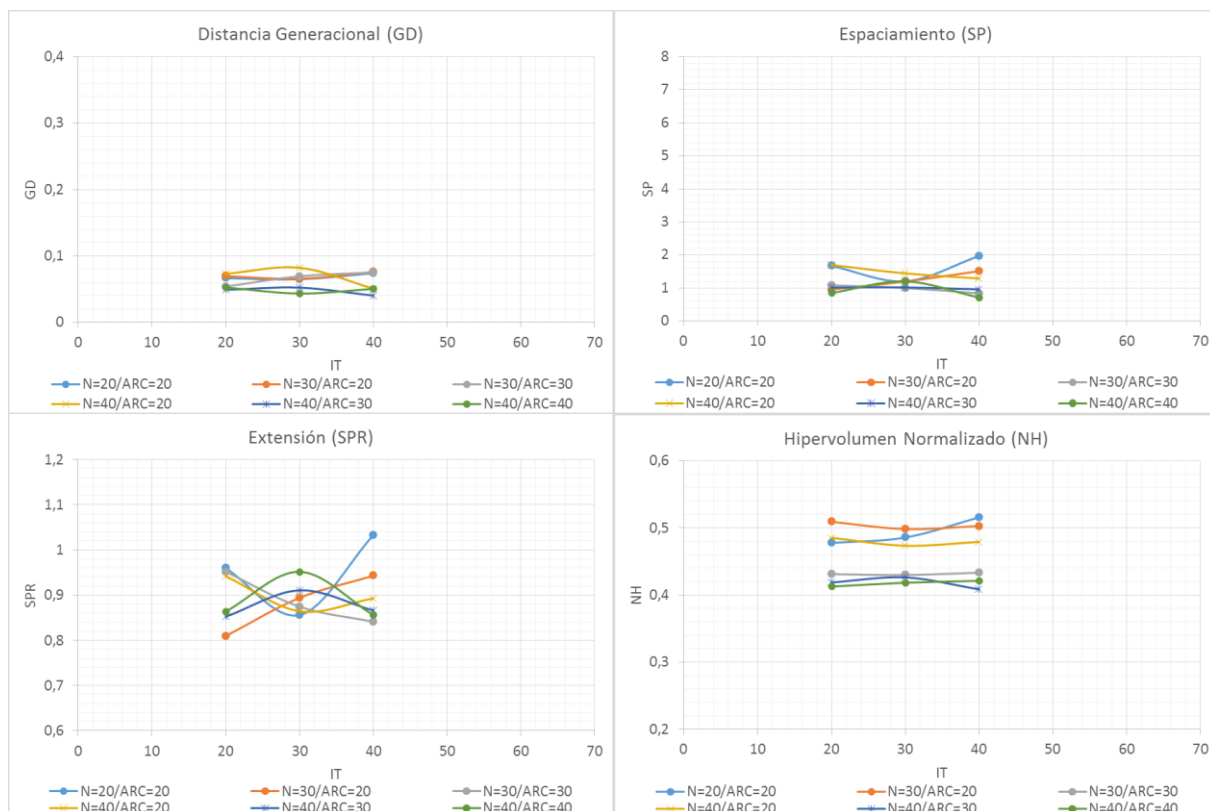


Figura 9.7: Segundo análisis de sensibilidad de SPEA-II: tamaño de población (N), tamaño de archivo (ARC) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia.

La Figura 9.7 muestra los resultados del segundo análisis de sensibilidad para el SPEA-II. Como se puede ver, la variación de estos parámetros influye poco en las métricas GD y SP. Respecto a la métrica NH, los posibles números de iteraciones considerados no influyen apenas en el resultado, pero sí se obtiene un valor menor de la métrica con tamaños de archivo y población mayores. Respecto a la Extensión (SPR), existe cierta variabilidad, pero se puede ver también un mejor resultado en general con valores de archivo y población superiores a 20.

Tomando en consideración estos resultados, y el criterio de similitud de tamaño y número de iteraciones entre algoritmos, se ha fijado un tamaño de población de 30, un tamaño de archivo de 30 y un número de iteraciones igual a 25. Por lo tanto, los parámetros de SPEA-II quedan fijados de acuerdo a lo mostrado en la Tabla 9.4.

| Parámetro | Tamaño población (N) | Número de iteraciones (IT) | Tamaño archivo (ARC) | Porcentaje cruce ($\%C$) | Parámetro cruce (PC) | Tasa mutación (TM) |
|-----------|--------------------------|--------------------------------|--------------------------|----------------------------|--------------------------|------------------------|
| Valor | 30 | 25 | 30 | 0,70 | 0,10 | 0,15 |

Tabla 9.4: Parámetros de SPEA-II ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.

9.3.4. MOEA-D

El algoritmo MOEA-D cuenta como parámetros definitorios con el tamaño de población (N), que en este caso equivale al número de subdivisiones del problema principal, el número de iteraciones (IT), el parámetro de cruce gamma (PCG) y el porcentaje de vecindario ($\%V$). El algoritmo también define un tamaño de archivo (ARC), pero en este caso, y de acuerdo a la propia formulación del MOEA-D, se toma igual a N .

Al igual que ocurría con SPEA-II, al no existir ejemplos previos de uso de este algoritmo en el campo que nos ocupa (véase Capítulo II), no se cuentan con ejemplos relativos a los valores que pueden adoptar estos parámetros, por lo que de nuevo se han tomado los que venían por defecto en el código base y se han variado dentro de unos rangos razonables. Siguiendo el procedimiento habitual, se ha fijado un número inicial de iteraciones igual a 10, y un tamaño de archivo/población igual a 20, y se ha procedido a evaluar la sensibilidad del algoritmo respecto a sus parámetros PCG y $\%V$. En este caso, se ha variado el parámetro PCG entre 0,1 y 0,5 y el parámetro $\%V$ entre el 15% y el 40%. La Figura 9.8 recoge los resultados de este primer análisis.

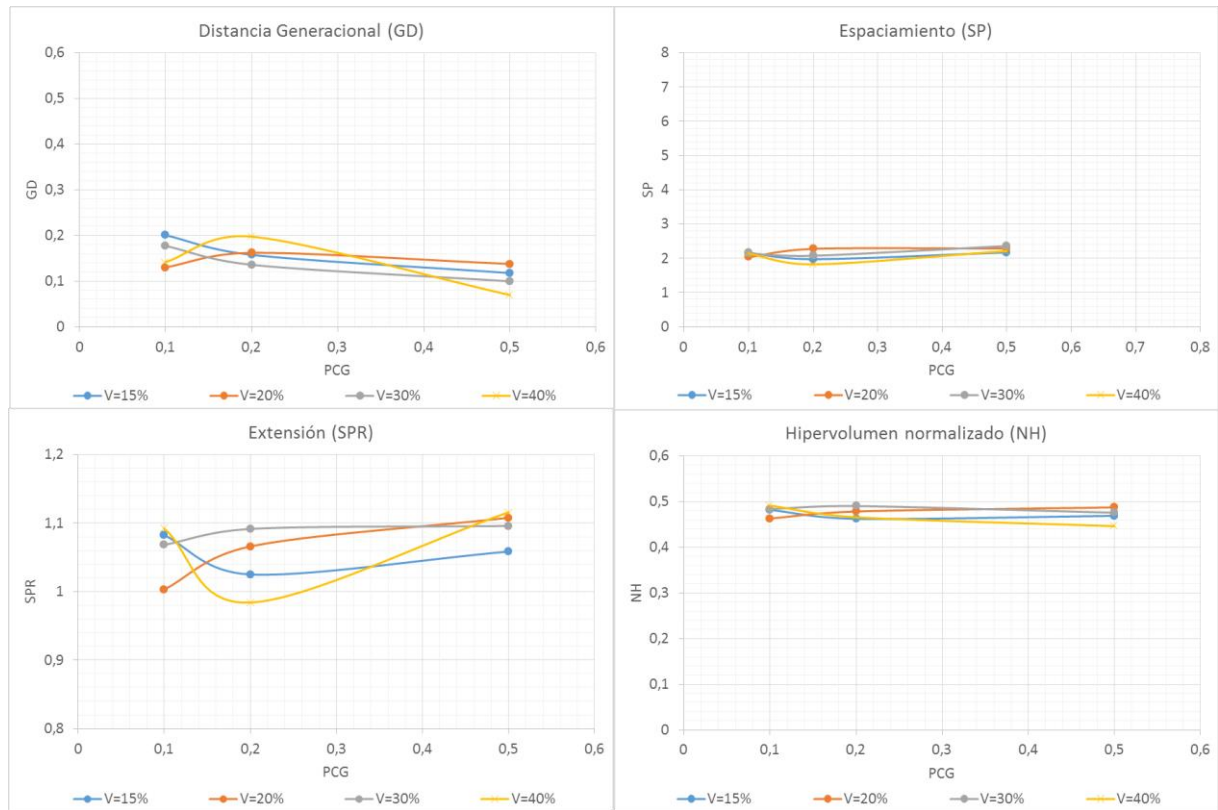


Figura 9.8: Primer análisis de sensibilidad de MOEA-D: parámetro de cruce gamma (PCG) y porcentaje de vecindario ($\%V$) vs métricas. Fuente: Elaboración propia.

En este caso se observa que la variación de estos dos parámetros no tiene incidencia ni en el Espaciamiento (SP) ni en el Hipervolumen Normalizado (NH). En el caso de la métrica GD sí se observa una cierta tendencia a la baja cuando se aumenta el parámetro de cruce gamma (PCG). En cuanto a la Extensión (SPR), es una vez más la métrica que presenta mayor variabilidad, y cuesta apreciar una tendencia clara.

Considerando estos resultados, finalmente se ha optado por escoger un parámetro de cruce PCG igual a 0,5 y un porcentaje de vecindario ($\%V$) igual a 0,15, por lo que se procede a analizar la sensibilidad del algoritmo ante las variaciones en el tamaño de la población (N) y el número de iteraciones (IT). Recuérdese que, en este caso, se iguala el valor N con el valor del archivo ARC . Por lo demás, se mantiene el criterio de igualar en la medida de lo posible tamaño y número de iteraciones a los fijados para los restantes algoritmos. La Figura 9.9 muestra los resultados de este segundo paso del análisis.

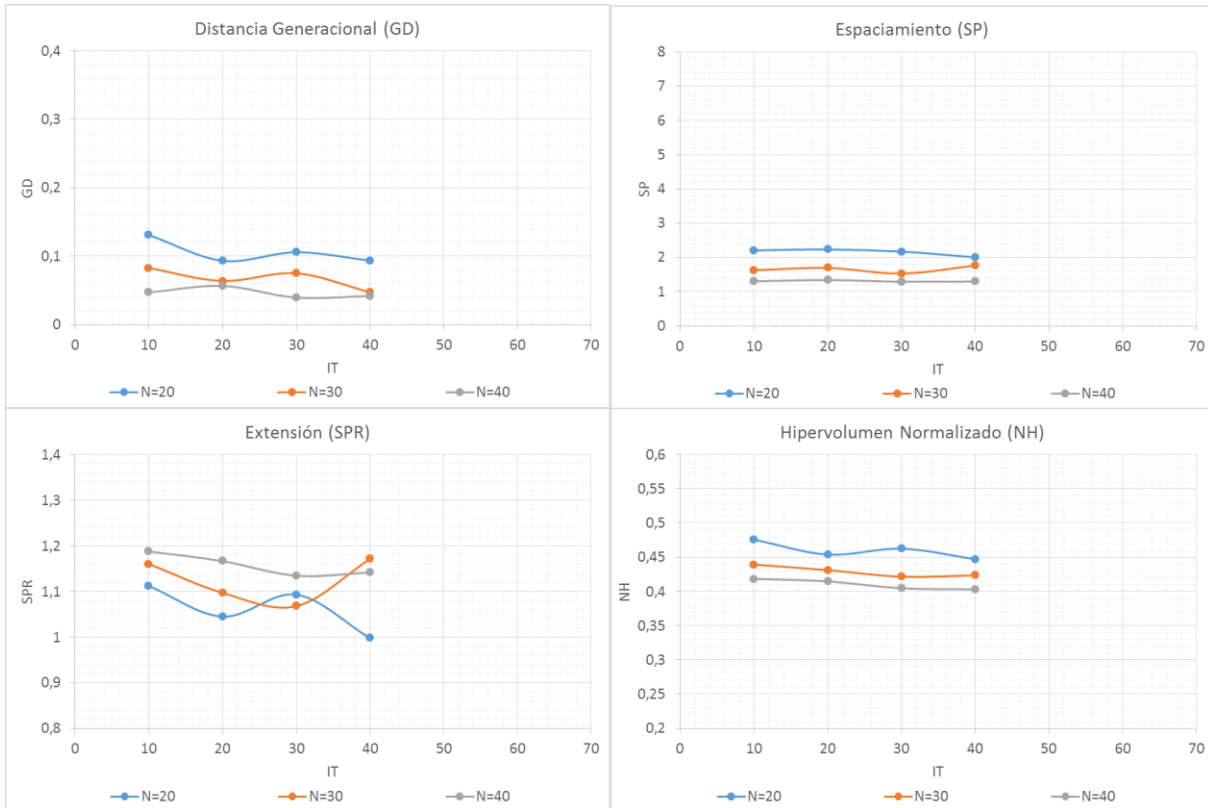


Figura 9.9: Segundo análisis de sensibilidad de MOEA-D: tamaño de población/archivo (N/ARC) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia.

En este caso se puede observar que, de forma sistemática, un mayor tamaño de población y archivo resulta en una mejora de tres de las cuatro métricas, exceptuando la Extensión (SPR) donde se invierte la tendencia. Por otra parte, el número de iteraciones no parece tener un efecto apreciable en los resultados, por lo que se puede tomar el valor empleado para los algoritmos analizados hasta el momento.

Por lo tanto, teniendo en cuenta estos resultados, se ha fijado un tamaño de población y archivo igual a 30 y un número de iteraciones igual a 25. Esto deja los parámetros de MOEA-D establecidos de acuerdo a lo mostrado en la Tabla 9.5.

| Parámetro | Tamaño población (N) | Número de iteraciones (IT) | Tamaño archivo (ARC) | Porcentaje vecinos ($\%V$) | Parámetro cruce gamma (PCG) |
|-----------|--------------------------|--------------------------------|--------------------------|------------------------------|---------------------------------|
| Valor | 30 | 25 | 30 | 0,15 | 0,5 |

Tabla 9.5: Parámetros de MOEA-D ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.

9.3.5. MOACOr

Respecto al último de los cinco algoritmos a comparar, MOACOr, sus parámetros definitorios incluyen el tamaño del archivo (ARC), el tamaño de la población de hormigas (N), el número de iteraciones (IT), el parámetro de pesos (q) y el parámetro de evaporación de feromona (ξ). Al igual que ocurría con los algoritmos SPEA-II y MOEA-D, la falta de ejemplos de aplicación para la optimización de marchas obliga a tomar los valores de partida de estos parámetros aportados en el código base y establecer unos rangos de variación razonables para cada uno.

De este modo, aplicando el mismo procedimiento que para los restantes algoritmos, se ha fijado un número inicial de iteraciones igual a 10, un tamaño de archivo igual a 20 y un número de hormigas también igual a 20 y se ha procedido a evaluar la sensibilidad del algoritmo frente a los parámetros de pesos (q) y evaporación de feromona (ξ). El primero se ha variado entre 0,05 y 0,8 y el segundo entre 0,5 y 1. La Figura 9.10 muestra los resultados obtenidos.

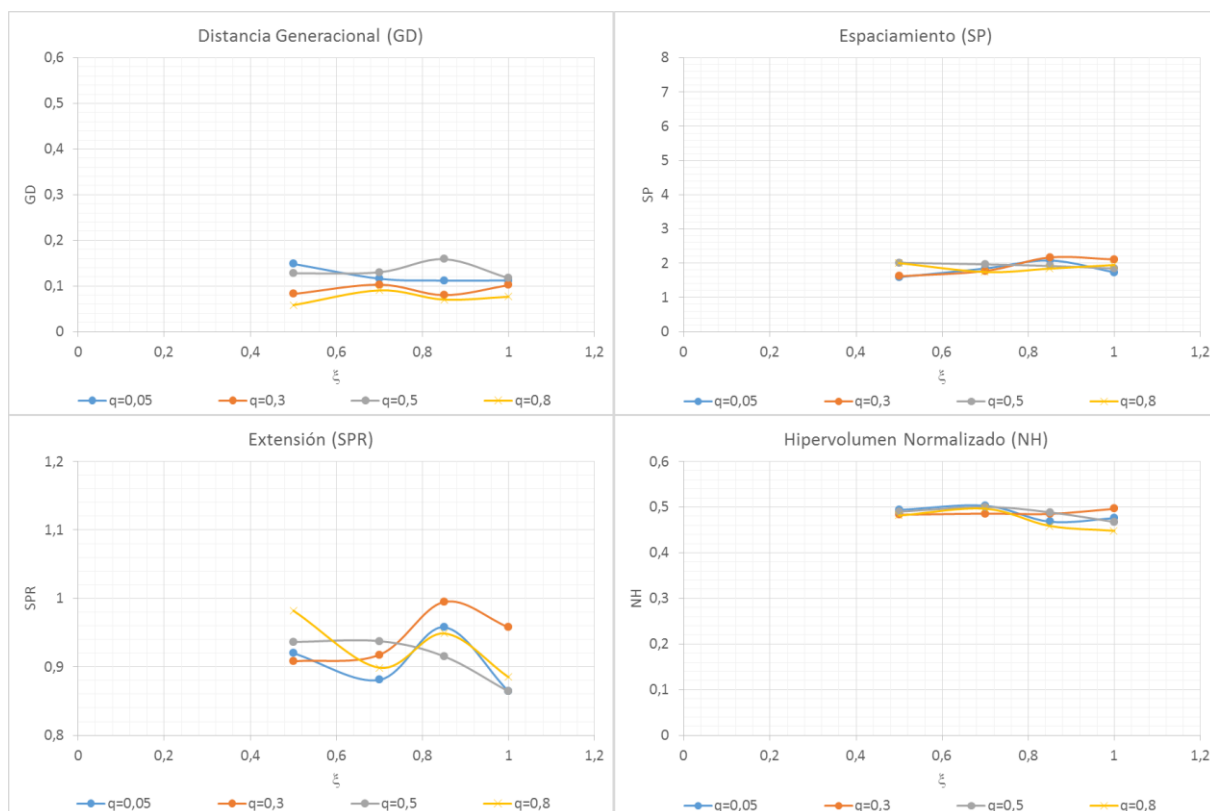


Figura 9.10: Primer análisis de sensibilidad de MOACOr: parámetro de pesos (q) y parámetro de evaporación de feromona (ξ) vs métricas. Fuente: Elaboración propia.

Como salta a la vista, una vez más la métrica que ofrece mayor variabilidad es la Extensión (SPR), donde se aprecia un mejor resultado con pesos y una tasa de evaporación de feromona más elevados. Respecto a NH y SP el algoritmo ofrece un resultado bastante consistente, al igual que respecto a GD. Considerando estos resultados, se ha optado por fijar el parámetro de pesos (q) en 0,8 y el parámetro de evaporación de feromona (ξ) en 1.

De nuevo, una vez fijados estos parámetros, se pasa a evaluar la sensibilidad del algoritmo MOACOR respecto al tamaño de su archivo (ARC), el número de hormigas (M) y el número de iteraciones (IT). Considerando además la equidad en la comparación con los restantes algoritmos, y los resultados obtenidos de los anteriores análisis de sensibilidad, se ha optado por fijar de antemano el tamaño del archivo (ARC) en 30, y testear sólo los otros dos parámetros. (N e IT). La Figura 9.11 muestra los resultados de este segundo paso del análisis.

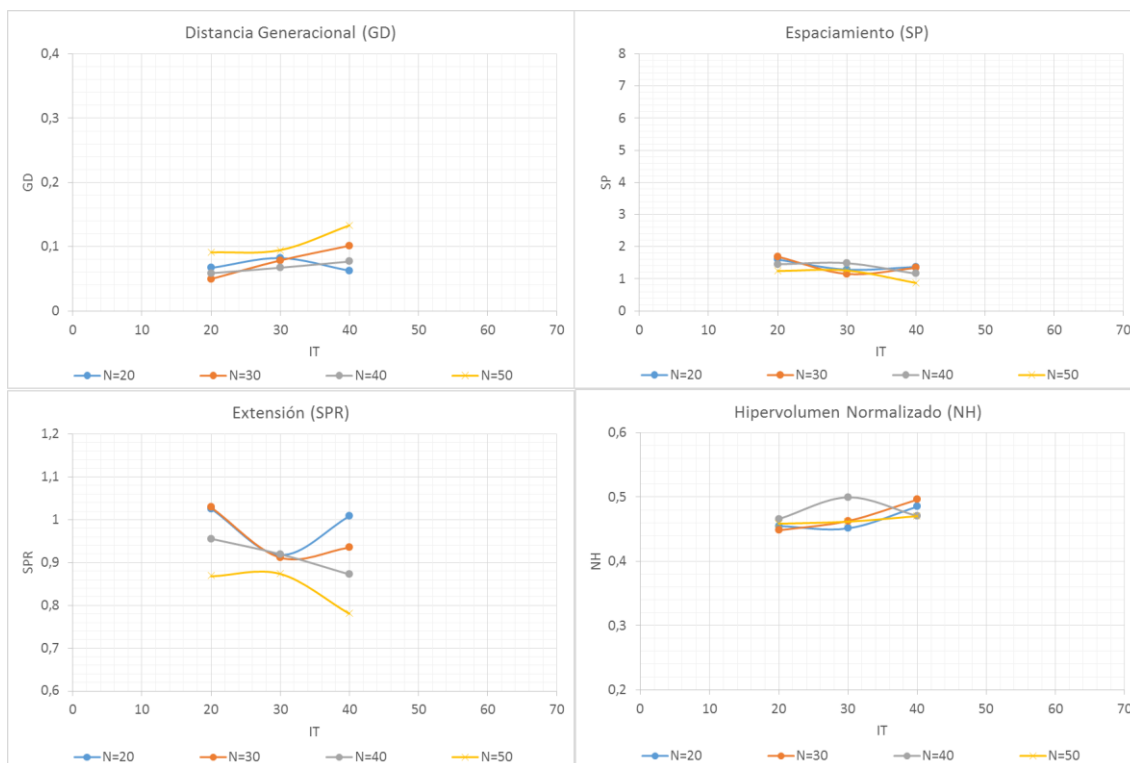


Figura 9.11: Segundo análisis de sensibilidad de MOACOR: tamaño de población (N) y número de iteraciones (IT) vs métricas. Fuente: Elaboración propia.

En este caso se puede observar cómo el aumento del número de iteraciones tiende a mejorar las métricas SP y SPR y a empeorar ligeramente las métricas NH y GD, lo que

apunta a escoger un valor intermedio. Por otra parte, respecto al número de hormigas a considerar, para un número de iteraciones no demasiado elevado, la opción que parece minimizar más todas las métricas sería también un valor intermedio entre 20 y 40.

Por lo tanto, teniendo en cuenta estos resultados, se ha fijado un tamaño de población igual a 30 (con un tamaño de archivo previamente fijado también en ese valor) y un número de iteraciones igual a 25, quedando los parámetros de MOACOr establecidos de acuerdo a los valores recogidos en la Tabla 9.6.

| Parámetro | Tamaño población (N) | Número de iteraciones (IT) | Tamaño archivo (ARC) | Parámetro pesos (q) | Parámetro evaporación feromona (ξ) |
|-----------|--------------------------|--------------------------------|--------------------------|-------------------------|--|
| Valor | 30 | 25 | 30 | 0,80 | 1 |

Tabla 9.6: Parámetros de MOACOr ajustados tras análisis de sensibilidad. Fuente: Elaboración propia.

9.4. Comparativa tramo a tramo

Una vez completado el análisis de sensibilidad en el apartado anterior, ya es posible aplicar los cinco algoritmos a cada uno de los 64 casos de estudio y obtener los valores de las cuatro métricas (además del tiempo de cálculo), para comparar su rendimiento. Como se explicó en la Sección 8, Capítulo IV, la metodología de comparación comprende tres etapas. En este primer apartado se va a proceder a realizar una comparación cualitativa por tramos, centrándose en aquéllos que resulten de mayor interés por sus características.

Así pues, a continuación se comparan y analizan las soluciones de Pareto obtenidas por cada algoritmo en determinados tramos seleccionados de cada una de las líneas objeto del estudio, para tratar de aportar una primera estimación del comportamiento de cada uno de los algoritmos e identificar posibles diferencias entre ellos. En los siguientes apartados se profundizará en la comparación a escala más global, tanto de forma cualitativa como a través del análisis estadístico. Cabe destacar que, si bien en este apartado sólo se analizan algunos tramos escogidos, en el Anexo III podrán hallarse los resultados obtenidos para los 64 casos de estudio.

9.4.1. Líneas 1, 2 y 7

Como ya se vio en la descripción del ámbito del estudio (Capítulo III), el tramo correspondiente a las líneas 1 y 2 es coincidente, por lo que se pueden analizar conjuntamente. Por

otra parte, la línea 7 comparte buena parte de su recorrido con las líneas 1 y 2, por lo que se incluye parcialmente en este apartado. Concretamente, se han escogido para su análisis los siguientes tramos:

Campanar-Beniferri

Se trata de un tramo de 949 metros de longitud, con un perfil en planta que comprende dos rectas conectadas por una única curva, y un perfil longitudinal con pendientes pronunciadas al inicio (de más de 14 mm/m) y rampas de 3 mm/m en su tramo central. Existe una limitación de velocidad de 40 km/h a la salida de la estación de Beniferri, pero en el resto del tramo los vehículos pueden circular a su máxima velocidad. La Figura 9.12 muestra las soluciones obtenidas por cada uno de los cinco algoritmos, y su comparación con el frente de Pareto real.

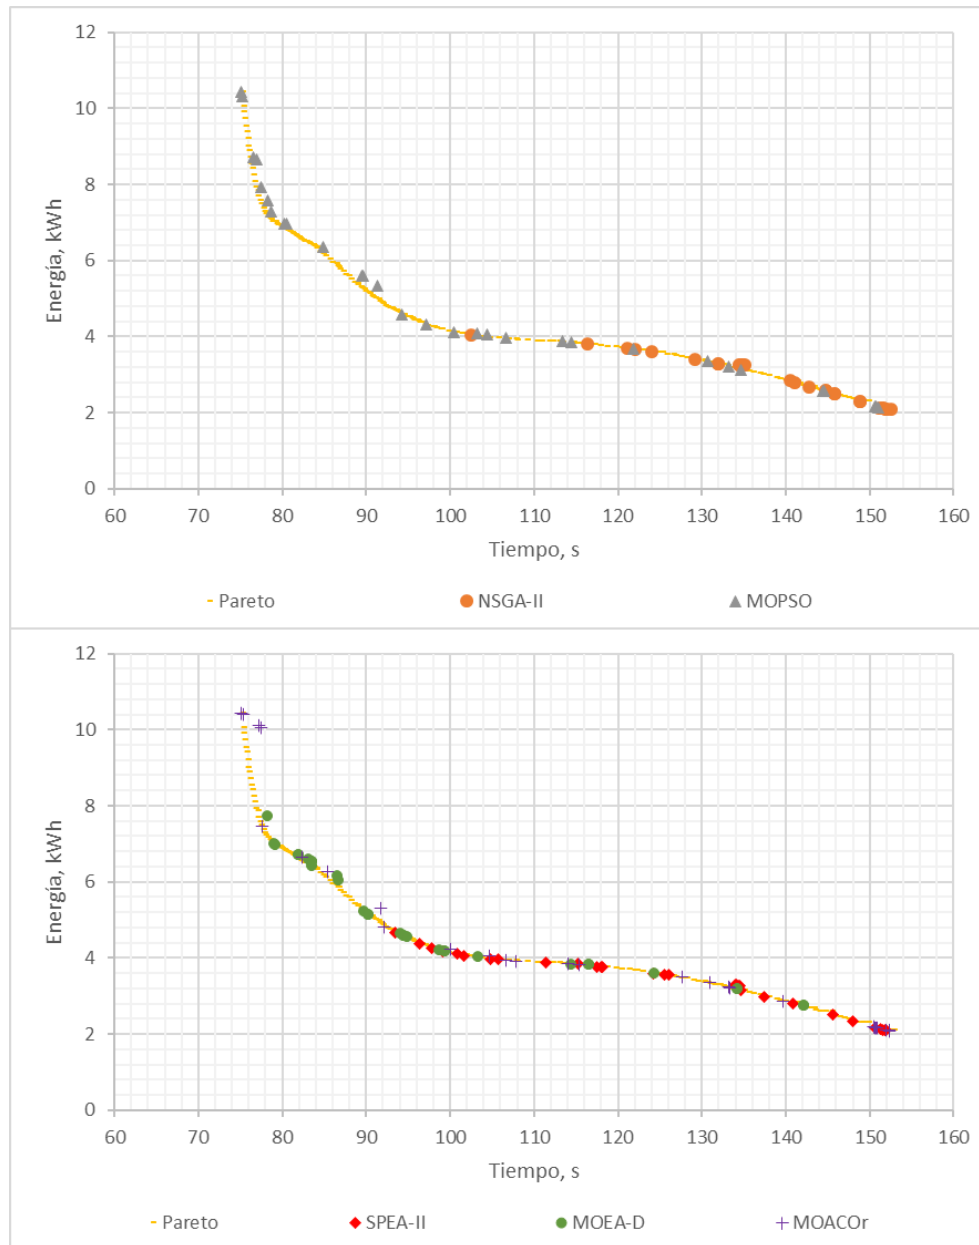


Figura 9.12: Resultados de los cinco algoritmos en el tramo Campanar-Beniferri (L1/L2). Fuente: Elaboración propia.

Como se puede ver, en este caso la curva de Pareto real obtenida es continua y cubre un espacio de soluciones entre los 75 y los 153 segundos, con un rango de consumo entre 10,44 y 2,09 kWh. A primera vista, parece que los cinco algoritmos ofrecen un conjunto de soluciones muy próximo al frente real (siendo MOACOr el que aporta un par de soluciones más separadas). En cuanto a la diversidad, los algoritmos que parecen ofrecer un mejor resultado son MOPSO y MOACOr, mientras que NSGA-II parece limitarse a la parte baja del frente. Para evaluar mejor este resultado, la Tabla 9.7 recoge los valores de

todas las métricas para este tramo, y su comparación con los valores calculados para el frente de Pareto real.

| Métrica | Distancia Generacional (GD) | Extensión (SPR) | Espaciamiento (SP) | Hipervolumen Normalizado (NH) | Tiempo de ejecución (s) |
|-------------|-----------------------------|-----------------|--------------------|-------------------------------|-------------------------|
| Frente real | N/A | 0,542 | 0,264 | 0,246 | N/A |
| NSGA-II | 0,028 | 1,012 | 2,787 | 0,455 | 665 |
| MOPSO | 0,048 | 0,764 | 2,683 | 0,274 | 1.030 |
| SPEA-II | 0,042 | 0,836 | 2,023 | 0,368 | 862 |
| MOEA-D | 0,034 | 1,045 | 3,124 | 0,279 | 792 |
| MOACOr | 0,095 | 0,917 | 3,298 | 0,283 | 854 |

Tabla 9.7: Métricas obtenidas en el tramo Campanar-Beniferri (L1/L2). Fuente: Elaboración propia.

Como se ve en la tabla, si bien todos los algoritmos obtienen buenos resultados respecto a la métrica GD, es el algoritmo genético convencional (NSGA-II) el que ofrece una solución más próxima a la real. Por el contrario, en términos de diversidad y correcta distribución, MOPSO es el que mejor puntúa. MOEA-D ofrece un buen resultado en cuanto a la métrica NH (lo que significa que su conjunto de soluciones cubre un espacio similar al frente real), pero en cuanto a SPR son mejores tanto MOACOr como SPEA-II. Este último, además, ofrece la solución más regular (esto es, uniformemente distribuida) de los cinco.

En lo que respecta a los tiempos de ejecución, cabe mencionar que los valores mostrados en la Tabla 9.7 incluyen las diversas ejecuciones del simulador de marchas, que suponen el grueso del tiempo total de ejecución de cada algoritmo, de ahí que los valores resulten ciertamente elevados. En cualquier caso, resultan interesantes a efectos de comparación, si bien se le dará una importancia menor a la de las métricas a lo largo del análisis del presente Capítulo. En este caso, se puede ver que el algoritmo con mejores resultados (MOPSO) es también el que precisa de un mayor tiempo de cálculo.

Sant Isidre-Safranar

Este tramo tiene una longitud de 728 metros, con un perfil mucho más irregular que incluye, en planta, dos curvas: la primera con un radio de 1.922 m y la segunda (que llega hasta la estación de Safranar) con un radio de 400 m. Por otra parte, el perfil longitudinal

incluye un tramo en pendiente de más de 22 mm/m y un tramo final en rampa próxima a 10 mm/m. El tramo no cuenta con ninguna limitación específica de velocidad, por lo que los trenes pueden alcanzar los 80 km/h en todo el recorrido. La Figura 9.13 muestra la comparativa entre el frente real de Pareto y las soluciones obtenidas por los cinco algoritmos.

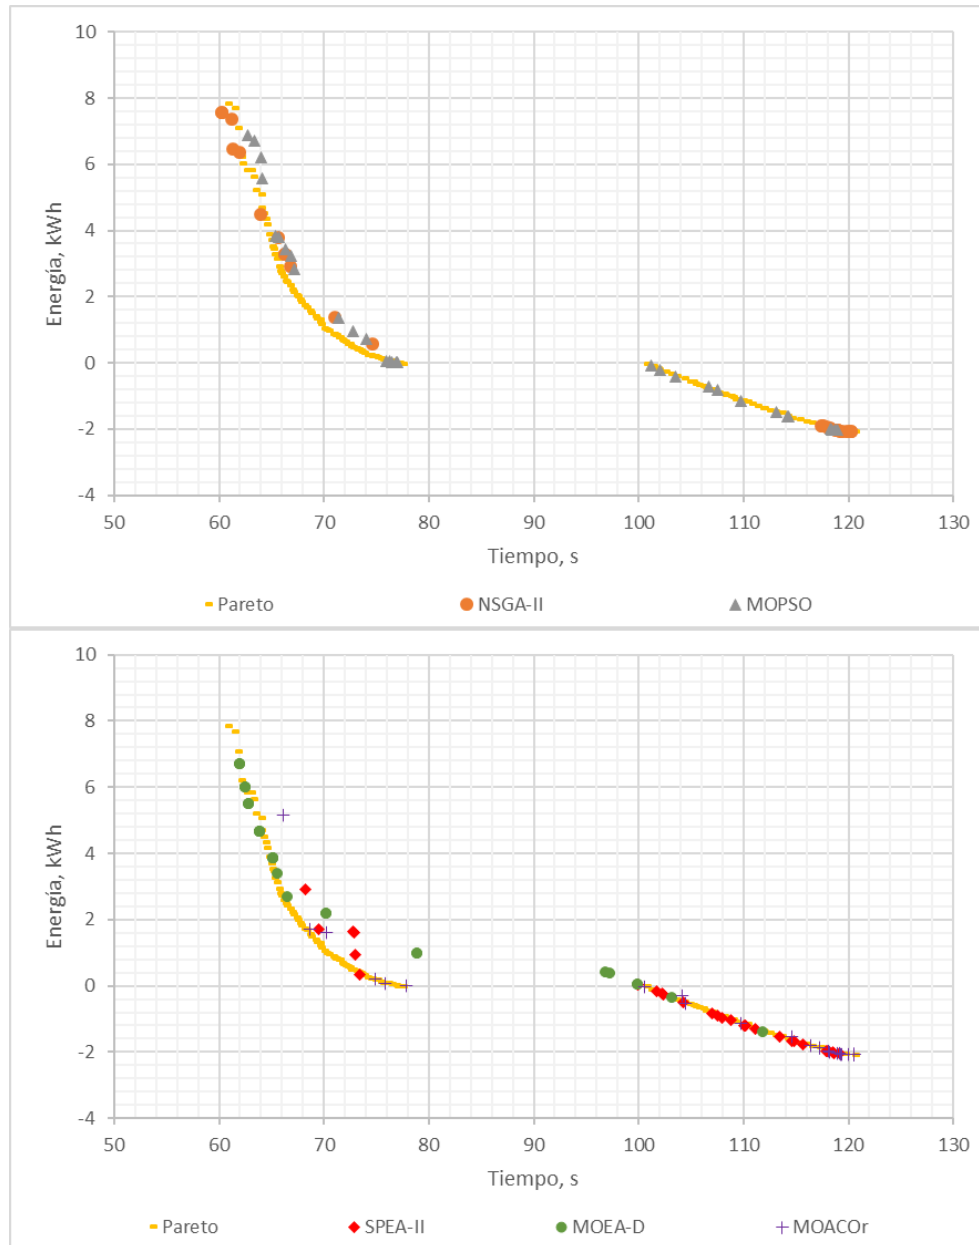


Figura 9.13: Resultados de los cinco algoritmos en el tramo Sant Isidre-Safranar (L1/L2/L7). Fuente: Elaboración propia.

En este caso, el frente de Pareto real queda partido en dos, con un primer tramo que cubre soluciones entre los 61 y los 77 segundos (con un consumo de 7,69 y 0 kWh respectivamente), mientras que el segundo tramo cubre soluciones entre los 100 y los 120 segundos de viaje (con un consumo de -0,02 y -2,09 kWh respectivamente). Gracias al trazado irregular del tramo, en este caso es posible desarrollar perfiles de velocidad con consumo energético nulo o incluso regenerar hasta 2 kWh de energía. En lo que respecta a los algoritmos, vemos que todos ofrecen soluciones muy próximas a la rama de regeneración de la curva de Pareto, mientras que parecen alejarse más de la rama de consumo neto. Por el contrario, en este tramo los cinco algoritmos parecen capaces de ofrecer soluciones en ambas ramas, por lo que la diversidad de sus respectivos conjuntos de marchas resultaría mejor que en el tramo anterior (especialmente en el caso del NSGA-II).

| Métrica | Distancia Generacional (GD) | Extensión (SPR) | Espaciamiento (SP) | Hipervolumen Normalizado (NH) | Tiempo de ejecución (s) |
|-------------|-----------------------------|-----------------|--------------------|-------------------------------|-------------------------|
| Frente real | N/A | 0,804 | 2,071 | 0,236 | N/A |
| NSGA-II | 0,075 | 1,393 | 7,772 | 0,326 | 471 |
| MOPSO | 0,092 | 0,973 | 4,354 | 0,269 | 691 |
| SPEA-II | 0,082 | 1,029 | 4,748 | 0,305 | 637 |
| MOEA-D | 0,203 | 1,243 | 3,828 | 0,318 | 654 |
| MOACOr | 0,075 | 1,153 | 4,259 | 0,290 | 690 |

Tabla 9.8: Métricas obtenidas en el tramo Sant Isidre-Safranar (L1/L2/L7). Fuente: Elaboración propia.

