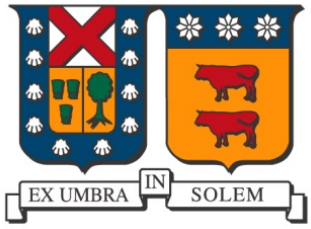
UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INFORMÁTICA
VALPARAÍSO - CHILE



“LOCALIZACIÓN DE CONTENEDORES Y DISEÑO DE RUTAS DE RECOLECCIÓN DE RESIDUOS RECICLABLES DOMICILIARIOS.”

FELIPE ANDRÉS JOSÉ SAN MARTÍN IRARRÁZABAL

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL EN INFORMÁTICA

Profesor Guía: Elizabeth Montero
Profesor Correferente: Nicolás Rojas-Morales

Octubre - 2025

CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ■ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: LOCALIZACIÓN DE CONTENEDORES Y DISEÑO DE RUTAS DE RECOLECCIÓN DE RESIDUOS RECICLABLES DOMICILIARIOS

Nombre del candidato(a): FELIPE ANDRÉS JOSÉ SAN MARTÍN IRARRÁZABAL

Carrera / Grado: INGENIERIA CIVIL INFORMÁTICA

Campus: CASA CENTRAL **Departamento:** Informática

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Elizabeth Montero , en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

■ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por **(marcar una opción)**:

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:



Fecha: 28 -Octubre – 2025 **Firma:** _____

Estudiante o Candidato(a):



Fecha: 28 – Octubre – 2025 **Firma:** _____

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

DEDICATORIA

Dedico este trabajo a mi mamá, mi papá, mi hermana y mi familia, quienes me brindaron apoyo incondicional y siempre confiaron en mis capacidades. A mis amigos, que estuvieron presentes para apoyarme y animarme en los momentos difíciles. A mi pareja, que me acompañó y ayudó a sobrellevar la etapa más desafiante de la redacción de este escrito.

AGRADECIMIENTOS

A mis padres, que se esforzaron por brindarme acceso a la educación que me permite escribir esta memoria. A mis compañeros, que me brindaron apoyo, ánimo y compañía para sobrellevar la carrera. A la Sra. Elkins, que me abrió las puertas de su hogar durante mi estadía en Valparaíso. A la profesora Elizabeth Montero, que fue muy dedicada y atenta durante el desarrollo de este escrito. Y a mi yo del pasado, que al final sí se pudo.

RESUMEN

Resumen— Este trabajo aborda el problema integrado de localización de puntos limpios y diseño de rutas de recolección de residuos reciclables multicompartimento en el contexto de la Ley REP en Chile. Se desarrolló un algoritmo Max-Min Ant System (MMAS) que optimiza simultáneamente ubicación de contenedores y planificación de rutas mediante matrices de feromonas separadas para localización (MCFLP) y ruteo (MCVRP). El modelo gestiona diferentes tipos de residuos bajo restricciones de capacidad. La validación utilizó datos reales de Renca (1061 centroides, 52 ubicaciones) evaluando escenarios con tasas de reciclaje del 10 % (2025) y 65 % (2040). Los resultados muestran que existen casos en los cuales el enfoque integrado supera la resolución secuencial tradicional, logrando reducciones del 5.1 % en distancia total y consolidación en menos rutas. La relevancia radica en proporcionar una herramienta práctica para municipalidades que facilita decisiones basadas en evidencia, cuantifica el impacto del incremento en tasas de reciclaje y contribuye a la optimización combinatoria aplicada a logística urbana sostenible.

Palabras Clave— MMAS; MCFLPVRP; Ley REP; Residuos Reciclables; Optimización

ABSTRACT

Abstract— This work addresses the integrated problem of locating recycling facilities and designing multi-compartment recyclable waste collection routes in the context of the REP Law in Chile. A Max-Min Ant System (MMAS) algorithm was developed that simultaneously optimizes container location and route planning using separate pheromone matrices for location (MCFLP) and routing (MCVRP). The model manages different types of waste under capacity constraints. The validation used real data from Renca (1061 centroids, 52 locations), evaluating scenarios with recycling rates of 10 % (2025) and 65 % (2040). The results show that there exists instances in which the integrated approach outperforms the traditional sequential solution, achieving reductions of 5.1 % in total distance and consolidation into fewer routes. The relevance lies in providing a practical tool for municipalities that facilitates evidence-based decisions, quantifies the impact of increased recycling rates, and contributes to combinatorial optimization applied to sustainable urban logistics.

Keywords— MMAS; MCFLPVRP; REP Law; Recyclable Waste; Optimization

GLOSARIO

UTFSM: Universidad Técnica Federico Santa María
DI: Departamento de Informática (UTFSM)
REP: Responsabilidad Extendida del Productor (Ley REP, Chile)
FLP: *Facility Location Problem* (problema de localización de instalaciones)
VRP: *Vehicle Routing Problem* (problema de ruteo de vehículos)
MCVRP: *Multiple Compartiment Vehicle Routing Problem* (ruteo con múltiples compartimentos)
CLP: *Container Location Problem* (localización de contenedores/puntos limpios)
MCFLP: *Multi-Compartment Facility Location Problem* (localización con múltiples compartimentos)
MCFLP–VRP / MCFLPVRP: Modelo integrado de localización (MCFLP) y ruteo (MCVRP) con compartimentos
ACO: *Ant Colony Optimization* (metaheurística de optimización por colonia de hormigas)
MMAS: *Max–Min Ant System* (variante de ACO con cotas de feromona)

ÍNDICE DE CONTENIDOS

RESUMEN iv

ABSTRACT iv

GLOSARIO v

ÍNDICE DE FIGURAS viii

ÍNDICE DE TABLAS viii

INTRODUCCIÓN 1

1 Objetivos y alcances de la memoria 2

DEFINICIÓN DEL PROBLEMA 4
2.1 Problema de localización de contenedores (FLP) . . . 5
2.2 Problema de ruteo de vehículos (VRP) . . . 6
2.3 Problema de ruteo de vehículos con múltiples compartimentos (MCVRP) . . . 6
2.4 Integración con el problema de ubicación de instalaciones (MCVRP–FLP) . . . 7
2.5 Modelo integrado de localización y ruteo con compartimientos . . . 8

PROPUESTA DE SOLUCIÓN 12
3.1 Visión General . . . 12
3.2 Contexto y selección de la Metaheurística . . . 12
3.2.1 Análisis de alternativas (ACO vs otras metaheurísticas) . . . 12
3.2.2 Fundamentos de Ant Colony Optimization . . . 12
3.2.3 Max-Min Ant System: Variante de ACO seleccionada . . . 13
3.3 Representación de la solución . . . 14
3.3.1 Estructura de Datos Principal . . . 14
3.3.2 Representación de la Fase MCFLP . . . 15
3.3.3 Representación de la Fase MCVRP . . . 16
3.3.4 Ejemplo de Instanciación . . . 17
3.3.5 Instanciación de Estructuras de Datos . . . 17
3.4 Algoritmo MMAS para MCFLPVRP . . . 18
3.4.1 Notación y parámetros . . . 18
3.4.2 Estructura general del algoritmo . . . 19
3.4.3 Inicialización del Algoritmo . . . 21
3.4.4 Construcción de Soluciones: Fase MCFLP . . . 21
3.4.5 Construcción de Soluciones: Fase MCVRP . . . 23
3.4.6 Actualización de Feromonas . . . 25
3.4.7 Mecanismos de Diversificación y Criterios de Parada . . . 26

4 MARCO EXPERIMENTAL 28

4.1 Formato de instancia . . . 28
4.2 Instancias de prueba: Aspectos generales . . . 31
4.3 Instancias de prueba . . . 33
4.3.1 Parámetros variables entre instancias . . . 33
4.3.2 Matriz de instancias generadas . . . 34
4.4 Configuración experimental . . . 35
4.4.1 Ambiente computacional . . . 35
4.4.2 Metodología de comparación . . . 36
4.4.3 Configuraciones de prueba para MMAS . . . 36
4.4.4 Parámetros experimentales . . . 37
4.5 Métricas de evaluación . . . 37

5 RESULTADOS **39**
5.1 Organización de resultados . . . 39
5.2 Resultados por instancia . . . 39
5.2.1 Escenario 2025 (10 % tasa de reciclaje) . . . 39
5.2.2 Escenario 2040 (65 % tasa de reciclaje) . . . 42
5.3 Análisis comparativo agregado . . . 45
5.4 Análisis particular de una instancia relevante - H03 . . . 46
5.4.1 Convergencia en la solucion de localización (MCFLP) . . . 47
5.4.2 Superioridad de MMAS en la optimización de rutas . . . 47
5.4.3 Eficiencia en el número de rutas . . . 48
5.4.4 Trade-off entre tiempo-calidad . . . 51
5.4.5 Implicaciones prácticas para la instancia H03 . . . 52
5.4.6 Comentarios finales sobre H03 . . . 52

CONCLUSIONES **53**
6.1 Cumplimiento de Objetivos . . . 53
6.2 Resultados Principales . . . 54
6.2.1 Calidad de Soluciones en Localización . . . 54
6.2.2 Eficiencia en Ruteo . . . 55
6.2.3 Diferencias entre Escenarios Temporales . . . 55
6.2.4 Eficiencia Computacional y Trade-offs . . . 56
6.3 Alcances y Limitaciones . . . 56
6.4 Aplicaciones y Valor de la Propuesta . . . 58
6.5 Recomendaciones y Trabajo Futuro . . . 60
6.5.1 Extensiones del Modelo . . . 60
6.5.2 Mejoras Algorítmicas . . . 60
6.5.3 Validación y Extensión Experimental . . . 61
6.6 Síntesis Final . . . 61

ANEXOS **62**

REFERENCIAS BIBLIOGRÁFICAS **63**

ÍNDICE DE FIGURAS

1 Antes y después de aplicar una solución al FLP de contenedores. Fuente: Elaboración propia. 5
2 Esquema ejemplo del problema de ruteo de vehículos (VRP). Fuente: Elaboración propia. 6
3 Esquema del problema de ruteo de vehículos con múltiples compartimentos (MCVRP). Fuente: Elaboración propia. 7
4 Antes y después de aplicar una solución al problema compuesto MCVRP–FLP. Fuente: Elaboración propia. 8
5 Ejemplo de archivo de entrada con el formato especial utilizado en este trabajo, inspirado en la notación de TSPLIB pero adaptado para el problema MCFLP/MCVRP. 30
6 Mapa de los centroides considerados para esta experimentación. Fuente: Elaboración propia. 31
7 Mapa de los puntos en donde es posible instalar un punto limpio. Fuente: Elaboración propia. 32
8 Ubicación de puntos limpios obtenida por Gurobi (2 fases) Fuente: Elaboración propia. 47
9 Ubicación de puntos limpios obtenida por MMAS. Las tres configuraciones MMAS convergieron a esta misma solución de localización Fuente: Elaboración propia. 48
10 Comparación de rutas de vehículos según diferentes configuraciones Fuente: Elaboración propia. 49
11 Puntos limpios instalados y rutas generadas por MMAS Config. 2 Fuente: Elaboración propia. 50

ÍNDICE DE TABLAS

1 Capacidades y costos de contenedores disponibles para la instalación de puntos limpios. Fuente: Elaboración propia. 33
2 Configuraciones de capacidad de contenedores por compartimento (litros). Fuente: Elaboración propia. 34
3 Configuraciones de capacidad de vehículos por compartimento (litros). Fuente: Elaboración propia. 34
4 Matriz completa de instancias de prueba generadas para la experimentación. Fuente: Elaboración propia. 35
5 Configuración de parámetros por método - VRP Fuente: Elaboración propia. . 37
6 Configuración de parámetros por método - MMAS Fuente: Elaboración propia. 37
7 Instancia H01: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 40
8 Instancia H02: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 40

9 Instancia H03: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 41
10 Instancia H04: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 41
11 Instancia H05: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 42
12 Instancia H06: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 42
13 Instancia H07: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 43
14 Instancia H08: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 43
15 Instancia H09: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 44
16 Instancia H10: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 44
17 Instancia H11: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 45
18 Instancia H12: Comparación de resultados - Promedio y mejor de 5 ejecuciones Fuente: Elaboración propia. 45
19 Resumen de métricas de cada método Fuente: Elaboración propia. 45

INTRODUCCIÓN

Este trabajo de memoria se lleva a cabo en el contexto de un proyecto de investigación relacionado con la recolección de desechos reciclables enfocado en lo que implica la ley REP [1]. Esta ley crea lo que se denomina Responsabilidad Extendida del Productor, obligando a los fabricantes de ciertos productos a organizar y financiar la gestión de los residuos derivados de los bienes que colocan en el mercado [Gobierno de Chile, 2024]. Esta ley fomenta, dentro de otras cosas, la optimización de la gestión de residuos y de reciclaje, es aquí donde surge el desafío del presente trabajo de memoria.

La problemática específica radica en el proceso de localización de contenedores y el diseño de rutas para la recolección de residuos domiciliarios reciclables. De acuerdo a [Pacto Chileno de los Plásticos, 2022], el 62 % de los chilenos que no reciclan señala que la falta de infraestructura es la principal razón. Además, considerando que Chile fue el país que más residuos generó en Sudamérica en el año 2023 [Croquevielle, 2023], es evidente la importancia de una gestión adecuada de los residuos reciclables.

Igualmente, es común que en muchas municipalidades no se realice reciclaje de manera efectiva, especialmente en localidades más extremas o desconectadas del país. En los casos en los que se implementa el reciclaje, a menudo no se hace con el objetivo de optimizar las rutas de recolección ni la localización de los contenedores. Esto resulta en una gestión ineficiente que afecta tanto el costo operativo como el impacto ambiental de las actividades de reciclaje.

Los actores involucrados en este proceso son diversos, incluyendo a las empresas que producen productos generadores de residuos - según lo estipula la Ley REP-, los ciudadanos, las municipalidades y los trabajadores del sector de manejo de residuos. Las empresas se ven afectadas por la necesidad de cumplir con las regulaciones ambientales y de reciclaje, los ciudadanos naturales buscan un entorno más limpio y saludable, las municipalidades enfrentan desafíos políticos para implementar políticas sostenibles, y los trabajadores del sector de residuos se benefician de un ambiente laboral más justo, con mejores condiciones de trabajo y horarios adaptados a las necesidades del servicio.

Este conjunto de actores hace necesario un enfoque más estructurado y eficiente en la localización de contenedores y en el diseño de rutas, permitiendo no solo cumplir con las normativas vigentes, sino también mejorar la calidad de vida de los ciudadanos y la sostenibilidad del entorno urbano.

Si las dificultades asociadas con el problema de enrutamiento de vehículos con múltiples compartimientos (MCVRP, *Multiple Compartment Vehicle Routing Problem*) y el problema de localizacion de basureros (FLP, *Facility Location Problem*) (ambos problemas se explican

[1] Ley No. 20920, establece un marco para la gestión de residuos, la responsabilidad extendida del productor y fomento al reciclaje.

más adelante en la sección **DEFINICIÓN DEL PROBLEMA**) no se abordan a corto y medio plazo, las consecuencias podrían ser significativas tanto para las municipalidades como para la sociedad en general. A corto plazo, la falta de optimización en las rutas de recolección generará un aumento en los costos operativos, debido al mayor consumo de recursos como combustible y tiempo. Esto también resultará en una baja eficiencia en la recolección, causando acumulación de residuos en los contenedores y problemas de higiene y salubridad en las áreas urbanas.

Además, la ausencia de compartimientos adecuados en los vehículos de recolección puede llevar a la contaminación cruzada entre distintos tipos de residuos reciclables, afectando negativamente la capacidad de procesamiento en las plantas de reciclaje y reduciendo la cantidad de materiales reutilizables. Asimismo, una ubicación inadecuada de los contenedores disminuirá la accesibilidad para los ciudadanos, desincentivando la separación correcta de residuos y reduciendo las tasas de reciclaje.

A medio plazo, la ineficiencia en la recolección y el manejo de residuos reciclables contribuirá a un incremento en la cantidad de residuos mal gestionados, lo que tendrá un impacto negativo en el medio ambiente al aumentar la contaminación del suelo, agua y aire. Además, la falta de una gestión adecuada aumentará la presión sobre los vertederos, acelerando su saturación y demandando la creación de nuevos espacios para gestionar residuos no reciclados.

Las municipalidades que no logren implementar una logística eficiente enfrentarán mayores dificultades económicas, lo que podría resultar en descontento social y problemas laborales en el sector de manejo de residuos. Asimismo, la falta de resolución de estos problemas llevará a una pérdida de oportunidades de valorización de los residuos reciclables, comprometiendo así potenciales ingresos a través de la venta de materiales reciclados y el cumplimiento de las leyes de responsabilidad extendida del productor. En conjunto, la falta de soluciones para estos problemas generará un círculo vicioso de ineficiencia, altos costos y efectos negativos sobre la sostenibilidad y la calidad de vida en las ciudades.

Objetivos y alcances de la memoria

El objetivo principal de la memoria es desarrollar una solución integral para la localización de contenedores de reciclaje y el enrutamiento de vehículos para la recolección de residuos reciclables, abordando simultáneamente ambos problemas. Esta solución busca optimizar la eficiencia operativa, reducir costos, y mejorar el impacto ambiental de las operaciones de recolección y reciclaje. Al integrar ambos problemas en un solo marco de optimización, se pretende garantizar una correcta clasificación de los residuos, evitar la contaminación cruzada, y maximizar la eficacia del sistema de recolección. La implementación de esta solución se llevará a cabo en un lenguaje de programación eficiente, basado en algoritmos del estado del arte y técnicas meta-heurísticas para abordar las complejidades inherentes a ambos problemas de manera efectiva.

- Objetivo General: Diseñar y desarrollar una propuesta heurística integral que optimice la ubicación de contenedores para residuos reciclables domiciliarios, así como la planificación eficiente de las rutas de recolección, encontrando una solución óptima del problema de forma simultánea.

- Objetivos Específicos

    1. Realizar un estudio del estado del arte sobre la localización de contenedores y el diseño de rutas de recolección de forma conjunta, analizando las metodologías y enfoques existentes en la literatura para abordar estos problemas.
    2. Seleccionar los métodos más adecuados para resolver los problemas de localización de contenedores y optimización de rutas de forma conjunta, evaluando su aplicabilidad y efectividad en el contexto de la gestión de residuos reciclables.
    3. Proponer un algoritmo de localización y optimización de rutas que aborde simultáneamente ambos problemas, maximizando la eficiencia en la recolección y mejorando la planificación logística.
    4. Evaluar el modelo propuesto utilizando datos reales de la comuna de Renca, analizando la eficiencia en la recolección y la reducción de gastos operativos en comparación con el sistema actual.

El alcance de la memoria incluye la implementación de algoritmos eficientes que busca encontrar la mejor ubicación posible para los contenedores y las rutas óptimas para los vehículos, considerando las restricciones específicas del *Multi-Compartment Vehicle Routing Problem*, como los compartimientos múltiples, y las necesidades del *Container Location Problem*. Además, se evaluará la eficacia de la solución propuesta mediante análisis comparativos, con el fin de demostrar su aplicabilidad y ventajas sobre soluciones existentes en el ámbito de la optimización logística. Para esto, se realizarán pruebas y estudios basados en casos reales de una comuna de Santiago, con el objetivo de validar la propuesta en un entorno práctico y evaluar su impacto en la gestión de residuos reciclables.

DEFINICIÓN DEL PROBLEMA

El encontrar una solución para estos problemas tiene implicaciones significativas en diversos contextos. En primer lugar, la optimización de rutas y la ubicación de contenedores se puede aplicar a la distribución de productos en cadenas de suministro, donde una mejora en la eficiencia puede reducir costos operativos, optimizar tiempos de entrega y maximizar la utilización de recursos.

Además, la planificación de servicios de emergencia y rescate también se beneficia enormemente de soluciones eficientes en la localización de recursos y la optimización de rutas. Una gestión eficaz puede asegurar una respuesta rápida y efectiva a emergencias, mejorando el tiempo de llegada y los resultados de las intervenciones. De manera similar, la gestión de recursos hídricos en áreas urbanas se optimiza mediante la correcta ubicación de infraestructuras y la planificación eficiente de rutas, facilitando una distribución equitativa y reduciendo el desperdicio de recursos.

Aunque ya existen soluciones para problemas relacionados con la distribución de productos y la logística, la mayoría de estas se centran en resolver problemas específicos por separado. La novedad y relevancia de este trabajo radica en la integración simultánea de los problemas MCVRP [Ostermeier *et al.*, 2021] y CLP [Ghiani *et al.*, 2012] (también referenciado como FLP) como un único problema general. La solución propuesta no solo aborda las complejidades de cada problema individualmente, sino que también ofrece una estrategia integral que optimiza ambos aspectos de manera conjunta. Este enfoque integrado es crucial, ya que permite una gestión más coherente y eficiente en contextos específicos como la recolección de residuos reciclables, donde las soluciones convencionales pueden no ser adecuadas. Por lo tanto, esta investigación ofrece una contribución significativa al abordar y resolver ambos problemas simultáneamente, mejorando la eficiencia y sostenibilidad en múltiples aplicaciones industriales y urbanas.

