

La investigación reportada en esta tesis es parte de los programas de investigación del CICESE (Centro de Investigación Científica y de Educación Superior de Ensenada, B.C.).

La investigación fue financiada por el CONAHCYT (Consejo Nacional de Humanidades, Ciencias y Tecnologías).

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México). El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo o titular de los Derechos Autor.

CICESE © 2023, Todos los Derechos Reservados, CICESE

Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California



Maestría en Ciencias en Ciencias de la computación

Problema de enrutamiento de vehículos con enfoque verde y flota mixta

Tesis

para cubrir parcialmente los requisitos necesarios para obtener el grado de
Maestro en Ciencias

Presenta:

Héctor Jahir Sandoval Chávez

Ensenada, Baja California, México

2023

Tesis defendida por

Héctor Jahir Sandoval Chávez

y aprobada por el siguiente Comité

Dr. Carlos Alberto Brizuela Rodríguez
Director de tesis

Dr. César Raúl García Jacas

Dra. Ivett Zavala Guillén



Dr. Pedro Gilberto López Mariscal
Coordinador del Posgrado en Ciencias de la computación

Dra. Ana Denise Re Araujo
Directora de Estudios de Posgrado

Resumen de la tesis que presenta Héctor Jahir Sandoval Chávez como requisito parcial para la obtención del grado de Maestro en Ciencias en Ciencias de la computación.

Problema de enrutamiento de vehículos con enfoque verde y flota mixta

Resumen aprobado por:

Dr. Carlos Alberto Brizuela Rodríguez

Director de tesis

El transporte de mercancía generó el 37 % de la emisión global de CO₂ en 2021, del cual el 76 % correspondió a vehículos terrestres. Uno de los esfuerzos para contrarrestar esta situación es la integración de vehículos eléctricos en tareas de distribución. Sin embargo, las restricciones asociadas a la batería de estos vehículos afectan su rápida adopción. El problema de enrutamiento de vehículos (VRP) está directamente relacionado con el transporte de mercancía. Éste consiste en definir las rutas para una flota de vehículos que parten de una central y deben visitar un conjunto de clientes para entregar mercancías. Recientemente, el VRP ha incorporado vehículos eléctricos en su formulación con sus variantes con flota eléctrica o flota mixta (vehículos convencionales y eléctricos). En este proyecto se propone analizar el impacto que tiene incluir vehículos eléctricos en tareas de distribución al comparar su desempeño con una flota de vehículos convencionales. Para ello, se resolvió el VRP con ventanas de tiempo con un enfoque multiobjetivo, minimizando simultáneamente distancia y tiempo de espera. Se utilizó el algoritmo NSGA-2 y se diseñaron cinco algoritmos para la construcción de rutas, uno para flota convencional y cuatro para flota mixta. De los frentes no dominados obtenidos, se realizó una comparación entre la flota convencional y la flota mixta para determinar la diferencia de calidad entre ambos tipos de flota. Se encontró que una flota mixta aumenta en promedio de 2.94 % a 44.92 % la distancia, mientras que el tiempo de espera se ve reducido en la mayoría de los casos. Posteriormente, se comparó el desempeño de cada flota mixta, encontrando mejores resultados al emplear una flota equilibrada. Además, se calculó la emisión total de CO₂ de las soluciones con menor distancia de cada frente, considerando emisiones directas de vehículos convencionales y emisiones indirectas de vehículos eléctricos, basadas en recarga y consumo de energía. Esto permitió determinar la reducción de emisiones al considerar una flota mixta, encontrando una disminución promedio entre 0.58 % y 16.14 %, al compararlo con la emisión de una flota convencional. También, se encontraron casos donde la inclusión de vehículos eléctricos provocó un aumento en emisiones, debido a una mayor emisión de vehículos convencionales.

Palabras clave: problema de enrutamiento de vehículos, ventanas de tiempo, flota mixta, vehículos eléctricos, optimización multiobjetivo, emisiones de dióxido de carbono

Abstract of the thesis presented by Héctor Jahir Sandoval Chávez as a partial requirement to obtain the Master of Science degree in Computer science.

Vehicle routing problem with green approach and mixed fleet

Abstract approved by:

Dr. Carlos Alberto Brizuela Rodríguez
Thesis Director

The transportation of goods accounted for 37 % of global CO₂ emissions in 2021, of which 76 % corresponded to land vehicles. One of the efforts to counteract this situation is the integration of electric vehicles in distribution tasks. However, the restrictions associated with the battery of these vehicles affect their rapid adoption. The vehicle routing problem (VRP) is directly related to transportation of goods. This problem consists of defining routes for a fleet of vehicles that depart from a depot and must visit a set of customers to deliver goods. Recently, the VRP has incorporated electric vehicles in its formulation with the electric fleet or mixed fleet (conventional and electric vehicles) variants. This project proposes to analyze the impact of including electric vehicles in distribution tasks by comparing their performance with a fleet of conventional vehicles. To this aim, the VRP with time windows was solved with a multi-objective approach, simultaneously minimizing distance and waiting time. The NSGA-2 algorithm was used and five route construction algorithms were designed, one for conventional fleet and four for mixed fleet. From the non-dominated fronts obtained, a comparison was made between the conventional fleet and the mixed fleet to determine the difference in quality between both fleet types. It was found that a mixed fleet gets an average increase in distance from 2.94 % to 44.92 %, while the waiting time is reduced in most cases. Then, the performance of each mixed fleet was compared, finding better results when using a balanced fleet. In addition, the total CO₂ emission of the solutions with the shortest distance from each front was calculated, considering direct emissions from conventional vehicles and indirect emissions from electric vehicles, based on energy recharging and consumption. This allowed to determine the reduction of emissions when considering a mixed fleet, finding an average decrease between 0.58 % and 16.14 %, when compared to the emission of a conventional fleet. Also, cases were found where the inclusion of electric vehicles caused an increase in emissions, due to a higher emission from conventional vehicles.

Keywords: vehicle routing problem, time windows, mixed fleet, electric vehicles, multiobjective optimization, carbon emissions

Dedicatoria

A mamá y papá.

Agradecimientos

Al Centro de Investigación Científica y de Educación Superior de Ensenada, Baja California por brindarme la oportunidad y los medios para concluir este proyecto de maestría.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por brindarme el apoyo económico para realizar mis estudios de maestría, por medio de la beca No. 1061774.

Al Dr. Carlos Brizuela, por su apoyo, orientación y paciencia durante todas las etapas del proyecto, desde las primeras reuniones hasta la redacción de este documento.

A la Dra. Ivett Zavala, por sus comentarios y retroalimentación en el aspecto ambiental del proyecto, los cuales motivaron el desarrollo del capítulo de análisis de emisiones de CO₂.

Al Dr. César García, por sus observaciones y consejos en el aspecto técnico del proyecto, los cuales fueron de gran ayuda para la realización de los experimentos.

A mis padres y hermano, por su constante apoyo y motivación para concluir esta importante meta en mi vida. También a mis amigos, por acompañarme en los momentos más complicados de este proyecto.

Tabla de contenido

	Página
Resumen en español	ii
Resumen en inglés	iii
Dedicatoria	iv
Agradecimientos	v
Lista de figuras	viii
Lista de tablas	ix
Capítulo 1. Introducción	
1.1. Antecedentes y justificación	2
1.2. Definición del problema	4
1.3. Objetivos	6
1.3.1. Objetivo general	6
1.3.2. Objetivos específicos	6
1.4. Organización de la tesis	7
Capítulo 2. Marco Teórico	
2.1. Problema de enrutamiento de vehículos	8
2.1.1. VRP con ventanas de tiempo (VRP-TW)	9
2.1.2. VRP con flota mixta (VRP-MF)	9
2.2. Funciones objetivo	10
2.2.1. Distancia recorrida	11
2.2.2. Tiempo de espera	11
2.3. Emisiones de CO ₂	12
2.3.1. Emisiones directas	13
2.3.2. Emisiones indirectas	15
2.4. Optimización Multiobjetivo	16
2.4.1. Dominancia y frente de Pareto	18
2.4.2. Cobertura de soluciones	20
2.5. Algoritmos evolutivos multiobjetivo	21
2.5.1. NSGA-II	22
2.5.2. MOEA/D	25
Capítulo 3. Metodología	
3.1. Casos de prueba	27
3.2. Clasificación de nodos	28
3.2.1. Nodos alcanzables	29
3.2.2. Nodos inalcanzables	29
3.2.3. Nodos alcanzables e inalcanzables desde la central	30
3.3. Representación de soluciones y algoritmo de decodificación	31
3.4. Consumo y recarga de batería	33
3.4.1. Estimación de carga por arista	34
3.4.2. Garantía de llegada a estación de recarga	35

3.5.	Algoritmo de decodificación para Flota Convencional	37
3.5.1.	Variante con balanceo	38
3.6.	Algoritmo de decodificación para Flota Mixta: Max-Electric	42
3.7.	Algoritmo de decodificación para Flota Mixta Balanced	43
3.7.1.	Versión mejorada	44
3.8.	Algoritmo de decodificación para Flota Mixta No-Stations	47
Capítulo 4.	Experimentación y resultados	
4.1.	Diseño de experimentos	51
4.2.	Resultados por experimento	52
4.2.1.	Experimento con flota convencional	53
4.2.2.	Experimento con flota mixta max-eléctrica	54
4.2.3.	Experimento con flota mixta equilibrada	55
4.2.4.	Experimento con flota mixta sin estaciones	56
4.3.	Comparación de frentes consolidados	57
4.3.1.	Casos de 50 clientes	57
4.3.2.	Casos de 75 a 150 clientes	60
4.3.3.	Casos de 200 clientes	62
4.4.	Análisis de distancia y tiempo de espera	64
4.5.	Conjeturas sobre resultados de distancia y tiempo de espera	68
Capítulo 5.	Análisis de emisiones de CO₂	
5.1.	Emisiones de CO ₂ por subconjunto de casos de prueba	70
5.2.	Revisión de casos de 50 clientes	73
5.2.1.	Análisis de caso UK50_05	74
5.3.	Análisis de casos de 10 clientes	77
5.3.1.	Caso UK10_12	77
5.3.2.	Caso UK10_15	82
5.4.	Emisión de CO ₂ por kilómetro	84
Capítulo 6.	Conclusiones	
6.1.	Sumario	87
6.2.	Conclusiones	87
6.3.	Trabajo futuro	89
Literatura citada	91
Anexo	96

Lista de figuras

Figura	Página
1. Elementos del VRP con flota mixta.	5
2. Comparación de frentes no dominados entre flota convencional y flota mixta.	6
3. Representación de problema de optimización.	17
4. Representación de conjunto y frente de Pareto.	18
5. Ejemplo de relación de dominancia.	19
6. Cobertura de conjuntos.	21
7. Selección de individuos para siguiente generación en NSGA-II.	23
8. Cálculo de distancia de amontonamiento en NSGA-II.	24
9. Análisis de recorrido para la clasificación de nodos.	30
10. Visualización de nodos alcanzables e inalcanzables.	31
11. Proceso de decodificación.	32
12. Ruta eléctrica con carga estimada por arista.	36
13. Ruta eléctrica con carga real por arista.	36
14. Frentes consolidados para casos UK50	59
15. Frentes consolidados para casos UK75, UK100 y UK150	61
16. Frentes consolidados para casos UK200	63
17. Soluciones con menor distancia obtenidas para el caso UK50_05	76
18. Soluciones con menor distancia obtenidas para el caso UK10_12	79
19. Soluciones de flota equilibrada V1 para el caso UK10_12	81
20. Soluciones con menor distancia obtenidas para el caso UK10_15.	83
21. Relación de emisiones indirectas y aumento en distancia.	85
22. Frentes no dominados con flota convencional: NSGA-II vs MOEA/D.	97
23. Frentes no dominados con flota mixta: NSGA-II vs MOEA/D.	98

Lista de tablas

Tabla		Página
1.	Propiedades de vehículos convencionales y eléctricos.	28
2.	Proporción de nodos alcanzables e inalcanzables en casos de prueba.	31
3.	Carga inicial promedio por vehículo, para cada subconjunto de casos de prueba.	35
4.	Parámetros del algoritmo NSGA-II.	51
5.	Distancia recorrida: soluciones obtenidas vs Goeke & Schneider (2015).	53
6.	Número de vehículos: soluciones obtenidas vs Goeke & Schneider (2015).	54
7.	Tiempos de ejecución promedio	54
8.	Resultados de soluciones con mejor distancia.	64
9.	Resultados de soluciones con mejor tiempo de espera.	65
10.	Menor distancia (flota convencional) vs Menor tiempo de espera (flota mixta).	65
11.	Aportación de vehículos eléctricos al tiempo de espera y distancia total.	66
12.	Distancia promedio por tipo de vehículo.	67
13.	Proporción de vehículos eléctricos en cada flota.	67
14.	Emisiones de CO ₂ de soluciones con menor distancia recorrida.	71
15.	Comparación de emisiones de CO ₂ para los casos UK50.	74
16.	Detalles de soluciones de menor distancia para el caso UK50_05.	75
17.	Soluciones con menor distancia para los casos UK10.	77
18.	Detalles de soluciones con menor distancia para el caso UK10_12.	80
19.	Detalles de soluciones con menor emisión total para el caso UK10_12.	82
20.	Carga y emisiones por arista en solución para caso UK10_15 (flota convencional).	84
21.	Carga y emisiones por arista en solución para caso UK10_15 (Balanced V2).	84
22.	Parámetros del algoritmo MOEA/D.	96

Capítulo 1. Introducción

El transporte de mercancía es esencial para el comercio y la economía global, permitiendo la distribución de bienes desde el lugar de fabricación hasta la ubicación de los clientes finales. A nivel terrestre, el uso masivo de vehículos de combustión interna tanto para el transporte de mercancía como para otras actividades cotidianas, representa una de las mayores fuentes de generación de gases de efecto invernadero que provocan el calentamiento global. La Agencia Internacional de Energía (IEA) reportó que en el año 2021 el sector de transporte produjo el 37 % de la emisión global de dióxido de carbono (CO₂), equivalente a 7.7 GtCO₂, de los cuales el 76 % corresponde a vehículos terrestres (IEA (2022b)).

Dado el aumento continuo de las emisiones globales de gases de efecto invernadero, en 2015 la Organización de las Naciones Unidas (ONU), compuesta por 196 países, declaró el Acuerdo de Paris con el objetivo de limitar el incremento de temperatura global en este siglo a no más de 1.5 grados Celsius (UNFCCC (2020)). En 2021, como parte de este acuerdo la ONU definió un plan de cero emisiones para el año 2050 (UN (2022)). Con este plan se pretende reducir a cero las emisiones de gases de efecto invernadero en cada país participante. Para ello, se estableció la meta para el 2030, de reducir las emisión global un 45 % menos en comparación con lo generado en 2010 (UNEP (2022)).

Diversas medidas se han aplicado para reducir los niveles de contaminación, desde la regulación en el proceso de fabricación de vehículos (CFR (2022)) hasta el control de la circulación de vehículos en grandes ciudades (SEDEMA (2022)). Uno de los esfuerzos con mayor crecimiento en la última década es el uso de vehículos eléctricos (IEA (2022a)). Compañías internacionales dedicadas a la distribución de paquetes y productos como DHL (2021), Amazon (2021) y Bimbo (2022), han reportado la integración de vehículos eléctricos en sus flotas. Sin embargo, el uso de estos vehículos trae consigo restricciones asociadas a la batería que les da energía, ya que limita la distancia que éstos pueden recorrer, siendo necesaria la visita a estaciones de recarga.

En el campo de investigación, el transporte de mercancía es un problema que se ha estudiado desde 1959 (Dantzig (1959)) con el nombre de problema de enrutamiento de vehículos (VRP). Este problema consiste en encontrar el conjunto de rutas óptimo (respecto a una función de costo) para distribuir bienes o proveer servicios a un conjunto de clientes, mediante el despliegue de una flota de vehículos. Con el paso de los años, el VRP ha adoptado nuevas características de acuerdo a los desafíos actuales del transporte de mercancía. Recientemente, surgió el interés por considerar dentro del VRP, la reducción del impacto ambiental de los vehículos convencionales (con motor de combustión interna) y la inclusión de vehículos eléctricos en las tareas de distribución.

1.1. Antecedentes y justificación

El problema de enrutamiento de vehículos fue estudiado por primera vez por Dantzig (1959) bajo el contexto de una red de distribución de combustible, donde una flota de camiones partía de una refinería para visitar cada estación de servicio y satisfacer su respectiva demanda, recorriendo una distancia mínima. Posteriormente, Clarke & Wright (1964) y Christofides & Eilon (1969) revisitarían el problema proponiendo una mejora al método de Dantzig (1959) pero manteniendo las mismas restricciones. Más de una década después Christofides (1976) titularía su artículo como "The vehicle routing problem", integrando las características del problema estudiadas hasta entonces y dando inicio a una serie de estudios bajo el nombre de problema de enrutamiento de vehículos.

Las primeras variantes del VRP jugaban con las características esenciales del problema. El VRP con ventanas de tiempo (Solomon & Derosiers (1988)) definía intervalos de tiempo en los que cada cliente podía ser atendido. El VRP con múltiples centrales (Cordeau et al. (1997)) planteaba un escenario con más de una central, donde los vehículos debían regresar a la misma central de la cual partieron. En el VRP con flota heterogénea (Taillard (1999)) se considera que la flota se compone de diferentes tipos de vehículos en términos de capacidad, velocidad y costo.

Posteriormente, otras variantes extendieron el planteamiento original del VRP añadiendo niveles de distribución tanto físicamente como a través del tiempo. El Two-Echelon VRP (Cuda et al. (2015)) considera una distribución por capas, donde desde una central se realizan entregas a puntos intermedios, a partir de los cuales otra flota de vehículos distribuye los productos a los clientes finales. Por otro lado, el VRP periódico (Yu & Yang (2011)) consiste en construir de rutas para la distribución de bienes a lo largo de varios días. En la década de los 90's y 00's, éstas y muchas más variantes serían estudiadas combinadas entre sí, creando versiones específicas del problema para determinados casos de estudio (Golden et al. (2008)).

A inicios de la década de los 10's surgiría una nueva categoría de problemas de enrutamiento llamada Green VRP, en los cuales se pretende disminuir el impacto ambiental de las tareas de distribución de mercancía (Lin et al. (2014)). Bektaş & Laporte (2011) propondrían el problema de enrutamiento contaminante (Pollution-Routing Problem) donde el objetivo es crear un conjunto de rutas cuyo costo de emisiones de CO₂ sea mínimo. En este trabajo, se implementó un modelo de emisiones de CO₂ basado en el consumo de combustible, el cual se calcula a partir de la distancia recorrida, velocidad y peso total del vehículo. Después, Erdoğan & Miller-Hooks (2012) publicaría su artículo "A Green Vehicle Routing

Problem”, en el cual se plantea resolver el VRP con una flota de vehículos de combustible alternativo, específicamente de biodiésel, minimizando la distancia recorrida. Dada la escasa presencia de estaciones de biodiésel, se añade una restricción en el recorrido de los vehículos de acuerdo a lo permitido por un tanque de combustible lleno y propone la visita a estaciones de recarga para aumentar su alcance.

A partir del estudio del Green VRP y dado el interés por emplear vehículos eléctricos en tareas de distribución, nace el Electric VRP (Qin et al. (2021)). En esta nueva variante, se supone una flota de vehículos eléctricos, con un alcance limitado por la capacidad de la batería pero con la oportunidad de visitar estaciones de recarga, similar a las características del Green VRP de Erdoğan & Miller-Hooks (2012). El Electric VRP ha sido estudiado en su versión genérica por Woller et al. (2021), con ventanas de tiempo por Schneider et al. (2014), con una función de carga no lineal por Montoya et al. (2017) y con incertidumbre del consumo de energía por Pelletier et al. (2019).

Otra variante que también considera vehículos eléctricos es el VRP con flota mixta, donde ésta se compone tanto de vehículos convencionales como eléctricos. Esta versión del problema ha sido estudiada por Goeke & Schneider (2015) y Hiermann et al. (2019). En dichos trabajos la función objetivo contempla el consumo de combustible por parte de los vehículos convencionales y el consumo de energía por parte de los eléctricos. Macrina et al. (2019) también tratan el VRP con flota mixta con la diferencia de que considera las emisiones de CO₂ dentro de la formulación del problema, en forma de restricción para los vehículos convencionales.

De la literatura revisada, se observa que en la mayoría de las variantes, el VRP se intenta resolver optimizando una sola función objetivo, como distancia, costo total, tiempo de recorrido, entre otros. El enfoque mono-objetivo pretende encontrar una única solución, que sea mejor a todas las demás. Por otro lado, en un problema multiobjetivo se optimizan dos o más funciones objetivo que se encuentran en conflicto, situación común en los problemas del mundo real. Bajo un enfoque multiobjetivo, no se obtiene una única solución, sino más bien un conjunto de soluciones de la misma calidad (llamado frente no dominado), de las cuales se puede elegir dependiendo del contexto. Sin embargo, poco se ha estudiado sobre el VRP multiobjetivo: Demir et al. (2014) minimizan el consumo de combustible y el tiempo de recorrido, Konstantakopoulos et al. (2020) minimizan el número de vehículos y la distancia total, y Zhang et al. (2020) minimizan el número de vehículos y el tiempo de espera.

Respecto a las variantes del VRP que consideran vehículos eléctricos, surgen algunas inquietudes respecto a su implementación en escenarios reales. Aunque la comercialización de vehículos eléctricos para tareas de distribución ha crecido en los últimos años, ésta sigue siendo un porcentaje menor en comparación con

la venta de vehículos convencionales (EFTE (2022)). La limitación de batería, la poca disponibilidad de estaciones de recarga, así como los costos de adquisición y mantenimiento de estos vehículos, son consideraciones que pueden afectar su adopción masiva por empresas dedicadas al transporte de mercancías. Dadas estas preocupaciones, surge el interés por estudiar el impacto en logística que tendría incluir vehículos eléctricos en tareas de distribución, al comparar su desempeño con el de una flota convencional (compuesta completamente por vehículos convencionales).

Pocos trabajos han analizado el impacto en la conversión de una flota convencional a eléctrica. Gonçalves et al. (2011) estudiaron el impacto económico de incluir vehículos eléctricos en una flota convencional. Para ello, definieron tres flotas diferentes: una flota convencional, una flota mixta y una flota eléctrica. Sin embargo, dado que en ese momento dicha tecnología seguía en desarrollo, las características y restricciones asociadas a los vehículos eléctricos no se tratan de forma realista. Recientemente, Romero-Ocaño et al. (2022) analizaron el impacto de reemplazar vehículos convencionales por eléctricos dentro de un conjunto de rutas definido, aplicando los ajustes necesarios para que cada recorrido fuera factible. Dicho análisis fue realizado con un enfoque multiobjetivo, donde se buscaba minimizar distancia recorrida y tiempo de espera, lo cual permitió observar la degradación del frente no dominado de la flota convencional, después del reemplazo de vehículos.

1.2. Definición del problema

Con base en las inquietudes descritas anteriormente, en este proyecto se propone analizar el impacto en la calidad de las soluciones, que tendría emplear una flota mixta por sobre una convencional, considerando un enfoque multiobjetivo. Para ello, se pretende resolver el problema de enrutamiento de vehículos con ventanas de tiempo, empleando primero una flota convencional y posteriormente una flota mixta, minimizando distancia total recorrida y tiempo de espera. Para asegurar una comparación justa, se utilizará un mismo conjunto de casos de prueba que sea compatible con ambas versiones del problema.

El VRP con ventanas de tiempo y flota mixta se define de la siguiente forma: dado un conjunto de clientes, una central y una flota de vehículos convencionales y eléctricos, definir un conjunto de rutas en el que cada cliente reciba su pedido en una sola visita y cada vehículo inicie y termine su recorrido en la central. El conjunto de rutas debe respetar las restricciones de capacidad del vehículo, las ventanas de tiempo de los clientes y el nivel de batería de los vehículos eléctricos. Para extender su alcance, los vehículos eléctricos podrán visitar una estación de recarga. La Figura 1 ilustra las características del VRP

con flota mixta. El VRP con ventanas de tiempo y flota convencional, se define de forma similar al VRP con flota mixta, omitiendo las características y restricciones asociadas a los vehículos eléctricos.

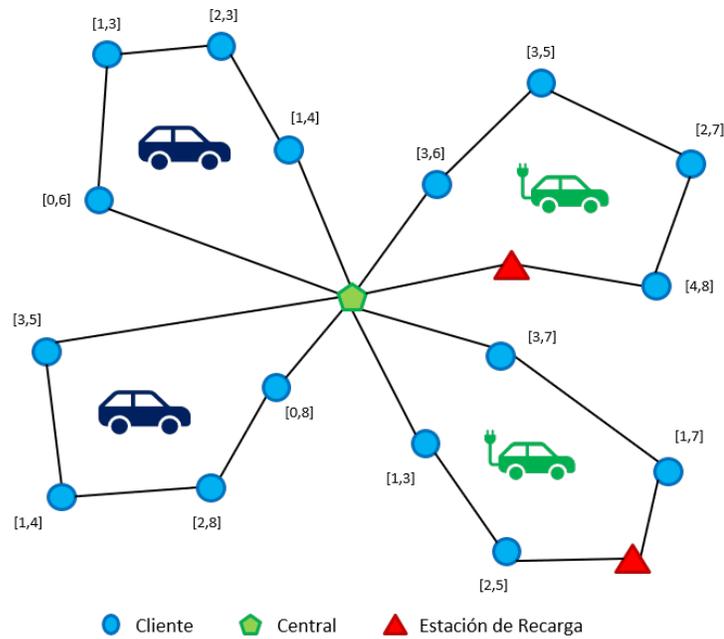


Figura 1. Elementos del VRP con flota mixta.

El enfoque multiobjetivo permitirá visualizar el impacto en distancia y tiempo de espera que tendrá el uso de una flota mixta, al comparar los frentes no dominados correspondientes a cada flota (Figura 2). En adición a estas funciones objetivo, se pretende cuantificar y analizar las emisiones de CO₂ de ambas flotas para evidenciar el beneficio del uso de vehículos eléctricos e identificar la relación de compromiso entre la reducción de emisiones y la degradación de calidad de las soluciones.

Dado que el VRP pertenece a la clase de problemas NP-difícil (Lenstra & Kan (1981)), es poco probable encontrar soluciones exactas para casos grandes en un tiempo razonable. La mayoría de las técnicas utilizadas para resolver el VRP han sido metaheurísticas, es decir, estrategias para encontrar soluciones aproximadas a la solución óptima en un tiempo razonable. Algunas de éstas son la búsqueda tabú (Gendreau et al. (1994), Taillard et al. (1997)), templado simulado (Hiquebran et al. (1993), Xiao et al. (2012)) y el algoritmo genético (Baker & Ayechev (2003), Berger & Barkaoui (2003)). Para problemas multiobjetivo, dos de las metaheurísticas más utilizadas en la literatura son NSGA-II (Deb et al. (2002)) y MOEA/D (Zhang & Li (2007)), las cuales serán consideradas en este proyecto.

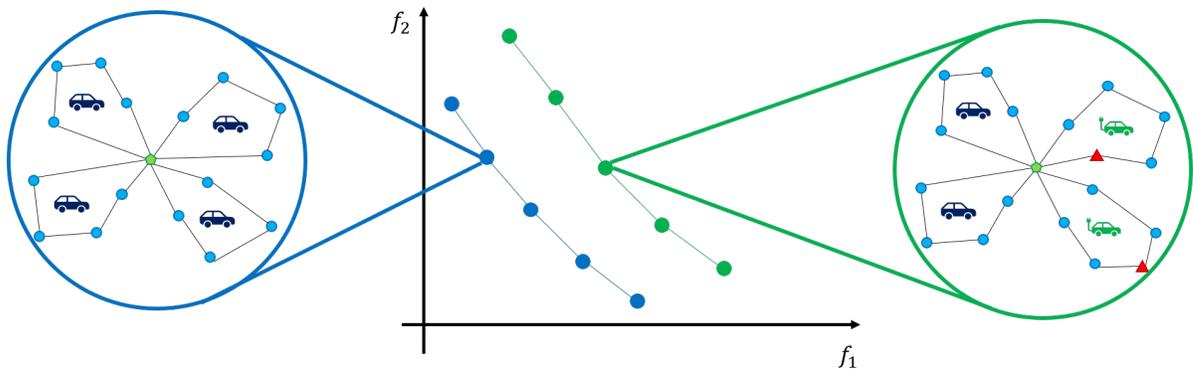


Figura 2. Comparación de frentes no dominados entre flota convencional (color azul) y flota mixta (color verde).

1.3. Objetivos

1.3.1. Objetivo general

Resolver el problema de enrutamiento de vehículos con flota convencional y flota mixta, aplicando una metaheurística multiobjetivo, para analizar el impacto en la calidad del frente no dominado, producido por la inclusión de vehículos eléctricos en la flota.

1.3.2. Objetivos específicos

1. Seleccionar de la literatura un conjunto de casos de prueba con el cual se pueda resolver el problema de enrutamiento de vehículos con ventanas de tiempo, tanto con una flota convencional como con una flota mixta.
2. Implementar las funciones objetivo definidas para el problema de enrutamiento de vehículos con ventanas de tiempo, asegurando que sean aplicables para una flota convencional y una flota mixta.
3. Comparar el desempeño de los algoritmos NSGA-II y MOEA/D para resolver el problema de enrutamiento de vehículos y seleccionar aquel con mejores resultados.
4. Diseñar algoritmos de decodificación que permitan construir conjuntos de rutas para una flota convencional y para flotas mixtas con diferentes características.

5. Analizar y determinar el impacto en la calidad del frente no dominado, al considerar una flota mixta en lugar de una convencional.
6. Desarrollar un entorno de experimentación que permita cargar casos de prueba para el problema de enrutamiento de vehículos y resolverlos aplicando una metaheurística multiobjetivo.

1.4. Organización de la tesis

El documento está estructurado de la siguiente forma: En el Capítulo 2 se describe el marco teórico del proyecto, incluyendo una descripción detallada del problema, la formulación de las funciones objetivo y una introducción a la optimización multiobjetivo. En el Capítulo 3 se define la metodología del proyecto, desde la selección de casos de prueba hasta la descripción de los algoritmos propuestos para la construcción de rutas. El Capítulo 4 presenta el diseño de experimentos y el análisis de los resultados en términos de distancia y tiempo de espera. El Capítulo 5 contiene el análisis de emisiones directas e indirectas de CO₂ de las soluciones obtenidas de los experimentos. Por último, en el Capítulo 6 se presentan las conclusiones del proyecto y se proponen algunas ideas de investigación a futuro.

Capítulo 2. Marco Teórico

En este capítulo se explicarán los conceptos básicos relacionados al problema de enrutamiento de vehículos, las funciones objetivo con las que se evaluarán las soluciones al problema y una introducción al concepto de optimización multiobjetivo, así como a los algoritmos evolutivos multiobjetivo.

2.1. Problema de enrutamiento de vehículos

El problema de enrutamiento de vehículos (VRP por sus siglas en inglés) fue estudiado por primera vez por Dantzig (1959), bajo el nombre de problema de despacho de camiones. Esta primera versión del problema, consistía en definir un conjunto de rutas para una flota de camiones que transportarían gasolina de una central hacia diferentes estaciones de servicio. Para ello, se deseaba asignar estaciones a camiones, de forma que todas las demandas fueran satisfechas y la distancia total recorrida fuera mínima. En dicho trabajo, el problema de despacho de camiones se formuló como una generalización del problema del vendedor viajero (Laporte (2010)), el cual consiste en definir la ruta más corta para visitar un conjunto de puntos dado.

En su versión genérica, el problema de enrutamiento de vehículos se define como: dada una flota de vehículos ubicada en una central y un conjunto de clientes C con una demanda asociada, definir un conjunto de rutas R en el que cada cliente sea visitado por un vehículo y el costo total de distribución sea mínimo (Laporte (2009)). Las condiciones generales consideradas en el VRP son:

- Todos los vehículos inician y terminan su recorrido en la central.
- Los vehículos no regresan a la central hasta el final de su recorrido.
- Cada cliente es visitado una sola vez por un solo vehículo.
- La suma de las demandas de los clientes a visitar en cada ruta no sobrepasa la capacidad de carga del vehículo.
- Todos los vehículos tienen las mismas características: peso, capacidad máxima, velocidad, costo.

Después de más de 60 años del primer artículo donde se estudió el VRP, muchas variaciones han surgido con el paso de los años. Cada versión del VRP modifica o agrega características al planteamiento clásico

del problema, con el fin de reflejar las restricciones presentes en situaciones reales. A continuación, se describen las dos variantes del VRP que serán consideradas en este proyecto.

2.1.1. VRP con ventanas de tiempo (VRP-TW)

La variante de VRP con ventanas de tiempo (VRP-TW por sus siglas en inglés) agrega una nueva restricción al problema donde cada cliente tiene definida una ventana de tiempo $[\alpha, \beta]$, en la que se encuentra disponible para atender la visita del vehículo (Solomon & Derosiers (1988)). Existen dos tipos de ventanas de tiempo: flexibles (soft time windows) y estrictas (hard time windows). Las ventanas de tiempo flexibles permiten que el vehículo visite al cliente antes del inicio de su ventana de tiempo o después de que termine, a cambio de una penalización que se refleja en la función objetivo como un costo por entrega fuera de tiempo o por insatisfacción del cliente (Taillard et al. (1997), Qureshi et al. (2009), Taş et al. (2013)). Por el contrario, las ventanas de tiempo estrictas no permiten visitas extemporáneas, de modo que si el vehículo llega antes del inicio de la ventana de tiempo, debe esperar para realizar la entrega, y no es factible llegar con el cliente después del fin de la ventana de tiempo (Demir et al. (2012), Goeke & Schneider (2015), Romero-Ocaño et al. (2022)).