La Tabla 9.8 muestra los resultados de las métricas para el tramo Sant Isidre-Safranar. En primer lugar, salta a la vista los elevados valores de Espaciamiento (SP), debidos a esa separación tan clara entre ambas ramas del frente de Pareto real. En términos de convergencia, NSGA-II y MOACOr ofrecen los mejores resultados, mientras que MOEA-D puntúa claramente peor. Por el contrario, en términos de diversidad, de nuevo MOPSO muestra un mejor comportamiento, si bien en este caso, como se preveía, las diferencias son menores en general (con SPEA-II muy próximo a MOPSO). En todo caso, una vez más NSGA-II es el que peor puntúa en las métricas de diversidad, pero ofrece un coste de computación claramente menor.

Empalme-Beniferri

Este tramo tiene una longitud de 1.051 metros, con un perfil notablemente irregular: en planta, presenta varias curvas con radios que oscilan entre los 200 y los 830 metros; mientras que en alzado el tramo discurre en pendiente prácticamente en su totalidad (ya que la línea pasa de la superficie al túnel), con valores que alcanzan los 20 mm/m. Por otra parte, existen limitaciones a 60 y 65 km/h en algunos puntos del tramo. La Figura 9.14 muestra los resultados de los cinco algoritmos respecto al frente de Pareto real.

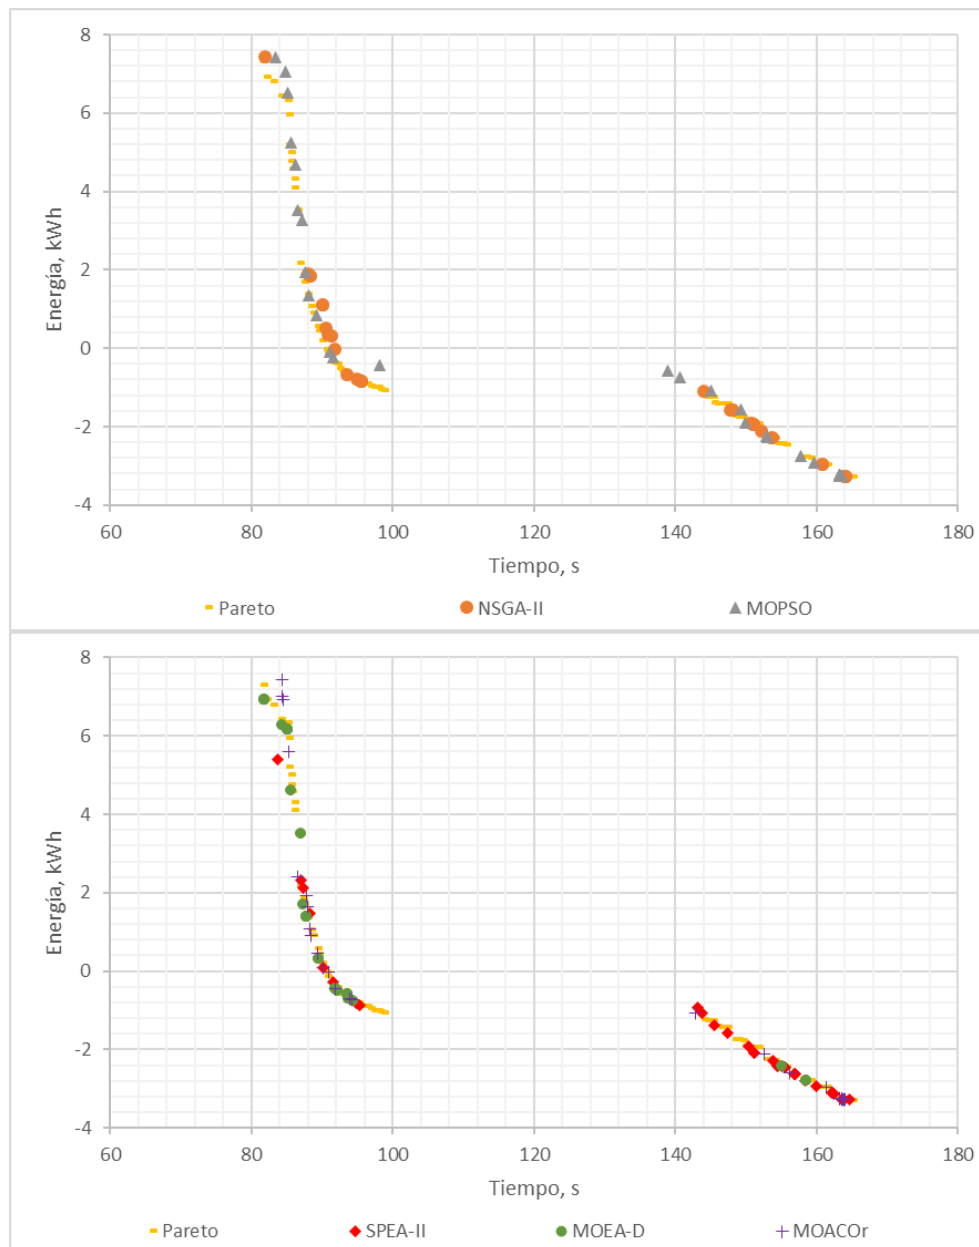


Figura 9.14: Resultados de los cinco algoritmos en el tramo Empalme-Beniferri (L1/L2). Fuente: Elaboración propia.

Como se ve en la figura, en este caso también el frente de Pareto real queda partido en dos, con un primer tramo en el que se cubre un rango de tiempos de viaje de 17 segundos (entre 82 y 99), pasando de un consumo neto de tracción de 7,31 kWh a una regeneración de 1,06 kWh. La segunda rama, más tendida, pasa de los 145 a los 165 segundos de tiempo de viaje (con una regeneración de energía de 1,38 a 3,28 kWh respectivamente). La principal diferencia con el tramo anterior es que en este caso la primera rama del frente de Pareto real también presenta ciertas discontinuidades.

En cuanto a las soluciones proporcionadas por los algoritmos, se aprecia de nuevo una convergencia bastante buena para todos ellos, si bien en este caso NSGA-II no es, en apariencia, el que más se aproxima al frente real. Por otra parte, todos los algoritmos parecen cubrir razonablemente bien ambas ramas del frente, e incluso MOPSO y MOEA-D proporcionan alguna solución que rellena huecos de la primera rama.

| Métrica | Distancia Generacional (GD) | Extensión (SPR) | Espaciamiento (SP) | Hipervolumen Normalizado (NH) | Tiempo de ejecución (s) |
|-------------|-----------------------------|-----------------|--------------------|-------------------------------|-------------------------|
| Frente real | N/A | 1,047 | 5,210 | 0,235 | N/A |
| NSGA-II | 0,077 | 1,272 | 8,840 | 0,273 | 655 |
| MOPSO | 0,210 | 1,069 | 7,349 | 0,282 | 817 |
| SPEA-II | 0,093 | 1,097 | 8,562 | 0,252 | 792 |
| MOEA-D | 0,038 | 1,379 | 10,977 | 0,271 | 778 |
| MOACOr | 0,073 | 1,279 | 8,889 | 0,264 | 780 |

Tabla 9.9: Métricas obtenidas en el tramo Empalme-Beniferri (L1/L2). Fuente: Elaboración propia.

De acuerdo a los resultados que se muestran en la Tabla 9.9, en este caso MOEA-D es el que ofrece una mejor convergencia, seguido de MOACOr y NSGA-II. De nuevo los valores de Espaciamiento son notablemente elevados (más incluso que en el tramo anterior) debido a la discontinuidad del frente de Pareto. En términos de diversidad, una vez más MOPSO ofrece el mejor resultado, si bien SPEA-II se acerca mucho (y mejora el valor de la métrica NH). NSGA-II vuelve a ser el algoritmo con menor tiempo de ejecución.

Plaça Espanya-Jesús

Este tramo tiene una longitud de 797 metros. En planta, presenta una curva de radio 110 metros, y a partir de los 500 metros de recorrido encadena tres curvas con radios 1.675, 3.000 y 100 m respectivamente, para concluir en recta. En alzado, el tramo discurre en pendiente en su práctica totalidad, con valores reducidos en su sección inicial (por debajo de los 3 mm/m), y más elevados en los últimos 100 metros del tramo (18,4 mm/m). Por otra parte, existen dos limitaciones a 45 km/h en el tramo, una entre los 60 y los 200 metros y otra entre los 650 y los 740 metros.




Figura 9.15: Resultados de los cinco algoritmos en el tramo Pl. Espanya-Jesús (L1/L2). Fuente: Elaboración propia.

La Figura 9.15 muestra la comparativa entre el frente real y las soluciones proporcionadas por los algoritmos. En este caso el frente de Pareto es una única rama con una doble curvatura (si bien con pequeñas discontinuidades), que abarca perfiles de velocidad con tiempos de viaje entre los 68 y los 130 segundos (con un consumo de 6,50 y 1,77 kWh respectivamente). En este caso, a pesar de que el trayecto discurre en pendiente en su mayor parte, no se llega a regenerar energía, probablemente debido a las limitaciones de velocidad y a que las pendientes son suaves salvo en los últimos metros.

Por lo que respecta al resultado de los algoritmos, la convergencia parece ser mejor en la parte más tendida de la curva de Pareto, y peor en la parte más vertical. Por otra parte, una vez más NSGA-II parece ofrecer un peor resultado en cuanto a diversidad que los otros cuatro algoritmos, si bien en el caso de MOACOr hay bastante irregularidad en la distribución de las soluciones.

| Métrica | Distancia Generacional (GD) | Extensión (SPR) | Espaciamiento (SP) | Hipervolumen Normalizado (NH) | Tiempo de ejecución (s) |
|-------------|-----------------------------|-----------------|--------------------|-------------------------------|-------------------------|
| Frente real | N/A | 0,821 | 0,480 | 0,271 | N/A |
| NSGA-II | 0,036 | 0,835 | 1,290 | 0,450 | 547 |
| MOPSO | 0,150 | 0,949 | 2,769 | 0,334 | 757 |
| SPEA-II | 0,041 | 0,935 | 1,828 | 0,401 | 721 |
| MOEA-D | 0,097 | 1,121 | 2,425 | 0,334 | 688 |
| MOACOr | 0,036 | 1,311 | 4,491 | 0,364 | 743 |

Tabla 9.10: Métricas obtenidas en el tramo Pl. Espanya-Jesús (L1/L2). Fuente: Elaboración propia.

De acuerdo a los resultados de la Tabla 9.10, el algoritmo NSGA-II es, junto con el algoritmo MOACOr, el que mejor valor de GD (y por tanto mejor convergencia) consigue. Por el contrario, MOPSO puntúa visiblemente peor respecto a esta métrica. En cuanto a las métricas de diversidad, NSGA-II también obtiene el mejor resultado, a pesar de no cubrir todo el frente, y vuelve a destacar por su menor tiempo de ejecución.

Esto pone de manifiesto una cierta limitación de la métrica SPR, ya que una distribución muy regular del frente obtenido por el algoritmo (como es el caso de NSGA-II, que obtiene un SP mucho menor que el del resto de algoritmos) puede pesar más en el valor resultante de SPR que el hecho de no extenderse por todo el frente real. De hecho, en la mé-

trica NH (que también mide la diversidad), son los algoritmos MOPSO y MOEA-D los mejor parados, y el resultado de NSGA-II es más pobre.

Por último, se confirma el peor resultado en cuanto a Espaciamiento (y por tanto regularidad del frente de soluciones obtenido) del algoritmo MOACOr en este caso.

9.4.2. Líneas 3, 5 y 7

Las líneas 3 y 5 coinciden en buena parte de su recorrido (véase Capítulo III), por lo que también se pueden analizar conjuntamente en gran medida. Por otra parte, la línea 7 comparte también parte de su recorrido con la línea 5, por lo que dicha parte queda incluida en este apartado. En este caso, se han escogido para su análisis los siguientes tramos:

Manises-Salt de l'Aigua

Este tramo cuenta con una longitud de 971 metros, y discurre en línea recta en su mayor parte salvo por dos curvas enlazadas de 320 y 420 metros de radio (con un desarrollo total de 120 metros) y otra curva en su tramo final de 415 metros de radio y 30 metros de longitud. En cuanto a su perfil longitudinal, el tramo discurre con una fuerte pendiente (25 mm/m) durante sus primeros 200 metros, y luego presenta una rampa pronunciada de 23,2 mm/m durante los siguientes 200 metros, discurriendo el resto del tramo en llano. Por otra parte, el tramo cuenta con una limitación a 55 km/h a la salida de la estación de Manises, y otra de 30 km/h que afecta a sus últimos 200 metros de recorrido. La Figura 9.16 muestra la comparativa entre el frente de Pareto real y las soluciones aportadas por los cinco algoritmos.

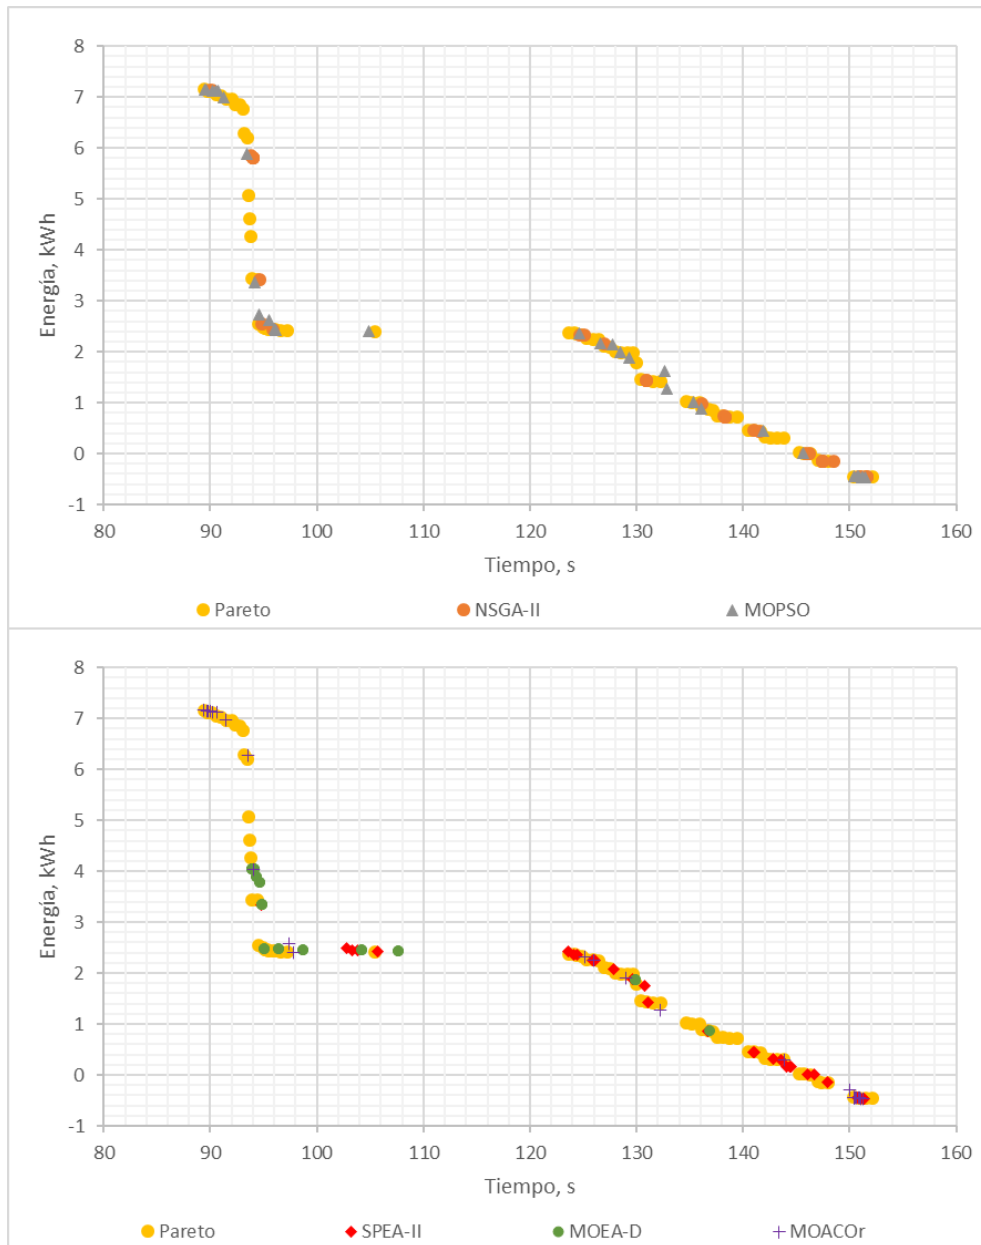


Figura 9.16: Resultados de los cinco algoritmos en el tramo Manises-Salt de l'Aigua (L3/L5). Fuente: Elaboración propia.

En este caso se vuelve a obtener un frente de Pareto real fraccionado, con una primera rama muy discontinua que cubre un rango de tiempos de viaje de apenas 10 segundos (de 90 a 97) para un rango de consumos que va desde los 7,12 hasta los 2,42 kWh. Por el contrario, la segunda rama, más tendida, cubre desde los 124 a los 152 segundos, con un consumo en el primer caso de 2,37 kWh y una energía regenerada de 0,46 kWh en el segundo.

Este frente tan irregular, probablemente debido tanto al importante cambio de pendiente longitudinal en la sección central del tramo como a la restrictiva limitación de velocidad en su parte final, representa un cierto desafío para los algoritmos de optimización. Como se ve en la Figura 9.16, todos los algoritmos ofrecen soluciones muy próximas al frente de Pareto y con presencia en ambas ramas, si bien se aprecian a simple vista problemas de diversidad.

| Métrica | Distancia Generacional (GD) | Extensión (SPR) | Espaciamiento (SP) | Hipervolumen Normalizado (NH) | Tiempo de ejecución (s) |
|-------------|-----------------------------|-----------------|--------------------|-------------------------------|-------------------------|
| Frente real | N/A | 0,845 | 2,268 | 0,330 | N/A |
| NSGA-II | 0,048 | 1,077 | 5,239 | 0,345 | 614 |
| MOPSO | 0,040 | 1,000 | 3,858 | 0,341 | 781 |
| SPEA-II | 0,132 | 0,985 | 3,498 | 0,363 | 788 |
| MOEA-D | 0,153 | 1,308 | 4,263 | 0,371 | 883 |
| MOACOr | 0,034 | 1,261 | 5,347 | 0,361 | 796 |

Tabla 9.11: Métricas obtenidas en el tramo Manises-Salt de l’Aigua (L3/L5). Fuente: Elaboración propia.

Observando los resultados mostrados en la Tabla 9.11, se puede ver bastante disparidad, como era de esperar con un frente objetivo tan irregular. Particularmente los resultados de Espaciamiento son, como es lógico, muy elevados, lo que también afecta a la métrica de Extensión (si bien el mejor algoritmo en ambos frentes es SPEA-II, con MOPSO muy próximo). Por otra parte, la métrica NH muestra resultados muy parejos entre los cinco algoritmos. En términos de convergencia MOACOr es el que mejor resultados ofrece, seguido de MOPSO y NSGA-II, mientras que este último vuelve a ser el mejor en cuanto a tiempo de ejecución.

Mislata-Nou d’Octubre

Este tramo cuenta con una longitud de 876 metros, y no tiene ninguna limitación de velocidad en todo su recorrido. Su perfil longitudinal es variado, con rampas de hasta 8,5 mm/m en sus primeros 200 metros, pendientes de hasta 17,3 mm/m en su tramo central, y un trazado llano en los últimos 150 metros. En cuanto a su trazado en planta, presenta tramos rectos alternando con varias curvas con radios que van desde los 600 a los 2.800

metros. La Figura 9.17 muestra los resultados de los algoritmos en comparación con el frente de Pareto real.




Figura 9.17: Resultados de los cinco algoritmos en el tramo Mislata-Nou d'Octubre (L3/L5). Fuente: Elaboración propia.

En este caso la curva de Pareto real es completa y bien distribuida, con un rango de tiempos de viaje entre 70 y 140 segundos y un rango de consumos entre 8,00 y 1,13 kWh. Observando las gráficas se puede ver cómo todos los algoritmos logran una buena convergencia con el frente de Pareto, mientras que, en términos de diversidad, MOPSO y MOEA-D parecen ofrecer un mejor resultado, mientras que SPEA-II y NSGA-II muestran mayores problemas.

| Métrica | Distancia Generacional (GD) | Extensión (SPR) | Espaciamiento (SP) | Hipervolumen Normalizado (NH) | Tiempo de ejecución (s) |
|-------------|-----------------------------|-----------------|--------------------|-------------------------------|-------------------------|
| Frente real | N/A | 0,513 | 0,279 | 0,199 | N/A |
| NSGA-II | 0,045 | 1,202 | 4,092 | 0,432 | 548 |
| MOPSO | 0,049 | 0,797 | 2,467 | 0,225 | 790 |
| SPEA-II | 0,032 | 1,137 | 3,038 | 0,414 | 737 |
| MOEA-D | 0,032 | 1,140 | 4,639 | 0,237 | 736 |
| MOACOr | 0,037 | 0,948 | 3,578 | 0,229 | 730 |

Tabla 9.12: Métricas obtenidas en el tramo Mislata-Nou d’Octubre (L3/L5). Fuente: Elaboración propia.

En base a los resultados de la Tabla 9.12, se puede ver cómo, en efecto, todos los algoritmos ofrecen un buen resultado de convergencia (métrica GD), siendo SPEA-II y MOEA-D los mejores en este sentido. Por otra parte, MOPSO y MOACOr son los que mejor puntúan en cuanto a la métrica de Extensión, mientras que SPEA-II y NSGA-II puntúan peor tanto en este apartado como en Espaciamiento (SP) tal y como se había anticipado. NSGA-II sigue ofreciendo el mejor tiempo de cálculo (frente a los cuatro algoritmos restantes que muestran resultados similares), pero en términos globales es MOPSO el que da un mejor resultado.

Ayora-Amistat

Este tramo, perteneciente a las líneas 5 y 7, tiene una longitud de 832 metros y presenta una limitación de velocidad de 35 km/h desde la salida de la estación de Ayora hasta casi la mitad del recorrido. Su perfil longitudinal es prácticamente llano, con unas rampas suaves (2 mm/m) en su parte central seguidas de una pendiente de 5 mm/m. En cuanto a su trazado en planta, presenta una curva de 100 metros de radio y 200 metros de desarrollo en su parte inicial (de ahí la limitación de velocidad), discurriendo el resto del tramo en

línea recta. La Figura 9.18 muestra la comparativa entre el frente de Pareto real y los resultados de los algoritmos.




Figura 9.18: Resultados de los cinco algoritmos en el tramo Ayora-Amistat (L5/L7). Fuente: Elaboración propia.

En este caso el frente de Pareto real es también completo y bien distribuido, si bien se observa que cubre un importante rango de tiempos de viaje (entre 85 y 134 segundos) con un rango de consumos más limitados (entre 5,44 y 2,27 kWh). Es por tanto una curva bastante tendida en comparación con las analizadas hasta este punto.

De nuevo todos los algoritmos parecen obtener soluciones muy próximas al frente de Pareto, y es en la distribución y regularidad de sus respectivos frentes donde se observan más diferencias: MOPSO y MOACOr parecen ser los que mejor cubren la totalidad del frente, mientras que SPEA-II parece centrarse más en el primer tramo de la curva (donde la pendiente es más pronunciada), y NSGA-II en el segundo.

| Métrica | Distancia Generacional (GD) | Extensión (SPR) | Espaciamiento (SP) | Hipervolumen Normalizado (NH) | Tiempo de ejecución (s) |
|-------------|-----------------------------|-----------------|--------------------|-------------------------------|-------------------------|
| Frente real | N/A | 0,553 | 0,378 | 0,209 | N/A |
| NSGA-II | 0,041 | 1,006 | 1,985 | 0,275 | 617 |
| MOPSO | 0,055 | 0,611 | 1,299 | 0,235 | 907 |
| SPEA-II | 0,044 | 0,940 | 2,061 | 0,247 | 842 |
| MOEA-D | 0,064 | 1,067 | 2,385 | 0,267 | 845 |
| MOACOr | 0,048 | 0,801 | 1,591 | 0,239 | 881 |

Tabla 9.13: Métricas obtenidas en el tramo Ayora-Amistat (L5/L7). Fuente: Elaboración propia.

De acuerdo a los resultados de la Tabla 9.13, vuelve a observarse mucha igualdad en cuanto a la métrica GD (si bien NSGA-II es el que mejor resultado obtiene). MOPSO es el que mejor se comporta respecto a las métricas de diversidad y regularidad, seguido de MOACOr, como se podía intuir al observar la Figura 9.18. Por el contrario, el resultado de SPEA-II y NSGA-II es más sorprendente, ya que ambos mejoran a MOEA-D tanto en la métrica SPR como en la SP (y SPEA-II también lo hace respecto a la métrica NH). Por tanto, en este caso particular parece que el algoritmo que peor resultados ofrece es MOEA-D

Àngel Guimerà-Avinguda del Cid

Este tramo tiene una extensión de 1.111 metros y presenta un perfil longitudinal que inicia con una pendiente suave (3,7 mm/m) que, tras unos 60 metros, se transforma en rampa de magnitud similar (4,5 mm/m). A partir de los 450 metros de trayecto, la rampa se agu-

diza notablemente hasta alcanzar los 25 mm/m. Los últimos 100 metros del recorrido, aproximadamente, discurren en llano. En cuanto a su trazado en planta, este tramo alterna secciones en recta y en curva, con radios entre 230 y 340 metros. Existe una única limitación de velocidad (a 70 km/h) entre los 700 y 910 metros del recorrido.

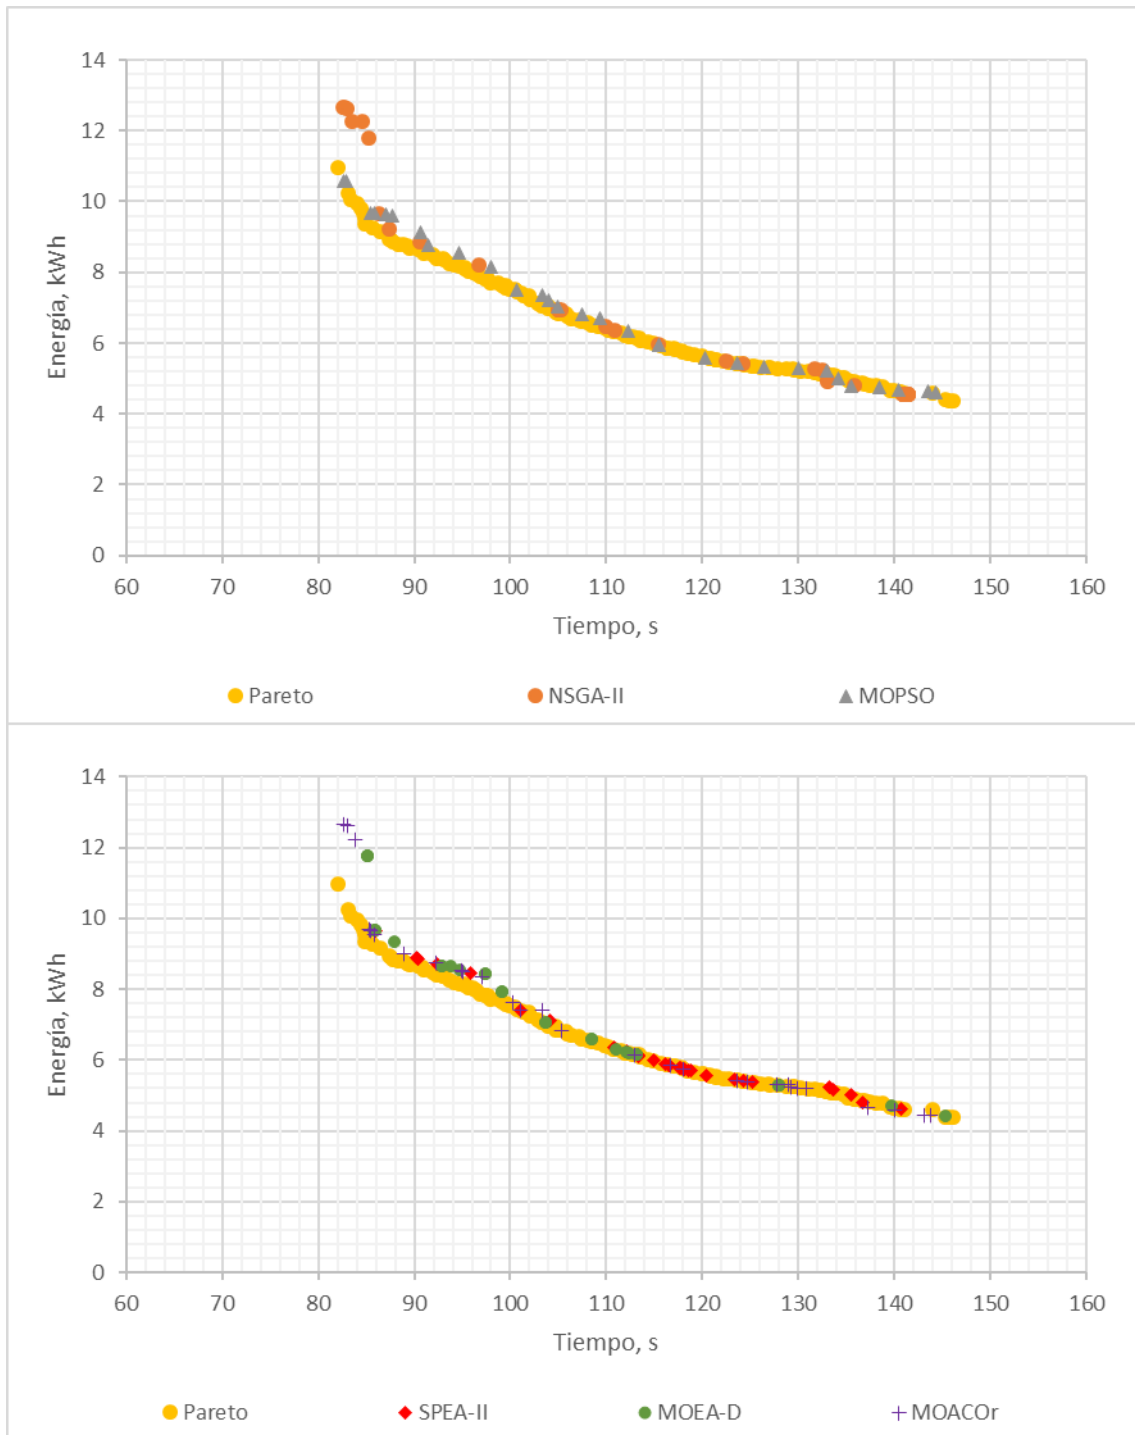


Figura 9.19: Resultados de los cinco algoritmos en el tramo Àngel Guimerà-Av. del Cid (L3/L5). Fuente: Elaboración propia.

De acuerdo a los resultados mostrados en la Figura 9.19, en este caso el frente de Pareto real es continuo y tiene un trazado bastante próximo a una línea recta, con un rango de tiempos de viaje entre 82 y 146 segundos y un rango de consumos energéticos entre 10,97 y 4,38 kWh. En cuanto al rendimiento de los algoritmos, en este caso NSGA-II parece cubrir mejor el frente que en otras ocasiones, a costa de ofrecer un puñado de soluciones que están claramente alejadas de la curva de Pareto. Algo similar le ocurre a MOACOr. Por otra parte, MOPSO y MOEA-D parecen ofrecer un mejor resultado tanto en términos de convergencia como diversidad, y SPEA-II podría tener problemas de regularidad.

| Métrica | Distancia Generacional (GD) | Extensión (SPR) | Espaciamiento (SP) | Hipervolumen Normalizado (NH) | Tiempo de ejecución (s) |
|-------------|-----------------------------|-----------------|--------------------|-------------------------------|-------------------------|
| Frente real | N/A | 0,487 | 0,333 | 0,325 | N/A |
| NSGA-II | 0,171 | 0,973 | 2,533 | 0,386 | 707 |
| MOPSO | 0,067 | 0,506 | 1,209 | 0,364 | 1.189 |
| SPEA-II | 0,038 | 0,830 | 2,040 | 0,370 | 1.006 |
| MOEA-D | 0,135 | 1,076 | 3,494 | 0,388 | 1.030 |
| MOACOr | 0,127 | 0,690 | 1,896 | 0,371 | 952 |

Tabla 9.14: Métricas obtenidas en el tramo Àngel Guimerà-Avinguda del Cid (L3/L5). Fuente: Elaboración propia.

De acuerdo a los resultados de la Tabla 9.14, se puede ver que, en este caso, SPEA-II ofrece el mejor resultado en cuanto a convergencia (métrica GD), mientras que NSGA-II puntúa mucho peor, seguido de MOEA-D y MOACOr como se había observado en la Figura 9.19. Por otra parte, MOPSO vuelve a ser el que mejor puntúa en las métricas de diversidad y regularidad, mientras que MOEA-D presenta mayores problemas en el Espaciamiento que NSGA-II y SPEA-II, contradiciendo lo que se esperaba al observar las gráficas. NSGA-II vuelve a ser el más rápido en tiempo de ejecución.

9.4.3. Conclusiones preliminares

A la vista del análisis de los resultados obtenidos en los ocho tramos seleccionados, se pueden establecer unas primeras conclusiones preliminares sobre el rendimiento de los cinco algoritmos de optimización:

- En términos de convergencia (medida mediante la métrica GD), por lo general los cinco algoritmos presentan buenos resultados y ofrecen conjuntos de soluciones muy próximas al frente de Pareto real. No obstante, NSGA-II suele destacar por encima de los demás en este apartado, seguido de cerca por MOACOr.
- En términos de diversidad (medida mediante las métricas SPR y NH), el algoritmo que presenta los mejores resultados es MOPSO, si bien SPEA-II también presenta valores positivos (y, en menor medida, MOACOr). Por el contrario, NSGA-II suele puntuar pobremente en estas métricas. El rendimiento de MOEA-D en este sentido es irregular, con buenos resultados en algunos tramos y peores en otros.
- La regularidad de las soluciones de cada algoritmo (entendida como una distribución equiespaciada de las mismas) puede verse afectada en aquellos tramos en los que, debido a condicionantes específicos (perfil longitudinal, limitaciones importantes de velocidad), la curva de Pareto real queda partida en dos. En estos casos todos los algoritmos arrojan valores de Espaciamiento (SP) muy elevados.
- En aquellos tramos en los que la curva de Pareto real está fraccionada, la métrica de Extensión (SPR) puede verse sesgada debido a su naturaleza combinada: al medir tanto la distribución como la regularidad del conjunto de soluciones, un pobre resultado en el segundo aspecto (causado no por el algoritmo en sí sino por la naturaleza de la curva real) puede enmascarar una correcta distribución por todo el frente.
- Por último, en cuanto a tiempos de ejecución, NSGA-II es, de forma consistente, el que precisa de un menor tiempo para ofrecer soluciones, mientras que MOPSO es el que más tiempo requiere. Los restantes algoritmos se mueven en valores intermedios similares entre sí.

El siguiente paso del análisis se centrará en una evaluación global de las métricas obtenidas en los 64 tramos, para así poder confirmar (o refutar) las tendencias observadas en este primer análisis por tramos.

9.5. Comparativa cualitativa global

Para poder evaluar con mayor profundidad el rendimiento de cada algoritmo en base a los resultados obtenidos en los 64 casos de estudio, se ha calculado, con respecto a cada una de las cuatro métricas, cuál es el algoritmo que mejor puntúa en cada caso. La Figura 9.20 recoge los resultados de este cálculo según la métrica empleada. Se ha omitido la representación de los resultados correspondientes al tiempo de ejecución ya que,

con respecto a este parámetro, NSGA-II ha obtenido el menor valor en el 100% de los casos.




Figura 9.20: Distribución de la mejor puntuación de cada algoritmo, para cada métrica, en cada uno de los 64 casos de estudio. Fuente: Elaboración propia.

Como se puede ver, en términos de la métrica GD (que mide la convergencia con el frente de Pareto real), los resultados están bastante repartidos. MOEA-D es el algoritmo que mejor resultado da (un 29% de los casos) seguido de MOACOr (un 27%), mientras que MOPSO sólo obtiene el menor valor de GD en un 11% de los casos. Por el contrario, las métricas que miden la diversidad (SPR y NH) muestran un dominio abrumador de MOPSO, que obtiene el mejor valor en un 80% y un 70% de los casos, respectivamente. Si nos centramos en la métrica NH (menos sensible a la distorsión que provocan frentes de Pareto discontinuos, como se vio en el apartado 9.4), sólo MOACOr (y, en menor medida, SPEA-II) ofrecen una cierta alternancia con MOPSO.

Por último, en términos de regularidad de la solución (medida a través de la métrica SP), si bien también el algoritmo MOPSO destaca en un 50% de los casos, se observa más variedad de resultados. MOEA-D obtiene el menor valor en un 28% de los casos, y

SPEA-II en un 13%, si bien esta métrica, como ya se vio en el apartado 9.4, puede verse afectada por la discontinuidad del frente de Pareto en algunos tramos.

Para poder profundizar aún más en el análisis del rendimiento de los algoritmos, se ha calculado no sólo cuál obtiene el mejor resultado en cada métrica y caso, sino la clasificación completa. Esto permitirá identificar las posibles jerarquías que se establezcan entre algoritmos. La Figura 9.21 recopila los resultados de esta clasificación para cada algoritmo, en el que cada valor representa el número de veces que dicho algoritmo ha puntuado en primera posición, segunda, tercera, etc., para cada una de las métricas definidas.

