



UNIVERSIDAD
Finis Terrae

UNIVERSIDAD FINIS TERRAE
FACULTAD DE INGENIERÍA
INGENIERÍA CIVIL EN INFORMÁTICA Y TELECOMUNICACIONES

**EL PROBLEMA DEL TAMAÑO DE UNA FLOTA DE DRONES PARA
OPERACIONES DE DELIVERY: CASO DE ESTUDIO EN COLINA, SANTIAGO**

GUILLERMO BASTHIAN ANCACOY LALUT

Trabajo de título presentado a la Facultad de Ingeniería de la Universidad Finis Terrae, para
optar al Título de Ingeniero Civil en Informática y Telecomunicaciones

Profesor Guía: Alfredo Candia Vejar

Santiago, Chile
2025

A mi familia, por apoyarme en todo este proceso les agradezco.

AGRADECIMIENTOS

Quiero agradecer a mi familia por estar conmigo en cada etapa de este proceso, por alentarme a seguir adelante semestre tras semestre, incluso cuando las cosas se pusieron difíciles. Gracias por motivarme a terminar esta etapa de mi vida, por confiar en mí y por brindarme su apoyo incondicional, especialmente en los momentos más duros que vivimos mientras yo aún estaba en la universidad. Y, sobre todo, gracias a mi pareja, que siempre estuvo ahí, acompañándome y dándome fuerza cuando más la necesitaba.

También quiero agradecer a mis amigos, quienes hicieron que los días en la universidad fueran más llevaderos y me motivaron a seguir adelante, incluso cuando las ganas faltaban. Gracias por estar, por acompañarme, por ayudarme a estudiar y por impulsarme a superarme cada día. Me siento afortunado de haber compartido este camino con ustedes.

Agradezco también a mi profesor guía, que, a pesar de haber sido pocos meses, me aceptó cuando ya no sabía qué hacer y me dio la oportunidad de tomar un proyecto de título cuando el tiempo era muy justo. Me apoyó en todo el proceso y siempre estuvo dispuesto a guiarme. Hubo semanas en que nos reuníamos hasta tres veces solo para aclarar dudas y sacar este proyecto adelante. Gracias por su paciencia, dedicación y por ayudarme en un momento clave.

Por último, gracias a la comisión de evaluación, que me aceptó este proyecto a último momento y me dio la oportunidad de terminar el semestre y poder egresar.

INDICE DE CONTENIDOS

RESUMEN	8
ABSTRACT.....	9
CAPÍTULO 1: INTRODUCCIÓN	10
1.1. Situación problema	11
1.2. Solución propuesta.....	12
1.3. Objetivo general.....	13
1.4. Objetivos específicos	13
1.5 Alcances y limitaciones	14
1.5.1 Alcances del proyecto	14
1.5.2 Limitaciones del proyecto.....	14
1.6 Estado del arte.....	14
1.7 Situación actual.....	15
1.8 Disponibilidad de la información	17
1.9. Situación actual del mercado de drones comerciales para operaciones logísticas	18
CAPÍTULO 2: MARCO TEÓRICO.....	20
2.1 Optimización matemática	20
2.2 Problemas de ruteo y dimensionamiento de flotas	20
2.3 Tecnología y operación de drones	20
2.4 Gestión energética de drones	21
2.5 Metaheurísticas aplicadas a la logística	21
2.6 Formulación matemática del modelo propuesto	21
2.6.1 Conjuntos	22
2.6.2 Parámetros	22
2.6.3 Variables de decisión.....	22
2.7 Función objetivo	22
2.8 Restricciones del modelo	23
2.8.1 Visita única a cada cliente	23
2.8.2 Conservación del flujo	23
2.8.3 Rutas comienzan y terminan en el depósito.....	24
2.8.4 Eliminación de subtours (MTZ)	24
2.8.5 Autonomía energética de los drones	24
2.8.6 Cálculo del tiempo total de operación por dron.....	24

2.9	Selección y Evaluación de Drones.....	25
2.9.1	Wingcopter 198.....	25
2.9.2	Zipline Platform 1	27
CAPÍTULO 3: METODOLOGÍA.....		29
3.1	Definición del área de operación y selección del centro logístico.....	29
3.2	Estimación y caracterización de la demanda	29
3.3	Selección técnica de drones	29
3.4	Formulación e implementación del modelo matemático.....	30
3.5	Análisis de resultados y sensibilidad	30
CAPÍTULO 4: TIPOS DE DRONES Y ESTIMACIÓN ECONÓMICA		32
4.1.	Comparación de modelos de drones comerciales	32
4.2.	Estimación económica del proyecto	33
4.2.1.	Costos de adquisición	33
4.2.2.	Costos operativos anuales.....	33
4.2.3.	Proyección de costos a cinco años.....	34
4.2.4.	Viabilidad económica general	34
CAPÍTULO 5: DESARROLLO E IMPLEMENTACIÓN DEL MODELO.....		36
5.1.	Entorno computacional utilizado.....	36
5.2.	Fragmentos clave del código implementado	37
5.2.1.	Fragmento 1: Definición de parámetros globales y matriz de distancias	37
5.2.2.	Fragmento 2: Variables de decisión y función objetivo	38
5.2.3.	Fragmento 3: Restricciones esenciales del modelo implementado	40
5.2.4.	Fragmento 4: Ejecución del modelo y obtención de resultados	41
CAPÍTULO 6: DESARROLLO EXPERIMENTAL		44
6.1.	Descripción de los experimentos	44
6.1.1.	Escenarios simulados.....	44
6.1.2.	Escenarios con datos reales:	45
6.2.	Implementación de los modelos experimentales	45
6.2.1.	Modelo exacto (MILP)	45
6.2.2.	Modelo heurístico simple.....	45
6.3.	Resultados y comparaciones de distintos experimentos	46
6.4.	Resultados Experimento 1 con un dron y 10 clientes:.....	46
6.4.1.	Experimento 1 Con dos drones y 10 clientes.....	46
6.4.2.	Experimento 1 Con tres drones y 10 clientes	47
6.4.3.	Análisis comparativo experimento 1	48

6.4.4.	Ventaja del modelo heurístico	48
6.4.5.	Impacto del número de drones.....	48
6.5.	Resultados experimento 2 con un dron y 10 clientes, 20 km de diámetro:	49
6.5.1.	Con dos drones.....	49
6.5.2.	Con 3 drones	50
6.5.3.	Análisis comparativo Experimento 2.....	51
6.6.	Resultados Experimento 3 con un dron y 20 clientes.....	51
6.6.1.	Con dos drones:	52
6.6.2.	Con tres drones	53
6.6.3.	Análisis comparativo experimento 3	54
6.8.	Escenario 1: configuración base	55
6.8.1.	Resultados 1.....	55
6.8.2.	Asignación de clientes	55
6.8.3.	Análisis primer escenario.....	56
6.9.	Escenario 2: Configuración con baterías adicionales permitidas	56
6.9.1.	Resultados 2.....	56
6.9.2.	Asignación de clientes	57
6.9.3.	Análisis Escenario 2.....	57
6.10.	Escenario 3: Configuración con dos baterías adicionales permitidas.....	57
6.10.1.	Resultados Escenario 3	58
6.10.2.	Asignación de clientes	58
6.10.3.	Análisis escenario 3	58
6.11.	Escenario 4: Configuración con tres baterías adicionales permitidas.....	58
6.11.1.	Resultados escenario 4:.....	59
6.11.2.	Asignación de clientes:	59
6.11.3.	Análisis escenario 4	59
6.11.4.	Análisis de sensibilidad para el escenario 4.....	60
6.11.5.	Discusión de resultados experimento final	60
6.12.	La Tabla 11 expone los resultados del experimento 4.....	61
CAPITULO 7: RESULTADOS Y ANÁLISIS DEL MODELO DE OPTIMIZACIÓN		62
7.1.	Resultados obtenidos por escenario.....	63
7.2.	Análisis general de los resultados.....	63
7.3.	Análisis de Sensibilidad.....	64
7.3.1.	Impacto del parámetro α (ponderación del tiempo total).....	64
7.3.2.	Impacto de priorizar número de drones (β)	64

7.3.3. Influencia del uso de baterías adicionales (γ)	64
CAPITULO 8: CONCLUSIONES Y TRABAJOS FUTUROS.....	66
8.1. Conclusión	66
8.2. Trabajos futuros	67
8.2.1. Incorporar restricciones regulatorias específicas	67
8.2.2. Modelos dinámicos y tiempo real	67
8.2.3. Ampliación de la flota y escenarios más complejos	67
8.2.4. Simulación computacional detallada	68
GLOSARIO	69
ABREVIATURAS.....	70
BIBLIOGRAFIA	70
ANEXO	72

INDICE DE TABLAS

Tabla 1 Comparación de modelos de drones comerciales	32
Tabla 2 Resultados Experimento 1 con un dron	46
Tabla 3. Resultados Experimento 1 con dos drones	47
Tabla 4. Resultados Experimento 1 con tres drones	48
Tabla 5. Resultados Experimento 2 con un dron.	49
Tabla 6. Resultados Experimento 2 con dos drones.	50
Tabla 7. Resultados Experimento 2 con tres drones.	51
Tabla 8. Resultados Experimento 3 con un dron.	52
Tabla 9. Resultados Experimento 3 con dos drones.	53
Tabla 10. Resultados Experimento 3 con un dron.	54
Tabla 11. Resultados Experimento final.....	61
Tabla 12. Resultados Finales	63

INDICE DE FIGURAS

Figura 1. Definición de parámetros globales y matriz de distancias	38
Figura 2. Variables de decisión y función objetivo	39
Figura 3. Restricciones esenciales del modelo implementado	41
Figura 4. Ejecución del modelo y obtención de resultados	43

RESUMEN

El presente trabajo aborda la problemática del dimensionamiento óptimo de una flota de drones destinada a operaciones logísticas en la comuna de Colina, Santiago. Para ello, se desarrolló un modelo matemático basado en Programación Lineal Entera Mixta (MILP), con el objetivo de minimizar el número de drones necesarios, optimizar el uso de baterías adicionales y garantizar la cobertura completa de la demanda. El área de operación y los puntos de entrega son definidos mediante coordenadas reales obtenidas de Google Earth, mientras que la demanda es estimada considerando patrones de consumo locales y datos poblacionales.

Se realiza simulaciones computacionales y experimentos con datos reales, analizando escenarios con distintas cantidades de drones y disponibilidad de baterías adicionales. Los resultados evidencian que la incorporación estratégica de baterías adicionales reduce significativamente la cantidad de drones requeridos, pasando de seis unidades en el escenario base a tres drones en el escenario óptimo. Además, el análisis de sensibilidad permite evaluar el impacto de variaciones en parámetros clave como autonomía energética, velocidad operativa y localización del centro logístico.

Se concluye que la planificación estratégica mediante modelos matemáticos y el uso adecuado de recursos energéticos permiten optimizar significativamente las operaciones logísticas con drones. Finalmente, se propone como trabajo futuro la implementación de metaheurísticas, en particular el método GRASP, para resolver instancias más complejas con mayores volúmenes de demanda y restricciones dinámicas.

Palabras clave: Optimización logística, Drones, Programación Lineal Entera Mixta, MILP, GRASP, Última milla, Autonomía energética, Baterías adicionales, Colina.

ABSTRACT

This work addresses the problem of determining the optimal size of a drone fleet for logistical operations in the commune of Colina, Santiago. A mathematical model based on Mixed Integer Linear Programming (MILP) is developed, aiming to minimize the number of drones required, optimizing the use of additional batteries, and ensuring full coverage of demand. The operational area and delivery points are defined using real geographic coordinates obtained from Google Earth, while demand estimation is based on local consumption patterns and demographic data.

Computational simulations and experiments with real data are carried out, analyzing scenarios with different numbers of drones and varying availability of additional batteries. The results show that the strategic use of additional batteries significantly reduced the number of drones required, from six units in the base scenario to three drones in the optimal configuration. Moreover, sensitivity analysis allows the assessment of variations in key parameters such as energy autonomy, operating speed, and the location of the logistics center.

It is concluded that strategic planning through mathematical models and efficient energy resource management can significantly optimize logistics operations with drones. Finally, as future work, the implementation of metaheuristic approaches, specifically the GRASP method (Greedy Randomized Adaptive Search Procedure), is proposed to solve more complex instances with higher demand volumes and dynamic constraints.

Keywords: Logistics optimization, Drones, Mixed Integer Linear Programming (MILP), Drone delivery, GRASP, Energy Autonomy, Last-mile delivery.

CAPÍTULO 1: INTRODUCCIÓN

En los últimos años, la incorporación de drones en operaciones logísticas ha representado una oportunidad innovadora para resolver problemáticas relacionadas con la reducción de tiempos de entrega, la mejora en la cobertura geográfica y la disminución de costos operativos. Sin embargo, dimensionar correctamente el tamaño óptimo de la flota y gestionar eficientemente sus recursos energéticos constituyen desafíos relevantes para lograr operaciones sostenibles y económicamente viables.

La comuna de Colina, ubicada al norte de Santiago de Chile, presenta características geográficas y logísticas particulares, tales como una distribución dispersa de zonas urbanas, semiurbanas y rurales, lo cual incrementa la complejidad de las operaciones de entrega. Actualmente, la mayoría de las entregas en la comuna se realiza mediante transporte terrestre tradicional, enfrentando limitaciones operativas, altos costos y dificultades para acceder a zonas remotas. Por tanto, la implementación de drones para operaciones logísticas en Colina surge como una oportunidad para mejorar la eficiencia del servicio y reducir el impacto ambiental.