2.1.2. VRP con flota mixta (VRP-MF)

En la variante de VRP con flota mixta (VRP-MF por sus siglas en inglés), la flota se compone de vehículos convencionales y eléctricos. Esta versión del problema suele estar relacionada con el VRP verde (GVRP, green vehicle routing problem), el cual engloba distintas variantes del VRP que estudian el impacto ambiental de las soluciones. El VRP-MF fue estudiado por primera vez por Goeke & Schneider (2015) y posteriormente ha sido trabajado por Hiermann et al. (2019) y Macrina et al. (2019). Usualmente, los casos de prueba para esta variante describen un conjunto de estaciones de recarga ST , que los vehículos eléctricos pueden visitar para extender su alcance. También, esta variación trae consigo nuevas condiciones, principalmente relacionadas con la batería de los vehículos eléctricos:

- El vehículo eléctrico sale de la central con una batería llena.
- En cualquier punto de la ruta, la batería debe tener suficiente energía para permitir que el vehículo llegue a su siguiente destino.

- Todos los vehículos eléctricos tienen las mismas características: batería, peso, capacidad máxima, velocidad, costo.
- Las recargas de batería son completas, el vehículos no puede partir de la estación de recarga con una batería parcialmente cargada.

2.2. Funciones objetivo

Generalmente, en el VRP se trata de encontrar un conjunto de rutas que minimice el costo de distribución que, dependiendo del contexto del problema, puede incluir el salario de conductores, la renta de los vehículos y el consumo de combustible. Todos estos costos dependen principalmente de dos factores: la distancia y el tiempo. Debido a ello, en este proyecto se tratará de resolver el VRP optimizando distancia recorrida y tiempo de espera. Además, con el interés de estudiar el impacto ambiental de las soluciones obtenidas, se definen tres modelos para el cálculo de emisiones de CO₂. El primer modelo describe el cálculo de emisiones correspondientes a vehículos convencionales y los dos modelos siguientes describen el cálculo de emisiones indirectas por parte de los vehículos eléctricos.

Para continuar con la descripción del cálculo de las funciones objetivo, se propone lo siguiente:

A partir de un conjunto de N clientes $C = \{c_1, c_2, \dots, c_N\}$, una solución al VRP es representada como una permutación de dichos clientes $P = (p_1, p_2, \dots, p_N)$, y después de ser procesada por un algoritmo de decodificación se tiene como salida un conjunto de k rutas $R = \{R_1, R_2, \dots, R_k\}$, donde cada ruta es un arreglo de clientes, que puede o no incluir estaciones de recarga. El conjunto de rutas R tiene la siguiente estructura:

$$R_1 = (\pi_0^1, \pi_1^1, \dots, \pi_{n_1}^1, \pi_{(n_1+1)}^1),$$

$$R_2 = (\pi_0^2, \pi_1^2, \dots, \pi_{n_2}^2, \pi_{(n_2+1)}^2),$$

...

$$R_i = (\pi_0^i, \pi_1^i, \dots, \pi_{n_i}^i, \pi_{(n_i+1)}^i),$$

...

$$R_k = (\pi_0^k, \pi_1^k, \dots, \pi_{n_k}^k, \pi_{(n_k+1)}^k)$$

donde $\pi_j^i \in (C \cup ST)$ es el j -ésimo cliente o estación de recarga en ser visitada en la i -ésima ruta ($1 \leq i \leq k$); n_i es el número de nodos (clientes y estaciones de recarga) visitados en la ruta; π_0^i y $\pi_{(n_i+1)}^i$ representan la central o depósito.

2.2.1. Distancia recorrida

La distancia que recorre el vehículo es un factor esencial para el cálculo del costo de distribución. Dada una velocidad constante, recorrer una mayor distancia significa consumir más combustible y más tiempo de conducción. El cálculo de la distancia recorrida se describe a continuación:

Dado un conjunto de k rutas $\{R_1, R_2, \dots, R_k\}$, en el que cada ruta es un arreglo compuesto por clientes y estaciones de recarga, de la forma $R_i = (\pi_0^i, \pi_1^i, \dots, \pi_{n_i}^i, \pi_{(n_i+1)}^i)$, la distancia total recorrida se obtiene mediante la ecuación:

$$f_1(\Pi) = \sum_{i=1}^k \sum_{j=0}^{n_i} d_{\pi_j^i, \pi_{(j+1)}^i} \quad (1)$$

donde $d_{\pi_j^i, \pi_{(j+1)}^i}$ es la distancia entre los nodos π_j^i y $\pi_{(j+1)}^i$.

2.2.2. Tiempo de espera

El tiempo de espera que se produce por una llegada anticipada con un cliente, representa tiempo muerto en el proceso de distribución, lo que se traduce en pérdida de dinero para la empresa responsable de dicha tarea. Por ello, en el contexto del VRP con ventanas de tiempo, se considera que la minimización del tiempo de espera ayuda a reducir costos de distribución, al acortar o eliminar los tiempos muertos de cada ruta (Solomon & Derosiers (1988)). El tiempo de espera se calcula de la siguiente forma:

Dado un conjunto de k rutas $\{R_1, R_2, \dots, R_k\}$, en el que cada ruta es un arreglo compuesto por clientes y estaciones de recarga, de la forma $R_i = (\pi_0^i, \pi_1^i, \dots, \pi_{n_i}^i, \pi_{(n_i+1)}^i)$, el tiempo de espera total se obtiene mediante la ecuación:

$$f_2(\Pi) = \sum_{i=1}^k \sum_{j=1}^{n_i} \max((\alpha_{\pi_j^i} - at_{\pi_j^i}), 0) \quad (2)$$

donde $\alpha_{\pi_j^i}$ es el tiempo de inicio de la ventana de tiempo del cliente π_j^i y $at_{\pi_j^i}$ es el tiempo de llegada del vehículo a la ubicación de dicho cliente. Es importante mencionar que ninguna visita a estación de recarga producirá tiempo de espera, ya que se considera que toda estación está disponible desde el inicio de las tareas de distribución. El tiempo que toma recargar la batería será tomado en cuenta dentro del tiempo total del recorrido, más no será considerado como tiempo de espera.

Para el estudio multiobjetivo del VRP, minimizar el tiempo de espera puede entrar en conflicto con minimizar la distancia recorrida. Un ejemplo de esta situación es cuando se desea visitar el cliente más cercano a la ubicación actual del vehículo, pero el tiempo de llegada implica esperar a que inicie la ventana de tiempo de dicho cliente. De igual forma, el conflicto se presenta en escenarios donde las ventanas de tiempo que se habilitan primero corresponden a clientes que se encuentran alejados de la ubicación actual del vehículo.

2.3. Emisiones de CO₂

El estudio del impacto ambiental del uso de vehículos dentro del VRP ha tomado fuerza en la última década. Diferentes trabajos se han enfocado en encontrar soluciones de enrutamiento que minimicen el consumo de combustible o el costo de emisiones de gases de efecto invernadero, al incluirlos dentro del cálculo del costo total de distribución (Bektaş & Laporte (2011), Koç et al. (2016)). En algunos de ellos se ha explorado el uso de una flota heterogénea, compuesta de diferentes tipos de vehículos convencionales (Koç et al. (2014)), y también se han estudiado costos energéticos en flotas eléctricas (Pelletier et al. (2019)) y mixtas (Hiermann et al. (2019)). Sin embargo, cuando se consideran vehículos eléctricos en la flota, generalmente no se cuestiona si las emisiones indirectas de CO₂, asociadas al consumo de energía eléctrica, presentan una diferencia notable en comparación con las emisiones de una flota convencional. Con el objetivo de comparar ambos tipos de emisiones, a continuación, se definen los modelos para emisiones directas e indirectas de CO₂.

2.3.1. Emisiones directas

Para calcular emisiones directas de CO₂ se utilizó el modelo integral de emisiones descrito por Barth et al. (2005), Scora & Barth (2006), y Barth & Boriboonsomsin (2008), el cual permite estimar el consumo de combustible para un instante de tiempo dado y que ha sido utilizado en otros estudios del VRP (Bektaş & Laporte (2011), Demir et al. (2012), Koç et al. (2014), Goeke & Schneider (2015)).

El modelo describe la siguiente función para el cálculo de tasa de combustible:

$$FR = \xi(kNV + P/\eta)/\kappa \quad (3)$$

donde ξ es la tasa de masa combustible-a-aire, k es el factor de fricción del motor, N es la velocidad del motor (medida en revoluciones por segundo), V es el desplazamiento del motor (medido en litros), y η y κ son constantes. P es la potencia de salida del motor por segundo, medida en kilowatts, y se calcula de la siguiente forma:

$$P = P_{tract}/\eta_{tf} + P_{acc} \quad (4)$$

donde η_{tf} es la eficiencia del tren de transmisión del vehículo, y P_{acc} es la demanda de potencia del motor asociada a pérdidas y al uso de otras funciones del vehículo, como el aire acondicionado. Usualmente, en el contexto del VRP, P_{acc} se supone con valor cero. El requerimiento de potencia de tracción total P_{tract} , medido en kilowatts, equivale a lo siguiente:

$$P_{tract} = (M\tau + Mg \sin \theta + 0.5C_d\rho Av^2 + MgC_r \cos \theta)v/1000 \quad (5)$$

donde M es el peso total del vehículo en kilogramos, v es la velocidad del vehículo en metros por segundo, τ es la aceleración (m/s^2), θ es la inclinación del camino, g es la constante gravitacional, C_d es el coeficiente de resistencia aerodinámica, C_r es el coeficiente de resistencia de rodadura, ρ es la densidad del aire y A es el área de la superficie frontal del vehículo.

Para una arista dada (i, j) de longitud d , sea v la velocidad del vehículo con la que recorre dicha arista. Si todas las variables en 3, excepto la velocidad del vehículo v , se mantuvieran constantes en la arista

(i, j) , el consumo de combustible (en litros) para esta arista puede ser calculado como:

$$F(v) = kNV\lambda d/v + P\lambda\gamma d/v \quad (6)$$

donde $\lambda = \xi/\kappa\psi$ y $\gamma = 1/1000\eta_t f \eta$ son constantes, y ψ es el factor de conversión de gramos por segundo a litros por segundo. Además, sea $M = w + f$, donde w es el peso del vehículo vacío y f es la carga que lleva el vehículo en la arista (i, j) . Sea $\alpha = \tau + g \sin \theta + gC_r \cos \theta$ una constante específica para el vehículo y esta arista y $\beta = 0.5C_d\rho A$ una constante específica para el vehículo. Suponiendo que en toda arista la inclinación del camino es cero, la variable α ahora es constante, y omitiendo los índices (i, j) en las variables v, d, f para simplificar la presentación, entonces $F(v)$ puede reescribirse como:

$$F(v) = \lambda(kNV + w\gamma\alpha v + \gamma\alpha f v + \beta\gamma v^3)d/v \quad (7)$$

A partir del combustible consumido calculado por la ecuación 7 es posible obtener la emisión de CO₂ mediante el coeficiente de emisiones de CO₂ por litro de combustible $C_l = 2.32kg$ (EIA (2022)). Por lo tanto, el cálculo de emisiones directas de CO₂ (en kilogramos) para una arista, en función de una distancia d , velocidad v y peso w dado, es el siguiente:

$$E_m(d, v, w) = C_l * (\lambda(kNV + w\gamma\alpha v + \gamma\alpha f v + \beta\gamma v^3)d/v) \quad (8)$$

Una vez descrito el modelo para calcular emisiones por arista, se define la función para el cálculo del total de emisiones directas dada una solución al VRP:

Dado un conjunto de k rutas $\{R_1, R_2, \dots, R_k\}$, en el que cada ruta es un arreglo compuesto por clientes y estaciones de recarga (opcional), de la forma $R_i = (\pi_0^i, \pi_1^i, \dots, \pi_{n_i}^i, \pi_{(n_i+1)}^i)$, el total de emisiones directas de CO₂ se obtiene con la función:

$$E_D(\Pi) = \sum_{i=1}^k \sum_{j=0}^{n_i} E_m(d_{\pi_{ij}, \pi_{i(j+1)}}, v_{\pi_{ij}, \pi_{i(j+1)}}, w_{\pi_{ij}, \pi_{i(j+1)}}) \quad (9)$$

donde $d_{\pi_{ij}, \pi_{i(j+1)}}$ es la distancia entre los nodos π_{ij} y $\pi_{i(j+1)}$, $v_{\pi_{ij}, \pi_{i(j+1)}}$ es la velocidad con la que el vehículo recorre la arista $(\pi_{ij}, \pi_{i(j+1)})$, y $w_{\pi_{ij}, \pi_{i(j+1)}}$ es el peso total del vehículo en la misma arista.

2.3.2. Emisiones indirectas

En México, cada año la Comisión Reguladora de Energía, a través de la Secretaría de Medio Ambiente y Recursos Naturales (SEMARNAT), publica el factor de emisión del sistema eléctrico nacional, el cual permite calcular las emisiones indirectas de gases de efecto invernadero por consumo de electricidad (SEMARNAT (2022)). Dicho factor es utilizado por empresas y organizaciones para la elaboración de reportes que deben entregar al Registro Nacional de Emisiones y considera la generación de las centrales eléctricas que entregan energía a la red eléctrica nacional. Otros países que también calculan su propio factor de emisión por consumo de electricidad son Estados Unidos, China e India (IEA (2020)).

En el contexto del VRP, el factor de emisiones permite calcular las emisiones indirectas asociadas a la recarga de batería de los vehículos eléctricos. De esta forma, se pretende evaluar las soluciones con flota mixta con una perspectiva realista, de acuerdo a la situación energética actual, donde los métodos de generación de energía eléctrica dependen de la quema de combustibles fósiles (IEA (2021)). Para ello, se definen dos enfoques para el cálculo de emisiones indirectas: por recarga y por consumo. En ambos casos, se considera el factor de emisión en México, expresado en kilogramos de CO₂ equivalente por kilowatt-hora: $F_E = 0.423 \text{ kgCO}_2\text{e/kWh}$. Otra investigación que también considera emisiones indirectas es la de Zhao et al. (2021), donde se define un factor de emisión de $0.785 \text{ kgCO}_2\text{e/kWh}$.

Emisiones indirectas por recarga

El enfoque por recarga considera el total de energía eléctrica que fue consumida en estaciones de recarga por vehículos eléctricos, incluyendo la recarga inicial en la central con la cual se garantiza que cada vehículo inicia su recorrido con una batería llena. Bajo este enfoque, se pretende cuantificar el impacto ambiental de cada recarga, sin importar el nivel de batería restante con el que los vehículos eléctricos se queden al final de su recorrido. Por lo tanto, el total de emisiones indirectas de CO₂ para una solución dada es:

$$E_R(\Pi) = \sum_{i=1}^k BR_i * F_E \quad (10)$$

donde BR_i es el total de energía recargada (en kilowatt-hora) en la ruta i y F_E es el factor de emisión.

Emisiones indirectas por consumo

Por otra parte, el enfoque por consumo considera solamente la energía requerida para el recorrido, omitiendo el nivel restante con el que cada vehículo eléctrico regresa a la central. Este enfoque es más flexible que el anterior, al cuantificar el impacto ambiental asociado a la energía invertida en el recorrido. Hiermann et al. (2019) utiliza este enfoque para calcular los costos de distribución de los vehículos eléctricos en una flota mixta. Para este enfoque, el total de emisiones indirectas de CO₂ para una solución dada es:

$$E_C(\Pi) = \sum_{i=1}^k (BR_i - BL_i) * F_E \quad (11)$$

donde BR_i es el total de energía recargada (en kilowatt-hora) en la ruta i , BL_i es la energía restante en la batería al terminar la ruta i y F_E es el factor de emisión.

2.4. Optimización Multiobjetivo

La presente definición de problema de optimización está basada en la definición usada por Eiben & Smith (2015), la cual supone un sistema computacional de caja negra, como el descrito en la Figura 3. Al recibir una entrada, este sistema la procesa a través de un modelo computacional, cuyos detalles pueden o no ser conocidos. Una vez concluido el procesamiento, el sistema retorna una salida. En este sistema computacional de caja negra se identifican tres componentes esenciales: modelo, entrada y salida. El modelo puede representar aspectos del mundo real, como una herramienta para estimar la probabilidad de lluvia a partir de ciertos datos meteorológicos o una fórmula para calcular la longitud de una ruta a partir de una lista de ciudades.

Un problema de optimización es aquel en donde el modelo es conocido y también la salida deseada o sus características, y donde el objetivo es encontrar la entrada (o conjunto de entradas) que consiguen la salida deseada. Por ejemplo, en el problema del vendedor viajero, el objetivo es encontrar la ruta más corta que visite, exactamente una vez, cada una de las ciudades de un conjunto dado (Laporte (2010)). En este problema, el modelo es la fórmula con la cual se calcula la longitud de la ruta, la entrada es la permutación de ciudades que la conforma y la salida es su longitud. En este caso, el problema es encontrar la entrada que produzca la salida deseada, es decir, encontrar la permutación de ciudades que

genere un recorrido de longitud mínima. Para ello, no se conoce el valor de salida exacto, sino más bien se busca encontrar el valor óptimo (mínimo o máximo), el cual se identifica al compararlo con las salidas asociadas a otras entradas.



Figura 3. Representación de problema de optimización basada en modelo de caja negra de sistema computacional.

Muchos problemas del mundo real requieren optimizar simultáneamente dos o más objetivos que usualmente se encuentran en conflicto y están sujetos a ciertas restricciones. Por ejemplo, cuando se va a comprar una casa, las personas buscan aquella que cumpla con ciertas características como el número de habitaciones, el costo, el diseño exterior e interior, la reputación del vecindario, la distancia al lugar de trabajo o la escuela, entre otros. Generalmente en este tipo de problemas se busca maximizar los factores de comodidad y minimizar el costo, lo cual genera un conflicto entre ambas características ya que a mayor comodidad, mayor será el costo. En esos casos no existe una solución única que se considere óptima sino más bien un conjunto óptimo de soluciones, es decir, un conjunto de opciones de las cuáles se puede elegir, evaluando las características de cada una.

Un problema de optimización multiobjetivo está compuesto por una función vector \mathbf{f} que mapea una tupla de n parámetros (variables de decisión) a una tupla de m objetivos (vector objetivo). Suponiendo, sin pérdida de generalidad, un problema de optimización multiobjetivo donde se busca minimizar todas los objetivos, la función \mathbf{f} se define formalmente como:

$$\text{minimizar } \mathbf{y} = \mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})] \quad (12)$$

sujeto a

$$\mathbf{x} = (x_1, x_2, \dots, x_n) \in X \quad (13)$$

$$\mathbf{y} = (y_1, y_2, \dots, y_m) \in Y \quad (14)$$

donde \mathbf{x} es el vector de decisión, X es el espacio de decisión, \mathbf{y} es el vector objetivo, y Y es el espacio objetivo (Zitzler & Thiele (1999)). La Figura 4 describe el mapeo de vectores de decisión a vectores objetivo en espacios de dos dimensiones. En la figura se puede observar como a dos vectores de decisión con componentes diferentes les puede corresponder el mismo vector objetivo. Esto depende del contexto y restricciones del problema.

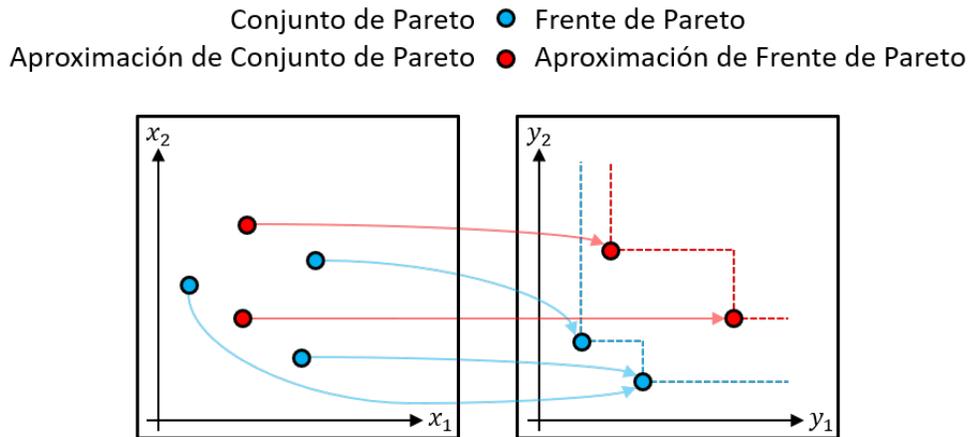


Figura 4. Representación de conjunto y frente de Pareto, en espacio de decisión y espacio objetivo. (Zitzler et al. (2004))

2.4.1. Dominancia y frente de Pareto

En optimización multiobjetivo, la dominancia es una relación de orden que permite comparar dos soluciones de un problema multiobjetivo. Se dice que una solución domina a otra si es al menos tan buena como la segunda en todos los objetivos y estrictamente mejor en al menos uno de ellos. Si una solución domina a otra significa que la primera es mejor en términos de todas las funciones objetivo, o al menos en una de ellas sin ser peor en las demás.

Dadas dos soluciones (vectores de decisión), \mathbf{a} y \mathbf{b} , y sus vectores objetivos correspondientes, $\mathbf{f}(\mathbf{a})$ y $\mathbf{f}(\mathbf{b})$, existen cuatro posibles relaciones entre ambas (Brizuela & Juárez (2019)):

1. La solución \mathbf{a} domina a la solución \mathbf{b} si cada componente de $\mathbf{f}(\mathbf{a})$ es igual o menor que el componente correspondiente de $\mathbf{f}(\mathbf{b})$ y al menos un componente es estrictamente menor.

$$\mathbf{a} \prec \mathbf{b} \iff \forall i \in \{1, 2, \dots, n\} : f_i(\mathbf{a}) \leq f_i(\mathbf{b}) \text{ y } \exists i \in \{1, 2, \dots, n\} : f_i(\mathbf{a}) < f_i(\mathbf{b})$$

2. La solución \mathbf{a} es dominada por la solución \mathbf{b} si para cada componente de $\mathbf{f}(\mathbf{a})$ los componentes de $\mathbf{f}(\mathbf{b})$ son iguales o menores, y al menos un componente es estrictamente mayor.

$$\mathbf{a} \succ \mathbf{b} \iff \forall i \in \{1, 2, \dots, n\} : f_i(\mathbf{a}) \geq f_i(\mathbf{b}) \text{ y } \exists i \in \{1, 2, \dots, n\} : f_i(\mathbf{a}) > f_i(\mathbf{b})$$

3. La solución \mathbf{a} es igual que la solución \mathbf{b} si cada componente de $\mathbf{f}(\mathbf{a})$ es igual al componente correspondiente de $\mathbf{f}(\mathbf{b})$.

$$\mathbf{a} = \mathbf{b} \iff \forall i \in \{1, 2, \dots, n\} : f_i(\mathbf{a}) = f_i(\mathbf{b})$$

4. La solución \mathbf{a} no es comparable con la solución \mathbf{b} cuando ninguno de los casos anteriores se cumple. Entonces se considera que ambas soluciones tienen el mismo nivel de calidad.

$$\mathbf{a} \succ\prec \mathbf{b} \iff \exists i, j \in \{1, 2, \dots, n\} : f_i(\mathbf{a}) \leq f_i(\mathbf{b}) \text{ y } f_j(\mathbf{a}) \geq f_j(\mathbf{b}); \text{ y } \mathbf{a} \neq \mathbf{b}$$

La Figura 5 muestra cuatro soluciones en el espacio objetivo de un problema de optimización donde se busca minimizar dos funciones objetivo. La solución de color verde domina a la azul porque tienen la misma componente en f_2 , pero la componente en f_1 es menor. La solución roja domina a la de color azul porque para ambas funciones objetivo la solución roja tiene menores componentes que la azul. Por último, la solución amarilla domina a la azul porque tiene el mismo componente en f_1 pero es menor su componente en f_2 . La relación entre las soluciones verde, roja y amarilla cae en el cuarto caso del listado anterior, ya que éstas no se dominan entre sí.

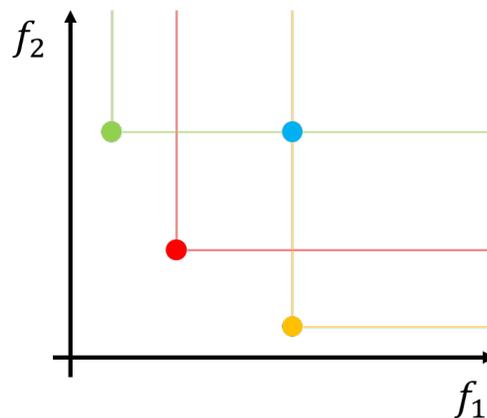


Figura 5. Ejemplo de relación de dominancia. Las soluciones de color verde, rojo y amarillo dominan a la solución de color azul.

En problemas de optimización multiobjetivo, donde las funciones objetivo entran en conflicto, no existe una sola solución que domine a todas las demás. Por lo tanto, la solución a un problema multiobjetivo

es el conjunto de todas las soluciones (vectores de decisión) que no son dominadas por cualquier otra. Estas soluciones forman el conjunto óptimo de Pareto (P):

$$P := \{\mathbf{x} \in X \mid \nexists \mathbf{x}' \in X : \mathbf{x}' \prec \mathbf{x}\}$$

Al conjunto de vectores objetivo que corresponden a las soluciones del conjunto óptimo de Pareto se le conoce como frente óptimo de Pareto:

$$PF := \{\mathbf{y} = \mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})] \mid \mathbf{x} \in P\}$$

La Figura 4 muestra en color azul los vectores de decisión y vectores objetivo que forman el conjunto y frente de Pareto, respectivamente, en un problema de minimización de dos funciones objetivo. Cuando el conjunto y frente de Pareto no se conocen, el conjunto de soluciones y vectores objetivo se consideran aproximaciones (color rojo) y suelen ser llamados conjunto de soluciones no dominadas y frente no dominado.

2.4.2. Cobertura de soluciones

La cobertura de soluciones es un criterio que permite comparar la calidad de dos frentes no dominados aplicando el concepto de dominancia. Trabajos como los de Zitzler & Thiele (1998), y Zitzler & Thiele (1999) han utilizado este criterio para comparar el desempeño de varios algoritmos de optimización multiobjetivo a través de los frentes no dominados resultantes. La cobertura de conjuntos está definida por una función C que toma dos conjuntos de soluciones no dominadas y calcula el porcentaje de soluciones de un conjunto que son dominadas por soluciones del otro conjunto (Brizuela & Juárez (2019)). Dados dos frentes no dominados, A y B , el cubrimiento de A sobre B se calcula como:

$$C(A, B) = \frac{|\{b \in B \mid \exists a \in A : a \prec b\}|}{|B|} \quad (15)$$

El valor de $C(A, B)$ será igual al porcentaje de soluciones en B que son dominadas por A . Cuando $C(A, B) = 1$ significa que todas las soluciones en el frente B son dominadas por al menos una solución del frente A . Cuando $C(A, B) = 0$ significa que ninguna de las soluciones en B es dominada por alguna

solución en A . Al calcular este criterio, es importante especificar el orden de los frentes no dominados en la función, ya que $C(A, B)$ es diferente de $C(B, A)$ y no necesariamente $C(A, B) = 1 - C(B, A)$.

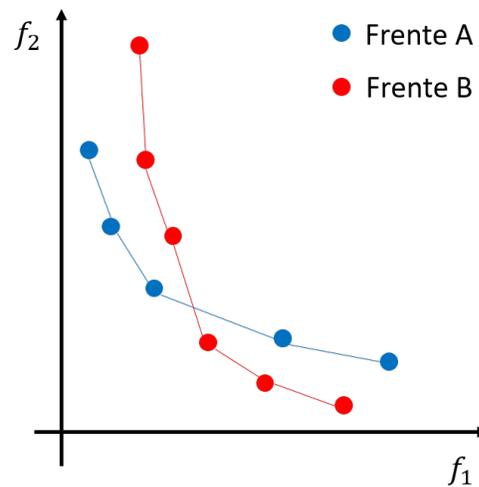


Figura 6. Cobertura de conjuntos. El frente A cubre 3 de las 6 soluciones en B y el frente B cubre 2 de 5 soluciones en A .

La Figura 6 muestra un ejemplo de la comparación de dos frentes no dominados mediante la cobertura de soluciones. El frente A cubre el 50% de las soluciones en B , mientras que B cubre el 20% de las soluciones en A . Este y otros criterios para la comparación de frentes no dominados son estudiadas por Knowles & Corne (2002) y Zitzler et al. (2003).

2.5. Algoritmos evolutivos multiobjetivo

Un algoritmo evolutivo es una técnica computacional inspirada en los principios de la evolución de las especies: dada una población de individuos dentro de un ambiente con recursos limitados, la competencia por dichos recursos causa la selección natural, es decir, la supervivencia de los más aptos. A través de varias generaciones, este fenómeno provoca un aumento en la aptitud general de la población (Eiben & Smith (2015)). Con esta premisa, los algoritmos evolutivos proponen la siguiente analogía: los individuos son soluciones candidatas a un problema y dada una función de calidad a maximizar, es posible medir la aptitud de cada individuo (solución). Con base en estos valores de aptitud es posible mantener a los mejores candidatos para la siguiente generación, en la cual se aplicará un proceso de recombinación y mutación, que producirán nuevas soluciones.

El esquema general de un algoritmo evolutivo se describe en el Algoritmo 1. El proceso empieza con la

formación de un conjunto de soluciones aleatorias, las cuales son evaluadas con la función de calidad. A partir de este paso comienza la iteración del proceso por generaciones. Primero, un subconjunto de soluciones es seleccionado para el proceso de recombinación. La recombinación es un operador aplicado a dos o más soluciones (llamadas padres), para producir una o más soluciones nuevas (llamadas hijos). Posteriormente, se aplica un operador de mutación a los hijos, es decir, una modificación con la cual se genera una nueva solución. Después de aplicar estos dos operadores se tiene un conjunto de nuevas soluciones candidatas, las cuales son evaluadas para competir con los candidatos antecesores, buscando mantenerse en la siguiente generación. Entonces el proceso se repite por varias generaciones hasta que una condición de terminación se cumple, como encontrar una solución candidata de calidad suficiente o cumplir con un número determinado de generaciones.

Algoritmo 1: Esquema general de algoritmo evolutivo (Eiben & Smith (2015))

```

1 INICIALIZAR población con soluciones aleatorias
2 EVALUAR cada solución candidata
3 while CONDICIÓN DE TERMINACIÓN no sea alcanzada do
4   SELECCIONAR padres
5   RECOMBINAR pares de padres
6   MUTAR hijos resultantes
7   EVALUAR nuevas soluciones
8   SELECCIONAR individuos para siguiente generación

```

2.5.1. NSGA-II

NSGA-II es una versión del algoritmo genético (Mitchell (1995)) para la solución de problemas multi-objetivo, propuesto por Deb et al. (2002). Su nombre corresponde a las siglas de algoritmo genético con ordenamiento por no-dominancia, y es el más utilizado de los algoritmos propuestos por Deb (NSGA: Srinivas & Deb (1994), NSGA-III: Deb & Jain (2013)). NSGA-II sigue el esquema general de los algoritmos evolutivos:

1. Se inicializa una población P_0 de tamaño N , con soluciones aleatorias. Todos los individuos en P_0 son evaluados.

Por cada generación t se realiza lo siguiente:

2. Se seleccionan pares de individuos para participar en el proceso de recombinación.

3. Después de la recombinación y mutación, se obtiene un conjunto de hijos Q_t , de tamaño N .
4. De la población P_t y el conjunto de hijos Q_t se forma el conjunto $R_t = P_t \cup Q_t$, de tamaño $2N$. De R_t se seleccionan los mejores N individuos que pasarán a la siguiente generación.

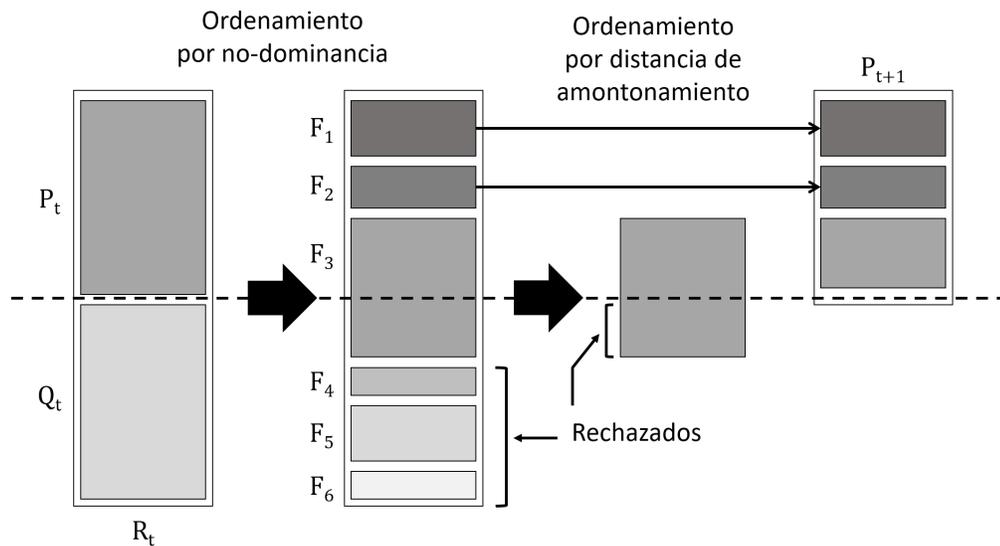


Figura 7. Selección de individuos para siguiente generación en NSGA-II (Deb et al. (2002)).

Para problemas de optimización de un sola función objetivo, un algoritmo evolutivo relaciona dicha función con la aptitud de los individuos. Sin embargo, cuando hay más de una función objetivo a optimizar, esta relación se vuelve más compleja. Una de las características principales de NSGA-II es la forma elitista en que selecciona los individuos que pasarán a la siguiente generación, basándose en el concepto de dominancia, frentes no dominados y distanciamiento de las soluciones.

NSGA-II jerarquiza las soluciones mediante su clasificación en frentes no dominados. Primero se obtiene el frente no dominado a partir de la población total (padres e hijos) y se le asigna el índice 1. Posteriormente se vuelve a obtener un frente no dominado, ignorando aquellas soluciones que conforman el frente 1. A este nuevo frente se le asigna el índice 2. Este proceso se repite hasta que todas las soluciones hayan sido incluidas en algún frente. Una vez terminada la organización por frentes, es posible comparar individuos con base en el índice del frente no dominado al que pertenecen, donde un menor índice indica una mayor aptitud.