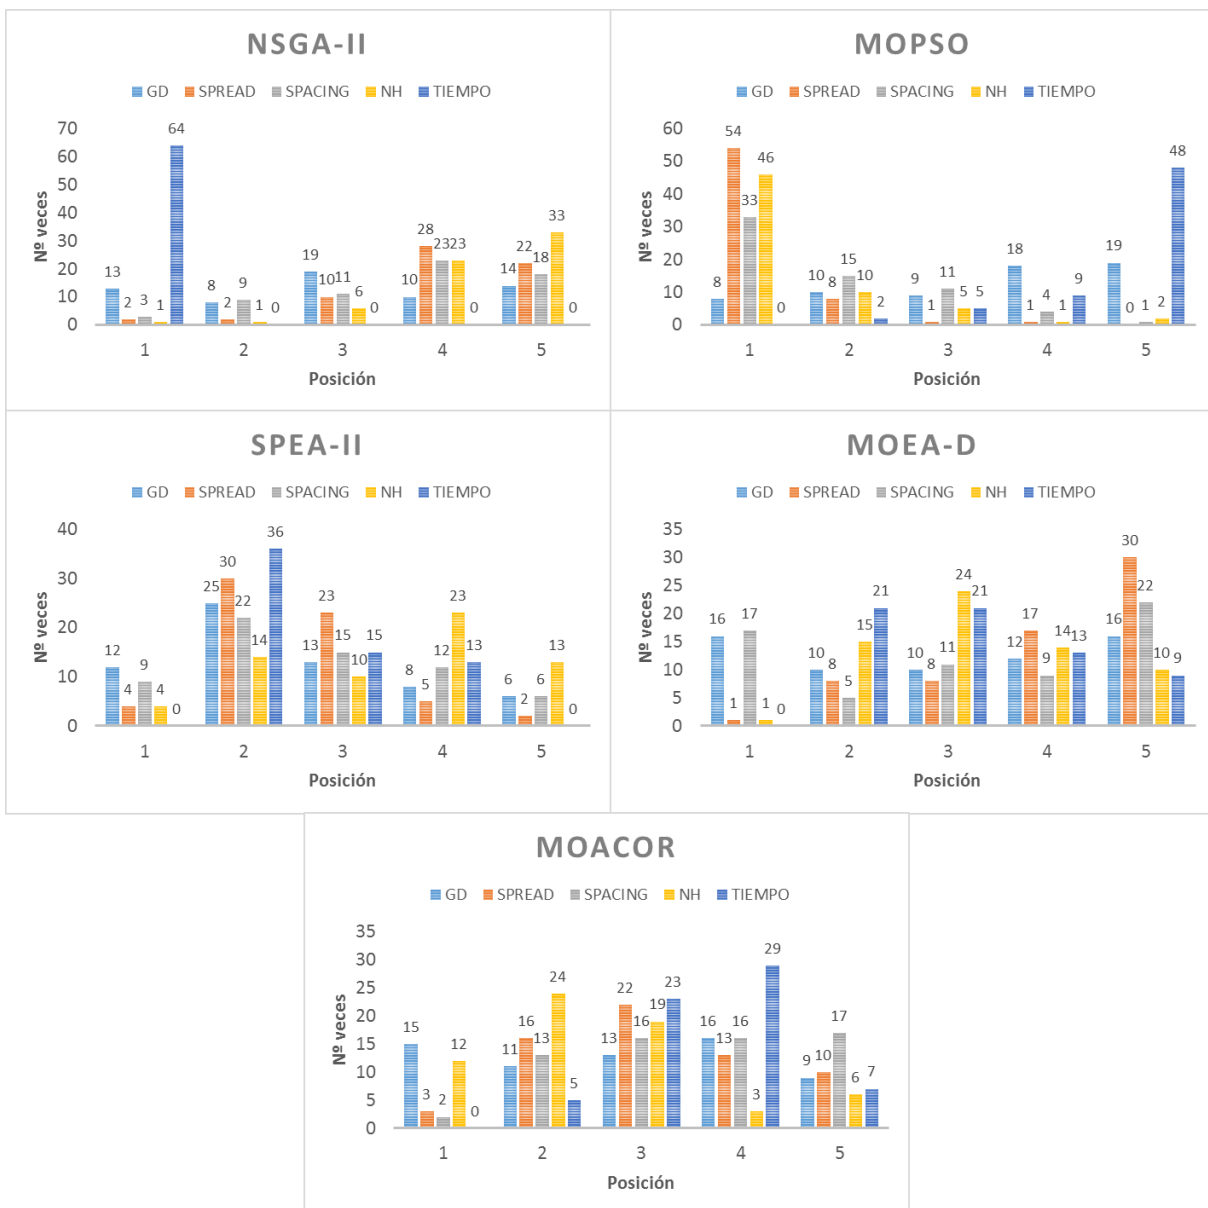


Figura 9.21: Clasificación de cada algoritmo para cada métrica. Fuente: Elaboración propia.

Como se puede apreciar en la Figura 9.21, el algoritmo NSGA-II es, de forma abrumadora, el que menor tiempo de ejecución precisa. También tiende a puntuar positivamente en cuanto a convergencia con el frente de Pareto real (medida a través de la métrica GD), ya que en 40 de los 64 casos de estudio ha estado entre los tres mejores en este aspecto. No obstante, respecto a las restantes métricas este algoritmo tiende a quedar siempre en los últimos puestos, especialmente en lo que se refiere a las métricas de diversidad (SPR y NH).

Por otra parte, MOPSO, si bien es de forma consistente el más lento de los algoritmos, confirma su buen rendimiento en términos de diversidad de las soluciones que aporta, ya que ocupa las primeras tres posiciones en 63 de 64 casos respecto a la métrica SPR y en 61 de 64 respecto a la métrica NH. En cambio, su rendimiento en cuanto a convergencia puntúa en los dos últimos puestos en 37 de 64 casos.

Los otros tres algoritmos tienden a ocupar posiciones intermedias entre NSGA-II y MOPSO. En relación a la métrica SPR, el algoritmo SPEA-II parece ser la mejor alternativa a MOPSO, ya que ocupa el segundo o tercer lugar en 53 de 64 casos. En cambio, atendiendo a la métrica NH (menos sensible a frentes discontinuos), es el algoritmo MOACO el que más se aproxima a MOPSO, con 43 de 64 casos en los que obtiene el segundo o tercer mejor valor de dicha métrica. Por último, el algoritmo MOEA-D obtiene unos resultados muy variables, aunque tiende a puntuar más en los últimos puestos salvo en términos de métricas GD y SP.

9.6. Comparativa estadística

Como último paso de la comparación de los resultados ofrecidos por los cinco algoritmos meta-heurísticos, se procede a realizar un análisis estadístico que permita discernir si las diferencias y tendencias observadas, tanto tramo a tramo como globalmente, tienen alguna significancia estadística que permita extraer conclusiones más fundamentadas. Para ello se toman los 64 casos de estudio como muestra a analizar.

El análisis estadístico se ha centrado en cada una de las cuatro métricas previamente establecidas, dejando de lado el tiempo de ejecución. Éste se ha excluido, por una parte, porque se ha considerado que el análisis realizado hasta este punto es suficiente para determinar las diferencias entre algoritmos en este aspecto; y, por otra parte, porque, como ya se ha explicado, el tiempo de ejecución depende en gran medida de la eficiencia del simulador de marchas, que podría modificarse notablemente a través de una optimización del algoritmo (o incluso de un cambio en el lenguaje de programación). Esto que-

da fuera del alcance de la presente tesis, y de ahí que se le dé una importancia menor al tiempo de ejecución como criterio de comparación entre los algoritmos.

Así pues, para cada una de las cuatro métricas, se han tomado los resultados obtenidos por cada algoritmo y se han calculado los siguientes estadísticos:

- Media.
- Mediana.
- Desviación típica.
- Asimetría.
- Curtosis.

Por otra parte, se ha evaluado, para cada muestra, su grado de normalidad, empleando para ello el criterio de asimetría y curtosis, esto es, que los valores de ambos parámetros deben localizarse en el rango $[-2, 2]$ para aceptar normalidad de la muestra. Una vez calculados estos estadísticos, se han llevado a cabo una serie de test comparativos para cada métrica, resumidos en la Figura 9.22:

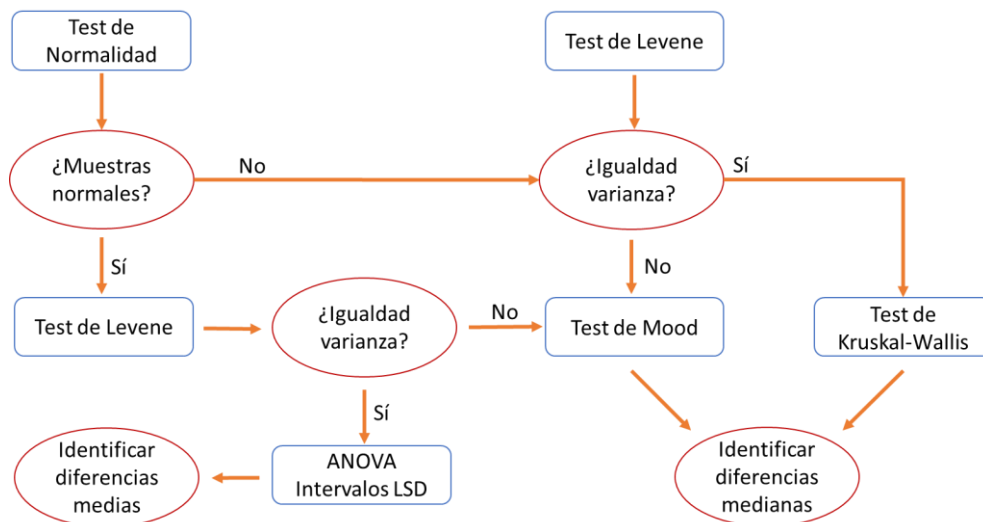


Figura 9.22: Esquema de los test estadísticos aplicados. Fuente: Elaboración propia.

Así pues, en el caso de que se pueda asumir la normalidad (e igualdad de varianzas) de las muestras a comparar, se emplea un análisis ANOVA y se calculan los intervalos LSD para identificar posibles diferencias entre los valores medios. Por el contrario, si las muestras no siguen una distribución normal, se opta por un test no paramétrico para identificar diferencias entre las medianas, preferentemente Kruskal-Wallis o, en el caso de

que no se cumpla el requisito de igualdad de varianza, el test de Mood. A continuación se muestran los resultados de este análisis estadístico para cada una de las cuatro métricas.

9.6.1. Distancia Generacional (GD)

Respecto a esta métrica, que mide la convergencia de la solución aportada por el algoritmo al frente de Pareto real, los resultados obtenidos hasta este punto han demostrado una cierta igualdad entre algoritmos, si bien con preponderancia de MOEA-D. La Tabla 9.15 recoge los principales marcadores estadísticos obtenidos por cada algoritmo respecto a GD.

| Estadístico | NSGA-II | MOPSO | SPEA-II | MOEA-D | MOACOr |
|-----------------------------------|------------------------------|--------|---------|--------|--------|
| Media | 0,080 | 0,079 | 0,058 | 0,079 | 0,080 |
| Mediana | 0,047 | 0,058 | 0,037 | 0,045 | 0,036 |
| Desviación típica | 0,087 | 0,086 | 0,045 | 0,101 | 0,120 |
| Asimetría | 11,234 | 17,281 | 9,658 | 19,804 | 16,045 |
| Curtosis | 22,679 | 55,602 | 17,722 | 70,514 | 44,053 |
| Normalidad | NO | NO | NO | NO | NO |
| Igualdad varianza (Levene) | SI (P-valor = 0,3246 > 0,05) | | | | |
| Igualdad mediana (Kruskal-Wallis) | SI (P-valor = 0,1183 > 0,05) | | | | |

Tabla 9.15: Resultados estadísticos para la métrica GD. Fuente: Elaboración propia.

Como se puede ver en los resultados de la Tabla 9.15, la distribución de los valores de la métrica GD no se puede asimilar a una normal en ningún caso, pero sí que se puede afirmar que no existe diferencia significativa entre las varianzas de cada uno de los 5 algoritmos con un nivel de confianza del 95% (test de Levene).

Por ello, para poder detectar si existe realmente una diferencia significativa entre los diferentes algoritmos respecto a esta métrica, es necesario recurrir a un test no paramétrico como el de Kruskal-Wallis, que no compara los valores medios sino las medianas de las distribuciones. En este caso, no se detecta una diferencia significativa entre las medianas de la métrica GD para ninguno de los cinco algoritmos (con un 95% de nivel de confianza). Por ello, a efectos de significancia estadística, y con la información disponible, se puede concluir que los cinco algoritmos tendrán un desempeño análogo en cuanto a la métrica GD y, por tanto, ofrecerán soluciones con un nivel de convergencia similar.

9.6.2. Extensión (SPR)

Respecto a esta métrica, que mide de forma combinada la diversidad y regularidad de la solución aportada por el algoritmo, los resultados obtenidos hasta este punto indican una clara preponderancia del algoritmo MOPSO. La Tabla 9.16 recoge los principales marcadores estadísticos obtenidos por cada algoritmo respecto a SPR.

| Estadístico | NSGA-II | MOPSO | SPEA-II | MOEA-D | MOACOr |
|----------------------------|-------------------------|--------|---------|--------|--------|
| Media | 1,120 | 0,782 | 0,973 | 1,153 | 1,021 |
| Mediana | 1,126 | 0,759 | 0,955 | 1,135 | 1,031 |
| Desviación típica | 0,167 | 0,137 | 0,163 | 0,116 | 0,204 |
| Asimetría | 0,867 | 1,437 | 0,656 | 1,649 | -0,474 |
| Curtosis | -0,920 | -0,667 | -0,631 | -0,337 | -1,587 |
| Normalidad | SI | SI | SI | SI | SI |
| Igualdad varianza (Levene) | NO (P-valor = 0 < 0,05) | | | | |
| Igualdad mediana (Mood) | NO (P-valor = 0 < 0,05) | | | | |

Tabla 9.16: Resultados estadísticos para la métrica SPR. Fuente: Elaboración propia.

De acuerdo a los resultados de la Tabla 9.16, la distribución de los valores de la métrica SPR sí se puede asimilar a una normal en los cinco casos. Sin embargo, en este caso no se cumple la hipótesis de igualdad de varianzas (test de Levene), lo que invalida la aplicación del ANOVA, y también el uso del test de Kruskal-Wallis. Por ello, es necesario emplear el test de Mood para evaluar las posibles diferencias entre las medianas.

En este caso, sí se detecta una diferencia significativa entre las medianas de la métrica SPR con un 95% de nivel de confianza. Para poder detectar qué algoritmos presentan un valor mediano significativamente diferente, se recurre a calcular los intervalos de confianza, con la corrección de Bonferroni para asegurar un nivel de confianza estadística del 95%. Este procedimiento calcula unos intervalos de confianza más amplios, y computa la diferencia entre los rangos promedio de las variables a comparar (en este caso, la métrica SPR) agrupadas por parejas, para identificar qué diferencias se salen de los límites del intervalo. El resultado de esta comparativa se recoge en la Tabla 9.17.

| Emparejamientos | Diferencia en el rango promedio | Límites del intervalo |
|--------------------|---------------------------------|-----------------------|
| NSGA-II vs MOPSO | 146,593 | ± 45,767 |
| NSGA-II vs SPEA-II | 66,148 | ± 45,767 |
| NSGA-II vs MOEA-D | -19,414 | ± 45,767 |
| NSGA-II vs MOACOr | 41,555 | ± 45,767 |
| MOPSO vs SPEA-II | 80,444 | ± 45,767 |
| MOPSO vs MOEA-D | 166,007 | ± 45,767 |
| MOPSO vs MOACOr | 105,038 | ± 45,767 |
| SPEA-II vs MOEA-D | -85,563 | ± 45,767 |
| SPEA-II vs MOACOr | -24,594 | ± 45,767 |
| MOEA-D vs MOACOr | 60,969 | ± 45,767 |

Tabla 9.17: Intervalos de Bonferroni de la mediana para la métrica SPR. Fuente: Elaboración propia.

A la vista de los resultados de la Tabla 9.17, se pueden establecer las siguientes conclusiones, con un nivel de confianza estadística del 95%:

- El algoritmo MOPSO presenta un valor mediano de la métrica SPR significativamente menor al de los restantes algoritmos.
- El algoritmo SPEA-II presenta un valor mediano de la métrica SPR significativamente menor al de MOEA-D y NSGA-II.
- El algoritmo MOACOr presenta un valor mediano de la métrica SPR significativamente menor al del MOEA-D.
- No se puede determinar que existan diferencias significativas entre los valores medianos de la métrica SPR de los algoritmos MOEA-D y NSGA-II.

9.6.3. Espaciamiento (SP)

Respecto a esta métrica, que mide la regularidad (entendida como distribución uniforme) de la solución aportada por el algoritmo, los resultados obtenidos hasta este punto indican una cierta preponderancia del algoritmo MOPSO (aunque menor que en el caso de la métrica de Extensión), seguido por MOEA-D. La Tabla 9.18 recoge los principales marcadores estadísticos obtenidos por cada algoritmo respecto a SP.

| Estadístico | NSGA-II | MOPSO | SPEA-II | MOEA-D | MOACOr |
|-----------------------------------|-----------------------------|-------|---------|--------|--------|
| Media | 3,136 | 2,375 | 2,687 | 2,646 | 3,103 |
| Mediana | 2,532 | 2,107 | 2,125 | 2,180 | 2,745 |
| Desviación típica | 2,121 | 1,563 | 1,755 | 1,728 | 2,016 |
| Asimetría | 4,482 | 3,526 | 3,942 | 7,509 | 3,652 |
| Curtosis | 2,596 | 1,209 | 2,228 | 13,062 | 1,684 |
| Normalidad | NO | NO | NO | NO | NO |
| Igualdad varianza (Levene) | SI (P-valor = 0,172 > 0,05) | | | | |
| Igualdad mediana (Kruskal-Wallis) | SI (P-valor = 0,144 > 0,05) | | | | |

Tabla 9.18: Resultados estadísticos para la métrica SP. Fuente: Elaboración propia.

Como se puede ver de los resultados de la Tabla 9.18, la distribución de los valores de la métrica SP no puede asimilarse a una normal, pero sí cumple la hipótesis de igualdad de varianzas de acuerdo al test de Levene, por lo que es de aplicación el test de Kruskal-Wallis para determinar si existen diferencias significativas entre las medianas de los cinco algoritmos.

En este caso, como el P-valor del test de Kruskal-Wallis es superior a 0,05, no existe diferencia significativa entre las medianas de la métrica SP con un 95% de nivel de confianza. Por lo tanto, en términos de regularidad de la solución aportada, y con los datos disponibles, los cinco algoritmos proporcionarán un conjunto con un desempeño similar en cuanto al valor mediano de Espaciamento.

9.6.4. Hipervolumen Normalizado (NH)

Para finalizar, con respecto a esta métrica, que mide la diversidad de la solución aportada por el algoritmo, los resultados obtenidos hasta este punto indican una clara preponderancia del algoritmo MOPSO, seguido por el algoritmo MOACOr. La Tabla 9.19 recoge los principales marcadores estadísticos obtenidos por cada algoritmo respecto a NH.

| Estadístico | NSGA-II | MOPSO | SPEA-II | MOEA-D | MOACOr |
|-----------------------------------|---|-------|---------|--------|--------|
| Media | 0,358 | 0,302 | 0,341 | 0,323 | 0,319 |
| Mediana | 0,345 | 0,288 | 0,337 | 0,312 | 0,305 |
| Desviación típica | 0,090 | 0,082 | 0,084 | 0,089 | 0,089 |
| Asimetría | 1,725 | 2,169 | 3,307 | 2,239 | 3,223 |
| Curtosis | 1,699 | 0,372 | 5,363 | 0,762 | 3,121 |
| Normalidad | SI | NO | NO | NO | NO |
| Normalidad (Shapiro-Wilk) | SI | SI | NO | SI | NO |
| Igualdad varianza (Levene) | SI (P-valor = 0,950 > 0,05) | | | | |
| Igualdad medias (ANOVA) | NO (P-valor = 0,001 < 0,05) (Sólo NSGA-II, MOPSO y MOEA-D) | | | | |
| Igualdad mediana (Kruskal-Wallis) | NO (P-valor = 0,001 < 0,05) | | | | |

Tabla 9.19: Resultados estadísticos para la métrica NH. Fuente: Elaboración propia.

De acuerdo a los resultados de la Tabla 9.19, la distribución de los valores de la métrica NH no puede asimilarse a una normal en todos los casos, si bien sí podría identificarse como tal la distribución correspondiente al algoritmo NSGA-II, y las de los algoritmos MOPSO y MOEA-D quedan muy cerca de cumplir el criterio. Para confirmar o descartar la hipótesis de normalidad de una forma más precisa, en este caso se ha aplicado adicionalmente el test de Shapiro-Wilk, el cual confirma normalidad para las muestras de NSGA-II, MOPSO y MOEA-D. Por otra parte, también se cumple la hipótesis de normalidad de varianza entre las cinco muestras, de acuerdo al test de Levene.

Este resultado abre la posibilidad de realizar una doble comparativa. Por una parte, se ha realizado un ANOVA entre los resultados de los tres algoritmos que sí siguen una distribución normal (esto es, NSGA-II, MOPSO y MOEA-D), el cual indica que sí existe una diferencia significativa entre los valores medios de NH de estos tres algoritmos con una confianza estadística del 95%. Por otra parte, se ha aplicado el test de Kruskal-Wallis a los resultados de los cinco algoritmos, identificándose también una diferencia significativa entre los valores medianos de NH. Los resultados de ambos test se recogen también en la Tabla 9.19.

Para identificar qué valores medios son diferentes de acuerdo al ANOVA, la Tabla 9.20 recoge la comparativa por parejas de los intervalos LSD (o intervalos de Fisher) para cada uno de los tres algoritmos que sí cumplen la hipótesis de normalidad. Siguiendo el

mismo procedimiento al mostrado en la Tabla 9.17 (si bien sin la corrección de Bonferroni), se identifican como diferentes aquellos emparejamientos en los que la diferencia de medias es mayor a los límites de los intervalos calculados.

| Emparejamiento | Diferencia de medias | Límites del intervalo |
|-------------------|----------------------|-----------------------|
| NSGA-II vs MOPSO | 0,056 | ± 0,030 |
| NSGA-II vs MOEA-D | 0,035 | ± 0,030 |
| MOPSO vs MOEA-D | -0,021 | ± 0,030 |

Tabla 9.20: Intervalos LSD de la media para la métrica NH. Fuente: Elaboración propia.

Como se ve en la Tabla 9.20, existen diferencias significativas entre el valor medio de la métrica NH del algoritmo NSGA-II y los correspondientes a los algoritmos MOPSO y MOEA-D. En cambio, no se puede establecer una diferencia significativa entre los valores medios de estos dos últimos algoritmos.

Por otra parte, la Tabla 9.21 recoge los intervalos de Bonferroni que comparan, para cada pareja de algoritmos, si efectivamente existe o no una diferencia en los valores medianos de la métrica NH, tal y como ha identificado el test de Kruskal-Wallis. Tal y como ya se ha explicado, se identifica que existe una diferencia significativa (con un nivel de confianza del 95%) en un emparejamiento cuando la diferencia entre los rangos promedio de ambas variables (en este caso, la mediana de la métrica NH) es mayor que el límite del intervalo calculado.

| Emparejamientos | Diferencia en el rango promedio | Límites del intervalo |
|--------------------|---------------------------------|-----------------------|
| NSGA-II vs MOPSO | 62,914 | ± 45,910 |
| NSGA-II vs SPEA-II | 17,984 | ± 45,910 |
| NSGA-II vs MOEA-D | 39,800 | ± 45,910 |
| NSGA-II vs MOACOr | 45,164 | ± 45,910 |
| MOPSO vs SPEA-II | -44,930 | ± 45,910 |
| MOPSO vs MOEA-D | -23,117 | ± 45,910 |
| MOPSO vs MOACOr | -17,750 | ± 45,910 |
| SPEA-II vs MOEA-D | 21,813 | ± 45,910 |
| SPEA-II vs MOACOr | 27,180 | ± 45,910 |
| MOEA-D vs MOACOr | 5,367 | ± 45,910 |

Tabla 9.21: Intervalos de Bonferroni de la mediana para la métrica NH. Fuente: Elaboración propia.

Como se ve en la Tabla 9.21, sólo existe una diferencia significativa en el valor mediano de la métrica NH, correspondiente al emparejamiento entre NSGA-II y MOPSO. Del resto de emparejamientos no se puede determinar ninguna diferencia con el nivel de confianza estadística requerido.

Teniendo en cuenta estos resultados, se puede determinar que los algoritmos MOPSO y MOEA-D obtienen un valor medio significativamente inferior de la métrica NH (y por tanto una mejor diversidad de su solución) en comparación con el algoritmo NSGA-II. Por otra parte, el algoritmo MOPSO ofrece un valor mediano de la métrica NH significativamente inferior al del algoritmo NSGA-II.

9.7. Conclusiones

En este Capítulo V se ha presentado el análisis de los resultados obtenidos de aplicar los cinco algoritmos meta-heurísticos de optimización seleccionados a los 64 casos de estudio disponibles y calcular las correspondientes métricas. El análisis se ha llevado a cabo en tres etapas: primero se han analizado los resultados en algunos tramos escogidos para identificar posibles tendencias; después se han determinado los resultados globales de los 64 casos de estudio, y finalmente se ha llevado a cabo un análisis estadístico para determinar si las diferencias observadas en las anteriores etapas son significativas y pueden generalizarse.

En base a estos tres análisis, se pueden establecer las siguientes conclusiones:

- En términos de convergencia, es decir, de cercanía de la solución calculada al frente de Pareto real, todos los algoritmos analizados presentan un desempeño similar. Si bien en apariencia los algoritmos MOEA-D y MOACOr parecen puntuar algo mejor en la métrica de GD, no se han detectado diferencias estadísticamente significativas.
- En términos de regularidad, se ha observado que, en determinados tramos, el frente de Pareto real queda partido en dos o tiene discontinuidades debido a condicionantes específicos del tramo que no permiten un desarrollo libre de todas las marchas posibles, tales como un trazado longitudinal particular o limitaciones de velocidad muy restrictivas. En estos casos todos los algoritmos ofrecen soluciones con un peor valor de la métrica SP. Esta discontinuidad también afecta indirectamente a la métrica SPR, lo que puede afectar a su utilidad ya que una mala distribución por causas ajenas al algoritmo puede enmascarar un buen desempeño en términos de diversidad.
- En todo caso, en lo que a regularidad se refiere, si bien algunos algoritmos (MOPSO, MOEA-D) parecen obtener mejores resultados en cuanto a la métrica SP, no se han identificado diferencias estadísticamente significativas entre los cinco algoritmos.
- En términos de diversidad de la solución que aporta el algoritmo, entendida como una distribución uniforme que cubra todo el frente de Pareto real, se ha observado una clara preponderancia del algoritmo MOPSO, y en menor medida de los algoritmos MOACOr, MOEA-D y SPEA-II. Estas diferencias han quedado confirmadas a través del análisis estadístico, con un nivel de confianza del 95%:
 - De acuerdo a la métrica SPR, el valor mediano que obtiene MOPSO es significativamente menor (y por tanto mejor) que el de los restantes algoritmos. Por otra parte, el algoritmo SPEA-II obtiene un valor mediano significativamente mejor que los algoritmos MOEA-D y NSGA-II. Por su parte, el algoritmo MOACOr mejora al algoritmo MOEA-D.
 - De acuerdo a la métrica NH, los algoritmos MOPSO y MOEA-D obtienen un valor medio significativamente menor que el algoritmo NSGA-II.
- Por último, en lo que a tiempo de ejecución se refiere, el algoritmo NSGA-II es el más rápido en todos los casos. En cambio, el algoritmo MOPSO es el que requiere más tiempo para ofrecer una solución, y los restantes algoritmos se mueven en valores intermedios entre ambos extremos. Así y todo, este resultado podría variar

con una optimización del código del simulador de marchas, cuyas ejecuciones representan la inmensa mayoría del tiempo de cálculo de todos los algoritmos metaheurísticos. De ahí que, a efectos del presente estudio, se le conceda una importancia secundaria a este apartado.

En base a estos resultados, se puede concluir que, de los cinco algoritmos, el que ofrece un mejor desempeño global es el algoritmo MOPSO, que proporciona un conjunto de soluciones con una convergencia equiparable a las de los demás y una diversidad que mejora significativamente a, como mínimo, el algoritmo NSGA-II (de acuerdo a la métrica NH), si bien se podría extender esta ventaja sobre los demás algoritmos (de acuerdo a la métrica SPR, que puede verse más afectada en tramos con un frente de Pareto discontinuo). De los restantes algoritmos, sólo SPEA-II ofrece un rendimiento que, sin alcanzar al de MOPSO, se aproxima bastante y mejora también, al menos, al ofrecido por NSGA-II.

En última instancia, el algoritmo más ampliamente usado en la literatura para la optimización de marchas (NSGA-II), si bien no presenta problemas de convergencia, es sistemáticamente el que peores resultados ha obtenido en términos de diversidad, por lo que cualquiera de los otros algoritmos analizados en la presente tesis (y, especialmente, el algoritmo MOPSO) sería una opción preferible, al menos en un contexto de ferrocarril urbano similar al de este estudio.

Con estos resultados, las principales tareas de la presente tesis han quedado completadas. En el posterior Capítulo VI se recogen las conclusiones generales alcanzadas, se determinan las limitaciones del estudio y se proponen futuras líneas de trabajo.

Capítulo VI

10. Conclusiones

En este Capítulo VI, que cierra la presente tesis, se exponen las principales conclusiones obtenidas, evaluando el grado de cumplimiento de los objetivos presentados en el Capítulo I. Por otra parte, también se discuten el alcance y las limitaciones del estudio realizado, y se proponen posibles mejoras y futuras líneas de trabajo que permitan proseguir y ampliar los resultados obtenidos.

10.1. Conclusiones

Tal y como se estableció en el Capítulo I, la motivación fundamental de la presente tesis era la de contribuir al conocimiento de las herramientas empleadas para la modelización y optimización de marchas en líneas de ferrocarril urbano, con vistas a mejorar la eficiencia energética de las mismas y favorecer un transporte de masas más sostenible. Esta motivación se articulaba a través de cuatro objetivos específicos a alcanzar durante el desarrollo de la presente tesis:

- Analizar las principales tendencias de consumo energético en la red de metro de Valencia, marco del presente estudio.
- Modelizar el consumo energético mediante el desarrollo y entrenamiento de redes neuronales y obtener un simulador de marchas validado con datos reales.
- Realizar una simulación sistemática de posibles marchas en cada tramo entre estaciones de las líneas estudiadas y obtener los correspondientes frentes de Pareto.

- Realizar una comparativa entre los algoritmos meta-heurísticos de optimización más habituales para identificar los puntos fuertes y débiles de cada uno en base a una serie de métricas y criterios preestablecidos.

Respecto al primer objetivo, se han analizado las principales características de la red de metro de Valencia, y a partir de los datos obtenidos de una extensa campaña de medición llevada a cabo durante el año 2014, se han podido establecer una serie de tendencias de consumo energético en dicha red:

- El consumo por kilómetro oscila entre 4,8 y 7,9 kWh, según el perfil de la línea y el número de paradas.
- La relación consumo bruto/consumo neto se localiza en el rango 67%-85%.
- El consumo de los sistemas auxiliares representa, en promedio, entre un 15% y un 45% del consumo total neto en disyuntor, con una clara influencia de la estación del año y la hora del día en los tramos en superficie.
- El consumo en resistencias supone, en promedio, un 3% del consumo neto total, si bien los mayores porcentajes se dan en ciertos tramos periféricos de la red, con bajas frecuencias y vía única. En los tramos centrales de la red, el porcentaje no supera el 1,5%.

Estas tendencias de consumo caracterizan a la red de metro de Valencia y determinan el contexto en el que se desarrolla el resto de la tesis.

El segundo objetivo de la tesis comprende el desarrollo de una herramienta de simulación que permita calcular tiempos de viaje y consumos por trayecto, un elemento imprescindible para el posterior planteamiento y resolución del problema de optimización de marchas. Para ello se ha elaborado un simulador de marchas con discretización temporal, basado en ecuaciones deterministas del movimiento del vehículo, que incorpora la lógica de un sistema ATO y que, a partir de los comandos de dicho sistema (además de los datos técnicos del material rodante y la geometría de la vía), es capaz de desarrollar el perfil de velocidad del vehículo y proporcionar el tiempo de viaje.

Por otra parte, y como elemento complementario al simulador, se ha desarrollado y entrenado una red neuronal que, a partir del perfil de velocidad obtenido del simulador y de los datos geométricos de la vía, proporciona la potencia eléctrica de tracción y el consumo energético total por trayecto. Este aspecto de la simulación representa un enfoque novedoso, apenas explorado hasta ahora en la literatura revisada, que permite solventar

la falta de ciertos datos técnicos del material rodante que dificultaban calcular de forma directa y fiable el consumo.

En conjunto, la herramienta simulador-red neuronal permite evaluar cualquier combinación posible de comandos del sistema ATO definido, desarrollar por completo el perfil de velocidad del vehículo entre dos estaciones consecutivas y calcular el tiempo de viaje y el consumo energético de dicho trayecto. Esta herramienta se ha validado con datos reales obtenidos de la campaña de medición llevada a cabo en la red de metro de Valencia, alcanzándose los siguientes resultados:

- Respecto al tiempo de viaje, el simulador de marchas presenta un error medio del 1,43%, un poco superior a los valores habituales alcanzados por otros autores con sus simuladores, pero suficiente a efectos de la comparativa que se pretende desarrollar.
- Respecto al consumo energético, la red neuronal presenta un error medio del 1,49%, en línea con lo que han logrado otros autores con una simulación directa. Además, la red neuronal presenta un Error Cuadrático Medio relativo (ECMr) igual o inferior al 20% con respecto a todas las series de datos empleadas para su entrenamiento, validación y test (incluyendo varios test adicionales con datos independientes), lo cual cumple con los criterios de aceptación de la red neuronal que se habían fijado de antemano.

Por tanto, el segundo objetivo de la tesis ha quedado cumplido, ya que se ha desarrollado correctamente la herramienta de simulación necesaria para proceder a plantear el problema de optimización y realizar la comparativa entre algoritmos. Mediante el uso de esta herramienta, se han podido simular, de forma sistemática, 5.832 posibles combinaciones de comandos ATO (de los cuales 666 corresponden a perfiles de regulación (R) y 5.166 a perfiles deriva-remotorización (D-R)) para cada uno de los 32 tramos de la red de metro de Valencia seleccionados para el presente estudio. Considerando ambos sentidos de circulación, se obtienen 64 nubes de puntos tiempo-energía.

Cada una de estas nubes de puntos delimitan el espacio de marchas posibles en cada tramo y sentido de circulación, y permiten calcular una aproximación al frente de Pareto real en cada caso, lo que representa el tercer objetivo de la presente tesis. Éste es un paso necesario para poder llevar a cabo una comparativa del rendimiento de los diferentes algoritmos de optimización, ya que permite evaluar las soluciones que éstos aportan en base a la curva de Pareto real.

El último objetivo de la tesis planteaba comparar de forma extensa el comportamiento de cinco algoritmos de optimización de tipo meta-heurístico, al ser esta clase de algoritmos los más empleados para resolver problemas de optimización de marchas en líneas de metro. Los algoritmos escogidos son:

- Algoritmo Genético No-dominado Clasificado (**NSGA-II**).
- Algoritmo Multi-Objetivo de Enjambre de Partículas (**MOPSO**).
- Algoritmo Evolutivo de Frente de Pareto (**SPEA-II**).
- Algoritmo Evolutivo basado en Descomposición (**MOEA-D**).
- Algoritmo Multi-Objetivo de Colonia de Hormigas (**MOACOR**).

Para comparar su rendimiento, se han empleado los cinco algoritmos para obtener conjuntos de soluciones no-dominadas en cada uno de los 64 casos de estudio, y se ha medido la bondad de dichos conjuntos de soluciones en base a una serie de métricas que evalúan su convergencia (cercanía al frente de Pareto real), diversidad (extensión a lo largo del frente de Pareto real) y regularidad (distribución uniforme a lo largo del frente de Pareto real). Las métricas escogidas son la Distancia Generacional (GD), la Extensión (SPR), el Espaciamiento (SP) y el Hipervolumen Normalizado (NH). También se ha tenido en cuenta el tiempo de ejecución del algoritmo.

La comparativa entre los algoritmos se ha realizado en tres fases: primero se han evaluado los resultados en ciertos tramos concretos representativos, después se han evaluado los resultados globales en el conjunto de 64 casos de estudio, y por último se ha llevado a cabo un análisis estadístico para determinar si las diferencias halladas eran significativas y podían extrapolarse a nivel poblacional. A raíz de este análisis se han alcanzado las siguientes conclusiones:

- En términos de convergencia (métrica GD), todos los algoritmos analizados presentan un desempeño similar, ya que no se han detectado diferencias estadísticamente significativas.
- En términos de regularidad (métrica SP), entendida ésta como una componente de la diversidad, tampoco se han identificado diferencias estadísticamente significativas entre los cinco algoritmos.
- No obstante, cabe destacar que, en aquellos tramos en los que el frente de Pareto real es claramente discontinuo, todos los algoritmos puntúan negativamente en la métrica SP. Además, esta discontinuidad afecta a la métrica SPR, que mide de

forma combinada la distribución y regularidad, lo que puede comprometer su utilidad para medir la diversidad.

- En términos de diversidad destaca notablemente el algoritmo MOPSO, y en menor medida el algoritmo SPEA-II. Estas diferencias han quedado confirmadas a través del análisis estadístico, con un nivel de confianza del 95%:
 - De acuerdo a la métrica SPR, el valor mediano que obtiene MOPSO es significativamente menor (y por tanto mejor) que el de los restantes algoritmos. Por otra parte, el algoritmo SPEA-II obtiene un valor mediano significativamente mejor que los algoritmos MOEA-D y NSGA-II. Por último, el algoritmo MOACOr mejora al algoritmo MOEA-D.
 - De acuerdo a la métrica NH, los algoritmos MOPSO y MOEA-D obtienen un valor medio significativamente menor que el algoritmo NSGA-II.
- Respecto al tiempo de ejecución, el algoritmo NSGA-II es el más rápido en todos los casos, mientras que el algoritmo MOPSO es el que requiere más tiempo para ofrecer una solución, y los restantes algoritmos se mueven en valores intermedios entre ambos extremos. Estas diferencias se deben, fundamentalmente, al número de ejecuciones del simulador de marchas que cada algoritmo necesita realizar para obtener su solución.