El objetivo general del presente proyecto es determinar el tamaño óptimo de una flota de drones para operaciones logísticas en la comuna de Colina, Santiago, mediante el desarrollo y aplicación de un modelo matemático de optimización. Los objetivos específicos incluyen la definición del área de operación, la estimación y caracterización de la demanda, la selección técnica de drones adecuados, la formulación e implementación de un modelo MILP y la realización de un análisis de sensibilidad sobre parámetros críticos.

La solución propuesta consiste en la formulación de un modelo matemático exacto, complementado por simulaciones y experimentos computacionales, con la incorporación estratégica de baterías adicionales como recurso clave para reducir el número de drones necesarios.

El trabajo se desarrolla en el contexto de la carrera de Ingeniería Civil en Informática y Telecomunicaciones de la Universidad Finis Terrae, en colaboración con información técnica

de fabricantes de drones y datos oficiales del Instituto Nacional de Estadísticas (INE), asegurando así la pertinencia y aplicabilidad del estudio.

El documento se encuentra estructurado en ocho capítulos. El primero presenta la introducción general al problema; el segundo desarrolla el marco teórico y la formulación matemática; el tercero expone la metodología aplicada; el cuarto detalla la selección de drones y la evaluación económica; el quinto desarrollo e implementación del modelo; el sexto describe el desarrollo experimental; el séptimo presenta los resultados y análisis; y el octavo expone las conclusiones y trabajos futuros.

1.1. Situación problema

La incorporación de drones en operaciones logísticas se ha convertido en una solución innovadora capaz de resolver desafíos importantes como la reducción en los tiempos de entrega, la ampliación del alcance a zonas de difícil acceso y la disminución general de los costos operativos. Sin embargo, la implementación efectiva de esta tecnología requiere enfrentar desafíos técnicos significativos, siendo uno de los más críticos el dimensionamiento óptimo de la flota de drones necesaria para cumplir eficientemente con la demanda estimada, lo cual implica considerar factores claves como la autonomía energética, la capacidad operativa de los drones y los tiempos requeridos para recarga.

La comuna de Colina, ubicada en Santiago, presenta características geográficas y logísticas específicas, destacando por su diversidad territorial y distribución dispersa de puntos de interés. Estas particularidades generan la necesidad urgente de desarrollar metodologías que permitan calcular, de forma precisa y eficiente, el número óptimo de drones para satisfacer completamente la demanda logística local. Actualmente, no existe un modelo estándar adaptado específicamente a las condiciones operativas y geográficas de esta comuna, lo que resalta la pertinencia de este estudio.

Resolver esta problemática resulta crucial, ya que permite no sólo optimizar recursos económicos y técnicos, sino también generar una operación más sostenible ambientalmente. Determinar correctamente el tamaño óptimo de la flota minimiza la cantidad de drones requeridos, reduce costos asociados al mantenimiento y operación, optimiza el uso de baterías adicionales como recursos estratégicos y garantiza que los drones operen dentro de

sus límites de autonomía energética. Por tanto, abordar esta problemática resulta indispensable para mejorar la eficiencia operativa y promover una logística más sostenible y económica, contribuyendo al desarrollo tecnológico y social en la comuna de Colina.

1.2. Solución propuesta

La solución planteada en este estudio consiste en la formulación e implementación de un modelo matemático exacto basado en la Programación Lineal Entera Mixta (MILP), diseñado específicamente para determinar el tamaño óptimo de una flota de drones en operaciones logísticas dentro de la comuna de Colina, Santiago. Este modelo tiene como objetivo principal minimizar la cantidad total de drones requeridos para cubrir completamente la demanda de entregas, optimizando simultáneamente tiempos operacionales y recursos energéticos.

La metodología propuesta considera la incorporación estratégica de baterías adicionales, permitiendo aumentar la autonomía operativa de los drones y reducir significativamente el tamaño necesario de la flota. De esta manera, el modelo asigna eficientemente cada cliente a un dron específico, garantizando el cumplimiento de restricciones técnicas esenciales, tales como autonomía energética, tiempos máximos de vuelo permitidos, tiempos de recarga, y distancias entre el centro de operación y los puntos de entrega.

El modelo propuesto es implementado computacionalmente utilizando la biblioteca PuLP de Python, que permite simular diversos escenarios operativos. Adicionalmente, se realiza un análisis de sensibilidad sobre parámetros críticos, tales como la autonomía energética y el número máximo permitido de baterías adicionales por dron, para asegurar que la solución propuesta fuera robusta y adaptable ante cambios en las condiciones operativas. Como futura extensión, se propone complementar esta solución exacta con la implementación de técnicas heurísticas avanzadas, particularmente el método GRASP (Greedy Randomized Adaptive Search Procedure), que facilita el tratamiento de escenarios más complejos, con mayores cantidades de clientes y restricciones operativas más exigentes, mejorando significativamente el tiempo computacional requerido para obtener soluciones cercanas al óptimo.

1.3. Objetivo general

Determinar el tamaño óptimo de una flota de drones destinada a operaciones logísticas en la comuna de Colina, Santiago, mediante técnicas de optimización matemática y simulaciones computacionales.

1.4. Objetivos específicos

Se establecen una serie de objetivos específicos que orientan el desarrollo e implementación del proyecto. Estos objetivos permiten estructurar el análisis y la solución del problema logístico mediante drones, asegurando una planificación detallada del área de operación, la caracterización de la demanda, la selección adecuada de los modelos de drones y la optimización de los recursos disponibles a través de modelos matemáticos. De este modo, se garantiza la eficiencia y viabilidad técnica y operativa del sistema de entrega mediante drones en la comuna de Colina.

- Definir el área específica de operación logística para drones en la comuna de Colina, Santiago, utilizando coordenadas reales obtenidas mediante Google Earth.
- Estimar y caracterizar la demanda esperada de servicios de entrega por drones.
- Seleccionar y evaluar técnicamente el o los modelos de drones más adecuados para satisfacer la demanda identificada, considerando factores como autonomía energética, velocidad, capacidad de carga y costo operativo.
- Formular e implementar un modelo matemático basado en Programación Lineal Entera Mixta (MILP) para determinar el número óptimo de drones, la distribución eficiente de rutas y la gestión estratégica de baterías adicionales.
- Analizar el impacto del uso de baterías adicionales como estrategia para reducir el número total de drones requeridos por la flota.
- Realizar un análisis de sensibilidad que permita evaluar cómo varían los resultados obtenidos al modificar parámetros clave del modelo, tales como la autonomía energética, el número máximo de baterías adicionales permitidas y la ubicación del centro de operación.

1.5 Alcances y limitaciones

En esta sección se presentan los límites operativos y metodológicos definidos para el desarrollo del presente estudio, especificando claramente qué aspectos han sido abordados y cuáles quedan excluidos, para facilitar la comprensión del alcance y utilidad práctica de los resultados obtenidos.

1.5.1 Alcances del proyecto

El presente estudio se concentra específicamente en determinar el tamaño óptimo de una flota de drones para realizar operaciones logísticas dentro de la comuna de Colina, Santiago, considerando únicamente variables técnicas, operativas y geográficas relevantes al contexto del estudio. En particular, el alcance del trabajo considera:

- Definición del área específica de operación logística para drones mediante coordenadas geográficas reales.
- Selección técnica de drones basada en criterios operativos.
- Implementación del modelo matemático exacto MILP.
- Análisis comparativo y de sensibilidad sobre parámetros críticos.

1.5.2 Limitaciones del proyecto

- No considera aspectos regulatorios ni legales.
- No incorpora variabilidad dinámica de la demanda.
- El modelo MILP presenta limitaciones para escalabilidad en casos más complejos.

1.6 Estado del arte

En esta sección se presentan los principales estudios, avances y enfoques recientes realizados sobre el dimensionamiento óptimo de flotas de drones y su aplicación a la logística de entregas, especialmente en operaciones de última milla. El propósito es identificar metodologías utilizadas por otros investigadores, destacando los principales resultados obtenidos y cómo estos pueden contribuir al desarrollo del presente trabajo.

Diversos estudios recientes han explorado la aplicación de drones en el ámbito logístico para la distribución de mercancías. Troudi et al. (2018) proponen un modelo basado en Programación Lineal Entera Mixta (MILP) para la optimización de flotas de drones, enfatizando la importancia de factores críticos como autonomía energética, tiempo de vuelo y restricciones operativas específicas. Asimismo, Dorling et al. (2017) plantean algoritmos heurísticos avanzados para optimizar rutas de drones, destacando la relevancia de métodos aproximados cuando el número de clientes es considerablemente alto.

En relación con métodos heurísticos, estudios recientes han aplicado con éxito procedimientos adaptativos basados en técnicas como GRASP (Greedy Randomized Adaptive Search Procedure), destacando su capacidad para abordar escenarios complejos con tiempos computacionales reducidos y soluciones cercanas al óptimo (Festa & Resende, 2019).

Por otro lado, estudios locales relacionados al contexto chileno indican que, aunque aún incipientes, existen diversas iniciativas que exploran la factibilidad y eficiencia del uso de drones en diferentes comunas del país, resaltando especialmente desafíos relacionados con aspectos técnicos, energéticos y regulatorios (Clara et al., 2020).

La literatura existente evidencia claramente la utilidad de combinar métodos exactos, como MILP, con heurísticas adaptativas como GRASP, lo que sugiere la idoneidad de esta estrategia para el presente estudio. Sin embargo, también subraya la importancia de realizar adaptaciones específicas según condiciones geográficas, operativas y regulatorias propias del contexto local, aspecto central abordado en este trabajo.

1.7 Situación actual

En esta sección se describe el contexto operativo actual en la comuna de Colina, identificando las características geográficas, logísticas y tecnológicas que influyen directamente en el dimensionamiento y operación de una flota de drones para actividades de entrega.

La comuna de Colina, ubicada al norte de Santiago, presenta particularidades que representan importantes desafíos logísticos debido a su extensión territorial de

aproximadamente 970 km² y una población en constante crecimiento, que actualmente supera los 180.000 habitantes. Su diversidad geográfica incluye zonas urbanas, semiurbanas y rurales, generando demandas de distribución variadas que requieren soluciones logísticas eficientes y adaptativas.

Actualmente, la mayoría de las entregas en Colina se realizan mediante transporte terrestre tradicional, principalmente vehículos livianos, camiones pequeños y motocicletas. Estos métodos enfrentan diversos problemas operativos, tales como tiempos prolongados de desplazamiento debido al tráfico vehicular, dificultades para acceder a zonas rurales o de difícil tránsito, y costos operativos elevados relacionados con combustible y mantenimiento vehicular.

Adicionalmente, la infraestructura vial presenta ciertas limitaciones, particularmente en sectores alejados del núcleo urbano, lo que incrementa la necesidad de alternativas tecnológicas como los drones. Esta tecnología ofrece ventajas significativas como la reducción del tiempo de entrega, ahorro en costos operativos y una mejora en la accesibilidad a zonas remotas, aspectos críticos para aumentar la eficiencia y sostenibilidad en la logística local.

En términos tecnológicos, aunque existen diversas iniciativas y propuestas para incorporar drones en la logística local, hasta la fecha no se han implementado sistemas operativos de distribución a escala real. Esto se debe principalmente a incertidumbres relacionadas con el tamaño óptimo de la flota, las limitaciones técnicas actuales de los equipos disponibles y la ausencia de metodologías adecuadas para planificar rutas eficientes adaptadas al contexto local.

Por tanto, la situación actual resalta la necesidad urgente de desarrollar estudios técnicos específicos como el presente, que permitan evaluar y planificar adecuadamente la incorporación de drones en la cadena logística de Colina.

1.8 Disponibilidad de la información

En esta sección se describe el origen, disponibilidad y características de la información utilizada para el desarrollo del presente estudio, identificando las fuentes, los datos recopilados y la forma en que estos han sido tratados y aplicados en la investigación.

La información geográfica utilizada en este trabajo proviene principalmente de datos abiertos y herramientas digitales ampliamente disponibles, destacando especialmente el uso de **Google Earth**, desde donde se obtuvieron coordenadas reales para definir claramente las áreas operativas y los puntos específicos de entrega en la comuna de Colina.

Los datos técnicos referentes a las características operativas de los drones (autonomía, velocidad, tiempos de carga, capacidad de baterías adicionales y costos) fueron recopilados directamente desde catálogos técnicos, especificaciones proporcionadas por fabricantes y distribuidores autorizados. Además, esta información es complementada y contrastada con estudios similares publicados en revistas técnicas especializadas.

En cuanto a la demanda logística estimada para la comuna de Colina, se utiliza información proveniente de estudios locales, datos de crecimiento demográfico entregados por el Instituto Nacional de Estadísticas (INE), e información adicional proveniente de investigaciones recientes sobre patrones de consumo y necesidades logísticas locales.

Finalmente, la información relativa a restricciones operativas específicas (autonomía máxima de los drones, tiempos de operación permitidos y límites técnicos relacionados) ha sido definida en función de la revisión bibliográfica y los estudios técnicos previamente mencionados, garantizando su relevancia y aplicabilidad directa en la formulación del modelo matemático desarrollado.

La adecuada disponibilidad y tratamiento de esta información ha resultado fundamental para asegurar la precisión, validez y representatividad de los resultados alcanzados en este estudio.

