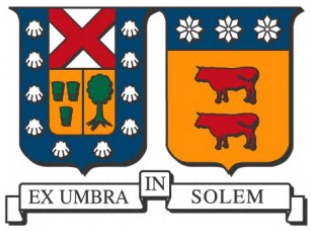
UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INFORMÁTICA
SANTIAGO - CHILE



“UBICACIÓN ESTRATÉGICA DE INFRAESTRUCTURAS CRÍTICAS: UN ENFOQUE MULTI-OBJETIVO CON MOEA/D PARA DESFIBRILADORES Y CÁMARAS DE VIDEOVIGILANCIA”

IGNACIO BENJAMÍN MUÑOZ SÁNCHEZ

MEMORIA PARA OPTAR AL TÍTULO DE
INGENIERO CIVIL EN INFORMÁTICA

Profesor Guía: Elizabeth Montero
Profesor Correferente: Daniela Opitz

Julio - 2026

CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

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

Título del trabajo: UBICACIÓN ESTRATÉGICA DE INFRAESTRUCTURAS CRÍTICAS: UN ENFOQUE MULTI-OBJETIVO CON MOEA/D PARA DESFIBRILADORES Y CÁMARAS DE VIDEOVIGILANCIA

Nombre del candidato(a): Ignacio Benjamín Muñoz Sánchez

Carrera / Grado: Ingeniería Civil Informática

Campus: Santiago San Joaquín **Departamento:** Informática

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

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

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

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

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

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

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

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

_____

_____

_____

4.- FIRMAS

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

Fecha: 06 de Julio del 2026 **Firma:** _____

Estudiante o Candidato(a):

Fecha: 06 de Julio del 2026 **Firma:** _____

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

DEDICATORIA

“La mejor tesis es una tesis terminada, no una perfecta”

A mi familia por su amor, su esfuerzo y por creer siempre en mí.

A los compañeros y amigos que conocí en la universidad, por hacer del camino algo más que un destino.

A todos quienes estuvieron cerca, en los momentos fáciles y en los difíciles.

Este trabajo es para ustedes.

AGRADECIMIENTOS

Agradezco a mi familia por el apoyo incondicional a lo largo de mi etapa universitaria. Sin su respaldo, este proceso habría sido más difícil.

Agradezco a mi guía Elizabeth Montero, quien me ha acompañado durante tanto tiempo y cuya orientación, paciencia y buena disposición fueron fundamentales para llevar esta memoria a buen término.

Finalmente, este estudio fue financiado por el proyecto FONDECYT N°1230365, cuyo apoyo hizo posible el desarrollo de esta investigación.

RESUMEN

Resumen— Los problemas de cobertura de conjuntos son relevantes para numerosas aplicaciones del mundo real en la actualidad. En particular, la reubicación de desfibriladores y la instalación de cámaras de video-vigilancia constituyen aplicación de especial interés. Ademas, en estos problemas es posible identificar múltiples medidas de calidad provenientes de las distintas perspectivas de los actores involucrados. En este trabajo se estudian los problemas multi-objetivo de ubicación y reubicación de desfibriladores y cámaras de video-vigilancia. Para ello, se propone una adaptación específica del algoritmo MOEA/D. Se resuelven instancias reales de gran escala a partir de datos públicos de Estados Unidos para el problema de desfibriladores, y de datos públicos de México para el escenario de video-vigilancia. Los resultados se comparan con los obtenidos mediante enfoques exactos formulados en AMPL y resueltos con Gurobi. El enfoque propuesto obtiene gaps de hipervolumen competitivos, con rangos entre $-5\,\%$ y $+3\,\%$ respecto al solver exacto en ambos dominios, superándolo en la mayoría de las instancias comparables y produciendo frentes de Pareto significativamente mas ricos. Los resultados demuestran la efectividad del enfoque propuesto en términos de convergencia y cobertura al enfrentarse a escenarios de gran escala. Estos hallazgos respaldan la aplicabilidad práctica del método como herramienta de apoyo a la toma de decisiones para planificadores urbanos y autoridades de salud pública en problemas de despliegue a gran escala.