La Figura 7 describe el proceso de selección de individuos para la siguiente generación en NSGA-II. Esta consiste en ordenar a los individuos de acuerdo a su clasificación en frentes. Si el número de individuos

en F_1 es menor que el tamaño de la nueva población ($|F_1| < N$), todos los individuos en F_1 formarán parte de la nueva población. Después, se intenta agregar las soluciones en F_2 , verificando que el número de soluciones en él sea menor al número de espacios disponibles en la nueva población ($|F_2| < N - |F_1|$). Este proceso se repite sucesivamente con cada frente hasta formar la nueva población de tamaño N .

Si algún frente no puede ser seleccionado completamente porque supera al número de espacios disponible en la nueva población, entonces sólo se seleccionará un número de individuos equivalente a la cantidad de espacios disponible de acuerdo a la distancia de amontonamiento (Deb et al. (2002)). Esta distancia permite identificar a los individuos con mayor aislamiento en el frente, lo cual favorece a tener una mayor diversidad de soluciones en el frente. La distancia de amontonamiento de una solución corresponde a la distancia promedio entre los dos puntos aledaños a ella, para cada una de las funciones objetivo.

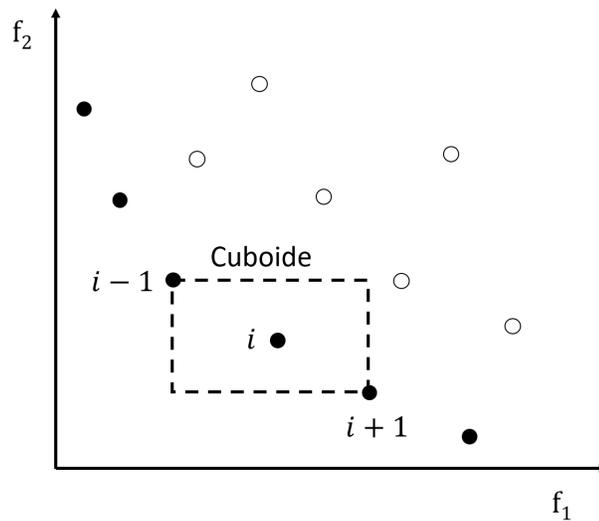


Figura 8. Cálculo de distancia de amontonamiento en NSGA-II (Deb et al. (2002)).

La Figura 8 muestra un ejemplo para un problema de optimización donde se busca minimizar dos funciones objetivo. La distancia de amontonamiento del punto i es un estimado del perímetro del cuboide formado por los vértices $(i + 1)$ y $(i - 1)$. Para identificar los puntos más cercanos a una solución i , es necesario ordenar las soluciones del frente por cada función objetivo e ir acumulando la diferencia normalizada entre $(i + 1)$ y $(i - 1)$, por cada objetivo. Esto se aplica para todas las soluciones en el frente, a excepción de aquellas ubicadas en los extremos. A este par de soluciones se les asigna una distancia de amontonamiento igual a infinito.

2.5.2. MOEA/D

MOEA/D son las siglas de algoritmo evolutivo multiobjetivo basado en descomposición. Este algoritmo fue propuesto por Zhang & Li (2007), se caracteriza por descomponer un problema de optimización multiobjetivo en varios subproblemas de optimización mono-objetivo y resolverlos de forma simultánea. La descomposición se realiza a través de funciones de agregación, que asignan un valor escalar a cada subproblema a partir de un vector de pesos.

El Algoritmo 2 describe el proceso general del algoritmo MOEA/D, suponiendo un problema de optimización multiobjetivo donde se busca minimizar todas las funciones objetivo y considerando la función de agregación de Tchebycheff. Ésta función de agregación define la función objetivo a minimizar del j -ésimo subproblema como:

$$g^{te}(x^j | \lambda^j, z^*) = \max_{1 \leq i \leq m} \{\lambda_i^j * |f_i(x) - z_i^*|\} \quad (16)$$

donde $\lambda^j = (\lambda_1^j, \dots, \lambda_m^j)^T$ es el vector de pesos asociado a x^j y $z^* = (z_1^*, \dots, z_m^*)^T$ es el punto de referencia.

En cada iteración t del algoritmo MOEA/D se mantiene una población de N soluciones $P_t = \{x^1, \dots, x^N\}$, donde x^i es la mejor solución encontrada hasta el momento para el i -ésimo subproblema. Cada solución x^i tiene un vector FV^i asociado, el cual corresponde a la evaluación de dicha solución por la función f del problema de optimización multiobjetivo ($FV^i = f(x^i)$). También, en cada iteración se actualiza el punto de referencia $z = (z_1, \dots, z_m)^T$, donde z_i es el mejor valor conocido hasta el momento para la función objetivo f_i . Por último, al final de cada iteración se actualiza una población externa (EP), la cual contiene todas aquellas soluciones no dominadas que fueron encontradas durante todo el proceso.

Otra de las características principales de MOEA/D, es la definición de vecindarios para cada subproblema. El vecindario de cada vector de pesos λ^i está definido por el conjunto de vectores de peso más cercanos a él. Por lo tanto, el vecindario del i -ésimo subproblema es el conjunto de subproblemas cuyos vectores de peso se encuentran en el vecindario de λ^i . En el Algoritmo 2, el vecindario se ve representado como el conjunto de índices de los vectores de peso más cercanos a cada vector ($B(i) = \{i_1, \dots, i_T\}$). También, por cada iteración, las soluciones vecinas son actualizadas si la nueva solución producida es mejor en términos de la función de Tchebycheff (ecuación 16).

Algoritmo 2: Algoritmo MOEA/D (Zhang & Li (2007))

Input: N , número de subproblemas (tamaño de población),
 T , tamaño de vecindario,
 $\lambda^1, \dots, \lambda^N$, vectores de peso

Output: EP , población externa

- 1 $EP \leftarrow \emptyset$
- 2 Calcular distancia euclidiana entre cada par de vectores de peso.
 // Obtener vecindario $B(i)$ de cada vector λ^i :
- 3 **for** $i = 1$ **to** N **do**
- 4 $B(i) \leftarrow \{i_1, \dots, i_T\}$ donde $\lambda^{i_1}, \dots, \lambda^{i_T}$ son los T vectores de peso más cercanos a λ_i .
- 5 Generar una población inicial $\{x^1, \dots, x^N\}$, con soluciones aleatorias.
- 6 Por cada solución evaluar $FV^i = f(x^i)$.
- 7 Inicializar $z = (z_1, \dots, z_m)^T$.
- 8 **while** *CONDICIÓN DE TERMINACIÓN* no sea alcanzada **do**
- 9 **for** $i = 1$ **to** N **do**
- 10 // Reproducción:
 Seleccionar de forma aleatoria dos índices, k y l , de $B(i)$ y generar una nueva solución y
 a partir de la recombinación de x^k y x^l .
 // Mejora:
 Aplicar un proceso de reparación u operador de mutación a y para generar y' .
 // Actualizar z :
- 12 **for** $j = 1$ **to** m **do**
- 13 **if** $f_j(y') < z_j$ **then**
- 14 $z_j \leftarrow f_j(y')$
- // Actualizar las soluciones del vecindario.
- 15 **foreach** j **in** $B(i)$ **do**
- 16 **if** $g^{te}(y' | \lambda^j, z) \leq g^{te}(x^i | \lambda^j, z)$ **then**
- 17 $x^j \leftarrow y'$
- 18 $FV^j \leftarrow f(y')$
- // Actualizar EP :
- 19 Remover de EP todos los vectores dominados por $f(y')$.
- 20 Agregar $f(y')$ a EP si no hay vectores en EP que dominen a $f(y')$.
- 21 **return** EP

Capítulo 3. Metodología

En este capítulo, se describen los casos de prueba utilizados para los experimentos, las características de los vehículos que conforman la flota y la representación de las soluciones para el problema. También se define un proceso de clasificación de nodos y las estrategias aplicadas para la creación de rutas eléctricas factibles. Además, se explica a detalle cada uno de los algoritmos de decodificación implementados para la creación de rutas con diferentes tipos de flota mixta.

3.1. Casos de prueba

Una de las primeras actividades realizadas fue la identificación de casos de prueba para tratar el problema de enrutamiento de vehículos, buscando que estos permitieran el análisis del uso de una flota convencional y una flota mixta en el mismo ambiente. De esta revisión, se seleccionaron dos conjuntos de casos de prueba que facilitarían el análisis deseado. El primero es el propuesto en Demir et al. (2012), el cual trata el VRP con flota convencional, y el segundo es una modificación del anterior presentada por Goeke & Schneider (2015), que adapta los casos al VRP con flota mixta.

En los casos de prueba de Demir et al. (2012), los casos de prueba presentan ciudades de Reino Unido como clientes, utilizando distancias reales en kilómetros. El conjunto se compone de 180 casos, divididos en 9 subconjuntos de 20 casos cada uno, organizados de acuerdo al número de clientes: 10, 15, 20, 25, 50, 75, 100, 150 y 200 clientes. Cada caso de prueba se conforma de una matriz de distancias asimétrica y un listado de clientes con su respectiva ventana de tiempo, demanda y tiempo de servicio.

El conjunto de casos de prueba de Goeke & Schneider (2015), contiene los mismos casos del conjunto anterior pero adaptados al VRP con flota mixta. Para ello, en cada caso vienen definidas estaciones de recarga, que son representadas por la central y un subconjunto de clientes. También se añade un número estimado de vehículos convencionales y eléctricos a utilizar, limitando la cantidad de eléctricos a no más de la mitad del total de vehículos.

Respecto a las características de los vehículos, se decidió utilizar las propiedades del vehículo presentado en los artículos donde se originan ambos conjuntos de casos de prueba (tabla 1). De esta forma, tanto el vehículo convencional como el eléctrico tienen las mismas características de peso, capacidad de carga y velocidad, diferenciándose solamente en el tipo de energía que requieren para andar.

Tabla 1. Propiedades de vehículos convencionales y eléctricos.

Notación	Valor	Descripción
g	9.81 metros por segundo al cuadrado	Constante gravitacional
ρ	1.2041 kilogramos por metro cúbico	Densidad del aire
A	3.912 metros al cuadrado	Superficie frontal
m_c	6350 kilogramos	Peso del vehículo sin carga
Q	3650 kilogramos	Capacidad de carga
C_r	0.01	Coeficiente de resistencia a rodadura
C_d	0.7	Coeficiente de arrastre aerodinámico
k	0.2 kilojoules por revolución por litro	Factor de fricción de motor
ξ	1	Relación de masa de combustible a aire
η	0.9	Parámetro de eficiencia de motores diesel
η_{tf}	0.4	Parámetro de eficiencia de transmisión
κ	44 kilojoules por gramo	Valor de calentamiento para combustible diesel
ψ	737 litros por gramo	Factor de conversión
N	33 revoluciones por segundo	Velocidad del motor
V	5 litros	Desplazamiento de motor
B	80 kilowatt-hora	Capacidad de batería
r	120^{-1} horas por kilowatt	Tasa de recarga
ϕ^d	1.184692	Parámetro de eficiencia (modo motor)
φ^d	1.112434	Parámetro de eficiencia (descarga)

3.2. Clasificación de nodos

Una vez definidos los casos de prueba y las propiedades de los vehículos, se encontró que en la mayoría de los casos de VRP con estaciones de recarga, no es posible resolver el problema utilizando una flota completamente eléctrica porque la restricción de la batería no permite visitar ciertos nodos. Con el fin de identificar estos nodos y tener una guía durante la construcción de rutas eléctricas y convencionales, se definió una clasificación de nodos que se basa en la posibilidad de realizar visitas a estos nodos con un vehículo eléctrico.

Un proceso similar es aplicado por Goeke & Schneider (2015) y Yu et al. (2021) para generar rutas eléctricas factibles. Para cada caso de prueba, se excluyen todas las aristas cuyo recorrido requiere más energía que la de una batería completa, considerando que el vehículo lleva sólo la demanda del cliente.

En Schneider et al. (2014), se considera una flota completamente eléctrica y los clientes a los que no se puede llegar en tiempo son omitidos del caso de prueba. En cambio, Woller et al. (2021) generan de forma aleatoria la ubicación de las estaciones de recarga, verificando que todo cliente es alcanzable desde al menos una estación.

3.2.1. Nodos alcanzables

Un nodo se considera alcanzable si partiendo de su estación de recarga más cercana, con una batería completa y llevando sólo la demanda de dicho cliente, es factible llegar al nodo y regresar a la estación más cercana. Si este recorrido se puede realizar, existe la posibilidad de que un vehículo eléctrico visite a este cliente, pero no lo garantiza, ya que se está considerando que el vehículo sólo lleva esta demanda.

La carga que lleva el vehículo en la arista $Estación \rightarrow Nodo_i$ será igual o mayor a la demanda del cliente ($Nodo_i$), dependiendo del momento en que sea visitado. Cuando es mayor, la energía requerida para recorrer la arista también será mayor, lo cual podría impedir el regreso a la estación e incluso la llegada al nodo. Como esta clasificación identifica a los clientes que serán considerados para la visita de un vehículo eléctrico, estos nodos pueden ser asignados tanto a una ruta eléctrica como a una convencional.

3.2.2. Nodos inalcanzables

Un nodo se considera inalcanzable si partiendo de su estación de recarga más cercana, con una batería completa y llevando sólo la demanda de dicho cliente, no es posible realizar la entrega y volver a la estación más cercana, o incluso no es posible llegar al nodo. Cuando este recorrido no es factible, se sabe con seguridad que el nodo no podrá ser visitado por un vehículo eléctrico en ningún momento, porque si no es posible visitarlo llevando sólo su demanda, tampoco será posible visitarlo con una carga mayor. Por lo tanto, todo nodo inalcanzable deberá ser asignado a una ruta convencional.

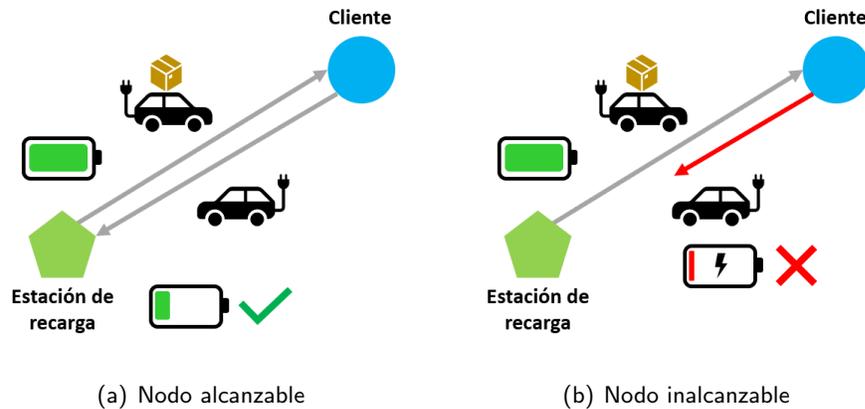


Figura 9. Análisis de recorrido para la clasificación de nodos.

3.2.3. Nodos alcanzables e inalcanzables desde la central

Un nodo alcanzable desde la central es aquel en el que el recorrido $Central \rightarrow Nodo_i \rightarrow Central$ es factible, con una batería completa y llevando sólo la demanda de dicho cliente ($Nodo_i$). Con esta etiqueta se identificarán los nodos que podrían ser visitados por un vehículo eléctrico directamente desde la central.

Por el contrario, un nodo inalcanzable desde la central es aquel en el que el recorrido $Central \rightarrow Nodo_i \rightarrow Central$ no es factible, saliendo con una batería completa y llevando sólo la demanda del cliente. De esta forma, se identifica a los clientes que en ningún momento podrán ser visitados por un vehículo eléctrico que parte directamente de la central.

Esta clasificación de nodos respecto a la central será esencial en el algoritmo de decodificación para flota mixta No-Stations (sección 3.8). En esta flota se restringen las visitas a estaciones de recarga, por lo que los vehículos eléctricos deben completar sus recorridos con solo la carga inicial de la central. Por lo tanto, sólo los nodos alcanzables desde la central pueden ser considerados para una visita por vehículo eléctrico.

En la figura 10 se muestra la distribución de los nodos alcanzables e inalcanzables en el grafo para un caso de 50 clientes. A la izquierda se encuentra la clasificación de nodos con respecto a la estación de recarga más cercana y a la derecha el etiquetado con respecto a la central. También, la tabla 2 muestra la proporción promedio de nodos alcanzables e inalcanzables por subconjunto de casos de prueba.

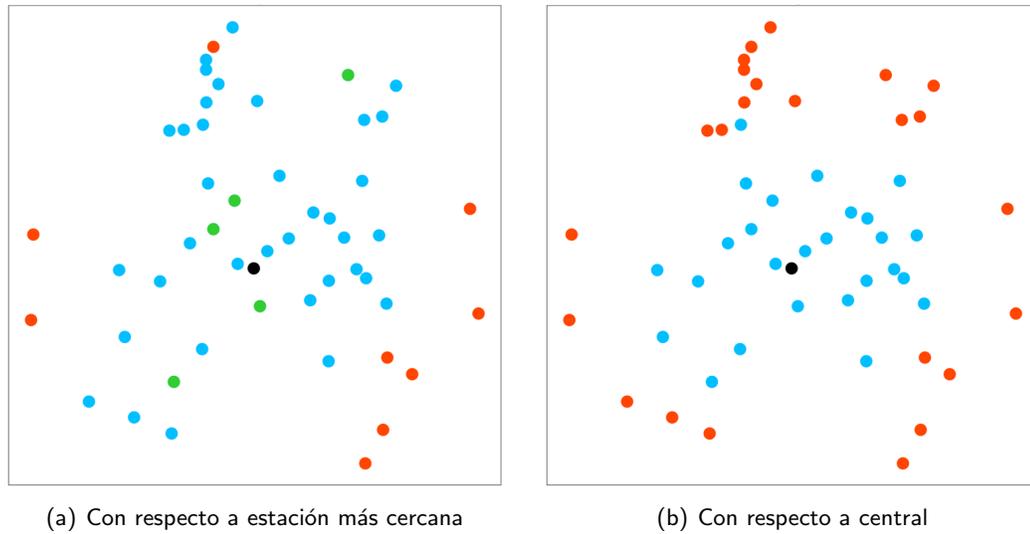


Figura 10. Visualización de nodos alcanzables e inalcanzables con respecto a la estación de recarga más cercana (a) y con respecto a la central (b). Central (negro), nodos alcanzables (azul), nodos inalcanzables (rojo), estaciones (verde).

Tabla 2. Proporción de nodos alcanzables e inalcanzables en casos de prueba.

Subconjunto de casos de prueba	Alcanzables	Inalcanzables	Alcanzables (central)	Inalcanzables (central)
UK10	76 %	24 %	52 %	48 %
UK15	71.33 %	28.67 %	49 %	51 %
UK20	83.25 %	16.75 %	50 %	50 %
UK25	87.6 %	12.4 %	52.2 %	47.8 %
UK50	94.6 %	5.4 %	51.3 %	48.7 %
UK75	94.4 %	5.6 %	51.13 %	48.87 %
UK100	96.55 %	3.45 %	48.6 %	51.4 %
UK150	99 %	1 %	51.93 %	48.07 %
UK200	98.8 %	1.2 %	56.2 %	43.8 %

3.3. Representación de soluciones y algoritmo de decodificación

Dado que la solución a un caso del VRP es un conjunto de rutas, se decidió representar cada solución al problema como una permutación de clientes. Esta representación además es compatible con los operadores de mutación y cruzamiento característicos de los algoritmos evolutivos que se planea utilizar: NSGA-II y MOEA/D. Sin embargo, se requiere de un algoritmo de decodificación que reciba la permutación y devuelva el conjunto de rutas resultante (figura 11), así como la evaluación de las funciones objetivo.

Para ello, se diseñaron e implementaron diferentes algoritmos de decodificación que se caracterizan por

construir rutas para un tipo de flota en específico. Las flotas que se consideraron en este proyecto y que posteriormente serán descritas con mayor detalle son: convencional, mixta Balanced, mixta Max-Electric y mixta No-Stations.

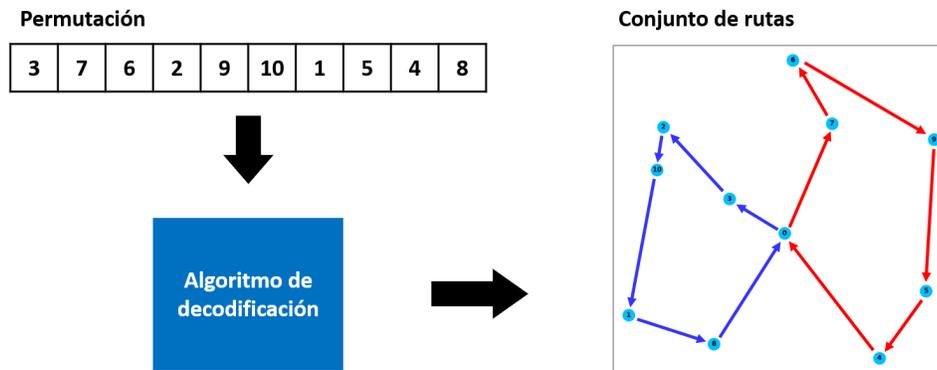


Figura 11. Proceso de decodificación.

Todos los algoritmos de decodificación desarrollados consisten en construir rutas a partir del orden en que aparecen los clientes en la permutación recibida y se componen de tres etapas esenciales: inicialización de rutas, asignación de clientes y finalización de rutas.

Etapa 1 - Inicialización de rutas

En esta etapa, se inicializa un número determinado de rutas, creando los arreglos correspondientes a las rutas y agregando a cada uno el nodo 0 (central), como punto de partida. La cantidad de rutas a inicializar puede ser una o varias, y pueden ser declaradas como rutas convencionales o eléctricas, dependiendo del algoritmo de decodificación.

Etapa 2 - Asignación de clientes

Esta etapa es la más importante de cada algoritmo de decodificación y es el principal diferenciador de cada uno. En este paso, se comienza a leer los clientes de la permutación, para añadirlos uno por uno a una ruta disponible, siguiendo su orden de aparición.

El proceso general que se sigue en todos los algoritmos de decodificación desarrollados es el siguiente:

1. Por cada cliente en la permutación, se revisa cada ruta parcial para ver si es factible agregar el cliente, verificando que no se supere la capacidad de carga del vehículo y que el vehículo llegue antes del cierre de la ventana de tiempo.

2. De las rutas en las que es factible añadir el vehículo, se elige aquella donde el recorrido sea de menor distancia y el cliente se asigna a ella.
3. Si ninguna ruta es seleccionada, debido a que no es factible agregar el cliente a ninguna de ellas, entonces se crea una nueva ruta, donde se parte de la central y después se visita al cliente.

Cada algoritmo de decodificación presenta características diferentes en este proceso, desde las condiciones para asignar un cliente, hasta la forma en que se crean nuevas rutas. Por lo tanto, si la misma permutación se ingresa a estos algoritmos, cada uno regresará un conjunto de rutas diferente.

Etapas 3 - Finalización de rutas

Por último, la finalización de rutas consiste en añadir el nodo 0 (central) en cada una de las rutas construidas, convencionales y eléctricas, para cumplir con la condición de que todo vehículo debe regresar a la central, una vez terminado su recorrido. Este proceso es igual en todos los algoritmos de decodificación.

3.4. Consumo y recarga de batería

Para calcular el consumo de energía de la batería en vehículos eléctricos se implementó el modelo propuesto por Goeke & Schneider (2015), el cual está basado en el modelo de Bektaş & Laporte (2011), descrito en el capítulo anterior (sección 2.3). Primero se calcula el poder mecánico requerido para un recorrido con velocidad v y carga w , descrito en la ecuación 17, que toma como base el cálculo de poder de tracción (ecuación 5). Formalmente, esta función se define como:

$$P_M(v, w) = 0.5C_d\rho Av^2 + (m_c + w)g(\sin \theta + C_r \cos \theta) \quad (17)$$

donde C_d es el coeficiente de resistencia aerodinámica, ρ es la densidad del aire, A es el área de la superficie frontal del vehículo, g es la constante gravitacional, C_r es el coeficiente de resistencia de rodadura y θ es la inclinación del camino. A partir de la función P_M es posible convertir la potencia mecánica en eléctrica a través del coeficiente de eficiencia ϕ^d . Después, la potencia eléctrica se convierte en potencia de batería mediante el coeficiente de descarga φ^d . De esta forma, el consumo de batería para recorrer la arista (i, j) de distancia d_{ij} , con una velocidad v_{ij} y una carga w_{ij} , se define como:

$$P_E(d_{ij}, v_{ij}, w_{ij}) = \phi^d * \varphi^d * P_M(v_{ij}, w_{ij}) * d_{ij} \quad (18)$$

La única modificación que se hizo a este modelo fue la omisión del modo de recarga de batería, el cual se puede aplicar cuando se conoce el ángulo de inclinación de los recorridos. Dado que los casos de prueba encontrados no describen esta información, sólo se considera el modo de descarga.

Para calcular los tiempos de recarga de energía, se empleó el modelo de carga lineal utilizado por Goeke & Schneider (2015) y Romero-Ocaño et al. (2022). Este modelo consiste en multiplicar la energía a recargar en kWh por la tasa de recarga (r en tabla 1) especificada en horas por kWh. Con base en este modelo se obtiene que, para recargar completamente la batería de 80 kWh, transcurrirán 40 minutos.

3.4.1. Estimación de carga por arista

Como en los algoritmos de decodificación, la construcción de las rutas se realiza parcialmente, no es posible saber con precisión cuál será la carga por arista que lleva cada vehículo, hasta que las rutas estén completas. Por ello, para garantizar la construcción de rutas eléctricas factibles, se considera que el vehículo sale de la central con una carga máxima y conforme visita a los clientes, esta carga va disminuyendo. De esta forma, se supone la peor situación posible para el consumo de batería ya que, a mayor carga del vehículo, mayor será el consumo de energía.

Una vez terminadas las rutas eléctricas y conociendo las cargas específicas por arista, se realiza una evaluación de cada ruta para volver a calcular el consumo de batería por arista, los tiempos de recarga en estaciones y por ende los tiempos de llegada a los clientes y el tiempo de espera de la ruta. Es importante mencionar que después de esta evaluación, no es posible obtener rutas que violen el cierre de ventanas de tiempo ya que, si las rutas evaluadas son factibles para el peor caso respecto a la carga inicial del vehículo, también serán factibles para una carga igual o inferior.

Las figuras 12 y 13 muestran la misma ruta eléctrica de un caso de 50 clientes, donde se utilizan cargas estimadas y cargas reales, respectivamente. En cada arista se especifica la carga del vehículo (en kilogramos) y se indica el nivel de batería restante después de llegar a cada cliente. También se observa el tiempo (en minutos) que toma la recarga completa de la batería en las estaciones visitadas.

Al comparar ambos escenarios, se observa que la estimación de carga se aproxima a los valores reales

debido a que la carga con la que el vehículo parte de la central se acerca a la máxima posible. Esta situación es común en los casos de prueba de más de 50 clientes, como lo muestra la tabla 3. La carga inicial promedio por vehículo se obtiene a partir de la ecuación 19, dividiendo el total de las demandas sobre el número de rutas estimado.

Tabla 3. Carga inicial promedio por vehículo, para cada subconjunto de casos de prueba.

Subconjunto de casos de prueba	Carga inicial promedio
UK10	2311.77
UK15	3071.04
UK20	3173.86
UK25	3151.24
UK50	3438.61
UK75	3483.02
UK100	3512.60
UK150	3537.39
UK200	3585.12

3.4.2. Garantía de llegada a estación de recarga

En todos los algoritmos de decodificación que construyen rutas para vehículos eléctricos, se añade una condición para garantizar que el vehículo nunca se quede varado en la ubicación de un cliente. Esta condición consiste en que, siempre que se intente añadir un cliente a una ruta eléctrica, se debe verificar que el nivel de batería permita realizar el recorrido: *Último nodo de ruta* \rightarrow *Cliente* \rightarrow *Estación más cercana*.

De esta forma se asegura que, en cualquier punto de una ruta eléctrica, el vehículo podrá llegar a la estación más cercana a ese nodo antes de agotar completamente la batería. En el caso del algoritmo para flota mixta No-Stations (sección 3.8), la validación se hace con respecto a la central, garantizando que el regreso a la central sea factible desde cualquier nodo de las rutas eléctricas creadas.

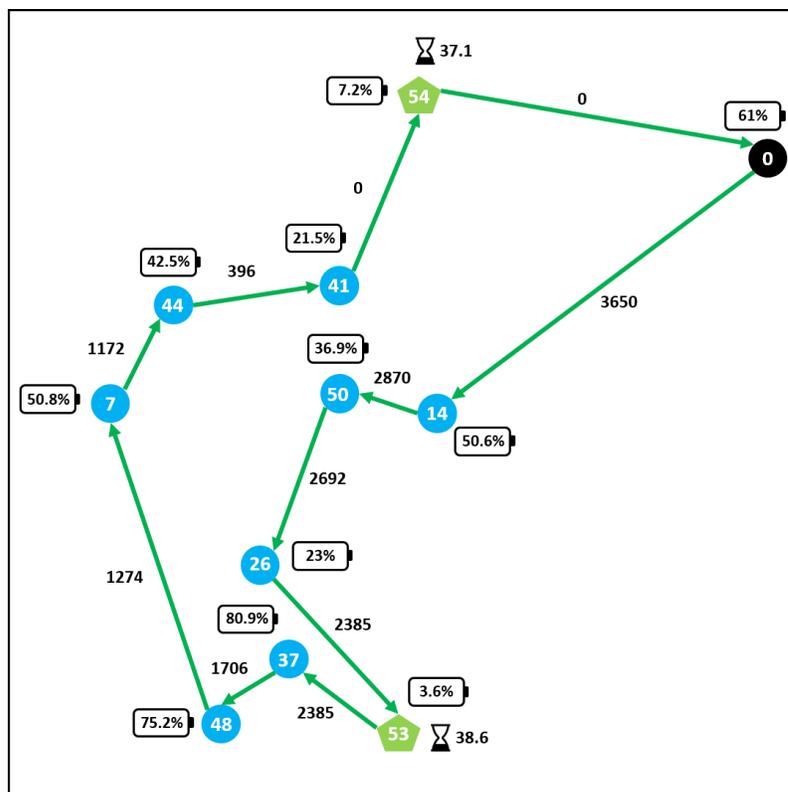


Figura 12. Ruta eléctrica con carga estimada por arista.

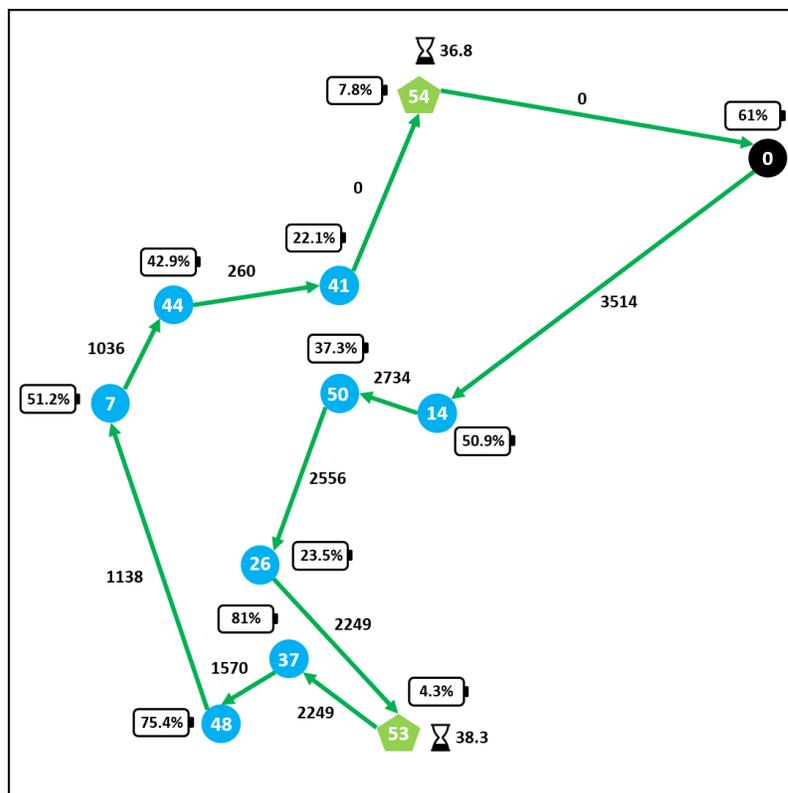


Figura 13. Ruta eléctrica con carga real por arista.

3.5. Algoritmo de decodificación para Flota Convencional

El primer algoritmo de decodificación desarrollado fue pensado para resolver los casos de prueba del VRP con flota convencional. La primera versión de este algoritmo está basada en el algoritmo propuesto por Romero-Ocaño et al. (2022), donde se implementa una estrategia voraz para la asignación de clientes, buscando siempre añadir el cliente más cercano a las rutas.

Preprocesamiento

Para este algoritmo se define un número de rutas estimado, las cuales serán inicializadas para el posterior proceso de asignación de clientes. Este número estimado se obtiene considerando la suma de las demandas de todos los clientes del caso de prueba y la capacidad de carga del vehículo. La siguiente fórmula describe este cálculo.

$$nR = \left\lceil \frac{\sum_{i=1}^{nC} dm_i}{Q} \right\rceil \quad (19)$$

Donde nR es el número de rutas estimado, nC es el número de clientes, dm_i es la demanda del cliente i , y Q es la carga máxima que puede llevar el vehículo.

Descripción de algoritmo

Etapa 1: Para este algoritmo se inicializa el número de rutas estimadas (nR) calculado durante el preprocesamiento del caso de prueba.

Etapa 2: Por cada cliente, se verifica si es factible añadirlo a alguna de las rutas disponibles, considerando las restricciones de capacidad de carga y ventanas de tiempo. La ruta factible que genere la menor distancia para visitar al cliente es seleccionada para la asignación. Cuando no es posible añadir un cliente a una ruta disponible, se crea una nueva ruta conformada por la central y el cliente en cuestión.

Etapa 3: Por último, se añade la central al final de cada recorrido.