1.9. Situación actual del mercado de drones comerciales para operaciones logísticas

El análisis del mercado actual evidencia que la disponibilidad de drones comerciales diseñados específicamente para operaciones logísticas de reparto es limitada. Si bien existen modelos avanzados como el Wingcopter 198, el DJI Matrice 300 RTK o el Workhorse HorseFly, estos equipos presentan un costo elevado y están orientados a aplicaciones profesionales de gran escala. En cambio, drones más accesibles económicamente no cumplen con las características de autonomía, capacidad de carga y alcance necesarias para operaciones logísticas eficientes y seguras.

Por otro lado, las principales compañías tecnológicas y logísticas a nivel mundial, tales como Amazon, iFood en Brasil y Speedbird Aero, no adquieren drones comerciales disponibles en el mercado para sus operaciones de entrega. En su lugar, estas empresas han optado por el desarrollo de modelos propios o adaptaciones específicas a través de alianzas estratégicas o departamentos internos de investigación y desarrollo. Esta práctica les permite contar con vehículos aéreos no tripulados que se ajustan a sus necesidades operacionales particulares, cumpliendo con normativas regulatorias locales y que incorporan tecnología personalizada en términos de autonomía, navegación y gestión de flotas (Infobae, 2023).

En el caso de Brasil, empresas como Speedbird Aero han logrado obtener las primeras autorizaciones regulatorias para operar drones en entregas comerciales, desarrollando sus propios modelos como el DLV-1 NEO, capaces de transportar cargas en entornos urbanos y rurales (DPL News, 2022). Asimismo, compañías como iFood han implementado drones como complemento a sus operaciones logísticas tradicionales, fortaleciendo su posicionamiento en el mercado mediante el uso de tecnologías innovadoras (El Universo, 2020).

Cabe destacar que estos drones no se encuentran disponibles para la venta pública y sus valores de mercado no son divulgados. La mayoría de las operaciones con drones de entrega se realizan bajo proyectos piloto o programas experimentales, con autorizaciones regulatorias específicas que restringen el uso masivo y comercial abierto. En este contexto, Brasil ha emergido como un polo tecnológico destacado en América Latina, con empresas como

XMrobots, que lideran la fabricación y desarrollo de drones para aplicaciones especializadas, aunque sin comercializar modelos de reparto para el público general (XMrobots, 2022).

Como resultado, las empresas que deseen incursionar en la logística aérea mediante drones enfrentan una doble limitación: por un lado, la escasa disponibilidad de equipos comerciales con las características necesarias y, por otro, los altos costos asociados a los pocos modelos disponibles. Esto conduce a que, para iniciar operaciones de reparto con drones, las compañías deban optar por invertir en drones de alto costo diseñados para aplicaciones industriales o bien desarrollar sus propias soluciones tecnológicas en colaboración con fabricantes especializados.

Esta situación refleja la inmadurez del mercado comercial de drones para delivery, que aún se encuentra en fase de consolidación, y evidencia la necesidad de políticas de innovación, apoyo a la investigación y marcos regulatorios que faciliten la expansión de este tipo de soluciones logísticas a mayor escala.

CAPÍTULO 2: MARCO TEÓRICO

El marco teórico que sustenta este estudio se fundamenta principalmente en los conceptos relacionados con la optimización matemática aplicada a la logística, la operación técnica de drones y las herramientas de optimización utilizadas. A continuación, se presentan las bases teóricas esenciales del proyecto:

2.1 Optimización matemática

La optimización matemática consiste en determinar la mejor solución posible a un problema definido mediante restricciones y objetivos específicos (Taha, 2017). En particular, este proyecto aplica la **Programación Lineal Entera Mixta (MILP)**, técnica matemática que permite resolver problemas complejos, en los cuales algunas variables son enteras y otras continuas, permitiendo modelar situaciones reales con precisión (Hillier & Lieberman, 2021). Esta metodología resulta particularmente efectiva para dimensionar flotas logísticas debido a su capacidad de incorporar múltiples restricciones operativas (autonomía, tiempos de carga distancias máximas recorridas, entre otros).

2.2 Problemas de ruteo y dimensionamiento de flotas

Los problemas de ruteo (Vehicle Routing Problem, VRP) consisten en definir las rutas óptimas para una flota de vehículos, minimizando costos operativos y tiempos totales de recorrido mientras se atienden puntos específicos de demanda (Dantzig & Ramser, 1959). En el contexto actual, este concepto se extiende al uso de drones, conocidos como **Drone Routing Problems (DRP)**. La incorporación de restricciones específicas como la autonomía energética, tiempo de recarga, limitaciones en la capacidad de carga y regulación operativa resulta esencial para modelar adecuadamente estas situaciones (Dorling et al., 2017; Troudi et al., 2018).

2.3 Tecnología y operación de drones

Un drone, o vehículo aéreo no tripulado (VANT), es una aeronave que se opera de manera remota o autónoma, permitiendo realizar tareas que van desde vigilancia y reconocimiento hasta logística y entregas rápidas (Custers, 2016). Los drones utilizados para logística

habitualmente tienen limitaciones en su autonomía energética, velocidad operativa y capacidad de carga, aspectos técnicos fundamentales que afectan su dimensionamiento y operación logística (Floreano & Wood, 2015). En este proyecto, se utiliza información técnica real proporcionada por fabricantes, lo que garantiza la validez técnica y operativa del estudio realizado.

2.4 Gestión energética de drones

La gestión energética es una limitante crítica en la operación efectiva de drones, ya que la duración limitada de sus baterías condiciona directamente su autonomía y tiempo operativo máximo. Por esta razón, el uso de baterías intercambiables ha emergido como una solución práctica para extender significativamente la autonomía operativa (Guerrero, 2020). En este estudio se explora específicamente el uso estratégico de baterías adicionales para minimizar el tamaño de la flota requerida, logrando un equilibrio entre autonomía, número de drones y costos operativos asociados.

2.5 Metaheurísticas aplicadas a la logística

Las metaheurísticas son técnicas heurísticas avanzadas para resolver problemas complejos que resultan difíciles de abordar mediante métodos exactos debido a limitaciones computacionales. Una de estas técnicas es **GRASP (Greedy Randomized Adaptive Search Procedure)**, que combina estrategias aleatorias y adaptativas para obtener soluciones cercanas al óptimo en tiempos razonables (Festa & Resende, 2019). Aunque este proyecto inicialmente utiliza un enfoque exacto MILP, se anticipa la futura implementación de GRASP para mejorar la escalabilidad del modelo ante situaciones más complejas con mayores cantidades de clientes.

2.6 Formulación matemática del modelo propuesto

La formulación matemática propuesta corresponde a un problema avanzado del tipo Drone Routing Problem (DRP), considerando baterías intercambiables y múltiples retornos al centro de operación para recarga. Este modelo está basado en Programación Lineal Entera Mixta (MILP) y considera restricciones realistas relacionadas con la autonomía energética, tiempos operativos y limitaciones logísticas.

2.6.1 Conjuntos

- $N = \{0, 1, \dots, n\}$: conjunto de nodos, donde el nodo 0 representa el depósito, y los nodos 1, ..., n los clientes.
- $K = \{1, 2, \dots, m\}$: conjunto potencial de drones disponibles.

2.6.2 Parámetros

- d_{ij} : distancia (en km) entre los nodos i y j .
- v : velocidad promedio del dron en km/min.
- T_{rec} : tiempo fijo de recolección o entrega en cada cliente (minutos).
- $T_{Bateria}$: autonomía máxima de una batería (en minutos).
- B_{max} : cantidad máxima de baterías adicionales permitidas por dron.
- T_{max} : Autonomía máxima de una batería.

2.6.3 Variables de decisión

- x_{ijk} : variable binaria que toma el valor 1 si el dron k viaja del nodo i al nodo j , y 0 en caso contrario.
- y_k : variable binaria que toma valor 1 si el dron k es utilizado en la solución, y 0 si no lo es.
- t_k : tiempo total operativo del dron k (en minutos).
- b_k : número de baterías adicionales utilizadas por el dron k .
- z_k : variable entera que representa el número total de segmentos o viajes realizados por el dron k , definida como $z_k = (b_k + 1) * y_k$.
- u_{jk} : variable auxiliar (MTZ) para eliminación de subtours, indicando el orden del nodo j en la ruta del dron k .

2.7 Función objetivo

La función objetivo busca minimizar el tiempo total operativo, el número de drones utilizados y el número de baterías adicionales requeridas, ponderado según coeficientes α , β , γ :

$$\text{Minimizar } Z = \alpha * \sum_{k \in K} t_k + \beta * \sum_{k \in K} y_k + \gamma * \sum_{k \in K} b_k$$

2.8 Restricciones del modelo

A continuación, se describen en detalle las restricciones del modelo matemático propuesto, las cuales representan limitaciones reales y específicas que condicionan la solución al problema planteado. Estas restricciones reflejan aspectos operativos esenciales, como la cobertura total de clientes, autonomía energética de los drones, uso estratégico de baterías adicionales y cumplimiento de condiciones técnicas, garantizando así la viabilidad práctica de las soluciones obtenidas.

2.8.1 Visita única a cada cliente

Esta restricción asegura formalmente que cada cliente sea visitado exactamente una vez por un único dron, evitando así entregas duplicadas o clientes sin atender.

$$\sum_{k \in K} \sum_{i \in N, i \neq j} x_{ijk} = 1, \quad \forall j \in N \setminus \{0\}$$

2.8.2 Conservación del flujo

Mediante esta restricción, se garantiza que, para cada dron, la cantidad de rutas que entran a un cliente específico sea igual a la cantidad de rutas que salen de ese cliente. Esto asegura la continuidad lógica y la coherencia operativa de cada ruta asignada a un dron.

$$\sum_{i \in N, i \neq j} x_{ijk} - \sum_{m \in N, m \neq j} x_{jmk} = 0, \quad \forall j \in N \setminus \{0\}, \forall k \in K$$

2.8.3 Rutas comienzan y terminan en el depósito

Esta condición establece formalmente que cada dron debe comenzar y finalizar cada segmento de ruta en el depósito. La variable auxiliar z_k controla cuántos viajes o segmentos puede realizar cada dron, en función del número de baterías adicionales que utiliza.

$$\sum_{j \in N \setminus \{0\}} x_{0jk} = z_k, \quad \forall k \in K$$
$$\sum_{j \in N \setminus \{0\}} x_{j0k} = z_k, \quad \forall k \in K$$

Donde:

$$z_k = (b_k + 1) * y_k$$

2.8.4 Eliminación de subtours (MTZ)

Esta restricción formal es esencial para evitar la formación de subtours o ciclos cerrados que no incluyan al depósito. Mediante el uso de las variables auxiliares u_{ik} , se garantiza que todas las rutas formadas sean completas y que comiencen y finalicen en el depósito.

$$u_{ik} - u_{jk} + n * x_{ijk} \leq n - 1, \quad \forall i, j \in N \setminus \{0\}, i \neq j, \quad \forall k \in K$$

2.8.5 Autonomía energética de los drones

Esta restricción establece formalmente un límite superior al tiempo de operación total de cada dron, en función de la autonomía máxima de cada batería y la cantidad adicional de baterías que emplea cada dron. El factor 0.9 introduce un margen de seguridad para evitar situaciones de riesgo operativo por agotamiento energético.

$$t_k \leq 0.9 * t_{\max} * (b_k + 1), \quad \forall k \in K$$

2.8.6 Cálculo del tiempo total de operación por dron

Esta ecuación determina formalmente el tiempo total necesario para que cada dron complete todas sus entregas asignadas, considerando tanto el tiempo de viaje entre nodos (calculado mediante la distancia y la velocidad operativa) como el tiempo fijo de atención en cada cliente.

$$t_k = \sum_{i \in N} \sum_{j \in N, j \neq i} \left(\frac{d_{ij}}{\left(\frac{v}{60}\right)} + t_{rec} \right) x_{ijk}, \quad \forall k \in K$$

2.9 Selección y Evaluación de Drones

La selección adecuada de drones es fundamental en la planificación de flotas logísticas, ya que impacta directamente en la eficiencia operativa y la viabilidad del servicio. Para realizar una elección informada, es esencial evaluar diversos aspectos técnicos y operativos clave. A continuación, se presentan dos modelos destacados en el ámbito de la logística, junto con sus especificaciones técnicas:

2.9.1 Wingcopter 198

El Wingcopter 198 es un dron de fabricación alemana diseñado para entregas de última milla y misiones de mapeo, levantamiento e inspección. Sus características principales son:

- **Diseño y características de vuelo:**
 - **Tipo:** eVTOL (despegue y aterrizaje vertical eléctrico) con alas fijas.
 - **Tecnología de rotor basculante:** Permite transiciones suaves entre despegue/aterrizaje vertical y vuelo horizontal eficiente.
 - **Resistencia al viento:** Capaz de operar en condiciones climáticas adversas, soportando vientos promedio de 15 m/s y ráfagas de hasta 20 m/s.
- **Capacidad de carga y alcance:**
 - **Carga útil máxima:** Hasta 6 kg en total; con la función de triple entrega, puede transportar hasta 5 kg.
 - **Alcance de vuelo:**
 - 75 km con una carga de 5 kg.
 - 85 km con una carga de 3 kg.
 - 95 km con una carga de 1 kg.
 - 110 km sin carga útil.
- **Velocidad y altitud:**
 - **Velocidad de crucero predeterminada:** 100 km/h.
 - **Velocidad máxima:** 144 km/h.