Palabras Clave— Cobertura de conjuntos; multi-objetivo; MOEA/D, reubicación de desfibriladores; ubicación de cámaras de video-vigilancia

ABSTRACT

***Abstract*—**Set-covering problems are relevant to several real-world problems nowadays. In particular, the relocation of defibrillators and the placement of the video-vigilance camera are relevant applications to study. Moreover, in these problems, several quality measures can clearly be identified coming from different perspectives of the different actors involved. In this work, we study the multi-objective location-relocation problems of defibrillators and video-vigilance cameras. To this end, we propose a specifically adapted MOEA/D approach. We solve large real-world problem instances from public data in the USA for the defibrillator problem and from public data in México for the video-vigilance scenario. We compare our results with those obtained from exact approaches formulated in AMPL and

solved using Gurobi. Our approach obtains competitive hypervolume gaps ranging from $-5\,\%$ to $+3\,\%$ against the exact solers across both problem domains, outperforming it in the majority of comparable instances while producing significantly richer Pareto fronts. Our results demonstrate the effectiveness in terms of convergence and coverage of our approach in facing large scenarios. These findings support the practical applicability of the proposed method as a decision support tool for urban planners and public health authorities managing large-scale deployment problems.

Keywords— Set-covering; multi-objective; MOEA/D; defibrillator relocation problem; video-vigilance camera location problem

GLOSARIO

AED: Automatic External Defibrillator (Desfibrilador Externo Automático).
AG: Algoritmo Genético.
AMPL: A Mathematical Programming Language (Lenguaje de modelado para optimización matemática).
ANN: Average Nearest Neighbor (índice de vecino más cercano promedio).
BIP: Binary Integer Programming (Programación entera binaria).
C2: Centro de Comando y Control.
CCTV: Closed-Circuit Television (Circuito Cerrado de Televisión).
CDMX: Ciudad de México.
DEA: Desfibrilador Externo Automático.
DRP: Defibrillator Relocation Problem (Problema de Reubicación de Desfibriladores).
EPSG: European Petroleum Survey Group (Organización que define los códigos de los sistemas de referencia de coordenadas).
FLP: Facility Location Problem (Problema de Localización de Instalaciones).
GA: Genetic Algorithm (Algoritmo Genético).
GIS: Geographic Information System (Sistema de Información Geográfico)
HC: Hill Climbing (Algoritmo de búsqueda local).
HV: Hypervolumen (Métrica de Hipervolumen)
INAI: Instituto Nacional de Transparencia, Acceso a la Información y Protección de Datos Personales.
INEGI: Instituto Nacional de Estadística y Geografía.
MCLP: Maximum Covering Location Problem (Problema de Localización de Cobertura Máxima).
MOEA/D: Multi Objetive Evolutionary Algorithm based on Decomposition
NSGA-II: Non-dominated Sorting Genetic Algorithm II.
NYC: New York City (Ciudad de Nueva York).
OCP: Optimal Camera Placement (Ubicación Optima de Cámaras).
OHCA: Out of Hospital Cardiac Arrest (Paro Cardíaco Extrahospitalario).
ParamILS: Automated Algorithm Configuration Framework (Marco para la configuración automática de algoritmos basados en búsqueda local iterada).
PCEH: Para Cardíaco Extrahospitalario.
PF: Pareto Front (Frente de Pareto).
PSO: Particle Swarm Optimization (Optimización por enjambre de partículas).
SCP: Set Covering Problem (Problema de Cobertura de Conjuntos).
UTFSM: Universidad Técnica Federico Santa María.
UTM: Universal Transverse Mercator (Sistema de coordenadas proyectadas).
WGS84: World Geodetic System 1984 (Estándar de coordenadas geográficas).

ÍNDICE DE CONTENIDOS

RESUMEN iv

ABSTRACT iv

GLOSARIO vi

ÍNDICE DE FIGURAS ix

ÍNDICE DE TABLAS x

INTRODUCCIÓN 1

CAPÍTULO 1: DEFINICIÓN DEL PROBLEMA 3
1.1 Contexto y Motivación . . . 3
1.2 Actores y Consecuencias . . . 4
1.3 Enfoque de Solución . . . 5
1.4 Descripción de los Problemas . . . 6
1.4.1 Problema de Reubicación de Desfibriladores (DRP) . . . 6
1.4.2 Problema de Ubicación de Cámaras (OCP) . . . 7
1.4.3 Formulación Matemática Unificada . . . 8
1.5 Objetivos y Alcances de la Memoria . . . 11

CAPÍTULO 2: ESTADO DEL ARTE 13
2.1 Problemas de cobertura . . . 13
2.2 Problema de Desfibriladores . . . 14
2.3 Problema de instalación de cámaras de videovigilancia . . . 21
2.4 Resumen . . . 27