Por lo tanto, de acuerdo a los resultados obtenidos del presente estudio, se puede concluir que el algoritmo más empleado con diferencia para la optimización de marchas ferroviarias (NSGA-II), si bien ofrece un buen rendimiento y logra una convergencia aceptable con el frente de Pareto real, aporta menor diversidad que otros algoritmos. Así pues, de cara a futuros estudios de optimización, sería recomendable limitar el uso de NSGA-II y recurrir a algoritmos como MOPSO (o, en menor medida, SPEA-II o MOEA-D), que ofrecen conjuntos de soluciones no-dominadas con igual grado de convergencia y mayor diversidad.

10.2. Limitaciones

Si bien se han alcanzado los objetivos de la tesis y se ha obtenido una evaluación significativa del rendimiento de los cinco algoritmos meta-heurísticos, el estudio presenta ciertas limitaciones que es conveniente apuntar:

- Respecto al análisis de las tendencias de consumo en la red de metro de Valencia, es evidente que las conclusiones obtenidas pueden haber quedado desfasadas parcialmente debido al tiempo transcurrido desde que se ejecutó la campaña

- de toma de datos. Sin embargo, como el objetivo de este estudio no es la optimización efectiva de marchas en la red de metro de Valencia, se considera que el análisis realizado cumple su función al establecer un marco realista en el que llevar a cabo la comparación entre algoritmos de optimización.
- Por lo que respecta al simulador de marchas, éste presenta dos limitaciones destacables:
 - La primera se refiere a la lógica del sistema ATO implementado, ya que éste no se corresponde realmente con el utilizado en la red de metro de Valencia (del que se desconocían sus características) sino que es una simplificación del existente en la red de metro de Madrid, cuyo funcionamiento se ha podido extraer de diversas publicaciones. Esto, si bien es aceptable en el marco del estudio comparativo llevado a cabo en la presente tesis, compromete la utilidad del simulador para llevar a cabo una optimización efectiva de marchas en la red.
 - La segunda limitación tiene que ver con el error del simulador, que es algo superior al que suelen alcanzar otros autores con sus respectivos simuladores. Esta diferencia, aunque reducida, podría deberse a la discordancia con el sistema ATO ya mencionada, pero en todo caso debería resolverse si se pretende usar esta herramienta de forma más efectiva.
 - En cuanto a la red neuronal, si bien cumple todos los criterios de validación y presenta un error similar al que logran otros autores con simulación directa, se ha observado que, mientras que estima muy bien los picos de consumo durante las fases de tracción, tiende a subestimar la energía regenerada durante las fases de frenado. Esta limitación debería ser corregida para lograr una mejor estimación del consumo energético por trayecto.
 - Por otra parte, para el entrenamiento de la red neuronal se han empleado datos de pendiente y curvatura de la vía tal y como aparecían en la documentación proporcionada por FGV. Sin embargo, es posible que existan pequeñas discrepancias entre los planos y el trazado real por errores durante la construcción, operaciones de mantenimiento, etc., lo que puede explicar el poco peso relativo de la pendiente como variable de entrada de la red neuronal.
 - Otro aspecto a mejorar en el entrenamiento de la red neuronal es el posible uso de la masa del vehículo como variable de entrada. Es evidente que la masa juega un papel crucial en el consumo energético, pero no se controló el trasiego de viajeros durante la campaña de medición en la red de metro de Valencia, lo que im-

pidió emplear la masa del tren (y sus variaciones) como variable input de la red. Disponer de esta clase de datos ayudaría a mejorar el proceso de entrenamiento.

- Los algoritmos de optimización se han formulado de acuerdo a la práctica habitual observada en la literatura revisada. Esto supone, por ejemplo, que el algoritmo NSGA-II empleado aquí incluye mecanismos para mejorar la diversidad (*Crowding Distance*). No obstante, con alguno de los algoritmos menos convencionales (como, por ejemplo, MOACOr), sería posible ahondar más en formulaciones alternativas que incluyan mecanismos correctores, lo que podría mejorar su rendimiento.
- Por último, en lo que se refiere a la comparación entre algoritmos, se han empleado métricas bien establecidas en la literatura, y de hecho la evaluación de la convergencia (a través de la métrica GD) y la regularidad (métrica SP) no ha presentado problemas aparentes. La medida de la diversidad, en cambio, sí que ofrece ciertas dudas, ya que la métrica SPR, por su naturaleza combinada, se ve sesgada cuando el frente de Pareto real es claramente discontinuo. Si bien la métrica NH parece más robusta en este sentido (y por eso se han usado ambas), no ofrece una medida tan evidente de la diversidad, por lo que sería conveniente explorar otras métricas de diversidad.

10.3. Futuras líneas de investigación

Los resultados de esta tesis no pretenden ser definitivos, sino ofrecer una contribución al conocimiento de las herramientas y algoritmos empleados en la optimización de marchas y establecer una base sobre la que seguir ahondando en la mejora de la eficiencia energética del ferrocarril. En este sentido, a partir de los desarrollos de la tesis, se plantean, al menos, las siguientes líneas para posteriores estudios:

- Una vez resueltas las limitaciones específicas del simulador expuestas en el apartado anterior, se podría plantear una optimización efectiva de marchas en la red de metro de Valencia. Para ello sería necesario contar con información detallada del sistema ATO, así como llevar a cabo una nueva campaña de medición que permita actualizar las tendencias de consumo y necesidades de eficiencia de la red.
- En cuanto a simulación, los resultados positivos obtenidos con el uso de la red neuronal ponen de manifiesto el potencial de estas herramientas para simular relaciones no-lineales complejas entre conjuntos de variables, por lo que se podría profundizar en su uso para la estimación del consumo energético en el ferrocarril. Esto podría hacerse a través de una mejora en el entrenamiento (con más datos y

mejor pre-procesado de los mismos), o con el uso de estructuras de redes más complejas (redes de tres capas, conjuntos de redes, etc.). En cualquier caso, la idea no es tanto sustituir por completo la simulación directa, sino ofrecer un complemento útil que sirva de alternativa para modelizar aspectos de los que no se cuenta con información suficiente para plantear ecuaciones explícitas.

- En lo que se refiere a la comparativa entre algoritmos, ésta podría extenderse para incorporar otros meta-heurísticos más novedosos no contemplados en el presente estudio, o para evaluar formulaciones diferentes. Por otra parte, también se podría replicar la comparativa en otros contextos (redes convencionales, alta velocidad) para determinar si las conclusiones extraídas son extrapolables a otros problemas de optimización de marchas ferroviarias con condiciones diferentes.

Referencias

- Açikbas, S., Soylemez, M., 2008. Coasting point optimisation for mass rail transit lines using artificial neural networks and genetic algorithms. *IET Electr. Power Appl.* 2, 172–182.
- Agencia Internacional de la Energía, 2017. *Railway Handbook 2017*.
- Ahmadi, S., Dastfan, A., Assili, M., 2018. Energy saving in metro systems: Simultaneous optimization of stationary energy storage systems and speed profiles. *J. Rail Transp. Plan. Manag.* 8, 78–90. <https://doi.org/10.1016/j.jrtpm.2018.03.003>
- Albrecht, A., Howlett, P., Pudney, P., Vu, X., Zhou, P., 2016a. The key principles of optimal train control—Part 1: Formulation of the model, strategies of optimal type, evolutionary lines, location of optimal switching points. *Transp. Res. Part B* 94, 482–508.
- Albrecht, A., Howlett, P., Pudney, P., Vu, X., Zhou, P., 2016b. The key principles of optimal train control—Part 2: Existence of an optimal strategy, the local energy minimization principle, uniqueness, computational techniques. *Transp. Res. Part B* 94, 509–538.
- Amri, H., Hofstädter, R.N., Kozek, M., 2011. Energy efficient design and simulation of a demand controlled heating and ventilation unit in a metro vehicle. *2011 IEEE Forum Integr. Sustain. Transp. Syst. FISTS 2011* 7–12. <https://doi.org/10.1109/FISTS.2011.5973605>
- Antoniucci, G.A., Bentley, P.J., 2016. Analysis of the Distribution of Pareto Optimal Solutions on various Multi-Objective Evolutionary Algorithms.
- Baumel, P., 2011. Measuring Bulk Product Transportation Fuel Efficiency. *J. Transp. Res. Forum* 50, 79–88.
- Bishop, C.M., 1995. *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford.
- Bocharnikov, Y.V., Tobias, A.M., Roberts, S., Hillmansen, S., Goodman, C., 2007. Optimal driving strategy for traction energy saving on DC suburban railways. *IET Electr. Power Appl.* 1, 675–682. <https://doi.org/10.1049/iet-epa>
- Brenna, M., Foadelli, F., Longo, M., 2016. Application of genetic algorithms for driverless subway train energy optimization. *Int. J. Veh. Technol.* 2016, 1–14. <https://doi.org/10.1155/2016/8073523>
- Carvajal-Carreño, W., Cucala, P., Fernández-Cardador, A., 2014. Optimal design of energy-efficient ATO CBTC driving for metro lines based on NSGA-II with fuzzy parameters. *Eng. Appl. Artif. Intell.* 36, 164–177. <https://doi.org/10.1016/j.engappai.2014.07.019>
- Chang, C.S., Sim, S.S., 1997. Optimising train movements through coast control using genetic algorithms. *IEE Proc. - Electr. Power Appl.* 144, 65–73. <https://doi.org/10.1049/ip-epa:19970797>
- Chen, D., Han, X., Cheng, R., Yang, L., 2016. Position calculation models by neural computing and online learning methods for high-speed train. *Neural Comput. Appl.* 27, 1617–1628. <https://doi.org/10.1007/s00521-015-1960-6>
- Chuang, H.J., Ho, C.Y., Chen, C.S., Chen, C.S., Lin, C.H., Hsieh, C.H., 2009. Design of Optimal Coasting Speed for MRT Systems Using ANN Models. *IEEE Trans. Ind. Appl.* 45, 2090–2097. <https://doi.org/10.1109/TIA.2009.2031898>
- Coello Coello, C.A., Toscano Pulido, G., Salazar Lechuga, M., 2004. Handling Multiple Objectives With Particle Swarm Optimization. *IEEE Trans. Evol. Comput.* 8, 256–279.
- Coleman, D., Howlett, P., Pudney, P., Vu, X., Yee, R., 2010. Coasting boards vs optimal control, in: *IET Conference on Railway Traction Systems*. pp. 1–5.
- Comisión Europea, 2018a. Energy, transport and environment indicators 2018, Eurostat

- Pocketbooks on Environment and energy. <https://doi.org/DOI 10.2785/33652>
- Comisión Europea, 2018b. EU energy in figures - Statistical Pocketbook 2018. <https://doi.org/10.2833/77817>
- Comisión Europea, 2018c. A Clean Planet for all. A European strategic long-term vision for a prosperous, modern, competitive and climate neutral economy - Communication from the Commission to the European Parliament, the Council, the European and Social Committee and the Committee.
- Comisión Europea, 2017. EU transport in figures - Statistical Pocketbook 2017. <https://doi.org/10.2832/041248>
- Comisión Europea, 2016. Estrategia europea a favor de la movilidad de bajas emisiones.
- Comisión Europea, 2013. Together towards competitive and resource-efficient urban mobility.
- Cucala, P., Fernández-Cardador, A., Sicre, C., Domínguez, M., 2012. Fuzzy optimal schedule of high speed train operation to minimize energy consumption with uncertain delays and driver's behavioral response. *Eng. Appl. Artif. Intell.* 25, 1548–1557. <https://doi.org/10.1016/j.engappai.2012.02.006>
- Davydov, B., Chebotarev, V., Kablukova, K., 2018. Online Train Traffic Adjustments: Probabilistic Modeling and Estimating, in: Sierpiński, G. (Ed.), *Advanced Solutions of Transport Systems for Growing Mobility*. Springer International Publishing, Cham, pp. 50–60.
- Domínguez, M., Fernández-Cardador, A., Cucala, P., Gonsalves, T., Fernández, A., 2014. Multi objective particle swarm optimization algorithm for the design of efficient ATO speed profiles in metro lines. *Eng. Appl. Artif. Intell.* 29, 43–53. <https://doi.org/10.1016/j.engappai.2013.12.015>
- Domínguez, M., Fernández-Cardador, A., Cucala, P., Pecharromán, R., 2012. Energy Savings in Metropolitan Railway Substations Through Regenerative Energy Recovery and Optimal Design of ATO Speed Profiles. *IEEE Trans. Autom. Sci. Eng.* 9, 496–504.
- Domínguez, M., Fernández, A., Cucala, P., Blanquer, J., 2010. Efficient design of Automatic Train Operation speed profiles with on board energy storage devices. *WIT Trans. Built Environ.* 114, 509–520. <https://doi.org/10.2495/CR100471>
- Domínguez, M., Fernández, A., Cucala, P., Cayuela, L.P., 2008. Computer-aided design of ATO speed commands according to energy consumption criteria. *WIT Trans. Built Environ.* 103, 183–192. <https://doi.org/10.2495/CR080191>
- Domínguez, M., Fernández, A., Cucala, P., Lukaszewicz, P., 2011. Optimal design of metro automatic train operation speed profiles for reducing energy consumption. *Proc. Inst. Mech. Eng. Part F J. Rail Rapid Transit* 225, 463–473. <https://doi.org/10.1177/09544097JRRT420>
- Douglas, H., Roberts, C., Hillmanssen, S., Schmid, F., 2015. An assessment of available measures to reduce traction energy use in railway networks. *Energy Convers. Manag.* 106, 1149–1165. <https://doi.org/10.1016/j.enconman.2015.10.053>
- Dündar, S., Şahin, I., 2013. Train re-scheduling with genetic algorithms and artificial neural networks for single-track railways. *Transp. Res. Part C* 27, 1–15. <https://doi.org/10.1016/j.trc.2012.11.001>
- Eaton, J., Yang, S., Gongora, M., 2017. Ant Colony Optimization for Simulated Dynamic Multi-Objective Railway Junction Rescheduling. *IEEE Trans. Intell. Transp. Syst.* 18, 2980–2992. <https://doi.org/10.1109/TITS.2017.2665042>
- Faramehr, S., Hemida, H., 2016. Aerodynamics of trains in tunnels, in: *Proceedings of the Third International Conference on Railway Technology: Research, Development and Maintenance*.
- Feng, X., 2011. Optimization of target speeds of high-speed railway trains for traction energy saving and transport efficiency improvement. *Energy Policy* 39, 7658–7665.
- Fernández, A., 2018. Train eco-driving optimisation based on simulation models.

- Universidad Pontificia Comillas.
- Fernández, A., Fernández-Cardador, A., Cucala, P., Domínguez, M., Gonsalves, T., 2015. Design of Robust and Energy-Efficient ATO Speed Profiles of Metropolitan Lines Considering Train Load Variations and Delays. *IEEE Trans. Intell. Transp. Syst.* 16, 2061–2071. <https://doi.org/10.1109/TITS.2015.2391831>
- FGV, 2017. Informe de gestión, cuentas anuales y memoria de sostenibilidad 2017.
- Franke, R., Terwiesch, P., Meyer, M., 2000. An algorithm for the optimal control of the driving of trains, in: *Proceedings of the 39th IEEE Conference on Decision and Control*. Sydney, pp. 23–27.
- Frilli, A., Meli, E., Nocciolini, D., Pugi, L., Rindi, A., 2016. Energetic optimization of regenerative braking for high speed railway systems. *Energy Convers. Manag.* 129, 200–215.
- García-Najera, A., Bullinaria, J.A., 2007. Extending ACO R to Solve Multi-Objective Problems, UK Workshop on Computational Intelligence. Aberdeen.
- García Álvarez, A., 2007a. Consumo de energía y emisiones del tren de alta velocidad en comparación con otros medios de transporte: la extensión de la red AVE mejora la sostenibilidad del transporte. *An. mecánica y Electr.* 84, 26–34.
- García Álvarez, A., 2007b. *Dinámica de los trenes en alta velocidad*, 4th ed. Fundación de los Ferrocarriles Españoles, Madrid.
- García Álvarez, A., 2006. *Gestión energética en el ferrocarril*.
- García Álvarez, A., Martín Cañizares, M. del P., 2012. *Cuantificación del consumo de energía eléctrica del ferrocarril español*. Madrid.
- González-Gil, A., Palacin, R., Batty, P., Powell, J.P., 2014. A systems approach to reduce urban rail energy consumption. *Energy Convers. Manag.* 80, 509–524. <https://doi.org/10.1016/j.enconman.2014.01.060>
- Grasso, M., Gallone, M., Genovese, A., Macera, L., Penta, F., Pucillo, G., Strano, S., 2015. Composite material design for rail vehicle innovative lightweight components. *Lect. Notes Eng. Comput. Sci.* 2218, 731–736.
- Hagan, M., Demuth, H., Beale, M., De Jesús, O., 2014. *Neural Network Design*, 2nd ed. Martin Hagan.
- He, T., Xiong, R., 2018. Research on Multi-Objective Real-Time Optimization of Automatic Train Operation (ATO) in Urban Rail Transit. *J. Shanghai Jiaotong Univ.* 23, 327–335. <https://doi.org/10.1007/s12204-018-1941-x>
- Howlett, P., 2000. The Optimal Control of a Train. *Ann. Oper. Res.* 98, 65–87.
- Howlett, P., Pudney, P., Vu, X., 2009. Local energy minimization in optimal train control. *Automatica* 45, 2692–2698.
- Huang, J., Deng, Y., Yang, Q., Sun, J., 2016. An Energy-Efficient Train Control Framework for Smart Railway Transportation. *IEEE Trans. Comput.* 65, 1407–1417. <https://doi.org/10.1109/TC.2015.2500565>
- Huang, S.R., Sung, H.K., Ma, C.H., 2015. Optimize Energy of Train Simulation with Track Slope Data. *IEEE Conf. Intell. Transp. Syst.* 2015-October, 590–597. <https://doi.org/10.1109/ITSC.2015.103>
- Huang, Y., Tan, L., Chen, L., Tang, T., 2016. A neural network driving curve generation method for the heavy-haul train. *Adv. Mech. Eng.* 8, 1–14. <https://doi.org/10.1177/1687814016647883>
- Huang, Y., Yang, L., Tang, T., Gao, Z., Cao, F., 2017. Joint train scheduling optimization with service quality and energy efficiency in urban rail transit networks. *Energy* 138, 1124–1147.
- Ibaiondo, H., Romo, A., 2010. Kinetic energy recovery on railway systems with feedback to the grid, in: *Proceedings of EPE-PEMC 2010 - 14th International Power Electronics and Motion Control Conference*. IEEE, pp. 94–97. <https://doi.org/10.1109/EPEPEMC.2010.5606545>
- Instituto de Investigación Tecnológica, 2010. *Diseño de los modelos de simulación en*

líneas metropolitanas.

- Jiménez, F., Sánchez, G., Vasant, P., Verdegay, J.L., 2013. A multi-objective evolutionary approach for fuzzy optimization in production planning. *J. Intell. Fuzzy Syst.* 25, 441–455. <https://doi.org/10.3233/IFS-130651>
- Jong, J.-C., Chang, S., 2005. ALGORITHMS FOR GENERATING TRAIN SPEED PROFILES. *J. East. Asia Soc. Transp. Stud.* 6, 356–371.
- Kang, M.-H., 2011. GA-based Algorithm for Creating an Energy-Optimum Train Speed Trajectory. *J. Int. Coun. Electr. Eng.* 1, 123–128. <https://doi.org/10.5370/JICEE.2011.1.2.123>
- Keating, E.M., Raath, N., Winnett, J., Hughes, D.J., Hope, G., Ravaioli, M., Cozien-cazuc, S., 2017. Opportunities for the Use of Composite Materials in Rail Applications – a Case Study, in: 21st International Conference on Composite Materials. pp. 1–7.
- Khmelnitsky, E., 2000. On an optimal control problem of Train Operation. *IEEE Trans. Automat. Contr.* 45, 1257–1266. [https://doi.org/10.1016/S0377-0427\(97\)00198-2](https://doi.org/10.1016/S0377-0427(97)00198-2)
- Kim, K.M., Oh, S.-M., Han, M., 2010. A Mathematical Approach for Reducing the Maximum Traction Energy: The Case of Korean MRT Trains, in: Proceedings of the International MultiConference of Engineers and Computer Scientists. Hong Kong, pp. 1–5.
- Kokken, K., 2003. The reduction of energy consumption in EMU-trains of NS, in: World Congress on Railway Research (WCRR).
- Komaki, D., Yano, K., Fukumoto, T., 2016. An Electrical Energy Allotment Method for a Large Railway Network. *Electr. Eng. Japan* 196, 49–57. <https://doi.org/10.1002/eej.22844>
- Komyakov, A.A., Ivanchenko, V.I., Erbes, V.V., 2015. Application of artificial neural networks for electric load forecasting on railway transport, in: IEEE 15th International Conference on Environment and Electrical Engineering (EEEIC). pp. 43–46. <https://doi.org/10.1109/EEEIC.2015.7165296>
- Kondo, K., 2010. Recent energy saving technologies on railway traction systems. *IEEJ Trans. Electr. Electron. Eng.* 5, 298–303. <https://doi.org/10.1002/tee.20533>
- Liu, R., Golovitcher, I., 2003. Energy-efficient operation of rail vehicles. *Transp. Res. Part A* 37, 917–932.
- Liu, R., Li, S., Yang, L., Yin, J., 2018. Energy-Efficient Subway Train Scheduling Design With Time-Dependent Demand Based on an Approximate Dynamic Programming Approach. *IEEE Trans. Syst. Man Cybern. Syst.* 1–16.
- Liu, S., Cao, F., Xun, J., Wang, Y., 2015. Energy-Efficient Operation of Single Train Based on the Control Strategy of ATO. *IEEE Conf. Intell. Transp. Syst.* 2015-October, 2580–2586. <https://doi.org/10.1109/ITSC.2015.415>
- López-López, Á., Pecharromás, R., Fernández-Cardador, A., Cucala, P., 2014. Assessment of energy-saving techniques in direct-current-electrified mass transit systems. *Transp. Res. Part C* 38, 85–100. <https://doi.org/10.1016/j.trc.2013.10.011>
- Lu, S., Hillmansen, S., Roberts, C., 2011. A power-management strategy for multiple-unit railroad vehicles. *IEEE Trans. Veh. Technol.* 60, 406–420. <https://doi.org/10.1109/TVT.2010.2093911>
- Lu, S., Hillmansen, S., Tin Kin, H., Roberts, C., 2013. Single-Train Trajectory Optimization. *IEEE Trans. Intell. Transp. Syst.* 14, 743–750.
- Lu, S., Wang, M.Q., Weston, P., Chen, S., Yang, J., 2016. Partial Train Speed Trajectory Optimization Using Mixed-Integer Linear Programming. *IEEE Trans. Intell. Transp. Syst.* 17, 2911–2920. <https://doi.org/10.1109/TITS.2016.2535399>
- Lukaszewicz, P., 2001. Energy Consumption and Running Time for Trains. Modelling of running resistance and driver behaviour based on full scale testing. Stockholm Royal Institute of Technology.
- Lv, X., He, B., Li, Y., 2013. Inbound Energy-Saving Slope Design Method of High-Speed Railway, in: Conference: Fourth International Conference on Transportation

- Engineering. pp. 2241–2247. <https://doi.org/10.1061/9780784413159.326>
- Martínez Fernández, P., Salvador Zuriaga, P., Villalba Sanchís, I., Sánchez Alandí, R., García Román, C., Insa Franco, R., 2015. Measuring & modelling energy consumption in metro trains by means of neural networks, in: 13th International Conference & Exhibition, Railway Engineering 2015. Civil-Comp Press, Edinburgh, pp. 1–12.
- Molines, J., Herrera, M.P., Medina, J.R., 2018. Estimations of wave forces on crown walls based on wave overtopping rates. *Coast. Eng.* 132, 50–62. <https://doi.org/10.1016/j.coastaleng.2017.11.004>
- Molines, J., Medina, J.R., 2014. Calibration of overtopping roughness factors for concrete armor units in non-breaking conditions using the CLASH database. *Coast. Eng.* 96, 62–70. <https://doi.org/10.1016/j.coastaleng.2014.11.008>
- Nasri, A., Fekri Moghadam, M., Mokhtari, H., 2010. Timetable optimization for maximum usage of regenerative energy of braking in electrical railway systems, in: SPEEDAM 2010 - International Symposium on Power Electronics, Electrical Drives, Automation and Motion. IEEE, pp. 1218–1221. <https://doi.org/10.1109/SPEEDAM.2010.5542099>
- Paul, J.C., 2016. Aerodynamic Drag Reduction of Open-Top Gondola and Hopper Cars in Unit Train Operation and Impact on Train Fuel Consumption and Economics, in: Dillmann, A., Orellano, A. (Eds.), *The Aerodynamics of Heavy Vehicles III. ECI 2010. Lecture Notes in Applied and Computational Mechanics*. Springer International Publishing, pp. 37–60.
- Quaglietta, E., Punzo, V., 2013. Supporting the design of railway systems by means of a Sobol variance-based sensitivity analysis. *Transp. Res. Part C Emerg. Technol.* 34, 38–54. <https://doi.org/10.1016/j.trc.2013.05.007>
- Rao, R.V., Savsani, V.J., Vakharia, D.P., 2011. Teaching–learning-based optimization: A novel method for constrained mechanical design optimization problems. *Comput. Des.* 43, 303–315. <https://doi.org/10.1016/j.cad.2010.12.015>
- Salim, V., Cai, X., 1995. Scheduling cargo trains using genetic algorithms, in: *Proceedings of 1995 IEEE International Conference on Evolutionary Computation*. Perth, pp. 224–227. <https://doi.org/10.1109/ICEC.1995.489149>
- Salvador Zuriaga, P., Insa Franco, R., Villalba Sanchís, I., Martínez Fernández, P., Sánchez Alandí, R., Rovira Cardete, A., 2014. Fuel Measurements in Diesel Multiple Units for Energy Management Purposes, in: *2nd International Conference on Railway Technology: Research, Development and Maintenance (RAILWAYS 2014)*. Civil-Comp Press, Ajaccio, pp. 1–11.
- Salvador Zuriaga, P., Martínez Fernández, P., Villalba Sanchís, I., Insa Franco, R., 2017. Modelling energy consumption in diesel multiple units. *Proc. Inst. Mech. Eng. Part F J. Rail Rapid Transit* 232, 1539–1548.
- Sato, K., Yoshizawa, M., Fukushima, T., 2010. Traction systems using power electronics for Shinkansen High-speed Electric Multiple Units. *2010 Int. Power Electron. Conf. - ECCE Asia - IPEC 2010* 2859–2866. <https://doi.org/10.1109/IPEC.2010.5542320>
- SCI Verkehr, 2018. *Railway Electrification - Global Market Trends*.
- Sicre, C., Cucala, P., Fernández-Cardador, A., 2014. Real time regulation of efficient driving of high speed trains based on a genetic algorithm and a fuzzy model of manual driving. *Eng. Appl. Artif. Intell.* 29, 79–92. <https://doi.org/10.1016/j.engappai.2013.07.015>
- Sicre, C., Cucala, P., Fernández-Cardador, A., Lukaszewicz, P., 2012. Modeling and optimizing energy-efficient manual driving on high-speed lines. *IEEJ Trans. Electr. Electron. Eng.* 7, 633–640. <https://doi.org/10.1002/tee.21782>
- Sicre, C., Cucala, P., Fernández, A., Jiménez, J.A., Ribera, I., Serrano, A., 2010. A method to optimise train energy consumption combining manual energy efficient driving and scheduling. *WIT Trans. Built Environ.* 114, 549–560. <https://doi.org/10.2495/CR100511>

- Socha, K., Dorigo, M., 2008. Ant colony optimization for continuous domains. *Eur. J. Oper. Res.* 185, 1155–1173. <https://doi.org/10.1016/j.ejor.2006.06.046>
- Steiner, M., Klohr, M., Pagiola, S., 2007. Energy storage system with Ultracaps on board of railway vehicles, in: 2007 European Conference on Power Electronics and Applications. pp. 1–10. <https://doi.org/10.1109/EPE.2007.4417400>
- Su, S., Li, X., Tang, T., Gao, Z., 2013. A subway train timetable optimization approach based on energy-efficient operation strategy. *IEEE Trans. Intell. Transp. Syst.* 14, 883–893. <https://doi.org/10.1109/TITS.2013.2244885>
- Su, S., Tang, T., Roberts, C., 2015. A Cooperative Train Control Model for Energy Saving. *IEEE Trans. Intell. Transp. Syst.* 16, 622–631. <https://doi.org/10.1109/TITS.2014.2334061>
- Su, S., Tang, T., Wang, Y., 2016. Evaluation of strategies to reducing traction energy consumption of metro systems using an Optimal Train Control Simulation model. *Energies* 9, 1–19. <https://doi.org/10.3390/en9020105>
- Tetko, I. V., Livingstone, D.J., Luik, A.I., 1995. Neural Network Studies. 1. Comparison of Overfitting and Overtraining. *J. Chem. Inf. Comput. Sci.* 35, 826–833.
- Thiele, L., Zitzler, E., 1999. Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach. *IEEE Trans. Evol. Comput.* 3, 257–271.
- Tian, Z., Hillmansen, S., Roberts, C., Weston, P., Zhao, N., Chen, L., Chen, M., 2015. Energy evaluation of the power network of a DC railway system with regenerating trains. *IET Electr. Syst. Transp.* 6, 1–9. <https://doi.org/10.1049/iet-est.2015.0025>
- Wang, D.P., He, Z.K., Li, M.G., Zhao, W.Z., 2011. Numerical research on aerodynamic drag reduction optimization of EMU. *J. China Railw. Soc.* 33, 15–18.
- Wang, F.F., 2017. Study on the Application of Carbon Fiber Composite Materials in High-Speed Trains, *Materials Science Forum.* <https://doi.org/10.4028/www.scientific.net/msf.893.31>
- Wang, J., Rakha, H., 2017. Electric train energy consumption modeling. *Appl. Energy* 193, 346–355.
- Wang, Q., Zhu, J., 2014. Analysis and Simulation of Energy-Efficient Control of a Train, in: *Proceedings of the 33rd Chinese Control Conference.* Nanjing, pp. 3373–3380.
- Watanabe, S., Koseki, T., 2015. Energy-saving train scheduling diagram for automatically operated electric railway. *J. Rail Transp. Plan. Manag.* 5, 183–193. <https://doi.org/10.1016/j.jrtpm.2015.10.004>
- Weiland, K., 2004. Electric traction energy metering on German Railways and the impact of European standardisation on the energy billing process in Germany, in: Allan, J., Brebbia, C.A., Hill, R.J., Sciotto, G., Some, S. (Eds.), *Computers in Railways IX.* WIT Press, p. 1020.
- Winnett, J., Hoffrichter, A., Iraklis, A., McGordon, A., Hughers, D.J., Ridler, T., Mallinson, N., 2017. Development of a very light rail vehicle. *Proc. Inst. Civ. Eng. - Transp.* 170, 231–242.
- Wong, K.K., Ho, T.K., 2004. Dynamic coast control of train movement with genetic algorithm. *Int. J. Syst. Sci.* 35, 835–846. <https://doi.org/10.1080/00207720412331203633>
- Xin, T., Roberts, C., He, J., Hillmansen, S., Zhao, N., Chen, L., Tian, Z., Su, S., 2014. Railway vertical alignment optimisation at stations to minimise energy, in: *17th IEEE International Conference on Intelligent Transportation Systems.* pp. 2119–2124. <https://doi.org/10.1109/ITSC.2014.6958016>
- Yang, H., Liu, H., Fu, Y., 2015. Multi-objective operation optimization for electric multiple unit-based on speed restriction mutation. *Neurocomputing* 169, 383–391. <https://doi.org/10.1016/j.neucom.2014.08.097>
- Yang, L., Li, K., Gao, Z., Li, X., 2012. Optimizing trains movement on a railway network. *Omega* 40, 619–633. <https://doi.org/10.1016/j.omega.2011.12.001>
- Zhang, J., Wang, J., Wang, Q., Xiong, X., Gao, G., 2018. A study of the influence of bogie

- cut outs' angles on the aerodynamic performance of a high-speed train. *J. Wind Eng. Ind. Aerodyn.* 175, 153–168.
- Zhang, Q., Li, H., 2007. MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition. *IEEE Trans. Evol. Comput.* 11, 712–731. <https://doi.org/10.1109/TEVC.2007.892759>
- Zhao, N., Roberts, C., Hillmansen, S., 2012. The application of an enhanced Brute Force algorithm to minimise energy costs and train delays for differing railway train control systems. *Proc. Inst. Mech. Eng. Part F J. Rail Rapid Transit* 228, 158–168.
- Zhao, N., Roberts, C., Hillmansen, S., Nicholson, G., 2015. A Multiple Train Trajectory Optimization to Minimize Energy Consumption and Delay. *IEEE Trans. Intell. Transp. Syst.* 16, 2363–2372.

Anexo I. Relación de artículos

Se han publicado dos artículos en revistas recogidas en el JCR que guardan relación con la presente tesis:

- A. MARTÍNEZ FERNÁNDEZ, P., VILLALBA SANCHÍS, I., YEPES, V., INSA FRANCO, R. (2019). "A review of modelling and optimisation methods applied to railways energy consumption", *Journal of Cleaner Production*; Vol. 220, pp. 153-162 (<https://doi.org/10.1016/j.jclepro.2019.03.037>).
- B. MARTÍNEZ FERNÁNDEZ, P., SALVADOR, P., VILLALBA SANCHÍS, I., INSA FRANCO, R. (2019). "Neural Networks for modelling the energy consumption of metro trains", *Proceedings of the Institution of Mechanical Engineers Part F: Journal of Rail and Rapid Transit*; Vol. XX (XX), pp. XX (<https://doi.org/10.1177/0954409719861595>).

El artículo A presenta una detallada revisión bibliográfica centrada en dos áreas. Por un lado, analiza la modelización del consumo energético del ferrocarril, evaluando los principales enfoques utilizados por los diferentes autores y los diferentes factores considerados. Por otro lado, se analiza el problema de la optimización del consumo energético ferroviario, centrándose en los diferentes algoritmos empleados. Este artículo se corresponde, a grandes rasgos, con las Secciones 3 y 4 (Capítulo II) de la tesis.

El artículo B se centra en el desarrollo, entrenamiento y validación de una red neuronal para estimar el consumo energético en la red de metro de Valencia. Esta red neuronal es parte fundamental del modelo de simulación empleado en la presente tesis. Este artículo se corresponde con la Sección 7 (Capítulo IV) de la tesis.

Anexo II. Conclusions

En el presente anexo se exponen las conclusiones de la Tesis traducidas al inglés.

Conclusions

As noted in Chapter I, the main motivation for this thesis is to contribute to the knowledge regarding the tools used to model and optimise speed profiles on urban railways. By doing so, this thesis aims to improve the energy efficiency and sustainability of mass transport systems. This motivation is defined through four objectives:

- To analyse the main energy consumption trends of the Valencia metro network.
- To model the energy consumption by means of a trained neural network and to obtain a driving simulator validated with real data.
- To thoroughly simulate speed profiles on every inter-station track stretch and to obtain the corresponding Pareto fronts.
- To compare the most used meta-heuristic optimisation algorithms in order to identify their strengths and weaknesses based on certain metrics and criteria.

Regarding the first objective, the main characteristics of the Valencia metro network have been analysed. Thanks to the data obtained from an extensive monitoring scheme carried out in 2014, the following consumption trends have been identified:

- The average consumption per kilometre is between 4.8 and 7.9 kWh, depending on the line profile and the number of stations.
- The ratio gross/net consumption is within the range 67-85%.
- The energy consumed by auxiliaries is, on average, between 15% and 45% of the net energy supplied to the vehicle. This value is greatly affected by the season and the time of the day on surface track stretches.
- The energy consumed by the rheostatic brake is, on average, 3% of the total net consumption, although higher percentages were found on marginal parts of the networks (with low frequencies and a single track). In the central part of the network, this percentage is below 1.5%.

These consumption trends characterise the Valencia metro network and set the framework for the rest of the thesis.

The second objective deals with the development of a simulation tool that provides travel time and energy consumed per inter-station trip. This is an essential element for the optimisation problem. Therefore, a time-step driving simulator has been developed which, taking into account the commands of the ATO system (as well as data from the track and rolling stock), yields the vehicle speed profile and total travel time.

Additionally, as a complement to such simulator, a neural network has been developed and trained to yield the traction electric power and total energy consumption, using the speed profile and track geometry as input data. This part of the overall simulation is quite new and has barely been explored on the reviewed literature. The use of this approach allows solving the lack of certain technical data from the rolling stock that prevented a direct, explicit simulation of the energy consumption.

The simulator-neural network, taken as a whole, allows evaluating every possible combination of ATO speed commands, calculates the complete speed profile between two consecutive stations and yields the travel time and total energy consumption of such trip. This tool has been validated using real data gathered from the monitoring carried out in the Valencia metro network. The following results have been obtained:

- With regard to travel time, the simulator yields an average error of 1.43%. This is slightly higher than what other authors have achieved, but is nevertheless enough for the purposes of this thesis.
- With regard to energy consumption, the neural network yields an average error of 1.49%, in line with what other authors have achieved through direct simulation. Moreover, the network shows a relative Mean Square Error (rMSE) equal or lower than 20% for every dataset used during training, validation and test (including additional tests carried out with independent datasets). This fulfils the validation criteria fixed beforehand.

Therefore, the second thesis objective has been completed, as a fully validated simulation tool has been developed. By using this tool, up to 5,832 possible combinations of ATO commands have been simulated for each of the 32 selected inter-station stretches (of which 666 are holding speed profiles and 5,166 are coasting-remotoring profiles). Considering both ways of driving, this yields 64 sets of time-energy pairs.

Each of those 64 sets defines the solution space of possible speed profiles for each track stretch and direction, and allows obtaining an approximation to the real Pareto front. This

is the third objective of the thesis, and a necessary step for the comparison between algorithms, as it allows assessing the fitness of their respective solutions against the real Pareto front.

The last thesis objective aims to compare the performance of five meta-heuristic optimisation algorithms, as these are the most used to solve speed profile optimisation problems in metro networks. The chosen algorithms are:

- Non-dominated Sorted Genetic Algorithm (**NSGA-II**).
- Multi-Objective Particle Swarm Optimisation (**MOPSO**).
- Strength Pareto Evolutionary Algorithm (**SPEA-II**).
- Multi-Objective Evolutionary Algorithm based on Decomposition (**MOEA-D**).
- Multi-Objective Ant Colony Optimisation (**MOACOr**).