- **Techo de servicio:** Hasta 5,000 metros sobre el nivel del mar.
- **Sistemas de seguridad y redundancia:**
 - **Arquitectura redundante:** Equipado con ocho motores, ocho controladores electrónicos de velocidad (ESC) y dos baterías para garantizar la seguridad operativa incluso en caso de fallo en el sistema de propulsión.
 - **Sistemas de control de vuelo redundantes:** Incluye sensores de velocidad del aire duales y sistemas de posicionamiento y navegación duplicados para asegurar un control ininterrumpido.
 - **Sistemas avanzados de detección de riesgos:** Cuenta con ADS-B in, FLARM y Remote ID, además de un sistema de conciencia óptica que detecta obstáculos, con una IA integrada que evalúa riesgos en tiempo real y, de ser necesario, inicia maniobras evasivas.
- **Eficiencia operativa:**
 - **Sistema de triple entrega:** Permite la entrega de hasta tres paquetes separados a múltiples ubicaciones en un solo vuelo, optimizando la eficiencia de la ruta y reduciendo costos de entrega.
 - **Gestión de flotas:** Un solo operador puede controlar y monitorear hasta 10 drones Wingcopter 198 simultáneamente, gracias al software de estación de control intuitivo que facilita la planificación de vuelos y misiones.
 - **Mantenimiento avanzado:** Los datos de rendimiento de los componentes se cargan automáticamente en una base de datos segura para una gestión eficiente del mantenimiento, evitando tiempos de inactividad no planificados y mejorando la fiabilidad de la flota.
- **Autonomía y facilidad de uso:**
 - **Alto nivel de autonomía:** Diseñado para vuelos y entregas autónomas de nivel 4, reduciendo la necesidad de interacción humana y permitiendo una configuración y capacitación rápidas, así como operaciones eficientes y estables.

- **Planificación de misiones rápida y sencilla:** El software de la estación de control es un sistema para la planificación de vuelos y misiones, control de aeronaves y monitoreo operativo, específicamente diseñado para mejorar el flujo de trabajo del piloto al mando y del proveedor logístico.
- **Baterías inteligentes de intercambio rápido:** Las baterías inteligentes que alimentan al Wingcopter 198 están diseñadas para maximizar el tiempo en el aire y garantizar una larga vida útil de la batería, optimizadas para intercambios rápidos y manejo sencillo en tierra.

Estas especificaciones hacen del Wingcopter 198 una opción versátil y eficiente para operaciones logísticas en diversas condiciones ambientales.

2.9.2 Zipline Platform 1

Zipline es una empresa destacada en la entrega de suministros médicos mediante drones automatizados, especialmente en regiones de difícil acceso. Su modelo Platform 1 presenta las siguientes especificaciones:

- **Diseño y características de vuelo:**
 - **Tipo:** Dron de ala fija optimizado para entregas de largo alcance.
 - **Altitud de vuelo:** Opera a aproximadamente 90 metros (300 pies) sobre el nivel del suelo.
- **Capacidad de carga y alcance:**
 - **Carga útil máxima:** Hasta 1,8 kg.
 - **Radio de servicio:** 16 km (10 millas) por vuelo, con capacidad para vuelos de ida y vuelta de hasta 38 km (24 millas).
- **Velocidad y eficiencia:**
 - **Velocidad de crucero:** Diseñada para optimizar la eficiencia energética y garantizar entregas rápidas dentro de su radio de servicio.
- **Sistemas de seguridad y precisión:**
 - **Sistema de entrega de precisión:** Utiliza un mecanismo de descenso controlado para entregar los paquetes de forma precisa en el destino final, garantizando la integridad de la carga y la seguridad en la entrega.

- **Diseño robusto:** Construido para operar en diversas condiciones climáticas y geográficas, asegurando la fiabilidad en entornos desafiantes.

La robustez y eficiencia del Zipline Platform 1 lo convierten en una opción ideal para entregas rápidas y seguras en áreas remotas.

CAPÍTULO 3: METODOLOGÍA.

En esta sección se describen detalladamente los pasos, procedimientos, métodos y herramientas utilizadas para el logro de los objetivos definidos en la investigación. La metodología del presente estudio se divide en cuatro etapas principales, las cuales se detallan a continuación.

3.1 Definición del área de operación y selección del centro logístico

En esta primera etapa se define con precisión el área de operación logística mediante la obtención de coordenadas geográficas reales, extraídas desde la herramienta Google Earth, para la comuna de Colina. Se determina puntos específicos correspondientes a potenciales clientes y se establece un depósito central (o centro de operaciones) desde el cual los drones iniciarían y finalizarían sus rutas. La selección del lugar del centro operativo consideró criterios como proximidad a clientes, accesibilidad geográfica y adecuación logística para optimizar rutas.

3.2 Estimación y caracterización de la demanda

La demanda es caracterizada utilizando datos poblacionales y patrones de consumo obtenidos a través de fuentes oficiales (Instituto Nacional de Estadísticas, INE) y análisis de mercado local. Posteriormente, se definen 20 puntos específicos de entrega en la comuna de Colina, considerando distancias promedio realistas y viables para operaciones logísticas mediante drones.

3.3 Selección técnica de drones

La selección técnica de drones se efectúa mediante una revisión exhaustiva de modelos comerciales disponibles, analizando específicamente factores claves como:

- Autonomía energética (tiempo máximo de vuelo).
- Velocidad promedio operativa.
- Capacidad de carga o peso máximo permitido.
- Tiempo de recarga de baterías.
- Costos asociados a operación y mantenimiento.

La información técnica fue obtenida desde catálogos oficiales de fabricantes de drones comerciales (DJI, Parrot, Skydio, entre otros) y literatura técnica especializada. Se aplica un análisis comparativo multicriterio que permite seleccionar los drones que mejor cumpla con los requerimientos específicos del proyecto.

3.4. Formulación e implementación del modelo matemático

La siguiente etapa consiste en formular un modelo matemático utilizando la metodología de Programación Lineal Entera Mixta (MILP), con el objetivo principal de minimizar la cantidad de drones utilizados, optimizar el uso de baterías adicionales y asignar rutas eficientes. Para ello, se siguen los siguientes pasos específicos:

- Definición formal del problema (identificación de variables, parámetros y restricciones del modelo).
- Implementación computacional utilizando la biblioteca PuLP en lenguaje Python.
- Resolución del modelo mediante un solver específico de optimización lineal entera (CBC), estableciendo límites de tiempo para la obtención de soluciones.

En este modelo se incluyeron restricciones operativas claves tales como autonomía energética máxima, número permitido de baterías adicionales por dron y la obligatoriedad de visitar a todos los clientes exactamente una vez.

- Las variables de decisión incluyeron variables binarias (uso del dron, rutas asignadas), variables enteras (cantidad de baterías adicionales) y variables continuas (tiempos operativos).
- La función objetivo considera simultáneamente tiempos operativos, cantidad de drones y número de baterías adicionales, cada una ponderada mediante coeficientes estratégicos (alfa, beta y gamma).

3.5. Análisis de resultados y sensibilidad

Finalmente, se realiza un análisis detallado y comparativo de los resultados obtenidos en distintos escenarios, evaluando especialmente el impacto que tiene la incorporación de baterías adicionales sobre el tamaño óptimo de la flota. Además, se ejecuta un análisis de

sensibilidad para explorar cómo varía los resultados del modelo al modificar parámetros claves tales como:

- Autonomía energética de las baterías.
- Número máximo permitido de baterías adicionales.
- Ubicación específica del centro logístico.
- Velocidad operacional promedio del dron.

Esto permite evaluar la robustez de la solución propuesta frente a cambios potenciales en las condiciones operativas, así como su aplicabilidad práctica.

CAPÍTULO 4: TIPOS DE DRONES Y ESTIMACIÓN ECONÓMICA

En este capítulo, se analizan diversos modelos de drones comerciales adecuados para operaciones logísticas, con énfasis en sus características técnicas y económicas. Se incluye una comparación detallada de los modelos considerados, seguida de una estimación económica completa del proyecto, abarcando tanto la inversión inicial como los costos operativos proyectados para un horizonte de cinco años.

4.1. Comparación de modelos de drones comerciales

A continuación, la Tabla 1 presenta una comparativa que resume las especificaciones técnicas y costos estimados de diversos drones comerciales empleados en logística:

Modelo de dron	Precio estimado (USD)	Autonomía de vuelo (min)	Capacidad de carga (kg)	Distancia máxima de operación (km)	Velocidad máxima (km/h)	Compatibilidad con baterías adicionales
Wingcopter 198	14,000	40	6	~75	150	Sí (usa 2 baterías; intercambiables)
Matternet M2	7,500	20–30	2	20	57.6	Sí (1 batería; diseño de cambio rápido)
DJI Matrice 300 RTK	16,600	hasta 55	2.7	15	82	Sí (2 baterías, hot-swap)
DJI Matrice 600 Pro	12,000	hasta 38	6	5	65	Sí (6 baterías; requiere recarga simultánea)
Workhorse HorseFly	~15,000 – 20,000	45	4.5	16	80	Sí (batería intercambiable)

Tabla 1 Comparación de modelos de drones comerciales

Fuente. Elaboración Propia

Notas:

- Wingcopter 198: Aunque el precio exacto no se ha publicado oficialmente, se estima que oscila alrededor de 14,000 USD por unidad, basándose en las características avanzadas y el posicionamiento en el mercado de drones de carga similares.
- Workhorse HorseFly: No se ha divulgado públicamente el precio exacto de este modelo. Sin embargo, considerando sus especificaciones y el mercado objetivo, se estima que su precio se encuentra entre 15,000 y 20,000 USD por unidad.

4.2. Estimación económica del proyecto

Para evaluar la viabilidad económica del proyecto logístico basado en drones, se desarrolló una estimación económica detallada que incluye costos de adquisición, operativos y proyecciones para un horizonte de cinco años.

4.2.1. Costos de adquisición

Considerando una flota inicial de cuatro drones Wingcopter 198 (valor aproximado de 14.000 USD por unidad), junto con 2 baterías adicionales por cada dron, se determinan los siguientes costos iniciales aproximados:

- **Adquisición de drones:** $4 \times 14.000 \text{ USD} = 56.000 \text{ USD}$.
- **Baterías adicionales:** 8 baterías adicionales (aproximadamente 700 USD cada una) = **5600 USD**.
- **Infraestructura básica (estaciones de carga, equipamiento y software):** entre **3,000 y 5,000 USD**.

En consecuencia, la inversión inicial total estimada para la implementación del proyecto se sitúa en torno a los **64,600 a 66,600 USD** para una flota de **cuatro drones** y equipamiento inicial básico.

4.2.2. Costos operativos anuales

Los costos operativos se componen principalmente del mantenimiento, consumo de energía eléctrica para la recarga de baterías y el reemplazo periódico de las mismas:

- **Mantenimiento:** Se estima un costo anual de mantenimiento preventivo y correctivo de aproximadamente 1,500 a 2,100 USD por dron, resultando en alrededor de 6,000 a 8,400 USD al año para cuatro drones en operación regular.
- **Energía eléctrica:** Considerando entre 8 y 12 vuelos diarios para toda la flota y un consumo promedio de 1,5 kWh por vuelo, el costo anual en electricidad se estima entre 438 y 657 USD, siendo este valor bajo respecto al total de costos operativos.

- Gestión y reemplazo de baterías: Dado el ciclo de vida limitado de las baterías de litio (aproximadamente 300-500 ciclos), se estima un reemplazo anual de aproximadamente cinco a siete baterías, generando costos adicionales de alrededor de 4,000 a 5,600 USD al año.

Sumando estos conceptos, el costo operativo anual total se sitúa entre 10,438 y 14,657 USD aproximadamente. A estos gastos podrían sumarse otros costos menores, tales como seguros, licencias operativas y capacitación del personal.

4.2.3. Proyección de costos a cinco años

Para una evaluación integral del proyecto, se estiman los costos operativos acumulados en un periodo de cinco años, incluyendo la amortización de la inversión inicial y eventuales renovaciones tecnológicas o reemplazos mayores en el año final:

- Amortización de la inversión inicial (64,600 a 66,600 USD): aproximadamente 12,920 a 13,320 USD anuales.
- Costos operativos totales (cinco años): entre 52,190 y 73,285 USD acumulados.
- Renovación tecnológica o actualización parcial de la flota en el quinto año: se estima prudente reservar aproximadamente 12,000 a 15,000 USD adicionales.

En total, se proyecta que el costo acumulado para operar una flota de cuatro drones durante cinco años se ubica en el rango de 128,790 a 154,885 USD. Esta proyección permite estimar un costo promedio anual cercano a los 25,758 a 30,977 USD.

4.2.4. Viabilidad económica general

La evaluación económica muestra que el proyecto es potencialmente viable, especialmente si se logran altos niveles de utilización diaria (gran cantidad de entregas). Con una alta frecuencia de entregas diarias, los costos operativos y de adquisición pueden diluirse considerablemente, alcanzando costos unitarios por entrega competitivos frente a métodos logísticos tradicionales.

En términos generales, el uso de drones presenta beneficios adicionales difíciles de cuantificar económicamente, pero importantes para la logística, tales como rapidez, flexibilidad operativa y acceso a zonas de difícil alcance mediante vehículos terrestres. No obstante, la inversión inicial alta y los costos recurrentes en mantenimiento y baterías exigen una planificación cuidadosa y una gestión eficiente de los recursos.