3.5.1. Variante con balanceo

Una versión alternativa del algoritmo, consiste en repetir el proceso de construcción de rutas cuando se encuentra una diferencia notable en el número de clientes que se visita por vehículo. A este proceso se le llamó balanceo y su objetivo es mantener un balance en el número de clientes que visita cada vehículo.

Si al terminar la construcción de las rutas, la cantidad de vehículos necesarios es mayor al estimado, se revisa la posibilidad de aplicar el proceso de balanceo. La condición para repetir el proceso es la siguiente: si el menor número de clientes visitados por uno de los vehículos es menor que la tercera parte del número de clientes de la ruta con más clientes, entonces se repite el proceso de decodificación desde la etapa 1, inicializando una ruta extra.

Algoritmo 3: Algoritmo de decodificación para flota convencional

```

Input:  $C$ , permutación de clientes,
          $nR$ , número estimado de rutas
Output:  $Routes$ , conjunto de rutas
// Inicialización de rutas
1 for  $i = 1$  to  $nR$  do
2   | Agregar  $[0]$  a  $Routes$ 
// Asignación de clientes
3 foreach  $c$  in  $C$  do
4   |  $assigned \leftarrow false$ 
5   |  $bestDist \leftarrow \infty$ 
6   | for  $r = 1$  to  $nR$  do
7     |  $lastNode \leftarrow$  Último nodo de  $Routes[r]$ 
8     | Calcular  $arrivalTime$  y  $accumWeight$  por recorrido  $lastNode \rightarrow c$ 
9     | if  $arrivalTime \leq endTimeWindow(c)$  and  $accumWeight \leq Q$  then
10    | | if  $dist(lastNode, c) < bestDist$  then
11    | | |  $bestDist \leftarrow dist(lastNode, c)$ 
12    | | |  $bestIdx \leftarrow r$ 
13    | | |  $assigned \leftarrow true$ 
14   | if  $assigned$  then
15   | | Agregar  $c$  a  $Routes[bestIdx]$ 
16   | else
17   | | Agregar  $[0, c]$  a  $Routes$ 
18   | |  $nR \leftarrow nR + 1$ 
// Finalización de rutas
19 for  $r = 1$  to  $nR$  do
20   | Agregar  $0$  a  $Routes[r]$ 

```

Algoritmo 4: Algoritmo de decodificación para flota convencional con balanceo

Input: C , permutación de clientes,
 nR , número estimado de rutas

Output: $Routes$, conjunto de rutas

```

1 repeat  $\leftarrow$  true
2  $nR_{new} \leftarrow nR$ 
3 while repeat do
4   repeat  $\leftarrow$  false
   // Inicialización de rutas
5   for  $i = 1$  to  $nR_{new}$  do
6     [ Agregar [0] a  $Routes$ 
   // Asignación de clientes
7   foreach  $c$  in  $C$  do
8     assigned  $\leftarrow$  false
9     bestDist  $\leftarrow$   $\infty$ 
10    for  $r = 1$  to  $nR_{new}$  do
11      lastNode  $\leftarrow$  Último nodo de  $Routes[r]$ 
12      Calcular  $arrivalTime$  y  $accumWeight$  por recorrido lastNode  $\rightarrow c$ 
13      if  $arrivalTime \leq endTimeWindow(c)$  and  $accumWeight \leq Q$  then
14        if  $dist(lastNode, c) < bestDist$  then
15          [ bestDist  $\leftarrow dist(lastNode, c)$ 
16            [ bestIdx  $\leftarrow r$ 
17              [ assigned  $\leftarrow$  true
18        if assigned then
19          [ Agregar  $c$  a  $Routes[bestIdx]$ 
20        else
21          [ Agregar  $[0, c]$  a  $Routes$ 
22            [  $nR_{new} \leftarrow nR_{new} + 1$ 
23    if  $nR_{new} > nR$  then
24      [  $nMax =$  Máximo número de clientes por ruta en  $Routes$ 
25      [  $nMin =$  Mínimo número de clientes por ruta en  $Routes$ 
26      if  $nMin < \lceil \frac{nMax}{3} \rceil$  then
27        [ repeat  $\leftarrow$  true
28        [  $nR \leftarrow nR_{new}$ 
   // Finalización de rutas
29 for  $r = 1$  to  $nR$  do
30 [ Agregar 0 a  $Routes[r]$ 

```

Algoritmo 5: Algoritmo de decodificación para flota mixta Max-Electric

```

Input:  $C$ , permutación de clientes
Output:  $eRoutes$ , conjunto de rutas eléctricas,
            $cRoutes$ , conjunto de rutas convencionales
// Inicialización de rutas
1 Agregar [0] a  $eRoutes$ 
2 Agregar [0] a  $cRoutes$ 
// Asignación de clientes
3 foreach  $c$  in  $C$  do
4    $assignedEV \leftarrow false$ 
5    $assignedCV \leftarrow false$ 
6    $bestDist \leftarrow \infty$ 
7   if  $c.isReachable$  then
8     |  $SeleccionarRutaEléctrica()$ 
9   else
10    |  $SeleccionarRutaConvencional()$ 
11   if  $assignedEV$  then
12     | Si es necesario, agregar estación más cercana de  $lastNode$  a  $eRoutes[bestIdx]$ 
13     | Agregar  $c$  a  $eRoutes[bestIdx]$ 
14   else if  $c.isReachable$  then
15     |  $distE \leftarrow \infty$ 
16     |  $cST \leftarrow$  Estación más cercana a  $c$ 
17     | if  $(FullBattery - battery(0, c) - battery(c, cST)) > 0$  then
18       | Calcular  $arrivalTime$  por recorrido  $0 \rightarrow c$ 
19       | if  $arrivalTime \leq endTimeWindow(c)$  then
20         | |  $distE \leftarrow dist(0, c)$ 
21       |  $SeleccionarRutaConvencional()$ 
22       |  $distC \leftarrow$  Distancia de la ruta convencional seleccionada
23       | if  $distE < distC$  then
24         | | Agregar  $[0, c]$  a  $eRoutes$ 
25   if  $assignedCV$  then
26     | Agregar  $c$  a  $cRoutes[bestIdx]$ 
27   else if not  $assignedEV$  then
28     | Agregar  $[0, c]$  a  $cRoutes$ 
// Finalización de rutas
29 for  $eRoute$  in  $eRoutes$  do
30   | Agregar 0 a  $eRoute$ 
31 for  $cRoute$  in  $cRoutes$  do
32   | Agregar 0 a  $cRoute$ 

```

Algoritmo 6: *SeleccionarRutaElectrica()*

```

1 foreach eRoute in eRoutes do
2   lastNode  $\leftarrow$  Último nodo de eRoute
3   cST  $\leftarrow$  Estación más cercana a c
4   Calcular arrivalTime y accumWeight por recorrido lastNode  $\rightarrow$  c
5   if arrivalTime  $\leq$  endTimeWindow(c) and accumWeight  $\leq$  Q then
6     if (eRoute.battery  $-$  battery(lastNode, c)  $-$  battery(c, cST))  $>$  0 then
7       if dist(lastNode, c)  $<$  bestDist then
8         bestDist  $\leftarrow$  dist(lastNode, c)
9         bestIdx  $\leftarrow$  eRoute.Index
10        assignedEV  $\leftarrow$  true
11      else
12        lnST  $\leftarrow$  Estación más cercana a lastNode
13        if (FullBattery  $-$  battery(lnST, c)  $-$  battery(c, cST))  $>$  0 then
14          Calcular arrivalTime por recorrido lastNode  $\rightarrow$  lnST  $\rightarrow$  c
15          if arrivalTime  $\leq$  endTimeWindow(c) then
16            if (dist(lastNode, lnST)  $+$  dist(lnST, c))  $<$  bestDist then
17              bestDist  $\leftarrow$  dist(lastNode, lnST)  $+$  dist(lnST, c)
18              bestIdx  $\leftarrow$  eRoute.Index
19              assignedEV  $\leftarrow$  true

```

Algoritmo 7: *SeleccionarRutaConvencional()*

```

1 foreach cRoute in cRoutes do
2   lastNode  $\leftarrow$  Último nodo de cRoute
3   Calcular arrivalTime y accumWeight por recorrido lastNode  $\rightarrow$  c
4   if arrivalTime  $\leq$  endTimeWindow(c) and accumWeight  $\leq$  Q then
5     if dist(lastNode, c)  $<$  bestDist then
6       bestDist  $\leftarrow$  dist(lastNode, c)
7       bestIdx  $\leftarrow$  cRoute.Index
8       assignedCV  $\leftarrow$  true

```

3.6. Algoritmo de decodificación para Flota Mixta: Max-Electric

En un inicio, este algoritmo fue desarrollado para resolver los casos de prueba de Goeke & Schneider (2015) con una flota completamente eléctrica. Sin embargo, se encontró que había clientes que no podían ser visitados por un vehículo eléctrico, lo cual motivó la identificación de nodos alcanzables e inalcanzables. A partir de este hallazgo, el algoritmo se modificó para construir rutas con una flota mixta, dándole prioridad al uso de vehículos eléctricos.

Preprocesamiento

Para este algoritmo, primero se identifican las estaciones más cercanas a cada cliente del caso de prueba y se guardan para su consulta durante la construcción de rutas. Con base en esto, se realiza el etiquetado de nodos alcanzables e inalcanzables, que servirá como filtro para la asignación de clientes a rutas eléctricas.

Descripción de algoritmo

Etapla 1: A diferencia del algoritmo para flota convencional, este algoritmo se encargará de construir dos tipos de rutas: eléctricas y convencionales. Se podría utilizar el mismo número estimado de rutas que se describió anteriormente, pero es difícil definir cuántas de esas rutas serán eléctricas y cuántas convencionales. Por ello, se decidió que para la flota mixta Max-Electric se inicializará una ruta eléctrica y una ruta convencional, permitiendo la creación de rutas adicionales de ambos tipos cuando sea necesario.

Etapla 2: Por cada cliente en la permutación, se verifica si éste es alcanzable o inalcanzable y con base en ello se sigue un proceso diferente.

- **Nodo alcanzable:** Si el cliente es alcanzable, se intenta añadir a una de las rutas eléctricas disponibles, seleccionando aquellas que respeten las restricciones de capacidad de carga, ventana de tiempo y nivel de batería. Si para cierta ruta, el nivel de batería no permite llegar directamente al cliente, se considera la visita a la estación de recarga más cercana, calculando los tiempos de recarga y el nuevo tiempo de llegada. De las rutas candidatas para asignar el cliente, se escoge aquella que genere la menor distancia.

Si ninguna ruta es seleccionada, entonces se considera la creación de una nueva ruta eléctrica.

Primero, se verifica que el recorrido *Central* \rightarrow *Cliente* es factible con un vehículo eléctrico. Después, se selecciona la ruta convencional que genere la menor distancia al asignarle el cliente. Si la distancia de la nueva ruta es menor que la distancia que suma la ruta convencional seleccionada, la ruta eléctrica es creada. Si no, el cliente alcanzable se añade a la ruta convencional.

Si no es factible añadir el cliente a una nueva ruta eléctrica y tampoco es factible asignarlo a una de las rutas convencionales, entonces se crea una nueva ruta convencional para visitar al cliente.

- **Nodo inalcanzable:** Cuando el cliente está etiquetado como inalcanzable, se sigue el mismo proceso del algoritmo para flota convencional, el cual consiste en identificar las rutas convencionales donde es factible añadir el cliente y elegir la que suma la menor distancia. Cuando ninguna ruta puede ser seleccionada, entonces se crea una nueva.

Etapa 3: Por último, se añade la central al final de cada ruta eléctrica y convencional.

3.7. Algoritmo de decodificación para Flota Mixta Balanced

El presente algoritmo fue diseñado para obtener soluciones del VRP con una flota mixta que compartiera la misma característica que la flota mixta utilizada por Goeke & Schneider (2015): Un balance en la proporción de vehículos convencionales y eléctricos. Este balance limita el número de vehículos eléctricos a no más de la mitad del total de la flota, a diferencia de Max-Electric, que se enfoca en el uso mayoritario de vehículos eléctricos.

Preprocesamiento

Al igual que el algoritmo Max-Electric, primero se identifican las estaciones de recarga más cercanas a cada cliente y después se realiza el etiquetado de nodos alcanzables e inalcanzables. Además, se establece un número estimado de rutas convencionales y eléctricas, que se extrae de cada caso de prueba del conjunto de Goeke & Schneider (2015).

Descripción de algoritmo

Etapa 1: En este algoritmo, el número de rutas eléctricas y convencionales inicializadas corresponde al definido en los casos de prueba.

Etapa 2: Siguiendo lo descrito en el algoritmo Max-Electric, lo primero que se revisa de cada cliente en la permutación es si éste es alcanzable o inalcanzable y a partir de ello se realiza un proceso particular.

- **Nodo alcanzable:** Cuando el cliente es alcanzable, se sigue un proceso similar al de Max-Electric para asignarlo a una de las rutas eléctricas disponibles. Se seleccionan aquellas que respeten las restricciones de capacidad de carga, ventana de tiempo y nivel de batería, incluso visitando una estación de recarga, y después se elige la que genere la menor distancia.

Si ninguna de las rutas disponibles es seleccionada, no se considera la creación de una nueva ruta eléctrica. Esta restricción se aplica para no tener más rutas eléctricas que las indicadas para el caso de prueba, buscando mantener el balance entre los dos tipos de vehículos. Por lo tanto, cuando se presenta esta situación, el nodo alcanzable se trata como inalcanzable, siguiendo el proceso de asignación correspondiente.

- **Nodo inalcanzable:** Si el cliente es inalcanzable, se sigue el proceso del algoritmo para flota convencional: Identificar las rutas convencionales candidatas (verificando factibilidad) y elegir la que sume la menor distancia. A diferencia de las rutas eléctricas en este algoritmo, sí está permitido crear una nueva ruta convencional cuando ninguna es seleccionada. De esta forma, es posible tener más rutas convencionales que las definidas inicialmente, pero no más rutas eléctricas.

Etapa 3: Al igual que los algoritmos anteriores, a cada ruta eléctrica y convencional se le añade la central al final de su recorrido.

3.7.1. Versión mejorada

Posteriormente, se desarrolló una nueva versión de este algoritmo que se caracteriza por permitir la asignación de nodos alcanzables a rutas convencionales, cuando se considere que es lo más conveniente, en términos de distancia (algoritmo 9). En la mayoría de los casos de prueba, los resultados obtenidos

por este algoritmo superaron a aquellos de la primera versión, manteniendo la propiedad de la flota mixta balanceada. Un análisis más detallado de estos resultados se puede encontrar en el capítulo 4.

Algoritmo 8: Algoritmo de decodificación para flota mixta Balanced

```

Input:  $C$ , permutación de clientes,
          $nRE$ , número estimado de rutas eléctricas,
          $nRC$ , número estimado de rutas convencionales
Output:  $eRoutes$ , conjunto de rutas eléctricas,
           $cRoutes$ , conjunto de rutas convencionales
// Inicialización de rutas
1 for  $i = 1$  to  $nRE$  do
2   | Agregar [0] a  $eRoutes$ 
3 for  $i = 1$  to  $nRC$  do
4   | Agregar [0] a  $cRoutes$ 
// Asignación de clientes
5 foreach  $c$  in  $C$  do
6   |  $assignedEV \leftarrow false$ 
7   |  $assignedCV \leftarrow false$ 
8   |  $bestDist \leftarrow \infty$ 
9   | if  $c.isReachable$  then
10  |   |  $SeleccionarRutaEléctrica()$ 
11  | else
12  |   |  $SeleccionarRutaConvencional()$ 
13  | if  $assignedEV$  then
14  |   | Si es necesario, agregar estación más cercana de  $lastNode$  a  $eRoutes[bestIdx]$ 
15  |   | Agregar  $c$  a  $eRoutes[bestIdx]$ 
16  | else if  $c.isReachable$  then
17  |   |  $SeleccionarRutaConvencional()$ 
18  | if  $assignedCV$  then
19  |   | Agregar  $c$  a  $cRoutes[bestIdx]$ 
20  | else if not  $assignedEV$  then
21  |   | Agregar [0,  $c$ ] a  $cRoutes$ 
// Finalización de rutas
22 for  $eRoute$  in  $eRoutes$  do
23   | Agregar 0 a  $eRoute$ 
24 for  $cRoute$  in  $cRoutes$  do
25   | Agregar 0 a  $cRoute$ 

```

Algoritmo 9: Algoritmo de decodificación para flota mixta Balanced V2

```

Input:  $C$ , permutación de clientes,
          $nRE$ , número estimado de rutas eléctricas,
          $nRC$ , número estimado de rutas convencionales
Output:  $eRoutes$ , conjunto de rutas eléctricas,
          $cRoutes$ , conjunto de rutas convencionales
// Inicialización de rutas
1 for  $i = 1$  to  $nRE$  do
2   | Agregar [0] a  $eRoutes$ 
3 for  $i = 1$  to  $nRC$  do
4   | Agregar [0] a  $cRoutes$ 
// Asignación de clientes
5 foreach  $c$  in  $C$  do
6   |  $assignedEV \leftarrow false$ 
7   |  $assignedCV \leftarrow false$ 
8   |  $bestDist \leftarrow \infty$ 
9   | if  $c.isReachable$  then
10  |   |  $distE \leftarrow \infty$ 
11  |   |  $distC \leftarrow \infty$ 
12  |   |  $SeleccionarRutaEléctrica()$ 
13  |   |  $distE \leftarrow$  Distancia de la ruta eléctrica seleccionada
14  |   |  $SeleccionarRutaConvencional()$ 
15  |   |  $distC \leftarrow$  Distancia de la ruta convencional seleccionada
16  |   | if  $distE < distC$  then
17  |   |   |  $assignedEV \leftarrow true$ 
18  |   |   |  $assignedCV \leftarrow false$ 
19  |   | else
20  |   |   |  $assignedCV \leftarrow true$ 
21  |   |   |  $assignedEV \leftarrow false$ 
22  |   | else
23  |   |   |  $SeleccionarRutaConvencional()$ 
24  |   | if  $assignedEV$  then
25  |   |   | Si es necesario, agregar estación más cercana de  $lastNode$  a  $eRoutes[bestIdx]$ 
26  |   |   | Agregar  $c$  a  $eRoutes[bestIdx]$ 
27  |   | if  $assignedCV$  then
28  |   |   | Agregar  $c$  a  $cRoutes[bestIdx]$ 
29  |   | else if not  $assignedEV$  then
30  |   |   | Agregar [0,  $c$ ] a  $cRoutes$ 
// Finalización de rutas
31 for  $eRoute$  in  $eRoutes$  do
32   | Agregar 0 a  $eRoute$ 
33 for  $cRoute$  in  $cRoutes$  do
34   | Agregar 0 a  $cRoute$ 

```

3.8. Algoritmo de decodificación para Flota Mixta No-Stations

El algoritmo de decodificación No-Stations se caracteriza por construir rutas eléctricas en las que no se pueden visitar estaciones de recarga. Esta restricción limita la distancia que cada vehículo eléctrico puede recorrer, ajustándose a lo que permite una sola recarga de batería. Este tipo de restricción también es considerada por Stehling et al. (2021), donde se utiliza una flota mixta y no hay estaciones de recarga fuera de la central.

Actualmente, el número de estaciones de recarga disponibles es limitado en muchos países y las empresas que integran vehículos eléctricos dentro de sus actividades, han instalado estaciones de recarga propias en sus centros de distribución (DHL (2021)). Debido a esta situación, surgió el interés por obtener soluciones que se adaptaran a escenarios realistas, donde las recargas sólo se pueden realizar en la central.

También, desde una perspectiva ambiental, surgió la inquietud por conocer el impacto que tendría en el total de emisiones de CO_2 , limitar la fuente de emisiones indirectas de los vehículos eléctricos. Las soluciones obtenidas con este algoritmo, permitieron analizar la relevancia de las recargas externas en las emisiones totales, al compararlas con las soluciones obtenidas por las otras flotas mixtas (capítulo 5).

Preprocesamiento

Dado que, para este algoritmo, se ignorarán todas las estaciones de recarga externas, es necesario clasificar los nodos como alcanzables e inalcanzables, con respecto a la central. Una vez etiquetados los nodos, se procede a calcular el número estimado de rutas eléctricas y convencionales. Estos estimados se obtienen al aplicar la fórmula utilizada en la flota convencional (ecuación 19), adaptada a cada tipo de vehículo.

$$nRE = \left\lceil \frac{\sum_{c \in Al} dm_c}{Q} \right\rceil \quad (20)$$

$$nRC = \left\lceil \frac{\sum_{c \notin Al} dm_i}{Q} \right\rceil \quad (21)$$

Donde nRE es el número estimado de rutas eléctricas, nRC es el número estimado de rutas convencionales, dm_c es la demanda del cliente c , Al es el subconjunto de clientes alcanzables y Q es la carga máxima que puede llevar el vehículo.

Descripción de algoritmo

Etapa 1: Se inicializa el número estimado de rutas eléctricas (nRE) y convencionales (nRC), calculado en las ecuaciones 20 y 21, respectivamente.

Etapa 2: Por cada cliente en la permutación, se verifica su etiqueta y dependiendo si es alcanzable o inalcanzable desde la central, se procede de acuerdo a lo siguiente.

- **Nodo alcanzable desde la central:** Cuando el cliente es alcanzable, se intentará añadir a una de las rutas eléctricas inicializadas. Este proceso es similar al de la flota *Balanced*, primero seleccionando las rutas factibles y eligiendo la que suma la menor distancia. La diferencia con los demás algoritmos para flota mixta, es que aquí nunca se analiza la posibilidad de visitar una estación de recarga. Además, para garantizar que el vehículo no quede varado en un nodo, se verifica que al llegar con el cliente, el nivel de batería permita al vehículo regresar a la central.

Si ninguna ruta es seleccionada, se aplica el mismo proceso de la flota *Max-Electric*. Primero, se verifica que el recorrido $Central \rightarrow Cliente$ es factible. Esto podría parecer innecesario porque ya se sabe que el nodo es alcanzable desde la central, pero al momento de etiquetarlo se consideró que el vehículo llevaba sólo la demanda del cliente. En cambio, durante la construcción de rutas se considera una carga estimada, que para este caso será la carga máxima que soporta el vehículo.

Después, se simula el proceso de asignación del cliente a una ruta convencional y se compara la distancia generada por la ruta seleccionada con la del recorrido $Central \rightarrow Cliente$. Si la distancia de una nueva ruta eléctrica es menor que la distancia que sumaría añadir el cliente a una ruta convencional, entonces se crea la ruta eléctrica. En caso contrario, o cuando el recorrido de la nueva ruta eléctrica no es posible, el cliente se agrega a la ruta convencional seleccionada.

Cuando tampoco es factible asignar el cliente a una de las rutas convencionales, entonces se crea una nueva ruta convencional a la cual se asigna el cliente.

- **Nodo inalcanzable desde la central:** Si el cliente es inalcanzable, se realiza el mismo procedimiento del algoritmo para flota convencional, identificando las rutas candidatas y eligiendo aquella cuyo recorrido represente la menor distancia. Cuando ninguna ruta convencional puede ser seleccionada, se crea una nueva y se asigna el cliente.

Etapa 3: Por último, se añade la central al final de cada ruta eléctrica y convencional.

Algoritmo 10: Algoritmo de decodificación para flota mixta No-Stations

```

Input:  $C$ , permutación de clientes,
          $nRE$ , número estimado de rutas eléctricas,
          $nRC$ , número estimado de rutas convencionales
Output:  $eRoutes$ , conjunto de rutas eléctricas,
           $cRoutes$ , conjunto de rutas convencionales
// Inicialización de rutas
1 for  $i = 1$  to  $nRE$  do
2   | Agregar [0] a  $eRoutes$ 
3 for  $i = 1$  to  $nRC$  do
4   | Agregar [0] a  $cRoutes$ 
// Asignación de clientes
5 foreach  $c$  in  $C$  do
6   |  $assignedEV \leftarrow false$ 
7   |  $assignedCV \leftarrow false$ 
8   |  $bestDist \leftarrow \infty$ 
9   | if  $c.isReachableFromDepot$  then
10  |   |  $SeleccionarRutaEléctricaNS()$ 
11  | else
12  |   |  $SeleccionarRutaConvencional()$ 
13  | if  $assignedEV$  then
14  |   | Agregar  $c$  a  $eRoutes[bestIdx]$ 
15  | else if  $c.isReachableFromDepot$  then
16  |   |  $distE \leftarrow \infty$ 
17  |   | if  $(FullBattery - battery(0, c) - battery(c, 0)) > 0$  then
18  |   |   | Calcular  $arrivalTime$  por recorrido  $0 \rightarrow c$ 
19  |   |   | if  $arrivalTime \leq endTimeWindow(c)$  then
20  |   |   |   |  $distE \leftarrow dist(0, c)$ 
21  |   |  $SeleccionarRutaConvencional()$ 
22  |   |  $distC \leftarrow$  Distancia de la ruta convencional seleccionada
23  |   | if  $distE < distC$  then
24  |   |   | Agregar  $[0, c]$  a  $eRoutes$ 
25  | if  $assignedCV$  then
26  |   | Agregar  $c$  a  $cRoutes[bestIdx]$ 
27  | else if not  $assignedEV$  then
28  |   | Agregar  $[0, c]$  a  $cRoutes$ 
// Finalización de rutas
29 for  $eRoute$  in  $eRoutes$  do
30   | Agregar 0 a  $eRoute$ 
31 for  $cRoute$  in  $cRoutes$  do
32   | Agregar 0 a  $cRoute$ 

```

Algoritmo 11: *SeleccionarRutaEléctricaNS()*

```

1 foreach eRoute in eRoutes do
2   lastNode  $\leftarrow$  Último nodo de eRoute
3   Calcular arrivalTime y accumWeight por recorrido lastNode  $\rightarrow$  c
4   if arrivalTime  $\leq$  endTimeWindow(c) and accumWeight  $\leq$  Q then
5     if (eRoute.battery - battery(lastNode, c) - battery(c, 0)) > 0 then
6       if dist(lastNode, c) < bestDist then
7         bestDist  $\leftarrow$  dist(lastNode, c)
8         bestIdx  $\leftarrow$  eRoute.Index
9         assignedEV  $\leftarrow$  true

```

Capítulo 4. Experimentación y resultados

4.1. Diseño de experimentos

Dada la complejidad del problema y el enfoque multiobjetivo del proyecto, se planteó utilizar algoritmos evolutivos multiobjetivo como NSGA-II y MOEA/D. Para ello, se utilizó MOEA Framework (<http://moeaframework.org>), una librería de algoritmos de optimización multiobjetivo desarrollada en Java y de acceso libre. Se realizaron pruebas preliminares con ambos algoritmos, de las cuáles se concluyó la superioridad de NSGA-II sobre MOEA/D, en los casos analizados y comparando con criterios de dominancia (ver Anexo A).

Los experimentos realizados consistieron en ejecutar 30 veces el algoritmo NSGA-II por cada caso de prueba, con los parámetros descritos en la Tabla 4. A partir de los frentes no dominados resultantes de cada ejecución, se obtuvo un frente consolidado, el cual se consigue al identificar las soluciones no dominadas dentro del conjunto de todas las soluciones encontradas. En todos los casos, las funciones objetivo a optimizar fueron distancia total recorrida y tiempo de espera (Ecuación 1 y 2).

Tabla 4. Parámetros del algoritmo NSGA-II.

Parámetro	Valor
Tamaño de población	300
Número de generaciones	2000
Probabilidad de cruzamiento	1
Probabilidad de mutación	0.3

Por cada ejecución, se generó un archivo con las soluciones del frente no dominado y al terminar las 30 ejecuciones se generó también un archivo con las soluciones del frente consolidado. Cada archivo contiene la siguiente información: nombre del caso de prueba, algoritmo de optimización utilizado, parámetros del algoritmo de optimización, funciones objetivo optimizadas y el nombre del algoritmo de decodificación utilizado.

Además, por cada solución en el frente no dominado, se describe lo siguiente: número de vehículos convencionales y eléctricos utilizados, energía consumida (kWh), distancia total, máximo tiempo de

rutas, tiempo de espera, emisiones de CO₂, el genotipo (permutación de clientes) y el conjunto de rutas correspondiente. Esta información nos permitió realizar un análisis detallado de las soluciones para comparar el desempeño de cada algoritmo de decodificación.

Todos los experimentos fueron realizados en una misma computadora, con las siguientes características técnicas: Procesador AMD Ryzen 5 3600 6-Core (3.6 GHz), 16 GB de memoria RAM y sistema operativo Windows 10. Los algoritmos de decodificación y demás funciones auxiliares para la ejecución de los algoritmos de optimización fueron programados en Java. También, en una libreta de Jupyter se desarrollaron funciones en Python, dentro de la plataforma Google COLAB. Algunas de las tareas realizadas con estas funciones fueron: generación de gráficos, visualización de rutas, descripción detallada de soluciones y comparación de frentes no dominados.

4.2. Resultados por experimento

A continuación, se presentan los resultados de cada experimento realizado, correspondientes a los algoritmos de decodificación desarrollados tanto para flota convencional como para flota mixta. Para conocer el nivel de calidad de las soluciones encontradas, se decidió hacer una comparación con los resultados de Goeke & Schneider (2015). En dicho trabajo se origina el conjunto de casos de prueba que se utilizó en este proyecto y además se reporta la menor distancia obtenida para cada uno de los casos de prueba, después de 10 corridas del algoritmo propuesto.

La Tabla 5 muestra por cada subconjunto de casos de prueba (de 50 a 200 clientes), el promedio de distancia (en kilómetros) de las soluciones publicadas por Goeke & Schneider (2015). Por cada algoritmo de decodificación, se presenta la diferencia de distancia promedio entre los resultados de Goeke & Schneider (2015) y las soluciones con menor distancia que se obtuvieron en este proyecto. Posteriormente, la Tabla 6 presenta el promedio de número de vehículos utilizados en las soluciones con menor distancia y en aquellas de Goeke & Schneider (2015). Por último, la Tabla 7 muestra los tiempos de ejecución promedio (en minutos) de una corrida individual del algoritmo de Goeke & Schneider (2015) y de cada corrida individual del algoritmo NSGA-II, correspondiente a los experimentos realizados en este proyecto. El equipo de cómputo usado por Goeke & Schneider (2015) fue una computadora de escritorio con procesador Intel Core i7 (2.8 GHz), memoria RAM de 8 GB y sistema operativo Windows 7.

4.2.1. Experimento con flota convencional

Como un acercamiento inicial al problema de enrutamiento de vehículos y con el fin de obtener un conjunto de soluciones base, el primer experimento consistió en resolver los casos de prueba permitiendo el uso de vehículos convencionales de manera exclusiva para generar las rutas. Los resultados de este experimento permitieron posteriormente medir el impacto en calidad que tiene el uso de una flota mixta para la solución de los mismos casos de prueba.

Tabla 5. Comparación de distancia entre soluciones obtenidas con menor distancia y resultados de Goeke & Schneider (2015).

Casos	Goeke & Schneider (2015)	Convencional	Max-Electric	Balanced V1	Balanced V2	No-Stations
UK50	1414.38	0.73 %	14.36 %	5.18 %	3.71 %	11.91 %
UK75	2041.48	1.86 %	21.44 %	8.56 %	4.85 %	12.33 %
UK100	2564.57	4.62 %	34.40 %	14.39 %	8.65 %	13.78 %
UK150	3639.39	9.43 %	52.03 %	19.18 %	13.41 %	17.89 %
UK200	4517.46	14.47 %	65.79 %	24.65 %	19.31 %	22.34 %

Al revisar la Tabla 5, se observa que las soluciones con menor distancia obtenidas con flota convencional no mejoran las distancias obtenidas por Goeke & Schneider (2015), donde se considera una flota mixta. Esta diferencia en distancia, que va del 0.73 % (casos de 50 clientes) al 14.47 % (casos de 200 clientes), demuestra que las soluciones obtenidas son de peor calidad que aquellas obtenidas por Goeke & Schneider (2015), en términos de distancia. Sin embargo, el enfoque de ambos proyectos es diferente. Goeke & Schneider (2015) resuelven el VRP con flota mixta bajo un enfoque mono-objetivo, optimizando la distancia total recorrida mediante la implementación de un algoritmo de búsqueda de vecindario adaptativa, donde una solución inicial se va mejorando con cada iteración. Por otro lado, en este proyecto se resuelve el VRP con un enfoque multi-objetivo, optimizando distancia total recorrida y tiempo de espera, empleando el algoritmo de optimización NSGA-II, en el cual se evoluciona un conjunto de soluciones con cada iteración.

Respecto al número de vehículos, la Tabla 6 muestra que en los casos de 100 clientes en adelante, hay un aumento en el número total de vehículos utilizados, por parte de las soluciones obtenidas con flota convencional. De estos subconjuntos de casos de prueba, en 2 de cada 20 soluciones la flota convencional utiliza un vehículo más que la flota mixta de Goeke & Schneider (2015). Para los subconjuntos de 50 y 75 clientes, la flota convencional utiliza un vehículo menos, en 1 de cada 20 soluciones.

Tabla 6. Comparación de número de vehículos entre soluciones obtenidas con menor distancia y resultados de Goeke & Schneider (2015).

Casos	Goeke & Schneider (2015)		Convencional		Max-Electric		Balanced V1		Balanced V2		No-Stations	
	nVC	nVE	nVC	nVE	nVC	nVE	nVC	nVE	nVC	nVE	nVC	nVE
UK50	3.9	3.15	7	0	2	5.3	3.9	3.15	3.95	3.15	4.45	4.05
UK75	5.4	5	10.35	0	2.7	7.85	5.5	5	5.5	5	6.7	5.6
UK100	6.95	6.45	13.5	0	3.15	10.6	7	6.45	6.95	6.45	8.75	6.95
UK150	10.2	9.85	20.15	0	2.85	17.85	10.2	9.85	10.25	9.85	12.8	10.85
UK200	13.55	12.8	26.45	0	3.55	23.65	13.65	12.8	13.7	12.8	15.1	16

Tabla 7. Tiempo de ejecución promedio (en minutos) por corrida individual y total de corridas, del algoritmo de Goeke & Schneider (2015) y de los algoritmos propuestos.