La solución a ambos problemas se basa en la línea de investigación dentro de la informática conocida como optimización combinatoria, que abarca técnicas para encontrar la mejor solución posible en problemas donde existen múltiples combinaciones posibles. Este campo está estrechamente vinculado con áreas como la investigación Operativa y la teoría de grafos, que permiten modelar y resolver problemas de transporte y logística a través de algoritmos avanzados, como aquellos de búsqueda heurística, programación entera, o metaheurísticas.

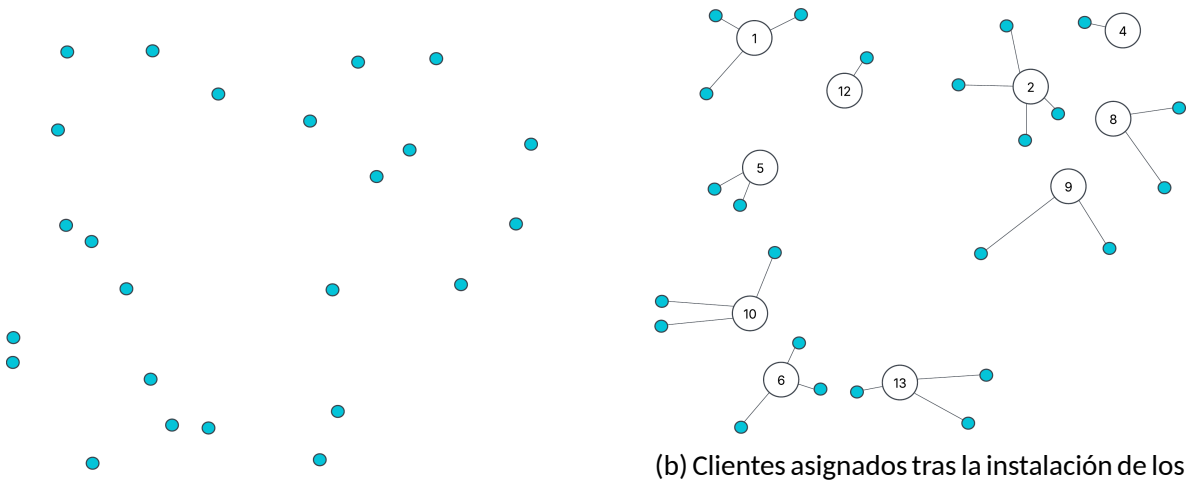
El problema de enrutamiento de vehículos con múltiples compartimientos y el problema de localización de contenedores requieren la resolución de problemas NP-duros, lo que implica que su complejidad aumenta exponencialmente con el tamaño del problema. Por ello, la optimización se convierte en una herramienta esencial para encontrar soluciones eficientes y viables dentro de tiempos razonables. Esto es especialmente crucial cuando se manejan grandes volúmenes de datos o se enfrentan restricciones complejas, como la clasificación adecuada de los residuos en diferentes compartimientos de los vehículos o la correcta dis-

tribución geográfica de los contenedores en áreas urbanas.

A continuación, se detallarán los problemas individuales, para luego introducir el problema integrado, comenzando con el Problema de Localización de Contenedores [Ghiani *et al.*, 2012] (CLP), seguido por el Problema de Enrutamiento de Vehículos con Múltiples Compartimientos [Ostermeier *et al.*, 2021] (MCVRP) explicando en cada uno su relevancia dentro del contexto de la gestión de residuos reciclables.

2.1. Problema de localización de contenedores (FLP)

El problema de localización de contenedores de materiales reciclables se puede considerar como una instancia específica del **Facility Location Problem** (FLP). Consiste en determinar los lugares óptimos para ubicar contenedores destinados a la recolección de residuos reciclables, de modo que se minimicen tanto los costos operativos de la recolección como las distancias que deben recorrer los ciudadanos para depositar sus residuos.



(a) Ubicación de los clientes a cubrir.

(b) Clientes asignados tras la instalación de los contenedores.

Figura 1: Antes y después de aplicar una solución al FLP de contenedores.
Fuente: Elaboración propia.

Una correcta localización de los contenedores es fundamental para asegurar una alta participación ciudadana en el reciclaje. Si los puntos de recolección se sitúan demasiado lejos o no están distribuidos estratégicamente, se reduce la motivación de las personas para separar sus residuos y aumentan los costos operativos al requerirse más recursos o rutas ineficientes. Este desafío se agrava en zonas urbanas densamente pobladas o de difícil acceso, donde optimizar la cobertura y la eficiencia de las rutas es crítico.

La figura 1 ilustra este proceso: en la subfigura 1a los usuarios (puntos turquesa) muestran la demanda inicial, y en la subfigura 1b los círculos numerados son los contenedores abiertos

tras resolver el FLP, mientras que las líneas conectan cada cliente con el contenedor más cercano, evidenciando la cobertura de cada instalación.

2.2. Problema de ruteo de vehículos (VRP)

El **Vehicle Routing Problem** (VRP) consiste en planificar rutas eficientes para una flota de vehículos que debe distribuir o recoger mercancías (o residuos) en un conjunto de clientes, minimizando un coste operativo (por ejemplo, tiempo o distancia recorrida) y satisfaciendo restricciones como la capacidad de los vehículos o las ventanas de tiempo de servicio.

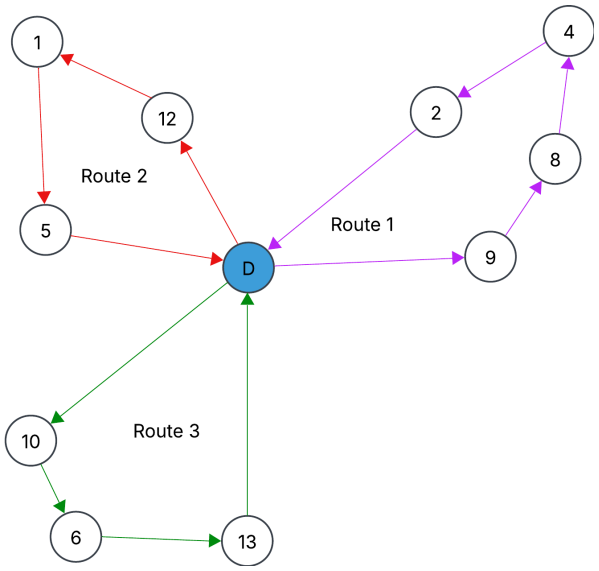


Figura 2: Esquema ejemplo del problema de ruteo de vehículos (VRP).
Fuente: Elaboración propia.

En la Figura 2 se muestra un ejemplo ilustrativo: los nodos numerados son puntos de recolección, el nodo D representa el depósito de origen y las flechas, codificadas por color, indican las tres rutas cerradas que siguen los vehículos. En este caso, el vehículo 1 visita cuatro puntos, el vehículo 2 atiende tres y el vehículo 3 recorre otros tres destinos.

2.3. Problema de ruteo de vehículos con múltiples compartimentos (MCVRP)

El **Multi Compartment Vehicle Routing Problem** (MCVRP) extiende el VRP clásico añadiendo la gestión interna de varios compartimentos diferenciados dentro de cada vehículo, de modo que distintos tipos de carga no se mezclen.

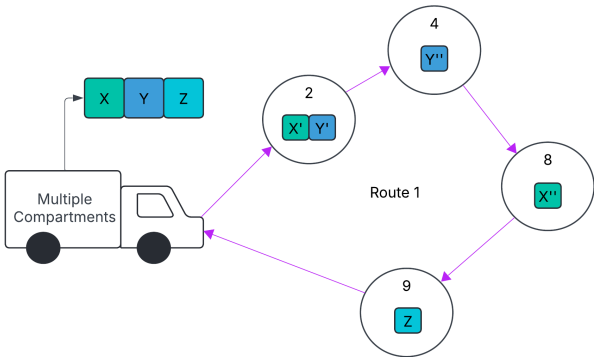


Figura 3: Esquema del problema de ruteo de vehículos con múltiples compartimentos (MCVRP).
Fuente: Elaboración propia.

En la Figura 3, el vehículo dispone de tres compartimentos (X, Y y Z). Durante la ruta, en los nodos (puntos limpios) con desechos $X^{'}$ y $X^{''}$ se realiza la carga/descarga del compartimento X; en $Y^{'}$ y $Y^{''}$, del compartimento Y; y en Z, del compartimento Z. Las flechas muestran la secuencia óptima que permite atender cada tipo de material sin violar la capacidad de los compartimentos.

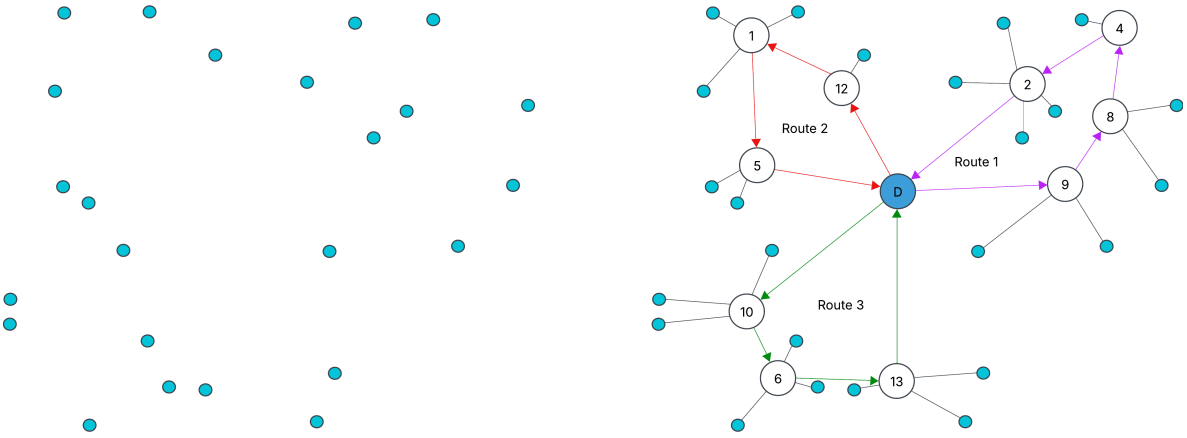
La separación en compartimentos es esencial en la recolección de residuos reciclables (aceites, aparatos eléctricos, baterías, envases, neumáticos, pilas, etc.) para evitar contaminación cruzada y garantizar la viabilidad del reciclaje [Gobierno de Chile, 2024]. Así, el MCVRP no solo minimiza costes de transporte, sino que también asegura que cada compartimento conserve su pureza y no supere su capacidad.

2.4. Integración con el problema de ubicación de instalaciones (MCVRP–FLP)

En muchas operaciones logísticas es crucial decidir simultáneamente dónde ubicar los depósitos y cómo diseñar las rutas de la flota. Al integrar el MCVRP con el FLP, se obtiene un modelo compuesto que:

- Selecciona la localización óptima de los depósitos (FLP).
- Planifica las rutas de los vehículos desde y hacia esos depósitos, minimizando costes de transporte (VRP/MCVRP).

La Figura 4b ilustra cómo a la decisión de apertura de instalaciones se superpone la construcción de rutas óptimas, lo que permite reducir de forma conjunta los costes de infraestructura y de operación de la flota [Fu *et al.*, 2022].



(a) Ubicación de los clientes, previa a la instalación de puntos limpios y obtención de rutas.

(b) Esquema del problema compuesto MCVRP–FLP.

Figura 4: Antes y después de aplicar una solución al problema compuesto MCVRP–FLP. Fuente: Elaboración propia.

2.5. Modelo integrado de localización y ruteo con compartimientos

Supuestos:

- Se asume que la demanda de cualquier centroide individual puede ser satisfecha completamente por un único punto limpio, es decir, no se requiere dividir la demanda de un centroide entre múltiples instalaciones. Más explícitamente, no se define previamente un centroide si su basura debe dividirse en más de un punto limpio; esto para cumplir con que no pase más de un camión de basura por punto limpio.
- Se considera el conjunto de rutas de solución como la composición de todas las rutas necesarias por recorrer, y no necesariamente la cantidad de vehículos disponibles; es decir, existen los siguientes casos:
    1. Se tienen más camiones que rutas, por lo que podrían quedar camiones sin utilizar si esto minimiza la función objetivo.
    2. Se tiene la misma cantidad de rutas que de camiones, por lo que cada camión realiza una única ruta.
    3. Se tienen más rutas que camiones; por lo tanto, si un camión termina su ruta antes, éste se vacía y puede realizar otra ruta más. Esto es más logístico para el empleador de los camioneros, quien deberá distribuir la carga de acuerdo con lo necesario.

Conjuntos e índices:

$$
\begin{aligned}
I &: \{\text{centroides de generación de residuos}\},\\
J &: \{\text{ubicaciones candidatas de punto limpio}\},\\
K &: \{\text{tipos de residuo / compartimientos}\},\\
V &: \{\text{vehículos disponibles}\},\\
N &:= J \cup \{0\}, \quad 0 = \text{depósito (depot)}.
\end{aligned}
$$

Parámetros:

$$
\begin{aligned}
h_{ik} &: \text{residuos de tipo } k \text{ generados en } i \in I,\\
C_k^F &: \text{capacidad de cada compartimiento } k \text{ en un punto limpio},\\
C_k^T &: \text{capacidad de cada compartimiento } k \text{ en un camión},\\
f_j &: \text{costo fijo de instalar un punto limpio en } j \in J,\\
c_{ij} &: \text{coste (distancia/tiempo) de ir de } i \to j\ ,\ i,j \in N.
\end{aligned}
$$

Variables de decisión:

$$
\begin{aligned}
y_j \in \{0,1\} &\ : \text{ 1 si abrimos el punto limpio } j \in J,\\
w_{ij} \in \{0,1\} &\ : \text{ 1 si el centroide } i \in I \text{ se asigna al punto limpio } j,\\
u_v \in \{0,1\} &\ : \text{ 1 si usamos el camión } v \in V,\\
z_{jv} \in \{0,1\} &\ : \text{ 1 si el camión } v \in V \text{ visita el punto limpio } j \in J,\\
x_{ijv} \in \{0,1\} &\ : \text{ 1 si el camión } v \in V \text{ recorre el arco } i \to j\ ,\ i,j \in N.
\end{aligned}
$$

Función objetivo (balanceada):

$$
(1) \quad \text{mín} \quad \underbrace{\sum_{j\in J} f_j y_j}_{\substack{\text{costo de instalación}\\ \text{de puntos limpios}}} + \gamma \underbrace{\sum_{v\in V}\sum_{i\in N}\sum_{j\in N} c_{ij}\, x_{ijv}}_{\substack{\text{costo total}\\ \text{de rutas}}} \quad (0 \le \gamma \le 1)
$$

La función objetivo balanceada descrita en (1) permite explorar el compromiso entre la inversión en infraestructura y el coste operativo de las rutas. El primer término, $\sum_{j\in J} y_j$, penaliza directamente el número de contenedores instalados, mientras que el segundo, $\gamma \sum v \in V \sum_{i,j\in N} c_{ij}\, x_{ijv}$, refleja el gasto total de desplazamiento de la flota. Al ajustar el parámetro γ en el intervalo $[0,1]$, el planificador puede privilegiar la reducción de contenedores (valores bajos de γ) o la minimización de la distancia recorrida (valores altos de γ), obteniendo así soluciones adaptadas a distintos escenarios presupuestarios y operacionales.

Las ecuaciones (2)–(4) garantizan que cada centroide de generación de residuos se asigne a exactamente un punto limpio abierto y que la demanda de cada tipo no exceda la capacidad

de los compartimentos instalados. Las restricciones (5) y (6) aseguran que todo punto limpio abierto sea visitado únicamente por vehículos activos, mientras que (7) y (8) imponen que cada ruta comience en el depósito y termine en él. Las igualdades de flujo entrante y saliente en cada nodo, dadas por (9) y (10), preservan la conectividad de las rutas. La condición (11) limita la carga transportada en cada compartimento de un vehículo según su capacidad, y la restricción (12) establece la naturaleza binaria de todas las variables de decisión. Este conjunto de restricciones, junto con la función objetivo (1), modela de forma integral el problema de localización y ruteo con múltiples compartimentos.

Restricciones:

(2)	$\sum_{j\in J} w_{ij} = 1$	$\forall\, i \in I$	(cada centroide asignado a un punto limpio)
(3)	$w_{ij} \le y_j$	$\forall\, i \in I,\ j \in J$	(solo a puntos limpios abiertos)
(4)	$\sum_{i\in I} h_{ik}\, w_{ij} \le C_k^F\, y_j$	$\forall\, j \in J,\ k \in K$	(capacidad en puntos limpios)
(5)	$\sum_{v\in V} z_{jv} = y_j$	$\forall\, j \in J$	(cada punto limpio abierto es visitado)
(6)	$z_{jv} \le u_v$	$\forall\, j \in J,\ v \in V$	(solo camiones activos visitan)
(7)	$\sum_{j\in J} x_{0jv} = u_v$	$\forall\, v \in V$	(salida desde depósito)
(8)	$\sum_{i\in J} x_{i0v} = u_v$	$\forall\, v \in V$	(retorno al depósito)
(9)	$\sum_{i\in N} x_{ijv} \;=\; z_{jv}$	$\forall\, j \in J,\ v \in V$	(flujo entrante = visita)
(10)	$\sum_{\ell\in N} x_{j\ell v} \;=\; z_{jv}$	$\forall\, j \in J,\ v \in V$	(flujo saliente = visita)
(11)	$\sum_{j\in J}\Big(\sum_{i\in I} h_{ik}\, w_{ij}\Big) z_{jv} \le C_k^T\, u_v$	$\forall\, v \in V,\ k \in K$	(capacidad en camiones)
(12)	$y_j,\ w_{ij},\ u_v,\ z_{jv},\ x_{ijv} \in \{0,1\}$	$\forall\, j \in J,\ i \in I,\ v \in V.$	

Datos de entrada:

- **Ubicaciones de los centroides.** Coordenadas (X_i, Y_i) para cada $i \in I$.
- **Generación de residuos por tipo.** Cantidades h_{ik} de residuo de tipo $k \in K$ producidas en cada centroide $i \in I$.

- **Ubicaciones candidatas de punto limpio.** Conjunto J de coordenadas (X_j, Y_j) donde puede instalarse un punto limpio.
- **Posición del depósito.** Coordenadas del nodo 0, origen y destino de todas las rutas.
- **Capacidades de compartimientos en puntos limpios.** Para cada $j \in J$ y cada $k \in K$, capacidad máxima C_k^F del compartimento.
- **Capacidades de compartimientos en camiones.** Para cada vehículo $v \in V$ y cada $k \in K$, capacidad C_k^T del compartimento en el camión.
- **Costes de desplazamiento y sentidos.** Matriz de costes c_{ij} y orientaciones (sentidos) de cada arco en el grafo dirigido sobre $N = J \cup \{0\}$.
- **Flota ilimitada.** Se asume que $|V|$ es suficientemente grande para cubrir todas las rutas sin restricción de número de vehículos.

PROPUESTA DE SOLUCIÓN

3.1. Visión General

Para el problema planteado, se seleccionó una estrategia de implementación que combina el análisis del estado del arte con criterios de factibilidad, eficiencia computacional y posibilidad de escalado. En la sección anterior se definieron los componentes clave del modelo integrado de ruteo–localización con compartimientos, identificando las variables de decisión y las restricciones asociadas a capacidades y costes. A continuación, se presenta el algoritmo propuesto, el detalle de sus principales componentes y cómo este busca una solución optima para el problema compuesto MCVRP+FLP.

3.2. Contexto y selección de la Metaheurística

La metaheurística seleccionada es la denominada *Ant Colony Optimization*, que implementa computacionalmente una aproximación al comportamiento natural de las hormigas en una colonia [Dorigo y Gambardella, 1997b].

3.2.1. Análisis de alternativas (ACO vs otras metaheurísticas)

En la literatura existen otros algoritmos inspirados en el comportamiento de distintas especies, como la *Bee Colony Optimization* [Tong *et al.*, 2025]; sin embargo, dado que este último se enfoca en la calidad de las soluciones en problemas con variaciones temporales—y el problema propuesto no presenta fluctuaciones significativas en el tiempo—no resulta adecuado para el caso tratado en este escrito.

Ant Colony Optimization fue propuesta originalmente por *Dorigo et al.* [Dorigo y Gambardella, 1997a] a finales de los años noventa y ha sido objeto de múltiples estudios en diversos campos dado que es especialmente efectiva en problemas relacionados al ruteo [Sundareswaran *et al.*, 2016].