CAPÍTULO 3: PROPUESTA DE SOLUCIÓN 28
3.1 Multi Objetive Evolutionary Algorithm with Decomposition (MOEA/D) . . . 28
3.2 Métodos de descomposición . . . 31
3.3 Generación de Vectores de Peso . . . 32
3.4 Representación . . . 32
3.5 Funciones Objetivo . . . 34
3.5.1 Maximizar Cobertura . . . 34
3.5.2 Minimizar Costos . . . 34
3.6 Factibilidad . . . 34
3.7 Inicialización . . . 35
3.7.1 Cantidad de recursos a instalar . . . 35
3.7.2 Estrategia de Inicialización . . . 36
3.8 Operadores de Transformación . . . 37
3.8.1 Filtro de validación heurística . . . 37
3.8.2 Operador de cruzamiento . . . 37

3.8.3 Operador de mutación 39
3.9 Mecanismo de Reparación de Factibilidad 41
3.10 Parámetros del algoritmo 41

CAPÍTULO 4: EXPERIMENTOS Y RESULTADOS **43**
4.1 Formato Instancias 43
4.1.1 Instancias para el Problema de Reubicación de Desfibriladores (DRP) . 45
4.1.2 Instancias para el Problema de Ubicación de Cámaras (OCP) 48
4.2 Sintonización de parámetros 51
4.3 Configuraciones experimentales 54
4.4 Resultados 55
4.4.1 Problema de Reubicación de Desfibriladores (DRP) 56
4.4.2 Problema de Ubicación de Cámaras (OCP) 62
4.5 Conclusiones 69

CAPÍTULO 5: CONCLUSIONES **70**
5.1 Cumplimiento de Objetivos 70
5.2 Síntesis de resultados 71
5.3 Contribuciones y Limitaciones 72
5.4 Trabajo Futuro 73

ANEXOS **75**

A Declaración de uso de Inteligencia Artificial **75**

B Construcción del frente de Pareto de referencia mediante el método exacto (AMPL) **75**

C Espacio de configuración de operadores de mutación **76**

D Obtención y preprocesamiento de datos para instancias de desfibriladores en NYC **78**
D.1 Puntos candidatos desde Censo 2010 (Block Groups) 78
D.2 Inventario de desfibriladores (AEDs) desde NYC Open Data 79
D.3 Fronteras administrativas (NYC Borough Boundaries) 79

E Resultados para el problema de los desfibriladores **81**

F Resultados para el problema de los desfibriladores **82**

REFERENCIAS BIBLIOGRÁFICAS **85**

ÍNDICE DE FIGURAS

1 Diagrama de flujo del algoritmo MOEA/D. Fuente: Elaboración propia. 29
2 Representación gráfica de los vectores de peso para un problema de dos objetivos y una población de 100 individuos. Cada flecha representa un vector λ. 33
3 Ejemplo de solución utilizando la representación. Fuente: Elaboración propia. 33
4 Ejemplo de archivo en formato AMPL/Gurobi 44
5 Distribución espacial de los puntos candidatos de instalación (puntos grises, centroides de grupos de bloques censales) y desfibriladores externos automáticos (DEAs) preinstalados (puntos naranjas) en la Ciudad de Nueva York, segmentada por condado (cada color representa un condado distinto). 47
6 Distribución espacial de los reportes de incidencia delictiva (puntos azules) y ubicaciones de cámaras de video-vigilancia preinstaladas (puntos naranjas) en la Ciudad de México, segmentada por alcaldía (cada color representa una alcaldía distinta). 51
7 Frentes de Pareto para las instancias del Problema de Reubicación de Desfibriladores (DRP). El eje-y muestra el costo y el eje-x muestra la cobertura probabilística. Los símbolos naranjas representan el frente agregado de las diez ejecuciones de MOEA/D. Los símbolos azules corresponden al frente obtenido por AMPL 57
8 Visualización geográfica de las Fases 0 y 3 para Staten Island y Bronx. El fondo representa la densidad de demanda estimada mediante KDE, donde las zonas más rojas, indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a DEAs preinstalados, los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D, y las cruces rojas a DEAs removidos durante la optimización. Las filas superiores e inferiores muestran el estado inicial y optimizado respectivamente 60
9 Frentes de Pareto para las instancias del Problema de Ubicación de Cámaras (OCP). El eje-y muestra el costo y el eje-x muestra la cobertura probabilística. Los símbolos naranjas representan el frente agregado de las diez ejecuciones de MOEA/D. Los símbolos azules corresponden al frente obtenido por AMPL 64
10 Visualización geográfica de las Fases 0 y 3 para La Magdalena Contreras, Coyoacan y Alvaro Obregon. El fondo representa la densidad de crímenes estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a cámaras preinstaladas y los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D. Las filas superior e inferior muestran el estado inicial y la solución optimizada respectivamente 67