Casos	Goeke & Schneider (2015)		Convencional		Max-Electric		Balanced V1		Balanced V2		No-Stations	
	1	10	1	30	1	30	1	30	1	30	1	30
UK50	1.37	13.68	0.17	5.00	0.19	5.80	0.19	5.75	0.20	5.95	0.18	5.44
UK75	2.88	28.76	0.24	7.22	0.27	8.01	0.27	8.20	0.29	8.57	0.25	7.42
UK100	6.70	67.05	0.33	9.91	0.35	10.64	0.39	11.56	0.39	11.65	0.32	9.70
UK150	11.91	119.12	0.59	17.78	0.60	17.87	0.67	20.24	0.70	20.96	0.54	16.15
UK200	16.71	167.15	0.98	29.39	0.87	25.99	1.04	31.30	1.06	31.71	0.82	24.63

En cuanto a tiempo de ejecución, el algoritmo de Goeke & Schneider (2015) requirió de 1.37 a 16.71 minutos para una corrida individual de su algoritmo y de 13.68 a 167.15 minutos para 10 corridas, de las cuales reportan el mejor resultado obtenido. En este experimento, cada ejecución del algoritmo NSGA-II tomó de 0.17 a 0.98 minutos y de 5 a 29.29 minutos para 30 corridas, de las cuáles también se reporta la menor distancia conseguida. Esta diferencia en tiempos de ejecución, indica que el experimento con flota convencional requiere de 64 % a 82 % menos tiempo que el realizado por Goeke & Schneider (2015).

4.2.2. Experimento con flota mixta max-eléctrica

El siguiente experimento consistió en resolver los casos de prueba utilizando el algoritmo Max-Electric, con lo cual se buscaba conseguir soluciones con una flota compuesta en mayor parte por vehículos eléctricos. Estos resultados son relevantes para comparar ambos extremos de la conformación de flotas: una flota convencional y una flota casi completamente eléctrica. De esta forma, se puede analizar el impacto en las funciones objetivo, que tendría buscar la mayor reducción de emisiones de CO₂ al priorizar el uso de vehículos eléctricos.

La Tabla 5 muestra que todos los resultados, las soluciones Max-Electric presentan el mayor aumento en distancia en todos los subconjuntos de casos de prueba, partiendo de un 14.36 % en casos de 50 clientes, hasta un 65.79 % en los casos de 200 clientes. Este aumento en distancia era esperado, ya que usar más vehículos eléctricos conlleva visitar más estaciones de recarga, lo que genera desviaciones que suman al total de distancia recorrida.

Revisando la Tabla 6, se puede identificar la característica principal de esta flota mixta, donde los vehículos eléctricos conforman del 72 % al 87 % de la flota, encontrando no más de 5 vehículos convencionales por solución. En cuanto al número total de vehículos, la flota max-eléctrica utiliza más vehículos que la flota convencional y que las soluciones de Goeke & Schneider (2015), llegando a tener hasta dos vehículos más por caso.

Al igual que con el experimento anterior, los tiempos de ejecución en este experimento fueron menores que los de Goeke & Schneider (2015). Esta condición se mantiene en los experimentos siguientes, dado que en todos ellos se utilizó el mismo algoritmo de optimización (NSGA-II) con los mismos parámetros. Por lo tanto, las diferencias de tiempo entre cada experimento dependen directamente del algoritmo de decodificación utilizado.

4.2.3. Experimento con flota mixta equilibrada

El objetivo de los experimentos con flota equilibrada fue obtener soluciones que emplearan una flota mixta con las mismas características que aquella planteada por Goeke & Schneider (2015), es decir, soluciones donde la cantidad de vehículos eléctricos no supera la mitad de la flota. Además, estos resultados representan un punto medio respecto a la composición de las flotas estudiadas anteriormente. Para estos experimentos se utilizaron los algoritmos Balanced V1 y V2, con el fin de comparar ambas estrategias en términos de calidad de las soluciones (distancia y tiempo de espera) y también averiguar cuál de las dos produce la mayor reducción de emisiones de CO₂ (Capítulo 5), en comparación con los resultados de la flota convencional.

Observando la Tabla 5, se encontró que las soluciones Balanced V2 presentan los mejores resultados en distancia en comparación con las demás flotas mixtas, sin superar lo conseguido por Goeke & Schneider (2015) ni las distancias de la flota convencional. Por su parte, las soluciones obtenidas con el algoritmo Balanced V1 se ubican con el segundo lugar para los casos de 50 y 75 clientes y con el tercer lugar en los casos restantes, siendo superado por los resultados del algoritmo No-Stations. La diferencia entre las

distancias conseguidas usando ambos algoritmos corresponde al comportamiento descrito en el Capítulo 3, donde la flota equilibrada V1 se caracteriza por asignar la mayor cantidad de nodos alcanzables a rutas eléctricas, mientras que la flota equilibrada V2 se caracteriza por asignar nodos alcanzables a rutas convencionales o eléctricas, buscando minimizar distancia.

Siguiendo con las características de los algoritmos Balanced, el número de vehículos eléctricos utilizados es idéntico al de la flota de Goeke & Schneider (2015), como lo muestra la Tabla 6. Sin embargo, el número de vehículos convencionales difiere ligeramente, al utilizar un vehículo extra en uno o dos de las 20 soluciones de cada subconjunto de casos.

De igual forma, los tiempos de ejecución reflejan las propiedades de estos algoritmos, al observar que cuando se utiliza Balanced V2 se requiere un poco más de tiempo que con Balanced V1. Esto se debe a que en el algoritmo Balanced V2, cuando se quiere asignar un cliente alcanzable, se analiza la posibilidad de agregarlo a cualquiera de las rutas disponibles sin importar el tipo, mientras que en Balanced V1 primero se intenta asignar a una ruta eléctrica y sólo cuando no es posible se verifican las rutas convencionales.

4.2.4. Experimento con flota mixta sin estaciones

La última serie de experimentos consistió en resolver los casos de prueba usando el algoritmo de decodificación No-Stations. La motivación detrás de estos experimentos es la de obtener soluciones que reflejen la situación actual alrededor del uso de vehículos eléctricos, donde la disponibilidad de estaciones de recarga es limitada y usualmente cada empresa recarga sus vehículos dentro de su centro de distribución. Además, dado que las emisiones indirectas de CO₂ provienen de la recarga de batería, surgió la inquietud por averiguar si al restringir esta actividad fuera de la central, las emisiones disminuirían en comparación con las demás flotas mixtas (Capítulo 5).

Referente a la distancia, la Tabla 5 muestra que los resultados de este experimento son mejores que los conseguidos con Balanced V1 a partir de los casos de 100 clientes, sin llegar a mejorar lo obtenido con Balanced V2. Al comparar el número total de vehículos utilizados, estos resultados destacan por ser los que más vehículos utilizan, llegando a emplear hasta 6 más que lo reportado por Goeke & Schneider (2015). Este aumento en el número de vehículos era esperado debido a que con la restricción de visitas a estaciones de recarga, serían necesarios más vehículos eléctricos para visitar a los clientes alcanzables desde la central. En cuanto a la proporción de vehículos, la Tabla 6 indica que los vehículos eléctricos

componen del 44 % al 51 % de la flota, lo cual se asemeja a la flota mixta equilibrada pero en este caso sin haberlo definido deliberadamente en el algoritmo.

4.3. Comparación de frentes consolidados

Como se describe en la Sección 4.1, el frente consolidado de cada experimento se origina al encontrar el frente no dominado del conjunto de todas las soluciones resultantes de las múltiples ejecuciones del algoritmo NSGA-II. La comparación y análisis de los frentes consolidados, permite conocer el impacto que tiene en las funciones objetivo, el uso de las flotas mixtas sobre el uso de una flota convencional. Este impacto se puede observar al comparar los resultados de distancia y tiempo de espera de la flota convencional contra los resultados de las flotas mixtas. Además, aplicando el concepto de dominancia y la métrica de cubrimiento de conjunto, es posible identificar cuál de las flotas es mejor que las demás, en términos de minimización de las funciones objetivo.

A continuación, por cada subconjunto de casos de prueba se analizarán los frentes consolidados resultantes de cada experimento. El código de colores utilizado en las figuras es el siguiente: (Azul) Soluciones con flota convencional; (Verde) Soluciones Max-Electric; (Rojo) Soluciones Balanced V1; (Rojo oscuro) Soluciones Balanced V2; (Amarillo) Soluciones No-Stations. Para todas las gráficas, el eje horizontal corresponde a la distancia total recorrida en kilómetros y el eje vertical corresponde al tiempo de espera en segundos.

4.3.1. Casos de 50 clientes

Empezando con los casos de 50 clientes, se encontró que las soluciones con flota convencional dominan entre el 60 % y el 100 % de las soluciones de cada flota mixta, cubriendo completamente a estos frentes en 8 de 20 casos. Como se observó en la sección 4.2, la flota convencional obtiene en todos los casos la solución con menor distancia recorrida, mientras que las soluciones No-Stations consiguen la mayor distancia recorrida en el 75 % de los casos, con las soluciones Max-Electric ocupando el 20 % y la flota convencional aportando la mayor distancia en uno de los casos.

Por su parte, las flotas equilibradas consiguen la menor distancia de todas las flotas mixtas, destacando las soluciones obtenidas con el algoritmo Balanced V2, que se posicionan con la menor distancia recorrida

en el 85 % de los casos. Por último, las distancias de las soluciones con restricción de recarga se asemejan a las soluciones Max-Electric, dominando parcialmente el frente Balanced V1 en 2 de 20 casos.

Para este subconjunto de casos de 50 clientes se encontraron cinco patrones al comparar los frentes consolidados de las flotas estudiadas. La Figura 14 muestra por cada patrón un ejemplo que representa sus características. El Patrón A, presente en el 40 % de los casos, tiene la característica de presentar un traslape entre los frentes consolidados de flota convencional y las flotas equilibradas, donde el frente de una flota equilibrada domina parcialmente el frente de la flota convencional, especialmente en las soluciones con menor tiempo de espera. Esto indica que en el 40 % de los casos, se encontraron soluciones con flota mixta cuya distancia recorrida es menor que las soluciones con flota convencional, con tiempos de espera similares y cercanos a cero.

El Patrón B, presente en el 20 % de los casos, muestra un traslape cerca del tiempo de espera cero entre los frentes consolidados de las flotas equilibradas. Este traslape se caracteriza porque uno de los frentes suele dominar las soluciones con menor tiempo de espera del otro frente. De igual forma, el Patrón C también muestra un traslape entre estos dos frentes, con la diferencia de que éste se da desde la mitad superior del frente.

El Patrón D, se caracteriza por no presentar un traslape entre los frentes de flota convencional y flotas equilibradas, observando una separación entre cada conjunto de soluciones. En los tres casos donde se identifica este patrón, se encontró también que el frente Balanced V2 domina completamente a los demás frentes de flota mixta. La superioridad de las soluciones Balanced V2 sobre todos los demás resultados con flota mixta, se presenta en dos casos más, incluyendo el correspondiente al Patrón E, donde todos los frentes consolidados se encuentran separados entre sí.

Se encontró un patrón adicional, identificado en 19 de los 20 casos, donde el frente consolidado de la flota max-eléctrica domina las soluciones con menor tiempo de espera de la flota con restricción de recargas. Este patrón es visible en los cinco ejemplos de la Figura 14 y en él se incluyen casos donde el frente Max-Electric domina desde sólo un par de soluciones (Figura 14(b)) hasta el frente No-Stations completo (14(c)). La razón de este comportamiento es que en el 80 % de los casos las soluciones con restricción de recargas no alcanzan el tiempo de espera cero, además de que en la mayoría de los casos, la solución con menor tiempo de espera también es la solución con mayor distancia de todas las flotas.

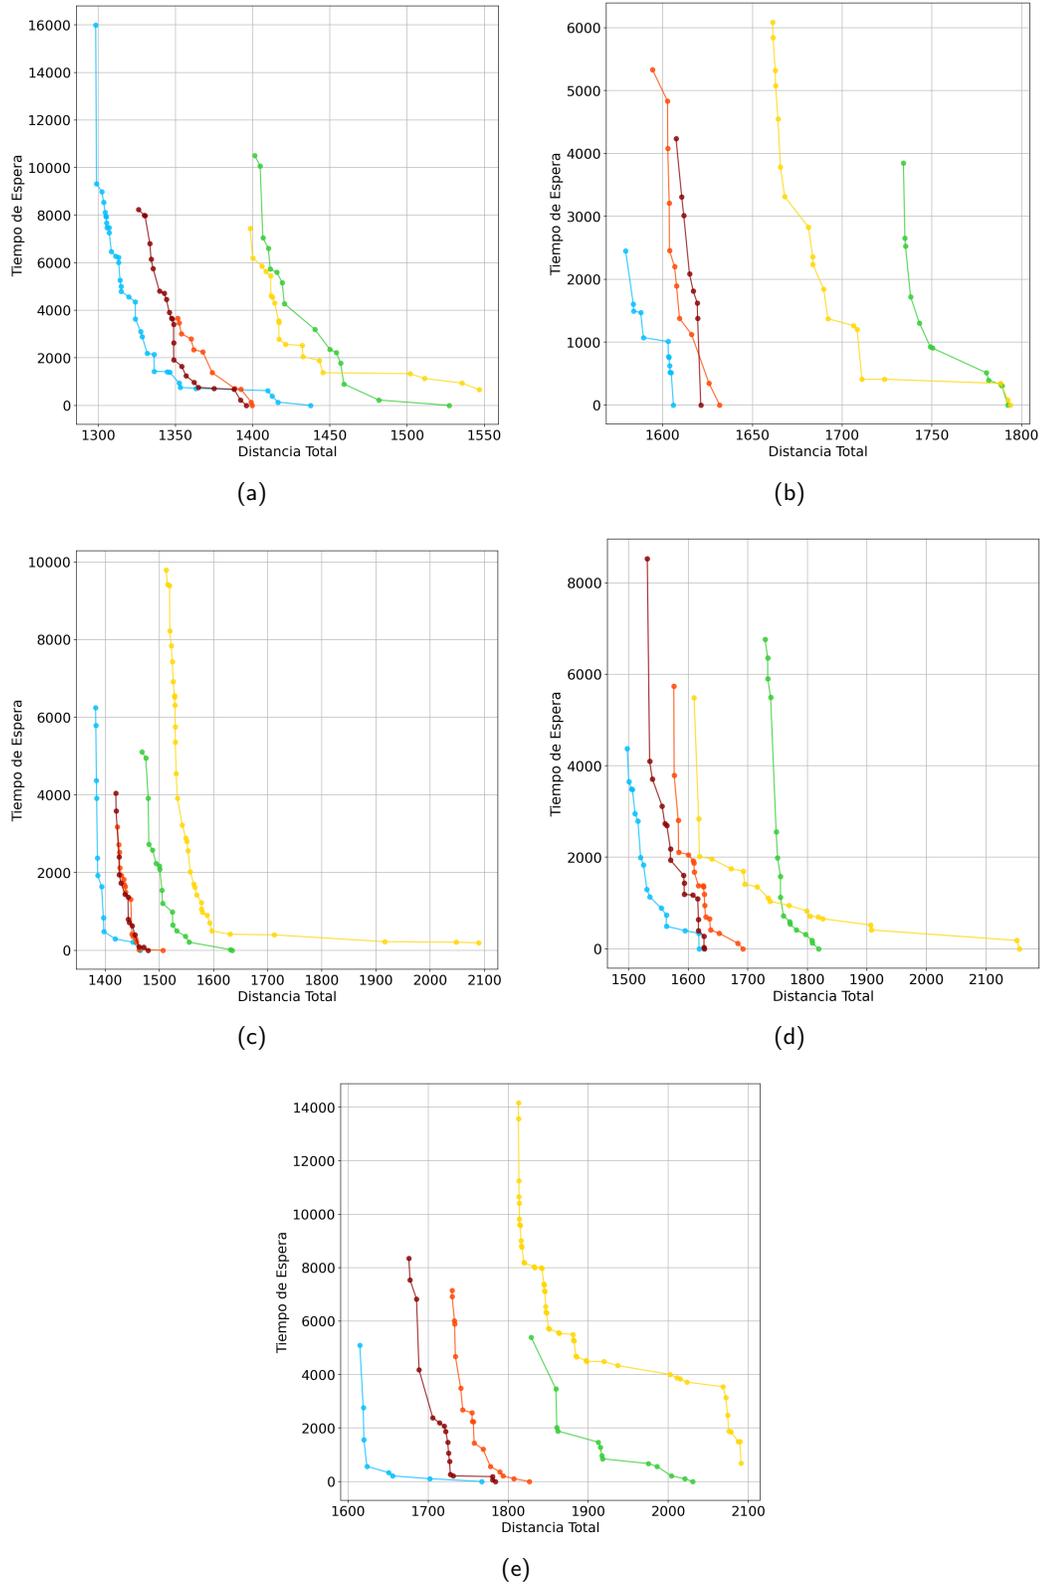


Figura 14. Frentes consolidados para casos UK50. (a) Patrón A, caso UK50_06; (b) Patrón B, caso UK50_10; (c) Patrón C, caso UK50_15; (d) Patrón D, caso UK50_11; (e) Patrón E, caso UK50_09. Color de frente: Convencional (Azul), Max-electric (Verde), Balanced V1 (Rojo), Balanced V2 (Rojo Oscuro), No-Stations (Amarillo).

4.3.2. Casos de 75 a 150 clientes

Para los casos de 75 a 100 clientes, se presenta un análisis de los escenarios característicos de cada comparativa de frentes consolidados, correspondiente a cada experimento. La Figura 15 muestra dos ejemplos por cada subconjunto de casos, ilustrando los patrones más notables. Una de las principales observaciones para estos casos es la mejora en calidad de las soluciones obtenidas con el algoritmo No-Stations, en términos de distancia recorrida.

Para los casos de 75 de clientes, la comparativa de los frentes consolidados es similar a la de 50 clientes. El patrón que se encontró con mayor frecuencia es el Patrón A, identificado en el 80 % de los casos, donde se observa una separación clara entre los frentes de flota convencional y flota equilibrada, en ocasiones presentando un traslape entre estos tres frentes, cerca del tiempo de espera cero. En 12 de 20 casos, se repite el escenario de los casos de 50 clientes donde el frente Max-Electric domina las soluciones No-Stations con menor tiempo de espera. Sin embargo, ahora el frente amarillo domina parcialmente a las soluciones con flota equilibrada en el 20 % de los casos, como se observa en el Patrón B (15(b)).

Respecto a los casos de 100 clientes, el patrón presente en el 50 % de los casos es representado por la Figura 15(c), donde se observa con mayor claridad la separación entre frentes, siguiendo la secuencia de izquierda a derecha: Convencional, Balanced V2, Balanced V1, No-Stations y Max-Electric, respectivamente.

De igual forma, se mantiene un traslape en las soluciones más cercanas al tiempo de espera cero, en el que en comparación con los casos anteriores, ahora se detecta un mayor número de soluciones azules siendo dominadas por frentes de flota mixta. Mientras tanto el Patrón B, identificado en la otra mitad de los casos, presenta al frente No-Stations dominando parcialmente a los frentes de flota equilibrada, principalmente a las soluciones Balanced V1.

En casos de 150 clientes, el Patrón A (15(e)) muestra al frente No-Stations dominando parcialmente soluciones de flota equilibrada en el 70 % de los casos, lo cual representa una mejora notable en la calidad de las soluciones de este experimento en comparación con su desempeño en los casos de 50 clientes. Por su parte, en el Patrón B aún se observa la organización de los frentes bajo la secuencia Convencional, Balanced V2, Balanced V1, No-Stations y Max-Electric. Sin embargo, la separación entre ellos nos es tan clara como anteriormente, detectando traslapes más complejos en soluciones cercanas al tiempo de espera cero.

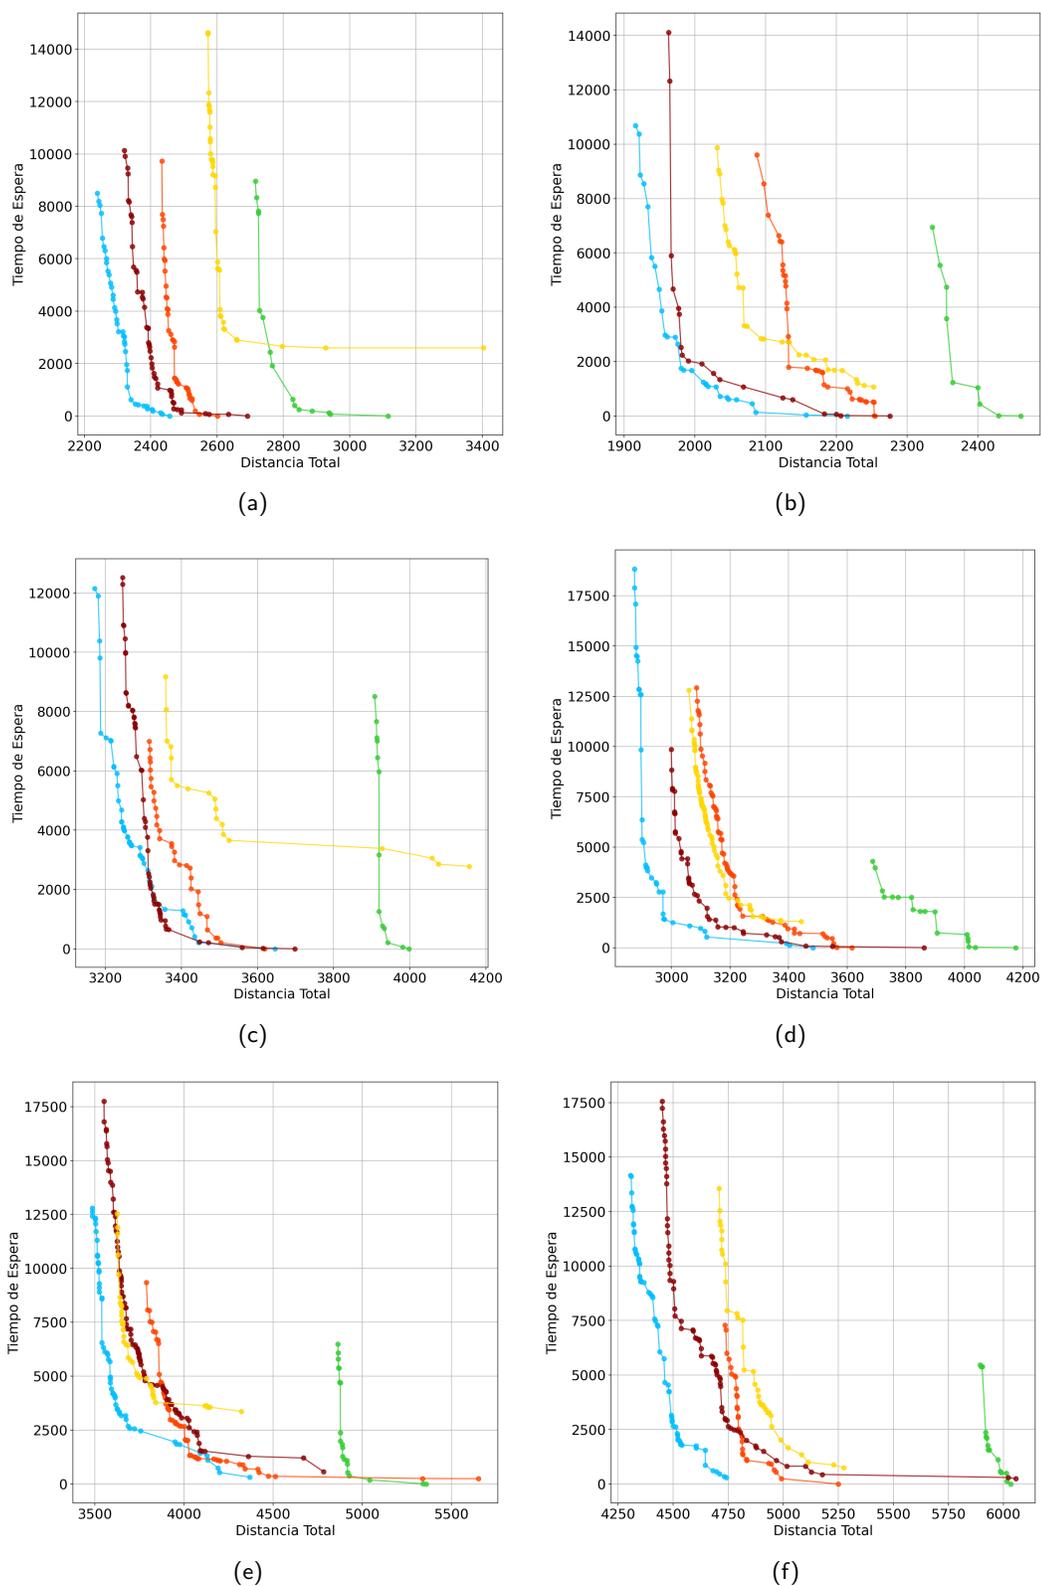


Figura 15. Frentes consolidados para casos UK75, UK100 y UK150. (a) Patrón UK75 A, caso UK75_07; (b) Patrón UK75 B, caso UK75_18; (c) Patrón UK100 A, caso UK100_15; (d) Patrón UK100 B, caso UK100_11; (e) Patrón UK150 A, caso UK150_15; (f) Patrón UK150 B, caso UK150_12. Color de frente: Convencional (Azul), Max-electric (Verde), Balanced V1 (Rojo), Balanced V2 (Rojo Oscuro), No-Stations (Amarillo).

4.3.3. Casos de 200 clientes

Para los casos más grandes del conjunto de casos de prueba, se encontró que la principal característica visual de esta comparativa, es el traslape entre los frentes Convencional, Balanced V2, Balanced V1 y No-Stations, el cual hace más difícil decidir cuál flota mixta es mejor que las demás. También, en comparación con los resultados anteriores, se observó una mejora de calidad en el frente No-Stations, llegando a dominar soluciones de la flota convencional en siete casos. Por su parte, el frente azul sigue obteniendo las soluciones con la menor distancia en cada caso.

Para este análisis, se identificaron cinco patrones que reflejan los escenarios más comunes encontrados en los 20 casos de prueba. El primer patrón, Patrón A, corresponde a casos en los que el frente convencional se ve dominado parcialmente por uno o varios frentes de flota mixta. Esta situación se presenta en el 85 % de los casos y confirma un patrón general en los resultados del conjunto de casos de prueba: conforme aumenta el número de clientes, más soluciones del frente convencional son dominadas por soluciones con flota mixta.

En el Patrón B, presente en el 70 % de los casos, se observa que el frente No-Stations domina parcialmente a los frentes de flota equilibrada. Mientras que en el 30 % restante, se identificó el Patrón C, donde los frentes de flota equilibrada dominan completamente las soluciones con restricción de recarga.

En seis casos se identificó el Patrón D, el cual muestra al frente Max-Electric dominando a las soluciones con menor tiempo de espera de la flota convencional y las flotas equilibradas. En todos los casos, este frente consiguió los menores tiempos de espera, llegando a obtener tiempo de espera cero en el 80 % de los casos. En los demás frentes no se encontraron soluciones con esa característica, por lo que el frente Max-Electric nunca es dominado completamente.

Por último, el Patrón E, identificado en 4 de los 20 casos, describe un escenario en donde ninguno de los cinco frentes es dominado completamente, es decir, cada uno de ellos tiene por lo menos una solución no dominada. Por lo tanto, si se unen las soluciones de todos los frentes en un solo conjunto y a partir de él se obtiene el frente no dominado, éste se conformaría de soluciones de todos los algoritmos.

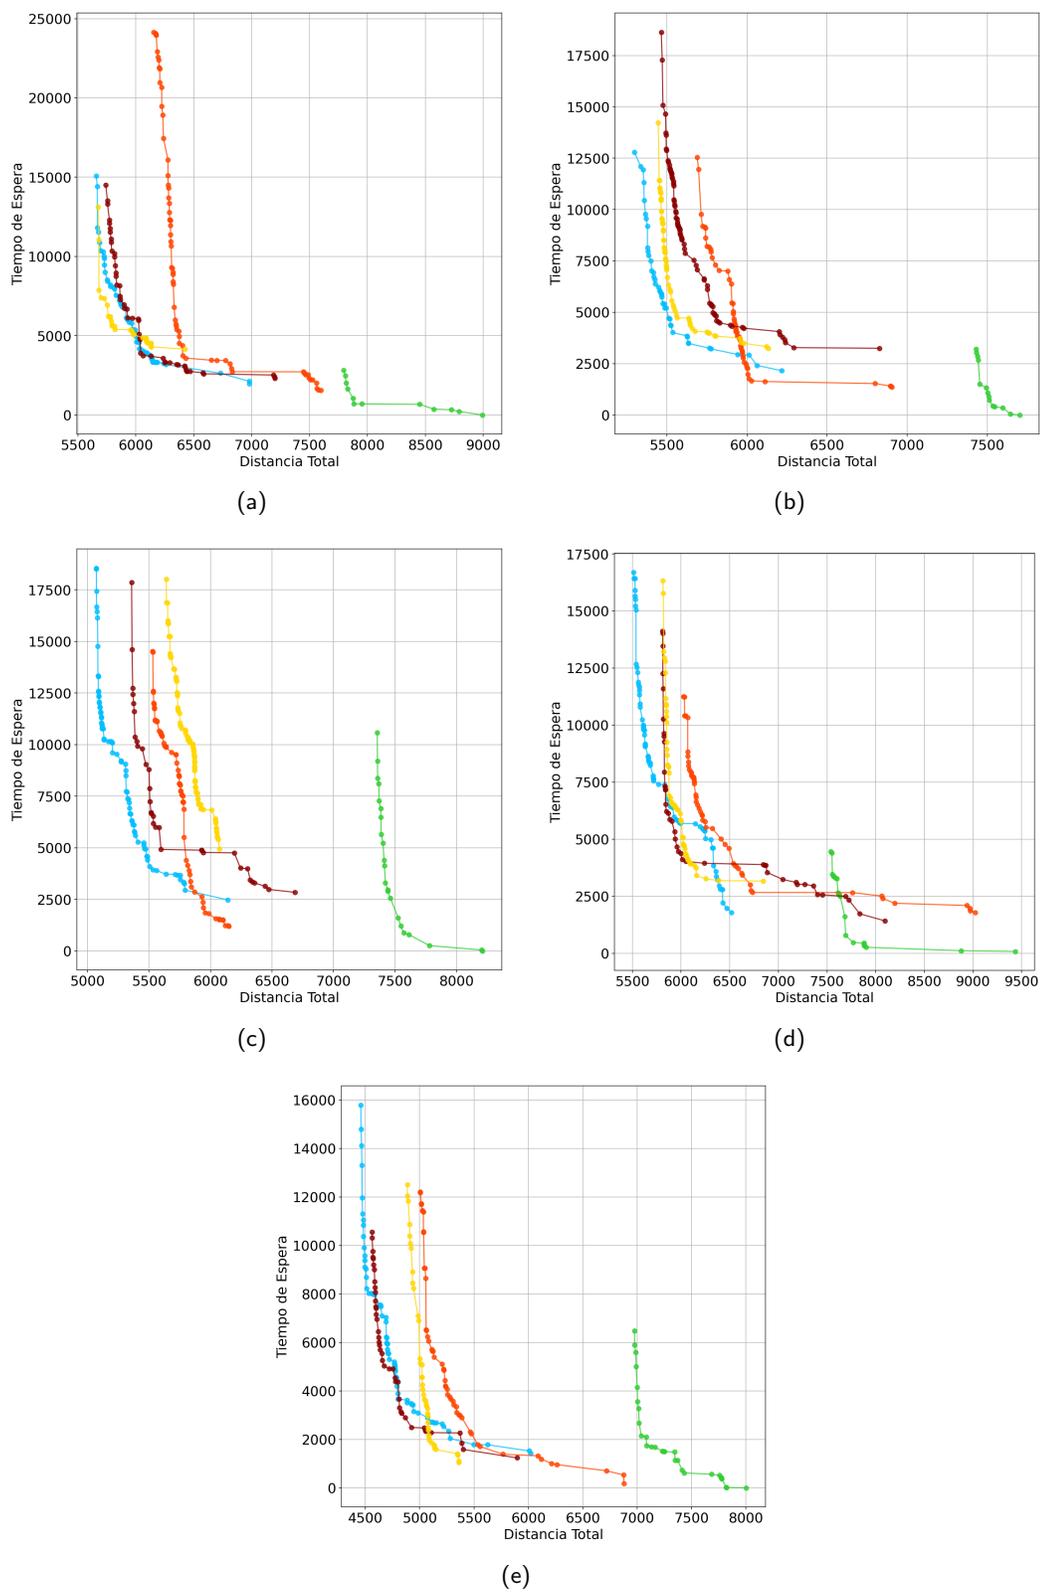


Figura 16. Frentes consolidados para casos UK200. (a) Patrón A, caso UK200_13; (b) Patrón B, caso UK200_01; (c) Patrón C, caso UK200_18; (d) Patrón D, caso UK200_20; (e) Patrón E, caso UK200_19. Color de frente: Convencional (Azul), Max-electric (Verde), Balanced V1 (Rojo), Balanced V2 (Rojo Oscuro), No-Stations (Amarillo).

4.4. Análisis de distancia y tiempo de espera

Después de analizar visualmente los frentes consolidados de cada experimento, en esta sección se revisarán con mayor detalle las características de cada flota mixta que producen la variación de distancia y tiempo de espera, con respecto a los resultados de la flota convencional. Empezando con la Tabla 8, ésta muestra los resultados de distancia recorrida (en kilómetros) y tiempo de espera (en segundos) de las soluciones con menor distancia, obtenidas de cada experimento. Estas soluciones se ubican en el extremo superior izquierdo de cada frente consolidado y representan la mejor solución en distancia para cada flota.

Tabla 8. Resultados de soluciones con mejor distancia.