3.2.2. Fundamentos de Ant Colony Optimization

El funcionamiento básico de ACO se basa en cómo un conjunto de agentes artificiales (hormigas) construyen soluciones de forma iterativa y probabilística, guiándose por dos tipos de información. El primer tipo de información es la *feromona artificial* τ_{ij}, que representa la experiencia acumulada sobre qué decisiones han llevado a buenas soluciones en iteraciones anteriores. La segunda fuente de información es la *información heurística* η_{ij}, que aporta

conocimiento específico del problema. Por ejemplo, para problemas de distancia más corta, se puede preferir arcos más cortos mediante $\eta_{ij} = 1/c_{ij}$. En cada iteración, cada hormiga construye una solución. En cada paso de la construcción, una hormiga en el nodo i selecciona el siguiente nodo j con una probabilidad proporcional a $[\tau_{ij}]^{\alpha} \cdot [\eta_{ij}]^{\beta}$, donde α y β son parámetros que balancean la importancia de la experiencia colectiva frente al conocimiento heurístico. Una vez que todas las hormigas completan sus soluciones, se actualizan los niveles de feromona. Primero se aplica una *evaporación* $\tau_{ij} \leftarrow (1-\rho) \cdot \tau_{ij}$ que reduce gradualmente todos los valores, permitiendo olvidar información obsoleta. Segundo, las hormigas que obtuvieron mejores soluciones *depositan* feromona adicional en los componentes que utilizaron, reforzando así los caminos prometedores. Este ciclo—construcción probabilística, evaluación de soluciones y actualización de feromonas—se repite durante una cierta cantidad de iteraciones, permitiendo que el algoritmo converja hacia soluciones de alta calidad mediante un balance natural entre la exploración de nuevas alternativas y la explotación de las.

Por su naturaleza, ACO permite codificar simultáneamente la decisión de apertura de instalaciones y la construcción de rutas compartimentadas, garantizando el respeto de las capacidades y flujos definidos en el modelo.

Además, ACO admite esquemas de paralelismo en la construcción de soluciones—cada "hormiga" puede ejecutarse en un hilo o proceso independiente—optimizando así el uso de recursos computacionales en problemas de gran complejidad. También existen implementaciones específicas para la parte de MCVRP que explotan directamente la dinámica de feromonas en rutas con múltiples compartimientos [Reed *et al.*, 2014].

3.2.3. Max-Min Ant System: Variante de ACO seleccionada

En particular se implementará la variante Max-Min Ant System (MMAS [Stützle y Hoos, 2000]), una adaptación del Ant Colony System clásico que introduce tres cambios clave:

- Impone cotas inferiores y superiores $\left[\tau_{\text{mín}}, \tau_{\text{máx}}\right]$ a cada nivel de feromona, evitando así tanto la saturación excesiva como la dispersión mínima que lleva al estancamiento.
- Sólo la mejor solución de cada iteración (o la mejor global) está autorizada a depositar feromona, siguiendo un esquema elitista que acelera la convergencia hacia rutas de alta calidad.
- Todos los arcos se inicializan con el valor máximo de feromona $\tau_{\text{máx}}$ y, en caso de detectarse falta de progreso (stall), son reiniciados para mejorar la exploración.

Finalmente implementar Max-Min Ant System a este problema tiene las siguientes ventajas:

- Construcción conjunta de apertura de basureros y diseño de rutas, de modo que cada decisión de localización se evalúe inmediatamente en función de su impacto en la parte de ruteo.
- Uso de probabilidades guiadas por feromona y heurística que equilibran la exploración (evaporación de feromonas, $\tau_{\text{mín}}$, reinicios por estancamiento) con la explotación de los recorridos y asignaciones más prometedores.
- Capacidad para reforzar simultáneamente tanto las aristas $(i \to j)$ de la fase FLP como los tramos $(j \to \ell)$ de la fase MCVRP, garantizando que las soluciones de bajo costo refuercen conjuntamente la apertura de basureros y las rutas resultantes.
- Flexibilidad para incorporar la cobertura en bloque de múltiples centroides, respetando restricciones de capacidad compartimento por compartimento, sin necesidad de resolver subproblemas enteros en cada iteración.
- Facilidad de paralelización: cada hormiga construye la solución FLP+MCVRP de forma independiente, lo que permite explotar procesamiento multi-núcleo al ejecutar varias hormigas simultáneamente.

Por estas razones, Min–Max Ant System constituye un enfoque eficiente y bien fundamentado para resolver el problema integrado de localización de basureros y ruteo de vehículos con compartimentos, aprovechando la retroalimentación de feromonas para coordinar ambas etapas y converge robustamente hacia soluciones de buena calidad en un espacio de búsqueda complejo.

3.3. Representación de la solución

La representación de una solución para el problema conjunto de MCFLP y MCVRP se basa en una estructura de datos compuesta que integra las decisiones de ambas fases del problema: la localización de instalaciones (MCFLP) y el ruteo de vehículos (MCVRP). Esta representación debe permitir tanto la evaluación eficiente de la función objetivo como la aplicación de operadores de búsqueda durante el proceso de optimización metaheurística.

3.3.1. Estructura de Datos Principal

Una solución s se representa mediante una tupla $s = (A, Y, Q, \mathcal{R})$ donde:

- A: Estructura de asignación centroide-instalación
- Y: Conjunto de instalaciones abiertas

- Q: Estructura de capacidades por instalación y compartimento
- $\mathcal{R}$: Conjunto de rutas de vehículos

Esta descomposición modular permite manipular independientemente cada componente del problema mientras se mantiene la consistencia global de la solución.

3.3.2. Representación de la Fase MCFLP

La componente de localización se representa mediante tres estructuras de datos complementarias:

Asignación de Centroides: La asignación se implementa mediante una tabla hash o arreglo directo $A : \{1, \ldots, m\} \to \{1, \ldots, n\}$ que mapea cada centroide i a su instalación asignada j. Esta estructura permite consultas de asignación en tiempo $O(1)$:

$$A[i] = j \quad \Leftrightarrow \quad \text{el centroide } i \text{ es servido por la instalación } j$$

Conjunto de Instalaciones Abiertas: El estado de apertura de instalaciones se representa mediante un vector binario $Y \in \{0, 1\}^n$ donde:

$$Y[j] = \begin{cases} 1 & \text{si la instalación } j \text{ está abierta} \\ 0 & \text{en caso contrario} \end{cases}$$

Adicionalmente, se mantiene el contador $|Y| = \sum_{j=1}^{n} Y[j]$ que indica el número total de instalaciones abiertas.

Estructura de Capacidades: Para cada instalación j y compartimento k, se mantienen dos matrices complementarias $Q^{\text{occ}}, Q^{\text{rem}} \in \mathbb{Z}_{\geq 0}^{n \times K}$ que representan las capacidades ocupadas y remanentes respectivamente:

$$Q^{\text{occ}}[j, k] + Q^{\text{rem}}[j, k] = Q_{\text{máx}}[k], \quad \forall j \in \{1, \ldots, n\}, \forall k \in \{1, \ldots, K\}$$

donde $Q_{\text{máx}}[k]$ es la capacidad máxima del compartimento k en cualquier instalación. Esta redundancia intencional permite verificaciones de factibilidad en $O(1)$ durante la construcción de soluciones, mediante:

$$\text{Factible}(i, j, k) \equiv Q^{\text{rem}}[j, k] \geq D[i, k]$$

donde $D[i, k]$ representa la demanda del centroide i en el compartimento k.

3.3.3. Representación de la Fase MCVRP

La componente de ruteo se representa mediante un conjunto de estructuras que describen las trayectorias de los vehículos.

Estructura de Ruta Individual: Cada ruta $r \in \mathcal{R}$ se implementa como una lista enlazada o arreglo dinámico que contiene:

$$r = (S_r, L_r, \ell_r) \tag{1}$$

donde:

- $S_r = [v_0, v_1, \ldots, v_{\ell_r - 1}, v_0]$ es la secuencia ordenada de nodos, con v_0 representando el depósito y $v_i \in Y$ para $i \geq 1$
- $L_r \in \mathbb{Z}^K_{\geq 0}$ es un vector que almacena la carga transportada por compartimento: $L_r[k] = \sum_{p=1}^{\ell_r - 1} Q^{\text{occ}}[v_p, k]$
- $\ell_r = |S_r|$ es la longitud de la secuencia (número de nodos visitados más el retorno al depósito)

Esta representación permite calcular la distancia total de la ruta como:

$$d(r) = \sum_{p=0}^{\ell_r - 2} T[S_r[p], S_r[p+1]] \tag{2}$$

donde T es la matriz de distancias nodo-nodo precalculada.

Conjunto de Rutas: El conjunto completo de rutas se representa como $\mathcal{R} = \{r_1, r_2, \ldots, r_V\}$ donde $V = |\mathcal{R}|$ es el número de vehículos utilizados. Se mantiene la siguiente propiedad de cobertura:

$$\bigcup_{r \in \mathcal{R}} (S_r \setminus \{v_0\}) = Y \tag{3}$$

es decir, toda instalación abierta debe ser visitada por exactamente una ruta.

3.3.4. Ejemplo de Instanciación

Para ilustrar la representación, considérese una instancia con $m = 9$ centroides, $n = 6$ nodos candidatos y $K = 3$ compartimentos. Una solución factible se instanciaría como se describe a continuación.

3.3.5. Instanciación de Estructuras de Datos

Estructuras MCFLP. Las asignaciones de clientes a instalaciones están dadas por el vector $\mathbf{A} = [2, 4, 4, 6, 2, 6, 2, 6, 6]$. El estado de las instalaciones se representa mediante $\mathbf{Y} = [0, 1, 0, 1, 0, 1]$ con $|\mathbf{Y}| = 3$, indicando que las instalaciones activas son $\{2, 4, 6\}$.

La ocupación por compartimento $\mathbf{Q}^{\text{occ}}$ (instalación $\times$ compartimento) está dada por:

$$\mathbf{Q}^{\text{occ}} = \begin{bmatrix} 0 & 0 & 0 \\ 150 & 100 & 80 \\ 0 & 0 & 0 \\ 120 & 90 & 70 \\ 0 & 0 & 0 \\ 180 & 140 & 110 \end{bmatrix}$$

donde las filas 1, 3 y 5 corresponden a instalaciones cerradas, mientras que las filas 2, 4 y 6 representan las instalaciones activas.

La capacidad remanente $\mathbf{Q}^{\text{rem}}$ se define como:

$$\mathbf{Q}^{\text{rem}} = \begin{bmatrix} 200 & 200 & 200 \\ 50 & 100 & 120 \\ 200 & 200 & 200 \\ 80 & 110 & 130 \\ 200 & 200 & 200 \\ 20 & 60 & 90 \end{bmatrix}$$

Estructuras MCVRP. Se utilizan $V = 2$ vehículos con el conjunto de rutas $R = \{r_1, r_2\}$. La ruta r_1 está definida por la secuencia $S_1 = [0, 2, 4, 0]$ con longitud $\ell_1 = 4$ y carga por compartimento $\mathbf{L}_1 = [270, 190, 150]$. Su distancia total es:

$$d(r_1) = T_{0,2} + T_{2,4} + T_{4,0}$$

La ruta r_2 se define mediante $S_2 = [0, 6, 0]$ con $\ell_2 = 3$ y carga $\mathbf{L}_2 = [180, 140, 110]$, con distancia:

$$d(r_2) = T_{0,6} + T_{6,0}$$

Esta representación es particularmente adecuada para algoritmos metaheurísticos basados en colonias de hormigas, donde múltiples soluciones deben ser construidas iterativamente mediante decisiones probabilísticas secuenciales, requiriendo verificaciones frecuentes de factibilidad y evaluaciones incrementales del costo.

3.4. Algoritmo MMAS para MCFLPVRP

3.4.1. Notación y parámetros

A continuación se presenta de manera estructurada y con notación uniforme el procedimiento de Max-Min Ant System (MMAS) para resolver conjuntamente el problema de Localización de Puntos Limpios (FLP) y Ruteo de Vehículos con Múltiples Compartimentos (MCVRP). Se usa la siguiente notación:

- I: Conjunto de centroides.
- J: Conjunto de instalaciones candidatas (puntos limpios).
- K: Número de compartimentos en cada instalación y cada vehículo.
- V: Conjunto de vehículos disponibles.
- c_{ij}: Distancia (o costo) entre el centroide $i \in I$ y la instalación $j \in J$.
- $c_{j\ell}$: Distancia (o costo) entre la instalación $j \in J$ y $\ell \in J$.
- $\tau_{ij}^{(1)}$: Feromona asociada a la asignación de $i \to j$ en la fase FLP.
- $\eta_{ij}^{(1)} = \frac{1}{c_{ij}}$: Valor heurístico para la asignación $i \to j$.
- $\tau_{j\ell}^{(2)}$: Feromona asociada al tramo de ruteo $j \to \ell$ en la fase MCVRP.
- $\eta_{j\ell}^{(2)} = \frac{1}{c_{j\ell}}$: Valor heurístico para el tramo $j \to \ell$.
- $\alpha,\ \beta$: Exponente de feromona y heurística, respectivamente.
- ρ: Tasa de evaporación de feromona, $0 < \rho < 1$.
- Q: Constante de depósito de feromona.
- $\tau_{\text{mín}},\ \tau_{\text{máx}}$: Límites inferior y superior para cada τ.
- $T_{\text{máx}}$: Número máximo de iteraciones (generaciones de hormigas).
- stall_limit: Máximo número de iteraciones sin mejora antes de reiniciar feromonas.

- U: Conjunto dinámico de centroides aún no asignados, $U \subseteq I$.
- $y_j \in \{0, 1\}$: Variable que indica si la instalación j está abierta.
- capRem$_j[k]$: Capacidad remanente en el compartimento k de la instalación j.
- demanda$_i[k]$: Demanda del centroide i en el compartimento k.
- R_j: Radio de cobertura de la instalación j (para asignar centroides en bloque).
- $u_v \in \{0, 1\}$: Variable que indica si el vehículo v ha sido utilizado.
- capVeh$_v[k]$: Capacidad remanente del vehículo v en el compartimento k.
- $x_{ijv} \in \{0, 1\}$: 1 si el vehículo v recorre el arco $i \to j$ en la solución de ruteo.
- $\gamma \in (0, 1)$: Coeficiente que pondera el número de instalaciones abiertas vs. distancia total recorrida.

3.4.2. Estructura general del algoritmo

El algoritmo implementado corresponde a una adaptación del Max-Min Ant System (MMAS) para resolver el problema MCFLPVRP. La estrategia consiste en una construcción secuencial en dos fases: primero se resuelve la componente de localización de instalaciones mediante la asignación de centroides a nodos candidatos, y posteriormente se construyen las rutas de vehículos sobre las instalaciones abiertas. El algoritmo mantiene matrices de feromonas independientes para cada fase, las cuales son actualizadas únicamente por la mejor solución encontrada hasta el momento. Además, se incorporan mecanismos de reinicialización de feromonas para escapar de óptimos locales cuando se detecta estancamiento en la búsqueda. El pseudocódigo general del algoritmo se presenta en el algoritmo 1.

El algoritmo se estructura en tres etapas principales: inicialización de estructuras auxiliares y matrices heurísticas (líneas 2-12), construcción iterativa de soluciones mediante información feromonal y heurística (líneas 14-28), y actualización adaptativa de feromonas con mecanismos de intensificación y diversificación (líneas 30-40). La separación de las matrices de feromonas permite que cada fase del problema evolucione de manera semi-independiente, mientras que los límites τ_{max} y τ_{min} se ajustan dinámicamente en función de la calidad de la mejor solución global, implementando así el principio fundamental de MMAS.

Algorithm 1 MMAS para MCFLPVRP

Require: Instancia del problema, número de hormigas m, parámetros $\alpha, \beta, \rho, \gamma$
Ensure: Mejor solución s^* y su costo z^*

// Inicialización
Precalcular matrices de distancias y demandas
Calcular matrices heurísticas η_{MCFLP} y η_{MCVRP} (distancias normalizadas)
// Determinar límites iniciales de feromonas
$z_{init} \leftarrow$ mejor costo entre m soluciones greedy construidas
$\tau_{max} \leftarrow 1/(\rho \cdot z_{init})$
$\tau_{min} \leftarrow \tau_{max}/(2m)$
// Inicializar feromonas
$\tau_{MCFLP} \leftarrow \tau_{max}$ (todas las posiciones válidas)
$\tau_{MCVRP} \leftarrow \tau_{max}$ (todas las posiciones válidas)
$z^* \leftarrow \infty$
$contador_{estancamiento} \leftarrow 0$
// Ciclo principal
for $iter = 1$ **hasta** $max\_iteraciones$ **do**
    // Construir soluciones
    for $k = 1$ **hasta** m **do**
        Construir fase MCFLP usando $\tau^{\alpha}_{MCFLP} \cdot \eta^{\beta}_{MCFLP}$
        Construir fase MCVRP usando $\tau^{\alpha}_{MCVRP} \cdot \eta^{\beta}_{MCVRP}$
        Evaluar solución s_k y obtener costo z_k
    end for
    // Actualizar mejor solución
    if mín$(z_k) < z^*$ **then**
        $z^* \leftarrow$ mín(z_k)
        $s^* \leftarrow$ solución correspondiente
        $contador_{estancamiento} \leftarrow 0$
    else
        $contador_{estancamiento} \leftarrow contador_{estancamiento} + 1$
    end if
    // Reinicializar si hay estancamiento
    if $contador_{estancamiento} \geq limite\_estancamiento$ **then**
        $\tau_{MCFLP} \leftarrow \tau_{max}$, $\tau_{MCVRP} \leftarrow \tau_{max}$
        $contador_{estancamiento} \leftarrow 0$
    end if
    // Actualizar feromonas (solo mejor global)
    Evaporar: $\tau_{MCFLP} \leftarrow (1-\rho) \cdot \tau_{MCFLP}$
    Evaporar: $\tau_{MCVRP} \leftarrow (1-\rho) \cdot \tau_{MCVRP}$
    Depositar feromona sobre las asignaciones en s^*
    Depositar feromona sobre los arcos de rutas en s^*
    Aplicar límites: $\tau_{min} \leq \tau \leq \tau_{max}$ para ambas matrices
    Actualizar límites: $\tau_{max} \leftarrow 1/(\rho \cdot z^*)$, $\tau_{min} \leftarrow \tau_{max}/(2m)$
end for
return s^*, z^*

A continuación se explican en detalle las tres etapas fundamentales del algoritmo propuesto.

3.4.3. Inicialización del Algoritmo

Antes de iniciar el ciclo iterativo principal, es necesario inicializar tanto las matrices de feromonas como las estructuras de datos que representan el estado de la solución. Este proceso establece las condiciones iniciales que guiarán la construcción de las primeras soluciones.

Matrices de feromonas y heurísticas: Las matrices de feromonas se inicializan uniformemente con el valor máximo permitido τ_{max}, tanto para la fase de localización como para la fase de ruteo. Específicamente, se establece $\tau_{ij}^{(1)} = \tau_{max}$ para todo par centroide-instalación $(i, j) \in I \times J$, y $\tau_{j\ell}^{(2)} = \tau_{max}$ para todo par de instalaciones $(j, \ell) \in J \times J$. Esta inicialización uniforme garantiza que todas las opciones tengan la misma probabilidad inicial de ser seleccionadas, fomentando la exploración temprana del espacio de búsqueda.

Las matrices heurísticas se calculan una única vez al inicio y permanecen constantes durante toda la ejecución. Para la fase MCFLP, la información heurística se define como el inverso de la distancia: $\eta_{ij}^{(1)} = 1/c_{ij}$, favoreciendo así asignaciones de centroides a instalaciones cercanas. De manera análoga, para la fase MCVRP se tiene $\eta_{j\ell}^{(2)} = 1/c_{j\ell}$, priorizando arcos cortos en las rutas de los vehículos.

Cálculo de límites de feromonas: Los valores τ_{max} y τ_{min} no son constantes arbitrarias, sino que se calculan a partir de soluciones greedy construidas durante una fase de inicialización. Se generan m soluciones completas (una por cada hormiga) utilizando construcciones probabilísticas guiadas únicamente por la información heurística. Sea z_{init} el costo de la mejor solución encontrada en esta fase inicial. Los límites de feromonas se establecen entonces según las fórmulas estándar de MMAS: $\tau_{max} = 1/(\rho \cdot z_{init})$ y $\tau_{min} = \tau_{max}/(2m)$. Estos valores se actualizarán dinámicamente a medida que se encuentren mejores soluciones durante el proceso iterativo.