In order to compare their performance, all five algorithms were applied to each of the 64 case studies to obtain sets of non-dominated solutions. The fitness of these sets was then assessed through certain metrics so as to evaluate their convergence (i.e. closeness to the real Pareto front), diversity (i.e. degree of spread along the front) and regularity (i.e. the uniformity of the distribution along the front). The chosen metrics are the Generational Distance (GD), Spread (SPR), Spacing (SP) and Normalised Hypervolume (NH). Time of execution was also taken into account.

The comparative between algorithm consists of three steps: Firstly, the results on certain, representative case studies were analysed. Afterwards, the global performance for all 64 case studies was calculated. Finally, a statistical analysis was carried out to determine whether any of the differences identified was significant and could be extrapolated. From this analysis in three stages the following conclusions have been drawn:

- In terms of convergence (GD metric), all algorithms show a similar behaviour, and no significant differences have been identified.
- In terms of regularity (SP metric), no significant difference has been found either.
- However, in those case studies where the real Pareto front is clearly discontinuous, all algorithms show a poor result of the SP metric. Moreover, this discontinuity also affects the SPR metric, which is a combined assessment of both diversity and regularity. This points out a potential shortcoming of the SPR metric to measure diversity.

- In terms of diversity, the MOPSO algorithm is clearly the best, followed by SPEA-II. These differences have been confirmed through the statistical analysis with a 95% confidence level:
 - According to the SPR metric, the median value obtained by MOPSO is significantly lower (and thus better) than the rest of the algorithms. SPEA-II obtains a median value significantly better than MOEA-D and NSGA-II, and MOACOr outperforms MOEA-D.
 - According to the NH metric, both MOPSO and MOEA-D yield an average value significantly lower than that of the NSGA-II.
- In terms of time of calculation, the NSGA-II is the fastest in all cases, while the MOPSO algorithm is the slowest. The rest are in between. This difference is mostly due to the number of calls to the simulator that each algorithm needs to perform in order to obtain a solution.

Therefore, according to the results obtained from this study, it can be said that the most used algorithm for optimisation of speed profiles (NSGA-II), while providing a good enough solution and scoring correctly in terms of convergence, offers a set of solutions with poorer diversity than other algorithms. Hence, for future optimisation studies it would be advisable to replace NSGA-II with other algorithms, particularly MOPSO (or, to a less extent, SPEA-II or MOEA-D), which offer sets of non-dominated solutions as good in terms of convergence and better in terms of diversity.

Limitations

Despite completing all the thesis objectives and concluding a significant evaluation of the performance of the five selected meta-heuristic algorithms, this study has certain limitations that should be taken into account:

- With regard to the analysis of the consumption trends in the Valencia metro network, it is evident that part of the conclusions obtained may be outdated due to the time passed since the data monitoring. This does not directly affect the study as the framework is still valid for the comparison between optimisation algorithms, but may preclude an actual, effective optimisation of the speed profiles applied in the network.
- With regard to the simulator, two main weaknesses are worth mentioning:
 - The first one affects the implementation of the ATO system. Due to the lack of information regarding the ATO actually used in the Valencia metro net-

work, a simplified model of the ATO system used in the Madrid metro network was used instead. This is acceptable for the purpose of the comparative study carried out in the thesis, but would affect the capacity of the simulator to be used to actually model and optimise speed profiles in the Valencia network.

- The second limitation refers to the simulator error, which is slightly higher than what other authors have achieved with their simulators. Although the difference is small (and could be caused by the aforementioned limitation regarding the ATO system), it could also affect the capacity of the simulator in further studies.
- With regard to the neuronal network, it fulfils all the validation criteria and yields an average error in line with what others authors have achieved with direct simulation. However, it has been observed that, while the network correctly models the energy peaks during traction, it tends to underestimate the energy regenerated during braking events. This limitation should be corrected to achieve a more accurate estimation of the energy consumed during each trip.
- Regarding the neural network training, slope and curvature data were provided by FGV from their records. However, small discrepancies may exist between the recorded data and the actual track layout due to errors during construction, maintenance operations, etc. This may explain the relatively low weight of the slope as an input variable for the neural network.
- Another aspect to improve regarding the neural network training is using the train mass as an input variable. It is clear that the mass plays a crucial role in the energy consumption, but variations of train mass due to passengers getting in and out the train were not measured during the data monitoring, and thus were not available for network training. Using such data as an input variable for the neural network would likely improve the training process.
- The optimisation algorithms used have been formulated according to the common rules found in the reviewed literature. This means that, for example, the NSGA-II used includes a mechanism to improve diversity (Crowding Distance). However, it would be possible to further study the formulation of the less common algorithms (e.g. MOACOr) to include corrective measures that may enhance their performance.
- Finally, with regard to the comparison between algorithms, well-established metrics found in the literature have been used and the assessment of convergence

(through the GD metric) and regularity (through the SP metric) have been done correctly. However, measuring the diversity has proven to be more difficult. The SPR metric, as a hybrid metric, may be biased when the real Pareto front is discontinuous, and while the NH metric seems more robust in that regard (and that is the reason why both have been used), other metrics may be studied and adapted to measure diversity.

Future research

The results of this thesis are not definitive, but aim to contribute to the knowledge regarding tools and algorithms used in railways speed profile optimisation and to serve as a foundation for further research on the energy efficiency of railways. Considering this, the following lines of research could be developed based on this thesis:

- Once the aforementioned simulator limitations have been solved, an actual, effective optimisation of the speed profiles used to operate the Valencia metro network could be carried out. In order to do so, detailed information of the ATO system used in the network would be required. Additionally, a new data gathering could be done to update the network consumption trends and efficiency needs.
- With regard to simulation, the positive results obtained by using a neural network show the huge potential of this tool to simulate complex non-linear relations between different variables. Therefore, more research could be done on the application of neural networks to model railways energy consumption, either through better training (more and better pre-processed data) or by using different network structures (three layered networks, network sets, etc.). In any case, the idea is not to completely replace direct simulation but to offer a useful alternative to model certain aspects when there is not enough information to formulate explicit equations.
- With regard to comparing algorithms, the study could be extended to include other, newer meta-heuristics not considered in this thesis, or to try different formulations. On the other hand, the comparison could be applied to other contexts (e.g. conventional or high-speed lines) in order to assess whether the conclusions drawn from this study may be extrapolated to other railways optimisation problems under diverse conditions.

Anexo III. Recopilación de resultados

En el presente anexo se recopilan los principales resultados obtenidos durante el desarrollo de la presente tesis, divididos en tres bloques:

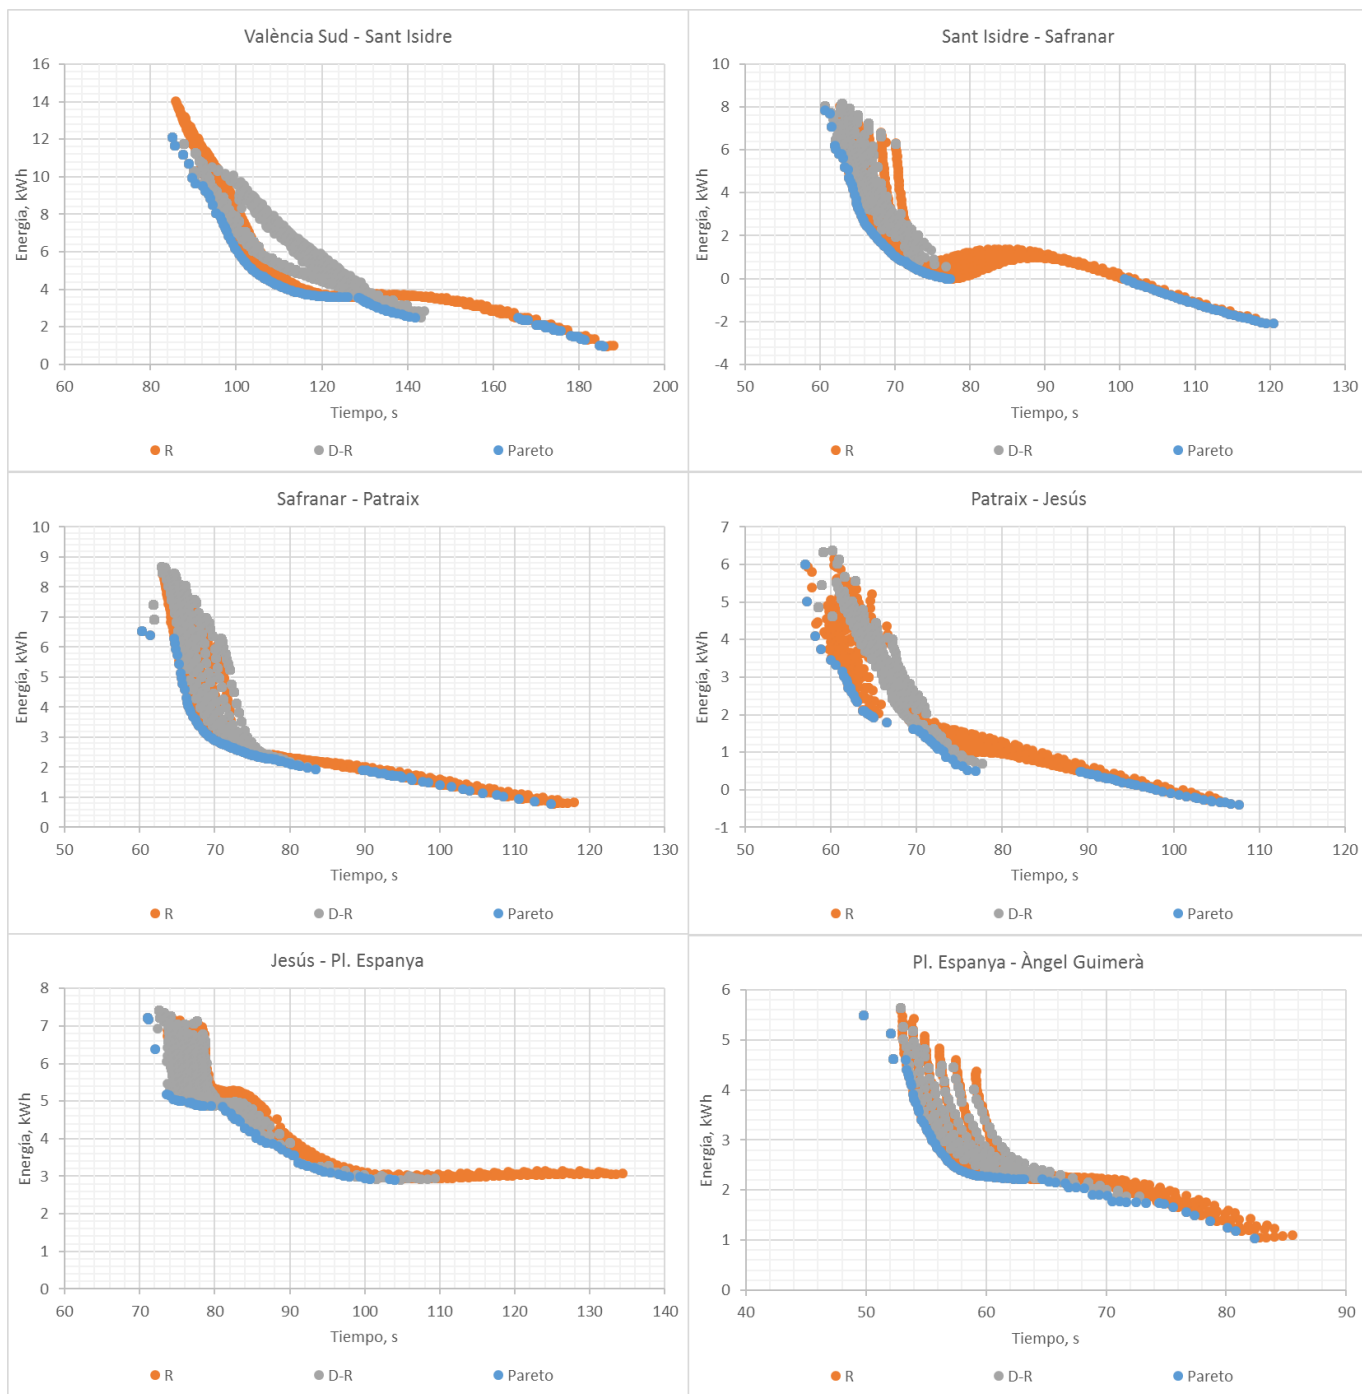
Bloque A: Resultados de la simulación sistemática y obtención de curvas de Pareto (64 gráficas con perfiles de Regulación (R), perfiles de Deriva (D-R) y frente de Pareto).





Bloque B: Resultados de la aplicación de los cinco algoritmos de optimización (64 gráficas con el frente de Pareto real y los conjuntos de soluciones de cada algoritmo).

Bloque C: Resultados de las métricas para cada algoritmo de optimización (5 tablas, una por cada algoritmo de optimización).



Bloque A: Resultados de la simulación sistemática

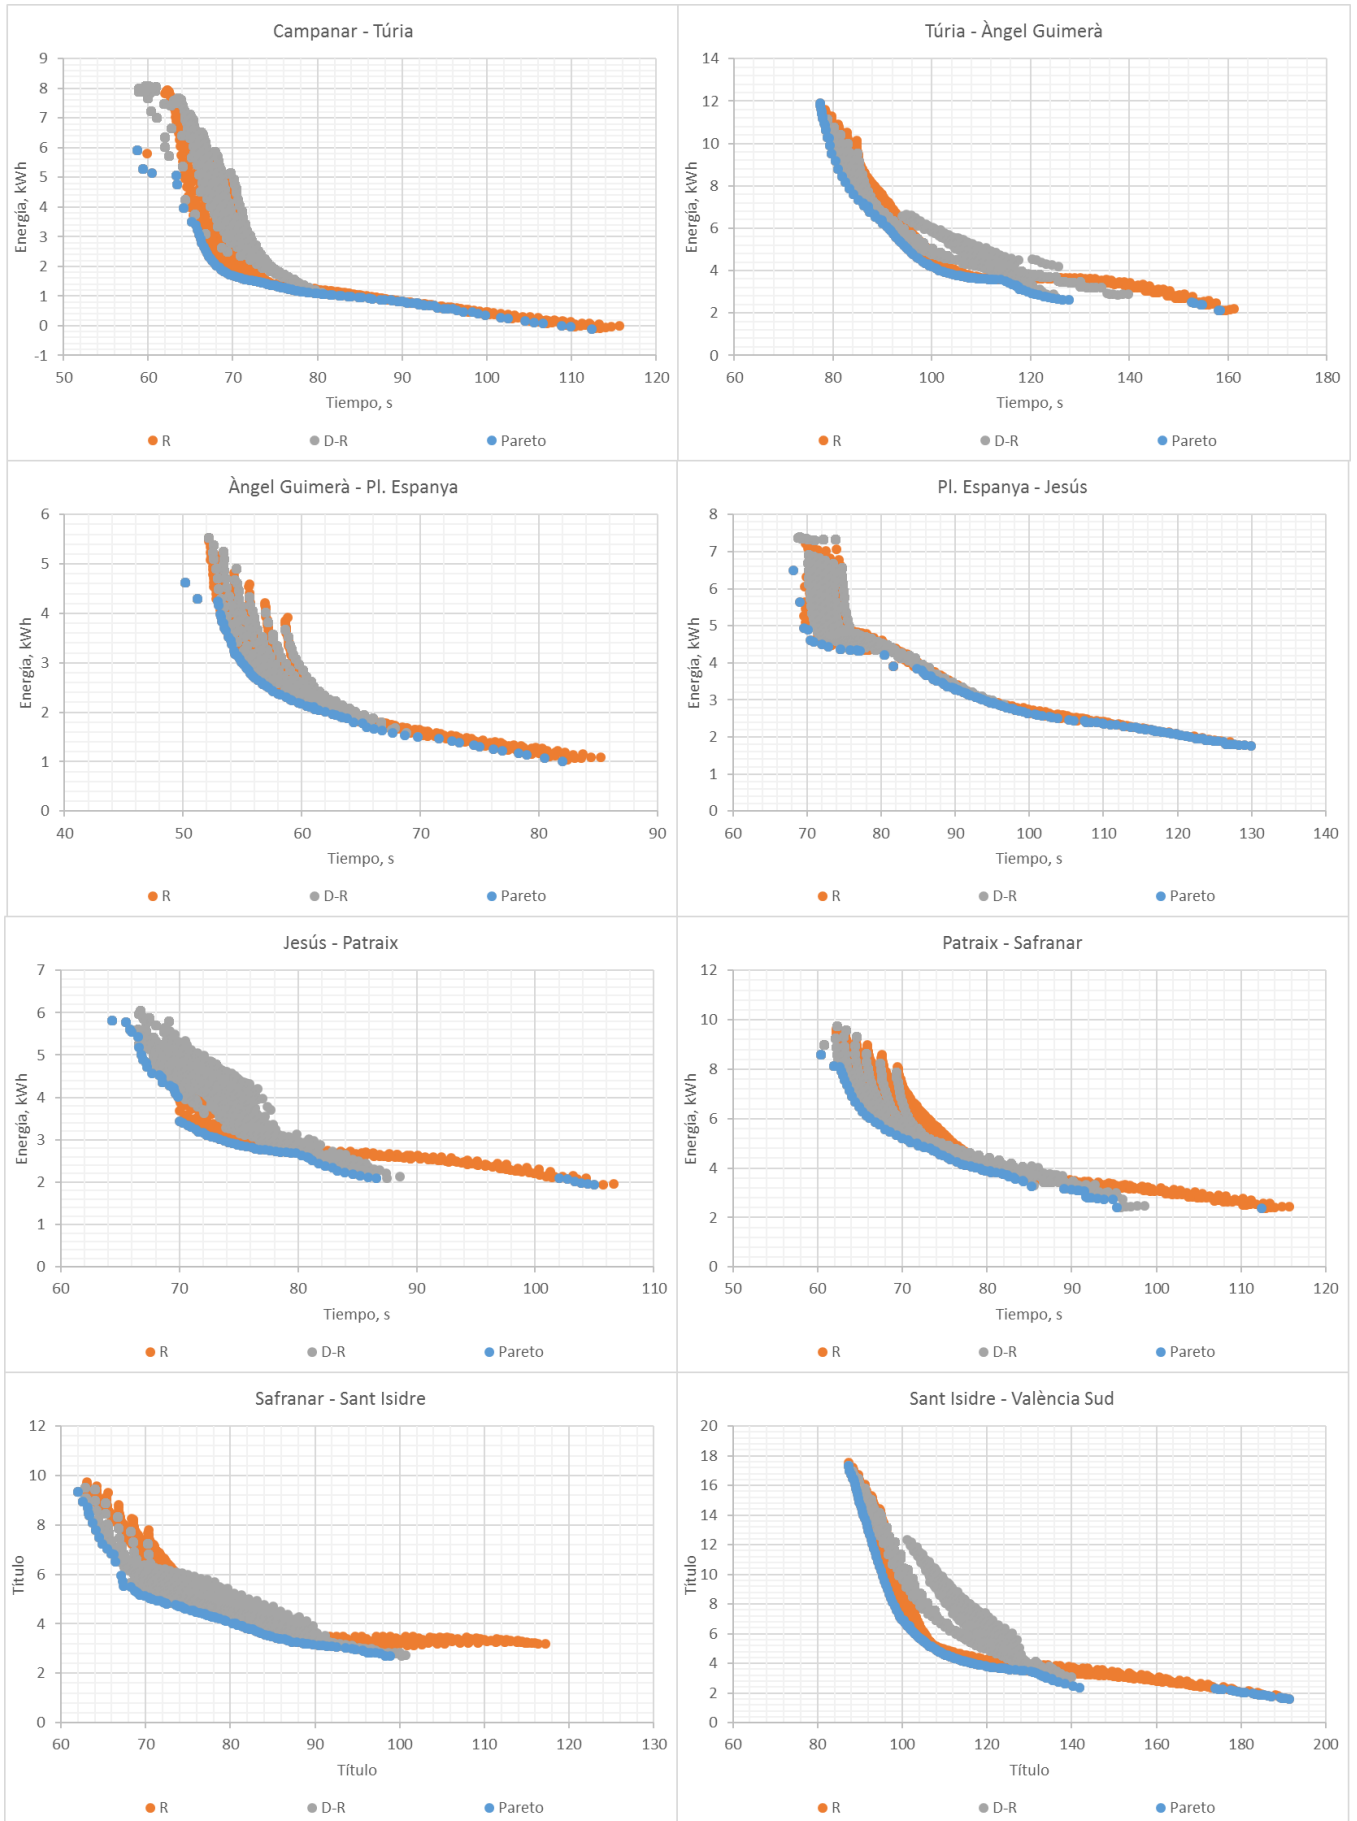
Líneas 1-2 (València Sud – Empalme) / Línea 7 (València Sud – Jesús)



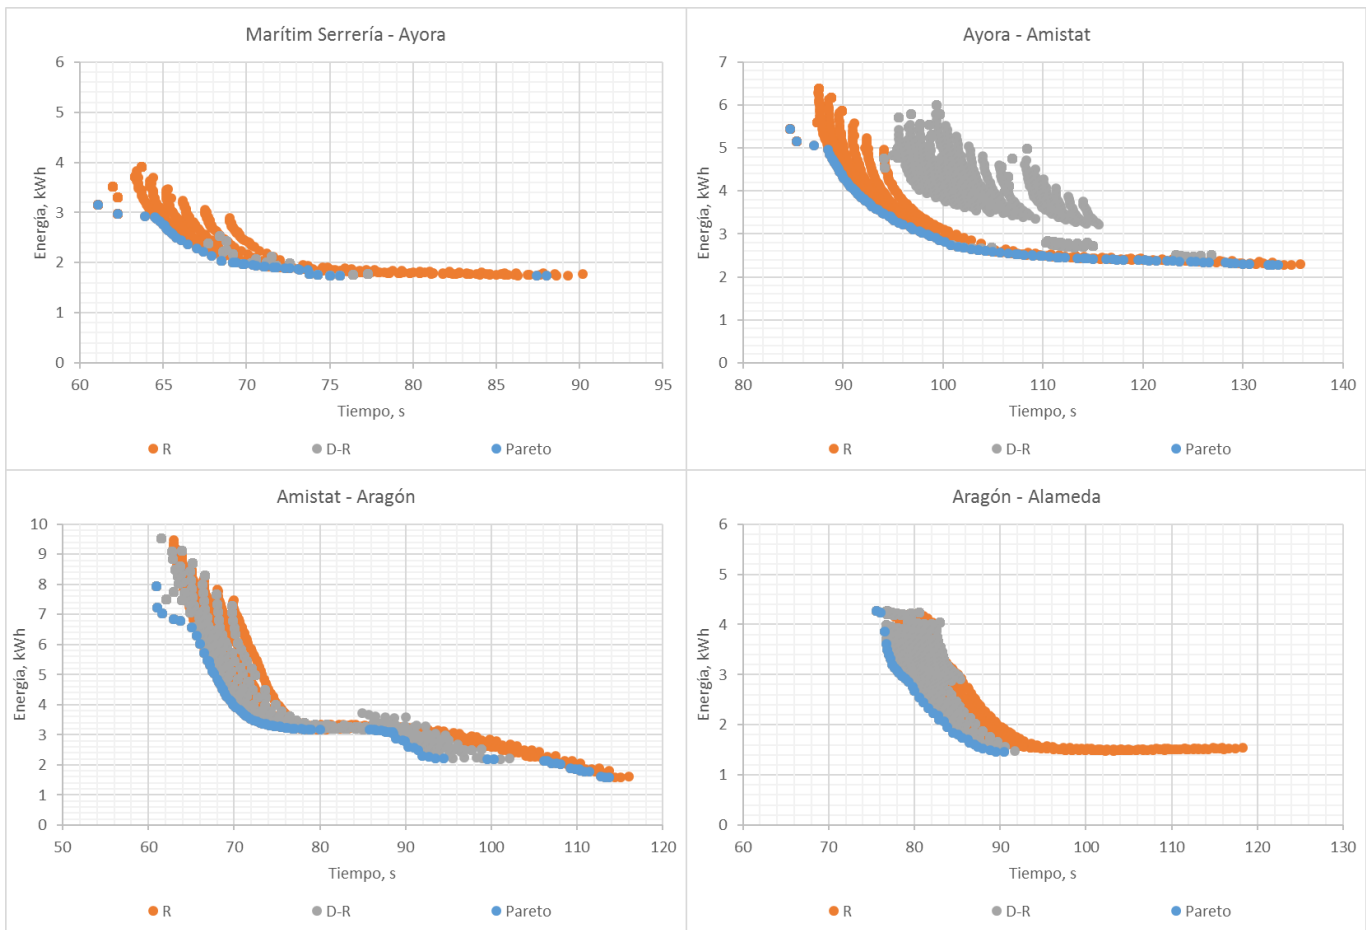


Líneas 1-2 (Empalme – València Sud) / Línea 7 (Jesús – València Sud)

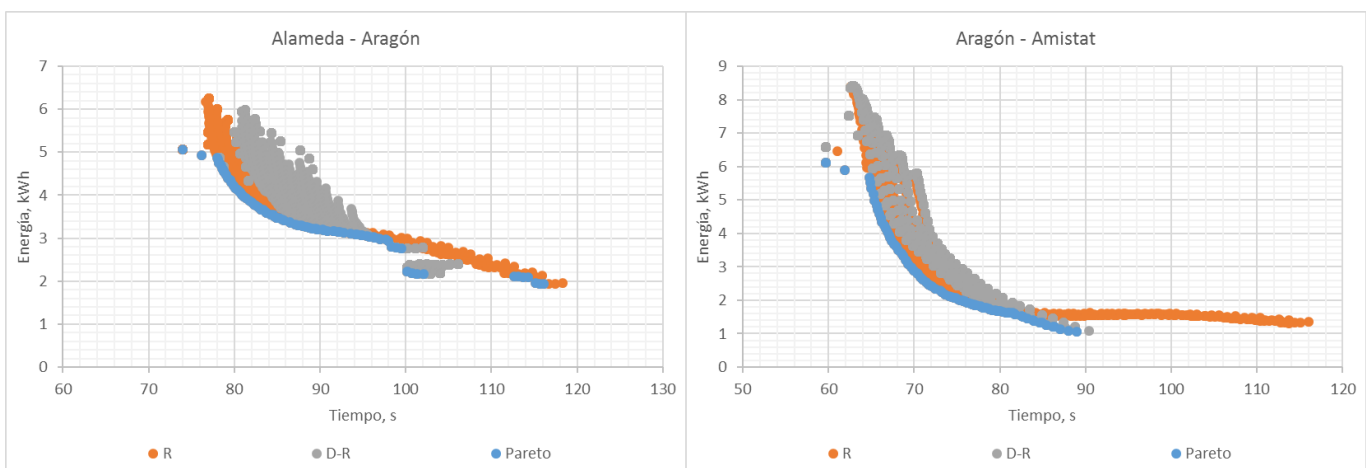





Líneas 5-7 (Marítim Serrería – Alameda)

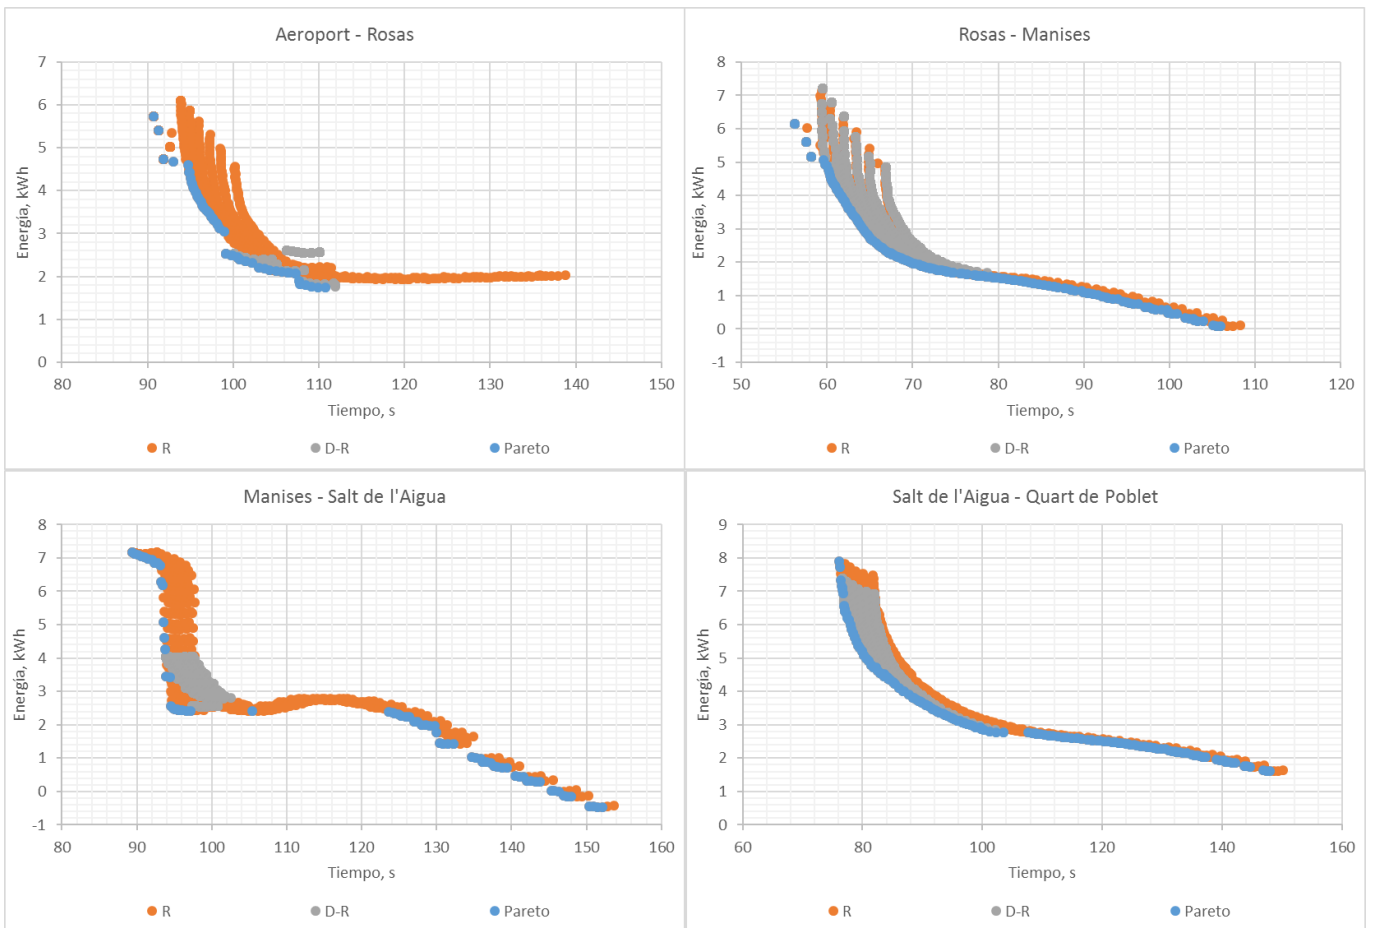


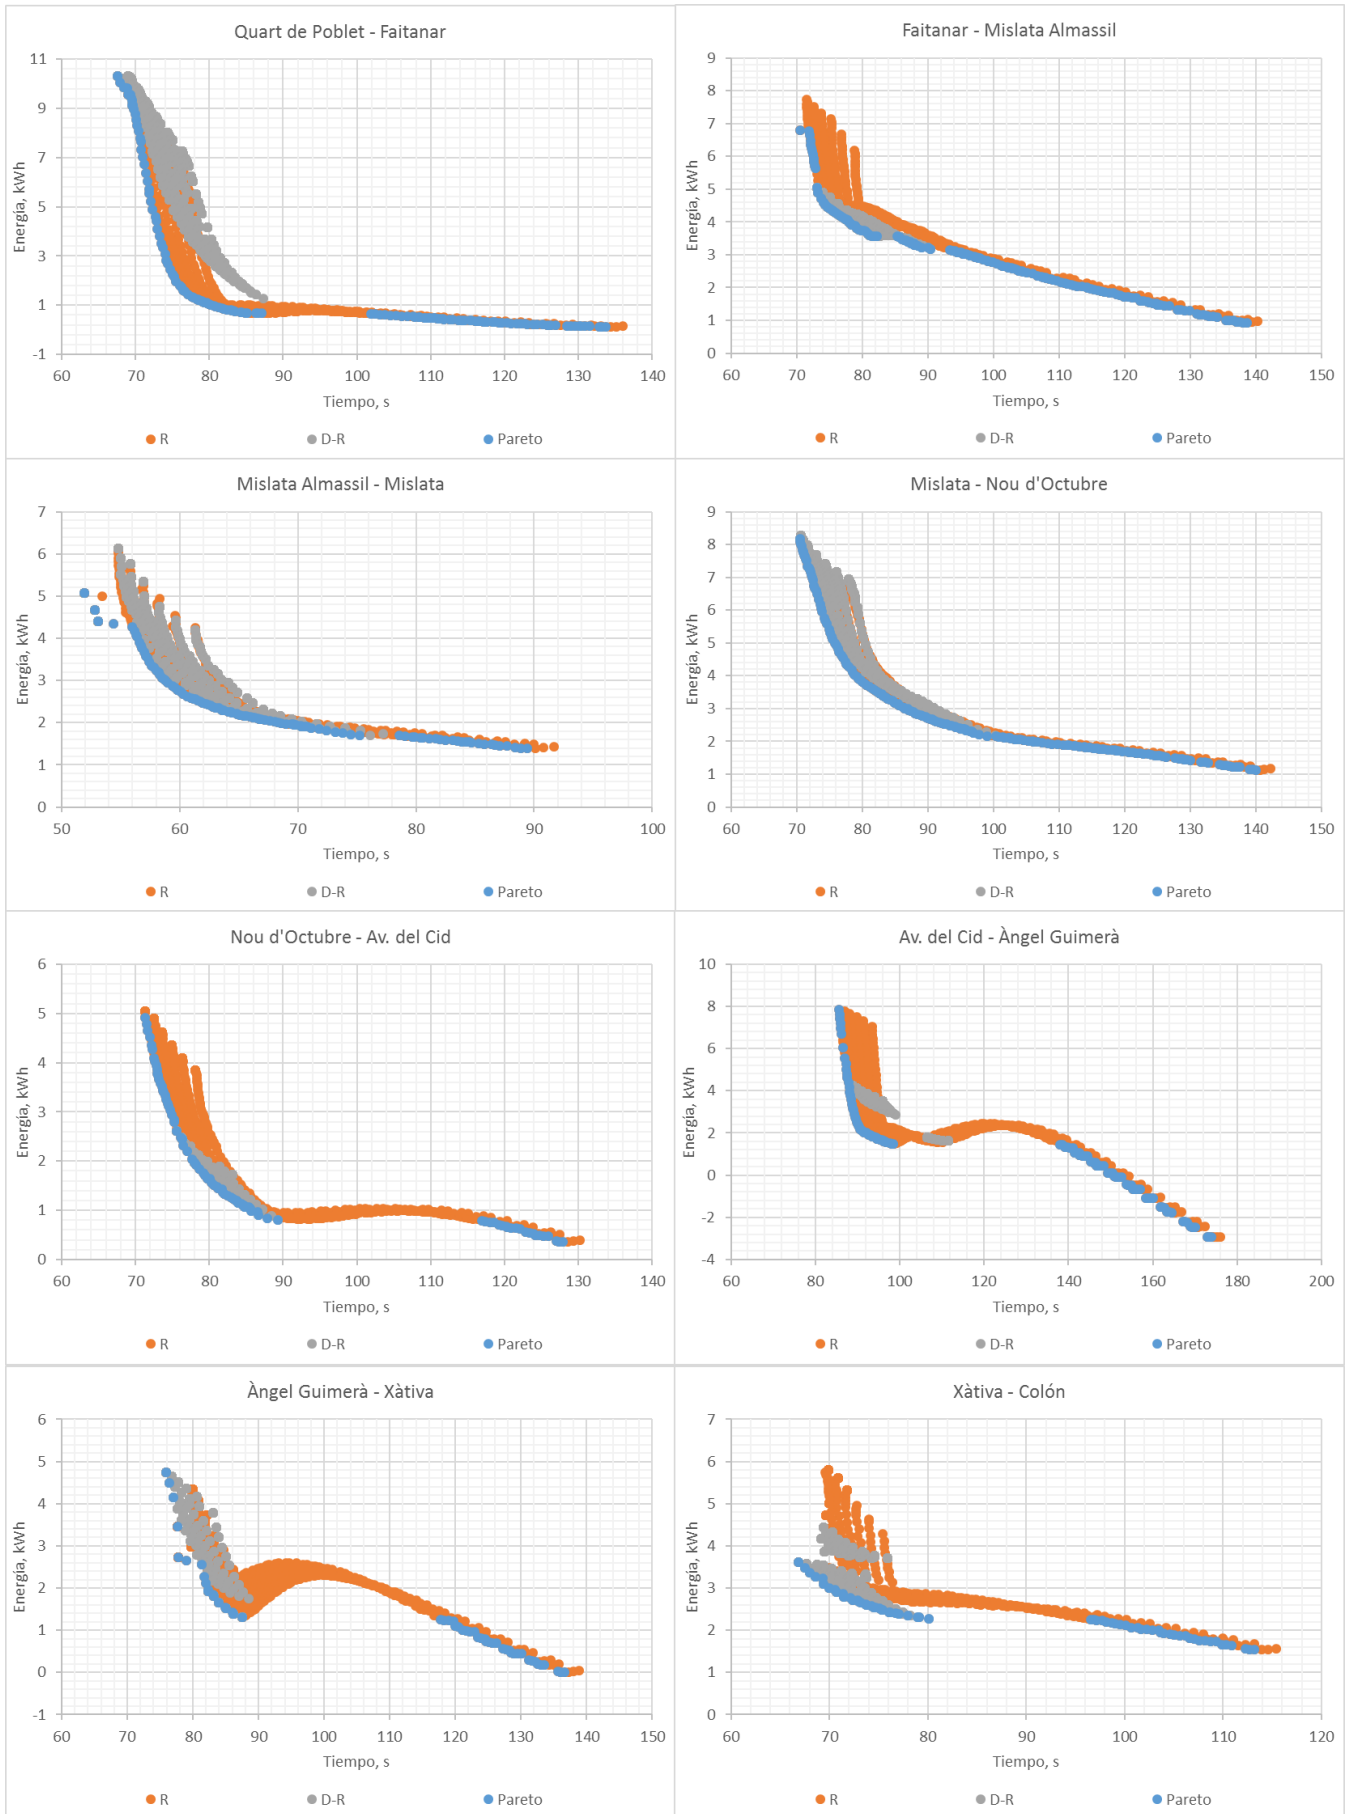
Líneas 5-7 (Alameda – Marítim Serrería)