Casos	Convencional		Max-Electric		Balanced V1		Balanced V2		No-Stations	
	Distancia	T. Espera	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.
UK50	1423.77	8934.12	13.56 %	-3887.46	4.45 %	-2263.20	2.99 %	-1626.55	11.12 %	767.01
UK75	2078.55	9767.31	19.21 %	-4908.21	6.57 %	-1959.94	2.94 %	-924.63	10.28 %	239.14
UK100	2683.34	11065.24	28.52 %	-5003.81	9.37 %	-2103.52	3.86 %	-1827.35	8.77 %	62.17
UK150	3980.02	14272.54	38.95 %	-8095.05	8.93 %	-5400.19	3.66 %	-2830.16	7.73 %	-3228.37
UK200	5174.02	16476.63	44.92 %	-9036.65	8.92 %	-1979.98	4.25 %	1198.94	6.90 %	-2125.70

En general, se observa que para la mayoría de los casos, el uso de flotas mixtas reduce los tiempos de espera pero aumentan la distancia recorrida, desde un 3 % (Balanced V2) hasta un 45 % (Max-Electric). La flota max-eléctrica destaca entre las demás, por obtener en todos los subconjuntos de casos la mayor reducción de tiempo de espera, pero también el mayor aumento en distancia. De las flotas equilibradas, las soluciones Balanced V1 presentan los menores tiempos de espera, mientras que las soluciones Balanced V2 presentan la menor diferencia en distancia respecto a la flota convencional. Por su parte, la flota con restricción de recargas es la única en mostrar un aumento en el tiempo de espera para los primeros tres subconjuntos de casos de prueba. Sin embargo, la reducción de tiempo que consigue para los casos de 150 y 200 clientes, es mejor que la obtenida con las soluciones Balanced V2.

Analizando ahora el otro extremo de los frentes consolidados, la Tabla 9 muestra los resultados de las soluciones con menor tiempo de espera, es decir, las soluciones ubicadas en el extremo inferior derecho de cada frente consolidado, representando la solución con mejor tiempo de espera de cada experimento. Comenzando con la flota max-eléctrica, ésta consigue tiempos de espera cero en 3 subconjuntos de casos de prueba (75, 100, 150), seguida de la flota equilibrada V1 que elimina los tiempos de espera en los casos de 50 y 75 clientes. En resumen, la flota max-eléctrica y ambas flotas equilibradas, logran reducir los tiempos de espera de las soluciones con menor tiempo de espera de la flota convencional,

pero presentan un aumento en la distancia recorrida de hasta un 32.44 % con Max-Electric, 14.48 % con Balanced V1 y 6.3 % con Balanced V2.

Tabla 9. Resultados de soluciones con mejor tiempo de espera.

Casos	Convencional		Max-Electric		Balanced V1		Balanced V2		No-Stations	
	Distancia	T. Espera	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.
UK50	1597.53	11.55	10.57 %	-2.35	1.23 %	-11.55	0.97 %	-6.06	17.75 %	881.42
UK75	2410.04	55.58	10.98 %	-55.58	0.81 %	-55.58	-0.46 %	-35.42	15.11 %	641.92
UK100	3424.56	166.45	10.78 %	-166.45	-1.32 %	-152.85	2.79 %	-105.53	3.54 %	1370.29
UK150	5137.55	585.94	15.59 %	-585.94	8.31 %	-433.04	6.30 %	-195.58	1.14 %	1623.45
UK200	6377.17	2305.05	32.44 %	-2280.39	14.48 %	-1011.18	5.80 %	-102.83	-1.66 %	1871.94

Sin embargo, al comparar estos resultados con las mejores soluciones en distancia de la flota convencional (ver Tabla 10), se observa que el aumento en distancia es mucho mayor. Las soluciones Max-Electric presentan una diferencia que va del 24.35 % al 62.75 % pero reducen más del 99 % del tiempo de espera. Ambas flotas equilibradas inician con un aumento de 13 % en los casos de 50 clientes, con las soluciones Balanced V1 alcanzando un aumento de 41 % y Balanced V2 llegando a 37 %.

Tabla 10. Resultados de solución con mejor distancia de flota convencional y soluciones con mejor tiempo de espera de flotas mixtas.

Casos	Convencional		Max-Electric		Balanced V1		Balanced V2		No-Stations	
	Distancia	T. Espera	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.	Dif. Dist.	Dif. TE.
UK50	1423.77	8934.12	24.35 %	-8924.92	13.67 %	-8934.12	13.44 %	-8928.63	32.35 %	-8041.15
UK75	2078.55	9767.31	29.20 %	-9767.31	17.34 %	-9767.31	15.83 %	-9747.15	32.89 %	-9069.81
UK100	2683.34	11065.24	41.50 %	-11065.24	25.90 %	-11051.64	31.24 %	-11004.32	31.99 %	-9528.50
UK150	3980.02	14272.54	48.91 %	-14272.54	39.69 %	-14119.63	36.57 %	-13882.17	29.95 %	-12063.14
UK200	5174.02	16476.63	62.75 %	-16451.97	40.89 %	-15182.77	29.99 %	-14274.42	20.68 %	-12299.65

Volviendo a la Tabla 9, la flota con restricción de recargas es la única que presenta en promedio un aumento en el tiempo de espera en todos los subconjuntos de casos de prueba, a excepción del último. En los primeros dos subconjuntos, el aumento en tiempo de espera, en conjunto con el aumento en distancia (el mayor de entre las cuatro flotas mixtas), es la razón por la que las soluciones con menor tiempo de espera del frente amarillo son dominadas por los demás frentes en los casos de 50 y 75 clientes.

Al igual que en las soluciones con menor distancia (Tabla 8), se observa que en las soluciones No-Stations la diferencia de distancia disminuye conforme aumenta el número de clientes. Este comportamiento indica que para un mayor número de clientes, el algoritmo de decodificación No-Stations genera mejores conjuntos de rutas en términos de distancia. Patrones como este y otros encontrados durante el análisis

de resultados son comentados en la sección 4.5.

En la Tabla 10, las soluciones No-Stations presentan un aumento de distancia de aproximadamente 32 % en los casos de prueba de 50, 75 y 100 clientes, mientras que para los casos de 150 y 200 clientes presentan un aumento de 29.95 % y 20.68 %, respectivamente. Este último par de resultados, representan las menores distancias de las soluciones con mejor tiempo de espera de las cuatro flotas mixtas. Este impacto en distancia trae consigo una reducción de 84 % y 74 % en los tiempos de espera, la cual es superada por los resultados de las demás flotas.

Por lo tanto, si se estuviera siguiendo el conjunto de rutas definido por la solución con menor distancia de la flota convencional y se deseara cambiar vehículos convencionales por eléctricos en la flota, y además, reducir lo más posible los tiempos de espera, el nuevo conjunto de rutas presentaría un aumento en distancia de entre 13.44 % y 62.75 %, a cambio de una reducción en los tiempos de espera de 74 % hasta 100 %. En caso de que se deseara cambiar vehículos convencionales por eléctricos y reducir lo más posible la distancia recorrida, la nueva flota tendría que recorrer de un 3 % a un 45 % más distancia y el tiempo de espera se reduciría de un 9 % a un 57 %, o en algunos casos aumentaría de 1 % a 9 %.

Además de la evaluación de cada flota como un solo conjunto, revisar el desempeño de cada tipo de vehículo permite conocer a detalle su aportación en distancia y tiempo de espera, lo cual también ayuda a entender el impacto, en las funciones objetivo, de incluir vehículos eléctricos y cómo éste varía con cada algoritmo de decodificación. La Tabla 11 muestra el aporte promedio a cada función objetivo de los vehículos convencionales y eléctricos, por cada subconjunto de casos de prueba. Posteriormente, en la Tabla 12 se presenta la distancia promedio recorrida por cada vehículo convencional y eléctrico de forma individual.

Tabla 11. Aportación promedio de los vehículos eléctricos al tiempo de espera y distancia total.

Casos	Max-Electric		Balanced V1		Balanced V2		No-Stations	
	%T.Espera VE	%Dist.VE						
UK50	82.44 %	64.53 %	59.74 %	40.59 %	50.74 %	40.77 %	80.85 %	26.54 %
UK75	83.97 %	68.92 %	59.80 %	45.22 %	53.19 %	42.88 %	79.40 %	25.68 %
UK100	89.69 %	74.51 %	51.77 %	48.61 %	47.60 %	46.97 %	82.07 %	24.79 %
UK150	95.41 %	85.03 %	57.23 %	51.01 %	46.72 %	49.44 %	83.10 %	27.40 %
UK200	93.80 %	85.29 %	59.57 %	51.63 %	54.48 %	49.10 %	86.08 %	31.83 %

La Tabla 11 permite comparar la aportación de distancia y tiempo de espera de cada tipo de vehículo con su aportación en cuanto a número de vehículos en la flota, reportada en la Tabla 13. Empezando con la flota max-eléctrica, en ésta los vehículos eléctricos conforman del 72 % al 87 % de la flota, aportando

del 64.53 % al 85.29 % de la distancia total recorrida y de 82.44 % al 93.8 % del tiempo de espera. La relación entre composición de la flota y aporte a la distancia recorrida parece coherente, aunque revisando la Tabla 13 se observa que en promedio cada vehículo convencional recorre más kilómetros que uno eléctrico. Esto se puede deber a que el algoritmo trata de asignar solamente nodos inalcanzables a rutas convencionales y estos suelen encontrarse alejados entre sí.

Tabla 12. Distancia promedio por tipo de vehículo.

Casos	Convencional	Max-Electric		Balanced V1		Balanced V2		No-Stations	
	Dist.x.VC	Dist.x.VC	Dist.x.VE	Dist.x.VC	Dist.x.VE	Dist.x.VC	Dist.x.VE	Dist.x.VC	Dist.x.VE
UK50	210.48	276.96	206.40	231.28	196.93	226.59	194.87	270.81	102.83
UK75	207.61	292.74	221.67	229.18	206.15	230.92	190.43	265.03	104.05
UK100	211.34	279.23	250.69	223.39	229.10	222.49	213.57	260.71	106.20
UK150	208.20	306.90	265.22	217.91	237.55	213.60	218.86	253.29	108.30
UK200	206.58	320.17	277.66	210.64	240.03	211.60	218.08	257.35	109.67

Pasando a las flotas equilibradas, la Tabla 13 confirma que el número de vehículos eléctricos no supera la mitad de la composición de la flota, manteniéndose entre un 44 % y un 50 %. En cuanto a su aporte a las funciones objetivo, se reporta que los vehículos eléctricos aportan del 40 % al 52 % de la distancia recorrida y del 46 % al 60 % del tiempo de espera. En ambas flotas se observa que conforme aumenta el número de clientes, la distancia promedio de cada ruta convencional va disminuyendo y que en los casos de más de 100 clientes, la distancia por ruta eléctrica es mayor que la recorrida por vehículo convencional.

Tabla 13. Proporción de vehículos eléctricos en cada flota.

Casos	Max-Electric	Balanced V1	Balanced V2	No-Stations
UK50	72.60 %	44.68 %	44.37 %	47.65 %
UK75	74.41 %	47.62 %	47.62 %	45.53 %
UK100	77.09 %	47.96 %	48.13 %	44.27 %
UK150	86.23 %	49.13 %	49.00 %	45.88 %
UK200	86.95 %	48.39 %	48.30 %	51.45 %

Por último, las soluciones No-Stations son las únicas en mostrar una diferencia notable entre la proporción de vehículos y su aportación a la evaluación del conjunto de rutas. Los vehículos eléctricos constituyen del 44 % al 52 % de la flota, mientras que sólo aportan del 24 % al 32 % de la distancia total recorrida, y del 79 % al 87 % del tiempo de espera. Sin embargo, estos resultados reflejan las características del algoritmo de decodificación con el que se construyeron estas soluciones. La restricción de recarga en estaciones limita al vehículo eléctrico a recorrer la distancia que permita una sola recarga inicial, la cual

va de los 102 km a los 110 km, como se reporta en la Tabla 12. Por otro lado, la aportación al tiempo de espera es tan alta debido a que las rutas eléctricas son tan cortas que las ventanas de tiempo de los clientes visitados no se encuentran abiertas cuando el vehículo llega para la entrega.

4.5. Conjeturas sobre resultados de distancia y tiempo de espera

A partir de los resultados observados en cada subconjunto de casos de prueba y analizados previamente, se conjetura lo siguiente:

- **Conforme aumenta el número de clientes en los casos de prueba, los frentes de la flota mixta equilibrada V2 se aproximan al frente de flota convencional debido a que las rutas de cada flota se asemejan.**

A medida que el número de clientes crece, la distancia entre los nodos del grafo es menor por lo que aumenta el número de nodos alcanzables, como lo muestra la Tabla 2. Debido a esto existe un mayor número de clientes que pueden ser asignados a rutas eléctricas y al encontrarse más cerca, es factible que un vehículo eléctrico haga más entregas antes de necesitar realizar una recarga y que la distancia para llegar a la estación de recarga sea menor. Estos recorridos con un mayor número de clientes visitados, desviaciones a estaciones de recarga más cortas y en menor cantidad, podrían llegar a generar rutas que se puedan encontrar en las soluciones con flota convencional. La Tabla 12 muestra cómo las distancias promedio recorridas por cada vehículo eléctrico se aproximan a las recorridas por cada ruta de la flota convencional, con una diferencia no mayor al 6%.

- **Los frentes de flota mixta dominan las soluciones con menor tiempo de espera de la flota convencional, debido a que las visitas a estaciones de recarga habilitan las ventanas de tiempo posteriores.**

Conforme transcurre el tiempo del recorrido en una ruta, más ventanas de tiempo se habilitan para que el vehículo pueda realizar la entrega en cuanto llega. Supóngase el siguiente escenario: En determinado momento del recorrido, el vehículo eléctrico pasa a una estación para recargar su batería y posteriormente visita a un cliente. La ventana de tiempo de dicho cliente fue habilitada durante el lapso de tiempo en el que se llevó a cabo la recarga de la batería. Por lo tanto, la desviación a la estación de recarga y la recarga en sí, suman al tiempo total del recorrido, eliminando el tiempo de espera que se hubiera sumado por la llegada anticipada con el siguiente cliente.

- **El frente consolidado No-Stations mejora su distancia conforme aumenta el número de clientes en los casos de prueba, debido a la estrategia aplicada en la construcción de rutas del algoritmo de decodificación.**

Como se describió en la sección 3.8, el algoritmo No-Stations utiliza el etiquetado de nodos para identificar a los clientes alcanzables e inalcanzables desde la central, con un vehículo eléctrico. Esta clasificación de nodos divide al conjunto de clientes en dos subconjuntos de aproximadamente el mismo tamaño (ver Tabla 2). Un subconjunto incluye a los clientes más cercanos a la central y otro a los más alejados de ella, como lo muestra la Figura 10(b).

Las rutas eléctricas se construyen a partir del subconjunto de clientes más cercanos y las rutas convencionales a partir del subconjunto de los más lejanos. Por lo tanto, sin haberlo diseñado con tal propósito, el algoritmo No-Stations aplica una estrategia similar a la técnica de divide y vencerás, partiendo al conjunto de clientes en dos y construyendo rutas específicas para cada subconjunto.

Aunque en los demás algoritmos también se emplea la clasificación de nodos, ésta se realiza con respecto a la estación de recarga más cercana, donde el subconjunto de nodos alcanzables integra del 71 % al 99 % del total de clientes y los nodos inalcanzables suelen encontrarse alejados entre sí, como lo muestra la Figura 10(a).

Además, conforme el número de clientes aumenta, la cantidad de nodos alcanzables desde la central también aumenta, siempre manteniendo la proporción de 50 % y 50 %. También, la distancia entre nodos es más corta, permitiendo visitar un mayor número de clientes dentro del límite de distancia establecido por la restricción de batería. Lo anterior hace factible la construcción de rutas eléctricas similares a rutas que se pueden encontrar en soluciones con flota convencional, ya que no requieren visitar estaciones de recarga.

Capítulo 5. Análisis de emisiones de CO₂

En este capítulo se analizarán las emisiones de CO₂ producidas por los vehículos convencionales (directas) y eléctricos (indirectas), correspondientes a las soluciones de flota convencional y flotas mixtas estudiadas en este proyecto. La finalidad de este análisis es descubrir en qué medida, la inclusión de vehículos eléctricos, ayuda a reducir el impacto ambiental provocado por las emisiones de CO₂. También, se busca comparar el desempeño de cada flota mixta para identificar la configuración de flota que obtiene los mejores resultados en términos de menor distancia y menores emisiones.

Para ello, se reportan tres valores de emisión de CO₂ correspondientes a los modelos descritos en el Capítulo 2 e identificados con una letra en las tablas de este capítulo: Emisiones directas (A), emisiones por recarga de energía (B) y emisiones por consumo de energía (C). Para fines de simplicidad, se utilizarán los términos de emisiones por recarga y emisiones por consumo para hacer referencia a la emisión total calculada por la suma de emisiones directas e indirectas, aún cuando estos términos en verdad indican la forma en que se calculan las emisiones indirectas (incurridas por vehículos eléctricos).

5.1. Emisiones de CO₂ por subconjunto de casos de prueba

En esta sección, se presentan y analizan los resultados de distancia total recorrida y emisiones de CO₂, correspondientes a las soluciones con menor distancia de cada frente consolidado. En la Tabla 14, se reportan por cada subconjunto de casos de prueba los promedios calculados a partir de los resultados de los veinte casos que lo conforman. Para la flota convencional se muestra la distancia total recorrida en kilómetros y el total de emisiones en kilogramos de CO₂. Para las flotas mixtas se presenta la diferencia de distancia y emisiones, resultante de la comparación con los resultados obtenidos por la flota convencional.

Empezando por las emisiones directas (A), la flota max-eléctrica consigue la mayor reducción de CO₂ de las cuatro flotas mixtas construídas, eliminando del 60.07 % al 78.57 % de lo generado por la flota convencional. Estos porcentajes concuerdan con las características de la flota, que está compuesta en un 72 % a 87 % de vehículos eléctricos (ver Tabla 13) y también con la aportación de las rutas eléctricas a la distancia recorrida, que es del 64 % al 86 %.

Por otro lado, las soluciones No-Stations presentan las menores reducciones de CO₂, con porcentajes de 17.28 % a 26.97 %. A diferencia de las soluciones Max-Electric, estos resultados no concuerdan con la composición de la flota, donde del 44 % al 52 % del total de vehículos son eléctricos. En cambio, donde

sí se encuentra una relación es con la aportación en distancia recorrida, que va de 24 % al 32 %, como se reporta en la Tabla 11.

Tabla 14. Emisiones de CO₂ de soluciones con menor distancia recorrida.

Casos	Convencional		Max-Electric				Balanced V1			
	Distancia	Total CO ₂	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)
UK50	1423.77	649.39	13.56 %	-60.07 %	-5.93 %	-14.41 %	4.45 %	-37.30 %	-5.92 %	-11.24 %
UK75	2078.55	949.81	19.21 %	-62.78 %	-3.08 %	-11.89 %	6.57 %	-41.03 %	-5.96 %	-11.47 %
UK100	2683.34	1225.78	28.52 %	-67.66 %	2.22 %	-7.69 %	9.37 %	-42.84 %	-3.98 %	-10.40 %
UK150	3980.01	1816.92	38.95 %	-78.52 %	6.46 %	-5.17 %	8.93 %	-45.54 %	-5.44 %	-11.64 %
UK200	5174.02	2362.81	44.92 %	-78.57 %	11.53 %	-1.52 %	8.92 %	-46.61 %	-5.20 %	-12.20 %

Casos	Convencional		Balanced V2				No-Stations			
	Distancia	Total CO ₂	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)
UK50	1423.77	649.39	2.99 %	-39.79 %	-7.58 %	-13.37 %	11.12 %	-18.51 %	3.66 %	-0.59 %
UK75	2078.55	949.81	2.94 %	-40.87 %	-8.46 %	-13.72 %	10.28 %	-17.28 %	3.36 %	-0.58 %
UK100	2683.34	1225.78	3.86 %	-44.74 %	-8.31 %	-14.59 %	8.77 %	-18.33 %	1.30 %	-1.88 %
UK150	3980.01	1816.92	3.66 %	-48.56 %	-9.66 %	-16.14 %	7.73 %	-21.59 %	-0.93 %	-3.70 %
UK200	5174.02	2362.81	4.25 %	-47.32 %	-8.54 %	-15.44 %	6.90 %	-26.97 %	-3.62 %	-6.31 %

Para las flotas equilibradas, la reducción de emisiones directas es similar entre ellas. Las soluciones Balanced V1 disminuyen del 37.3 % al 46.61 % la emisión directa, mientras que las soluciones Balanced V2 consiguen reducirlas de un 39.79 % a un 48.56 %. Al igual que con la flota max-eléctrica, estos porcentajes concuerdan con la proporción de vehículos eléctricos en la flota y con su aportación al total de distancia recorrida.

En resumen, los resultados de emisiones directas indican que al emplear una flota mixta, el número de vehículos eléctricos que se utilicen no necesariamente tendrá un efecto proporcional en la reducción de emisión de CO₂. Más bien, lo que sí hará diferencia en el impacto ambiental, será el porcentaje de distancia total que recorran estos vehículos.

Pasando a los resultados de emisiones por recarga, en las cuatro flotas mixtas se observa una notable diferencia entre las reducciones conseguidas bajo este enfoque y las analizadas anteriormente. Ahora que se toman en cuenta las emisiones indirectas (contabilizadas por cada recarga de batería), la reducción del impacto ambiental no es tan significativa como se esperaba e incluso se llegan a presentar casos con aumentos en la emisión de CO₂.

La flota max-eléctrica, que anteriormente obtenía la menor emisión de las cuatro flotas, ahora se ubica entre los porcentajes más bajos de disminución de CO₂ y es una de las flotas que empeora los niveles de emisión. En los casos de 50 y 75 clientes, consigue bajar las emisiones en un 5.93 % y 3.08 %, respectivamente, mientras que para los casos con 100 y más clientes, aumenta las emisiones hasta en

un 11.53 %. Dados estos resultados, las soluciones Max-Electric pasan de ser las mejores en reducción de CO₂ a las peores, incluso superando la emisión total de la flota convencional.

Otra de las flotas que presentan un aumento en emisiones, es la flota con restricción de recargas. A diferencia de la flota max-eléctrica, las soluciones No-Stations consiguen un mal desempeño en los casos de menos de 150 clientes, con un aumento de hasta 3.66 %. En los casos de 150 y 200 clientes, logran una reducción de 0.93 % y 3.62 %, respectivamente. Dado que estas soluciones se caracterizan por no permitir la visita a estaciones de recarga, resulta interesante que consigan niveles tan altos de emisión total. En esta flota, las emisiones indirectas provienen de las recargas realizadas en la central, por lo que dependen directamente del número de vehículos eléctricos que se utilicen. Al revisar la Tabla 6, que compara el número de vehículos que se emplean en cada flota, se confirma que las soluciones No-Stations usan más vehículos que los demás. Por lo tanto, la cantidad de vehículos eléctricos, en adición a la poca reducción de emisiones directas que consigue esta flota, explican este comportamiento bajo el enfoque de emisiones por recarga.

Por su parte, las soluciones Balanced V1 y V2 mantienen en promedio una disminución en emisiones. La flota equilibrada V1 consiguen bajar la emisión total de un 3.98 % a un 5.96 %, y la flota equilibrada V2 hace lo propio con una reducción de 7.58 % a 9.66 %. Dados estos resultados y recordando que la flota equilibrada V2 consigue la menor diferencia en distancia de las cuatro flotas mixtas, se concluye que considerando emisiones por recarga, las soluciones Balanced V2 presentan los mejores resultados en términos de menor impacto en distancia y mayor reducción de emisiones de CO₂.

Analizando ahora las emisiones por consumo, se observa que nuevamente hay una reducción en todas las flotas mixtas, sin aproximarse a los porcentajes reportados para emisiones directas y subiendo un poco los porcentajes de emisión por recarga. Revisando los resultados de la flota max-eléctric, se encuentra una reducción que va de 1.52 % a 14.41 %, valores que siguen sin reflejar un beneficio proporcional a la aportación al total de distancia recorrida de los vehículos eléctricos que utiliza.

La flota sin estaciones ya no presenta en promedio aumentos en emisión total, pero consigue la menor reducción de CO₂ en todos los subconjuntos a excepción de los casos de 200 clientes. En general, obtiene entre 0.58 % y 6.31 % menos emisiones que la flota convencional, indicando que pesar de haber cambiado la forma de calcular las emisiones indirectas, el número tan alto de vehículos eléctricos que emplea, provoca que las emisiones CO₂ se aproximen a las de la flota convencional.

Por último, las flotas equilibradas logran los mejores resultados, reduciendo V1 entre 10.4 % y 12.2 % la emisión de CO₂ y V2 consiguiendo la mayor reducción en todos los subconjuntos de casos de prueba,

a excepción de los casos de 50 clientes. Al igual que en los análisis anteriores, los resultados de las soluciones Balanced, las ubican como la mejor opción debido a su ligero aumento en distancia y mayor disminución de impacto ambiental. Aún así, una constante en todas las flotas mixtas bajo el enfoque de emisiones por consumo, es la diferencia entre el beneficio esperado por la inclusión de vehículos eléctricos (emisiones directas) y el beneficio real considerando emisiones indirectas (por recarga o por consumo).

5.2. Revisión de casos de 50 clientes

Con el fin de analizar a detalle las emisiones de un subconjunto de casos de prueba, a continuación se revisarán los casos de 50 clientes. Además, esta revisión permitirá identificar las características de cada algoritmo de decodificación tanto en los resultados de distancia y emisiones de CO₂, como visualmente en los conjuntos de rutas. La Tabla 15 presenta los resultados correspondientes a las soluciones con menor distancia de diez frentes consolidados.

Comenzando por las soluciones obtenidas con el algoritmo Max-Electric y como se ha visto desde el Capítulo 4, éstas presentan la mayor diferencia de distancia en comparación con las otras flotas, llegando a presentar un aumento de más de 20 %. En cambio, la reducción de emisiones directas en esta flota es la mayor de las cuatro, llegando a obtener una reducción de 100 % en el caso UK50_17, donde la flota es completamente eléctrica. Este es un caso interesante, ya que podría indicar que a cambio de un aumento de 10.66 % en distancia, se eliminan completamente las emisiones de CO₂. Sin embargo, al considerar las emisiones indirectas, se observa que la reducción real es de 15.32 % con emisiones por recarga y 30.34 % con emisiones por consumo. En algunos casos, incluso se llega a presentar un aumento en emisiones por recarga de hasta 5.53 % (UK50_11).

Por otro lado, las flotas equilibradas V1 y V2 presentan las menores diferencias de distancia, con un mínimo de 0.95 % y 0.31 %, respectivamente. Las emisiones directas se reducen hasta un 41.3 % con Balanced V1 y 53.11 % con Balanced V2, aproximándose al 50 % esperado, dadas las características de la flota. Considerando emisiones indirectas por recarga, la flota equilibrada V2 consigue la mayor reducción con un promedio de 7.58 %. Sin embargo, también presenta uno de los mayores aumentos, con un 8.36 % en el caso UK50_05. Respecto a emisiones por consumo, las soluciones obtenidas con Balanced V2, presentan resultados que compiten con las soluciones Max-Electric.

Por último, la flota sin estaciones presenta el mayor número de aumentos de emisiones tanto por recarga

como por consumo, consiguiendo hasta 10.64 % y 6.01 %, respectivamente. Aunque en algunas soluciones sí logra reducir el nivel de emisiones, el porcentaje de reducción para dichos casos se ve superado por las demás flotas. Estos resultados, ubican a la flota sin estaciones como la opción más contaminante de las cinco, al presentar un aumento de emisiones totales en la mayoría de los casos de prueba.

Tabla 15. Comparación de emisiones de CO₂ para los casos UK50.

Casos	Convencional		Max-Electric				Balanced V1			
	Distancia	Total CO ₂	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)
UK50_03	1444.563	658.68	14.21 %	-69.81 %	-10.21 %	-17.85 %	4.73 %	-36.28 %	-4.75 %	-10.25 %
UK50_05	1499.841	683.63	20.86 %	-50.91 %	0.10 %	-6.45 %	14.35 %	-34.67 %	2.05 %	-3.62 %
UK50_07	1224.091	554.59	8.56 %	-52.72 %	-4.08 %	-14.47 %	4.27 %	-35.37 %	-3.93 %	-9.83 %
UK50_08	1281.19	589.08	15.95 %	-49.46 %	3.02 %	-8.68 %	5.13 %	-21.81 %	0.27 %	-4.97 %
UK50_10	1579.341	723.52	9.80 %	-60.10 %	-9.53 %	-17.90 %	0.95 %	-37.97 %	-11.48 %	-14.04 %
UK50_11	1497.391	679.91	15.46 %	-36.59 %	5.53 %	-4.08 %	5.23 %	-32.94 %	-3.85 %	-9.26 %
UK50_13	1328.35	598.85	16.98 %	-48.42 %	5.32 %	-6.34 %	2.49 %	-39.89 %	-6.93 %	-13.33 %
UK50_14	1565.961	714.54	10.33 %	-58.24 %	-7.50 %	-15.93 %	2.13 %	-36.01 %	-7.12 %	-12.29 %
UK50_17	952.92	434.99	10.66 %	-100.00 %	-15.32 %	-30.34 %	4.98 %	-41.30 %	-5.92 %	-11.81 %
UK50_19	1367.762	625.5	18.57 %	-52.91 %	-1.26 %	-9.84 %	2.08 %	-34.92 %	-4.62 %	-12.31 %
	1423.77	649.39	13.56 %	-60.07 %	-5.93 %	-14.41 %	4.45 %	-37.30 %	-5.92 %	-11.24 %

Casos	Convencional		Balanced V2				No-Stations			
	Distancia	Total CO ₂	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)
UK50_03	1444.563	658.68	2.14 %	-35.28 %	-7.45 %	-12.28 %	13.69 %	-11.42 %	9.13 %	3.79 %
UK50_05	1499.841	683.63	9.06 %	-22.62 %	8.36 %	-2.48 %	9.77 %	-17.41 %	2.39 %	-0.66 %
UK50_07	1224.091	554.59	1.66 %	-30.36 %	-6.43 %	-10.31 %	3.59 %	-30.67 %	-6.26 %	-9.45 %
UK50_08	1281.19	589.08	4.00 %	-26.98 %	-1.04 %	-8.42 %	15.55 %	-23.50 %	5.22 %	0.16 %
UK50_10	1579.341	723.52	1.78 %	-40.32 %	-10.69 %	-14.49 %	5.19 %	-13.91 %	0.12 %	-2.21 %
UK50_11	1497.391	679.91	2.25 %	-35.04 %	-5.16 %	-12.18 %	7.50 %	-11.44 %	3.49 %	0.23 %
UK50_13	1328.35	598.85	0.31 %	-36.92 %	-4.84 %	-13.34 %	27.27 %	-40.54 %	4.67 %	-0.53 %
UK50_14	1565.961	714.54	1.03 %	-42.19 %	-12.24 %	-15.69 %	6.15 %	-3.73 %	5.74 %	2.11 %
UK50_17	952.92	434.99	1.98 %	-53.11 %	-10.64 %	-18.55 %	17.19 %	-54.48 %	-0.03 %	-11.21 %
UK50_19	1367.762	625.50	1.92 %	-37.52 %	-8.74 %	-13.15 %	18.05 %	-11.00 %	10.64 %	6.01 %
	1423.77	649.39	2.99 %	-39.79 %	-7.58 %	-13.37 %	11.12 %	-18.51 %	3.66 %	-0.59 %

5.2.1. Análisis de caso UK50_05

El caso de prueba UK50_05 tiene la característica de ser el único en el que todas las soluciones presentan un aumento en emisiones totales al considerar emisiones por recarga. Para analizar visualmente cada solución, la Figura 17 muestra los conjuntos de rutas obtenidas por cada algoritmo de decodificación para el caso UK50_05.

Lo primero que se observa de las soluciones, son las características de cada algoritmo de decodificación. La solución Max-Electric se compone de 4 rutas eléctricas y 2 convencionales, donde la mayoría de los nodos alcanzables (ver Figura 10(a)) son visitados por un vehículo eléctrico y las rutas convencionales tratan de visitar la mayor cantidad de nodos inalcanzables en la misma ruta. Las soluciones con flota

equilibrada utilizan sólo 3 vehículos eléctricos pero se distinguen por la cantidad de clientes visitados. En la solución V1, las rutas eléctricas visitan 27 clientes, mientras que en la solución V2 sólo se visitan 16. Esto se debe a que el algoritmo Balanced V1 busca asignar nodos alcanzables a rutas eléctricas antes que a una ruta convencional, mientras que el algoritmo Balanced V2 asigna nodos alcanzables a la ruta que suma la menor distancia, sin importar el tipo. La solución No-Stations se caracteriza por tener 4 rutas eléctricas, sin visitas a estaciones de recarga y compuestas por no más de 5 nodos. Estas propiedades reflejan la restricción de completar cada recorrido con sólo una recarga inicial de batería, visitando pocos clientes para llevar una carga ligera y obtener un recorrido corto.

Tabla 16. Detalles de soluciones de menor distancia para el caso UK50.05.

	Max-Electric	Balanced V1	Balanced V2	No-Stations
No. V.C.	2	3	4	4
No. V.E.	4	3	3	4
% Distancia V.E.	59.15 %	43.80 %	30.47 %	25.69 %
% CO ₂ V.E.	50.96 %	35.98 %	28.59 %	19.34 %
CO ₂ × V.C.	167.80	148.88	132.25	141.16
CO ₂ × V.E.	87.19	83.66	70.58	33.84
No. Recargas	8	6	4	0

La Tabla 16 permite analizar el desempeño de las rutas convencionales y eléctricas respecto a distancia y emisiones. De las 4 soluciones, la flota max-eléctrica tiene la mayor aportación de distancia (59.15 %) y la flota sin estaciones la menor (25.59 %). La emisión promedio por vehículo en la solución con flota convencional para el mismo caso es de 113.94 kgCO₂. La Tabla 16 muestra que en todas las soluciones con flota mixta, la emisión promedio por vehículo convencional es mayor al de la flota convencional. Sin embargo, la emisión promedio por vehículo eléctrico se ubica debajo de la de un vehículo convencional.