Estructuras de datos: Se inicializa el conjunto de centroides no asignados como $U = I$ (todos los centroides), el estado de apertura de instalaciones como $y_j = 0$ para todo $j \in J$ (todas cerradas inicialmente), y las capacidades remanentes como $\text{capRem}_j[k] = Q_{jk}$ para cada instalación j y compartimento k. Para los vehículos, se establece $u_v = 0$ (ningún vehículo utilizado) y $\text{capVeh}_v[k] = CT_{v,k}^{max}$ (capacidad completa disponible).

3.4.4. Construcción de Soluciones: Fase MCFLP

En cada iteración del algoritmo, cada hormiga construye una solución completa del problema comenzando por la fase de localización de instalaciones. Este proceso asigna todos los centroides a instalaciones candidatas respetando las restricciones de capacidad por compar-

timento.

El Algoritmo 2 detalla el procedimiento de construcción para la fase MCFLP. El proceso se inicia con el conjunto completo de centroides no asignados $U = I$ y todas las instalaciones cerradas.

Algorithm 2 Construcción de Solución MCFLP

Require: Matrices τ_{MCFLP}, η_{MCFLP}, instancia del problema
Ensure: Asignaciones A, instalaciones abiertas Y, capacidades Q

$U \leftarrow I$
$Y[j] \leftarrow 0$ para todo $j \in J$
Inicializar capacidades remanentes Q^{rem}
while $U \neq \emptyset$ **do**
    Seleccionar centroide $i \in U$ (aleatorio o por heurística)
    $J_{fact} \leftarrow \{j \in J \mid Q^{rem}[j,k] \geq D[i,k], \forall k\}$
    if $J_{fact} = \emptyset$ **then**
        break
    end if
    // Calcular probabilidades de selección
    for $j \in J_{fact}$ **do**
        $P_{ij} \leftarrow \frac{[\tau_{ij}^{(1)}]^{\alpha} \cdot [\eta_{ij}^{(1)}]^{\beta}}{\sum_{\ell \in J_{fact}} [\tau_{i\ell}^{(1)}]^{\alpha} \cdot [\eta_{i\ell}^{(1)}]^{\beta}}$
    end for
    Seleccionar $j^* \sim P_{ij}$
    // Asignar centroide y actualizar capacidades
    $Y[j^*] \leftarrow 1$
    $A[i] \leftarrow j^*$
    for $k = 1$ **to** K **do**
        $Q^{rem}[j^*,k] \leftarrow Q^{rem}[j^*,k] - D[i,k]$
        $Q^{occ}[j^*,k] \leftarrow Q^{occ}[j^*,k] + D[i,k]$
    end for
    $U \leftarrow U \setminus \{i\}$
    // Cobertura múltiple: asignar centroides vecinos
    $Vecinos \leftarrow \{i' \in U \mid \text{dist}(i', j^*) \leq R_{j^*}\}$
    for $i' \in Vecinos$ **do**
        if $Q^{rem}[j^*,k] \geq D[i',k]$ para todo k **then**
            Asignar i' a j^* y actualizar capacidades
            $U \leftarrow U \setminus \{i'\}$
        end if
    end for
end while
return A, Y, Q

Iterativamente, se selecciona un centroide $i \in U$ y se determina el conjunto de instalaciones factibles $J_{\text{factibles}}(i)$, que contiene aquellas instalaciones j cuya capacidad remanente en todos los compartimentos es suficiente para satisfacer la demanda del centroide: $\text{capRem}_j[k] \geq d_{i,k}$ para todo $k = 1, \ldots, K$.

La selección de la instalación se realiza mediante una regla de transición probabilística que combina la información empírica y heurística. Para cada instalación factible j, se calcula una probabilidad de selección proporcional a $[\tau_{ij}^{(1)}]^{\alpha} \cdot [\eta_{ij}^{(1)}]^{\beta}$, donde los exponentes α y β controlan la influencia relativa de la experiencia acumulada (feromona) y el conocimiento del problema (heurística), respectivamente. La probabilidad normalizada es:

$$P_{ij}^{(1)} = \frac{[\tau_{ij}^{(1)}]^{\alpha} \cdot [\eta_{ij}^{(1)}]^{\beta}}{\sum_{\ell \in J_{\text{factibles}}(i)} [\tau_{i\ell}^{(1)}]^{\alpha} \cdot [\eta_{i\ell}^{(1)}]^{\beta}}$$

Una vez seleccionada la instalación j^* mediante ruleta estocástica, se procede a: (1) abrir la instalación si no estaba previamente abierta ($y_{j^*} = 1$), (2) registrar la asignación $i \to j^*$, y (3) actualizar las capacidades remanentes restando la demanda del centroide en cada compartimento: $\text{capRem}_{j^*}[k] := \text{capRem}_{j^*}[k] - d_{i,k}$ para $k = 1, \ldots, K$.

Mecanismo de cobertura múltiple: Tras asignar el centroide i a la instalación j^*, se intenta asignar también otros centroides cercanos a la misma instalación. Se define el conjunto de centroides vecinos como $\text{Vecinos} = \{i' \in U : \text{dist}(i', j^*) \leq R_{j^*}\}$, donde R_{j^*} es el radio de cobertura de la instalación. Para cada centroide vecino i', si la capacidad remanente de j^* es suficiente en todos los compartimentos ($\text{capRem}_{j^*}[k] \geq d_{i',k}$ para todo k), entonces i' se asigna inmediatamente a j^* sin necesidad de nueva selección probabilística. Este mecanismo reduce el número de instalaciones abiertas y favorece soluciones más compactas. El proceso continúa hasta que todos los centroides hayan sido asignados ($U = \emptyset$).

3.4.5. Construcción de Soluciones: Fase MCVRP

Una vez completada la fase de localización, se conocen las instalaciones abiertas y sus demandas acumuladas. La segunda fase consiste en construir rutas de vehículos que visiten todas las instalaciones abiertas, comenzando y terminando en el depósito, respetando las restricciones de capacidad por compartimento.

El Algoritmo 3 describe el proceso de construcción de rutas. Inicialmente, se define el conjunto de instalaciones abiertas $J' = \{j \in J : y_j = 1\}$ y se calcula la demanda agregada de cada instalación sumando las demandas de todos los centroides asignados a ella: $\text{demanda\_inst}[j][k] = \sum_{i:A[i]=j} d_{i,k}$ para cada compartimento k. Se mantiene un conjunto $J_{\text{uncovered}}$ que inicialmente contiene todas las instalaciones abiertas y se va reduciendo a medida que las instalaciones son incluidas en rutas.

Algorithm 3 Construcción de Rutas MCVRP

Require: Instalaciones abiertas Y, matrices τ_{MCVRP}, η_{MCVRP}, instancia
Ensure: Conjunto de rutas $\mathcal{R}$

$J' \leftarrow \{j \in J \mid Y[j] = 1\}$
Calcular $demanda\_inst[j][k]$ para cada $j \in J'$, $k \in \{1, \ldots, K\}$
$J_{uncov} \leftarrow J'$
$\mathcal{R} \leftarrow \emptyset$
while $J_{uncov} \neq \emptyset$ **do**
    // Iniciar nueva ruta
    $r \leftarrow$ nueva ruta, $S_r \leftarrow$ [depósito]
    $capVeh[k] \leftarrow CT_k^{max}$ para todo k
    $pos_{actual} \leftarrow$ depósito
    // Seleccionar primera instalación factible
    $J_{fact} \leftarrow \{j \in J_{uncov} \mid capVeh[k] \geq demanda\_inst[j][k], \forall k\}$
    if $J_{fact} = \emptyset$ **then**
        break
    end if
    Calcular probabilidades $P_{\text{depósito},j}$ para $j \in J_{fact}$
    Seleccionar $j^* \sim P_{\text{depósito},j}$
    Agregar j^* a S_r, actualizar $capVeh$ y J_{uncov}
    $pos_{actual} \leftarrow j^*$
    // Extender ruta mientras sea posible
    while $\exists \ell \in J_{uncov}$ tal que $capVeh[k] \geq demanda\_inst[\ell][k], \forall k$ **do**
        $N \leftarrow \{\ell \in J_{uncov} \mid capVeh[k] \geq demanda\_inst[\ell][k], \forall k\}$
        // Calcular probabilidades
        for $\ell \in N$ **do**
            $P_{pos_{actual},\ell} \leftarrow \frac{[\tau^{(2)}_{pos_{actual},\ell}]^{\alpha} \cdot [\eta^{(2)}_{pos_{actual},\ell}]^{\beta}}{\sum_{m \in N} [\tau^{(2)}_{pos_{actual},m}]^{\alpha} \cdot [\eta^{(2)}_{pos_{actual},m}]^{\beta}}$
        end for
        Seleccionar $\ell^* \sim P_{pos_{actual},\ell}$
        Agregar ℓ^* a S_r
        Actualizar $capVeh[k] \leftarrow capVeh[k] - demanda\_inst[\ell^*][k]$ para todo k
        $J_{uncov} \leftarrow J_{uncov} \setminus \{\ell^*\}$
        $pos_{actual} \leftarrow \ell^*$
    end while
    $S_r \leftarrow S_r \cup \{$depósito$\}$
    Calcular carga total L_r y distancia $d(r)$
    $\mathcal{R} \leftarrow \mathcal{R} \cup \{r\}$
end while
return $\mathcal{R}$

El proceso de construcción de rutas opera de forma iterativa. Mientras existan instalaciones no cubiertas, se inicia una nueva ruta partiendo del depósito con un vehículo de capacidad

completa. La selección de instalaciones a visitar sigue una lógica similar a la fase MCFLP: se identifica el conjunto de instalaciones factibles (aquellas cuya demanda puede ser satisfecha con la capacidad remanente del vehículo en todos los compartimentos) y se calcula una probabilidad de selección para cada una. En este caso, la probabilidad depende de la feromona y la heurística del arco que conecta la posición actual del vehículo con cada instalación candidata:

$$P_{j\ell}^{(2)} = \frac{[\tau_{j\ell}^{(2)}]^{\alpha} \cdot [\eta_{j\ell}^{(2)}]^{\beta}}{\sum_{m \in N_j^v} [\tau_{jm}^{(2)}]^{\alpha} \cdot [\eta_{jm}^{(2)}]^{\beta}}$$

donde N_j^v representa el conjunto de instalaciones no cubiertas que caben en el vehículo v actual.

Tras seleccionar probabilísticamente la instalación ℓ^*, se agrega a la secuencia de la ruta, se resta su demanda de la capacidad del vehículo, y se elimina del conjunto de instalaciones no cubiertas. El vehículo continúa extendiendo su ruta agregando nuevas instalaciones mientras existan instalaciones factibles. Cuando ya no es posible incorporar más instalaciones (porque las restantes exceden la capacidad disponible), la ruta se cierra retornando al depósito. Este proceso se repite hasta que todas las instalaciones hayan sido visitadas.

Evaluación del costo: Una vez construidas ambas fases de la solución, se calcula el costo total como:

$$z_h = \sum_{j \in J} y_j + \gamma \sum_{v \in V} \sum_{p=0}^{|S_v|-2} c(S_v[p], S_v[p+1])$$

donde el primer término representa el número de instalaciones abiertas, multiplicado por el costo fijo unitario de apertura, y el segundo término pondera mediante γ la suma de distancias recorridas por todos los vehículos. Este costo se utiliza para comparar la calidad de las soluciones y determinar cuál hormiga depositará feromona.

3.4.6. Actualización de Feromonas

Una vez que todas las hormigas han construido sus soluciones completas, se procede a actualizar las matrices de feromonas siguiendo el esquema elitista característico de MMAS. Este proceso consta de tres etapas: evaporación, depósito elitista y aplicación de límites.

Evaporación: La evaporación modela el olvido gradual de información antigua y permite que el algoritmo escape de óptimos locales. Se aplica uniformemente a todas las posiciones de ambas matrices de feromonas mediante la regla $\tau \leftarrow (1-\rho)\tau$, donde $\rho \in (0,1)$ es la tasa

de evaporación. Tras la evaporación, se verifica que ningún valor caiga por debajo del límite inferior: $\tau_{ij}^{(1)} \leftarrow \max\{\tau_{min}, \tau_{ij}^{(1)}\}$ y $\tau_{j\ell}^{(2)} \leftarrow \max\{\tau_{min}, \tau_{j\ell}^{(2)}\}$ para todos los pares válidos. Esta cota inferior garantiza que ninguna opción quede completamente descartada, preservando la capacidad exploratoria del algoritmo.

Depósito elitista: Solo la hormiga que construyó la mejor solución de la iteración actual (o la mejor solución global encontrada hasta el momento) está autorizada a depositar feromona. Sea $h^* = \arg\min_h z_h$ la hormiga con el menor costo en la iteración actual, con costo $z_{best} = z_{h^*}$. Se definen los conjuntos $\mathcal{A}_{MCFLP}^{(h^*)}$ como el conjunto de pares (i, j) correspondientes a las asignaciones centroide-instalación realizadas por h^*, y $\mathcal{A}_{MCVRP}^{(h^*)}$ como el conjunto de arcos (j, ℓ) utilizados en las rutas de h^*.

Para cada componente usado por la mejor hormiga, se deposita una cantidad de feromona inversamente proporcional al costo de la solución:

$$\tau_{ij}^{(1)} \leftarrow \tau_{ij}^{(1)} + \rho \frac{Q}{z_{best}}, \quad \forall (i,j) \in \mathcal{A}_{MCFLP}^{(h^*)}$$

$$\tau_{j\ell}^{(2)} \leftarrow \tau_{j\ell}^{(2)} + \rho \frac{Q}{z_{best}}, \quad \forall (j,\ell) \in \mathcal{A}_{MCVRP}^{(h^*)}$$

donde Q es una constante de ajuste. Soluciones de menor costo depositan más feromona, reforzando así los componentes prometedores.

Aplicación de límites: Tras el depósito, se verifica que ningún valor de feromona exceda el límite superior: $\tau_{ij}^{(1)} \leftarrow \min\{\tau_{max}, \tau_{ij}^{(1)}\}$ y $\tau_{j\ell}^{(2)} \leftarrow \min\{\tau_{max}, \tau_{j\ell}^{(2)}\}$. Esta cota superior previene la convergencia prematura al evitar que ciertos componentes dominen completamente la selección probabilística.

Actualización dinámica de límites: A medida que se encuentran mejores soluciones, los límites τ_{max} y τ_{min} se ajustan dinámicamente. Si z^* es el costo de la mejor solución global encontrada hasta el momento, los límites se recalculan como $\tau_{max} = 1/(\rho \cdot z^*)$ y $\tau_{min} = \tau_{max}/(2m)$. Esta adaptación permite que el algoritmo intensifique la búsqueda en torno a las mejores soluciones encontradas, mientras mantiene un balance apropiado entre exploración y explotación.

3.4.7. Mecanismos de Diversificación y Criterios de Parada

Reinicialización por estancamiento: Para evitar la convergencia prematura a óptimos locales, el algoritmo monitorea el progreso de la búsqueda mediante un contador de iteraciones sin mejora. Si la mejor solución global no mejora durante stall_limit iteraciones consecutivas, se detecta un estancamiento y se ejecuta una reinicialización de las feromonas: todas las

posiciones de τ_{MCFLP} y τ_{MCVRP} se restablecen a τ_{max}. Este reinicio fuerza al algoritmo a explorar nuevas regiones del espacio de búsqueda, eliminando el sesgo acumulado hacia las soluciones previas. El contador de estancamiento se reinicia a cero tras la reinicialización.

Criterios de parada: El algoritmo finaliza su ejecución cuando se satisface alguna de las siguientes condiciones:

- Se alcanza el número máximo de iteraciones T_{max}, establecido previamente como parámetro.
- Se cumple el criterio de convergencia basado en el contador de estancamiento (stall_limit).
- Se ejecuta el código por un máximo de 1800 segundos.

Al detenerse, el algoritmo retorna la mejor solución global encontrada $s^* = (A^*, Y^*, Q^*, \mathcal{R}^*)$, que consiste en las asignaciones de centroides A^*, el conjunto de instalaciones abiertas Y^*, las capacidades ocupadas Q^*, y el conjunto de rutas de vehículos $\mathcal{R}^*$. Esta solución minimiza busca minimizar la función objetivo que combina el costo de apertura de instalaciones con el costo de ruteo ponderado, por γ.

MARCO EXPERIMENTAL

En este capítulo se presentan los casos de prueba utilizados para evaluar el algoritmo MMAS propuesto, describiendo el formato de las instancias empleadas y las características específicas de cada caso experimental. Los resultados obtenidos y su análisis detallado se presentan en el capítulo siguiente, dedicado a la validación de la solución.

Los casos de prueba utilizados en este trabajo corresponden a instancias que representan escenarios reales de recolección de residuos reciclables. La selección de estas instancias busca validar la aplicabilidad del algoritmo propuesto en contextos operacionales concretos, permitiendo evaluar tanto la factibilidad de las soluciones generadas como su calidad en términos de los objetivos definidos en el modelo matemático.

4.1. Formato de instancia

El archivo que contiene la información necesaria para ejecutar el código desarrollado y resolver el problema abordado en este trabajo utiliza un formato inspirado en la conocida notación de la librería TSPLIB [Reinelt, 1995], ampliamente utilizada en problemas de optimización combinatoria como el Traveling Salesman Problem (TSP). Sin embargo, para dar respuesta a los requerimientos particulares del problema integrado de localización de contenedores y diseño de rutas de recolección con compartimentos múltiples, se optó por definir un formato especial que mantiene la estructura y etiquetas características de TSPLIB, pero adaptado para representar explícitamente elementos como centroides de generación, capacidades por compartimiento, matrices de distancias y parámetros logísticos específicos del modelo MCFLP/MCVRP. Esto permite mantener compatibilidad conceptual con los estándares de la literatura, facilitando su análisis, modificación y posterior extensión, pero a la vez integra toda la información operativa y de restricciones relevante para el algoritmo propuesto.

Las especificaciones y claves del formato usado se ejemplifican en la figura 5 y son las siguientes:

- `NAME`: Nombre del archivo, debe coincidir exactamente con el nombre del archivo físico. Según el ejemplo anterior, el nombre del archivo debería ser `syl.dat`.
- `#`: Comentario. Cualquier línea que comience con este carácter se ignora completamente durante el procesamiento.
- `COMMENT`: Descripción informativa sobre la cantidad de centroides, posibles puntos limpios, depósito y cantidad de compartimientos. Se utiliza para generar el log y mostrar información durante la ejecución.

- `TYPE`: Identifica el tipo de problema dentro de la implementación, distinguiendo si el archivo corresponde a una instancia de TSP o al problema MCFLP/MCVRP propuesto.
- `NUM_CENTROIDS`: Cantidad de centroides de generación de residuos; debe ser un número entero positivo.
- `NUM_NODES`: Cantidad de nodos candidatos para instalación de puntos limpios; debe ser un número entero positivo.
- `NUM_COMPARTMENTS`: Cantidad de tipos de residuos o compartimientos; debe ser un número entero positivo.
- `CENTROID_NODE_DISTANCE_SECTION`: Matriz de distancias entre cada par centroide-nodo. Cada línea especifica el centroide, el nodo y la distancia entre ellos.
- `NODE_DISTANCE_SECTION`: Matriz de distancias entre nodos. La distancia entre un nodo y sí mismo es cero. Esta matriz define los costos de desplazamiento para la fase de ruteo.
- `WASTE_GENERATION_SECTION`: Generación de residuos por compartimiento para cada centroide. Por ejemplo, la línea `1 1 13` indica que el centroide 1 genera 13 unidades del residuo tipo 1.
- `FACILITY_COMPARTMENT_CAPACITY_SECTION`: Capacidad máxima de almacenamiento por compartimiento en cada punto limpio.
- `VEHICLE_COMPARTMENT_CAPACITY_SECTION`: Capacidad máxima de transporte por compartimiento en cada vehículo de recolección.
- `DEPOT_SECTION`: Identificador del nodo que funciona como depósito central, origen y destino de todas las rutas de recolección.
- `CENTROID_RADIUS`: Radio máximo de cobertura para la asignación de centroides a puntos limpios. Evita asignaciones de centroides a instalaciones excesivamente distantes.
- `FACILITY_FIXED_COST`: Costo fijo asociado a la apertura y operación de un punto limpio, incluyendo instalación, mantención y otros gastos operacionales.
- `VEHICLE_FIXED_COST`: Costo fijo asociado al uso de un vehículo de recolección en una ruta.
- `COST_PER_DISTANCE`: Factor de costo por unidad de distancia, que permite considerar gastos asociados al desplazamiento como combustible, tiempo y desgaste. Si no se desea aplicar ponderación adicional, debe indicarse el valor 1.
- `ROUTE_DISTANCE_LIMIT`: Distancia máxima que puede recorrer un vehículo en una ruta individual. Para instancias sin esta restricción, debe indicarse el valor -1.

```
NAME: syl
# El deposito se cuenta como nodo en la logica pero no tiene capacidad de
# almacenamiento ni compartimientos y queda marcado como que de ahi salen y
# llegan los vehiculos.
COMMENT: 2 centroides, 1 posibles punto limpio, 1 deposito y 2 compartimientos
TYPE: MCFLP_MCVRP
NUM_CENTROIDS: 2
NUM_NODES: 2
NUM_COMPARTMENTS: 2
# centroid_id node_id distance
CENTROID_NODE_DISTANCE_SECTION
1 1 3
1 2 8
2 1 3
2 2 6
# node_i node_j distance
NODE_DISTANCE_SECTION
1 1 0
1 2 9
2 1 9
2 2 0
# centroid_id compartment_id amount
WASTE_GENERATION_SECTION
1 1 13
1 2 8
2 1 6
2 2 7
# facility_compartment_id capacity
FACILITY_COMPARTMENT_CAPACITY_SECTION
1 100
2 50
# vehicle_compartment_id capacity
VEHICLE_COMPARTMENT_CAPACITY_SECTION
1 200
2 100
# node_id
DEPOT_SECTION
1
# Distancia maxima la cual un centroide puede ser servida por un punto limpio
CENTROID_RADIUS 4
# costo de asignar un punto limpio
FACILITY_FIXED_COST 1000
# Coste fijo por cada ruta (vehículo) usada; penaliza el número de vehículos
VEHICLE_FIXED_COST 500
# costo por distancia (escalar) y limite de distancia para la ruta
COST_PER_DISTANCE 1
ROUTE_DISTANCE_LIMIT 100
```

Figura 5: Ejemplo de archivo de entrada con el formato especial utilizado en este trabajo, inspirado en la notación de TSPLIB pero adaptado para el problema MCFLP/MCVRP.