La implementación estratégica de baterías adicionales demuestra ser una decisión clave en la reducción del número total de drones necesarios, confirmando la importancia de este recurso en la optimización económica del proyecto.

CAPÍTULO 5: DESARROLLO E IMPLEMENTACIÓN DEL MODELO

Luego de la formulación matemática detallada en el marco teórico y de la metodología descrita en capítulos anteriores, además de la validación preliminar mediante diversos escenarios experimentales, se realiza la implementación computacional final del modelo propuesto. Dicha implementación se lleva a cabo utilizando el lenguaje de programación Python, en conjunto con la biblioteca PuLP, la cual permite resolver eficazmente problemas de Programación Lineal Entera Mixta (MILP).

En esta sección, se presentan los aspectos relevantes del desarrollo del código final, destacando particularmente los parámetros utilizados, las variables de decisión, las restricciones fundamentales y la función objetivo empleada. Asimismo, se exponen fragmentos claves del código, explicando brevemente cada uno de ellos con el fin de facilitar la comprensión sobre cómo estos elementos computacionales se relacionan con la formulación matemática y las metodologías previamente descritas.

5.1. Entorno computacional utilizado

La implementación final del modelo propuesto se lleva a cabo mediante el lenguaje de programación **Python** (versión 3.x). Este lenguaje es seleccionado debido a su versatilidad, sencillez, y amplia disponibilidad de librerías especializadas para modelar y resolver problemas de optimización complejos.

En particular, se utiliza la biblioteca **PuLP**, ampliamente reconocida para formular y resolver problemas de Programación Lineal Entera Mixta (MILP). Esta librería facilita la definición clara de variables de decisión, restricciones y funciones objetivo, permitiendo utilizar el solver CBC (Coin-or Branch and Cut), que ofrece soluciones precisas en tiempos razonables de ejecución.

Adicionalmente, para el cálculo preciso de las distancias reales entre puntos geográficos (depósito y clientes), se emplea la librería **geopy**, que proporciona cálculos precisos basados en coordenadas geográficas reales.

La ejecución computacional es llevada a cabo en un equipo con las siguientes características técnicas:

- Procesador Intel Core i3-9100F.
- Memoria RAM de 8 GB.
- Tarjeta gráfica NVIDIA GeForce GTX 710 con 1 GB de memoria dedicada.
- Almacenamiento en disco de estado sólido (SSD) de 1,5 TB.

Estas especificaciones permiten una ejecución eficiente y sin inconvenientes del modelo propuesto, logrando tiempos de solución razonables y una respuesta efectiva ante las instancias planteadas.

5.2. Fragmentos clave del código implementado

A continuación, se presentan fragmentos clave del código implementado, los cuales constituyen la base operativa del modelo computacional desarrollado. La selección de estos fragmentos específicos permite ilustrar claramente cómo se materializaron aspectos fundamentales del modelo teórico previamente definido, tales como la asignación de rutas, la optimización del uso de recursos (drones y baterías) y la formulación matemática planteada. Cada fragmento está acompañado por una breve explicación, con el fin de facilitar una mejor comprensión del rol que cumple dentro del modelo computacional global.

5.2.1. Fragmento 1: Definición de parámetros globales y matriz de distancias

El primer fragmento del código (ver Figura 1) corresponde a la definición y configuración inicial de los parámetros globales esenciales para el funcionamiento del modelo. Se especifica claramente la velocidad promedio del dron en kilómetros por hora, el tiempo máximo permitido para la batería (autonomía) y el tiempo que cada dron debe permanecer en cada cliente para efectuar la entrega. Asimismo, se presentan los coeficientes (α , β , γ) empleados en la función objetivo, destinados a ponderar y balancear el tiempo total de operación, el número de drones utilizados y la cantidad de baterías adicionales requeridas durante la operación logística.

```
# Parámetros globales del modelo
velocidad_dron_kmh = 70      # Velocidad promedio del dron (km/h)
tiempo_max_bateria = 45     # Autonomía máxima por batería (minutos)
tiempo_recoleccion = 4      # Tiempo requerido por cada entrega (minutos)
alpha, beta, gamma = 33, 33, 34 # Coeficientes de ponderación de la función objetivo (sujeto a cambios)
```

```

# Función para calcular la matriz de distancias
def calcular_matriz_distancias(deposito, clientes):
    ubicaciones = [deposito] + clientes
    N = len(ubicaciones)
    dist_matrix = [[0]*N for _ in range(N)]
    for i in range(N):
        for j in range(N):
            if i != j:
                dist_matrix[i][j] = geodesic(ubicaciones[i], ubicaciones[j]).km
            else:
                dist_matrix[i][j] = 0
    return dist_matrix

dist_matrix = calcular_matriz_distancias (deposito, clientes)

```

Figura 1. Definición de parámetros globales y matriz de distancias

Fuente. Elaboración Propia

5.2.2. Fragmento 2: Variables de decisión y función objetivo

El fragmento de código implementado que se muestra en la Figura 2 define claramente las variables fundamentales que permiten tomar decisiones dentro del modelo propuesto. La variable binaria $x_{i,j,k}$ indica si el dron k recorre el arco desde el nodo i al nodo j . Por otro lado, la variable binaria y_k establece si un determinado dron es utilizado o no durante el proceso de entrega. La variable continua t_k representa el tiempo total de operación de cada dron, calculado en minutos, mientras que la variable entera b_k determina la cantidad de baterías adicionales que utiliza cada dron durante su operación.

Adicionalmente, se presenta formalmente la función objetivo del modelo, cuya estructura lineal permite minimizar una combinación ponderada entre el tiempo total de operación (α), el número total de drones utilizados (β), y el uso de baterías adicionales (γ). Esta función es clave para balancear adecuadamente la eficiencia operativa, el costo logístico asociado al número de drones requeridos y el impacto del uso adicional de baterías.

```

# Variables binarias para asignación de rutas (arcos)
x = {}
for k in range(num_drones_potenciales):
    for i in nodos:
        for j in nodos:
            if i != j:
                x[(i, j, k)] = pl.LpVariable(f"x_{i}_{j}_k{k}", cat=pl.LpBinary)

# Variables binarias para el uso de drones
y = {}
for k in range(num_drones_potenciales):
    y[k] = pl.LpVariable(f"y_{k}", cat=pl.LpBinary)

# Tiempo total de operación por dron (minutos)
t = {}
for k in range(num_drones_potenciales):
    t[k] = pl.LpVariable(f"t_{k}", lowBound=0, cat=pl.LpContinuous)

# Número de baterías adicionales empleadas por dron
b = {}
for k in range(num_drones_potenciales):
    b[k] = pl.LpVariable(f"b_{k}", lowBound=0, upBound=num_max_baterias, cat=pl.LpInteger)

# Definición de la función objetivo
model += (
    alpha * pl.lpSum(t[k] for k in range(num_drones_potenciales)) +
    beta * pl.lpSum(y[k] for k in range(num_drones_potenciales)) +
    gamma * pl.lpSum(b[k] for k in range(num_drones_potenciales))
), "Funcion_Objetivo"

```

Figura 2. Variables de decisión y función objetivo

Fuente. Elaboración Propia

5.2.3. Fragmento 3: Restricciones esenciales del modelo implementado

Este conjunto de restricciones (ver figura 3) representa las condiciones esenciales para garantizar la factibilidad y eficiencia operativa del modelo propuesto. La primera restricción asegura que cada cliente sea visitado exactamente una vez, evitando duplicaciones u omisiones en la asignación de entregas. La segunda restricción establece claramente que cada dron debe mantener un flujo continuo y coherente, es decir, cada llegada a un cliente implica una posterior salida desde ese mismo cliente, asegurando la continuidad lógica de la ruta.

Por otro lado, la tercera restricción es crucial para controlar la autonomía energética de cada dron. Esta condición limita el tiempo total de operación permitido según la autonomía proporcionada por la batería original y las baterías adicionales disponibles, incluyendo un factor de seguridad del 10% para evitar situaciones críticas durante la operación.

Finalmente, la última restricción asegura que la cantidad total de baterías adicionales utilizadas por toda la flota no exceda el límite global previamente establecido. Esto permite gestionar eficientemente el recurso energético adicional disponible, optimizando así tanto la operación como los costos asociados.

```
# Restricción 1: Cada cliente debe ser visitado exactamente una vez
for j in clientes_idx:
    model += pl.lpSum(x[(i, j, k)] for k in range(num_drones_potenciales) for i in nodos if i != j) == 1,
    f'Asigna_cliente_{j}'

# Restricción 2: Conservación del flujo para cada dron en cada cliente visitado
for k in range(num_drones_potenciales):
    for j in clientes_idx:
        model += (
            pl.lpSum(x[(i, j, k)] for i in nodos if i != j) ==
            pl.lpSum(x[(j, m, k)] for m in nodos if m != j)
        ), f'Flujo_cliente_{j}_dron_{k}'

# Restricción 3: Autonomía energética de los drones (considerando baterías adicionales)
for k in range(num_drones_potenciales):
```

```
model += t[k] <= 0.9 * tiempo_max_bateria * (b[k] + 1), f"Autonomia_dron_{k}"

# Restricción 4: Límite global en el uso total de baterías adicionales
model += pl.lpSum(b[k] for k in range(num_drones_potenciales)) <= num_max_baterias *
num_drones_potenciales, "BateriasGlobales"
```

Figura 3. Restricciones esenciales del modelo implementado

Fuente. Elaboración Propia

5.2.4. Fragmento 4: Ejecución del modelo y obtención de resultados

Este fragmento (ver Figura 4) presenta la ejecución final del modelo de optimización propuesto. Primeramente, se configura el número máximo de baterías adicionales permitido por dron, estableciendo así una condición crítica para la ejecución del modelo. Luego, se utiliza el solver CBC, proporcionado por PuLP, con un tiempo máximo de solución establecido en 300 segundos, asegurando una ejecución eficiente.

Una vez que el modelo es resuelto, se comprueba el estado de la solución. Si la solución es óptima o factible, el programa muestra el valor final alcanzado por la función objetivo, además del número de drones que fueron efectivamente utilizados en el proceso. También se despliega información detallada del desempeño individual de cada dron en términos del tiempo total empleado y el número de baterías adicionales utilizadas.

Adicionalmente, el programa determina y muestra las rutas específicas asignadas a cada dron, señalando claramente la secuencia de clientes atendidos en cada segmento. Esta información resulta particularmente relevante para validar la coherencia y lógica de las rutas generadas por el modelo, garantizando la factibilidad práctica de la solución.

En caso de no encontrar una solución óptima o factible, el programa informa claramente dicha situación, permitiendo identificar fácilmente si es necesario ajustar parámetros o restricciones del modelo.

```

def ejecutar_modelo():
    num_max_baterias = 5 # Número máximo de baterías adicionales permitidas por dron
    model, x, y, t, b, u = construir_modelo_optimo_drones_con_recarga(dist_matrix, num_max_baterias)
    solver = pl.PULP_CBC_CMD(timeLimit=300, msg=1)
    model.solve(solver)

    print("Estado del modelo:", pl.LpStatus[model.status])
    if pl.LpStatus[model.status] in ["Optimal", "Feasible"]:
        print("Valor Objetivo:", pl.value(model.objective))
        num_drones_usados = 0
        for k in range(len(y)):
            if pl.value(y[k]) > 0.5:
                num_drones_usados += 1
                print(f"\n=== Dron {k} ===")
                print(f" Tiempo total de operación: {pl.value(t[k])} min")
                print(f" Baterías adicionales usadas: {pl.value(b[k])}")

        rutas_dron = []
        usados = {(i, j): pl.value(x[(i, j, k)]) for i in range(N_total) for j in range(N_total)
                  if i != j and pl.value(x[(i, j, k)]) > 0.5}

        while True:
            if not any(i == 0 for (i, j) in usados.keys()):
                break
            segmento = []
            nodo_actual = 0
            while True:
                siguiente = None
                for j in range(N_total):
                    if nodo_actual != j and usados.get((nodo_actual, j), 0) > 0.5:
                        siguiente = j
                        segmento.append((nodo_actual, siguiente))
                        del usados[(nodo_actual, j)]
                        break
                if siguiente is None or siguiente == 0:
                    break
                nodo_actual = siguiente
            rutas_dron.append(segmento)

```

```
        if not usados:
            break
        print(" Rutas (segmentos):", rutas_dron)

        print(f"\nNúmero óptimo de drones utilizados: {num_drones_usados}")
    else:
        print("No se encontró solución factible u óptima.")

if __name__ == "__main__":
    ejecutar_modelo()
```

Figura 4. Ejecución del modelo y obtención de resultados

Fuente. Elaboración Propia

CAPÍTULO 6: DESARROLLO EXPERIMENTAL

En la búsqueda de soluciones óptimas y eficientes para la gestión de flotas de drones en escenarios de entrega, este capítulo presenta un análisis comparativo entre dos enfoques metodológicos iniciales: un modelo exacto basado en Programación Lineal Entera Mixta (MILP) y un modelo heurístico simple. Es importante señalar que estos experimentos fueron desarrollados en etapas preliminares del estudio, utilizando versiones simplificadas del modelo, las cuales no contemplaban la totalidad de variables ni restricciones incorporadas en el modelo final detallado en el Capítulo 5.