En rutas convencionales con flota equilibrada y max-eléctrica, las aristas que salen de la central suelen ser más extensas que en rutas convencionales de otras soluciones. Esto se debe a las características del algoritmo de decodificación, donde se decide visitar primero a los nodos inalcanzables. Aunque el algoritmo No-Stations tiene la misma característica, se distingue por la clasificación de nodos con respecto a la central, por lo que los primeros nodos de rutas suelen estar más cerca a la central. Además de la distancia, recorrer estas aristas tiene un mayor impacto ambiental por el factor de carga del vehículo, ya que éstos salen de la central cargando las demandas de todos los clientes que se visitarán.

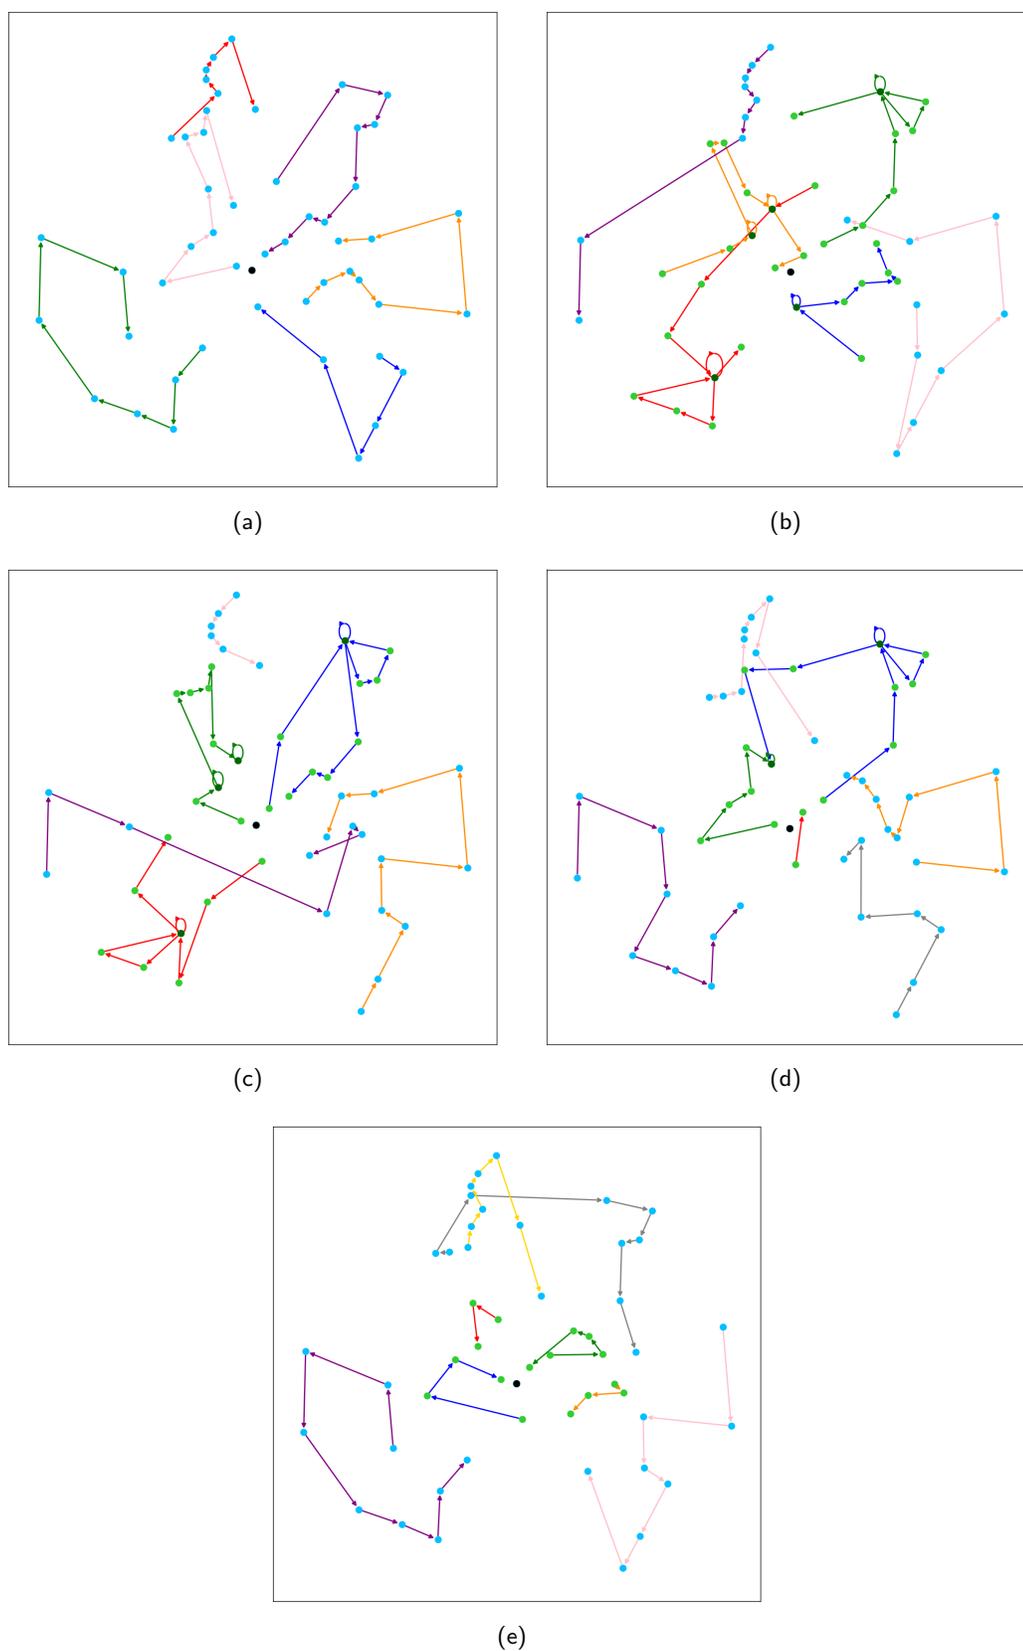


Figura 17. Soluciones con menor distancia obtenidas para el caso UK50.05. (a) Convencional; (b) Max-Electric; (c) Balanced V1; (d) Balanced V2; (e) No-Stations. Color de nodos: Central (Negro); Visita de vehículo convencional (Azul); Visita de vehículo eléctrico (Verde); Visita a estación de recarga (Verde oscuro).

5.3. Análisis de casos de 10 clientes

Al estudiar las soluciones de los casos más pequeños del conjunto de casos de prueba, se encontraron escenarios interesantes respecto al desempeño de los vehículos eléctricos y su emisión indirecta de CO₂. Dichos casos serán analizados en esta sección y se incluyen en la Tabla 17, la cual reúne una muestra de las soluciones con menor distancia obtenidas para el subconjunto de casos de 10 clientes. En esta tabla se compara la distancia (en kilómetros) y emisiones totales (en kilogramos de CO₂) entre lo obtenido por la flota convencional y los resultados con flota mixta.

Tabla 17. Soluciones con menor distancia para los casos UK10.

Casos	Convencional		Max-Electric				Balanced V1			
	Distancia	Total CO ₂	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)
UK10.01	408.13	184.26	5.46%	-25.33%	8.97%	-5.78%	5.46%	-25.33%	8.97%	-5.78%
UK10.02	527.02	237.56	16.12%	-38.22%	-0.70%	-6.17%	0.02%	-37.75%	-14.47%	-15.11%
UK10.04	479.86	214.19	3.71%	-15.58%	0.22%	-3.18%	3.62%	-16.18%	-0.38%	-3.78%
UK10.05	442.07	196.03	14.07%	-47.14%	1.78%	-11.26%	7.55%	-26.89%	-2.17%	-4.81%
UK10.07	494.69	219.52	11.69%	-2.08%	13.33%	7.84%	7.79%	-9.07%	6.35%	0.86%
UK10.08	567.55	254.39	21.85%	-14.34%	12.26%	7.92%	5.54%	-30.40%	-6.83%	-8.13%
UK10.12	459.371	202.36	15.98%	-6.15%	10.57%	8.08%	9.11%	-3.91%	12.81%	5.52%
UK10.15	292.04	131.62	12.73%	-100.00%	-4.94%	-30.27%	12.73%	-90.22%	-20.49%	-26.06%
UK10.19	414.46	187.24	10.50%	-29.06%	7.08%	-6.26%	5.27%	-19.05%	-0.98%	-4.62%
UK10.20	409.901	183.10	13.98%	-60.15%	9.29%	-15.48%	5.60%	-9.02%	9.47%	-0.44%
	466.81	209.27	11.91%	-26.20%	6.03%	-3.10%	6.54%	-23.82%	0.55%	-4.98%

Casos	Convencional		Balanced V2				No-Stations			
	Distancia	Total CO ₂	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)	Dif. Dist.	Dif. CO ₂ (A)	Dif. CO ₂ (B)	Dif. CO ₂ (C)
UK10.01	408.13	184.26	0.00%	-34.05%	-11.61%	-13.18%	8.98%	-25.33%	11.40%	-4.27%
UK10.02	527.02	237.56	0.02%	-37.75%	-14.47%	-15.11%	24.23%	-4.71%	23.78%	11.72%
UK10.04	479.86	214.19	3.62%	-16.18%	-0.38%	-3.78%	37.51%	-54.46%	8.74%	-1.30%
UK10.05	442.07	196.03	6.16%	-17.02%	0.24%	-2.42%	26.94%	-47.14%	4.65%	-3.49%
UK10.07	494.69	219.52	5.82%	-0.68%	14.73%	6.26%	7.79%	-9.07%	6.35%	0.86%
UK10.08	567.55	254.39	5.54%	-30.40%	-6.83%	-8.13%	21.85%	-14.34%	12.26%	7.92%
UK10.12	459.371	202.36	4.14%	-3.03%	13.70%	2.66%	15.98%	-6.15%	10.57%	8.08%
UK10.15	292.04	131.62	0.00%	-9.78%	15.93%	-3.83%	19.12%	-12.19%	13.52%	6.27%
UK10.19	414.46	187.24	0.00%	-12.91%	5.16%	-5.06%	10.32%	-30.04%	6.11%	-7.24%
UK10.20	409.901	183.10	5.13%	-14.68%	3.80%	-1.18%	21.90%	-57.69%	-2.25%	-11.16%
	466.81	209.27	3.86%	-16.13%	2.38%	-3.57%	17.44%	-20.44%	10.43%	1.88%

5.3.1. Caso UK10_12

El caso UK10.12 es uno de pocos casos en los que las flotas mixtas presentan un aumento en el total de emisiones al compararlas con lo conseguido por la solución óptima en distancia de flota convencional. Como se muestra en la Tabla 17, para este caso las flotas mixtas generan entre un 10.57% y 13.70% más emisiones por recarga, y de 2.66% a 8.08% más emisiones por consumo. Para las emisiones directas,

se observa que las flotas mixtas presentan una reducción de entre 3.03 % y 6.15 %, cuando se esperaría una reducción de 50 %, dado que se están eliminando las emisiones de un vehículo convencional en una flota de dos vehículos. Importante mencionar que para este caso, todas las soluciones se conforman de dos rutas, específicamente una ruta convencional y una eléctrica en flotas mixtas.

Con el fin de entender porqué el reemplazo de un vehículo convencional por uno eléctrico provoca un aumento en el total de emisiones, se analizaron los conjuntos de rutas correspondientes a las soluciones con menor distancia obtenidos con cada algoritmo de decodificación, presentados en la Figura 18. Empezando con la flota convencional, su conjunto de rutas divide al grafo en dos subconjuntos, uno conformado por los clientes ubicados a la izquierda de la central y otro por aquellos ubicados a la derecha de la central. Por otro lado, en los conjuntos de rutas con flota mixta, la distribución de clientes se organiza con base en su cercanía a la central, resultando en que la ruta eléctrica visita a los nodos más cercanos (ruta azul) y la ruta convencional visita a los más alejados (ruta roja). Otra característica importante de estas soluciones, es que las rutas eléctricas no requieren visitar la estación de recarga ubicada en el nodo 7.

La información de la Tabla 18 ofrece más detalles sobre las soluciones de cada flota. Primeramente, analizando la distancia, se observa que en las flotas mixtas, la ruta eléctrica aporta entre el 9.08 % y el 20.31 % de la distancia recorrida, dejando a la ruta convencional con la aportación mayoritaria de más de 79 %. Mientras que en la flota convencional cada vehículo recorre en promedio 229.69 km, en las flotas mixtas el vehículo convencional recorre hasta un 89.38 % más distancia y el vehículo eléctrico presenta una reducción de hasta un 81.09 %. Dado que el aumento en distancia de la ruta convencional es mayor que la reducción de la ruta eléctrica, el total recorrido aumenta de un 4.14 % hasta un 15.98 %, más que la flota convencional.

En cuanto a las emisiones, en la Tabla 18 se reporta que en las flotas mixtas, el vehículo convencional emite entre 87.7 % y 93.95 % más CO₂ que un vehículo de la flota convencional. Por su parte, el vehículo eléctrico emite 66.55 % menos CO₂ que un vehículo de la flota convencional. Esta reducción es la misma en las cuatro flotas debido a que se realiza una única recarga de batería, antes de empezar el recorrido en la central. Dado que el aumento en emisiones del vehículo convencional es mayor que la reducción que consiguen los vehículos eléctricos, la emisión total (por recarga) de las flotas mixtas es mayor que la emisión de la flota convencional.

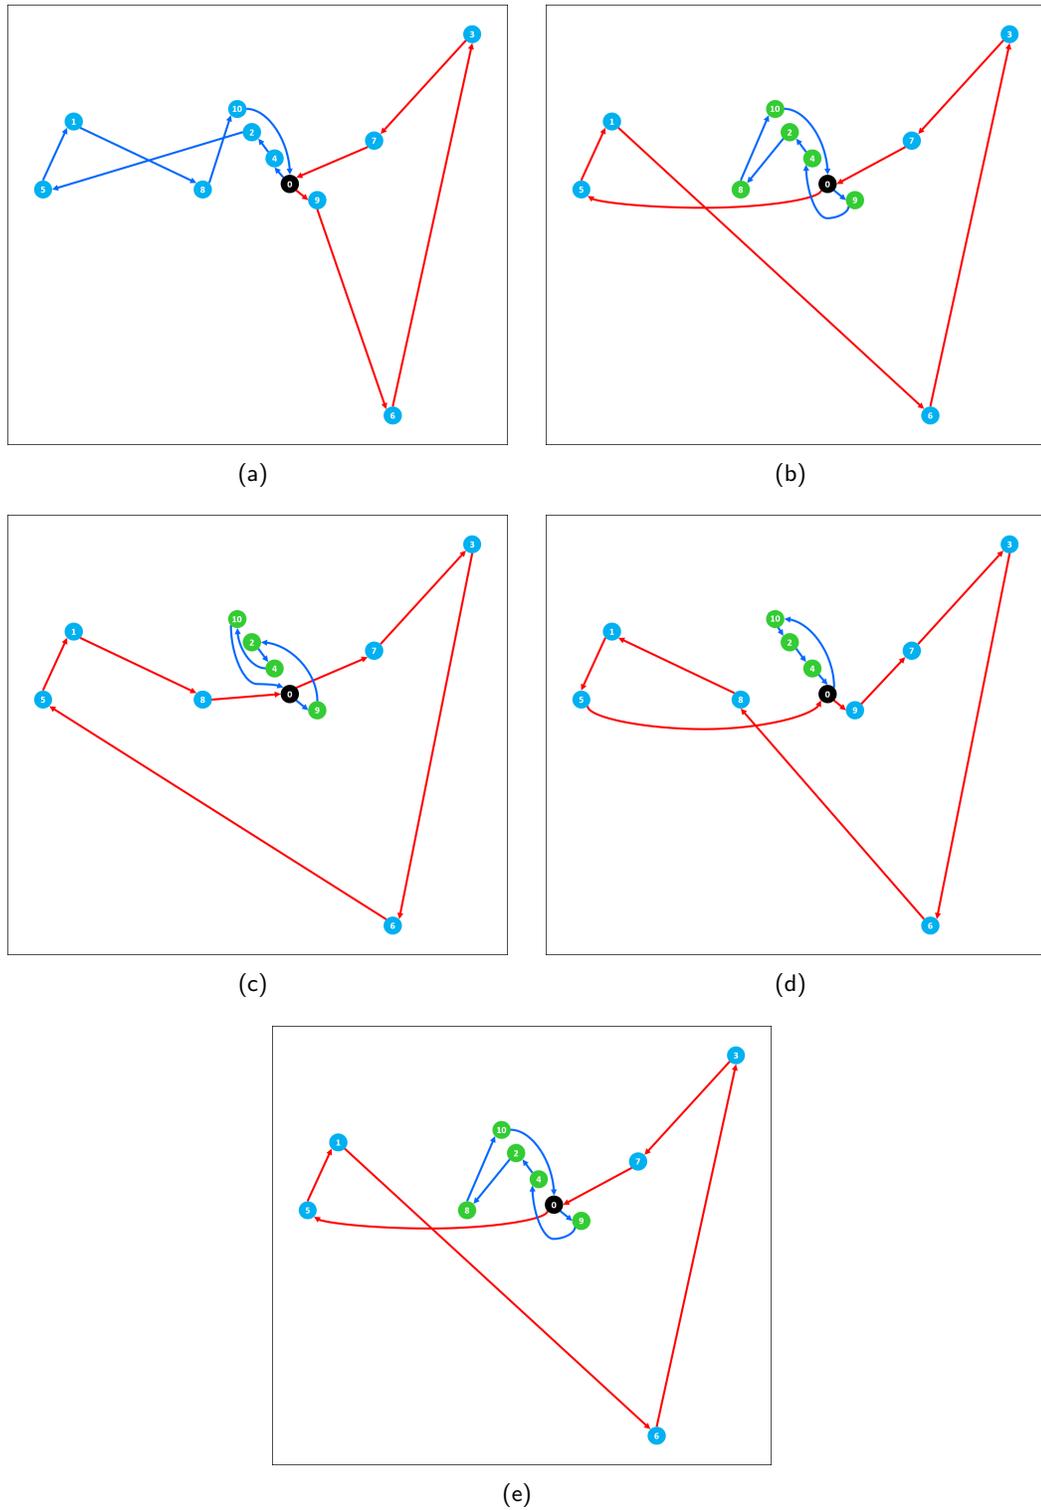


Figura 18. Soluciones con menor distancia obtenidas para el caso UK10_12 por algoritmos: a) Convencional; b) Max-Electric; c) Balanced V1; d) Balanced V2; e) No-Stations. Color de nodos: Central (Negro); Visita de vehículo convencional (Azul); Visita de vehículo eléctrico (Verde).

Tabla 18. Detalles de soluciones con menor distancia para el caso UK10_12.

	Convencional	Max-Electric	Balanced V1	Balanced V2	No-Stations
Dif. Dist	459.37	15.98 %	9.11 %	4.14 %	15.98 %
%Dist VE	-	20.31 %	14.33 %	9.08 %	20.31 %
Dist x VC	229.69	424.58	429.42	434.98	424.58
Dist x VE	-	108.18	71.80	43.43	108.18
Dif. CO ₂ x VC	101.18	87.70 %	92.18 %	93.95 %	87.70 %
CO ₂ x km VC	0.441	0.447	0.453	0.451	0.447
Dif. CO ₂ (B)	202.36	10.57 %	12.81 %	13.70 %	10.57 %
%CO ₂ VE (B)	-	15.12 %	14.82 %	14.71 %	15.12 %
Dif. CO ₂ x VE (B)	-	-66.55 %	-66.55 %	-66.55 %	-66.55 %
CO ₂ x km VE (B)	-	0.313	0.471	0.779	0.313
Consumo kWh	-	68.06	45.12	27.20	68.06
Dif. CO ₂ (C)	202.36	8.08 %	5.52 %	2.66 %	8.08 %
%CO ₂ VE (C)	-	13.16 %	8.94 %	5.54 %	13.16 %
Dif. CO ₂ x VE (C)	-	-71.54 %	-81.14 %	-88.63 %	-71.54 %
CO ₂ x km VE (C)	-	0.266	0.266	0.265	0.266
Clientes VC	10	5	6	7	5
Clientes VE	-	5	4	3	5

Esta situación se mantiene al considerar emisiones por consumo. La reducción de emisiones por parte del vehículo eléctrico va del 71.54 % al 88.63 %, lo cual sigue siendo menos que el aumento de emisiones del vehículo convencional. Por ello, las flotas mixtas presentan un aumento de 2.66 % a 8.08 % en la emisión total, al compararla con la emisión de la flota convencional. Por lo tanto, el impacto en la distancia recorrida causado por la ruta convencional también tiene un impacto en las emisiones de CO₂ y es la responsable de que, aún con un vehículo eléctrico en la flota, las emisiones sean mayores.

Sin embargo, las soluciones analizadas anteriormente sólo representan el extremo superior izquierdo de cada frente consolidado. Existen más soluciones por cada flota, que tendrán una mayor distancia recorrida y otros niveles de emisión. Con el fin de encontrar, una solución donde el uso del vehículo eléctrico disminuya el impacto ambiental de la flota, se revisaron las emisiones de CO₂ de todas las soluciones de los frentes consolidados. Así se confirmó que la solución óptima en distancia de la flota convencional, es la solución con la menor emisión total del frente consolidado. Por lo tanto, se compararía el desempeño de las flotas mixtas con la solución de menor impacto ambiental de la flota convencional.

Finalmente, se identificaron dos soluciones que logran reducir los 202.36 kgCO₂ emitidos por la flota convencional. Ambas soluciones pertenecen al frente consolidado de la flota equilibrada V1 y se muestran en la Figura 19. Una de las principales diferencias entre estos conjuntos de rutas y aquellos de menor distancia, es que en estos el vehículo eléctrico sí realiza recargas en la estación ubicada en el nodo 7 y visita a la mayoría de los clientes. Lo anterior se refleja en el aumento de la distancia total recorrida y

en el porcentaje que aporta el vehículo eléctrico.

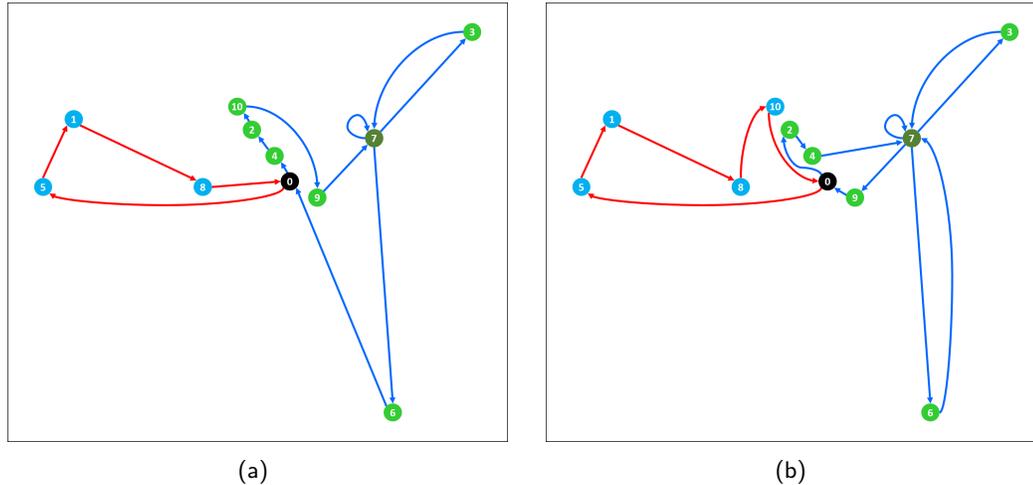


Figura 19. Soluciones de flota equilibrada V1 con menores emisiones que la flota convencional para el caso UK10_12. a) Solución A; b) Solución B. Color de nodos: Central (Negro); Visita de vehículo convencional (Azul); Visita de vehículo eléctrico (Verde); Estación de recarga (Verde oscuro).

La Tabla 19 contiene los detalles de distancia y emisiones de las soluciones encontradas. Respecto a distancia, las soluciones con flota mixta presentan un aumento de 9.63 % y 14.2 %, respectivamente. A cambio, se obtiene una reducción en las tres evaluaciones de emisiones de CO₂. Para emisiones directas (A) se consigue una reducción de más del 50 %, lo cual cumple la expectativa de eliminar la mitad de las emisiones por el reemplazo del vehículo convencional por eléctrico. Para emisiones por recarga, la solución A reduce 15.58 % de CO₂, mientras que la solución B genera 1 % menos que la flota convencional. Considerando la emisión por consumo, hay una reducción de 15.87 % y 11.55 %, respectivamente, indicando que en la solución B, la última recarga de batería no se consume completamente.

Otra de las características notables de estas soluciones es la aportación de emisiones de cada vehículo. De la emisión total por recarga, el vehículo eléctrico aporta 48.09 % y 55.31 %, mientras que de la emisión total por consumo, éste aporta 47.91 % y 49.94 %. Al comparar estos valores con la aportación en distancia, se observa que a pesar de recorrer aproximadamente el 60 % del total de kilómetros, los vehículos eléctricos aportan menos de la mitad de las emisiones totales de CO₂. Al comparar la emisión individual contra lo conseguido por la flota convencional, se obtiene que el vehículo convencional emite 12 % menos CO₂. Por su parte, los vehículos eléctricos disminuyen hasta en 19.39 % la emisión individual, con la excepción de las emisiones por recarga de la solución B, que presenta un aumento de 9.62 %. Dado que este aumento es menor que la reducción que presenta el vehículo convencional (11.44 kgCO₂), la emisión total es menor que la obtenida por la flota convencional, por una mínima diferencia.

Tabla 19. Detalles de soluciones con menor emisión total para el caso UK10_12.

	Convencional	Solución A	Solución B
Dif. Dist. Total	459.37	9.63 %	14.20 %
%Dist VE	-	59.91 %	61.44 %
Dif. CO ₂ (A)	202.36	-56.18 %	-55.72 %
Dif. CO ₂ (B)	-	-15.58 %	-0.91 %
Dif. CO ₂ (C)	-	-15.87 %	-11.55 %
%CO ₂ VE (B)	-	48.09 %	55.31 %
%CO ₂ VE (C)	-	47.91 %	49.94 %
Dif. CO ₂ × VC	101.18	-12.36 %	-11.44 %
Dif. CO ₂ × VE B	-	-18.80 %	9.62 %
Dif. CO ₂ × VE C	-	-19.39 %	-11.66 %

5.3.2. Caso UK10_15

El caso UK10_15 permite analizar el impacto de la distancia recorrida y la carga del vehículo en las emisiones de CO₂. Para este análisis se compararán dos conjuntos de rutas correspondientes a la solución óptima en distancia con flota convencional, obtenida por Goeke & Schneider (2015) para una flota mixta, y la solución de menor distancia para flota mixta, obtenida con el algoritmo Balanced V2. Ambos conjuntos de rutas se presentan en la Figura 20.

Empezando por la Figura 20(a), ésta muestra la solución óptima en distancia para el caso de prueba UK10_15. La solución se compone de dos rutas, la primera (color rojo) visita sólo al cliente 8 y la segunda (color azul) visita a los demás clientes. En la ruta roja se recorren 261.41 km y se emiten 119.21 kgCO₂. Después, la Figura 20(b) muestra la solución con menor distancia obtenida con el algoritmo Balanced V2 para el mismo caso de prueba. Ambas soluciones comparten la misma distribución de clientes en las rutas, diferenciándose en el orden de visita en las rutas rojas.

La solución obtenida con el algoritmo Balanced V2, tiene al cliente 9 como el primero en ser visitado en la ruta roja, mientras que en la flota convencional, es el último. Visualmente, la diferencia es casi imperceptible y en términos de distancia representa un aumento de no más de un kilómetro en la ruta de la flota mixta. A pesar de este aumento en distancia, la ruta roja de la solución Balanced V2 presenta una reducción en las emisiones de CO₂, al producir 118.75 kgCO₂ en comparación con los 119.21 kgCO₂ de la flota convencional.

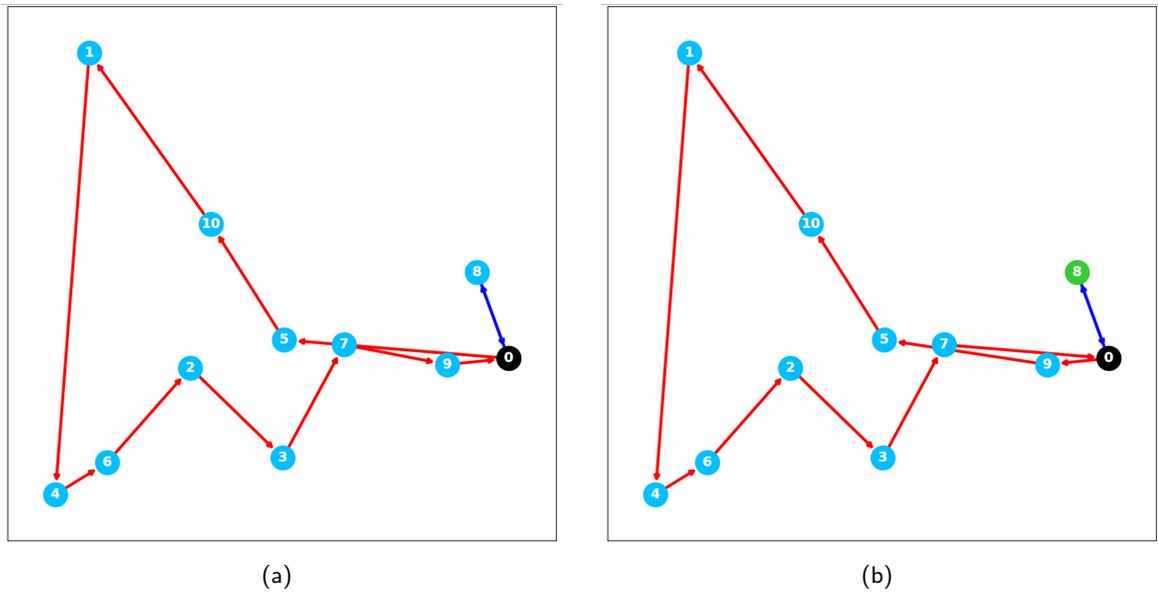


Figura 20. Soluciones con menor distancia obtenidas para el caso UK10_15, con algoritmo para flota convencional (a) y algoritmo Balanced V2 (b).

La ecuación 9, indica que los factores que influyen en la emisión de CO_2 además de la distancia, son la velocidad y el peso. Dado que en estos experimentos se consideró una velocidad constante (90 km/h), el peso es factor restante que podría provocar que la ruta óptima en distancia contamine más que una ruta de mayor distancia. En las tablas 20 y 21, se observa que en las aristas que comparten ambas soluciones, la carga que lleva el vehículo de la flota equilibrada V2 es menor que la que lleva el vehículo de la flota convencional. Esta diferencia en la carga tiene un impacto en las emisiones de CO_2 por arista, que se refleja en las emisiones acumuladas.

Para este caso, la diferencia de distancia y emisiones puede ser mínima, pero permite entender la importancia de los factores involucrados en el cálculo de emisiones de CO_2 y demuestra que una ruta óptima en distancia no necesariamente será óptima en emisiones de CO_2 . Es posible que escenarios como este se presenten en casos de mayor tamaño, donde la carga por arista del vehículo tenga un mayor impacto en las emisiones del recorrido.

Tabla 20. Carga y emisiones de CO₂ por arista en solución para caso UK10_15, con flota convencional.

Arista	Carga	Emisiones CO ₂	Acumulado Emisiones CO ₂
0 → 5	3249	23.57	23.57
5 → 10	3117	9.51	33.07
10 → 1	2387	15.09	48.17
1 → 4	1925	19.47	67.64
4 → 6	1233	6.2	73.84
6 → 2	886	8.83	82.67
2 → 3	712	10.8	93.47
3 → 7	431	7.4	100.88
7 → 9	261	9.96	110.83
9 → 0	0	8.38	119.21

Tabla 21. Carga y emisiones de CO₂ por arista en solución para caso UK10_15, con algoritmo Balanced V2.

Arista	Carga	Emisiones CO ₂	Acumulado Emisiones CO ₂
0 → 9	3249	9.64	9.64
9 → 5	2988	16.97	26.61
5 → 10	2856	9.41	36.02
10 → 1	2126	14.93	50.95
1 → 4	1664	19.26	70.2
4 → 6	972	6.13	76.33
6 → 2	625	8.73	85.06
2 → 3	451	10.68	95.74
3 → 7	170	7.32	103.06
7 → 0	0	15.69	118.75

5.4. Emisión de CO₂ por kilómetro

Los resultados del proyecto no sólo permitieron analizar la emisión total de la flota, sino también cuánto emite cada tipo de vehículo por kilómetro recorrido. Para ello, por cada conjunto de rutas se calculó un promedio, dividiendo las emisiones directas o indirectas sobre la distancia recorrida por el vehículo convencional o eléctrico, respectivamente.

En promedio, el vehículo convencional emite 0.45 kgCO₂ por kilómetro recorrido, mientras que el vehículo eléctrico genera 0.33 kgCO₂ considerando emisiones indirectas por recarga y 0.28 kgCO₂ calculando emisiones por consumo. Estos valores confirman que, al comparar emisiones directas e indirectas, el vehículo eléctrico emite menos CO₂ que uno convencional para la misma distancia recorrida, obteniendo una reducción del 27 % bajo el enfoque de emisiones por recarga y de 38 % para emisiones por consumo.

Con base en estos resultados y sujeto a los parámetros definidos para el cálculo de emisiones directas e indirectas, es posible conocer cuál sería la mayor reducción posible de CO₂ al utilizar vehículos eléctricos. Para ello, se supone el siguiente escenario: En una flota convencional, cada vehículo es reemplazado por uno eléctrico y el conjunto de rutas original puede ser recorrido sin visitar estaciones de recarga. Dado que en este escenario se eliminaron las emisiones directas y la distancia total recorrida es la misma tanto para la flota original como para la nueva flota completamente eléctrica, entonces se espera que la emisión total sea mínima. Por lo tanto, considerando la emisión indirecta por consumo, la emisión por kilómetro de 0.45 kgCO₂ se reduce a 0.28 kgCO₂, obteniendo como máxima reducción de emisiones un 38 %.