4.2. Instancias de prueba: Aspectos generales

Las instancias creadas en este escrito hacen uso de datos reales de la comuna de Renca, ubicada en la provincia de Santiago, Región Metropolitana de Chile. Estas instancias representan escenarios urbanos reales de gestión de residuos reciclables domiciliarios, considerando un caso de estudio base con la distribución geográfica de la población y las ubicaciones candidatas para la instalación de puntos limpios.

Centroides y ubicaciones posibles para puntos limpios de las instancias: El caso de estudio está compuesto por 1061 centroides generadores de residuos que representan agrupaciones de viviendas en la comuna. Además, se consideran 52 ubicaciones candidatas para la instalación de puntos limpios. La figura 6 muestra la ubicación espacial de los 1061 centroides como puntos de color verde. La figura 7 muestra la ubicación de los 52 sitios de posible ubicación de puntos limpios como puntos de color rojo.

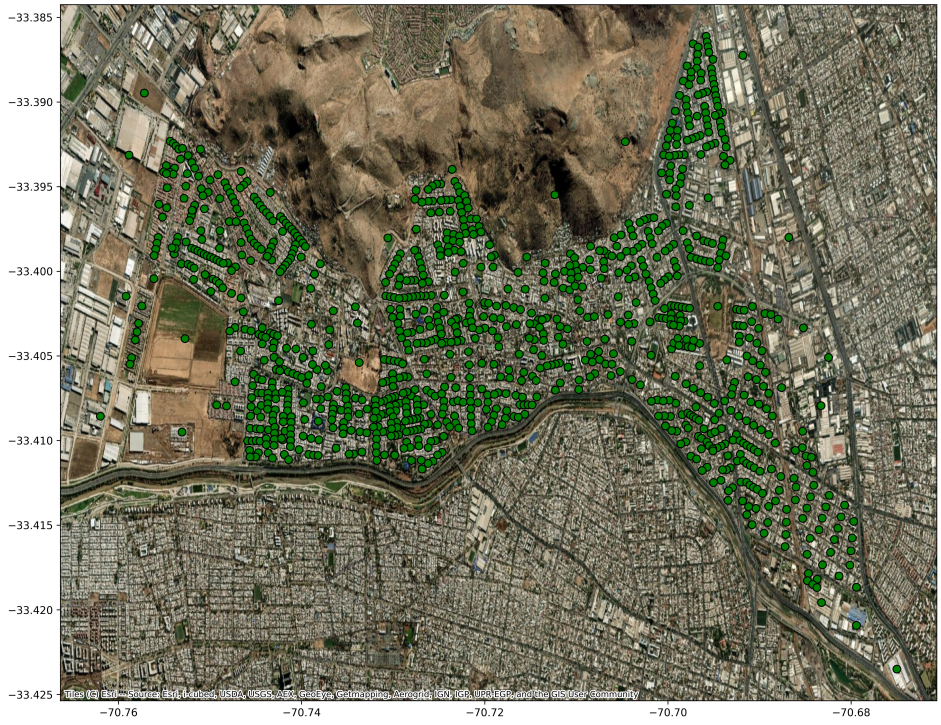


Figura 6: Mapa de los centroides considerados para esta experimentación.
Fuente: Elaboración propia.

Se consideran cuatro tipos de residuos reciclables diferenciados, correspondientes a los compartimentos que deben gestionar tanto las instalaciones como los vehículos de recolección:

1. `Paper_lt`: Papel
2. `Plastic_lt`: Plásticos

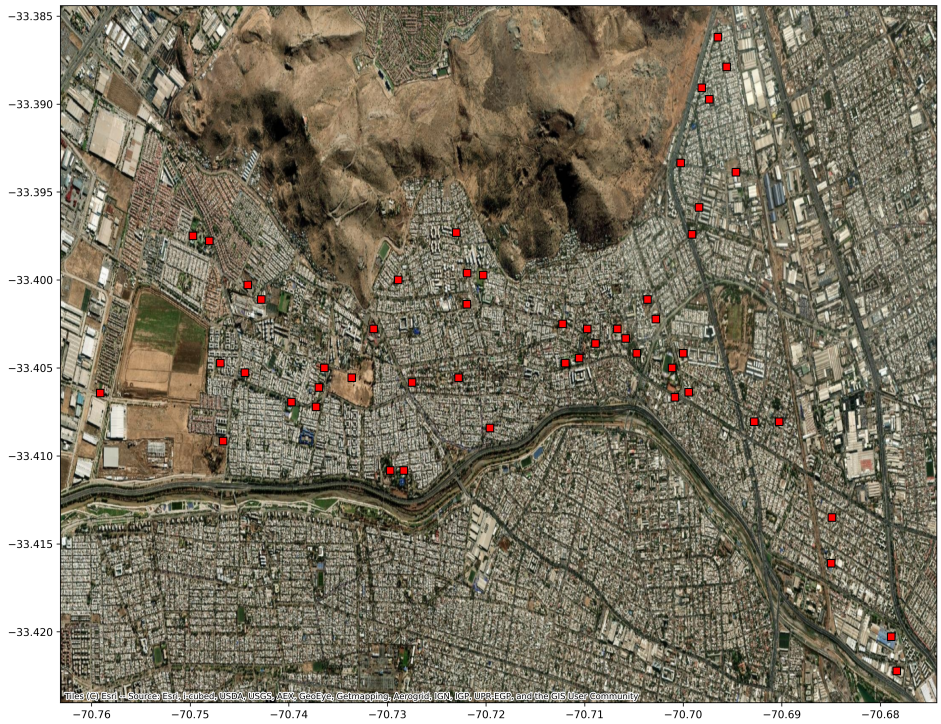


Figura 7: Mapa de los puntos en donde es posible instalar un punto limpio.
Fuente: Elaboración propia.

3. `Metal_lt`: Metales
4. `Glass_lt`: Vidrio

Capacidades operacionales: Las instancias consideran diferentes configuraciones de capacidades tanto para los puntos limpios como para los vehículos de recolección. Los puntos limpios pueden instalarse con contenedores de distintas capacidades según las necesidades operacionales, permitiendo gestionar independientemente cada tipo de residuo sin riesgo de contaminación cruzada. Los vehículos de recolección también presentan configuraciones de capacidad diferenciadas por compartimento, reflejando la proporción típica de generación de residuos reciclables en contextos urbanos chilenos.

Frecuencia de recolección: La ejecución del algoritmo identifica puntos limpios a instalar y las rutas a implementar, segun la generacion de residuos y la logica esperada, se puede considerar una frecuencia de recoleccion u otra.

Opciones de contenedores. Para el dimensionamiento de las instalaciones, se cuenta con información sobre contenedores disponibles comercialmente con las siguientes especificaciones:

Capacidad	Costo unitario
360 litros	US$ 110
660 litros	US$ 190
1100 litros	US$ 269
2200 litros	US$ 311

Tabla 1: Capacidades y costos de contenedores disponibles para la instalación de puntos limpios.
Fuente: Elaboración propia.

Así, considerando el escenario definido a partir del caso de estudio se generaron instancias que se detallan a continuación.

4.3. Instancias de prueba

4.3.1. Parámetros variables entre instancias

El conjunto de instancias se genera mediante la combinación de tres factores variables que representan diferentes condiciones operacionales y escenarios de niveles de recolección:

Escenarios de generación de residuos: Se consideran dos escenarios temporales que reflejan las proyecciones de tasas de reciclaje en la comuna identificadas en el manual de [ter, 2019].

- **Escenario 2025**: Generación base multiplicada por factor 0.1, representando una tasa de reciclaje actual del 10 % de los residuos generados.
- **Escenario 2040**: Generación base multiplicada por factor 0.65, representando una tasa de reciclaje proyectada al 2040 del 65 % de los residuos generados.

En ambos casos, la generación diaria se multiplica por 7 para reflejar la frecuencia semanal de recolección.

Configuraciones de contenedores: Se evalúan tres configuraciones diferentes de capacidades para los contenedores instalados en los puntos limpios, considerando opciones comercialmente disponibles:

Config.	Papel (L)	Plástico (L)	Metal (L)	Vidrio (L)
C1	360	360	360	360
C2	2200	2200	2200	2200
C3	2200	2200	1100	1100

Tabla 2: Configuraciones de capacidad de contenedores por compartimento (litros).
Fuente: Elaboración propia.

Los costos unitarios de los contenedores según su capacidad son los indicados en la tabla 1, por lo tanto, el costo fijo de instalación de un punto limpio varía según la configuración tal que:

- C1: US$ 440 (4 × US$ 110)
- C2: US$ 1,244 (4 × US$ 311)
- C3: US$ 1,160 (2 × US$ 311 + 2 × US$ 269)

Configuraciones de vehículos: Se consideran dos tipos de vehículos de recolección con diferentes distribuciones de capacidad por compartimento:

Config.	Papel (L)	Plástico (L)	Metal (L)	Vidrio (L)
V1	5000	5000	5000	5000
V2	7500	7500	2500	2500

Tabla 3: Configuraciones de capacidad de vehículos por compartimento (litros).
Fuente: Elaboración propia.

La configuración V1 representa vehículos con capacidad uniforme entre compartimentos, mientras que V2 refleja una distribución que prioriza papel y plástico, típicamente generados en mayores volúmenes en contextos urbanos chilenos.

4.3.2. Matriz de instancias generadas

La combinación de los factores variables genera un conjunto de 12 instancias de prueba, identificadas mediante códigos H01 a H12:

Instancia	Escenario	Config. Contenedores	Config. Vehículos
H01	2025	C1 (360L)	V1 (5000L)
H02	2025	C1 (360L)	V2 (7500/2500L)
H03	2025	C2 (2200L)	V1 (5000L)
H04	2025	C2 (2200L)	V2 (7500/2500L)
H05	2025	C3 (2200/1100L)	V1 (5000L)
H06	2025	C3 (2200/1100L)	V2 (7500/2500L)
H07	2040	C1 (360L)	V1 (5000L)
H08	2040	C1 (360L)	V2 (7500/2500L)
H09	2040	C2 (2200L)	V1 (5000L)
H10	2040	C2 (2200L)	V2 (7500/2500L)
H11	2040	C3 (2200/1100L)	V1 (5000L)
H12	2040	C3 (2200/1100L)	V2 (7500/2500L)

Tabla 4: Matriz completa de instancias de prueba generadas para la experimentación. Fuente: Elaboración propia.

Cada una de estas 12 instancias será evaluada utilizando los cuatro métodos de resolución definidos: Gurobi (2 fases), MMAS Config. 1, MMAS Config. 2 y MMAS Config. 3, resultando en un total de 48 experimentos computacionales. Esta matriz experimental permite evaluar el desempeño de los algoritmos bajo diferentes condiciones de demanda (escenarios 2025 vs 2040), restricciones de capacidad en instalaciones (configuraciones C1, C2, C3) y capacidades de transporte (configuraciones V1, V2).

4.4. Configuración experimental

4.4.1. Ambiente computacional

- Hardware: Procesador i5-12400F, 16 GB RAM, 6 núcleos físicos y 12 procesadores lógicos.
- Sistema Operativo: Ubuntu 13.3.0-6ubuntu2 24.04 en WSL, en Windows 11 Pro 24H2, 64 bits
- Lenguaje de implementación: C (C17 / C18)
- Compilador: gcc versión 13.3.0
- Solver de referencia: Gurobi 12.0.1

4.4.2. Metodología de comparación

Dado que el problema conjunto MCFLPVRP integrado no tiene benchamrks establecidos para este problema en la literatura, se establece como linea base la solucion obtenida mediante el solver comercial Gurobi 12.0.1, resolviendo el problema en dos fases secuenciales:

1. Fase 1 (FLP): Resolución del modelo de localizacion con programación entera.
2. Fase 2 (VRP): Resolución del modelo de ruteo sobre las instalaciones abiertas.

Esta estrategia secuencial representa el enfoque tradicional para problemas de localización-ruteo y sirve como cota de comparación para evaluar la calidad del algoritmo MMAS propuesto.

4.4.3. Configuraciones de prueba para MMAS

- **MMAS Config. 1**: (Enfoque balanceado hacia ruteo): Esta configuración utiliza un cociente α/β de 1.0:3.0, privilegiando la heurística (arcos más cortos) por sobre la feromona acumulada. La evaporación elevada ($\rho = 0{,}15$) acelera el "olvido" de caminos, manteniendo la exploración activa y evitando convergencias prematuras. Con 50 hormigas y $T_{max} = 5000$, se garantiza diversidad poblacional y tiempo de búsqueda suficiente. El peso de balance $\gamma = 1{,}0$ inclina la función objetivo hacia la minimización de distancia total de rutas por sobre la apertura de instalaciones, por lo que tiende a consolidar el diseño de ruteo incluso si ello mantiene un número similar de puntos limpios. El stall_limit de 300 activa reinicios oportunos de feromonas cuando no hay mejoras.
- **MMAS Config. 2**: (Enfoque exploratorio): Aquí el cociente α/β es 1.5:3.0. El aumento de α da algo más de voz a la feromona, pero el β alto sigue guiando por heurística; combinado con $\rho = 0{,}15$ se promueve una diversificación constante del espacio de búsqueda. El $\gamma = 0{,}6$ equilibra el peso entre abrir menos instalaciones y acortar rutas, permitiendo explorar trade–offs FLP–VRP más variados. Con 50 hormigas, $T_{max} = 3000$ y stall_limit=300, esta variante busca buenas soluciones rápidamente, aceptando mayor rotación de caminos para escapar de óptimos locales.
- **MMAS Config. 3**: (Enfoque explotativo): Esta configuración intensifica la explotación: el ratio α/β de 0.8:5.0 está fuertemente sesgado hacia la heurística, guiando decisiones greedy de distancia. La $\rho = 0{,}05$ preserva más la memoria histórica que en las otras configuraciones, permitiendo consolidar y refinar soluciones prometedoras durante más iteraciones. La reducción a 30 hormigas concentra el esfuerzo en intensificación, con $T_{max} = 5000$ y stall_limit=300. El $\gamma = 1{,}0$ prioriza decididamente la minimización de rutas, por lo que tenderá a favorecer configuraciones con recorridos

más cortos, aceptando la apertura de instalaciones que habiliten rutas especialmente eficientes si es necesario.

4.4.4. Parámetros experimentales

Los parámetros para los experimentos son diferentes para Gurobi que para el algoritmo propuesto de MMAS, y luego también cambian estos para cada configuración de MMAS, tal que la Tabla 5 presenta los parámetros específicos del solver comercial en su estrategia de resolución secuencial en dos fases (primero FLP, luego VRP sobre las instalaciones abiertas), mientras que la Tabla 6 detalla los parámetros del algoritmo MMAS y sus variaciones entre las tres configuraciones experimentales. Esta separación refleja la naturaleza fundamentalmente distinta de ambos enfoques: Gurobi opera mediante programación entera con parámetros de control de optimalidad y preprocesamiento, mientras que MMAS requiere la calibración de parámetros que gobiernan el balance entre la información feromonal y heurística, así como los mecanismos de exploración y convergencia.

Parámetros específicos Gurobi - VRP	**Gurobi (2 fases)**	**MMAS Config. 1**	**MMAS Config. 2**	**MMAS Config. 3**
MIPGap	0	N/A	N/A	N/A
InfUnbdInfo	1	N/A	N/A	N/A
Presolve	Si	N/A	N/A	N/A
Resultados previos de FLP	Si	N/A	N/A	N/A

Tabla 5: Configuración de parámetros por método - VRP
Fuente: Elaboración propia.

Parámetros específicos MMAS	**Gurobi (2 fases)**	**MMAS Config. 1**	**MMAS Config. 2**	**MMAS Config. 3**
γ (balance FLP-VRP)	N/A	1.0	0.6	1.0
α (exponente feromona)	N/A	1.0	1.5	0.8
β (exponente heurística)	N/A	3.0	3.0	5.0
ρ (tasa de evaporación)	N/A	0.15	0.15	0.05
m (número de hormigas)	N/A	50	50	30
Q (cantidad de feromona depositada)	N/A	*	*	*
τ_{min} (feromona mínima)	N/A	*	*	*
τ_{max} (feromona máxima)	N/A	*	*	*
stall_limit (límite estancamiento)	N/A	300	300	300
T_{max} (iteraciones máximas)	N/A	5000	3000	5000

$*$ Valores calculados dinámicamente durante la ejecución del algoritmo.

Tabla 6: Configuración de parámetros por método - MMAS
Fuente: Elaboración propia.

4.5. Métricas de evaluación

Métricas de calidad de solución

- Costo de instalaciones abiertas: Costo total según el tipo de contenedor instalado en el punto cada punto limpio
- Número de instalaciones abiertas: Componente FLP
- Distancia total recorrida: Suma de todas las rutas (metros)
- Número de vehículos utilizados: Cantidad de rutas generadas

Métricas de eficiencia computacional

- Tiempo de ejecución total: Segundos hasta convergencia

Con la configuración experimental definida, se procedió a ejecutar las tres variantes del algoritmo MMAS sobre la instancia de Renca, así como la resolución secuencial mediante Gurobi como línea base de comparación. Cada configuración se ejecutó considerando los parámetros establecidos en las Tablas 5 y 6, permitiendo evaluar el comportamiento del algoritmo bajo diferentes estrategias de balance entre exploración y explotación. A continuación se presentan los resultados obtenidos en términos de calidad de solución, eficiencia computacional y características operativas de las rutas y ubicaciones de instalaciones generadas.

RESULTADOS

5.1. Organización de resultados

Los resultados presentados en esta sección tienen como objetivo evaluar integralmente el desempeño del algoritmo Max-Min Ant System (MMAS) propuesto para resolver el problema conjunto de localización de contenedores y diseño de rutas de recolección con múltiples compartimentos. La evaluación se estructura de manera sistemática para facilitar el análisis comparativo entre diferentes configuraciones algorítmicas y escenarios operativos. Esto se hace incluyendo métricas de rendimiento como costos totales, distancias recorridas, número de contenedores ubicados y eficiencia en la recolección. La comparación se realiza contrastando el enfoque secuencial utilizando Gurobi (resolviendo FLP y MCVRP en dos fases separadas) con tres configuraciones distintas del algoritmo MMAS que abordan el problema de manera integrada. Finalmente, se realiza un análisis comparativo entre los casos de prueba y se evalúa el impacto de los diferentes parámetros del algoritmo en la calidad de las soluciones.

Los experimentos contemplan dos escenarios temporales que reflejan la evolución esperada de las tasas de reciclaje en Chile: el escenario 2025 con una tasa del 10 % (situación actual proyectada) y el escenario 2040 con una tasa del 65 %. Para cada escenario se evalúan diferentes configuraciones de contenedores que van desde sistemas uniformes pequeños hasta configuraciones mixtas que combinan contenedores de diferentes capacidades, considerando además que la generación de residuos de cada tipo no es uniforme. Los resultados se analizan considerando las siguientes perspectivas:

1. Calidad de las soluciones del problema FLP, por medio de la cantidad de puntos limpios a instalar
2. Efectividad de las rutas de recolección, evaluada mediante distancia total recorrida
3. Eficiencia de la implementación completa, estudiando el tiempo de ejecución total

5.2. Resultados por instancia

5.2.1. Escenario 2025 (10 % tasa de reciclaje)

Instancias H01-H02: Contenedores pequeños uniformes (360L)

Las tablas 7 y 8 presentan los resultados para las instancias H01 y H02 del escenario 2025 con contenedores pequeños uniformes de 360 litros. Cada tabla reporta cinco métricas clave

(costo de instalaciones, número de instalaciones, distancia total, número de rutas y tiempo de ejecución), mostrando tanto el promedio sobre 5 ejecuciones como el mejor resultado obtenido. Las columnas comparan el enfoque secuencial de Gurobi con las tres configuraciones del algoritmo MMAS propuesto.