Ambos modelos fueron evaluados mediante experimentos diseñados para simular condiciones controladas y escenarios con datos reales, proporcionando una perspectiva exploratoria sobre su desempeño en distintas configuraciones operativas. La estructura experimental permite analizar factores clave, como el tiempo total de operación, la distribución de tareas entre drones y el impacto de variables como la cantidad de drones disponibles, la dispersión geográfica de los clientes y diversas restricciones operativas. Este enfoque facilita no sólo la evaluación comparativa de los enfoques propuestos, sino también una comprensión progresiva de las dinámicas involucradas en la optimización de flotas, que posteriormente fundamentaron el desarrollo del modelo definitivo.

6.1. Descripción de los experimentos

Un conjunto de drones realiza reparto saliendo del depósito, vuela para realizar una entrega y vuelve al depósito para otro reparto o bien termina su trabajo. El criterio de optimización es minimizar el tiempo de operación que ocupan los drones en atender a todos los clientes y volver al depósito.

6.1.1. Escenarios simulados

Este experimento se diseña para evaluar el desempeño de los modelos exacto y heurístico simple en un entorno controlado, utilizando datos simulados y aleatorios. Los clientes fueron generados dentro de un área de 10 km de diámetro para el primer escenario y 20 km para el segundo, asegurando una distancia máxima de 1 km entre ellos. En ambos casos, se trabajó con un conjunto de 10 clientes, lo que permite analizar la capacidad de los modelos para asignar entregas de manera eficiente en escenarios con menor complejidad geográfica. Este

enfoque inicial proporciona un punto de referencia para comparar ambos métodos y comprender sus fortalezas y limitaciones bajo condiciones controladas.

6.1.2. Escenarios con datos reales:

En este experimento, se utiliza datos reales de la comuna de Colina, Chile, para evaluar el desempeño de un modelo de optimización heurístico y un modelo exacto basado en programación lineal entera mixta, en un escenario más representativo de las condiciones reales de operación. Se considera una configuración principal: clientes dispersos en un área de 20 km de diámetro. Este enfoque permite analizar cómo la dispersión geográfica y la complejidad operativa afectan la eficiencia de los modelos, proporcionando una validación más realista de su aplicabilidad.

6.2. Implementación de los modelos experimentales

Ambos modelos fueron implementados en Python, utilizando datos simulados y reales para evaluar su desempeño en términos de:

- Número total de drones utilizados.
- Tiempo total de operación.

6.2.1. Modelo exacto (MILP)

Se utiliza Programación Lineal Entera Mixta (MILP) implementada con la librería PuLP, que permite resolver de manera óptima escenarios con un número manejable de clientes. Este modelo fue especialmente útil en los escenarios simulados y en los casos con clientes concentrados.

6.2.2. Modelo heurístico simple

Este modelo asigna los clientes de manera iterativa al dron disponible con menor carga de trabajo (distancia acumulada). Si bien no garantiza una solución óptima, su simplicidad y rapidez lo hacen adecuado para analizar escenarios más grandes o dispersos.

6.3. Resultados y comparaciones de distintos experimentos

Los experimentos realizados generaron resultados clave que permiten evaluar el desempeño de los modelos exacto y heurístico en los diferentes escenarios considerados. A continuación, se presentan los hallazgos principales para cada configuración:

6.4. Resultados Experimento 1 con un dron y 10 clientes:

Modelo Exacto: Logra un tiempo total de operación de 0,8915 horas, lo que equivale a aproximadamente 53,49 minutos (ver Tabla 2).

Modelo Heurístico: Obtuvo el mismo tiempo de 0,8915 horas, mostrando un desempeño equivalente al modelo exacto en este escenario simplificado (ver Tabla 2).

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	0,8915	53,49	Dron 1: 0,8915
Heurístico	0,8915	53,49	Dron 1: 0,8915

Tabla 2 Resultados Experimento 1 con un dron

Computo. Python 3.x
Fuente. Elaboración Propia

6.4.1. Experimento 1 Con dos drones y 10 clientes

Modelo Exacto (ver Tabla 3)

- Tiempo total: 0,4467 horas (26,8 minutos).
- Distribución: El dron 1 tomó 0,4467 horas, mientras que el dron 2 tuvo un tiempo de operación de 0,4448 horas.

Modelo Heurístico (ver Tabla 3)

- Tiempo total: 0,4895 horas (29,37 minutos).
- Distribución: El dron 1 opera durante 0,4020 horas, mientras que el dron 2 tuvo un tiempo de operación de 0,4895 horas.

Diferencia: El modelo exacto fue 0,0428 horas (2,57 minutos) más eficiente que el heurístico.

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	0,4467	26,8	Dron 1: 0,4467; Dron 2: 0,4448
Heurístico	0,4895	29,37	Dron 1: 0,4020; Dron 2: 0,4895

Tabla 3. Resultados Experimento 1 con dos drones

Computo. Python 3.x
Fuente. Elaboración Propia

6.4.2. Experimento 1 Con tres drones y 10 clientes

Modelo exacto (ver Tabla 4)

- Tiempo total: 0,2992 horas (17,95 minutos).
- Distribución: El dron 1 operó durante 0,2979 horas, el dron 2 durante 0,2991 horas, y el dron 3 durante 0,2945 horas.

Modelo heurístico (ver Tabla 4)

- Tiempo total: 0,3362 horas (20,17 minutos).
- Distribución: El dron 1 operó durante 0,2832 horas, el dron 2 durante 0,2721 horas, y el dron 3 durante 0,3362 horas.

Diferencia: El modelo exacto fue 0,037 horas (2,22 minutos) más eficiente que el heurístico.

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	0,2992	17,95	Dron 1: 0,2979; Dron 2: 0,2991; Dron 3: 0,2945
Heurístico	0,3362	20,17	Dron 1: 0,2832; Dron 2: 0,2721; Dron 3: 0,3362

Tabla 4. Resultados Experimento 1 con tres drones

Computo. Python 3.x
Fuente. Elaboración Propia

6.4.3. Análisis comparativo experimento 1

Eficiencia del Modelo Exacto: En todos los escenarios, el modelo exacto logra tiempos de operación menores o iguales a los obtenidos por el modelo heurístico. Esto resalta su capacidad para encontrar soluciones óptimas.

6.4.4. Ventaja del modelo heurístico

Aunque menos preciso, el modelo heurístico destaca por su rapidez en la resolución, especialmente útil en escenarios más complejos.

6.4.5. Impacto del número de drones

Incrementar la cantidad de drones permite reducir significativamente los tiempos totales de operación en ambos modelos. Sin embargo, el modelo exacto muestra una mejor distribución de las tareas entre los drones.

6.5. Resultados experimento 2 con un dron y 10 clientes, 20 km de diámetro:

Modelo Exacto: El tiempo total de operación fue de 2,2684 horas aproximadamente 2 horas y 16 minutos (ver Tabla 5).

Modelo Heurístico: Obtuvo el mismo tiempo total de 2,2684 horas, mostrando un desempeño equivalente al modelo exacto en este escenario (ver Tabla 5).

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	2,2684	≈ 136 minutos (2 h 16 m)	Dron 1: 2,2684
Heurístico	2,2684	≈ 136 minutos (2 h 16 m)	Dron 1: 2,2684

Tabla 5. Resultados Experimento 2 con un dron.

Computo. Python 3.x
Fuente. Elaboración Propia

6.5.1. Con dos drones

Modelo exacto (ver Tabla 6)

- Tiempo total: 1,1342 horas (aproximadamente 1 hora y 8 minutos).
- Distribución:
- Dron 1: 1,1342 horas.
- Dron 2: 1,1342 horas.

Modelo heurístico (ver Tabla 6)

- Tiempo total: 1,1454 horas (aproximadamente 1 hora y 9 minutos).
- Distribución:
- Dron 1: 1,1454 horas.
- Dron 2: 1,1230 horas.

Diferencia: El modelo exacto es 0,0112 horas (aproximadamente 40 segundos) más eficiente en el tiempo total.

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	1,1342	≈ 68 minutos (1 h 8 m)	Dron 1: 1,1342; Dron 2: 1,1342
Heurístico	1,1454	≈ 69 minutos (1 h 9 m)	Dron 1: 1,1454; Dron 2: 1,1230

Tabla 6. Resultados experimento 2 con dos drones.

Computo. Python 3.x
Fuente. Elaboración Propia

6.5.2. Con 3 drones

Modelo exacto (ver Tabla 7)

- Tiempo total: 0,7561 horas (aproximadamente 45,37 minutos).
- Distribución:
- Dron 1: 0,7561 horas.
- Dron 2: 0,7561 horas.
- Dron 3: 0,7561 horas.

Modelo heurístico (ver Tabla 7)

- Tiempo total: 0,7958 horas (aproximadamente 47,75 minutos).
- Distribución:
- Dron 1: 0,7958 horas.
- Dron 2: 0,7847 horas.
- Dron 3: 0,6878 horas.

Diferencia: El modelo exacto fue 0,0397 horas (aproximadamente 2 minutos y 23 segundos) más eficiente en el tiempo total.

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	0,7561	≈ 45,37 minutos	Dron 1: 0,7561; Dron 2: 0,7561; Dron 3: 0,7561
Heurístico	0,7958	≈ 47,75 minutos	Dron 1: 0,7958; Dron 2: 0,7847; Dron 3: 0,6878

Tabla 7. Resultados experimento 2 con tres drones.

Computo. Python 3.x
Fuente. Elaboración Propia

6.5.3. Análisis comparativo Experimento 2

Eficiencia del modelo exacto: En todos los casos, el modelo exacto logra tiempos totales de operación iguales o menores que el modelo heurístico, especialmente destacándose en configuraciones con dos y tres drones.

Impacto del número de drones: Incrementar el número de drones reduce significativamente el tiempo total de operación en ambos modelos, aunque el modelo exacto muestra una mejor distribución de las tareas entre los drones.

Desempeño del modelo heurístico: Aunque subóptimo en comparación con el modelo exacto, el modelo heurístico resuelve el problema rápidamente y con tiempos totales cercanos al óptimo.

6.6. Resultados Experimento 3 con un dron y 20 clientes

Modelo exacto: Logró un tiempo total de operación de 3,5253 horas aproximadamente 3 horas y 31 minutos (ver Tabla 8).

Modelo heurístico: Alcanzó el mismo tiempo total de 3,5253 horas, mostrando un desempeño equivalente al modelo exacto en este escenario (ver Tabla 8).

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	3,5253	≈ 211 minutos (3 h 31 min)	Dron 1: 3,5253
Heurístico	3,5253	≈ 211 minutos (3 h 31 min)	Dron 1: 3,5253

Tabla 8. Resultados Experimento 3 con un dron.

Computo. Python 3.x
Fuente. Elaboración Propia

6.6.1. Con dos drones:

Modelo exacto (ver Tabla 9)

- Tiempo total: 1,7627 horas (aproximadamente 1 hora y 46 minutos).
- Distribución:
- Dron 1: 1,7627 horas.
- Dron 2: 1,7627 horas.

Modelo heurístico (ver Tabla 9)

- Tiempo total: 1,7781 horas (aproximadamente 1 hora y 47 minutos).
- Distribución:
- Dron 1: 1,7472 horas.
- Dron 2: 1,7781 horas.

Diferencia: El modelo exacto fue 0,0154 horas (aproximadamente 55 segundos) más eficiente en el tiempo total.

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	1,7627	≈ 106 minutos (1 h 46 min)	Dron 1: 1,7627; Dron 2: 1,7627
Heurístico	1,7781	≈ 107 minutos (1 h 47 min)	Dron 1: 1,7472; Dron 2: 1,7781

Tabla 9. Resultados Experimento 3 con dos drones.

Computo. Python 3.x
Fuente. Elaboración Propia

6.6.2. Con tres drones

Modelo exacto (ver Tabla 10)

- Tiempo total: 1,1751 horas (aproximadamente 1 hora y 10 minutos).
- Distribución:
- Dron 1: 1,1751 horas.
- Dron 2: 1,1751 horas.
- Dron 3: 1,1751 horas.

Modelo heurístico (ver Tabla 10)

- Tiempo total: 1,3288 horas (aproximadamente 1 hora y 20 minutos).
- Distribución:
- Dron 1: 1,3288 horas.
- Dron 2: 1,0754 horas.
- Dron 3: 1,1212 horas.

Diferencia: El modelo exacto fue 0,1537 horas (aproximadamente 9 minutos y 13 segundos) más eficiente en el tiempo total.

Modelo	Tiempo Total (horas)	Tiempo Total (minutos)	Distribución (horas)
Exacto	1,1751	≈ 70,5 minutos (1 h 10 min)	Dron 1: 1,1751; Dron 2: 1,1751; Dron 3: 1,1751
Heurístico	1,3288	≈ 79,7 minutos (1 h 20 min)	Dron 1: 1,3288; Dron 2: 1,0754; Dron 3: 1,1212

Tabla 10. Resultados Experimento 3 con un dron.

Computo. Python 3.x
Fuente. Elaboración Propia

6.6.3. Análisis comparativo experimento 3

Eficiencia del modelo exacto: En los escenarios con 2 y 3 drones, el modelo exacto demuestra una eficiencia superior, con menores tiempos totales de operación, especialmente en configuraciones más complejas.

Impacto de la dispersión: La mayor dispersión de los clientes incrementa los tiempos de operación en ambos modelos en comparación con escenarios más concentrados, evidenciando la importancia de optimizar las rutas en estas condiciones.

Desempeño del modelo heurístico: Aunque subóptimo en comparación con el modelo exacto, el modelo heurístico mantuvo un desempeño competitivo, especialmente en escenarios con un solo dron.