11 Visualización geográfica de las Fases 0 y 3 para Queens, Brooklyn y Manhattan. El fondo representa la densidad de demanda estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a desfibriladores externos automáticos preinstalados, los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D, y las cruces rojas a DEAs removidos durante la optimización. Las filas superiores e inferiores muestran el estado inicial y optimizado respectivamente. 81
12 Visualización geográfica de las Fases 0 y 3 para Milpa Alta, Cjpa. de Morelos, Tlahuac y Xochimilco. El fondo representa la densidad de crímenes estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a cámaras preinstaladas y los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D. Las filas superior e inferior muestran el estado inicial y la solución optimizada respectivamente. 82
13 Visualización geográfica de las Fases 0 y 3 para Azcapotzalco, Iztacalco, Tlalpan y Benito Juarez. El fondo representa la densidad de crímenes estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a cámaras preinstaladas y los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D. Las filas superior e inferior muestran el estado inicial y la solución optimizada respectivamente. 83
14 Visualización geográfica de las Fases 0 y 3 para Miguel Hidalgo, V. Carranza, Cuauhtemoc, G. A. Madero e Iztapalapa. El fondo representa la densidad de crímenes estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a cámaras preinstaladas y los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D. Las filas superior e inferior muestran el estado inicial y la solución optimizada respectivamente. 84

ÍNDICE DE TABLAS

1 Resumen de estudios sobre el Defibrillator Relocation Problem (DRP) 20
2 Resumen de estudios sobre el Optimal Camera Placement (OCP). La flecha ($\rightarrow$) indica optimización secuencial (por fases). Instalación 3D: Parámetros físicos como altura, campo de visión, orientación, etc. Instalación 2D: Considerar que la cámara cubre un sector circular. Espacio 3D: plano de cobertura discretizado en tres dimensiones. Espacio 2D: plano de cobertura discretizado en cuadrícula. 26
3 Resumen de parámetros configurables del algoritmo MOEA/D propuesto. . . 42
4 Población total por condado (Censo 2010). 46
5 Tamaño de las instancias por condado (candidatos, desfibriladores externos automáticos (DEAS) y total). 47

6 Frecuencia y probabilidad (%) de delitos de alto impacto por categoría 50
7 Instancias de Alcaldías 50
8 Puntos de referencia e hipervolumen obtenidos por el método exacto (AMPL) por instancia 53
9 Espacio de configuración de parámetros para el problema de desfibriladores (DRP). 54
10 Espacio de configuración de parámetros para el problema de Cámaras (OCP). 55
11 Configuración de parámetros seleccionada tras la sintonización. 56
12 Métricas de calidad para instancias del DRP 56
13 Tiempos de ejecución para instancias del DRP 57
14 Índice ANN antes y después de MOEA/D — DRP 58
15 Plan de implementación en fases para el DRP. R.: desfibriladores externos automáticos reubicados, C.: desfibriladores externos automáticos comprados (nuevos), $: costo incremental acumulado de la fase. Los valores de costo corresponden a: reubicación: 0.2, compra: 1.0 59
16 Z_1 y distancia promedio antes/después — Escenario 1: puntos de demanda . 61
17 Z_1 y distancia promedio antes/después — Escenario 2: incluye ubicaciones con desfibriladores externos automáticos preinstalados removidos 61
18 Métricas de calidad para instancias del OCP 63
19 Tiempos de ejecución para instancias del OCP 63
20 Índice ANN antes y después de MOEA/D — OCP 65
21 Plan de implementación en fases (cámaras nuevas por fase) — OCP 66
22 Z_1 y distancia promedio antes/después — OCP 68
23 Mapeo de configuraciones base e híbridas para el parámetro T_{mut}, detallando el parámetro interno que rige a cada operador. 77