Gurobi logró soluciones superiores en términos de número de instalaciones (32 puntos limpios) y distancia total recorrida: 45,465 metros en H01 versus rangos de 67,000-73,000 metros para MMAS, y 44,529 metros en H02 versus 56,000-64,000 metros para MMAS. Esta ventaja en instancias con contenedores pequeños refleja que las restricciones de capacidad más estrictas limitan el espacio de búsqueda del MMAS. No obstante, MMAS mostró tiempos de convergencia menores, especialmente Config. 3 en H02 (738 segundos versus 1,128 segundos de Gurobi).

Métrica	**Tipo**	**Gurobi**	**MMAS Config. 1**	**MMAS Config. 2**	**MMAS Config. 3**
Costo de instalación total	Promedio	14080	15520	15140	15960
	Mejor	14080	15400	14960	15840
Número de instalaciones	Promedio	32	35.2	34.4	36.2
	Mejor	32	35	34	36
Distancia total (m)	Promedio	45465.80	68234.50	68912.30	73456.20
	Mejor	45465.80	67012.90	67650.50	72698.60
Número de rutas	Promedio	3	3.0	3.0	3.0
	Mejor	3	3	3	3
Tiempo de ejecución (s)	Promedio	1052.02	465.20	1687.40	1012.80
	Mejor	1052.02	451	1609	989

Tabla 7: Instancia H01: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Métrica	**Tipo**	**Gurobi**	**MMAS Config. 1**	**MMAS Config. 2**	**MMAS Config. 3**
Costo de instalación total	Promedio	14080	15664	15664	15664
	Mejor	14080	15840	16280	15400
Número de instalaciones	Promedio	32	35.6	35.6	35.6
	Mejor	32	36	37	35
Distancia total (m)	Promedio	44529.80	60984.6	64553.8	62667.8
	Mejor	45465.80	56714	61709	56321
Número de rutas	Promedio	2	2	2	2
	Mejor	2	2	2	2
Tiempo de ejecución (s)	Promedio	1128.92	1178.01	1338.30	738.86
	Mejor	1128.92	992.06	1326.46	647.79

Tabla 8: Instancia H02: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Instancias H03-H04: Contenedores grandes uniformes (2200L)

Las tablas 9 y 10 muestran los resultados para H03 y H04 del escenario 2025 con contenedores grandes de 2200 litros. La estructura de estas tablas es idéntica a la sección anterior.

Un resultado destacable es la convergencia en localización: todos los métodos identificaron 9 instalaciones como óptimo (US$ 11,196). Sin embargo, MMAS superó a Gurobi en ruteo para H03, logrando distancias de 33,327-34,610 metros versus 35,137 metros de Gurobi, consolidando además en 2 rutas versus 3. La Config. 2 alcanzó una reducción del 5.1 %. El trade-off es el tiempo computacional: Gurobi finalizó en menos de 15 segundos mientras MMAS requirió 241-466 segundos.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	11196	11942.4	11942.4	12191.2
	Mejor	11196	11196	11196	11196
Número de instalaciones	Promedio	9	9.6	9.6	9.8
	Mejor	9	9	9	9
Distancia total (m)	Promedio	35137.40	35210.4	35522.2	36894.2
	Mejor	35137.40	34610.00	33327.00	33708.00
Número de rutas	Promedio	3	2.6	2.6	2.6
	Mejor	3	2	2	2
Tiempo de ejecución (s)	Promedio	15.01	455.98	464.55	271.65
	Mejor	15.01	404.94	388.07	241.62

Tabla 9: Instancia H03: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	11196	11569.2	11818	12440
	Mejor	11196	12440	12440	12440
Número de instalaciones	Promedio	9	9.3	9.5	10
	Mejor	9	10	10	10
Distancia total (m)	Promedio	29592.00	33079.67	32876.5	34709.5
	Mejor	29592.00	32544	32068	34611
Número de rutas	Promedio	2	2	2	2
	Mejor	2	2	2	2
Tiempo de ejecución (s)	Promedio	2.52	466.01	445.05	313.44
	Mejor	2.52	361.89	379.84	284.58

Tabla 10: Instancia H04: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Instancias H05-H06: Contenedores mixtos (2200/1100L)

Las tablas 11 y 12 presentan los resultados para H05 y H06, con configuración mixta de contenedores (2200L para papel/plástico, 1100L para metal/vidrio).

En H05, MMAS Config. 1 logró 34,581 metros versus 35,137 de Gurobi, aunque otras configuraciones fueron inferiores. En H06, Gurobi mantuvo ventaja en distancia (29,592 metros versus 31,783-33,601 para MMAS), pero todos consolidaron en 2 rutas.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	10440	11600	11600	11368
	Mejor	10440	11600	11600	11600
Número de instalaciones	Promedio	9	10	10	9.8
	Mejor	9	10	10	10
Distancia total (m)	Promedio	35137.40	34798.2	35417.6	36790.8
	Mejor	35137.40	34581	34089	35582
Número de rutas	Promedio	3	3	3	3
	Mejor	3	3	3	3
Tiempo de ejecución (s)	Promedio	4.16	433.56	447.49	295.16
	Mejor	4.16	379.35	392.64	220.57

Tabla 11: Instancia H05: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	10440	11020	11020	11020
	Mejor	10440	11600	11600	11600
Número de instalaciones	Promedio	9	9.5	9.5	9.5
	Mejor	9	10	10	9
Distancia total (m)	Promedio	29592.00	33601.5	33015.5	33191.5
	Mejor	29592.00	33000	31783	32995
Número de rutas	Promedio	2	2	2	2
	Mejor	2	2	2	2
Tiempo de ejecución (s)	Promedio	2.54	508.88	505.39	429.62
	Mejor	2.54	483.95	478.98	344.87

Tabla 12: Instancia H06: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

5.2.2. Escenario 2040 (65 % tasa de reciclaje)

Instancias H07-H08: Contenedores pequeños (360L)

Las tablas 13 y 14 corresponden a H07 y H08 del escenario 2040 con contenedores pequeños de 360 litros.

Todas las métricas presentan valores omitidos (-) porque las instancias resultaron infactibles. Como indica la nota al pie, los contenedores de 360L son insuficientes para la demanda del escenario 2040, incluso tras evaluar capacidades de 660L y 1100L. Esta infactibilidad evidencia cuantitativamente que la infraestructura de contenedores pequeños es inadecuada para las metas de reciclaje del 65 % proyectadas para 2040.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	-	-	-	-
	Mejor	-	-	-	-
Número de instalaciones	Promedio	-	-	-	-
	Mejor	-	-	-	-
Distancia total (m)	Promedio	-	-	-	-
	Mejor	-	-	-	-
Número de rutas	Promedio	-	-	-	-
	Mejor	-	-	-	-
Tiempo de ejecución (s)	Promedio	-	-	-	-
	Mejor	-	-	-	-

La instancia resultó infactible debido a que los contenedores de 360 L no fueron suficientes para cubrir la demanda de los centroides. Se realizaron pruebas aumentando la capacidad de los puntos limpios, primero a contenedores uniformes de 660 L y luego a 1100 L; sin embargo, en ambos casos la capacidad total siguió siendo insuficiente para satisfacer la demanda proyectada del escenario 2040 (con una tasa de reciclaje del 65 %).

Tabla 13: Instancia H07: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	-	-	-	-
	Mejor	-	-	-	-
Número de instalaciones	Promedio	-	-	-	-
	Mejor	-	-	-	-
Distancia total (m)	Promedio	-	-	-	-
	Mejor	-	-	-	-
Número de rutas	Promedio	-	-	-	-
	Mejor	-	-	-	-
Tiempo de ejecución (s)	Promedio	-	-	-	-
	Mejor	-	-	-	-

La instancia resultó infactible debido a que los contenedores de 360 L no fueron suficientes para cubrir la demanda de los centroides. Se realizaron pruebas aumentando la capacidad de los puntos limpios, primero a contenedores uniformes de 660 L y luego a 1100 L; sin embargo, en ambos casos la capacidad total siguió siendo insuficiente para satisfacer la demanda proyectada del escenario 2040 (con una tasa de reciclaje del 65 %).

Tabla 14: Instancia H08: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Instancias H09-H10: Contenedores grandes uniformes (2200L)

Las tablas 15 y 16 presentan los resultados para H09 y H10 del escenario 2040 con contenedores grandes de 2200 litros.

El incremento de demanda es dramático: H09 requiere 33 instalaciones y 16 rutas (versus 9 instalaciones y 2-3 rutas en H03), con distancias superiores a 108,000 metros. Gurobi alcanzó el límite temporal de 1800 segundos, mientras MMAS convergió en 1,015-1,357 segundos. Sin embargo, Gurobi logró menores distancias (108,132 metros versus 132,152-136,673 para MMAS). En H10, con vehículos V2, MMAS consolidó en 10 rutas versus 11 de Gurobi, aunque con distancias superiores (98,995-102,850 versus 87,247 metros).

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	41052	42296	42296	41052
	Mejor	41052	43540	42296	41674
Número de instalaciones	Promedio	33	34	34	33.5
	Mejor	33	35	34	33
Distancia total (m)	Promedio	108132.90	136673.5	134220	132874.5
	Mejor	108132.90	133045	132483	132152
Número de rutas	Promedio	16	15.5	16	16
	Mejor	16	15	16	16
Tiempo de ejecución (s)	Promedio	1800*	1186.12	1315.84	1358.27
	Mejor	1800*	1015.81	1271.32	1357.46

Tabla 15: Instancia H09: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	39808	44162	42918	44162
	Mejor	39808	44784	44784	44784
Número de instalaciones	Promedio	32	35.5	34.5	35.5
	Mejor	32	36	36	36
Distancia total (m)	Promedio	87247.10	99343.5	102850.5	100278
	Mejor	87247.10	98995	100395	99988
Número de rutas	Promedio	11	10	10	10
	Mejor	11	10	10	10
Tiempo de ejecución (s)	Promedio	1800*	922.09	919.90	919.87
	Mejor	1800*	922.05	918.33	919.13

Tabla 16: Instancia H10: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Instancias H11-H12: Contenedores mixtos (2200/1100L)

Las tablas 17 y 18 muestran los resultados para H11 y H12 del escenario 2040 con configuración mixta de contenedores.

Las distancias de ruteo son similares a H09, con Gurobi alcanzando nuevamente el límite de 1800 segundos versus 521-547 segundos de MMAS (más de 3× más rápido). En H12, con vehículos V2, se reduce a 10-11 rutas con distancias menores (79,488 metros para Gurobi versus 99,642-105,706 para MMAS), reflejando mejor aprovechamiento de capacidades asimétricas. A pesar de las brechas en calidad favoreciendo a Gurobi, la ventaja temporal de MMAS sugiere mejor escalabilidad computacional.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	37120	41180	40600	40600
	Mejor	37120	41760	40600	40600
Número de instalaciones	Promedio	32	35.5	35	35
	Mejor	32	36	35	35
Distancia total (m)	Promedio	109052.30	131181	134856	139773
	Mejor	109052.30	129904	131757	139654
Número de rutas	Promedio	16	15.5	16	16
	Mejor	16	16	16	16
Tiempo de ejecución (s)	Promedio	1800*	543.38	547.51	531.03
	Mejor	1800*	542.25	547.27	521.76

Tabla 17: Instancia H11: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

Métrica	Tipo	Gurobi	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Costo de instalación total	Promedio	37120	41760	40600	40020
	Mejor	37120	41760	41760	41760
Número de instalaciones	Promedio	32	36	35	34.5
	Mejor	32	36	36	36
Distancia total (m)	Promedio	79488.50	104336.5	101926	105706
	Mejor	79488.50	101753	99642	103650
Número de rutas	Promedio	11	10	10	10
	Mejor	11	10	10	10
Tiempo de ejecución (s)	Promedio	1800*	553.08	552.19	551.64
	Mejor	1800*	551.76	551.93	549.90

Tabla 18: Instancia H12: Comparación de resultados - Promedio y mejor de 5 ejecuciones
Fuente: Elaboración propia.

5.3. Análisis comparativo agregado

La Tabla 19 presenta un análisis agregado del desempeño de los cuatro métodos evaluados, promediando los resultados obtenidos sobre las 10 instancias factibles (H01-H06 del escenario 2025 y H09-H12 del escenario 2040). Este resumen permite identificar tendencias generales de comportamiento antes de profundizar en el análisis detallado de instancias específicas.

Métrica	Gurobi (2 fases)	MMAS Config. 1	MMAS Config. 2	MMAS Config. 3
Número de instalaciones abiertas promedio	22.90	25.12	24.81	25.21
Número de rutas creadas promedio	7.90	7.41	7.51	7.51
Distancia promedio por ruta (m)	60337.52	74053.54	74993.74	77333.33
Costo de instalación promedio	22653.20	26619.34	26245.84	26328.62
Tiempo de ejecución promedio (s)	1040.52	682.53	772.42	644.09

Tabla 19: Resumen de métricas de cada método
Fuente: Elaboración propia.

Cada métrica reflejada en la tabla captura un aspecto específico del desempeño algorítmico. El *número de instalaciones abiertas promedio* indica la componente de infraestructura de la solución y su nivel de cobertura territorial; valores menores sugieren soluciones más consolidadas que requieren menor inversión inicial en puntos limpios. El *número de rutas creadas promedio* evalúa la capacidad de consolidación operativa y eficiencia en el uso de vehículos; menos rutas implica mejor aprovechamiento de la capacidad vehicular y menores costos de operación simultánea de flota. La *distancia promedio por ruta* mide la eficiencia completa del trayecto de recolección, siendo un indicador directo de consumo de combustible, emisiones y tiempo operativo. El *costo de instalación promedio* cuantifica la inversión requerida en infraestructura de contenedores según las configuraciones de capacidad evaluadas. Finalmente, el *tiempo de ejecución promedio* permite evaluar la viabilidad práctica y escalabilidad computacional de cada enfoque metodológico.

Los resultados agregados muestran que Gurobi logró en promedio soluciones con menor número de instalaciones (22.90 versus 24.81-25.21 para MMAS) y distancias totales significativamente más cortas (60,337 metros versus 74,053-77,333 metros), reflejando un 17-28 % de diferencia favorable al enfoque secuencial. Sin embargo, las configuraciones MMAS lograron mayor consolidación de rutas (7.41-7.51 versus 7.90 de Gurobi), sugiriendo mejor aprovechamiento de capacidad vehicular. En términos de eficiencia computacional, MMAS demostró ventaja temporal: Config. 3 convergió en promedio en 644 segundos versus 1,040 segundos de Gurobi (38 % más rápido), siendo particularmente notoria esta diferencia en instancias del escenario 2040 donde Gurobi alcanzó consistentemente el límite temporal de 1800 segundos.

Es importante destacar que esta tabla considera promedios agregados sobre instancias heterogéneas que incluyen diferentes configuraciones de contenedores (pequeños, grandes, mixtos), tipos de vehículos (V1, V2) y niveles de demanda (escenarios 2025 y 2040). Como se evidenciará en la sección siguiente, existen diferencias significativas en el comportamiento relativo de los algoritmos según las características específicas de cada instancia. Por ello, el análisis agregado debe interpretarse como una tendencia general, mientras que el estudio de casos particulares revela matices importantes sobre cuándo y por qué cada enfoque es superior. A continuación se presenta un análisis detallado de la instancia H03, seleccionada por su relevancia al mostrar convergencia en localización pero diferencias significativas en ruteo, ilustrando las fortalezas del enfoque integrado propuesto.

5.4. Análisis particular de una instancia relevante - H03

La instancia H03 representa un caso particularmente interesante dentro del conjunto experimental, ya que corresponde al escenario 2025 con contenedores grandes uniformes (2200 litros) y vehículos de capacidad uniforme (V1: 5000 litros por compartimento). Esta configuración de alta capacidad tanto en instalaciones como en vehículos permite explorar el desempeño de los algoritmos en condiciones donde las restricciones de capacidad son menos restrictivas, enfocando la optimización principalmente en aspectos geográficos y de ruteo.

5.4.1. Convergencia en la solucion de localización (MCFLP)

Un resultado destacable de la instancia H03 es la convergencia completa de todos los métodos en la componente de localización de instalaciones. Como se observa en la Tabla 9, tanto el enfoque secuencial de Gurobi como las tres configuraciones del algoritmo MMAS identificaron el mismo conjunto óptimo de 9 puntos limpios, resultando en un costo fijo idéntico de US$ 11,196. Esta convergencia sugiere que, para esta configuración particular de capacidades, existe una solución dominante en términos de localización que todos los algoritmos lograron identificar.

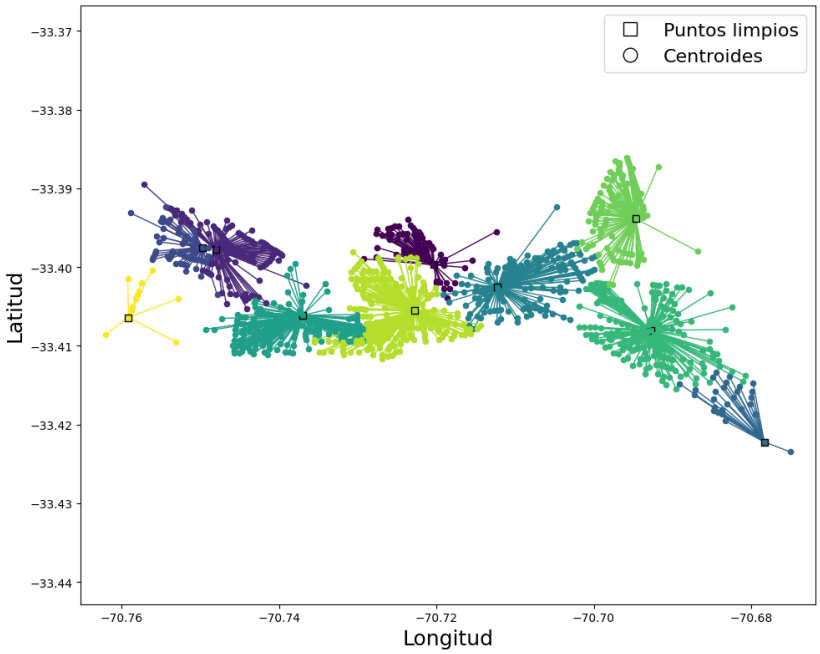


Figura 8: Ubicación de puntos limpios obtenida por Gurobi (2 fases)
Fuente: Elaboración propia.

La coincidencia en el número y costo de instalaciones indica que las capacidades de 2200 litros por compartimento son suficientemente holgadas para permitir configuraciones eficientes sin necesidad de abrir instalaciones adicionales. Las Figuras 8 y 9 muestran cómo los dos algoritmos distribuyeron estas 9 instalaciones de manera prácticamente idéntica en el territorio (la instalación fué la misma para MMAS Config. 1, 2 y 3), cubriendo estratégicamente las zonas de mayor concentración de centroides generadores de residuos.