Por el contrario, ahora se analiza el umbral de distancia para el cual un vehículo eléctrico emite mayor cantidad de CO₂ que un vehículo convencional. Para ello, se plantea el siguiente escenario: Una ruta convencional será recorrida por un vehículo eléctrico, respetando el orden de visita de cada cliente, siendo necesario visitar estaciones de recarga durante el recorrido pero aclarando que el tiempo que toma llegar a ellas y recargar la batería no afecta el cumplimiento de las ventanas de tiempo.

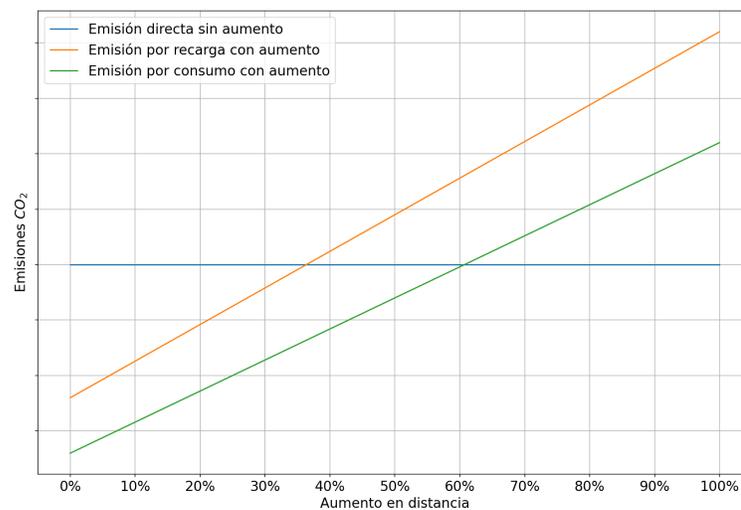


Figura 21. Relación de emisiones indirectas y aumento en distancia.

Suponiendo que el recorrido original es de 100 km, el nuevo recorrido con el vehículo eléctrico superaría los 100 km debido a las desviaciones para recargar energía. Bajo esta suposición y considerando la emisión por kilómetro, se calcularon las emisiones indirectas de CO₂ correspondientes a diferentes porcentajes de aumento de distancia. Los resultados se muestran en la Figura 21, donde la línea azul representa la emisión directa del vehículo convencional correspondiente al recorrido de 100 km, y las líneas amarilla y verde representan las emisiones indirectas (por recarga y por consumo) del vehículo eléctrico, que corresponden a recorridos de más de 100 km.

Analizando la gráfica, se observa que para un aumento en distancia de más de 35 %, las emisiones por recarga superan a las del recorrido original. Lo mismo sucede para las emisiones por consumo, con un aumento mayor a 60 % en los kilómetros recorridos. Por lo tanto, si cambiar el vehículo convencional por el eléctrico genera un aumento de más de 60 % en la distancia recorrida, entonces el vehículo eléctrico emitiría una mayor cantidad de CO₂ que el vehículo convencional.

Esto se podría extender a un escenario de flota mixta, donde una porción de vehículos de una flota convencional son reemplazados por eléctricos, respetando la visita de clientes del conjunto de rutas original. Si la distancia total de las rutas eléctricas es 60 % mayor que la distancia original requerida para visitar los mismos clientes, entonces habría un aumento en la emisión total de la flota provocado por los vehículos eléctricos.

Capítulo 6. Conclusiones

6.1. Sumario

En este proyecto se estudió el problema de enrutamiento de vehículos con ventanas de tiempo, considerando una flota convencional y una flota mixta, bajo un enfoque multiobjetivo. Para ello, se utilizó un conjunto de casos de prueba compatible con ambas versiones del problema y se minimizaron dos funciones objetivo: distancia total recorrida y tiempo total de espera. Para obtener el conjunto de rutas correspondiente a cada solución, se diseñaron cinco algoritmos de decodificación: para obtener una flota convencional, una flota mixta compuesta mayormente por vehículos eléctricos (Max-Electric), una flota mixta equilibrada (Balanced V1 y Balanced V2) o una flota mixta que no visite estaciones de recarga (No-Stations).

Por cada algoritmo, se realizó una serie de experimentos utilizando los casos de prueba seleccionados y aplicando el algoritmo NSGA-II. Con los resultados obtenidos, se analizó la diferencia de calidad, en términos de distancia y tiempo de espera, entre los frentes no dominados obtenidos con el algoritmo de flota convencional y los frentes conseguidos con los cuatro algoritmos para flota mixta. Además, se calculó la emisión total de CO₂ de la solución con menor distancia de cada frente no dominado, considerando las emisiones directas de los vehículos convencionales y las emisiones indirectas de los eléctricos. Con estos datos, se analizó la diferencia de emisiones entre las soluciones con flota convencional y las soluciones con flota mixta.

6.2. Conclusiones

Después de los experimentos realizados, se encontró que los mejores resultados en distancia, obtenidos de cada frente no dominado, no se acercan a los reportados por Goeke & Schneider (2015). El mejor algoritmo de flota mixta obtuvo un error relativo con respecto a las soluciones de Goeke & Schneider (2015) de entre 3.71 % y 19.31 %. Sin embargo, esta no es una comparación justa dado que el enfoque de dicho trabajo considera minimizar solo la distancia total recorrida.

Respecto a la comparación de frentes no dominados, se conjetura que conforme aumenta el número de clientes en los casos de prueba, el frente no dominado obtenido con el algoritmo Balanced V2 se aproxima

al frente de flota convencional debido a que las rutas eléctricas se asemejan a las rutas convencionales, encontrando que en promedio una ruta eléctrica presenta un aumento en distancia no mayor a 6 %, al compararla con una ruta de la flota convencional. También, se conjetura que los frentes de flota mixta dominan las soluciones con menor tiempo de espera de la flota convencional, debido a que el tiempo invertido en visitas a estaciones de recarga permite que se habiliten las ventanas de tiempo de los clientes por visitar. Además, el frente no dominado de la flota que evita hacer recargas, mejora su distancia conforme aumenta el número de clientes en los casos de prueba, debido a que la distancia entre nodos se va acortando, permitiendo que un vehículo eléctrico visite más clientes con una sola carga de batería, además de que no hay desviaciones a estaciones de recarga.

Por su parte, la flota mixta equilibrada, construida con el algoritmo Balanced V2, presenta las mejores soluciones con menor distancia recorrida, de las cuatro flotas mixtas estudiadas, respecto a la relación de compromiso entre aumento en distancia y reducción de emisiones de CO₂. En promedio, la flota presenta un aumento en distancia de 3.54 % a cambio de una disminución de 8.51 % en emisión total por recarga y 14.65 % en emisión por consumo. Suponiendo que las estaciones de recarga funcionaran con energía limpia, las soluciones del algoritmo Balanced V2 lograrían, en promedio, una reducción de emisiones de CO₂ de 44.26 % a cambio de un aumento en distancia de 3.54 %. Dicha reducción sería congruente con el porcentaje de vehículos eléctricos que conforman la flota, el cual va del 44.37 % al 49 %.

Los resultados de emisiones por recarga de las soluciones obtenidas con el algoritmo No-Stations, demuestran que a pesar de no recargar batería fuera de la central, es posible presentar una mayor emisión que la de una flota convencional. Esto se debe a que es necesario desplegar un mayor número de vehículos eléctricos para cumplir con la distribución, requiriendo más recargas iniciales. Además, los vehículos convencionales pueden llegar a recorrer largas distancias para visitar a los clientes inalcanzables, generando una mayor emisión de CO₂.

Se concluye también, que el deterioro en calidad de los frentes de flota mixta, observado al compararlos con el frente de flota convencional, se debe a un aumento en la distancia total recorrida. Este aumento es provocado por ambos tipos de vehículo: los eléctricos hacen desviaciones para visitar estaciones de recarga, llegando a formar ciclos que inician y terminan en la misma estación de recarga; y los vehículos convencionales hacen recorridos más extensos al visitar clientes inalcanzables con una separación notable entre ellos.

Por último, al comparar las emisiones de CO₂ de las soluciones con menor distancia de cada flota mixta con la emisión de la solución óptima en distancia de la flota convencional, se encontró que en algunos

casos la flota mixta emite más que la convencional. Esto se debe a que la emisión promedio por vehículo convencional en la flota mixta es mayor que la de un vehículo en la flota convencional, de forma que el porcentaje de aumento en emisiones correspondientes a rutas convencionales supera el porcentaje de reducción conseguido por las rutas con vehículos eléctricos.

6.3. Trabajo futuro

A continuación se presentan algunas ideas de investigación que pueden servir para dar continuidad a este trabajo:

- Resolver el VRP con flota convencional y flota mixta, minimizando distancia recorrida y total de emisiones de CO₂ para determinar en que grado ambas funciones objetivo entran en conflicto y cuáles son los factores adicionales a la distancia que influyen en las emisiones directas e indirectas.
- Aplicar una estrategia similar a la presentada por Romero-Ocaño et al. (2022), donde a partir de un conjunto de rutas definido para una flota convencional, se reemplazan vehículos convencionales por eléctricos, haciendo los ajustes necesarios para que los recorridos sean factibles.
- Considerar recargas parciales en lugar de recargas completas, con el fin de reducir los tiempos de ruta y disminuir las emisiones indirectas por recarga, además de implementar un modelo de recarga de batería realista, como el propuesto por Montoya et al. (2017).
- Explorar otras estrategias para la recarga de vehículos eléctrico, por ejemplo, recargar cada vez que el vehículo pase cerca de una estación de recarga, sin importar el nivel de energía restante.
- Considerar la velocidad como una variable de decisión, con lo cual cada arista puede ser recorrida con una velocidad diferente, influyendo en los tiempos de ruta y la energía o combustible consumido.
- Contemplar otros factores de emisión al momento de calcular las emisiones indirectas de CO₂, con lo cual se podría analizar el impacto ambiental de los vehículos eléctricos para diferentes regiones, como China, India o Estados Unidos (IEA (2020)).
- Utilizar otros conjuntos de casos de prueba, como el propuesto por Solomon (1987), para evidenciar la robustez de los algoritmos de decodificación diseñados y averiguar si los patrones identificados en los resultados de este proyecto se presentan en casos de prueba diferentes.

- Diseñar un nuevo conjunto de casos de prueba basado en un caso de estudio local, para analizar la factibilidad de la inclusión de vehículos eléctricos en la flota y conocer los niveles de emisión total de CO₂ tanto para una flota convencional como para una eléctrica o mixta.

Literatura citada

- Amazon (2021). Amazon's custom electric delivery vehicles are starting to hit the road. <https://www.aboutamazon.com/news/transportation/amazons-custom-electric-delivery-vehicles-are-starting-to-hit-the-road>.
- Baker, B. M. & Ayechev, M. (2003). A genetic algorithm for the vehicle routing problem. *Computers & Operations Research*, 30(5):787–800.
- Barth, M. & Boriboonsomsin, K. (2008). Real-world carbon dioxide impacts of traffic congestion. *Transportation Research Record*, 2058(1):163–171. <https://doi.org/10.3141/2058-20>.
- Barth, M., Younglove, T., & Scora, G. (2005). Development of a heavy-duty diesel modal emissions and fuel consumption model. *UC Berkeley: California Partners for Advanced Transportation Technology*.
- Bektaş, T. & Laporte, G. (2011). The pollution-routing problem. *Transportation Research Part B: Methodological*, 45(8):1232–1250. <https://doi.org/10.1016/j.trb.2011.02.004>.
- Berger, J. & Barkaoui, M. (2003). A new hybrid genetic algorithm for the capacitated vehicle routing problem. *Journal of the Operational Research Society*, 54:1254–1262.
- Bimbo, G. (2022). Informe anual integrado 2021. <https://www.grupobimbo.com/index.php/es/inversionistas/reportes/informes-anuales>.
- Brizuela, C. & Juárez, J. (2019). Optimización evolutiva multi-objetivo. In Coello, C., editor, *Computación Evolutiva*, capítulo 6, (pp.177–217). Academia Mexicana de Computación.
- CFR (2022). Passenger automobile average fuel economy standards. <https://www.ecfr.gov/current/title-49/subtitle-B/chapter-V/part-531>.
- Christofides, N. (1976). The vehicle routing problem. *Revue française d'automatique, informatique, recherche opérationnelle. Recherche opérationnelle*, 10(V1):55–70.
- Christofides, N. & Eilon, S. (1969). An algorithm for the vehicle-dispatching problem. *Journal of the Operational Research Society*, 20(3):309–318.
- Clarke, G. & Wright, J. W. (1964). Scheduling of vehicles from a central depot to a number of delivery points. *Operations Research*, 12(4):568–581. <https://doi.org/10.1287/opre.12.4.568>.
- Cordeau, J.-F., Gendreau, M., & Laporte, G. (1997). A tabu search heuristic for periodic and multi-depot vehicle routing problems. *Networks: An International Journal*, 30(2):105–119.
- Cuda, R., Guastaroba, G., & Speranza, M. G. (2015). A survey on two-echelon routing problems. *Computers & Operations Research*, 55:185–199.
- Dantzig, G. (1959). The truck dispatching problem. *Management Science*, (1):80–91.
- Deb, K. & Jain, H. (2013). An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part i: solving problems with box constraints. *IEEE transactions on evolutionary computation*, 18(4):577–601.
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197. <https://doi.org/10.1109/4235.996017>.
- Demir, E., Bektaş, T., & Laporte, G. (2012). An adaptive large neighborhood search heuristic for the pollution-routing problem. *European Journal of Operational Research*, 223(2):346–359. <https://doi.org/10.1016/j.ejor.2012.06.044>.

- Demir, E., Bektaş, T., & Laporte, G. (2014). The bi-objective pollution-routing problem. *European Journal of Operational Research*, 232(3):464–478.
- DHL (2021). Dhl: Pioneer in the use of battery electric commercial vehicles. <https://dhl-freight-connections.com/en/sustainability/dhl-pioneer-in-the-use-of-battery-electric-commercial-vehicles/>.
- EFTE (2022). Challenges: Road freight. <https://www.transportenvironment.org/challenges/road-freight/>.
- EIA (2022). Carbon dioxide emissions coefficients. https://www.eia.gov/environment/emissions/co2_vol_mass.php.
- Eiben, A. E. & Smith, J. E. (2015). *What is an evolutionary algorithm?*, (pp.25–48). Springer Berlin Heidelberg, Berlin, Heidelberg.
- Erdoğan, S. & Miller-Hooks, E. (2012). A green vehicle routing problem. *Transportation research part E: logistics and transportation review*, 48(1):100–114.
- Gendreau, M., Hertz, A., & Laporte, G. (1994). A tabu search heuristic for the vehicle routing problem. *Management science*, 40(10):1276–1290.
- Goeke, D. & Schneider, M. (2015). Routing a mixed fleet of electric and conventional vehicles. *European Journal of Operational Research*, 245(1):81–99. <https://doi.org/10.1016/j.ejor.2015.01.049>.
- Golden, B. L., Raghavan, S., Wasil, E. A., et al. (2008). *The vehicle routing problem: latest advances and new challenges*, volume 43. Springer.
- Gonçalves, F., Cardoso, S. R., & Relvas, S. (2011). Optimization of a distribution network using electric vehicles: A vrp problem. In *Proceedings of the IO2011-15 Congresso da associação Portuguesa de Investigação Operacional, Coimbra, Portugal*, 103–114. Faculdade de Economia da Universidade de Coimbra.
- Hiermann, G., Hartl, R. F., Puchinger, J., & Vidal, T. (2019). Routing a mix of conventional, plug-in hybrid, and electric vehicles. *European Journal of Operational Research*, 272(1):235–248. <https://doi.org/10.1016/j.ejor.2018.06.025>.
- Hiquebran, D., Alfa, A., Shapiro, J., & Gittoes, D. (1993). A revised simulated annealing and cluster-first route-second algorithm applied to the vehicle routing problem. *Engineering Optimization*, 22(2):77–107.
- IEA (2020). Carbon intensity of electricity generation in selected countries and regions, 2000-2020. <https://www.iea.org/data-and-statistics/charts/carbon-intensity-of-electricity-generation-in-selected-countries-and-regions-2000-2020>.
- IEA (2021). Global energy review 2021. <https://www.iea.org/reports/global-energy-review-2021>.
- IEA (2022a). Global ev outlook 2022. <https://www.iea.org/reports/global-ev-outlook-2022>.
- IEA (2022b). Transport. <https://www.iea.org/reports/transport>. License: CC BY 4.0.
- Jozefowicz, N., Semet, F., & Talbi, E.-G. (2008). Multi-objective vehicle routing problems. *European journal of operational research*, 189(2):293–309.

- Knowles, J. & Corne, D. (2002). On metrics for comparing nondominated sets. In *Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02 (Cat. No. 02TH8600)*, volume 1, 711–716. IEEE.
- Koç, Ç., Bektaş, T., Jabali, O., & Laporte, G. (2014). The fleet size and mix pollution-routing problem. *Transportation Research Part B: Methodological*, 70:239–254. <https://doi.org/10.1016/j.trb.2014.09.008>.
- Koç, Ç., Bektaş, T., Jabali, O., & Laporte, G. (2016). The impact of depot location, fleet composition and routing on emissions in city logistics. *Transportation Research Part B: Methodological*, 84(2001):81–102. <https://doi.org/10.1016/j.trb.2015.12.010>.
- Konstantakopoulos, G. D., Gayialis, S. P., Kechagias, E. P., Papadopoulos, G. A., & Tatsiopoulos, I. P. (2020). A multiobjective large neighborhood search metaheuristic for the vehicle routing problem with time windows. *Algorithms*, 13(10):243.
- Laporte, G. (2009). Fifty years of vehicle routing. *Transportation Science*, 43(4):408–416. <https://doi.org/10.1287/trsc.1090.0301>.
- Laporte, G. (2010). A concise guide to the traveling salesman problem. *Journal of the Operational Research Society*, 61(1):35–40. <https://doi.org/10.1057/jors.2009.76>.
- Lenstra, J. K. & Kan, A. R. (1981). Complexity of vehicle routing and scheduling problems. *Networks*, 11(2):221–227.
- Lin, C., Choy, K. L., Ho, G. T., Chung, S. H., & Lam, H. (2014). Survey of green vehicle routing problem: past and future trends. *Expert systems with applications*, 41(4):1118–1138.
- Macrina, G., Di Puglia Pugliese, L., Guerriero, F., & Laporte, G. (2019). The green mixed fleet vehicle routing problem with partial battery recharging and time windows. *Computers and Operations Research*, 101:183–199. <https://doi.org/10.1016/j.cor.2018.07.012>.
- Mitchell, M. (1995). Genetic algorithms: An overview. In *Complex.*, volume 1, 31–39. Citeseer.
- Montoya, A., Guéret, C., Mendoza, J. E., & Villegas, J. G. (2017). The electric vehicle routing problem with nonlinear charging function. *Transportation Research Part B: Methodological*, 103:87–110.
- Pelletier, S., Jabali, O., & Laporte, G. (2019). The electric vehicle routing problem with energy consumption uncertainty. *Transportation Research Part B: Methodological*, 126:225–255. <https://doi.org/10.1016/j.trb.2019.06.006>.
- Qin, H., Su, X., Ren, T., & Luo, Z. (2021). A review on the electric vehicle routing problems: Variants and algorithms. *Frontiers of Engineering Management*, 8:370–389.
- Qureshi, A., Taniguchi, E., & Yamada, T. (2009). An exact solution approach for vehicle routing and scheduling problems with soft time windows. *Transportation Research Part E: Logistics and Transportation Review*, 45(6):960–977.
- Rocha, D., Aloise, D., Aloise, D. J., & Contardo, C. (2022). Visual attractiveness in vehicle routing via bi-objective optimization. *Computers and Operations Research*, 137(June 2021):105507. <https://doi.org/10.1016/j.cor.2021.105507>.
- Romero-Ocaño, A. D., Cosío-León, M., Valenzuela-Alcaraz, V. M., & Brizuela, C. A. (2022). The impact of gradually replacing fossil fuel-powered vehicles with electric ones: A bi-objective optimisation approach. *Expert Systems with Applications*, 194(January):116546. <https://doi.org/10.1016/j.eswa.2022.116546>.

- Schneider, M., Stenger, A., & Goeke, D. (2014). The electric vehicle-routing problem with time windows and recharging stations. *Transportation science*, 48(4):500–520.
- Scora, G. & Barth, M. (2006). Comprehensive modal emissions model (cmem), version 3.01. *User guide*. Centre for environmental research and technology. University of California, Riverside, 1070:1580.
- SEDEMA (2022). Hoy no circula. <https://sedema.cdmx.gob.mx/programas/programa/hoy-no-circula>.
- SEMARNAT (2022). Factor de emisión del sistema eléctrico nacional 2021. https://www.gob.mx/cms/uploads/attachment/file/706809/aviso_fesen_2021.pdf.
- Solomon, M. M. (1987). Algorithms for the vehicle routing and scheduling problems with time window constraints. *Operations research*, 35(2):254–265.
- Solomon, M. M. & Derosiers, J. (1988). Time window constrained routing and scheduling problems. *Transportation Science*, 22(1):1–13. <https://doi.org/10.1287/trsc.22.1.1>.
- Srinivas, N. & Deb, K. (1994). Multiobjective optimization using nondominated sorting in genetic algorithms. *Evolutionary computation*, 2(3):221–248.
- Stehling, T. M., Freitas Souza, M. J., & de Souza, S. R. (2021). Variable neighborhood descent branching applied to the green electric vehicle routing problem with time window and mixed fleet. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12559 LNCS:14–27. https://doi.org/10.1007/978-3-030-69625-2_2.
- Taillard, É., Badeau, P., Gendreau, M., Guertin, F., & Potvin, J.-Y. (1997). A tabu search heuristic for the vehicle routing problem with soft time windows. *Transportation science*, 31(2):170–186.
- Taillard, É. D. (1999). A heuristic column generation method for the heterogeneous fleet vrp. *RAIRO-Operations Research*, 33(1):1–14.
- Taş, D., Dellaert, N., Van Woensel, T., & De Kok, T. (2013). Vehicle routing problem with stochastic travel times including soft time windows and service costs. *Computers & Operations Research*, 40(1):214–224.
- UN (2022). Net zero coalition. <https://www.un.org/en/climatechange/net-zero-coalition>.
- UNEP (2022). Emissions gap report 2022. <https://www.unep.org/resources/emissions-gap-report-2022>.
- UNFCCC (2020). The paris agreement. <https://unfccc.int/process-and-meetings/the-paris-agreement>.
- Woller, D., Kozák, V., & Kulich, M. (2021). The GRASP metaheuristic for the electric vehicle routing problem. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12619 LNCS:189–205. https://doi.org/10.1007/978-3-030-70740-8_12.
- Xiao, Y., Zhao, Q., Kaku, I., & Xu, Y. (2012). Development of a fuel consumption optimization model for the capacitated vehicle routing problem. *Computers & operations research*, 39(7):1419–1431.
- Yu, B. & Yang, Z. Z. (2011). An ant colony optimization model: The period vehicle routing problem with time windows. *Transportation Research Part E: Logistics and Transportation Review*, 47(2):166–181.

- Yu, V. F., Jodiawan, P., & Gunawan, A. (2021). An adaptive large neighborhood search for the green mixed fleet vehicle routing problem with realistic energy consumption and partial recharges. *Applied Soft Computing*, 105. <https://doi.org/10.1016/j.asoc.2021.107251>.
- Zhang, Q. & Li, H. (2007). Moea/d: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, 11(6):712–731. <https://doi.org/10.1109/TEVC.2007.892759>.
- Zhang, W., Yang, D., Zhang, G., & Gen, M. (2020). Hybrid multiobjective evolutionary algorithm with fast sampling strategy-based global search and route sequence difference-based local search for vrptw. *Expert Systems with Applications*, 145:113151.
- Zhao, P., Liu, F., Guo, Y., Duan, X., & Zhang, Y. (2021). Bi-objective optimization for vehicle routing problems with a mixed fleet of conventional and electric vehicles and soft time windows. *Journal of Advanced Transportation*, 2021. <https://doi.org/10.1155/2021/9086229>.
- Zitzler, E., Laumanns, M., & Bleuler, S. (2004). A tutorial on evolutionary multiobjective optimization. *Metaheuristics for multiobjective optimisation*, 535(535):21–40.
- Zitzler, E. & Thiele, L. (1998). Multiobjective optimization using evolutionary algorithms—a comparative case study. In *Parallel Problem Solving from Nature—PPSN V: 5th International Conference Amsterdam, The Netherlands September 27–30, 1998 Proceedings 5*, 292–301. Springer.
- Zitzler, E. & Thiele, L. (1999). Multiobjective evolutionary algorithms: A comparative case study and the strength pareto approach. *IEEE Transactions on Evolutionary Computation*, 3(4):257–271.
- Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C. M., & Da Fonseca, V. G. (2003). Performance assessment of multiobjective optimizers: An analysis and review. *IEEE Transactions on Evolutionary Computation*, 7(2):117–132. <https://doi.org/10.1109/TEVC.2003.810758>.

Anexo

A. Comparación de desempeño: NSGA-II vs MOEA/D

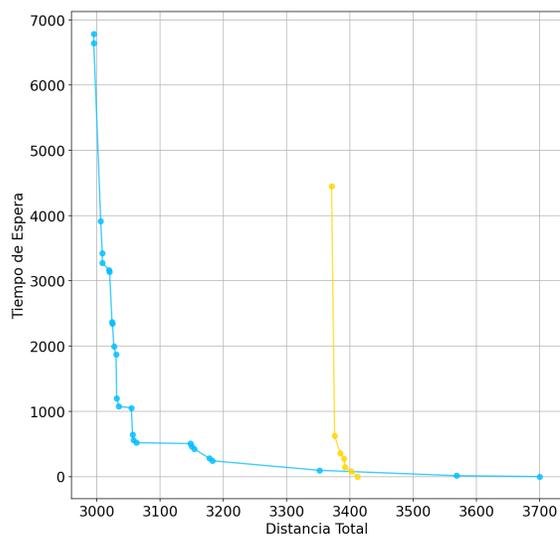
A continuación, se presentan ejemplos donde se compara la calidad de los frentes no dominados obtenidos con los algoritmos NSGA-II y MOEA/D. Los parámetros de NSGA-II pueden consultarse en la Tabla 4. Los parámetros utilizados para la ejecución del algoritmo MOEA/D se describen en la Tabla 22.

Tabla 22. Parámetros del algoritmo MOEA/D.

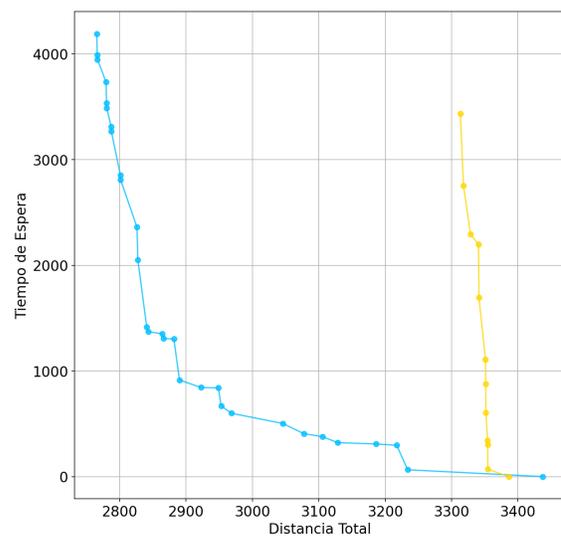
Parámetro	Valor
Tamaño de población	300
Número de generaciones	2000
Probabilidad de cruzamiento	1
Probabilidad de mutación	0.3
Tamaño de vecindario	30

La Figura 22 muestra cuatro comparaciones entre los frentes no dominados obtenidos con NSGA-II (en color azul) y MOEA/D (en color amarillo) correspondientes a casos de prueba de 100 clientes y en los que se considera una flota convencional.

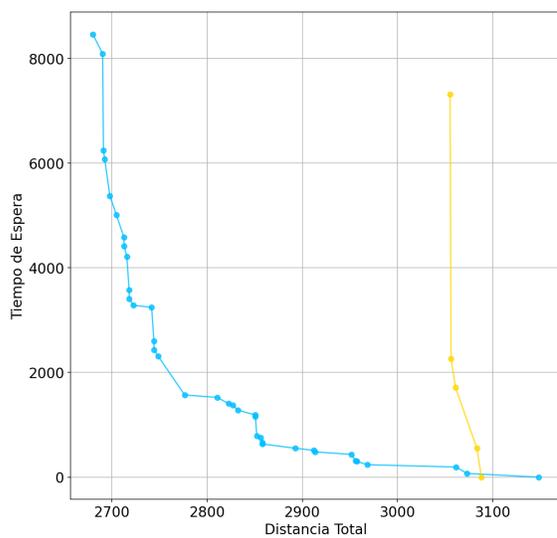
Después, la Figura 23 muestra también cuatro comparaciones entre los frentes obtenidos con NSGA-II y MOEA/D correspondientes a los mismos casos de prueba, pero ahora considerando una flota mixta construida con el algoritmo Balanced V2.



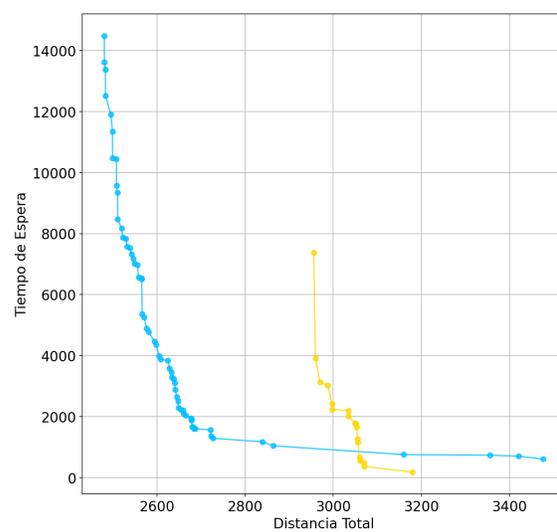
(a)



(b)

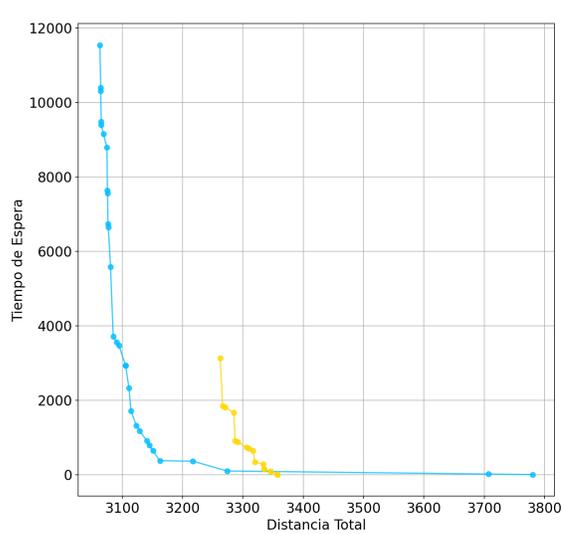


(c)

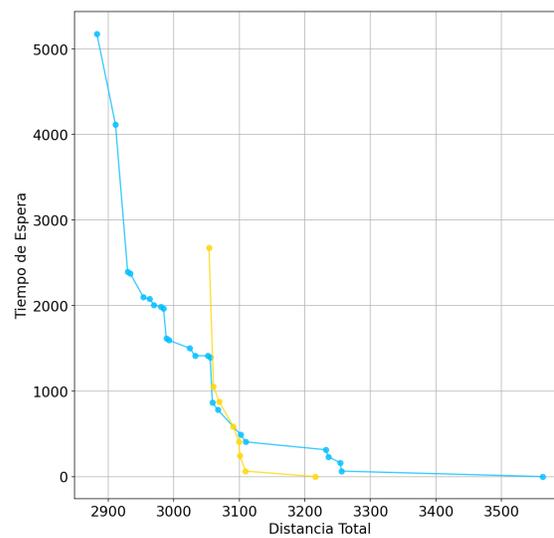


(d)

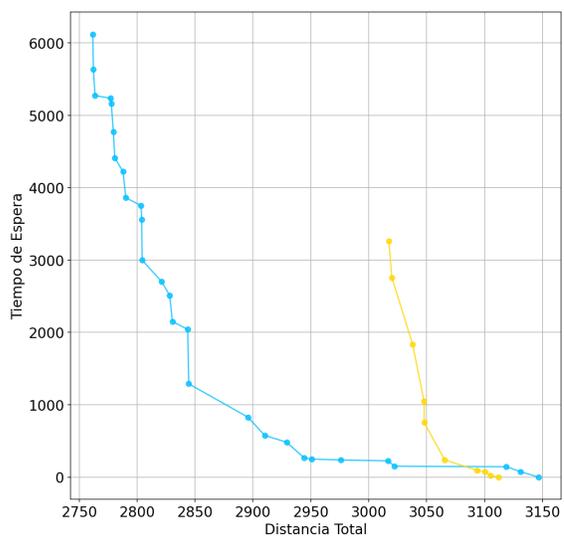
Figura 22. Comparación de frentes no dominados obtenidos para casos de 100 clientes y flota convencional, con NSGA-II (azul) y MOEA/D (amarillo).



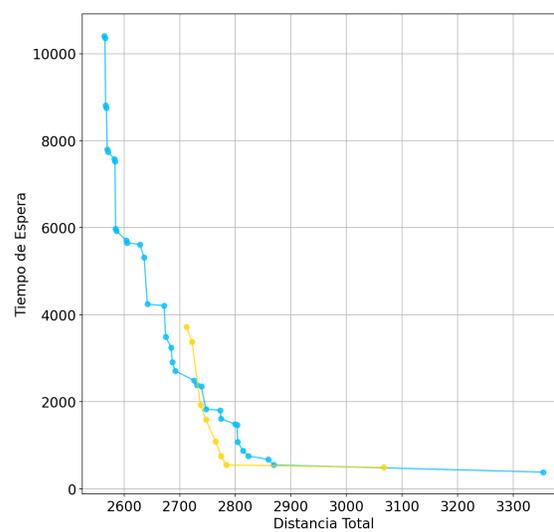
(a)



(b)



(c)



(d)

Figura 23. Comparación de frentes no dominados obtenidos para casos de 100 clientes y flota mixta (Balanced V2), con NSGA-II (azul) y MOEA/D (amarillo).