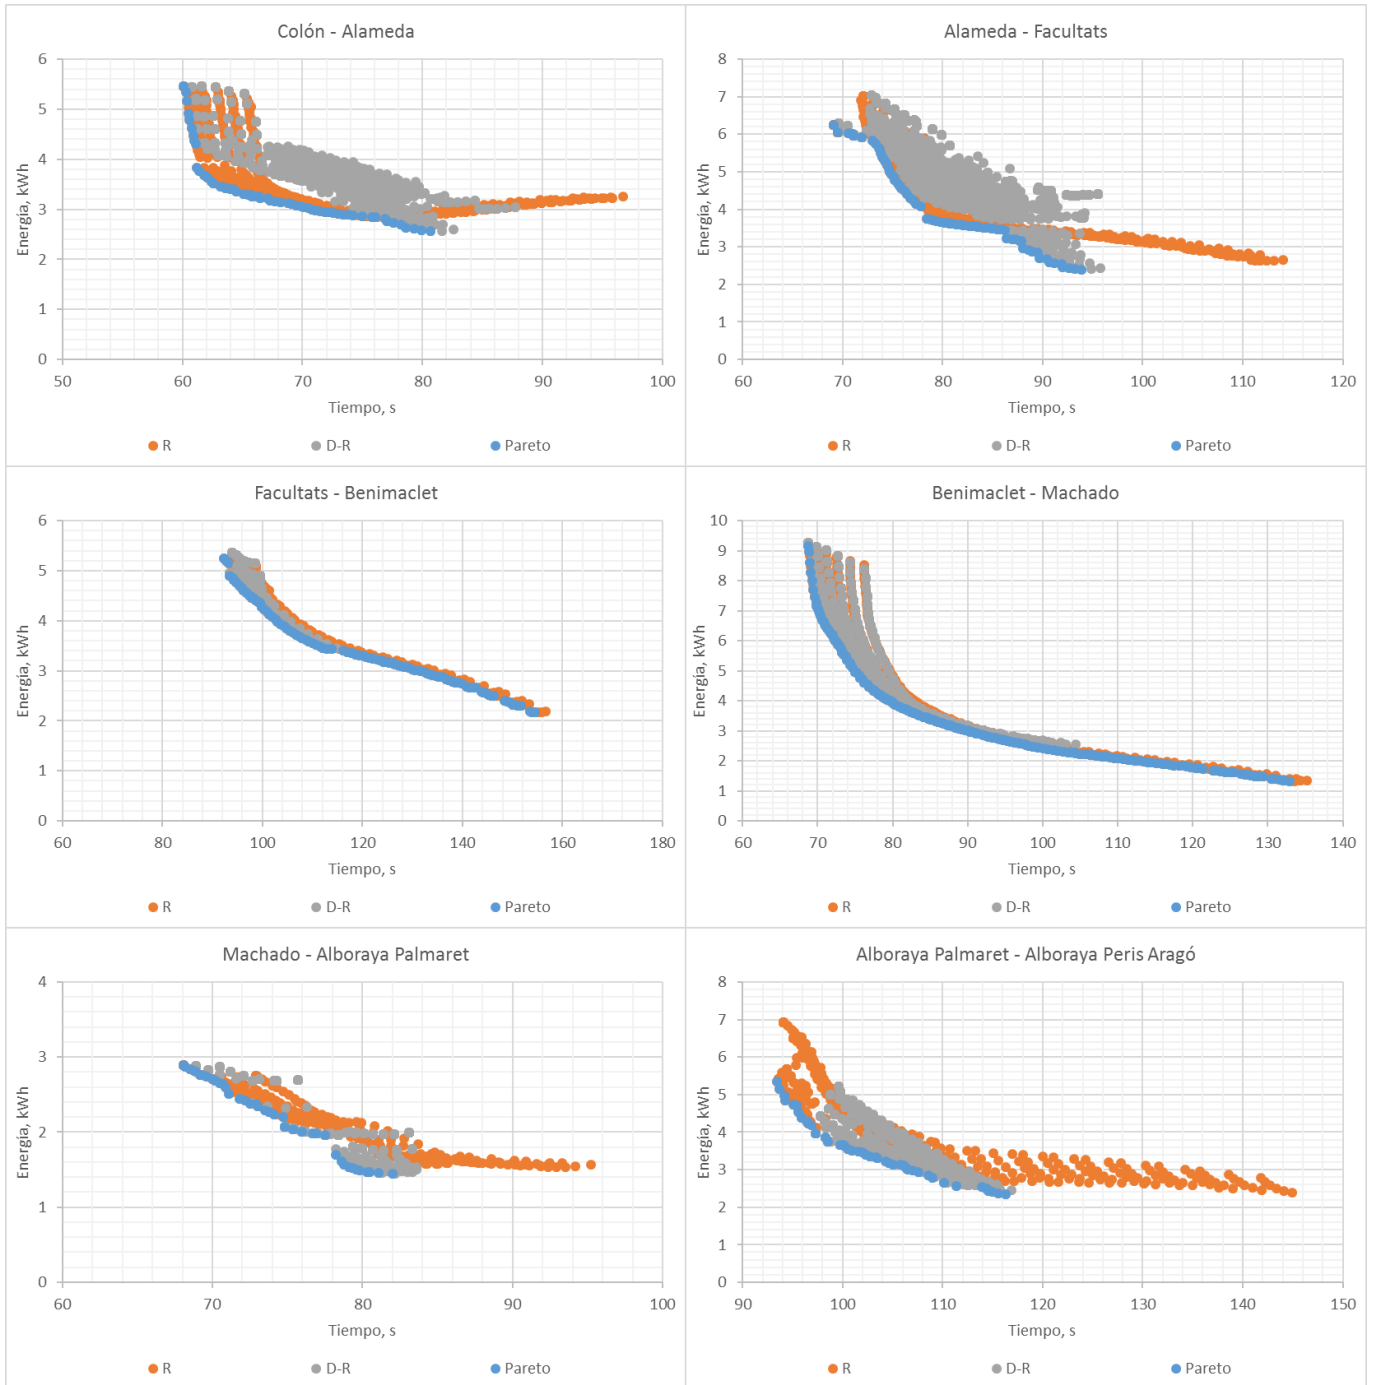




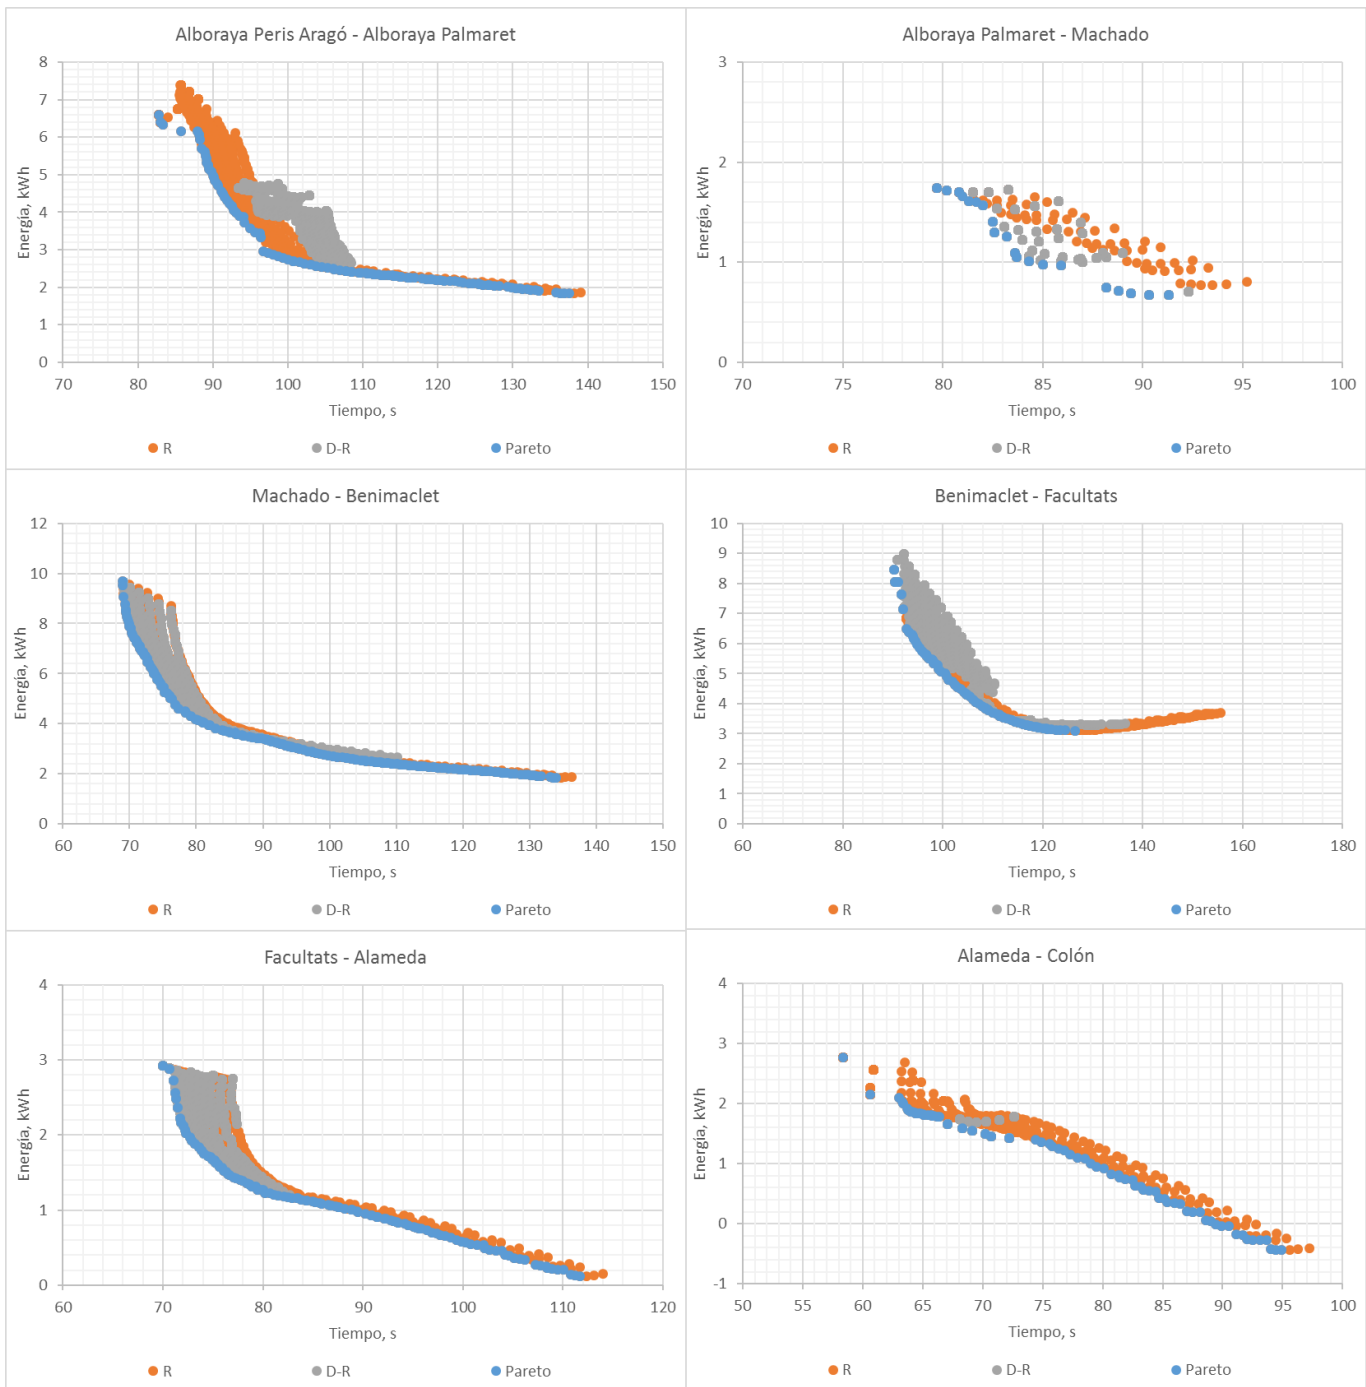
Línea 3 (Aeroport – Alboraya Peris Aragó) / Línea 5 (Aeroport – Alameda)

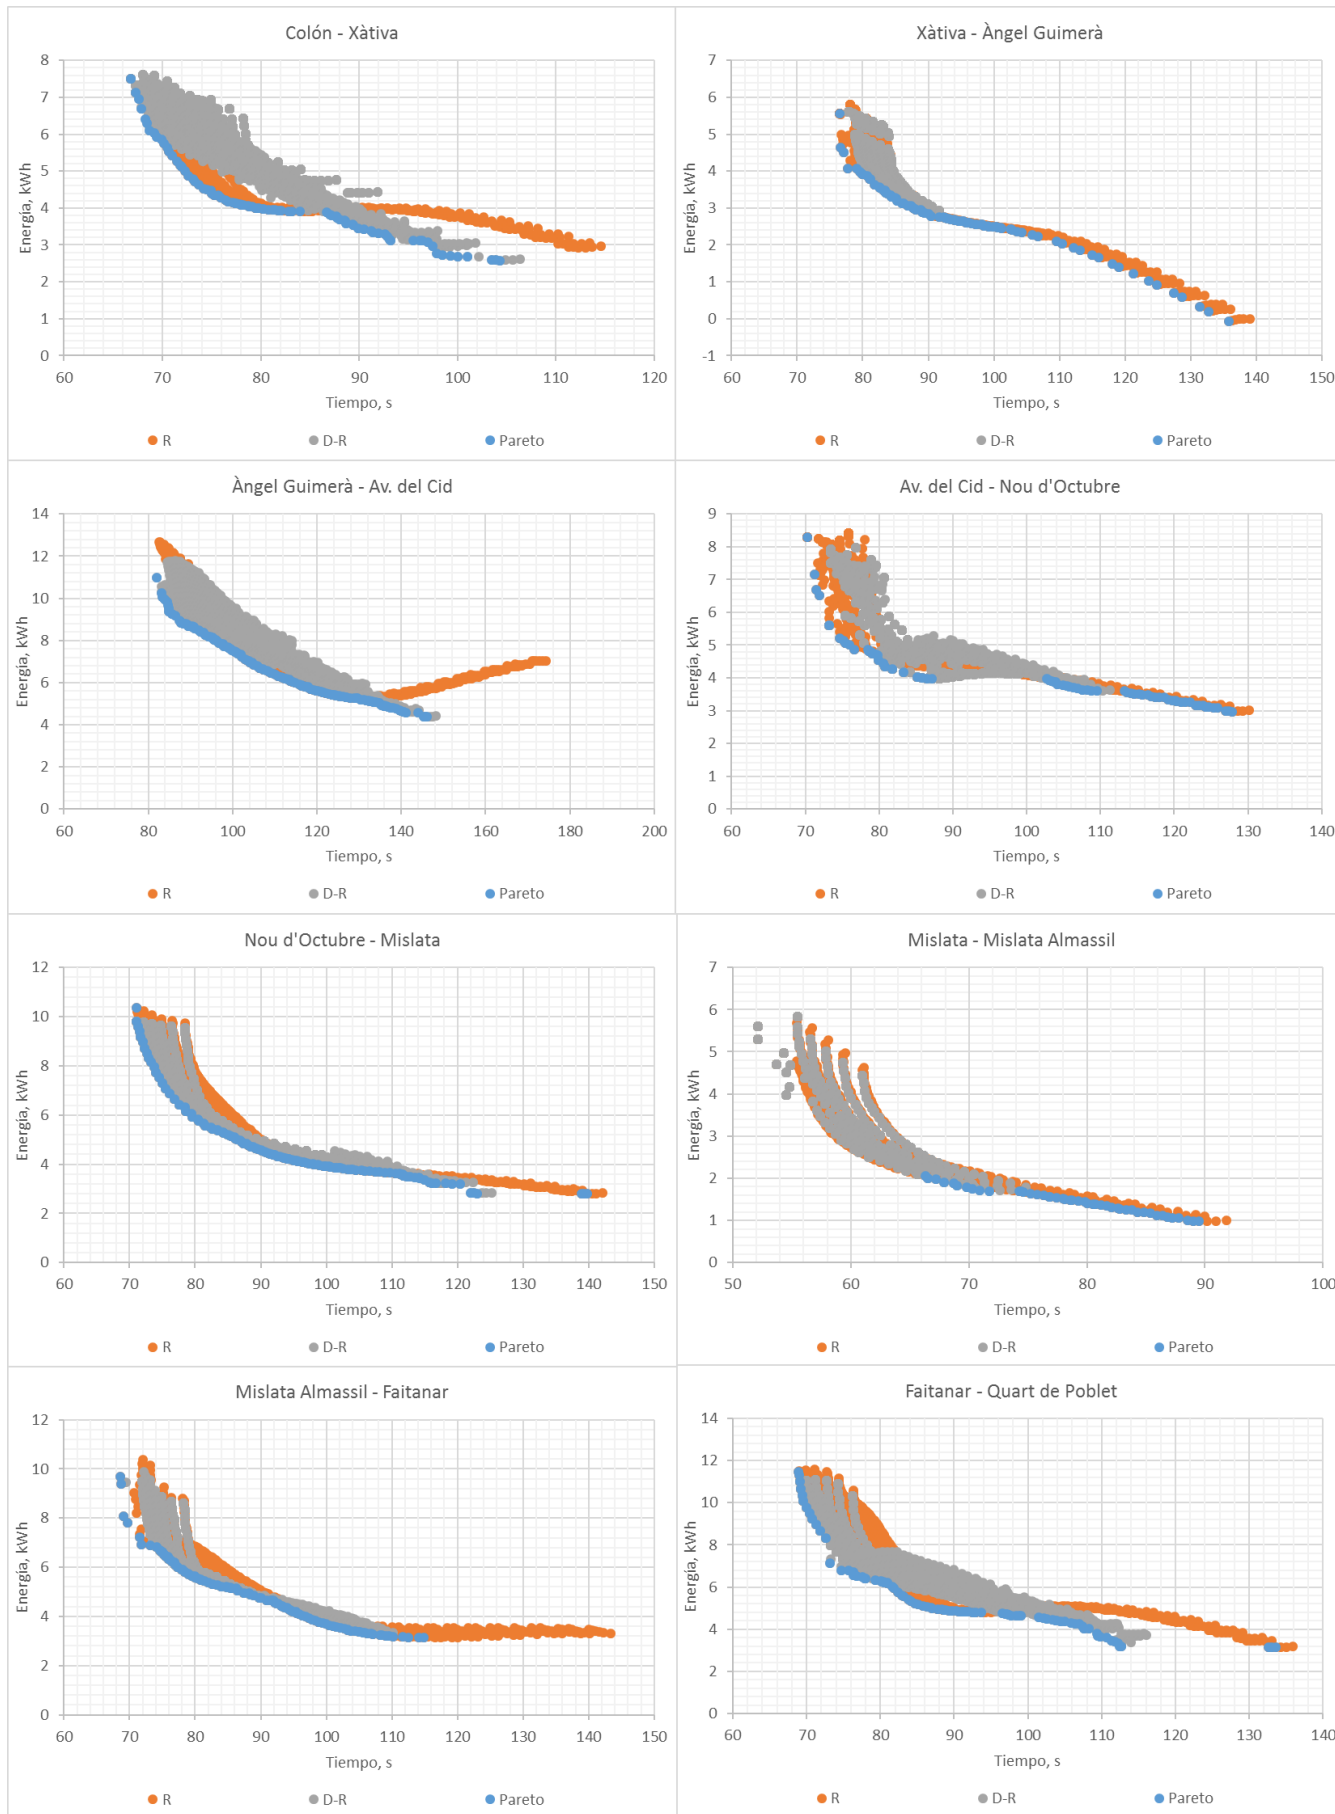










Línea 3 (Aeroport – Alboraya Peris Aragó) / Línea 5 (Aeroport – Alameda)

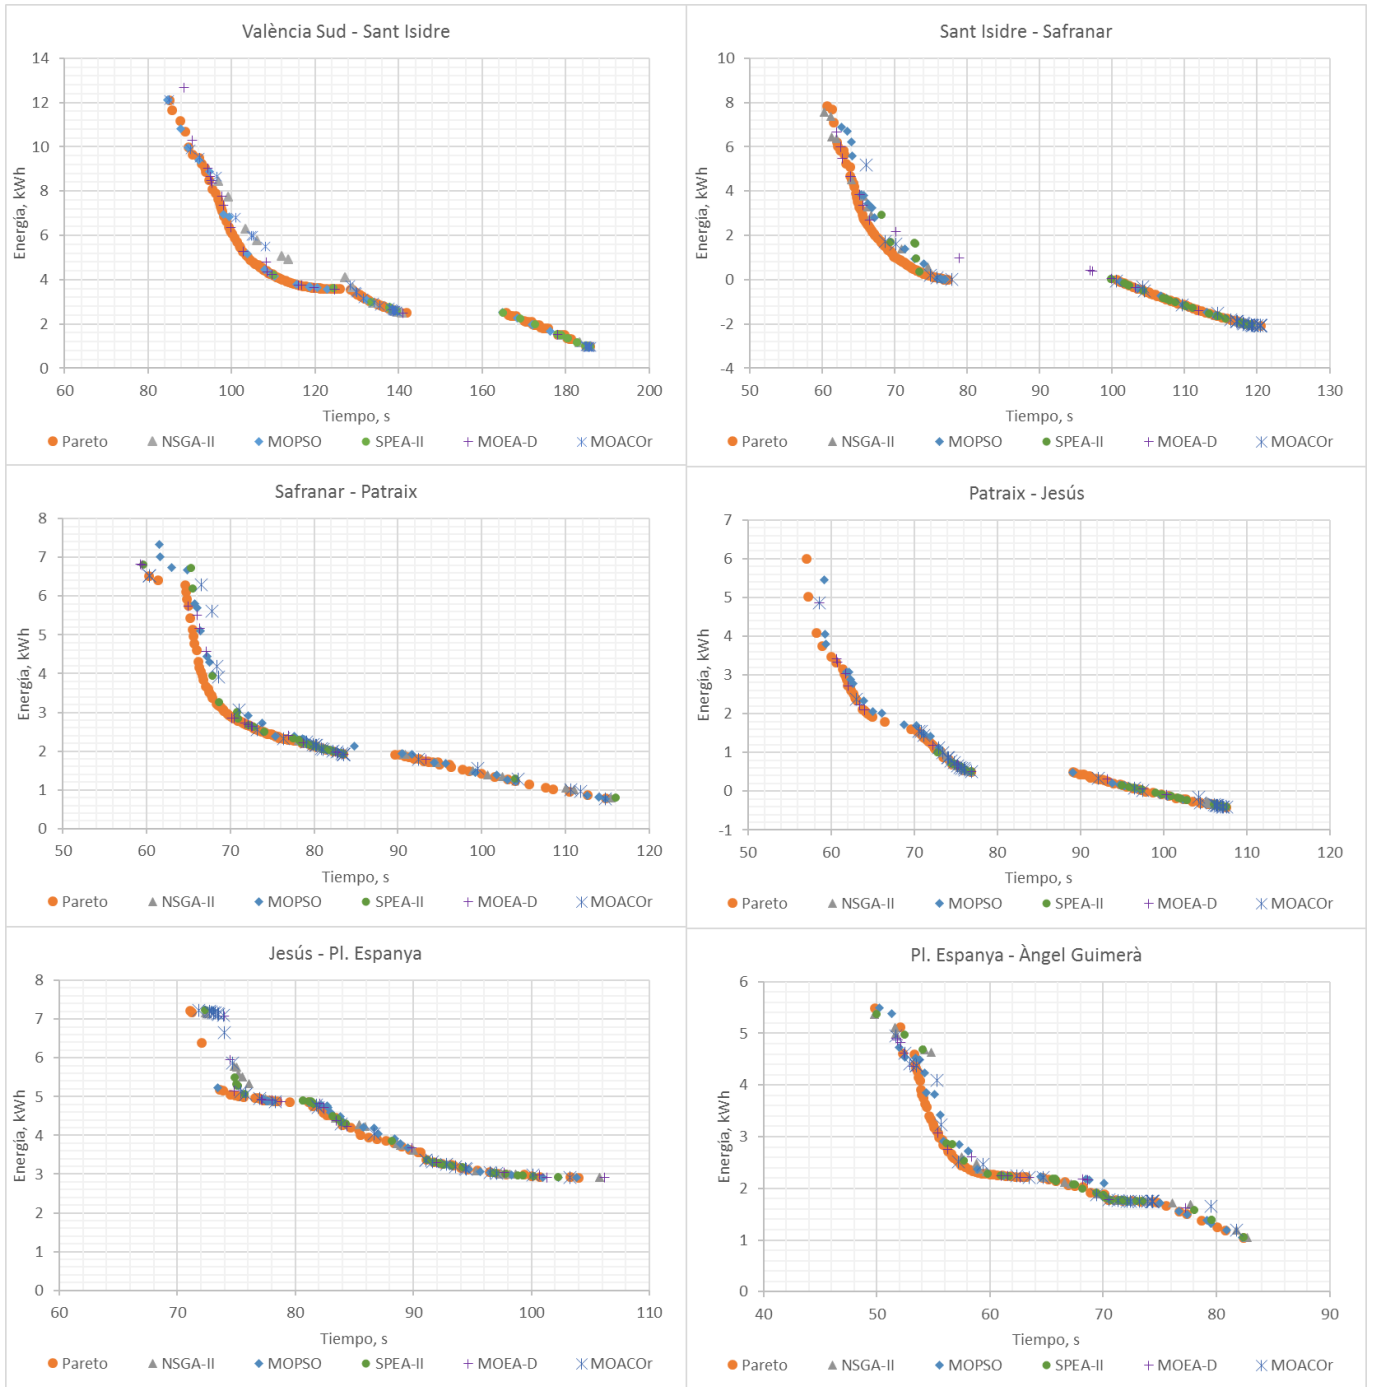


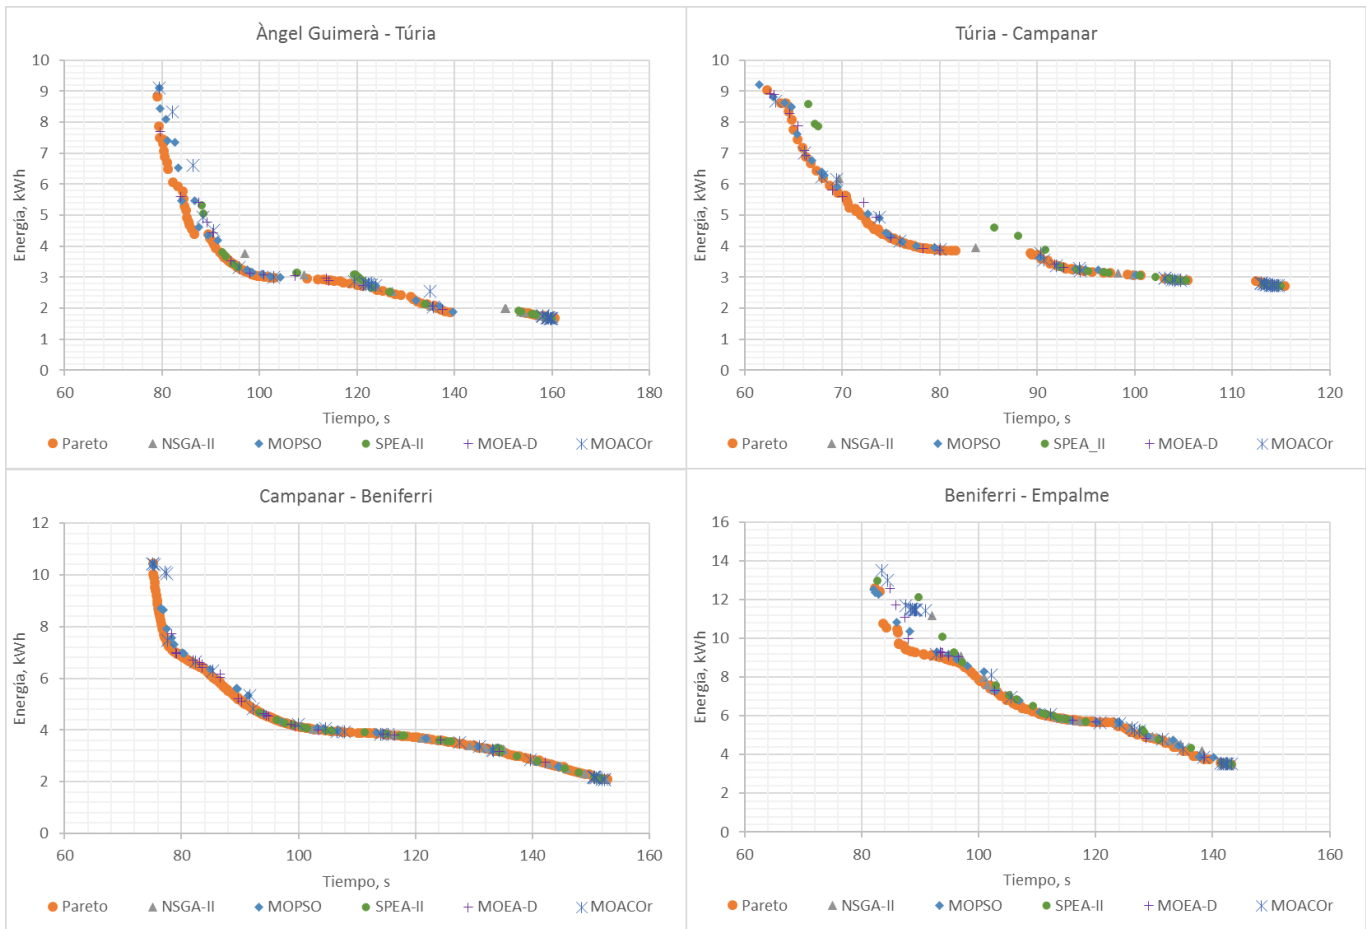





Bloque B: Resultados de los algoritmos de optimización

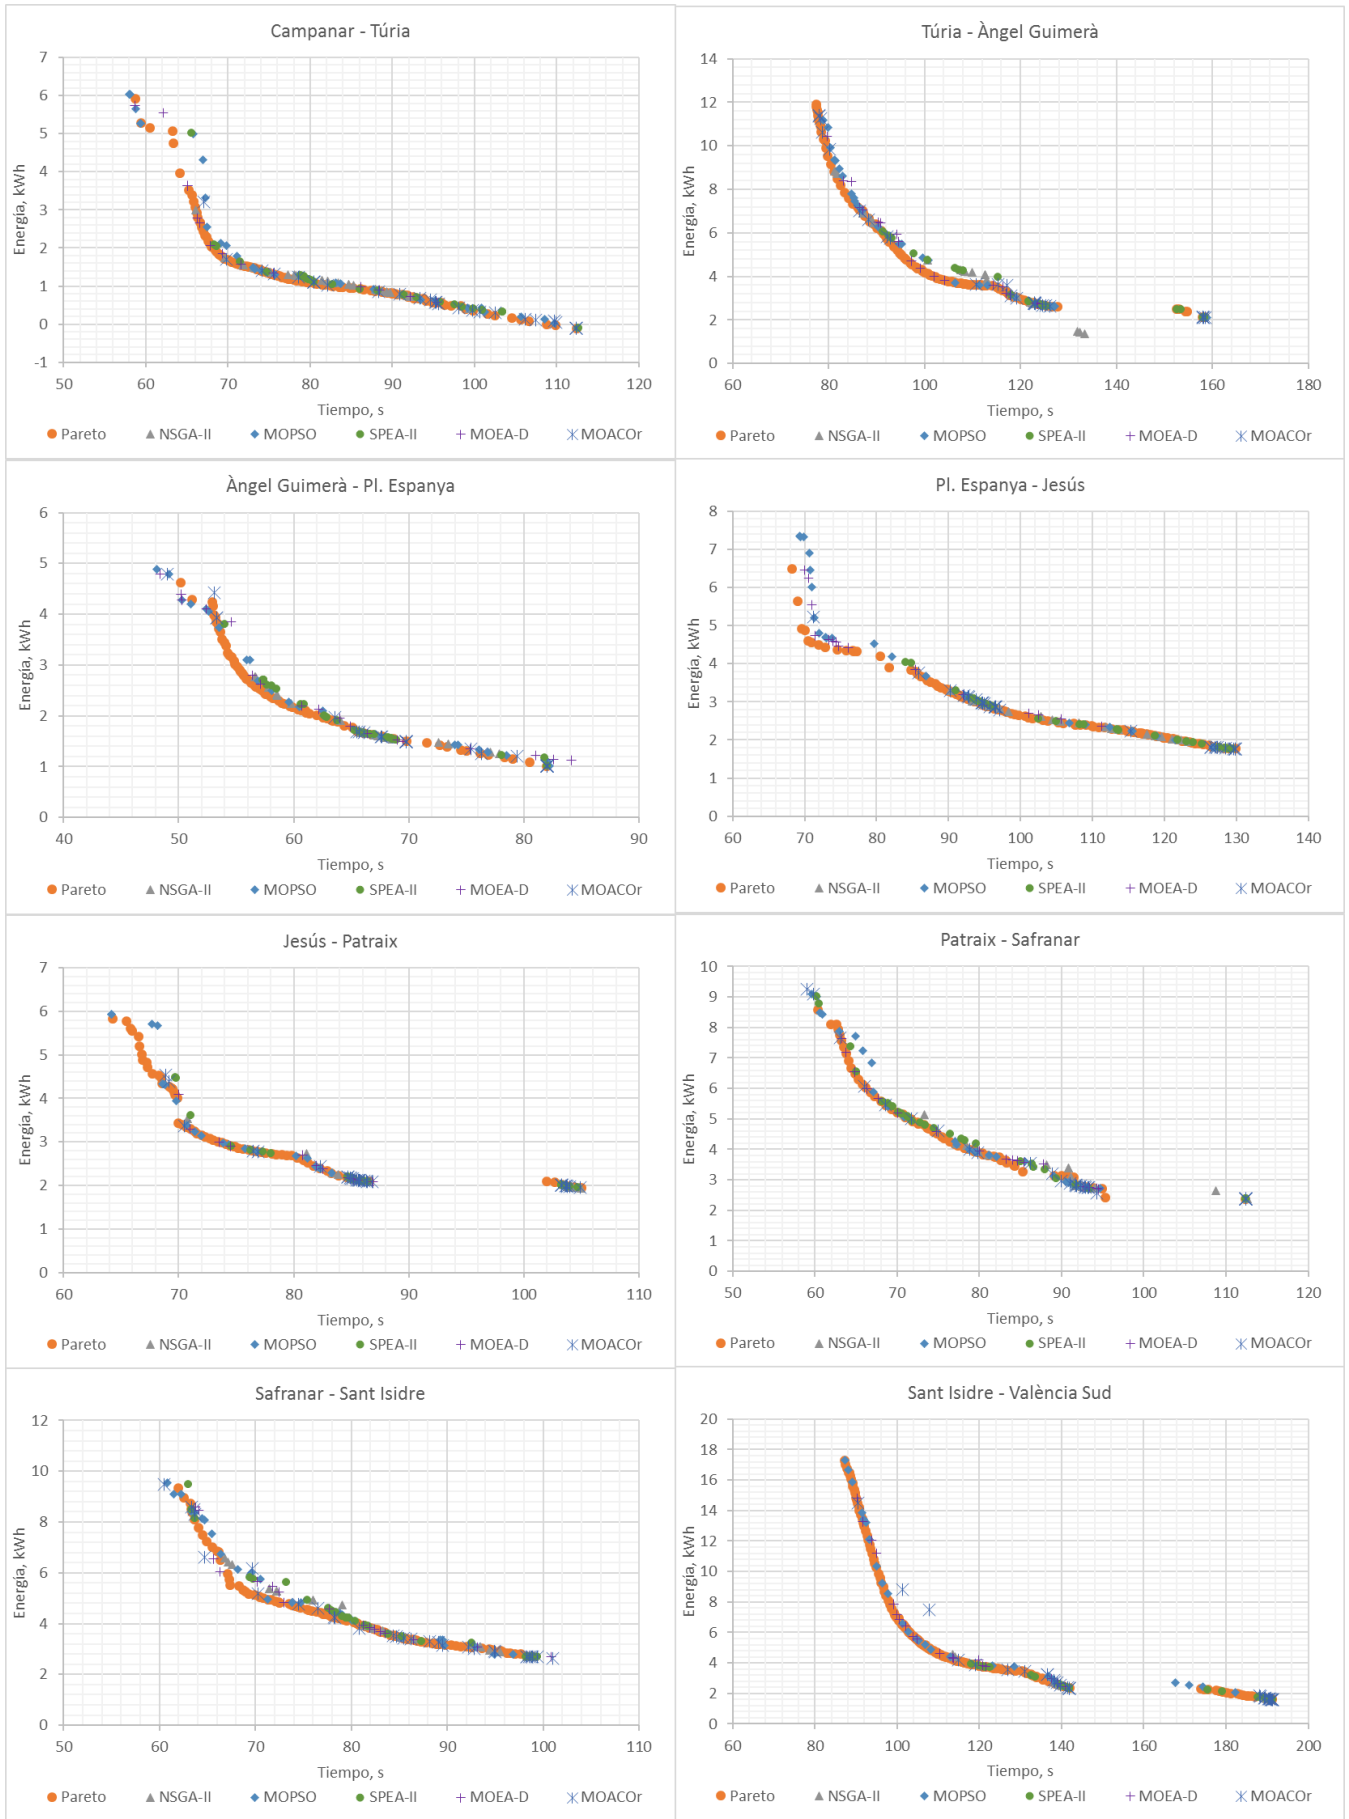
Líneas 1-2 (València Sud – Empalme) / Línea 7 (València Sud – Jesús)