5.4.2. Superioridad de MMAS en la optimización de rutas

A pesar de la convergencia en localización, se observan diferencias significativas en la calidad de las rutas de recolección generadas. Las tres configuraciones del MMAS superaron consistentemente al enfoque secuencial de Gurobi en términos de distancia total recorrida:

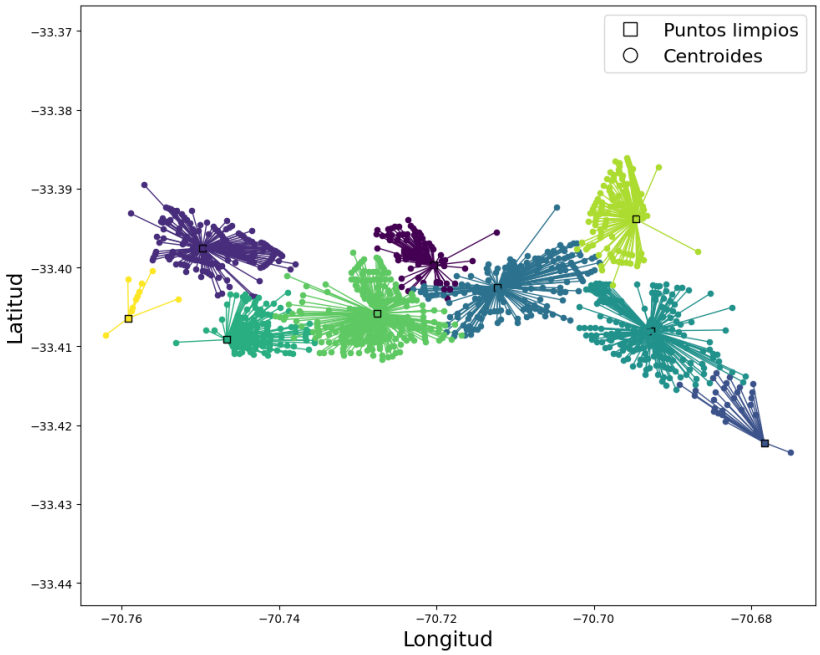


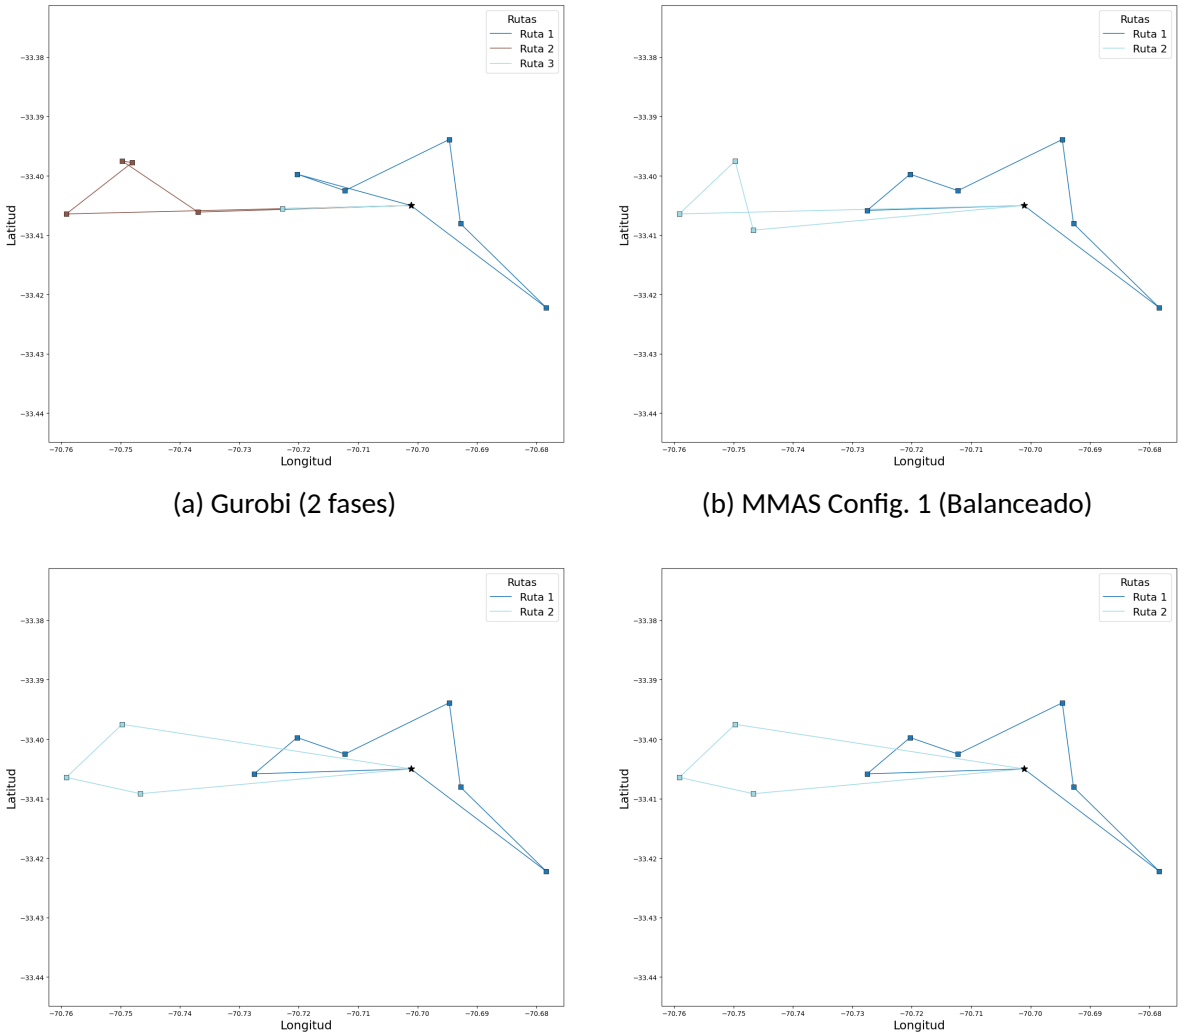
Figura 9: Ubicación de puntos limpios obtenida por MMAS. Las tres configuraciones MMAS convergieron a esta misma solución de localización
Fuente: Elaboración propia.

- **Gurobi (2 fases)**: 35137.40 metros utilizando 3 rutas
- **MMAS Config. 1 (Balanceado)**: 34610.00 metros utilizando 2 rutas (-1.5 % vs Gurobi)
- **MMAS Config. 2 (Exploratorio)**: 33327.00 metros utilizando 2 rutas (-5.1 % vs Gurobi)
- **MMAS Config. 3 (Explotativo)**: 33708.00 metros utilizando 2 rutas (-4.1 % vs Gurobi)

La configuración exploratoria (Config. 2) logró el mejor desempeño con una reducción del 5.1 % en la distancia total, lo que representa un ahorro de aproximadamente 1.8 kilómetros en cada ciclo semanal de recolección. Este resultado es particularmente relevante considerando que ambos enfoques trabajan sobre la misma configuración de instalaciones abiertas. La implementación de esta ruta se según lo mostrado en la figura 11, usando el mapa geográfico real de la comuna de Renca.

5.4.3. Eficiencia en el número de rutas

Un hallazgo notable es que todas las configuraciones del MMAS lograron completar la recolección utilizando únicamente 2 rutas, mientras que el enfoque secuencial de Gurobi requirió



(a) Gurobi (2 fases)

(b) MMAS Config. 1 (Balanceado)

(c) MMAS Config. 2 (Exploratorio)

(d) MMAS Config. 3 (Explotativo)

Figura 10: Comparación de rutas de vehículos según diferentes configuraciones
Fuente: Elaboración propia.

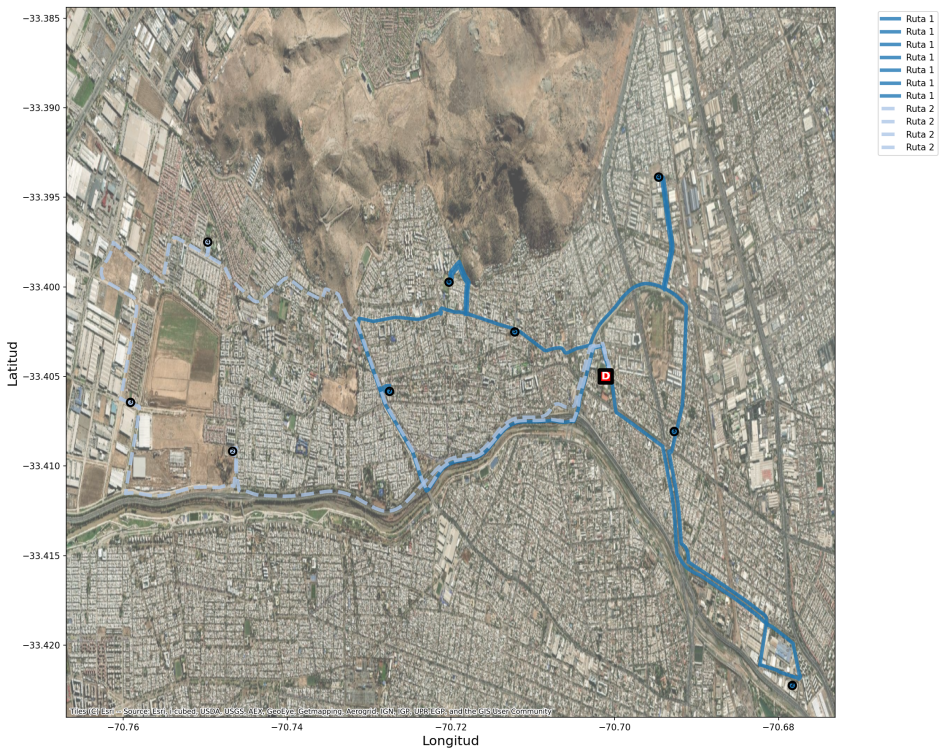


Figura 11: Puntos limpios instalados y rutas generadas por MMAS Config. 2
Fuente: Elaboración propia.

3 rutas. Esta diferencia estructural explica parcialmente la ventaja en distancia total: al consolidar las visitas en menos rutas, se eliminan retornos adicionales al depósito y se aprovecha mejor la capacidad de los vehículos.

La Figura 10 ilustra claramente esta diferencia estructural. Las figuras 10b, 10c y 10d correspondientes a las configuraciones MMAS muestran dos rutas (típicamente identificadas con dos colores) que distribuyen eficientemente la carga entre ambos vehículos, mientras que la figura 10a de Gurobi presenta tres rutas más cortas pero con mayor overhead de desplazamientos desde y hacia el depósito.

Esta consolidación de rutas es posible gracias a que el MMAS resuelve el problema de manera integrada, permitiendo que las decisiones de ruteo influyan implícitamente en cómo se aprovechan las capacidades de las instalaciones abiertas. En contraste, el enfoque secuencial de Gurobi toma la decisión de localización primero y luego optimiza las rutas sobre esa configuración fija, lo que puede resultar en una subutilización de la capacidad de los vehículos.

5.4.4. Trade-off entre tiempo-calidad

El principal costo de la superioridad del MMAS en calidad de solución para esta instancia es el tiempo computacional requerido. Gurobi completó ambas fases en apenas 15.01 segundos, mientras que las configuraciones MMAS necesitaron entre 203 y 393 segundos:

- MMAS Config. 3 (más rápido): 203.09 segundos (13.5$\times$ más lento que Gurobi)
- MMAS Config. 2: 362.99 segundos (24.2$\times$ más lento que Gurobi)
- MMAS Config. 1: 392.79 segundos (26.2$\times$ más lento que Gurobi)

Es importante señalar que estas diferencias temporales no solo reflejan diferencias algorítmicas, sino también disparidades significativas en el nivel de optimización de las implementaciones. Gurobi es un solver comercial altamente optimizado que aprovecha paralelismo mediante múltiples threads, cuenta con décadas de refinamiento en estructuras de datos especializadas, y emplea técnicas avanzadas de preprocesamiento y cortes inteligentes. En contraste, la implementación del MMAS desarrollada en este trabajo es esencialmente iterativa y secuencial, con optimizaciones enfocadas principalmente en la gestión eficiente de memoria y estructuras de datos, pero sin incorporar paralelización a nivel de threads o procesos.

Esta diferencia arquitectural explica en parte la ventaja temporal de Gurobi, especialmente considerando que el hardware utilizado dispone de 6 núcleos físicos y 12 procesadores lógicos que Gurobi puede explotar plenamente. Una implementación paralela del MMAS, donde cada hormiga construya su solución en un thread independiente, podría reducir significativamente los tiempos de ejecución reportados, potencialmente alcanzando aceleraciones cercanas al número de núcleos disponibles. Sin embargo, incluso sin esta optimización, los tiempos obtenidos resultan prácticos para el contexto de aplicación.

Sin embargo, este incremento temporal debe contextualizarse en el marco de la planificación logística. Para un problema de recolección semanal donde las rutas se planifican con anticipación, una diferencia de 6 minutos adicionales de cómputo es completamente aceptable si resulta en una reducción del 5 % en la distancia recorrida por los vehículos. Considerando que estas rutas se ejecutan repetidamente durante el año, el ahorro acumulado en combustible, emisiones y tiempo operativo justifica ampliamente el costo computacional adicional.

Es notable que la configuración explotativa (Config. 3), que logró un balance intermedio entre calidad de solución (33,708 metros, -4.1 % vs Gurobi) y tiempo de ejecución (203 segundos), representa el mejor compromiso para aplicaciones prácticas donde tanto la calidad como la eficiencia computacional son importantes.

5.4.5. Implicaciones prácticas para la instancia H03

Los resultados de H03 tienen implicaciones importantes para la planificación real de sistemas de recolección de residuos reciclables:

1. **Viabilidad de contenedores grandes**: La configuración C2 con contenedores de 2200 litros resultó suficiente para manejar la demanda del escenario 2025 con solo 9 instalaciones, sugiriendo que inversiones en contenedores de mayor capacidad pueden reducir el número de puntos limpios necesarios y simplificar la logística.
2. **Eficiencia en consolidación de rutas**: La capacidad de MMAS para consolidar la recolección en solo 2 rutas implica menores costos operativos (menos vehículos en circulación simultánea) y reducción de emisiones de CO_2, aspectos cruciales para políticas de sostenibilidad urbana.
3. **Ahorro operativo proyectado**: Una reducción del 5.1 % en distancia recorrida (caso Config. 2) aplicada a recolecciones semanales durante un año implica un ahorro de aproximadamente 93.6 kilómetros anuales por ciclo de recolección. Considerando costos típicos de operación vehicular, esto representa ahorros significativos que justifican la adopción de algoritmos de optimización más sofisticados.
4. **Robustez de la solución de localización**: La convergencia de todos los métodos a las mismas 9 instalaciones sugiere que esta configuración es robusta y no depende críticamente del algoritmo de optimización empleado, lo que aporta confianza para su implementación práctica.

5.4.6. Comentarios finales sobre H03

La instancia H03 demuestra que, aunque diferentes métodos converjan a la misma solución de localización, la manera de resolver el ruteo tiene impactos significativos en la eficiencia del sistema. El enfoque integrado del MMAS, considerando simultáneamente localización y ruteo, supera al secuencial de Gurobi logrando reducciones de 5.1 % en distancia total y consolidando en menos rutas. El análisis comparativo entre las tres configuraciones MMAS revela que no existe una universalmente superior: Config. 2 logra la mejor calidad de solución, Config. 3 ofrece el mejor balance tiempo-calidad, y Config. 1 proporciona exploración más exhaustiva a costa de mayor tiempo computacional. La elección debe basarse en las prioridades del contexto operativo: para máxima optimización, Config. 2 es preferible; para soluciones rápidas, Config. 3 es más adecuada.

Finalmente, H03 ilustra el valor del enfoque integrado MMAS en escenarios donde las capacidades son suficientemente holgadas para permitir múltiples configuraciones factibles de localización, pero donde la calidad del ruteo marca diferencias sustanciales en la eficiencia operativa.

CONCLUSIONES

Esta memoria aborda el problema integrado de localización de puntos limpios y ruteo de recolección multicompartimento (MCFLP–MCVRP) para apoyar la implementación operativa de la Ley REP en contextos urbanos reales. Su relevancia radica en que municipalidades y gestores necesitan dimensionar simultáneamente la infraestructura y las rutas para cumplir metas de valorización crecientes, equilibrando inversión y costos logísticos bajo restricciones de capacidad y servicio. Como aporte metodológico, se desarrolla una variante específica de Ant Colony Optimization (MMAS) en dos fases acopladas, con matrices de feromonas separadas para las decisiones de localización y para el ruteo compartimentado, lo que permite capturar la naturaleza compuesta del problema y guiar una búsqueda más efectiva. La propuesta se evalúa con instancias reales construidas con información de la comuna de Renca, contrastando escenarios de 2025 (tasa de reciclaje del 10 %) y 2040 (tasa proyectada del 65 %), con el fin de analizar su desempeño y sensibilidad frente a trayectorias de aumento en las tasas de reciclaje establecidas por la legislación chilena.

6.1. Cumplimiento de Objetivos

El objetivo general de diseñar y desarrollar una propuesta heurística integral que optimice simultáneamente la ubicación de contenedores y la planificación de rutas de recolección se cumplió satisfactoriamente mediante la implementación del algoritmo MMAS adaptado. La solución propuesta demuestra capacidad para abordar ambos problemas de forma conjunta, encontrando soluciones factibles y competitivas en términos de calidad y eficiencia operativa.

En cuanto a los objetivos específicos, estos se cumplieron de manera coherente con el alcance definido:

Objetivo 1 - Estudio del estado del arte: Se realizó una revisión exhaustiva de la literatura sobre problemas de localización de instalaciones (FLP), ruteo de vehículos (VRP), ruteo con múltiples compartimentos (MCVRP) y su integración. Se identificaron trabajos relevantes como los de [Ghiani *et al.*, 2012] sobre localización de contenedores, [Ostermeier *et al.*, 2021] sobre MCVRP, y otros sobre problemas integrados de localización-ruteo. Esta revisión estableció los fundamentos teóricos necesarios y permitió identificar la ausencia de benchmarks específicos para el problema conjunto MCFLPVRP, justificando la estrategia de comparación adoptada.

Objetivo 2 - Selección de métodos: Se justificó la selección de Ant Colony Optimization y específicamente su variante Max-Min Ant System basándose en su efectividad documentada para problemas de ruteo [Sundareswaran *et al.*, 2016] y su capacidad de adaptación a problemas compuestos. La comparación con alternativas como Bee Colony Optimization [Tong *et al.*, 2025] permitió fundamentar la elección de ACO como la metaheurística más

apropiada para este contexto.

Objetivo 3 - Propuesta algorítmica: Se diseñó e implementó una variante MMAS específica que resuelve simultáneamente localización y ruteo mediante dos fases acopladas con matrices de feromonas separadas. La implementación incluye mecanismos antiestancamiento mediante reinicialización de feromonas, actualización elitista que deposita feromona solo desde la mejor solución, y límites dinámicos τ_{min} y τ_{max} que se ajustan según la calidad de las soluciones encontradas. Las tres configuraciones desarrolladas (balanceada, exploratoria y explotativa) permiten explorar diferentes trade-offs entre exploración del espacio de búsqueda y explotación de soluciones prometedoras.

Objetivo 4 - Evaluación experimental: Se construyeron 12 instancias de prueba basadas en datos reales de la comuna de Renca, incluyendo 1061 centroides generadores de residuos y 52 ubicaciones candidatas para puntos limpios. La evaluación consideró dos escenarios temporales (2025 y 2040), tres configuraciones de contenedores (C1: 360L, C2: 2200L, C3: mixta) y dos configuraciones de vehículos (V1: uniforme, V2: asimétrica), totalizando 48 experimentos computacionales. Los resultados se compararon sistemáticamente contra una línea base establecida mediante el solver comercial Gurobi, analizando métricas de calidad de solución (costo de instalaciones, número de puntos limpios, distancia total, número de rutas) y eficiencia computacional (tiempo de ejecución).

6.2. Resultados Principales

6.2.1. Calidad de Soluciones en Localización

En la componente de localización (MCFLP), el algoritmo MMAS demostró capacidad para reproducir consistentemente los patrones de apertura de puntos limpios observados en la solución de referencia de Gurobi. En instancias como H03, todos los métodos convergieron a la misma configuración óptima de 9 instalaciones con costo de US$ 11,196, evidenciando robustez en la identificación de localizaciones estratégicas. Cuando se presentaron diferencias, estas fueron coherentes con el parámetro de balance γ: configuraciones con γ alto (como Config. 1 y Config. 3 con $\gamma = 1{,}0$) tendieron a aceptar más puntos limpios si esto permitía reducir significativamente las distancias de ruteo, mientras que $\gamma = 0{,}6$ (Config. 2) equilibró de manera más conservadora entre infraestructura y logística.

En el escenario 2025, el número promedio de instalaciones abiertas osciló entre 22.9 (Gurobi) y 25.2 (MMAS Config. 3), representando una diferencia del 10 % que se traduce en mayor cobertura territorial y potencialmente menor distancia promedio entre ciudadanos y puntos de reciclaje. Para el escenario 2040, con demanda 6.5 veces superior, la infraestructura necesaria se incrementó proporcionalmente: instancias como H09-H12 requirieron entre 32 y 36 puntos limpios, indicando que el crecimiento en las tasas de reciclaje proyectadas por la Ley REP demandará inversiones significativas en infraestructura durante los próximos 15

años.