INTRODUCCIÓN

En la gestión de entornos urbanos, la ubicación ineficiente de recursos críticos tiene un costo directo y cuantificable en vidas humanas y seguridad pública. En Estados Unidos, ocurren anualmente cerca de $350{,}000$ Paros Cardíacos Extrahospitalarios (PCEH, u OHCA por sus siglas en ingles: Out-of-hospital Cardiac Arrest) con una tasa de mortalidad de alrededor del $90\,\%$ [CARES, 2026]. Esto se traduce en una incidencia de 103 PCEH por cada $100{,}000$ habitantes[1]. Diversos estudios han demostrado que, durante emergencias, los testigos frecuentemente no logran ubicar o utilizar un Desfibrilador Externo Automático (DEA, o AED por sus siglas en ingles: Automated External Defibrillator) [Cunningham *et al.*, 2019, Gardett *et al.*, 2019]. Esto es especialmente crítico, ya que una rápida desfibrilación es un factor clave para la supervivencia [Valenzuela *et al.*, 2000, Ringh *et al.*, 2015], sin reanimación cardiopulmonar y desfibrilación inmediata, la probabilidad de sobrevivir disminuye entre un $7\,\%$ y $10\,\%$ por cada minuto de retraso [Link *et al.*, 2010]. En paralelo, bajo un contexto de seguridad pública, México evidencia un desafío espacial similar: en 2024 se estimaron 33.5 millones de delitos a nivel nacional, lo que representa una tasa de $33{,}918$ delitos por cada $100{,}000$ habitantes, ocultando ademas una "cifra negra" (delitos no denunciados) del $93.2\,\%$ [Instituto Nacional de Estadística y Geografía (INEGI), 2025]. Estas preocupantes cifras demuestran que el problema principal no siempre esta en la falta de recursos o presupuesto, sino en su distribución ineficiente, dejando zonas completamente vulnerables o con poca cobertura.

Abordar estructuralmente la distribución de estos recursos conduce al Problema de Localización de Instalaciones (Facility Location Problem, FLP), el cual se formaliza matemáticamente en este contexto mediante un modelo de Cobertura de Conjuntos (Set Covering Problem, SCP). Históricamente, determinar donde ubicar estos equipos se ha guiado por la experiencia de los operadores o decisiones intuitivas, careciendo a menudo de una base científica. Esta aproximación sub-óptima suele implicar mayores costos operativos a largo plazo, debido a que una cobertura ineficiente deja zonas vulnerables o fomenta la instalación redundante de dispositivos, consumiendo presupuesto que podría destinarse a mantenciones o usos urgentes.

En este contexto, este trabajo de memoria se enfoca en optimizar dos casos de alto impacto social: el Problema de Reubicación de Desfibriladores (DRP) y el Problema de Ubicación de Cámaras (OCP). Para el DRP, el estudio se centra en los cinco condados de la Ciudad de Nueva York, un lugar de alta densidad donde la demanda estimada alcanza los 110.6 casos PCEH por cada $100{,}000$ habitantes[2], superando ampliamente al promedio nacional de 78.7 [CARES, 2025, p. 49]. Por otro lado, para el OCP, el estudio se delimita a las 16 alcaldías de la Ciudad de México (CDMX), donde la tasa delictiva aumenta a 1.56 veces el promedio

[1] Para el calculo de esta tasa se considera una población de 340.0 millones de habitantes en Estados Unidos.

[2] Tasa basada en el registro CARES (Cardiac Arrest Registry to Enhance Survival). Ante la ausencia de datos para Nueva York, se utilizo como referencia análoga el Distrito de Columbia, al ser también una jurisdicción puramente urbana, representando una estimación conservadora [CARES, 2025, p. 49].

nacional, registrando $54{,}473$ delitos por cada $100{,}000$ habitantes. En este escenario, la optimización de cámaras no solo disuade ilícitos, además incrementa la probabilidad de generar pruebas visuales maximizando la detección de delitos en tiempo real, existiendo evidencia de reducciones de entre un $35\,\%$ y $41\,\%$ en robos a transeúntes en la CDMX, incluso al considerar variables socioeconómicas y contextuales del entorno [Díaz-Roman *et al.*, 2025]. Esto adquiere relevancia donde persisten importantes barreras para la denuncia, entre ellas la falta de pruebas. Por ello, una red de cámaras eficiente ataca directamente una de las dimensiones de la cifra negra, al proveer registros visuales que respaldan la denuncia y la investigación.