6.7. Experimento 4

Se presentan los resultados obtenidos a partir de la aplicación de un modelo simplificado de Programación Lineal Entera Mixta (MILP), desarrollado con fines experimentales. En esta etapa, no se incorpora el componente de ruteo, es decir, no se considera la variable de

decisión x asociada a los trayectos entre nodos. Como consecuencia, se trata de una formulación reducida, cuyo propósito es evaluar el comportamiento general del sistema bajo distintas configuraciones de parámetros.

Los análisis realizados comprenden la estimación del número de drones requeridos, los tiempos de operación individuales por dron, la asignación de rutas en términos de carga de trabajo, y el uso de baterías adicionales como estrategia para ampliar la autonomía operativa. A continuación, se exponen los escenarios evaluados y los principales resultados obtenidos en cada caso.

6.8. Escenario 1: configuración base

- Velocidad del dron: 70 km/h.
- Tiempo máximo de batería: 40 minutos.
- Número máximo de baterías adicionales: 0.
- Pesos en la función objetivo $\alpha= 0.9$ (tiempo), $\beta= 0.1$ (drones), $\gamma= 0.1$

6.8.1. Resultados 1

- Estado del modelo: Óptimo.
- Número de drones utilizados: 6.
- Tiempos de operación por dron:
 - Dron 1: 33.91 min.
 - Dron 2: 26.03 min.
 - Dron 3: 22.54 min.
 - Dron 4: 34.48 min.
 - Dron 5: 32.87 min.
 - Dron 6: 31.47 min.

6.8.2. Asignación de clientes

- Dron 1: Clientes [2, 5, 13, 16].
- Dron 2: Clientes [8, 14, 18].
- Dron 3: Clientes [7, 10, 20].

- Dron 4: Clientes [6, 11, 19].
 - Dron 5: Clientes [9, 12, 17].
 - Dron 6: Clientes [1, 3, 4, 15].
- Uso de baterías adicionales: 0.
 - Total, de baterías adicionales utilizadas: 0.

6.8.3. Análisis primer escenario

Este escenario demuestra que, con las restricciones impuestas, se necesitan seis drones para completar todas las entregas dentro del tiempo máximo permitido por batería.

6.9. Escenario 2: Configuración con baterías adicionales permitidas

- Velocidad del dron: 70 km/h.
- Tiempo máximo de batería: 40 minutos.
- Número máximo de baterías adicionales: 1.
- Pesos en la función objetivo: $\alpha= 0.9$ (tiempo), $\beta= 0.1$ (drones), $\gamma= 0.1$ (baterías).

6.9.1. Resultados 2

- Estado del modelo: Óptimo.
- Número de drones utilizados: 5.
- Tiempos de operación por dron:
 - Dron 1: 35.39 min.
 - Dron 2: 34.50 min.
 - Dron 3: 45.89 min.
 - Dron 4: 34.48 min.
 - Dron 5: 31.04 min

6.9.2. Asignación de clientes

- Dron 1: Clientes [5, 7, 17, 18].
- Dron 2: Clientes [1, 2, 9, 13, 15].
- Dron 3: Clientes [3, 10, 16, 20].
- Dron 4: Clientes [6, 11, 19].
- Dron 5: Clientes [4, 8, 12, 14].

- Uso de baterías adicionales:
- El dron 3 utiliza 1 batería adicional.
- Total, de baterías adicionales utilizadas: 1.

6.9.3. Análisis Escenario 2

La posibilidad de utilizar una batería adicional permitió reducir el número de drones necesarios de 6 a 5, optimizando los recursos logísticos.

El Dron 3 requiere el uso de una batería adicional, lo cual le permite extender su tiempo de operación hasta 45.89 minutos, excediendo el límite de una sola batería.

Aunque el número de drones disminuye, el modelo mantuvo un balance aceptable en los tiempos de operación de los demás drones, con un rango de tiempos entre 31.04 y 45.89 minutos.

6.10. Escenario 3: Configuración con dos baterías adicionales permitidas

- Velocidad del dron: 70 km/h.
- Tiempo máximo de batería: 40 minutos.
- Número máximo de baterías adicionales: 2.
- Pesos en la función objetivo: $\alpha= 0.9$ (tiempo), $\beta= 0.1$ (drones), $\gamma= 0.1$

6.10.1. Resultados Escenario 3

- Estado del modelo: Óptimo.
- Número de drones utilizados: 4.
- Tiempos de operación por dron:
 - Dron 1: 54.76 min.
 - Dron 2: 35.91 min.
 - Dron 3: 55.03 min.
 - Dron 4: 35.61 min.

6.10.2. Asignación de clientes

- Dron 1: Clientes [5, 7, 9, 11, 13, 17].
- Dron 2: Clientes [1, 2, 3, 6, 20].
- Dron 3: Clientes [4, 8, 10, 12, 14, 18].
- Dron 4: Clientes [15, 16, 19].

- Total, de baterías adicionales utilizadas: 2.

6.10.3. Análisis escenario 3

Este escenario logra reducir el número de drones necesarios a 4, gracias al uso de dos baterías adicionales.

Los drones que utilizan baterías adicionales (Dron 1 y Dron 3) extienden significativamente sus tiempos de operación hasta 54.76 y 55.03 minutos, respectivamente, optimizando las entregas asignadas.

Los tiempos de operación de los demás drones se mantuvieron dentro del límite inicial de 40 minutos, asegurando un balance razonable entre las rutas.

6.11. Escenario 4: Configuración con tres baterías adicionales permitidas

- Velocidad del dron: 70 km/h.

- Tiempo máximo de batería: 40 minutos.
- Número máximo de baterías adicionales: 3.
- Pesos en la función objetivo: $\alpha=1$ (tiempo), $\beta=0$ (drones), $\gamma=0$ (baterías).

6.11.1. Resultados escenario 4:

- Estado del modelo: Óptimo.
- Número de drones utilizados: 3.
- Tiempos de operación por dron:
 - Dron 1: 63.45 min.
 - Dron 2: 67.58 min.
 - Dron 3: 50.27 min.

6.11.2. Asignación de clientes:

- Dron 1: Clientes [2, 5, 9, 15, 16, 19].
- Dron 2: Clientes [4, 6, 10, 11, 14, 17, 20].
- Dron 3: Clientes [1, 3, 7, 8, 12, 13, 18].
- Uso de baterías adicionales:
 - Dron 1, Dron 2 y Dron 3 utilizan 1 batería adicional cada uno.
 - Total, de baterías adicionales utilizadas: 3.

6.11.3. Análisis escenario 4

En este escenario, el uso de tres baterías adicionales permite reducir la flota de drones necesarios a 3, optimizando el número de recursos requeridos.

Cada dron utiliza 1 batería adicional para extender su tiempo de operación y atender un mayor número de clientes. Esto lleva a tiempos de operación de hasta 67.58 minutos en el caso del Dron 2.

Las rutas se distribuyen eficientemente entre los drones, con una carga balanceada en términos de clientes asignados y distancia recorrida.

6.11.4. Análisis de sensibilidad para el escenario 4

Se realiza un análisis de sensibilidad variando el número máximo de baterías adicionales permitidas, con el fin de evaluar el impacto sobre la cantidad de drones utilizados y el tiempo total necesario para completar las entregas. La evaluación considera cuatro escenarios distintos, aumentando progresivamente la disponibilidad de baterías adicionales, lo que permite analizar cómo afecta dicha variable en la eficiencia operativa del sistema de drones.

6.11.5. Discusión de resultados experimento final

En el Escenario 1 (base), con la restricción más estricta (sin baterías adicionales permitidas), se necesitaron seis drones para realizar la totalidad de las entregas dentro del límite de autonomía de batería establecido en 40 minutos. El promedio de operación por dron se mantuvo alrededor de 33,49 minutos, generando la necesidad de distribuir las entregas en un mayor número de drones.

Al permitir una batería adicional (Escenario 2), fue posible reducir la flota de seis a cinco drones. La disponibilidad adicional de energía permite extender el tiempo operativo de uno de los drones hasta 45,89 minutos, lo que optimiza moderadamente la distribución de entregas, aunque incrementó ligeramente el tiempo promedio por dron (37,63 minutos). La ganancia en eficiencia justifica claramente la incorporación de la batería adicional,

Se realiza un análisis de sensibilidad variando el número máximo de baterías adicionales permitidas, con el fin de evaluar el impacto sobre la cantidad de drones utilizados y el tiempo total necesario para completar las entregas. La evaluación considera cuatro escenarios distintos, aumentando progresivamente la disponibilidad de baterías adicionales, lo que permite analizar cómo afecta dicha variable en la eficiencia operativa del sistema de drones.

En el Escenario 3, con la posibilidad de usar hasta dos baterías adicionales, se observa una reducción aún más significativa, requiriendo solo cuatro drones para satisfacer todas las entregas. La autonomía incrementada permite extender considerablemente los tiempos de operación (hasta aproximadamente 55 minutos), resultando en un balance eficiente entre autonomía energética y capacidad operativa.

Finalmente, en el Escenario 4, la autorización de tres baterías adicionales permite reducir a únicamente tres drones, llevando los tiempos de operación hasta aproximadamente 68 minutos. Este escenario muestra la mayor eficiencia operativa en términos del número de drones requeridos, aunque implica un manejo más cuidadoso de las baterías adicionales.

El análisis de sensibilidad evidencia que existe una relación directa entre la disponibilidad de baterías adicionales y la eficiencia operativa del sistema de drones. A medida que aumenta la cantidad de baterías disponibles, disminuye notablemente el número necesario de drones, extendiéndose la autonomía y maximizando la eficiencia de los recursos disponibles. Este hallazgo resalta la importancia de considerar el balance entre inversión inicial (adquisición de drones) y la gestión de recursos adicionales (baterías), para optimizar costos operativos y tiempos de entrega en operaciones logísticas con drones.

6.12. La Tabla 11 expone los resultados del experimento 4

Escenario	Entrada de parámetros			Salida		
	Velocidad(km/h)	Tiempo máx. batería	Baterías adicionales máx.	Drones utilizados	Tiempos max. por dron	Baterias usadas
1	70	40	0	6	34.48	0
2	70	40	1	5	45.89	1
3	70	40	2	4	55.03	2
4	70	40	3	3	67.58	3

Tabla 11. Resultados experimento 4.

Computo. Python 3.x
Fuente. Elaboración Propia

CAPITULO 7: RESULTADOS Y ANÁLISIS DEL MODELO DE OPTIMIZACIÓN

En este capítulo se presentan los resultados obtenidos a partir de la implementación computacional del modelo de optimización propuesto en el Ccapítulo 5, el cual constituye la formulación definitiva desarrollada en el presente trabajo. Este modelo corresponde a una formulación multivisita basada en Programación Lineal Entera Mixta (MILP), diseñada para resolver un problema de distribución con drones, incorporando la posibilidad de realizar múltiples viajes por unidad a través del uso de baterías adicionales.

La característica de multivisita implica que un dron puede salir del depósito, atender una o más entregas, regresar a recargar su batería y luego continuar operando con una nueva carga. Esta capacidad permite extender el horizonte operativo de cada unidad más allá del límite impuesto por la autonomía básica de una sola batería, y se modela mediante una combinación de variables de recarga, restricciones de flujo y asignaciones múltiples al depósito. De esta manera, se logra una representación más realista de operaciones logísticas aéreas, especialmente en escenarios de alta demanda o con distribución geográfica extensa.

Para evaluar el desempeño del modelo bajo distintas condiciones, se definen diversos conjuntos de parámetros que corresponden a variaciones en los pesos asignados en la función objetivo, concretamente los coeficientes α , β y γ , asociados respectivamente al tiempo total de operación, al número de drones utilizados y al uso de baterías adicionales, estas combinaciones permiten explorar distintos enfoques de priorización en la optimización del sistema, ya sea minimizando el tiempo operativo, la cantidad de drones requeridos o el consumo de recursos energéticos adicionales.

7.1. Resultados obtenidos por escenario

Set	Velocidad (km/h)	Tiempo máx. batería (min)	Alfa	Beta	Gamma	N° Drones utilizado	Makespan (min)	Tiempo Total Operación (hrs)	Valor Objetivo	Total batería usadas
1	70	45	80	10	10	3	73,29	2,38	230,4	1
2	70	45	10	80	10	2	77,28	2,37	203,7	2
3	70	45	10	10	80	4	65,47	2,63	146,3	1
4	70	45	50	30	20	3	69,13	2,70	265,2	2
5	70	45	30	50	20	2	78,25	2,36	210,8	2
6	70	45	30	20	50	2	112,88	2,46	213,8	2
7	70	45	40	40	20	3	79,66	2,41	236,4	1
8	70	45	20	40	40	2	73,32	2,26	205,2	2
9	70	45	40	20	40	2	72,39	2,36	214,4	2
10	70	45	33	33	34	2	71,55	2,28	209,2	2

Tabla 12. Resultados Finales

Computo. Python 3.x
Fuente. Elaboración Propia

7.2. Análisis general de los resultados

A partir de los resultados expuestos en la tabla 12, se observa claramente cómo las ponderaciones asignadas a los parámetros alfa (tiempo total), beta (cantidad de drones), y gamma (baterías adicionales) influyen directamente sobre la configuración óptima de la flota y sobre la distribución del tiempo operativo.

Por ejemplo, en el Conjunto 1, donde se otorga un alto peso al tiempo total (alfa = 80), se utilizan tres drones con un makespan relativamente bajo (73,29 minutos). Por el contrario, en el Conjunto 2, al priorizar la reducción del número de drones (beta = 80), se logra minimizar la cantidad de drones a dos unidades, aunque aumentando levemente el makespan (77,28 minutos).