6.2.2. Eficiencia en Ruteo

La componente de ruteo (MCVRP) representa el mayor aporte diferencial del enfoque integrado propuesto. En la instancia emblemática H03, las tres configuraciones MMAS superaron consistentemente la solución de Gurobi:

- **MMAS Config. 1 (Balanceada):** 34,610 metros utilizando 2 rutas (-1.5 % vs Gurobi)
- **MMAS Config. 2 (Exploratoria):** 33,327 metros utilizando 2 rutas (-5.1 % vs Gurobi)
- **MMAS Config. 3 (Explotativa):** 33,708 metros utilizando 2 rutas (-4.1 % vs Gurobi)

Frente a los 35,137 metros en 3 rutas de Gurobi, la configuración exploratoria logró una reducción del 5.1 %, equivalente a 1.8 kilómetros por ciclo semanal. Proyectado anualmente (52 semanas), esto representa aproximadamente 93.6 kilómetros de ahorro, con implicaciones directas en costos de combustible, emisiones de CO_2 y desgaste vehicular.

Un hallazgo particularmente relevante es la consolidación de rutas: todas las configuraciones MMAS completaron la recolección con 2 vehículos versus los 3 requeridos por Gurobi. Esta diferencia estructural no solo reduce costos operativos directos, sino que simplifica la logística al requerir menos vehículos en circulación simultánea, menos conductores y menos retornos al depósito. La Figura 9 del documento ilustra claramente cómo MMAS aprovecha mejor la capacidad de los vehículos al construir rutas más largas pero mejor consolidadas.

6.2.3. Diferencias entre Escenarios Temporales

La comparación entre escenarios 2025 y 2040 revela la magnitud del desafío logístico que enfrentarán las municipalidades al incrementar las tasas de reciclaje del 10 % al 65 %:

Infraestructura: El número de puntos limpios se incrementa en promedio de 24-36 instalaciones (escenario 2025) a 32-36 instalaciones (escenario 2040), representando aumentos entre 33 % y 50 % en inversión de capital.

Flota y rutas: El número de rutas necesarias se incrementa sustancialmente. En instancias comparables (por ejemplo, H03 vs H09, ambas con configuración C2-V1), se observa un aumento de 2-3 rutas en 2025 a 15-16 rutas en 2040, un incremento superior al 500 %.

Distancias: La distancia total recorrida se multiplica proporcionalmente. H03 requiere $\sim$35,000 metros mientras que H09 demanda $\sim$135,000 metros, casi cuatro veces más kilometraje semanal.

Estos resultados cuantifican el impacto operativo de las metas de la Ley REP y subrayan la necesidad de planificación anticipada y asignación presupuestaria progresiva para acompañar el crecimiento en las tasas de valorización.

6.2.4. Eficiencia Computacional y Trade-offs

El principal costo del enfoque MMAS es el tiempo computacional. En instancias pequeñas como H03, Gurobi completó ambas fases en 15 segundos mientras MMAS requirió entre 241 y 456 segundos según la configuración (aproximadamente 16-30 veces más tiempo). En instancias del escenario 2040 (H09-H12), Gurobi alcanzó el límite de 1800 segundos sin garantizar optimalidad, mientras MMAS convergió consistentemente en 500-1350 segundos.

Es fundamental contextualizar estas diferencias:

Naturaleza de las implementaciones: Gurobi es un solver comercial con décadas de optimización, preprocesamiento avanzado, cortes inteligentes y paralelización multi-thread que explota los 6 núcleos físicos del hardware de prueba. La implementación MMAS desarrollada es secuencial y sin paralelización, con optimizaciones limitadas a gestión eficiente de estructuras de datos.

Contexto de aplicación: Para planificación semanal o mensual de rutas, diferencias de 5-10 minutos de cómputo son completamente aceptables si resultan en ahorros operativos del 5 % en kilometraje recurrente.

Potencial de mejora: Una versión paralela de MMAS donde cada hormiga construya su solución en threads independientes podría lograr aceleraciones cercanas al número de núcleos (6-12$\times$), reduciendo tiempos a rangos competitivos con Gurobi manteniendo la ventaja en calidad de ruteo.

La configuración MMAS Config. 3 (explotativa) emerge como el mejor balance práctico: logra reducciones del 4.1 % en distancia con tiempos aproximadamente 30 % menores que las otras configuraciones MMAS, representando el punto óptimo entre calidad de solución y eficiencia computacional para aplicaciones operacionales.

6.3. Alcances y Limitaciones

El modelo implementado se sustenta en supuestos operativos que facilitan su tratamiento computacional pero que pueden requerir adaptaciones para contextos específicos. Se asume disponibilidad suficiente de vehículos para completar todas las rutas necesarias, permitiendo reutilización tras retorno al depósito, aunque en la práctica las municipalidades pueden tener restricciones presupuestarias o de adquisición que limiten la flota disponible. Cada centroide se asigna exactamente a un punto limpio y este es visitado por un único vehículo, lo cual

simplifica la gestión logística pero podría limitar la flexibilidad en operaciones reales donde asignaciones múltiples o visitas parciales podrían ser beneficiosas en casos de contenedores saturados. El cumplimiento exacto de capacidades por compartimento asume operación bajo condiciones nominales, sin considerar que fluctuaciones estacionales, eventos especiales o variabilidad en tasas de reciclaje pueden generar situaciones donde las capacidades resulten insuficientes o subutilizadas. La matriz de distancias y costos se considera estática, sin modelar explícitamente congestión vehicular, condiciones climáticas, obras viales o variabilidad en tiempos de carga y descarga que afectan las operaciones reales. Tampoco se consideran restricciones horarias de operación de puntos limpios, turnos laborales de conductores, ni preferencias ciudadanas de horarios de recolección, restricciones temporales que son frecuentes en operaciones municipales reales. Finalmente, se asume un único depósito central, cuando comunas extensas o con geografía fragmentada podrían beneficiarse de múltiples depósitos o centros de acopio intermedios.

Las instancias experimentales se construyen con información municipal real, aportando validez ecológica pero también introduciendo limitaciones que deben reconocerse. Los 1061 centroides y 52 ubicaciones candidatas corresponden específicamente a la comuna de Renca, por lo que la generalización a otras comunas requiere recolección de datos locales y potencial ajuste de parámetros. Las matrices de distancia se calcularon como distancias euclidianas entre coordenadas geográficas, aunque las distancias reales por red vial pueden diferir significativamente debido a sentidos de circulación, topografía o restricciones de tránsito que no se capturan en este cálculo simplificado. Los valores de generación de residuos se proyectan mediante factores constantes (0.1 para 2025 y 0.65 para 2040), sin considerar que la variabilidad estacional, evolución demográfica, cambios en patrones de consumo o éxito de campañas educativas pueden alterar sustancialmente la generación real en horizontes temporales extendidos. El modelo considera generación semanal constante a lo largo del año, cuando en la práctica periodos festivos, vacaciones escolares o eventos especiales pueden generar picos o valles significativos en la demanda de recolección que afectarían la factibilidad y eficiencia de las soluciones propuestas.

La comparación se establece contra Gurobi resolviendo FLP y VRP secuencialmente, lo cual representa una aproximación razonable al enfoque tradicional pero no permite contrastar contra otras metaheurísticas como algoritmos genéticos, búsqueda tabú o simulated annealing, ni contra soluciones exactas del problema integrado que serían computacionalmente prohibitivas para instancias de este tamaño. Las instancias H07 y H08, correspondientes al escenario 2040 con contenedores de 360 litros, resultaron infactibles, evidenciando que configuraciones de baja capacidad son inadecuadas para escenarios de alto reciclaje y limitando el análisis comparativo en ciertos rangos del espacio de diseño. Cada configuración MMAS se ejecutó cinco veces con diferentes semillas aleatorias, reportando promedios y mejores soluciones, lo cual captura variabilidad básica aunque un análisis estadístico más robusto mediante pruebas de hipótesis, intervalos de confianza o análisis de varianza fortalece ría las conclusiones sobre diferencias significativas entre configuraciones. Se evaluaron tres configuraciones MMAS con diferentes combinaciones de parámetros α, β, ρ y γ, pero un análisis sistemático tipo diseño de experimentos o calibración automática mediante herramientas

como irace o SPOT podría identificar configuraciones superiores o revelar interacciones paramétricas no evidentes en el análisis manual realizado.

6.4. Aplicaciones y Valor de la Propuesta

Desde la perspectiva de ciencias de la computación e ingeniería informática, este trabajo aporta contribuciones metodológicas y técnicas significativas. La especialización de MMAS con matrices de feromonas separadas para localización y ruteo constituye una contribución técnica reproducible para otros problemas biobjetivo o multicomponente donde decisiones en una fase impactan la otra, estableciendo un patrón de diseño aplicable a problemas similares de optimización integrada. El código desarrollado en C demuestra que metaheurísticas sofisticadas pueden implementarse eficientemente en lenguajes de bajo nivel, obteniendo tiempos de convergencia prácticos entre 5 y 30 minutos en hardware estándar para instancias realistas con más de 1000 centroides y 50 nodos candidatos, probando que la eficiencia computacional no requiere necesariamente solvers comerciales costosos. La estrategia de construcción por fases con mecanismos de factibilidad incremental, mediante actualización de capacidades remanentes y verificación por compartimento, ilustra buenas prácticas para abordar problemas NP-duros con múltiples restricciones heterogéneas, ofreciendo un modelo de implementación para estudiantes e investigadores que enfrenten problemas de complejidad similar. Además, la arquitectura modular facilita incorporar extensiones como ventanas temporales, múltiples depósitos, flota heterogénea o restricciones de jornada laboral mediante modificaciones localizadas en las funciones de factibilidad y construcción probabilística, garantizando la extensibilidad y reutilización del código desarrollado.

Las autoridades locales y gestores municipales pueden emplear esta herramienta para múltiples propósitos operativos y estratégicos que mejoran la gestión de residuos reciclables. En términos de planificación estratégica, permite evaluar escenarios futuros considerando crecimiento demográfico, incremento en tasas de reciclaje o cambios normativos, dimensionando con suficiente anticipación las inversiones necesarias en infraestructura y flota para evitar deficiencias de servicio o gastos reactivos. Para la optimización presupuestaria, facilita identificar configuraciones costo-efectivas que minimicen el gasto total combinando costos de instalación y operación bajo restricciones presupuestarias, explorando sistemáticamente el trade-off entre CAPEX en contenedores y OPEX en combustible y personal mediante el ajuste del parámetro γ. La herramienta también apoya la mejora continua al permitir rediseñar periódicamente rutas existentes a medida que se inauguran nuevos desarrollos habitacionales, se modifican patrones de generación o se incorporan nuevos tipos de residuos al sistema de reciclaje, adaptando el sistema a la dinámica urbana real. En cuanto a transparencia y rendición de cuentas, las soluciones obtenidas mediante modelos de optimización validados permiten justificar técnicamente ante concejos municipales o ciudadanía la ubicación de puntos limpios y frecuencias de recolección, fundamentando decisiones políticas en evidencia cuantitativa. Finalmente, en procesos de licitaciones y evaluación de ofertas, las soluciones pueden emplearse como benchmarks para evaluar propuestas de empresas

proveedoras de servicios de recolección, identificando ofertas económicamente atractivas y operacionalmente viables frente a estándares teóricamente alcanzables.

Los productores y gestores de residuos obligados por la Ley REP pueden beneficiarse significativamente de la metodología propuesta en diversos aspectos de su operación y planificación estratégica. La estimación de costos de compliance se facilita al permitir proyectar con mayor precisión los gastos asociados a cumplir metas de valorización mediante sistemas de puntos limpios y recolección diferenciada, facilitando la planificación financiera de largo plazo y la toma de decisiones informadas sobre participar en sistemas de gestión colectiva o implementar sistemas individuales. Para empresas que se agrupan en sistemas de gestión colectiva, la metodología permite dimensionar y operar eficientemente su infraestructura compartida de recolección en múltiples comunas, optimizando inversiones conjuntas y distribuyendo equitativamente costos entre los miembros del sistema. La evaluación de alternativas se vuelve más rigurosa al poder comparar cuantitativamente diferentes esquemas de recolección diferenciada, ya sea puntos limpios, recolección puerta a puerta o sistemas mixtos, en términos de costos, cobertura territorial y eficiencia operativa bajo las mismas condiciones de demanda y restricciones. Además, las soluciones técnicamente optimizadas proporcionan una base sólida para establecer diálogos informados con autoridades locales sobre ubicación de instalaciones, frecuencias de servicio y distribución justa de costos, facilitando negociaciones basadas en datos objetivos en lugar de apreciaciones subjetivas.

Para la sociedad y el medio ambiente, la implementación de soluciones optimizadas genera múltiples beneficios tangibles que trascienden la eficiencia operativa. La ubicación estratégica de puntos limpios minimiza distancias promedio que los ciudadanos deben recorrer para depositar sus residuos reciclables, reduciendo directamente las barreras de participación que han sido identificadas como el principal motivo de no-reciclaje, considerando que el 62 % de los chilenos declara no reciclar por falta de infraestructura accesible según datos del [Pacto Chileno de los Plásticos, 2022]. La reducción del 5 % en kilometraje de recolección demostrada en los experimentos se traduce directamente en menor consumo de combustibles fósiles y menores emisiones de gases de efecto invernadero, contribuyendo concretamente a las metas nacionales de mitigación climática establecidas en los compromisos internacionales de Chile. La consolidación de rutas implica que un menor número de vehículos circula simultáneamente por las calles, reduciendo la congestión vehicular, el ruido urbano asociado a operaciones de recolección y el deterioro acelerado de la infraestructura vial causado por vehículos pesados, beneficiando la calidad de vida urbana en general. La mejora en tasas de valorización de residuos reciclables fortalece la economía circular al generar empleos formales en la industria del reciclaje y procesamiento de materiales recuperados, mientras reduce la presión sobre vertederos y rellenos sanitarios cuya vida útil se extiende al desviar materiales valorizables del flujo de residuos sólidos urbanos. Finalmente, los modelos de optimización que consideran explícitamente criterios de cobertura geográfica pueden contribuir a una distribución equitativa de servicios de reciclaje entre barrios de diferentes niveles socioeconómicos, promoviendo justicia ambiental al garantizar que comunidades vulnerables no sean sistemáticamente excluidas de la infraestructura de reciclaje por criterios puramente económicos.

6.5. Recomendaciones y Trabajo Futuro

6.5.1. Extensiones del Modelo

Demanda estocástica: Incorporar variabilidad en la generación de residuos mediante distribuciones de probabilidad ajustadas a datos históricos, permitiendo diseñar soluciones robustas que mantengan factibilidad ante fluctuaciones estacionales o eventos imprevistos. Esto requeriría adaptar la función objetivo para optimizar valores esperados o minimizar riesgo de infactibilidad.

Planificación dinámica: Extender el modelo a horizontes temporales multi-periodo donde demanda, costos y disponibilidad de instalaciones evolucionan. Esto permitiría planificar expansiones graduales de infraestructura alineadas con trayectorias de crecimiento en tasas de reciclaje.

Ventanas temporales y turnos laborales: Incorporar restricciones horarias de operación de puntos limpios, jornadas laborales de conductores y preferencias ciudadanas de horarios de recolección, generando soluciones más realistas y alineadas con regulaciones laborales.

Múltiples depósitos: Considerar escenarios donde existen varios centros de acopio o instalaciones de transferencia, ampliando el espacio de decisión pero potencialmente reduciendo distancias de ruteo en geografías extensas o fragmentadas.

Flota heterogénea: Modelar vehículos con diferentes capacidades, costos operativos, consumos de combustible o tecnologías (eléctricos vs. diesel), optimizando simultáneamente asignación de tipos de vehículos y diseño de rutas.

6.5.2. Mejoras Algorítmicas

Paralelización: Implementar construcción paralela de soluciones donde cada hormiga ejecute en un thread independiente, aprovechando los núcleos disponibles en hardware moderno. Esto podría reducir tiempos de ejecución entre $4\times$ y $12\times$ según el número de procesadores, acercando la eficiencia temporal a la de solvers comerciales.

Calibración automática: Emplear herramientas de configuración automática de parámetros para identificar sistemáticamente configuraciones óptimas de α, β, ρ, γ, número de hormigas y criterios de parada, potencialmente superiores a las tres configuraciones manuales evaluadas.

Técnicas de aceleración: Implementar estructuras de datos avanzadas (quadtrees, k-d trees) para consultas eficientes de vecindad durante construcción de soluciones, o aproximaciones de distancias mediante heurísticas geométricas.

6.5.3. Validación y Extensión Experimental

Estudios de caso adicionales: Aplicar la metodología a otras comunas con características geográficas, demográficas y socioeconómicas diferentes, evaluando generalización y robustez de las configuraciones propuestas.

Comparación ampliada: Contrastar resultados con otras metaheurísticas (algoritmos genéticos, búsqueda tabú, GRASP, particle swarm optimization) para confirmar la competitividad de MMAS en este dominio específico.

Validación en campo: Implementar pilotos en municipalidades colaboradoras, monitoreando desempeño real de soluciones propuestas y capturando factores no modelados (congestión, variabilidad climática, comportamiento ciudadano) para refinar el modelo.

Análisis de sensibilidad sistemático: Realizar diseños de experimentos factoriales o análisis de varianza para cuantificar rigurosamente el impacto de cada parámetro y sus interacciones sobre métricas de calidad y tiempo de convergencia.

6.6. Síntesis Final

En síntesis, este trabajo demuestra que la integración simultánea de localización y ruteo mediante metaheurísticas especializadas como MMAS genera soluciones de alta calidad para problemas complejos de gestión de residuos reciclables. Los resultados validan la viabilidad técnica, económica y ambiental del enfoque propuesto, proporcionando una herramienta práctica para apoyar la implementación de la Ley REP en Chile y contribuyendo metodológicamente al campo de la optimización combinatoria aplicada a logística urbana sostenible. Las extensiones futuras propuestas abren múltiples líneas de investigación y desarrollo que pueden continuar mejorando tanto la calidad de las soluciones como su aplicabilidad a contextos operacionales cada vez más complejos y realistas.

ANEXOS

En los Anexos se incluye todo aquel material complementario que no es parte del contenido de los capítulos de la memoria, pero que permiten a un lector contar con un contenido adjunto relacionado con el tema.

REFERENCIAS BIBLIOGRÁFICAS

[ter, 2019] (2019). Hoja de ruta fija la meta de que chile recicle el 65 % de su basura domiciliaria al año 2040. Fundación Terram.

[Croquevielle, 2023] Croquevielle, S. (2023). Chile es el país que más basura produce en sudamérica: el apoyo a dos iniciativas que buscan combatir este problema. Medio Ambiente.

[Dorigo y Gambardella, 1997a] Dorigo, M. y Gambardella, L. (1997a). Ant colony system: a cooperative learning approach to the traveling salesman problem. IEEE Transactions on Evolutionary Computation, 1(1):53–66.

[Dorigo y Gambardella, 1997b] Dorigo, M. y Gambardella, L. M. (1997b). Ant colonies for the travelling salesman problem. Biosystems, 43(2):73–81.

[Fu *et al.*, 2022] Fu, B., Kathuria, T., Rizzo, D., Castanier, M., Yang, X. J., Ghaffari, M., y Barton, K. (2022). Simultaneous human-robot matching and routing for multi-robot tour guiding under time uncertainty.

[Ghiani *et al.*, 2012] Ghiani, G., Laganà, D., Manni, E., y Triki, C. (2012). Capacitated location of collection sites in an urban waste management system. Waste management (New York, N.Y.), 32:1291–6.

[Gobierno de Chile, 2024] Gobierno de Chile, M. d. M. A. (2024). Ley marco para la gestión de residuos, responsabilidad extendida y fomento al reciclaje. Economía Circular.

[Ostermeier *et al.*, 2021] Ostermeier, M., Henke, T., Hübner, A., y Wäscher, G. (2021). Multi-compartment vehicle routing problems: State-of-the-art, modeling framework and future directions. European Journal of Operational Research, 292(3):799–817.

[Pacto Chileno de los Plásticos, 2022] Pacto Chileno de los Plásticos, G. C. (2022). 62 Reciclando-Ando.

[Reed *et al.*, 2014] Reed, M., Yiannakou, A., y Evering, R. (2014). An ant colony algorithm for the multi-compartment vehicle routing problem. Applied Soft Computing, 15:169–176.

[Reinelt, 1995] Reinelt, G. (1995). Tsplib95: A library of sample instances for the tsp and related problems. Universidad de Heidelberg.

[Stützle y Hoos, 2000] Stützle, T. y Hoos, H. H. (2000). Max–min ant system. Future Generation Computer Systems, 16(8):889–914.

[Sundareswaran *et al.*, 2016] Sundareswaran, K., Vigneshkumar, V., Sankar, P., Simon, S. P., Srinivasa Rao Nayak, P., y Palani, S. (2016). Development of an improved po algorithm assisted through a colony of foraging ants for mppt in pv system. IEEE Transactions on Industrial Informatics, 12(1):187–200.

[Tong *et al.*, 2025] Tong, M., Peng, Z., y Wang, Q. (2025). A hybrid artificial bee colony algorithm with high robustness for the multiple traveling salesman problem with multiple depots. Expert Systems with Applications, 260:125446.