En la práctica, la resolución de estos problemas enfrenta restricciones presupuestarias que impiden la instalación de equipos en todas las ubicaciones necesarias. Por lo general, estos problemas se abordan mediante enfoques mono-objetivo, fijando un presupuesto inamovible para maximizar la cobertura, o al revés. No obstante, esto nos da una visión incompleta del problema. Por ello, esta memoria aborda la problemática desde una perspectiva multi-objetivo, buscando un equilibrio (trade-off) entre la maximización probabilística de la cobertura y la minimización de la inversión y costos operativos. Bajo este paradigma no hay una única solución, sino que hay un conjunto de soluciones matemáticamente eficientes (Frente de Pareto), otorgando a los actores de este proceso varias opciones estratégicas adaptables a diferentes escenarios o prioridades financieras, permitiéndoles tomar decisiones basadas en evidencia.

Para resolver esta alta complejidad computacional, se propone el diseño, adaptación y evaluación de un Algoritmo Evolutivo Multi-Objetivo basado en Descomposición (MOEA/D, por sus siglas en ingles: Multi-Objective Evolutionary Algorithm based on Decomposition). Este enfoque metaheurístico fue elegido porque permite descomponer el problema multi-objetivo en un conjunto de subproblemas mono-objetivo. De esta manera, el algoritmo resuelve simultáneamente dichos subproblemas, donde cada individuo se orienta a optimizar un subproblema específico, colaborando a aproximar distintas regiones del Frente de Pareto. Para validar la aplicabilidad de la propuesta, el algoritmo es puesto a prueba utilizando instancias basadas en los conjuntos de datos reales de los condados de NYC y las alcaldías de la CDMX.

Este documento se estructura de la siguiente manera: en el primer capítulo se formaliza la definición de los problemas a resolver, identificando sus supuestos y restricciones espaciales. El segundo capítulo comprende el estado del arte, revisando orígenes y evolución de los modelos y algoritmos aplicados tanto al DRP como al OCP, abarcando desde enfoques clásicos mono-objetivo hasta metodologías multi-objetivo. En el tercer capítulo se presenta la propuesta de solución, detallando el diseño de los operadores y la arquitectura adaptada del algoritmo MOEA/D para abordar ambos problemas. El cuarto capítulo describe el ambiente de experimentación, los conjuntos de datos, la sintonización de parámetros y la discusión de los resultados obtenidos mediante un análisis comparativo. Finalmente, en el quinto capítulo, se exponen las conclusiones de la investigación y se proponen líneas de trabajo futuro.

CAPÍTULO 1
DEFINICIÓN DEL PROBLEMA

En este capítulo se presenta la definición de los problemas abordados en esta memoria. Primero se contextualiza la situación actual de la distribución de desfibriladores en ciudades y el posicionamiento de cámaras de videovigilancia, identificando las limitaciones del proceso actual y los actores involucrados. Luego se examinan las consecuencias de no resolver estas trabas y se fundamenta por qué el enfoque multi-objetivo es la mejor alternativa para estos problemas. Después, se formalizan los dos problemas que se abordan en este trabajo: el Problema de Reubicación de Desfibriladores (DRP) y el Problema de Ubicación de Cámaras (OCP), detallando sus modelos, espacios de búsqueda y supuestos. Por último, se presentan los objetivos y alcances de la memoria.

1.1. Contexto y Motivación

La planificación y gestión de infraestructuras críticas como lo son los desfibriladores externos automáticos y las cámaras de videovigilancia resultan esenciales en lugares con alta densidad poblacional. Hoy en día estos equipos ya están instalados en diversos puntos del territorio, como edificios, calles, colegios, entre otros, siendo administrados por diversos organismos. En el ámbito de los desfibriladores externos automáticos, la ubicación de DEAs es un proceso más descentralizado, impulsado por leyes. En cambio, respecto a la videovigilancia de ciudades, puede tratarse de un problema fragmentado, como ocurre en la Región Metropolitana de Chile, o centralizado como el C5 (Centro de Comando, Control, Cómputo, Comunicaciones y Contacto Ciudadano) de la CDMX. Basado en este contexto, el trabajo se enfoca en dos metrópolis de escala masiva: la Ciudad de Nueva York (NYC) para el DRP y la Ciudad de México (CDMX) para el OCP. La elección de NYC se debe a su alta población de más de 8.3 millones de personas y su alto flujo turístico. Esto hace que la ciudad presente una alta variabilidad espacio-temporal que incrementa el riesgo de un PCEH. Por otro lado, la CDMX fue seleccionada por su red centralizada de videovigilancia, la cual se expande cada año, ofreciendo un modelo de soporte que tendría aplicabilidad y ayudaría a justificar la inversión pública en cámaras.