Estos resultados permiten concluir que el modelo implementado es capaz de adaptarse efectivamente a diferentes prioridades operativas establecidas mediante la variación de los pesos en la función objetivo, logrando un balance óptimo entre eficiencia temporal, uso de drones y consumo de baterías adicionales.

7.3. Análisis de Sensibilidad

El análisis de sensibilidad se efectúa variando sistemáticamente los parámetros α , β y γ , con el propósito de estudiar en profundidad la reacción del modelo frente a distintos objetivos operativos. Los resultados obtenidos evidencian claramente la sensibilidad del sistema frente a los cambios de estos parámetros.

7.3.1. Impacto del parámetro α (ponderación del tiempo total)

Al aumentar el valor de α , el modelo se orienta principalmente a reducir el tiempo total de operación (makespan), incluso a costa de aumentar ligeramente el número de drones o baterías adicionales empleadas. Por ejemplo, el Conjunto 1 con α equilibrado ($\alpha=33$) obtuvo un makespan moderado (73,29 minutos) y utiliza tres drones con una batería adicional.

7.3.2. Impacto de priorizar número de drones (β)

Al aumentar β considerablemente, el modelo prioriza claramente reducir el número de drones utilizados. Por ejemplo, en el Conjunto 2, con $\beta=80$, la cantidad de drones utilizados fue mínima (dos drones), a costa de un ligero aumento en el makespan (77,28 minutos) y en la cantidad de baterías adicionales usadas (dos baterías adicionales).

7.3.3. Influencia del uso de baterías adicionales (γ)

Cuando se incrementó sustancialmente el valor del parámetro γ , el modelo buscó limitar significativamente el uso de baterías adicionales, lo que influyó en una solución con mayor cantidad de drones, pero un uso más limitado de baterías adicionales. El Conjunto 3 ($\gamma=80$), por ejemplo, emplea cuatro drones, reduciendo el uso de baterías adicionales a solamente una, obteniendo además el menor makespan registrado (65,47 minutos).

Análisis revela claramente que al incrementar el peso asignado al **tiempo total de operación** (α) produce soluciones con tiempos más reducidos, pero aumenta los recursos logísticos.

Aumentar el peso en el **número de drones utilizados** (β) produce soluciones con menor cantidad de drones, elevando ligeramente tiempos y uso de baterías adicionales.

Al aumentar el peso del **uso de baterías adicionales** (γ) se minimiza este recurso, aumentando ligeramente el número de drones.

En consecuencia, mediante este análisis de sensibilidad, se concluye formalmente que el modelo propuesto es flexible y capaz de adaptarse efectivamente según las prioridades operacionales que se establezcan para diferentes contextos logísticos, facilitando la toma de decisiones fundamentadas en la asignación estratégica de los recursos disponibles.

CAPITULO 8: CONCLUSIONES Y TRABAJOS FUTUROS

En el presente capítulo se exponen claramente las conclusiones obtenidas del desarrollo del proyecto. En primer lugar, se realiza una síntesis formal y precisa de los principales resultados alcanzados, evaluando críticamente el grado de cumplimiento de los objetivos planteados al inicio de esta investigación. A continuación, se plantean posibles líneas futuras de trabajo, identificando áreas específicas en las que podría ampliarse o mejorarse el modelo desarrollado, con la finalidad de incrementar su alcance, aplicabilidad y eficiencia en contextos logísticos reales y complejos.

8.1. Conclusión

El presente estudio aborda la problemática de optimizar la gestión operativa de una flota de drones destinados al servicio logístico en la comuna de Colina. A partir de la implementación exitosa de un modelo matemático basado en Programación Lineal Entera Mixta (MILP), se logra determinar la configuración óptima de dicha flota, considerando diversas restricciones operacionales como la autonomía energética limitada y el uso restringido de baterías adicionales.

Se verifica formalmente el cumplimiento de los objetivos planteados en la investigación, destacando especialmente la capacidad del modelo para reducir considerablemente el número total de drones necesarios al utilizar estratégicamente baterías adicionales. Los resultados obtenidos fueron coherentes con los parámetros definidos en la función objetivo, reflejando claramente cómo distintos pesos asignados al tiempo de operación, número de drones, y baterías adicionales impactan significativamente en las soluciones propuestas. Asimismo, el análisis de sensibilidad desarrollado proporciona información valiosa acerca del comportamiento del sistema bajo diferentes escenarios, demostrando así la robustez y flexibilidad del modelo propuesto.

Finalmente, como proyección, se identifican múltiples áreas para futuras investigaciones que permitirían profundizar y complementar el trabajo actual. Entre estas destacan la incorporación de restricciones dinámicas en la demanda, la evaluación del impacto de normativas específicas del contexto chileno sobre las operaciones con drones, y la implementación de métodos heurísticos o metaheurísticos para abordar instancias de mayor

tamaño y complejidad. Estas líneas futuras permitirán fortalecer aún más la aplicabilidad y eficacia del modelo propuesto en contextos logísticos reales.

8.2. Trabajos futuros

A partir de los resultados obtenidos y las conclusiones alcanzadas en este estudio, se identifican diversas líneas de trabajo que permitirían ampliar y mejorar la investigación realizada. Estas sugerencias apuntan a fortalecer la aplicabilidad práctica del modelo propuesto, así como también a abordar nuevos desafíos relacionados con la optimización del uso de drones en contextos operacionales más amplios y realistas. A continuación, se detallan claramente estas recomendaciones.

8.2.1. Incorporar restricciones regulatorias específicas

Se propone incluir en futuras investigaciones aspectos regulatorios locales, tales como restricciones aéreas, limitaciones legales y permisos específicos del contexto chileno, para mejorar la aplicabilidad real del modelo.

8.2.2. Modelos dinámicos y tiempo real

Considerar una extensión del modelo actual hacia un contexto dinámico, integrando demandas variables en el tiempo, condiciones meteorológicas cambiantes y gestión en tiempo real de rutas, permitiendo una aplicación práctica más robusta y ajustada a situaciones reales.

8.2.3. Ampliación de la flota y escenarios más complejos

Implementar metodologías heurísticas avanzadas, tales como el procedimiento GRASP (Greedy Randomized Adaptive Search Procedure), o técnicas metaheurísticas similares, para abordar instancias mayores y más complejas, donde la optimización exacta podría resultar computacionalmente costosa.

8.2.4. Simulación computacional detallada

Desarrollar simulaciones en software especializado o entornos virtuales avanzados para evaluar, validar y visualizar de manera más precisa y práctica el comportamiento operativo de la flota de drones ante distintas situaciones reales.

La exploración de estas líneas futuras permitirá robustecer y ampliar considerablemente los alcances de la presente investigación, contribuyendo a mejorar significativamente la aplicabilidad práctica del modelo propuesto y entregando mayor valor en contextos operativos y académicos.

GLOSARIO

Autonomía energética: Capacidad de un dron para operar durante un período determinado sin necesidad de recargar o reemplazar baterías.

Centro logístico: Ubicación física desde donde los drones inician y finalizan sus operaciones de entrega.

Cliente: Punto de entrega identificado geográficamente que representa la demanda a satisfacer.

Drone Routing Problem (DRP): Problema de optimización que busca determinar las rutas óptimas para una flota de drones, considerando restricciones técnicas y operativas.

Metaheurística: Algoritmo de búsqueda aproximada utilizado para resolver problemas complejos, obteniendo soluciones cercanas al óptimo en tiempos computacionales razonables.

MILP (Programación Lineal Entera Mixta): Modelo matemático que utiliza variables continuas y enteras para resolver problemas de optimización sujetos a restricciones.

Optimización logística: Proceso de planificación para lograr la mayor eficiencia en operaciones logísticas, minimizando costos y tiempos.

Última milla: Etapa final en una cadena logística, correspondiente a la entrega directa desde el centro de distribución hasta el cliente final.

ABREVIATURAS

DRP: Drone Routing Problem

GRASP: Greedy Randomized Adaptive Search Procedure

INE: Instituto Nacional de Estadísticas

MILP: Mixed Integer Linear Programming (Programación Lineal Entera Mixta)

MTZ: Miller-Tucker-Zemlin (restricciones para eliminación de subtours)

USD: United States Dollar (dólar estadounidense)

VANT: Vehículo Aéreo No Tripulado

BIBLIOGRAFIA

[1] Arias Mahecha (septiembre de 2021) Análisis del uso de Drones en operaciones logísticas de distribución en el sector transporte

https://repository.unipiloto.edu.co/bitstream/handle/20.500.12277/10935/Mahecha_Kevin_Monografia_Drones.pdf

[2] Clara T. (febrero 6, 2024) Impacto de los Drones en la Logística y Entrega: Eficiencia y Sostenibilidad

<https://cdetech.org/impacto-de-los-drones-en-la-logistica-y-entrega-eficiencia-y-sostenibilidad/>

[3] RFLCargo (2024) ¿Cómo pueden influir los drones en el transporte de mercancías y el sector logístico?

<https://rflcargo.com/drones-en-el-transporte-de-mercancias-y-sector-logistico/>.

[4] Wingcopter. (n.d.). Wingcopter 198 Technical Specifications. <https://wingcopter.com/>

[5] Dorling, K., Heinrichs, J., Messier, G. G., & Magierowski, S. (2017). Vehicle routing problems for drone delivery. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 47(1), 70–85. <https://doi.org/10.1109/TSMC.2016.2582745>

- [6] Troudi, A., Addouche, S.-A., Dellagi, S., & El Mhamedi, A. (2018). Sizing of the drone delivery fleet considering energy autonomy. *Sustainability*, 10(9), 3344. <https://doi.org/10.3390/su10093344>
- [7] Boysen, N., Fedtke, S., & Schwerdfeger, S. (2021). Last-mile delivery concepts: A survey from an operational research perspective. *OR Spectrum*, 43(1), 1–58. <https://doi.org/10.1007/s00291-020-00607-8>
- [8] Clara, T. (2024). Impacto de los drones en la logística y entrega: Eficiencia y sostenibilidad. *Robótica y Automatización Tech News*. <https://cdetech.org/impacto-de-los-drones-en-la-logistica-y-entrega-eficiencia-y-sostenibilidad/>
- [9] Murray, C. C., & Chu, A. G. (2015). The flying sidekick traveling salesman problem: Optimization of drone-assisted parcel delivery. *Transportation Research Part C: Emerging Technologies*. <https://www.sciencedirect.com/science/article/abs/pii/S0968090X15000844?via%3Dihub>
- [10] Resende, M. G. C., & Ribeiro, C. C. (2003). Greedy randomized adaptive search procedures. En F. Glover & G. A. Kochenberger (Eds.), *Handbook of metaheuristics* (pp. 219-249). Springer. <https://mauricio.resende.info/doc/grasp-hao.pdf>
- [13] Gomez-Lagos, J., Rojas-Espinoza, B., and Candia-Vejar, A. (2022). On a pickup to delivery drone routing problem: Models and algorithms. *Computers & Industrial Engineering*, 172:108632
- [14] Tanveer Hossain Bhuiyan, Victor Walker, Mohammad Roni, Imtiaz (2024) Ahmed Aerial drone fleet deployment optimization with endogenous battery replacements for direct delivery of time-sensitive products, *Expert Systems With Applications* 252 124172
- [15] Entel. (s.f.). “El crecimiento del uso de drones en el mercado chileno.” <https://ce.entel.cl/articulos/el-crecimiento-del-uso-de-drones-en-el-mercado-chileno/>

[16] Portal Innova. (2023, 16 de marzo). Primer censo de operadores profesionales de drones arroja que la mitad trabaja en empresas que usan sus servicios como planta fija. <https://portalinnova.cl/primer-censo-de-operadores-profesionales-de-drones-arroja-que-la-mitad-trabaja-en-empresas-que-usan-sus-servicios-como-planta-fija/>

[17] Infobae. (2023, octubre 20). Así funciona el servicio de entrega a domicilio con drones de Amazon. <https://www.infobae.com/estados-unidos/2023/10/20/asi-funciona-el-servicio-de-entrega-de-domicilio-con-drones-de-amazon/>

[18] DPL News. (2022, febrero 11). Startup brasileño es la primera en tener autorización para usar drones en entregas. <https://dplnews.com/startup-brasilena-es-la-primer-a-en-tener-autorizacion-para-usar-drones-en-entregas/>

[19] El Universo. (2020, noviembre 6). La brasileña iFood será la primera empresa en usar drones en entregas. <https://www.eluniverso.com/noticias/economia/brasilena-ifood-sera-primer-a-empresa-en-usar-drones-en-entregas-nota/>

[20] Dirección General de Aeronáutica Civil (DGAC). (2022). Sistema de registro de drones. <https://www.dgac.gob.cl/como-operar-un-dron-en-chile/>

ANEXO

Con el objetivo de facilitar la revisión y replicación de los resultados obtenidos en este trabajo, se pone a disposición un repositorio en Google Drive que contiene todos los scripts utilizados durante el desarrollo del modelo. En este repositorio se incluyen tanto los códigos experimentales utilizados durante la etapa de exploración y prueba, como los códigos finales empleados para la obtención de los resultados presentados en el Capítulo 7.

El repositorio puede ser accedido a través del siguiente enlace:

<https://drive.google.com/drive/folders/1xaqOZSK7X90gDbWgaRHUPCQDIO66r9ue?usp=sharing>