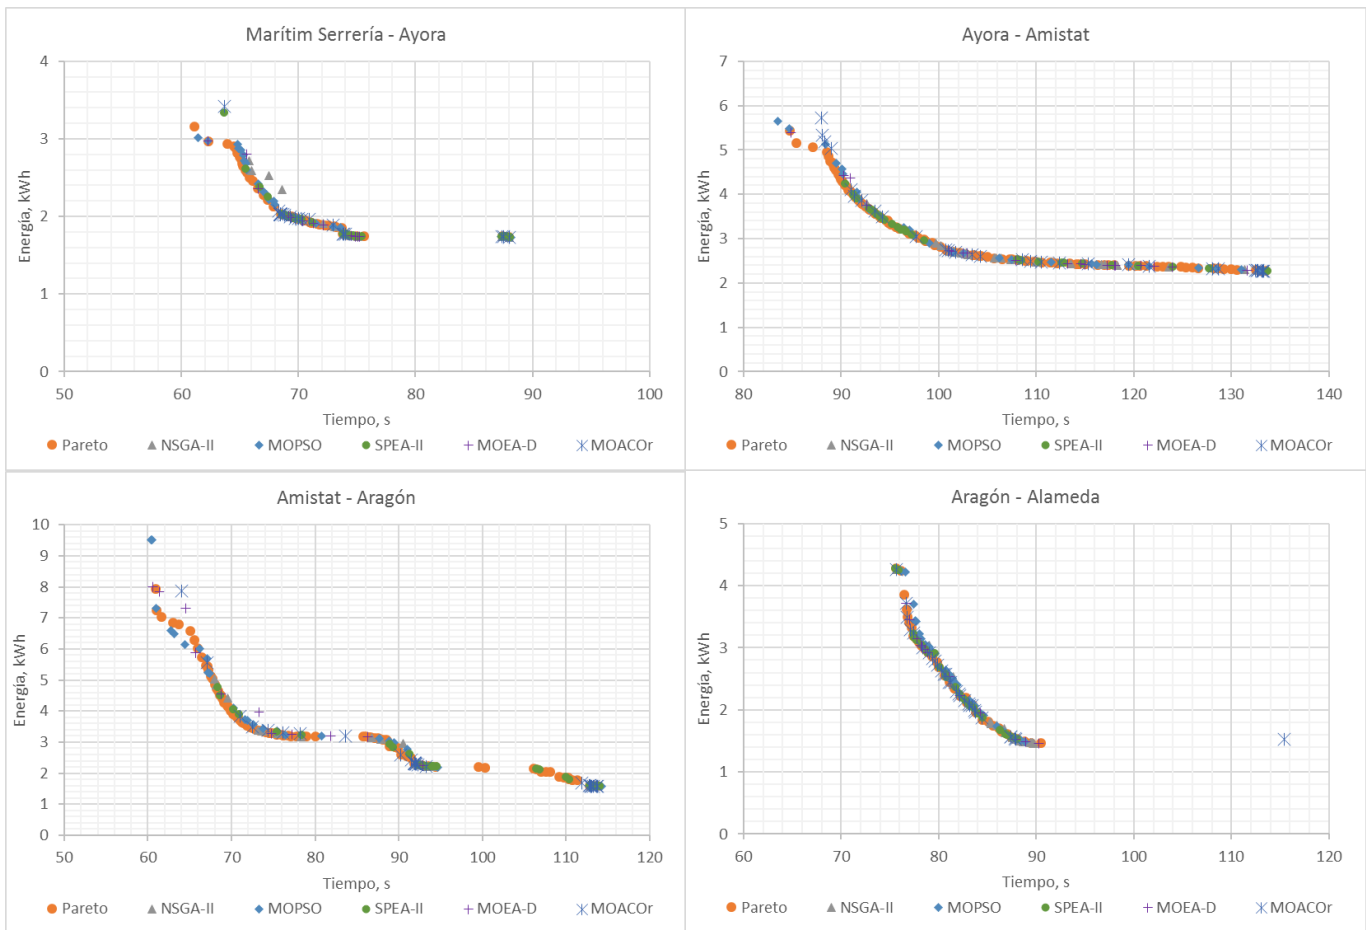


Líneas 1-2 (Empalme – València Sud) / Línea 7 (Jesús – València Sud)







Líneas 5-7 (Marítim Serrería – Alameda)

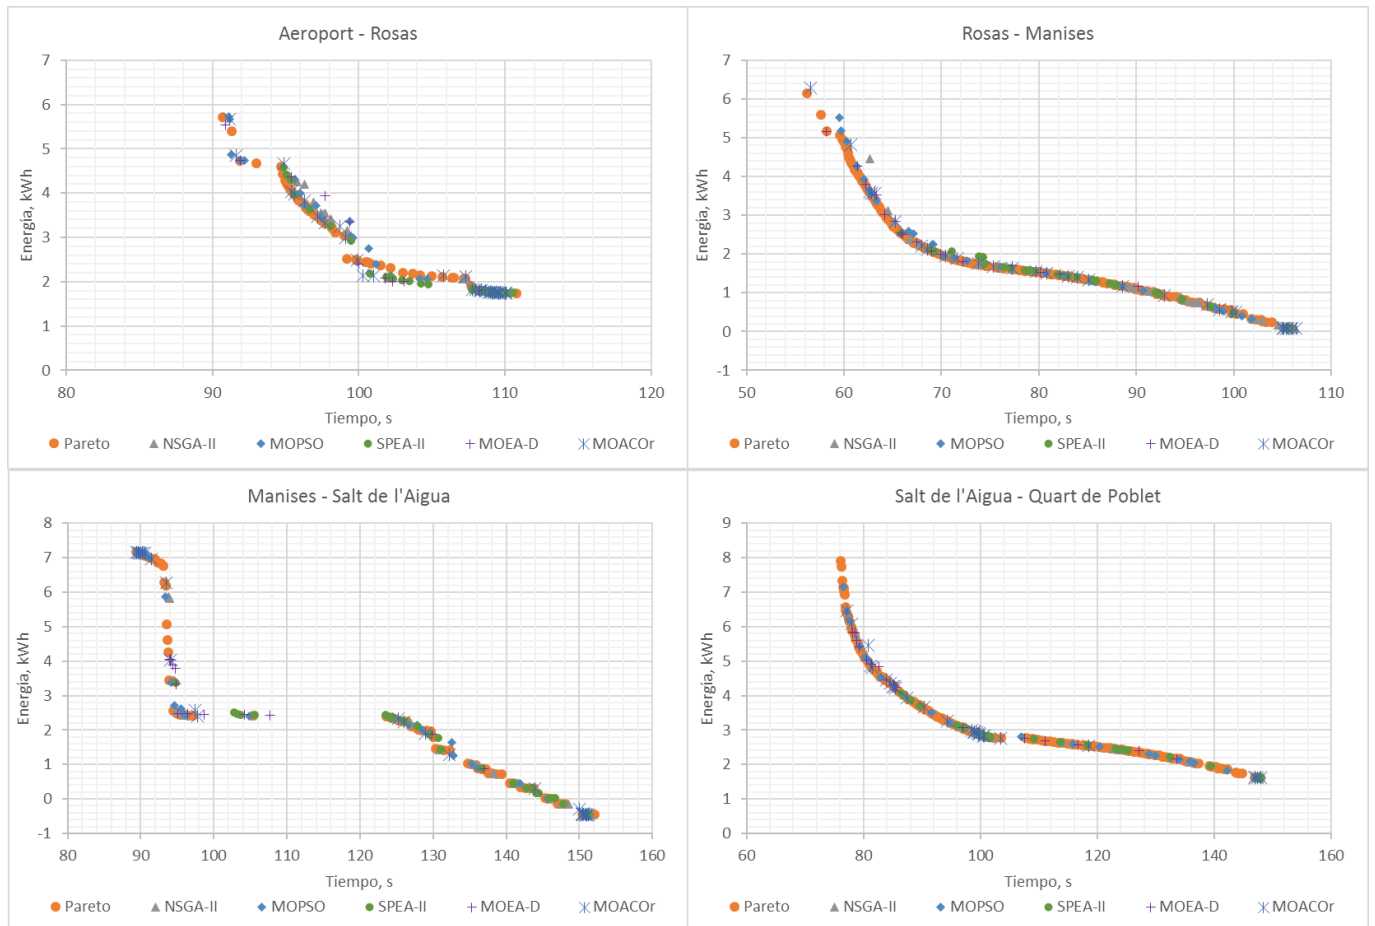


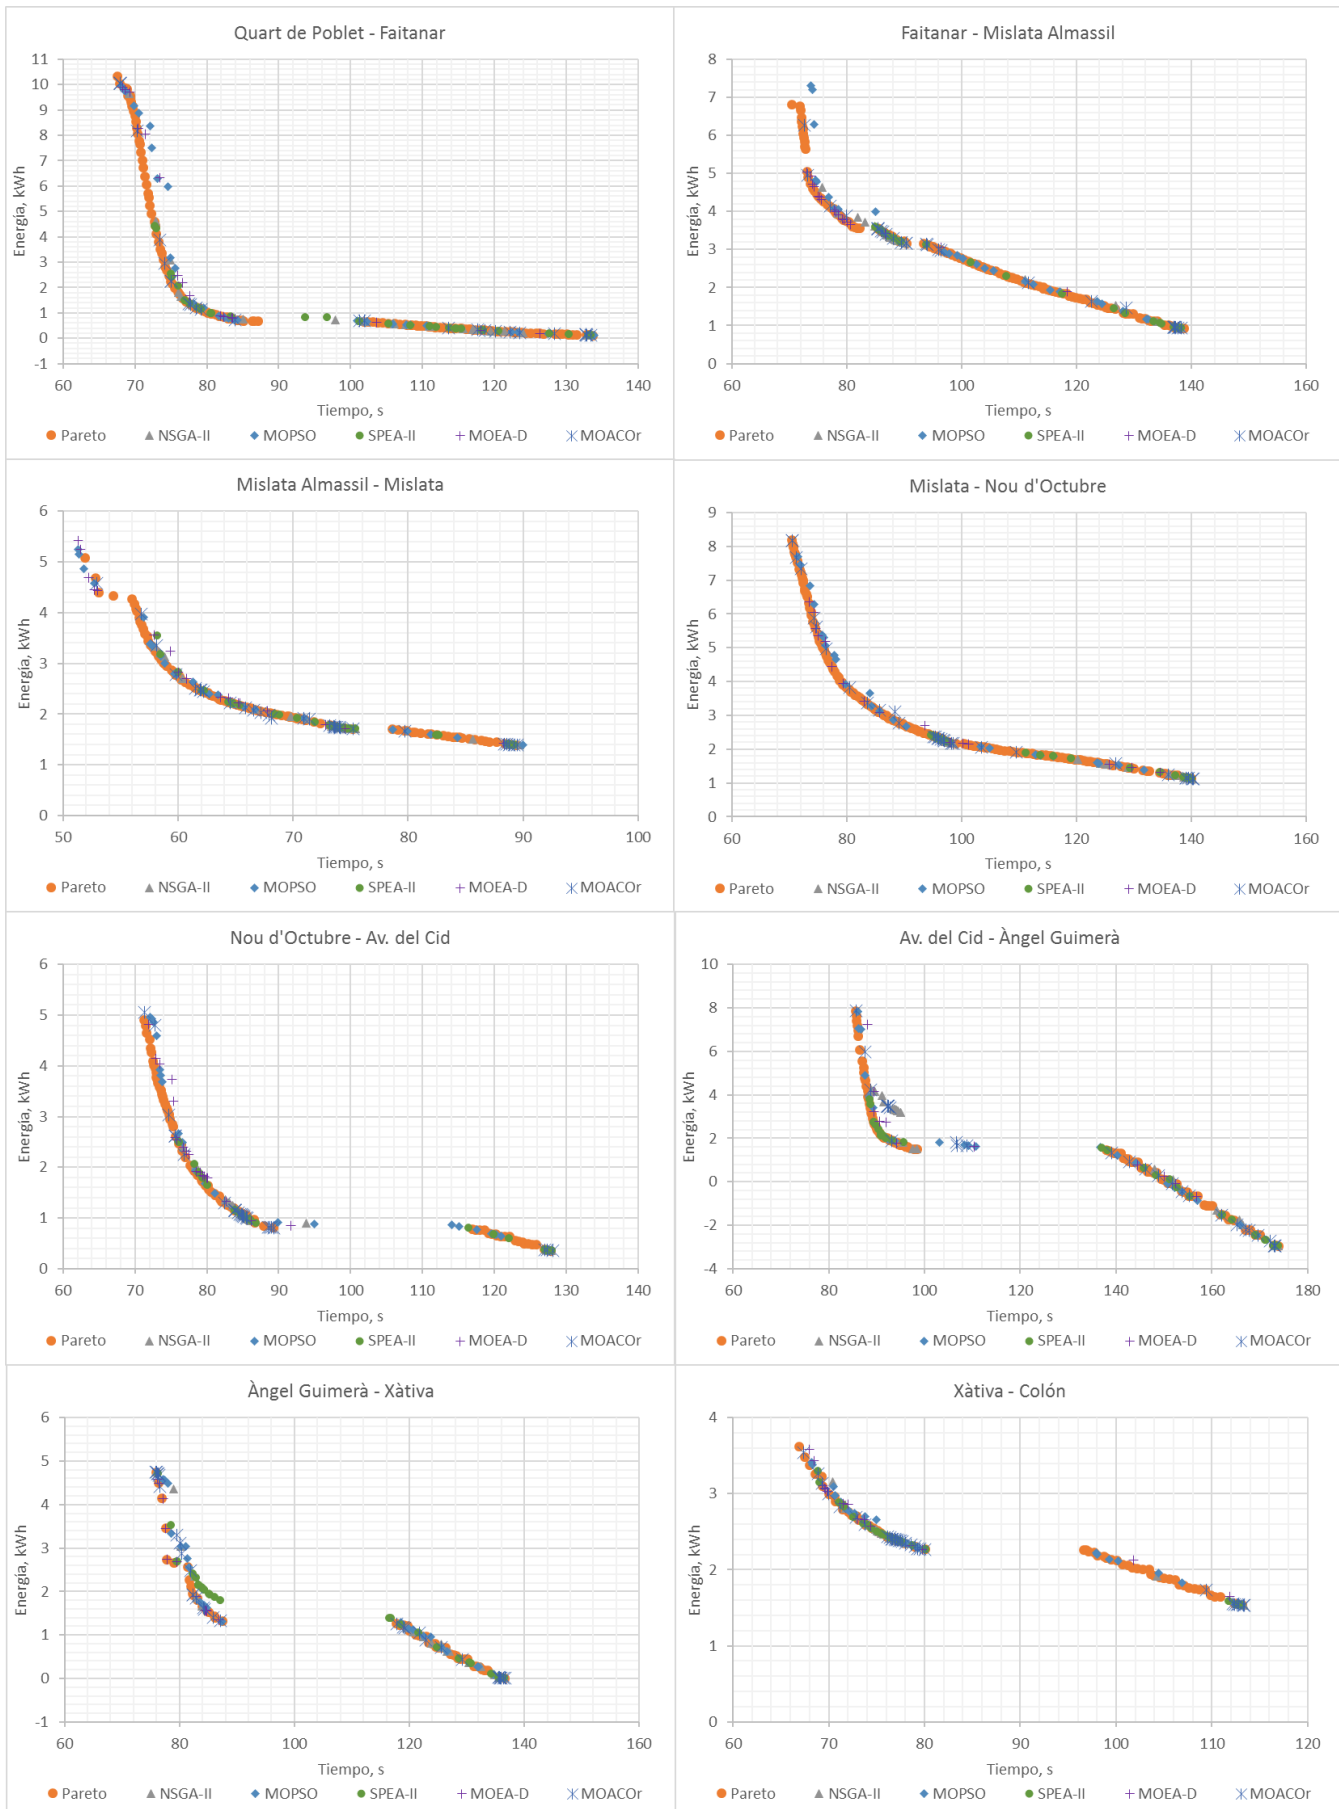
Líneas 5-7 (Alameda – Marítim Serrería)

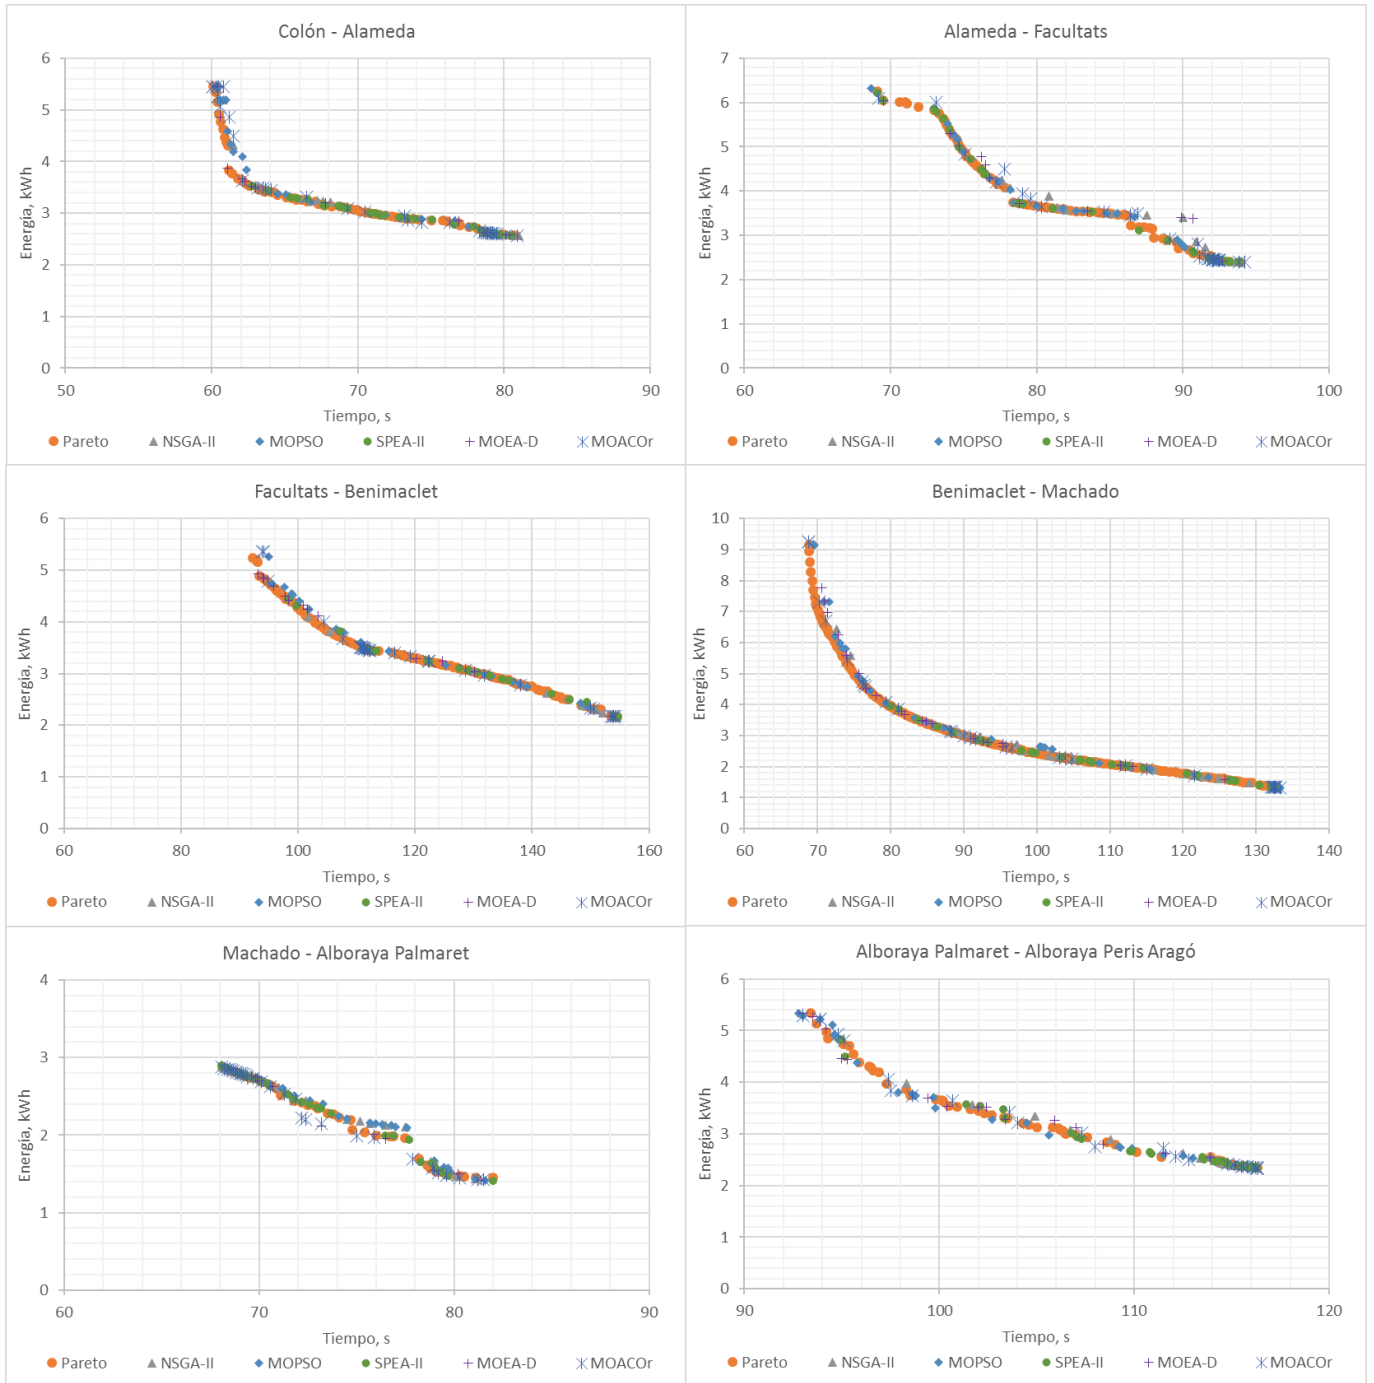




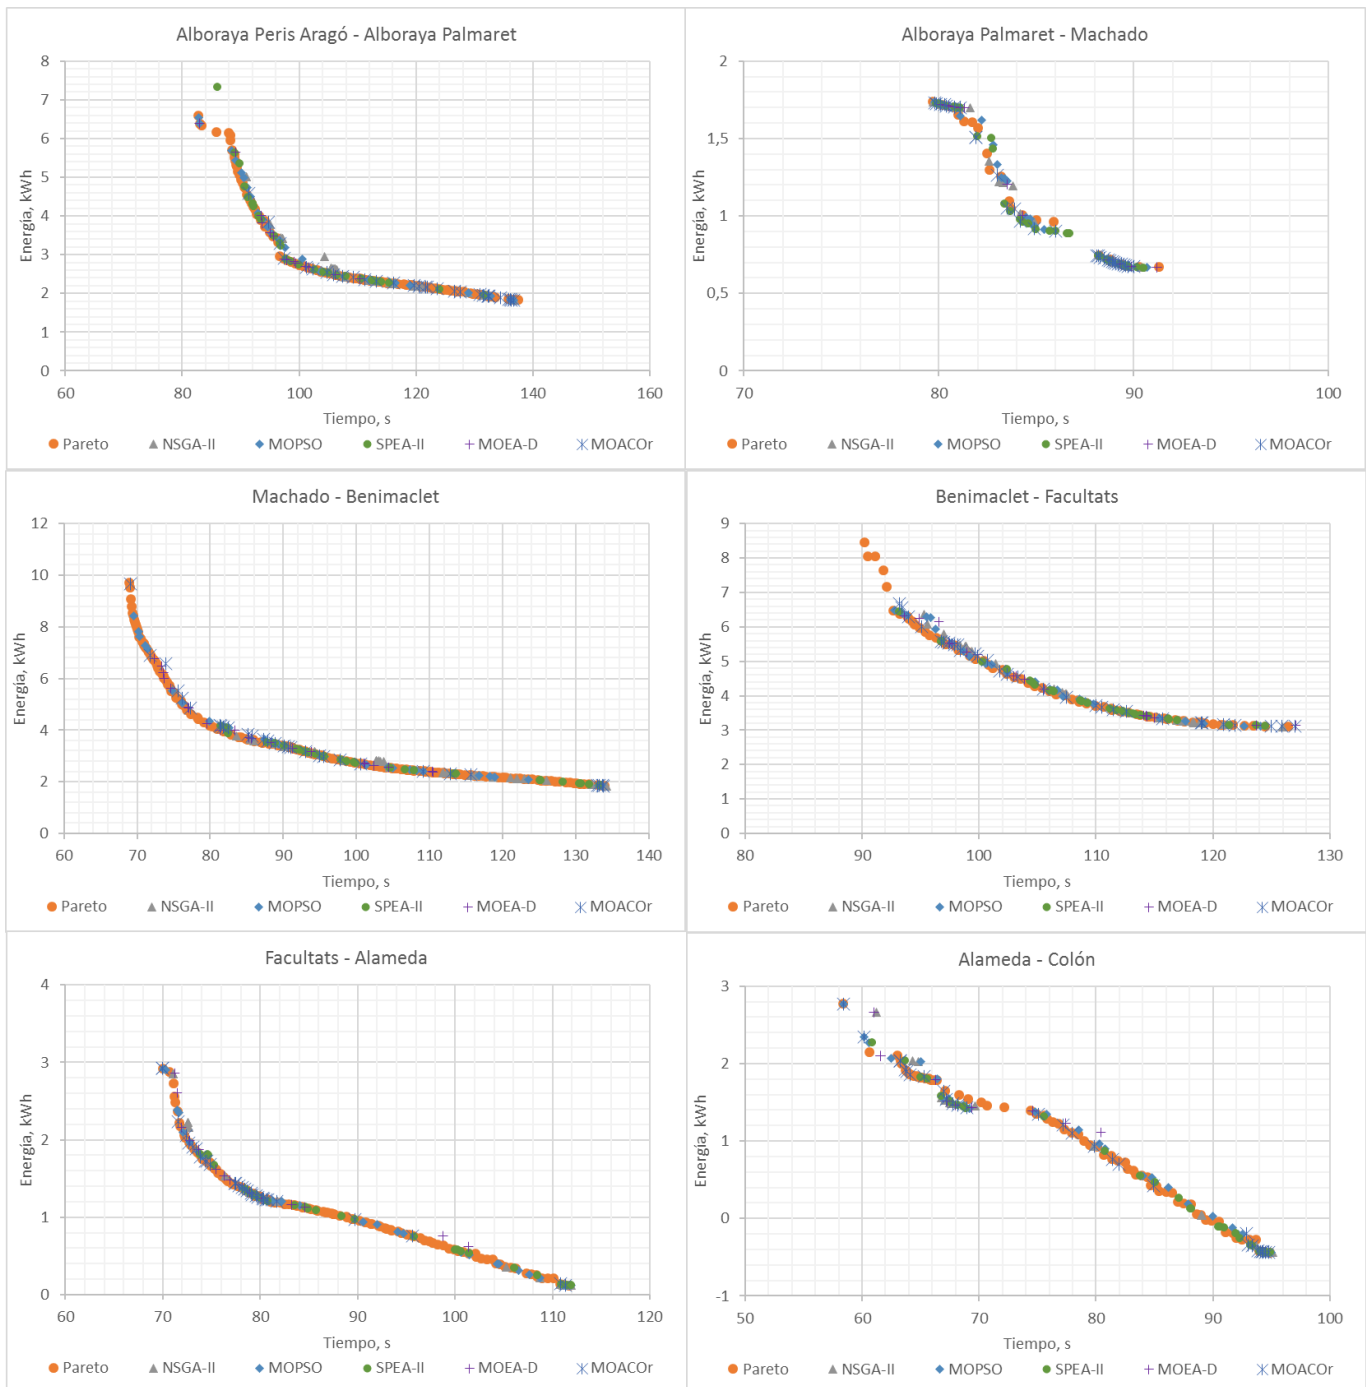
Línea 3 (Aeroport – Alboraya Peris Aragó) / Línea 5 (Aeroport – Alameda)

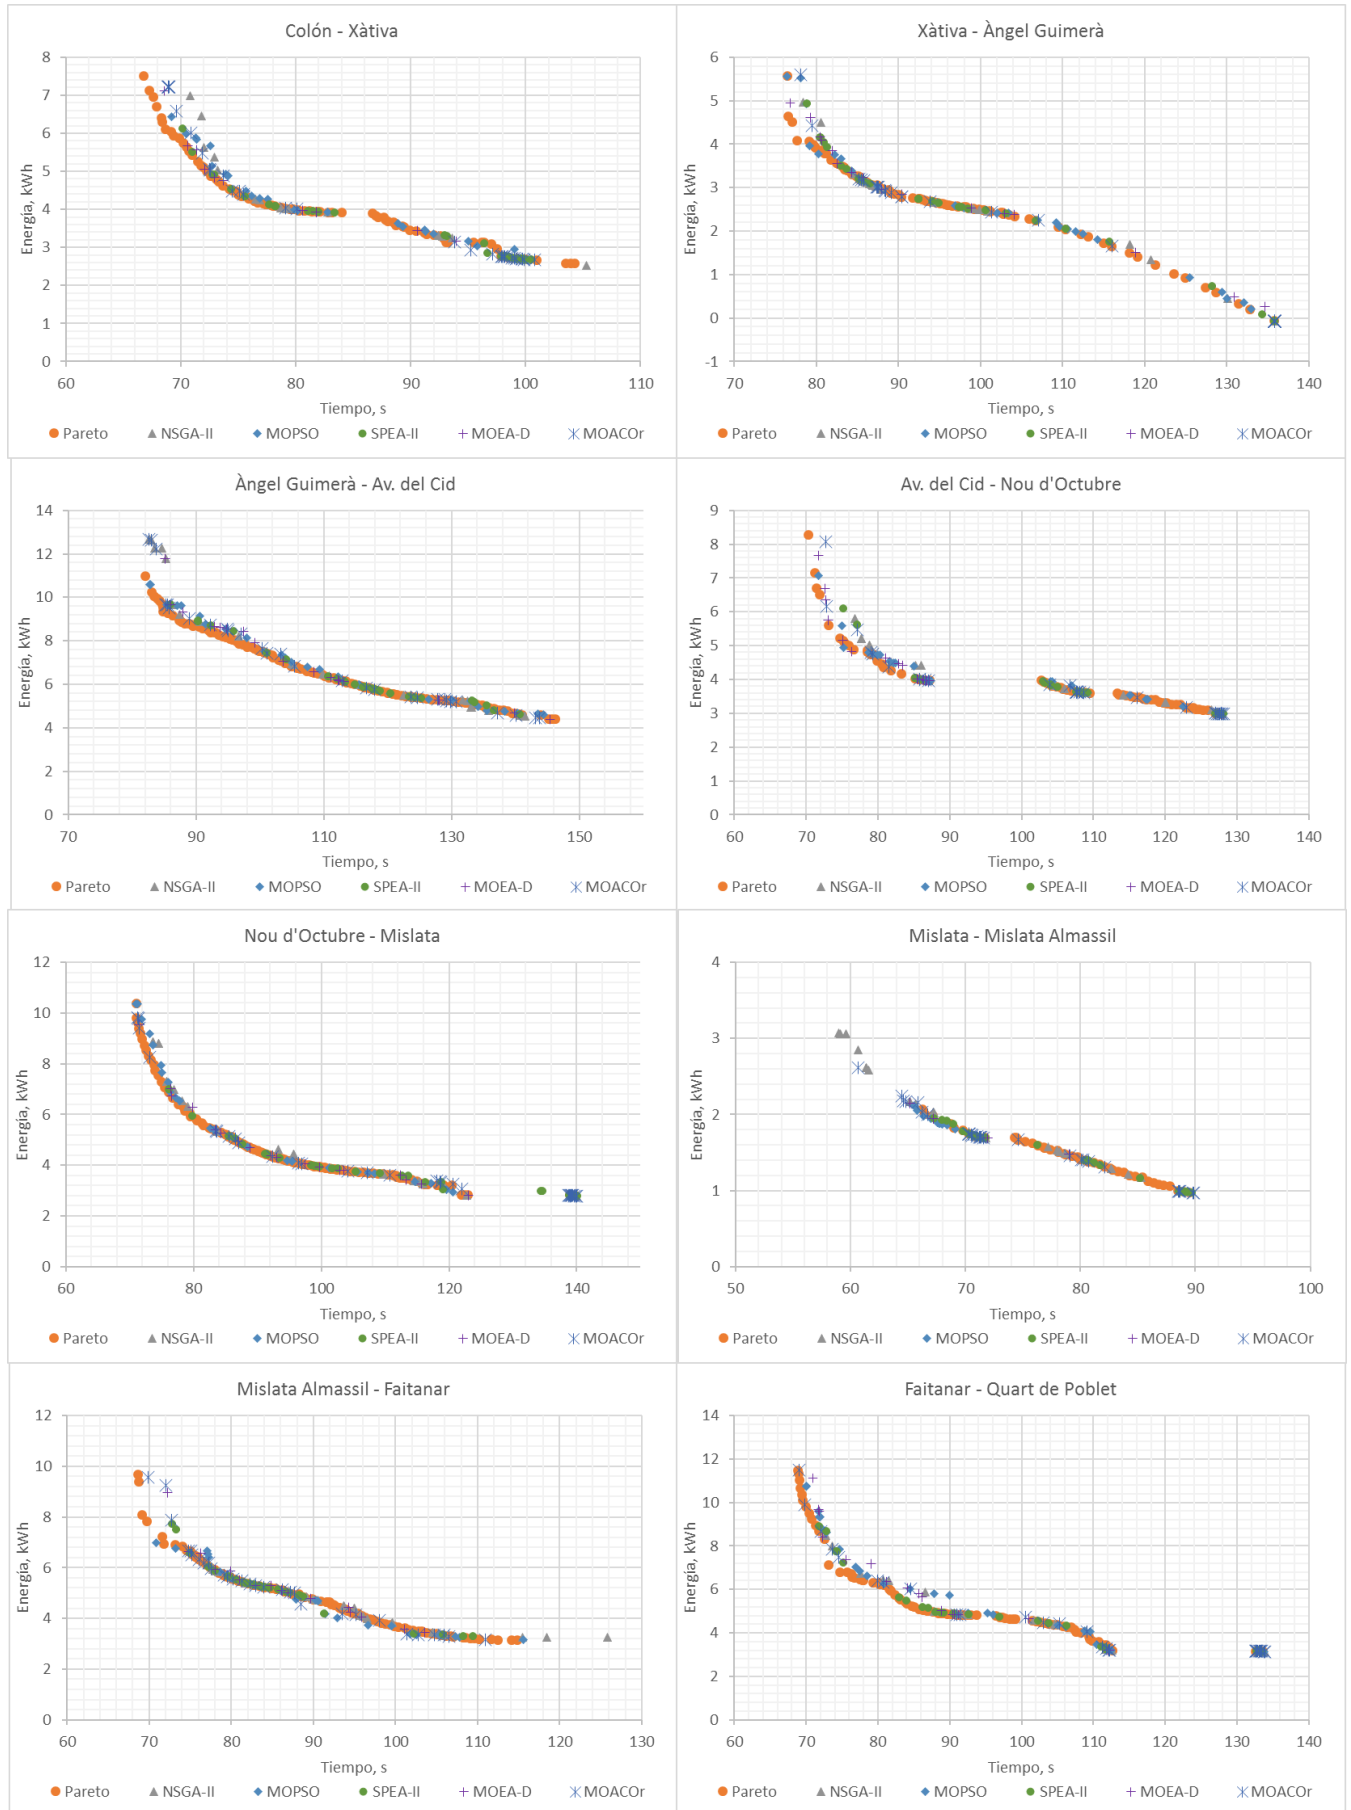


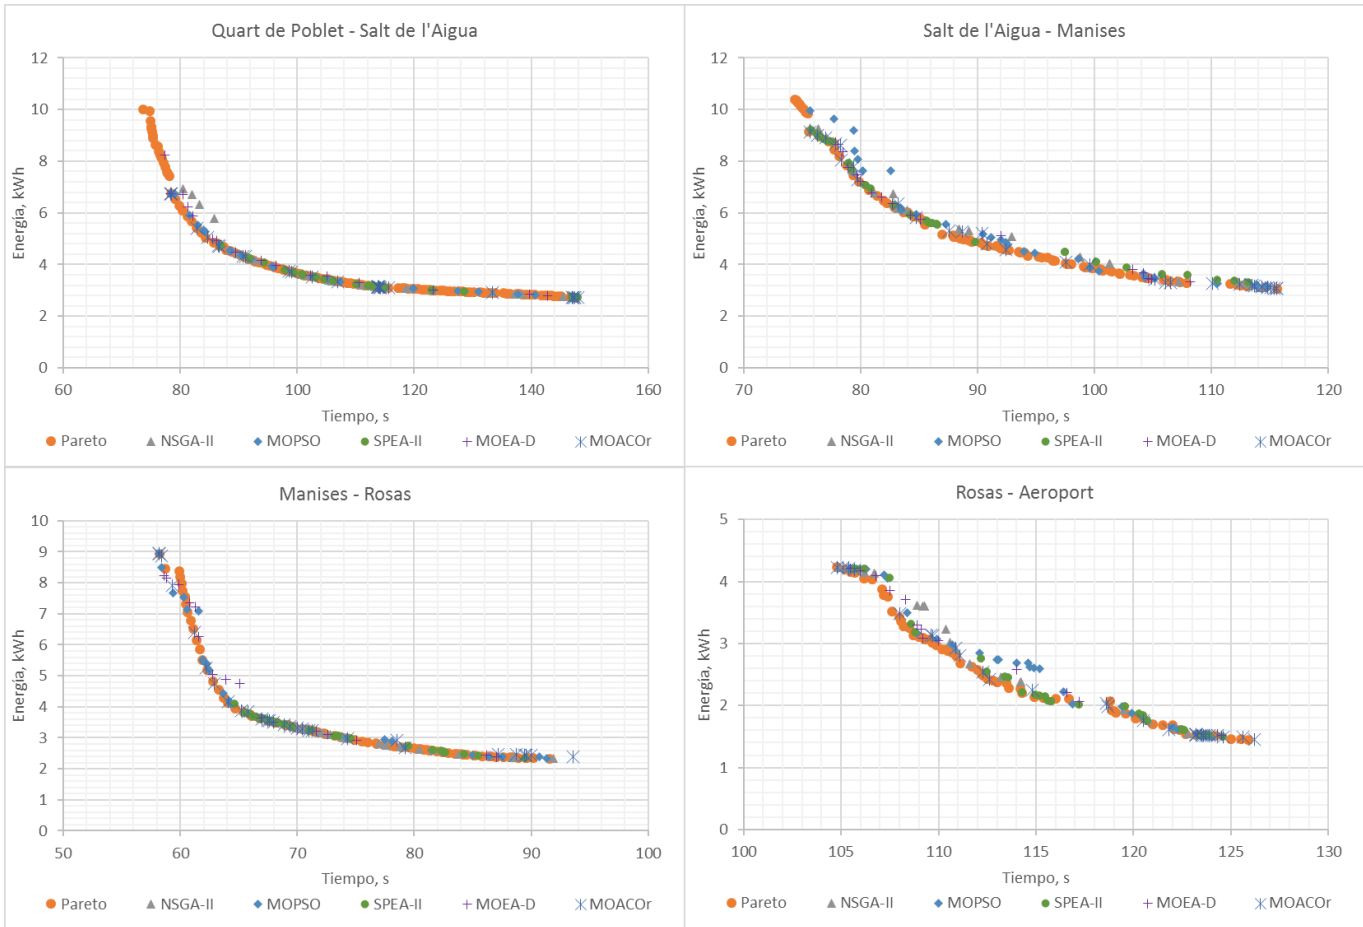




Línea 3 (Aeroport – Alboraya Peris Aragó) / Línea 5 (Aeroport – Alameda)