A pesar de la importancia de estos recursos, la distribución ha sido ineficiente debido a que el despliegue ha sido incremental, omitiendo una perspectiva global desde el inicio del proceso. Actualmente, las decisiones sobre dónde instalar un equipo se toman sin una metodología sistemática conocida. En el caso de los desfibriladores, existen normativas como la Ley 21,156 en Chile [Ministerio de Salud, 2019] o la Local Law 20 (2005) en NYC [New York City Deparment of Health and Mental Hygiene, 2006], que obligan a ubicar DEAs en ciertos lugares públicos y privados. Sin embargo, esta última solo menciona que el equipo debe encontrarse en un “lugar prominente, con acceso permanente y oportuno para

usuarios entrenados". Para el problema de la instalación de cámaras de videovigilancia, en la CDMX se estipula el uso de parámetros como el atlas delincuencial o atlas de riesgos para la colocación de equipos tecnológicos [Congreso de la Ciudad de México, 2008]. Sin embargo, y tal como se menciona en [Fuentes y Orozco, 2025], no existe transparencia pública sobre la metodología específica para determinar estas ubicaciones. Al depender de solo cumplir la parte legal, se carece de un proceso de planificación espacial estandarizado, generando distribuciones deficientes y causando que algunas zonas tengan demasiados equipos y otras presenten una escasez crítica.

Aunque en un principio la cantidad de información era manejable, el crecimiento de las ciudades y la magnitud de los datos han superado la capacidad de planificación humana. La complejidad de analizar miles de ubicaciones candidatas, procesar los puntos de demanda y ajustarse a un presupuesto hace inviable resolver el problema de forma manual. Es aquí donde entra la optimización combinatoria, que nos da el marco y los instrumentos para dar una respuesta computacional a los problemas. Al modelar matemáticamente los problemas, es posible transformar un problema de gestión en un problema de resolución algorítmica. Considerando que los organismos enfrentan el dilema entre maximizar la cobertura y minimizar los costos de instalación y/o reubicación, este trabajo plantea integrar ambas dimensiones bajo un enfoque multi-objetivo. Esto permitirá mejorar las imperfecciones actuales y generar conjuntos de soluciones que soporten una toma de decisiones basada en evidencia cuantitativa.

1.2. Actores y Consecuencias

Los actores que participan en este proceso se dividen en tres niveles: el gestor estratégico, el operador del sistema y los ciudadanos. En el primero se encuentran los organismos institucionales responsables del financiamiento, regulación y localización de los equipos. Para el DRP, la gestión de los equipos de acceso público recae en entidades como el New York City Department of Health and Mental Hygiene (DOHMH) y en los propietarios de locales privados que son obligados por ley. En el caso del OCP, este rol lo tiene el C5 de la CDMX. Aunque estas entidades puedan utilizar algún método algorítmico para decidir la ubicación de los dispositivos, al no existir transparencia sobre su mecánica, no se puede garantizar la eficiencia de sus elecciones. En el nivel operativo, están quienes ayudan en la ejecución de la respuesta. Para el DRP son los paramédicos y los operadores del 911 que deben guiar telefónicamente al ciudadano al DEA más cercano, y para el OCP son las fuerzas policiales y el personal que monitorea las cámaras. Finalmente, el actor más expuesto es el ciudadano común, el transeúnte que debe prestar ayuda ante un PCEH o quien puede convertirse en víctima de un delito. A diferencia de los niveles anteriores, este usuario no tiene información ni influencia sobre la distribución de los equipos, quedando dependiente de las decisiones de los otros actores.