Bloque C: Resultados de las métricas de cada algoritmo

| NSGA-II | | | | | | |
|--|--|-------|-------|-------|---------|---------|
| Línea | Tramo | GD | SPR | SP | NH | Tiempo |
| L1/L2/L7 | València Sud - Sant Isidre | 0,136 | 1,162 | 7,229 | 0,332 | 841,811 |
| | Sant Isidre - Safranar | 0,075 | 1,393 | 7,772 | 0,326 | 470,908 |
| | Safranar - Patraix | 0,055 | 1,146 | 2,275 | 0,431 | 504,304 |
| | Patraix - Jesús | 0,038 | 1,366 | 5,132 | 0,410 | 475,643 |
| | Jesús - Pl. Espanya | 0,117 | 1,111 | 1,846 | 0,337 | 552,685 |
| | Pl. Espanya - Àngel Guimerà | 0,070 | 0,883 | 1,315 | 0,371 | 382,897 |
| | Àngel Guimerà - Túria | 0,214 | 1,219 | 4,015 | 0,330 | 732,459 |
| | Túria - Campanar | 0,081 | 1,402 | 3,848 | 0,348 | 581,824 |
| | Campanar - Beniferri | 0,028 | 1,012 | 2,787 | 0,455 | 664,463 |
| | Beniferri - Empalme | 0,082 | 1,003 | 2,511 | 0,443 | 705,470 |
| L1/L2/L7 | València Sud - Sant Isidre | 0,077 | 1,272 | 8,840 | 0,273 | 654,848 |
| | Beniferri - Campanar | 0,038 | 1,011 | 2,144 | 0,406 | 601,191 |
| | Campanar - Túria | 0,032 | 0,930 | 1,518 | 0,304 | 448,133 |
| | Túria - Àngel Guimerà | 0,291 | 1,090 | 2,897 | 0,208 | 603,865 |
| | Àngel Guimerà - Pl. Espanya | 0,043 | 1,049 | 1,196 | 0,365 | 353,517 |
| | Pl. Espanya - Jesús | 0,036 | 0,835 | 1,290 | 0,450 | 546,934 |
| | Jesús - Patraix | 0,028 | 1,340 | 3,508 | 0,293 | 506,005 |
| | Patraix - Safranar | 0,131 | 1,181 | 2,956 | 0,368 | 546,180 |
| | Safranar - Sant Isidre | 0,057 | 0,974 | 1,482 | 0,340 | 534,640 |
| | Sant Isidre - València Sud | 0,080 | 1,497 | 9,672 | 0,322 | 812,437 |
| L3/L5 | Aeroport-Rosas | 0,045 | 1,060 | 1,038 | 0,413 | 624,584 |
| | Rosas-Manises | 0,046 | 0,894 | 1,912 | 0,341 | 445,570 |
| | Manises-Salt de l'Aigua | 0,048 | 1,077 | 5,239 | 0,345 | 614,244 |
| | Salt de l'Aigua-Quart de Poblet | 0,032 | 1,390 | 4,734 | 0,301 | 611,704 |
| | Quart de Poblet-Faitanar | 0,137 | 0,906 | 3,015 | 0,141 | 487,450 |
| | Faitanar-Mislata Almassil | 0,043 | 1,238 | 4,689 | 0,360 | 625,652 |
| | Mislata Almassil-Mislata | 0,032 | 1,139 | 2,058 | 0,307 | 403,734 |
| | Mislata - Nou d'Octubre | 0,045 | 1,202 | 4,092 | 0,432 | 547,962 |
| | Nou d'Octubre - Av. Del Cid | 0,155 | 1,457 | 6,192 | 0,235 | 514,129 |
| | Av. Del Cid- Àngel Guimerà | 0,209 | 1,314 | 9,074 | 0,388 | 619,397 |
| | Àngel Guimerà - Xàtiva | 0,087 | 1,136 | 6,404 | 0,345 | 529,414 |
| | Xàtiva - Colón | 0,037 | 1,430 | 4,946 | 0,423 | 475,946 |
| | Colón - Alameda | 0,035 | 1,195 | 1,381 | 0,270 | 421,518 |
| | Alameda - Facultats | 0,044 | 1,028 | 0,886 | 0,525 | 495,507 |
| | Facultats - Benimaclet | 0,035 | 1,348 | 5,656 | 0,469 | 636,168 |
| | Benimaclet - Machado | 0,037 | 0,898 | 2,658 | 0,265 | 540,006 |
| Machado - Alboraya Palmaret | 0,024 | 0,832 | 0,499 | 0,534 | 409,736 | |
| Alboraya Palmaret - Alboraya Peris Aragó | 0,050 | 1,181 | 1,082 | 0,437 | 709,636 | |
| L3/L5 | Alboraya Peris Aragó - Alboraya Palmaret | 0,055 | 1,031 | 2,175 | 0,310 | 586,196 |
| | Alboraya Palmaret - Machado | 0,030 | 0,949 | 0,714 | 0,431 | 468,584 |
| | Machado - Benimaclet | 0,038 | 0,906 | 1,940 | 0,306 | 625,591 |
| | Benimaclet - Facultats | 0,041 | 1,077 | 1,808 | 0,319 | 708,336 |
| | Facultats - Alameda | 0,030 | 1,306 | 4,292 | 0,413 | 517,470 |
| | Alameda - Colón | 0,070 | 1,296 | 2,530 | 0,549 | 437,817 |
| | Colón - Xàtiva | 0,081 | 1,113 | 2,112 | 0,345 | 533,381 |
| | Xàtiva - Àngel Guimerà | 0,072 | 1,215 | 3,717 | 0,455 | 535,250 |
| | Àngel Guimerà - Av. Del Cid | 0,171 | 0,973 | 2,533 | 0,386 | 706,588 |
| | Av. Del Cid - Nou d'Octubre | 0,065 | 1,147 | 3,410 | 0,272 | 571,075 |
| Nou d'Octubre - Mislata | 0,077 | 1,145 | 4,075 | 0,237 | 635,899 | |

| | | | | | | |
|-------|-----------------------------------|-------|-------|-------|-------|---------|
| | Mislata - Mislata Almassil | 0,537 | 1,000 | 1,439 | 0,655 | 398,259 |
| | Mislata Almassil - Faitanar | 0,388 | 1,095 | 2,548 | 0,353 | 606,453 |
| | Faitanar - Quart de Poblet | 0,056 | 1,117 | 4,019 | 0,236 | 612,372 |
| | Quart de Poblet - Salt de l'Aigua | 0,074 | 0,812 | 2,507 | 0,212 | 642,140 |
| | Salt de l'Aigua - Manises | 0,063 | 0,973 | 1,798 | 0,315 | 662,677 |
| | Manises - Rosas | 0,030 | 1,002 | 1,168 | 0,317 | 483,138 |
| | Rosas - Aeroport | 0,042 | 0,946 | 1,041 | 0,435 | 655,340 |
| L5/L7 | Alameda - Aragón | 0,028 | 1,162 | 2,656 | 0,411 | 597,329 |
| | Aragón - Amistad | 0,088 | 0,929 | 1,045 | 0,457 | 508,874 |
| | Amistad - Ayora | 0,023 | 1,209 | 2,890 | 0,315 | 611,665 |
| | Ayora - Marítim Serrería | 0,038 | 1,191 | 1,708 | 0,278 | 433,655 |
| | Marítim Serrería - Ayora | 0,035 | 1,156 | 2,221 | 0,270 | 464,447 |
| | Ayora - Amistat | 0,041 | 1,006 | 1,985 | 0,275 | 616,848 |
| | Amistat - Aragón | 0,036 | 1,173 | 3,659 | 0,310 | 528,524 |
| | Aragón - Alameda | 0,038 | 1,135 | 0,937 | 0,424 | 541,886 |

| MOPSO | | | | | | |
|----------|---------------------------------|-------|-------|-------|-------|----------|
| Línea | Tramo | GD | SPR | SP | NH | Tiempo |
| L1/L2/L7 | València Sud - Sant Isidre | 0,073 | 0,733 | 4,869 | 0,282 | 1090,295 |
| | Sant Isidre - Safranar | 0,092 | 0,973 | 4,354 | 0,269 | 691,434 |
| | Safranar - Patraix | 0,108 | 0,739 | 1,988 | 0,323 | 747,390 |
| | Patraix - Jesús | 0,074 | 0,832 | 2,536 | 0,245 | 649,455 |
| | Jesús - Pl. Espanya | 0,065 | 0,705 | 0,986 | 0,299 | 926,391 |
| | Pl. Espanya - Àngel Guimerà | 0,061 | 0,601 | 0,923 | 0,330 | 619,231 |
| | Àngel Guimerà - Túria | 0,104 | 0,911 | 4,610 | 0,204 | 944,363 |
| | Túria - Campanar | 0,053 | 0,760 | 2,460 | 0,240 | 827,162 |
| | Campanar - Beniferri | 0,048 | 0,764 | 2,683 | 0,274 | 1029,948 |
| | Beniferri - Empalme | 0,071 | 0,527 | 1,411 | 0,390 | 1113,411 |
| L1/L2/L7 | València Sud - Sant Isidre | 0,210 | 1,069 | 7,349 | 0,282 | 817,163 |
| | Beniferri - Campanar | 0,073 | 0,622 | 1,078 | 0,340 | 932,139 |
| | Campanar - Túria | 0,099 | 0,683 | 1,683 | 0,289 | 598,553 |
| | Túria - Àngel Guimerà | 0,082 | 1,022 | 5,711 | 0,227 | 956,335 |
| | Àngel Guimerà - Pl. Espanya | 0,089 | 0,702 | 1,176 | 0,326 | 520,901 |
| | Pl. Espanya - Jesús | 0,150 | 0,949 | 2,769 | 0,334 | 756,706 |
| | Jesús - Patraix | 0,057 | 0,986 | 3,182 | 0,234 | 668,927 |
| | Patraix - Safranar | 0,079 | 0,837 | 3,224 | 0,287 | 689,791 |
| | Safranar - Sant Isidre | 0,083 | 0,680 | 1,273 | 0,301 | 739,945 |
| | Sant Isidre - València Sud | 0,240 | 0,845 | 5,493 | 0,188 | 969,002 |
| L3/L5 | Aeroport-Rosas | 0,053 | 0,802 | 0,850 | 0,343 | 841,492 |
| | Rosas-Manises | 0,027 | 0,645 | 1,162 | 0,316 | 601,532 |
| | Manises-Salt de l'Aigua | 0,040 | 1,000 | 3,858 | 0,341 | 780,862 |
| | Salt de l'Aigua-Quart de Poblet | 0,033 | 0,690 | 2,287 | 0,232 | 859,171 |
| | Quart de Poblet-Faitanar | 0,129 | 0,854 | 3,522 | 0,141 | 667,928 |
| | Faitanar-Mislata Almassil | 0,108 | 0,713 | 2,094 | 0,326 | 799,747 |
| | Mislata Almassil-Mislata | 0,042 | 0,747 | 1,353 | 0,271 | 555,111 |
| | Mislata - Nou d'Octubre | 0,049 | 0,797 | 2,467 | 0,225 | 789,856 |
| | Nou d'Octubre - Av. Del Cid | 0,223 | 1,012 | 3,622 | 0,203 | 675,422 |
| | Av. Del Cid- Àngel Guimerà | 0,663 | 0,847 | 4,855 | 0,368 | 857,254 |
| | Àngel Guimerà - Xàtiva | 0,092 | 1,017 | 5,534 | 0,298 | 753,986 |
| | Xàtiva - Colón | 0,032 | 1,094 | 3,434 | 0,385 | 707,285 |
| | Colón - Alameda | 0,043 | 0,709 | 0,652 | 0,238 | 600,857 |

| | | | | | | |
|------------------|---|-------|-------|-------|---------|----------|
| | Alameda - Facultats | 0,030 | 0,662 | 0,792 | 0,435 | 705,530 |
| | Facultats - Benimaclet | 0,041 | 0,766 | 2,198 | 0,410 | 917,342 |
| | Benimaclet - Machado | 0,062 | 0,782 | 2,239 | 0,233 | 832,181 |
| | Machado - Alboraya Palmaret | 0,029 | 0,606 | 0,365 | 0,536 | 617,532 |
| | Alboraya Palmaret - Alboraya Peris Aragón | 0,063 | 0,738 | 0,860 | 0,340 | 937,615 |
| L3/L5 | Alboraya Peris Aragón - Alboraya Palmaret | 0,036 | 0,758 | 2,054 | 0,266 | 964,429 |
| | Alboraya Palmaret - Machado | 0,039 | 0,786 | 0,539 | 0,416 | 767,071 |
| | Machado - Benimaclet | 0,028 | 0,737 | 2,119 | 0,200 | 848,208 |
| | Benimaclet - Facultats | 0,038 | 0,635 | 0,794 | 0,266 | 1025,705 |
| | Facultats - Alameda | 0,029 | 0,759 | 1,595 | 0,338 | 712,704 |
| | Alameda - Colón | 0,040 | 0,711 | 1,201 | 0,500 | 599,850 |
| | Colón - Xàtiva | 0,058 | 0,759 | 1,220 | 0,315 | 782,477 |
| | Xàtiva - Àngel Guimerà | 0,095 | 0,659 | 2,245 | 0,426 | 810,470 |
| | Àngel Guimerà - Av. Del Cid | 0,067 | 0,506 | 1,209 | 0,364 | 1188,476 |
| | Av. Del Cid - Nou d'Octubre | 0,049 | 0,971 | 3,198 | 0,232 | 844,569 |
| | Nou d'Octubre - Mislata | 0,060 | 0,832 | 3,455 | 0,213 | 930,762 |
| | Mislata - Mislata Almassil | 0,047 | 1,471 | 5,833 | 0,474 | 616,153 |
| | Mislata Almassil - Faitanar | 0,064 | 0,772 | 1,642 | 0,264 | 928,942 |
| | Faitanar - Quart de Poblet | 0,101 | 0,860 | 3,860 | 0,234 | 927,173 |
| | Quart de Poblet - Salt de l'Aigua | 0,038 | 0,731 | 2,168 | 0,186 | 974,779 |
| | Salt de l'Aigua - Manises | 0,106 | 0,720 | 1,314 | 0,307 | 959,359 |
| | Manises - Rosas | 0,048 | 0,595 | 1,094 | 0,199 | 744,200 |
| Rosas - Aeroport | 0,052 | 0,664 | 0,535 | 0,419 | 992,072 | |
| L5/L7 | Alameda - Aragón | 0,036 | 0,875 | 2,536 | 0,379 | 803,330 |
| | Aragón - Amistad | 0,056 | 0,642 | 1,124 | 0,409 | 719,091 |
| | Amistad - Ayora | 0,043 | 0,762 | 1,570 | 0,248 | 852,677 |
| | Ayora - Marítim Serrería | 0,032 | 0,959 | 1,530 | 0,262 | 629,293 |
| | Marítim Serrería - Ayora | 0,026 | 1,022 | 2,184 | 0,228 | 589,963 |
| | Ayora - Amistat | 0,055 | 0,611 | 1,299 | 0,235 | 907,272 |
| | Amistat - Aragón | 0,095 | 0,855 | 3,353 | 0,279 | 816,552 |
| | Aragón - Alameda | 0,041 | 0,661 | 0,395 | 0,356 | 872,305 |

| SPEA-II | | | | | | |
|-----------------|-----------------------------|-------|-------|-------|---------|----------|
| Línea | Tramo | GD | SPR | SP | NH | Tiempo |
| L1/L2/L7 | València Sud - Sant Isidre | 0,090 | 1,166 | 5,343 | 0,373 | 1093,310 |
| | Sant Isidre - Safranar | 0,082 | 1,029 | 4,748 | 0,305 | 636,503 |
| | Safranar - Patraix | 0,071 | 1,163 | 4,219 | 0,325 | 684,170 |
| | Patraix - Jesús | 0,038 | 1,072 | 3,262 | 0,390 | 613,289 |
| | Jesús - Pl. Espanya | 0,062 | 0,890 | 1,262 | 0,324 | 798,053 |
| | Pl. Espanya - Àngel Guimerà | 0,050 | 0,767 | 1,169 | 0,348 | 504,487 |
| | Àngel Guimerà - Túria | 0,129 | 1,130 | 4,431 | 0,252 | 859,425 |
| | Túria - Campanar | 0,163 | 1,031 | 3,500 | 0,426 | 698,056 |
| | Campanar - Beniferri | 0,042 | 0,836 | 2,023 | 0,368 | 861,594 |
| | Beniferri - Empalme | 0,114 | 0,872 | 2,457 | 0,433 | 949,473 |
| L1/L2/L7 | València Sud - Sant Isidre | 0,093 | 1,097 | 8,562 | 0,252 | 791,997 |
| | Beniferri - Campanar | 0,042 | 0,835 | 1,410 | 0,405 | 869,847 |
| | Campanar - Túria | 0,078 | 0,879 | 1,977 | 0,310 | 605,822 |
| | Túria - Àngel Guimerà | 0,061 | 1,125 | 5,063 | 0,290 | 945,485 |
| | Àngel Guimerà - Pl. Espanya | 0,041 | 1,082 | 1,822 | 0,355 | 520,293 |
| | Pl. Espanya - Jesús | 0,041 | 0,935 | 1,828 | 0,401 | 720,839 |
| Jesús - Patraix | 0,031 | 1,281 | 3,243 | 0,263 | 614,181 | |

| | | | | | | |
|--|--|-------|-------|-------|---------|----------|
| | Patraix - Safranar | 0,083 | 0,915 | 3,469 | 0,289 | 647,040 |
| | Safranar - Sant Isidre | 0,059 | 0,953 | 1,707 | 0,339 | 637,431 |
| | Sant Isidre - València Sud | 0,058 | 1,210 | 6,405 | 0,342 | 1068,102 |
| I3/L5 | Aeroport-Rosas | 0,040 | 0,823 | 0,630 | 0,365 | 811,921 |
| | Rosas-Manises | 0,031 | 0,800 | 1,311 | 0,361 | 542,802 |
| | Manises-Salt de l'Aigua | 0,132 | 0,985 | 3,498 | 0,363 | 788,295 |
| | Salt de l'Aigua-Quart de Poblet | 0,037 | 1,039 | 2,684 | 0,291 | 802,957 |
| | Quart de Poblet-Faitanar | 0,283 | 0,750 | 2,208 | 0,140 | 611,615 |
| | Faitanar-Mislata Almassil | 0,039 | 1,113 | 2,840 | 0,397 | 751,558 |
| | Mislata Almassil-Mislata | 0,028 | 1,017 | 1,672 | 0,303 | 508,905 |
| | Mislata - Nou d'Octubre | 0,032 | 1,137 | 3,038 | 0,414 | 736,810 |
| | Nou d'Octubre - Av. Del Cid | 0,033 | 1,284 | 5,416 | 0,216 | 672,261 |
| | Av. Del Cid- Àngel Guimerà | 0,074 | 1,091 | 7,506 | 0,378 | 756,531 |
| | Àngel Guimerà - Xàtiva | 0,095 | 1,064 | 5,270 | 0,349 | 682,742 |
| | Xàtiva - Colón | 0,038 | 1,323 | 5,722 | 0,413 | 644,625 |
| | Colón - Alameda | 0,027 | 0,709 | 0,479 | 0,266 | 556,609 |
| | Alameda - Facultats | 0,021 | 0,882 | 0,994 | 0,429 | 638,820 |
| | Facultats - Benimaclet | 0,037 | 0,956 | 2,440 | 0,417 | 847,494 |
| | Benimaclet - Machado | 0,032 | 0,732 | 1,509 | 0,289 | 683,896 |
| | Machado - Alboraya Palmaret | 0,025 | 0,703 | 0,603 | 0,500 | 546,085 |
| Alboraya Palmaret - Alboraya Peris Aragó | 0,044 | 1,096 | 1,334 | 0,395 | 839,528 | |
| I3/L5 | Alboraya Peris Aragó - Alboraya Palmaret | 0,052 | 0,784 | 1,978 | 0,277 | 719,887 |
| | Alboraya Palmaret - Machado | 0,045 | 0,635 | 0,310 | 0,391 | 603,874 |
| | Machado - Benimaclet | 0,033 | 0,864 | 2,323 | 0,282 | 785,392 |
| | Benimaclet - Facultats | 0,027 | 0,901 | 1,201 | 0,276 | 820,395 |
| | Facultats - Alameda | 0,024 | 0,911 | 1,544 | 0,352 | 609,007 |
| | Alameda - Colón | 0,037 | 0,876 | 1,537 | 0,499 | 507,864 |
| | Colón - Xàtiva | 0,038 | 0,975 | 1,818 | 0,320 | 738,666 |
| | Xàtiva - Àngel Guimerà | 0,069 | 0,899 | 2,656 | 0,440 | 746,038 |
| | Àngel Guimerà - Av. Del Cid | 0,038 | 0,830 | 2,040 | 0,370 | 1005,551 |
| | Av. Del Cid - Nou d'Octubre | 0,052 | 1,353 | 4,474 | 0,285 | 768,149 |
| | Nou d'Octubre - Mislata | 0,208 | 0,871 | 2,969 | 0,229 | 854,535 |
| | Mislata - Mislata Almassil | 0,026 | 1,029 | 1,260 | 0,683 | 533,543 |
| | Mislata Almassil - Faitanar | 0,049 | 0,884 | 2,032 | 0,296 | 795,165 |
| | Faitanar - Quart de Poblet | 0,062 | 1,025 | 4,009 | 0,227 | 793,152 |
| | Quart de Poblet - Salt de l'Aigua | 0,033 | 1,012 | 3,628 | 0,251 | 867,833 |
| | Salt de l'Aigua - Manises | 0,070 | 0,844 | 1,575 | 0,299 | 872,053 |
| | Manises - Rosas | 0,033 | 0,920 | 1,131 | 0,267 | 685,703 |
| Rosas - Aeroport | 0,036 | 0,837 | 0,778 | 0,401 | 881,880 | |
| L5/L7 | Alameda - Aragón | 0,028 | 0,894 | 2,340 | 0,388 | 764,582 |
| | Aragón - Amistad | 0,076 | 0,992 | 1,299 | 0,480 | 644,178 |
| | Amistad - Ayora | 0,028 | 1,194 | 4,901 | 0,285 | 818,828 |
| | Ayora - Marítim Serrería | 0,031 | 1,112 | 1,584 | 0,274 | 597,419 |
| | Marítim Serrería - Ayora | 0,034 | 1,147 | 2,189 | 0,259 | 599,842 |
| | Ayora - Amistat | 0,044 | 0,940 | 2,061 | 0,247 | 842,226 |
| | Amistat - Aragón | 0,041 | 1,098 | 2,857 | 0,307 | 724,537 |
| | Aragón - Alameda | 0,024 | 0,667 | 0,428 | 0,334 | 717,683 |

| MOEA-D | | | | | | |
|--|--|-------|-------|--------|---------|----------|
| Línea | Tramo | GD | SPR | SP | NH | Tiempo |
| L1/L2/L7 | València Sud - Sant Isidre | 0,105 | 1,098 | 7,027 | 0,290 | 961,430 |
| | Sant Isidre - Safranar | 0,203 | 1,243 | 3,828 | 0,318 | 654,441 |
| | Safranar - Patraix | 0,093 | 1,121 | 2,189 | 0,338 | 591,547 |
| | Patraix - Jesús | 0,059 | 1,239 | 3,316 | 0,249 | 614,312 |
| | Jesús - Pl. Espanya | 0,134 | 1,071 | 1,702 | 0,325 | 818,340 |
| | Pl. Espanya - Àngel Guimerà | 0,048 | 1,117 | 1,559 | 0,344 | 510,964 |
| | Àngel Guimerà - Túria | 0,159 | 1,109 | 3,216 | 0,216 | 912,278 |
| | Túria - Campanar | 0,061 | 1,069 | 2,234 | 0,256 | 660,576 |
| | Campanar - Beniferri | 0,034 | 1,045 | 3,124 | 0,279 | 791,745 |
| | Beniferri - Empalme | 0,118 | 1,207 | 3,447 | 0,414 | 900,708 |
| L1/L2/L7 | València Sud - Sant Isidre | 0,038 | 1,379 | 10,977 | 0,271 | 777,780 |
| | Beniferri - Campanar | 0,031 | 1,113 | 1,906 | 0,342 | 821,309 |
| | Campanar - Túria | 0,051 | 1,127 | 2,246 | 0,297 | 612,144 |
| | Túria - Àngel Guimerà | 0,062 | 0,986 | 2,171 | 0,230 | 850,495 |
| | Àngel Guimerà - Pl. Espanya | 0,148 | 0,949 | 1,578 | 0,341 | 508,239 |
| | Pl. Espanya - Jesús | 0,097 | 1,121 | 2,425 | 0,334 | 687,627 |
| | Jesús - Patraix | 0,029 | 1,127 | 1,272 | 0,253 | 662,284 |
| | Patraix - Safranar | 0,064 | 1,031 | 1,560 | 0,287 | 651,016 |
| | Safranar - Sant Isidre | 0,114 | 1,144 | 2,063 | 0,307 | 645,249 |
| | Sant Isidre - València Sud | 0,070 | 0,999 | 3,171 | 0,186 | 905,994 |
| L3/L5 | Aeroport-Rosas | 0,066 | 1,301 | 1,214 | 0,361 | 929,076 |
| | Rosas-Manises | 0,027 | 1,033 | 1,786 | 0,338 | 581,736 |
| | Manises-Salt de l'Aigua | 0,153 | 1,308 | 4,263 | 0,371 | 883,104 |
| | Salt de l'Aigua-Quart de Poblet | 0,024 | 1,206 | 3,419 | 0,259 | 862,023 |
| | Quart de Poblet-Faitanar | 0,090 | 1,266 | 4,554 | 0,150 | 701,250 |
| | Faitanar-Mislata Almassil | 0,022 | 1,287 | 4,348 | 0,368 | 825,354 |
| | Mislata Almassil-Mislata | 0,054 | 1,188 | 2,724 | 0,291 | 589,135 |
| | Mislata - Nou d'Octubre | 0,032 | 1,140 | 4,639 | 0,237 | 736,357 |
| | Nou d'Octubre - Av. Del Cid | 0,150 | 1,025 | 1,221 | 0,209 | 709,566 |
| | Av. Del Cid - Àngel Guimerà | 0,806 | 1,297 | 6,768 | 0,398 | 815,138 |
| | Àngel Guimerà - Xàtiva | 0,062 | 1,078 | 0,812 | 0,330 | 728,434 |
| | Xàtiva - Colón | 0,039 | 1,378 | 4,334 | 0,406 | 683,095 |
| | Colón - Alameda | 0,024 | 1,301 | 1,839 | 0,263 | 571,560 |
| | Alameda - Facultats | 0,062 | 1,292 | 1,625 | 0,471 | 647,418 |
| | Facultats - Benimaclet | 0,028 | 1,278 | 4,664 | 0,446 | 849,309 |
| Benimaclet - Machado | 0,066 | 1,045 | 3,613 | 0,236 | 716,970 | |
| Machado - Alboraya Palmaret | 0,026 | 1,274 | 0,807 | 0,500 | 655,273 | |
| Alboraya Palmaret - Alboraya Peris Aragó | 0,035 | 1,032 | 1,071 | 0,370 | 938,927 | |
| L3/L5 | Alboraya Peris Aragó - Alboraya Palmaret | 0,028 | 1,135 | 1,689 | 0,301 | 764,355 |
| | Alboraya Palmaret - Machado | 0,028 | 1,312 | 0,902 | 0,473 | 643,141 |
| | Machado - Benimaclet | 0,042 | 0,983 | 1,759 | 0,215 | 686,166 |
| | Benimaclet - Facultats | 0,049 | 1,150 | 2,220 | 0,299 | 846,006 |
| | Facultats - Alameda | 0,024 | 1,097 | 2,609 | 0,377 | 638,257 |
| | Alameda - Colón | 0,097 | 1,217 | 1,401 | 0,604 | 546,407 |
| | Colón - Xàtiva | 0,047 | 1,245 | 2,070 | 0,346 | 637,633 |
| | Xàtiva - Àngel Guimerà | 0,089 | 1,136 | 3,612 | 0,449 | 754,897 |
| | Àngel Guimerà - Av. Del Cid | 0,135 | 1,076 | 3,494 | 0,388 | 1029,710 |
| | Av. Del Cid - Nou d'Octubre | 0,073 | 1,052 | 1,028 | 0,259 | 783,887 |
| | Nou d'Octubre - Mislata | 0,037 | 1,000 | 2,331 | 0,216 | 833,825 |
| | Mislata - Mislata Almassil | 0,105 | 1,495 | 5,137 | 0,498 | 556,721 |

| | | | | | | |
|-------|-----------------------------------|-------|-------|-------|-------|---------|
| | Mislata Almassil - Faitanar | 0,093 | 1,002 | 1,442 | 0,316 | 792,180 |
| | Faitanar - Quart de Poblet | 0,113 | 1,090 | 2,685 | 0,238 | 757,342 |
| | Quart de Poblet - Salt de l'Aigua | 0,047 | 1,066 | 3,799 | 0,195 | 788,963 |
| | Salt de l'Aigua - Manises | 0,049 | 1,135 | 2,378 | 0,333 | 897,131 |
| | Manises - Rosas | 0,074 | 1,035 | 2,101 | 0,225 | 626,947 |
| | Rosas - Aeroport | 0,047 | 1,166 | 1,348 | 0,447 | 939,136 |
| L5/L7 | Alameda - Aragón | 0,026 | 1,267 | 2,063 | 0,426 | 732,027 |
| | Aragón - Amistad | 0,078 | 1,230 | 1,784 | 0,441 | 655,645 |
| | Amistad - Ayora | 0,022 | 1,000 | 0,933 | 0,269 | 842,132 |
| | Ayora - Marítim Serrería | 0,028 | 1,300 | 1,944 | 0,284 | 551,125 |
| | Marítim Serrería - Ayora | 0,026 | 1,156 | 0,860 | 0,249 | 543,590 |
| | Ayora - Amistat | 0,064 | 1,067 | 2,385 | 0,267 | 844,519 |
| | Amistat - Aragón | 0,114 | 1,149 | 1,783 | 0,305 | 685,395 |
| | Aragón - Alameda | 0,017 | 1,231 | 0,861 | 0,357 | 742,060 |

| MOACOr | | | | | | |
|--------------------|---------------------------------|-------|-------|-------|---------|----------|
| Línea | Tramo | GD | SPR | SP | NH | Tiempo |
| L1/L2/L7 | València Sud - Sant Isidre | 0,086 | 1,186 | 8,727 | 0,331 | 1182,921 |
| | Sant Isidre - Safranar | 0,075 | 1,153 | 4,259 | 0,290 | 690,388 |
| | Safranar - Patraix | 0,101 | 0,956 | 2,424 | 0,319 | 660,049 |
| | Patraix - Jesús | 0,045 | 1,173 | 3,245 | 0,261 | 628,460 |
| | Jesús - Pl. Espanya | 0,142 | 0,803 | 1,184 | 0,319 | 795,298 |
| | Pl. Espanya - Àngel Guimerà | 0,057 | 0,856 | 1,303 | 0,345 | 527,942 |
| | Àngel Guimerà - Túria | 0,125 | 1,185 | 5,270 | 0,245 | 879,557 |
| | Túria - Campanar | 0,032 | 1,085 | 2,784 | 0,247 | 705,767 |
| | Campanar - Beniferri | 0,095 | 0,917 | 3,298 | 0,283 | 853,839 |
| | Beniferri - Empalme | 0,237 | 0,894 | 2,501 | 0,423 | 1066,907 |
| L1/L2/L7 | València Sud - Sant Isidre | 0,073 | 1,279 | 8,889 | 0,264 | 780,395 |
| | Beniferri - Campanar | 0,027 | 0,867 | 1,693 | 0,338 | 870,797 |
| | Campanar - Túria | 0,055 | 0,793 | 1,527 | 0,304 | 598,768 |
| | Túria - Àngel Guimerà | 0,038 | 1,223 | 6,506 | 0,253 | 952,201 |
| | Àngel Guimerà - Pl. Espanya | 0,047 | 1,267 | 2,255 | 0,440 | 551,369 |
| | Pl. Espanya - Jesús | 0,036 | 1,311 | 4,491 | 0,364 | 742,687 |
| | Jesús - Patraix | 0,033 | 1,323 | 3,229 | 0,248 | 646,773 |
| | Patraix - Safranar | 0,072 | 1,073 | 3,459 | 0,284 | 739,194 |
| | Safranar - Sant Isidre | 0,102 | 0,782 | 1,364 | 0,289 | 745,166 |
| | Sant Isidre - València Sud | 0,128 | 1,230 | 8,630 | 0,224 | 1142,881 |
| L3/L5 | Aeroport-Rosas | 0,038 | 0,834 | 1,000 | 0,332 | 844,332 |
| | Rosas-Manises | 0,031 | 0,640 | 1,392 | 0,326 | 563,583 |
| | Manises-Salt de l'Aigua | 0,034 | 1,261 | 5,347 | 0,361 | 796,374 |
| | Salt de l'Aigua-Quart de Poblet | 0,028 | 1,166 | 5,661 | 0,255 | 822,659 |
| | Quart de Poblet-Faitanar | 0,031 | 1,020 | 3,764 | 0,133 | 629,039 |
| | Faitanar-Mislata Almassil | 0,027 | 1,101 | 3,641 | 0,337 | 767,720 |
| | Mislata Almassil-Mislata | 0,026 | 0,928 | 1,807 | 0,277 | 541,353 |
| | Mislata - Nou d'Octubre | 0,037 | 0,948 | 3,578 | 0,229 | 729,759 |
| | Nou d'Octubre - Av. Del Cid | 0,040 | 1,371 | 6,856 | 0,207 | 709,575 |
| | Av. Del Cid- Àngel Guimerà | 0,544 | 0,901 | 5,752 | 0,377 | 827,166 |
| | Àngel Guimerà - Xàtiva | 0,069 | 1,139 | 5,576 | 0,300 | 719,228 |
| | Xàtiva - Colón | 0,034 | 1,253 | 5,301 | 0,398 | 654,093 |
| | Colón - Alameda | 0,036 | 0,866 | 0,830 | 0,242 | 588,697 |
| Alameda - Facultat | 0,036 | 0,990 | 1,150 | 0,462 | 686,789 | |

| | | | | | | |
|------------------|---|-------|-------|-------|---------|---------|
| | Facultats - Benimaclet | 0,037 | 1,073 | 3,005 | 0,421 | 888,708 |
| | Benimaclet - Machado | 0,030 | 0,895 | 2,705 | 0,229 | 721,739 |
| | Machado - Alboraya Palmaret | 0,026 | 0,761 | 0,485 | 0,447 | 575,380 |
| | Alboraya Palmaret - Alboraya Peris Aragón | 0,056 | 0,961 | 1,043 | 0,364 | 879,370 |
| L3/L5 | Alboraya Peris Aragón - Alboraya Palmaret | 0,044 | 0,644 | 1,116 | 0,284 | 810,852 |
| | Alboraya Palmaret - Machado | 0,030 | 0,838 | 0,441 | 0,388 | 653,649 |
| | Machado - Benimaclet | 0,041 | 0,802 | 3,318 | 0,211 | 735,673 |
| | Benimaclet - Facultats | 0,042 | 0,637 | 0,916 | 0,269 | 885,012 |
| | Facultats - Alameda | 0,020 | 1,218 | 3,130 | 0,368 | 653,510 |
| | Alameda - Colón | 0,033 | 0,941 | 1,807 | 0,507 | 540,521 |
| | Colón - Xàtiva | 0,096 | 0,975 | 2,496 | 0,329 | 699,558 |
| | Xàtiva - Àngel Guimerà | 0,056 | 1,292 | 4,155 | 0,473 | 807,945 |
| | Àngel Guimerà - Av. Del Cid | 0,127 | 0,690 | 1,896 | 0,371 | 952,057 |
| | Av. Del Cid - Nou d'Octubre | 0,073 | 1,108 | 3,461 | 0,239 | 768,829 |
| | Nou d'Octubre - Mislata | 0,036 | 1,075 | 3,801 | 0,242 | 829,570 |
| | Mislata - Mislata Almassil | 0,214 | 1,064 | 1,606 | 0,651 | 578,343 |
| | Mislata Almassil - Faitanar | 0,097 | 0,630 | 1,177 | 0,287 | 881,687 |
| | Faitanar - Quart de Poblet | 0,063 | 1,036 | 4,056 | 0,230 | 854,013 |
| | Quart de Poblet - Salt de l'Aigua | 0,029 | 1,171 | 4,202 | 0,193 | 931,376 |
| | Salt de l'Aigua - Manises | 0,071 | 0,756 | 1,436 | 0,286 | 927,964 |
| | Manises - Rosas | 0,076 | 0,805 | 1,633 | 0,207 | 710,237 |
| Rosas - Aeroport | 0,026 | 0,940 | 0,905 | 0,400 | 932,038 | |
| L5/L7 | Alameda - Aragón | 0,036 | 1,303 | 3,001 | 0,426 | 743,489 |
| | Aragón - Amistad | 0,108 | 1,066 | 1,295 | 0,474 | 641,366 |
| | Amistad - Ayora | 0,029 | 1,026 | 2,249 | 0,270 | 821,056 |
| | Ayora - Marítim Serrería | 0,034 | 1,318 | 1,865 | 0,325 | 570,528 |
| | Marítim Serrería - Ayora | 0,025 | 1,364 | 2,548 | 0,344 | 601,866 |
| | Ayora - Amistat | 0,048 | 0,801 | 1,591 | 0,239 | 880,655 |
| | Amistat - Aragón | 0,087 | 1,142 | 3,619 | 0,306 | 749,973 |
| | Aragón - Alameda | 0,830 | 1,209 | 4,965 | 0,327 | 775,345 |