Son precisamente estos actores los que enfrentan las consecuencias cuando la planificación falla. Si las deficiencias no se resuelven a corto y mediano plazo, acarrean consecuencias tan-

to sociales como financieras. A corto plazo, para el DRP, el resultado directo es el aumento de muertes evitables. Los dispositivos existen en la ciudad, pero si el operador del 911 no puede guiar al testigo al DEA más cercano en los primeros minutos debido a la mala distribución, el dispositivo se vuelve subutilizado y el recurso resulta inservible. En paralelo, para el OCP, se genera una falsa sensación de seguridad en la población. La instalación de cámaras sin un criterio de optimización crea puntos ciegos y si una persona es asaltada bajo una cámara mal situada e incapaz de registrar el delito, las fuerzas policiales quedan imposibilitadas para actuar, disminuyendo drásticamente la confianza ciudadana y aumentando la cifra negra. A mediano plazo, el problema principal radica en el derroche de los fondos. El costo financiero de los equipos no acaba con su compra, sino que exige un mantenimiento continuo (reemplazo de baterías, piezas y conectividad de red). Por lo tanto, un despliegue sin planificación matemática se traduce en altos costos operativos por mantener dispositivos ineficientes, consumiendo el presupuesto que debería destinarse a la optimización o expansión de la red.

1.3. Enfoque de Solución

Históricamente, los modelos matemáticos que se han utilizado para abordar estos problemas han sido formulados con un enfoque mono-objetivo, fijando un parámetro, por ejemplo, maximizar la cobertura con un presupuesto fijo o minimizar costos garantizando una cobertura mínima. Sin embargo, esto resulta insuficiente y limitativo, ya que fijar uno de estos límites introduce una subjetividad técnica que restringe la visión del tomador de decisiones, forzándolo a aceptar una única solución. Al entregar una sola respuesta, el modelo deja de representar la complejidad y dinámica de la realidad, donde las instituciones necesitan evaluar diferentes escenarios antes de comprometer los recursos de la ciudad.

Es aquí donde el enfoque multi-objetivo es importante para esta investigación. A diferencia de los modelos tradicionales, que entregan una respuesta única y rígida al tomador de decisiones, la optimización multi-objetivo entrega un conjunto de soluciones matemáticamente eficientes (frente de Pareto). Esto resulta indispensable debido a la volatilidad de la gestión, donde de un día para otro un nuevo factor puede cambiar las reglas del juego. Por ejemplo, si se hace un recorte de presupuesto a última hora, con una estrategia mono-objetivo se tendría que desechar el trabajo anterior y recalcular todo desde cero. En cambio, el modelo multi-objetivo ya tendría la distribución óptima para adaptarse a ese nuevo escenario. Del mismo modo, visualizar todas las soluciones permite descubrir niveles de eficiencia ocultos, por ejemplo, revelando que el presupuesto inicialmente asignado es superior al necesario y que con una fracción de este se alcanza la cobertura total, evitando un gasto redundante. O bien, si la exigencia de cobertura mínima cambia repentinamente, no es necesario rehacer el trabajo. En resumen, este enfoque proporciona a los tomadores de decisiones la flexibilidad, el realismo y la capacidad de adaptación frente a escenarios cambiantes.

1.4. Descripción de los Problemas

Esta sección formaliza los dos problemas de optimización abordados en esta memoria. En la Sección 1.4.1 se describe el Problema de Reubicación de Desfibriladores, definiendo su entorno y supuestos adoptados. Luego, en la Sección 1.4.2 se presenta el Problema de Ubicación de Cámaras, destacando las particularidades de su infraestructura en contraste con el DRP. Finalmente, en la Sección 1.4.3 se desarrolla la formulación matemática unificada de ambos problemas, aprovechando la estructura común que comparten.

1.4.1. Problema de Reubicación de Desfibriladores (DRP)

El problema de Reubicación de Desfibriladores (DRP, por sus siglas en inglés: Defibrillator Relocation Problem) es un problema de optimización diseñado para maximizar el acceso rápido a desfibriladores externos automáticos (DEA, o AED por sus siglas en inglés: Automated External Defibrillator) y, como resultado, mejorar la tasa de supervivencia en casos de paro cardíaco extrahospitalario (PCEH, u OHCA por sus siglas en inglés: Out of Hospital Cardiac Arrest). Teóricamente, el DRP pertenece a la familia de los Problemas de Localización de Instalaciones (Facility Location Problem, FLP) y, más específicamente, es una variante del Maximal Covering Location Problem (MCLP), el cual maximiza la cobertura bajo un presupuesto restringido. En este trabajo, el problema se formula bajo la estructura general de los Problemas de Cobertura de Conjuntos (Set Covering Problem, SCP). La diferencia entre el DRP y el MCLP clásico radica en que este último suele asumir la creación de una red desde cero. En cambio, el DRP aborda una red ya existente pero ineficiente, evaluando simultáneamente dónde instalar nuevos equipos y de dónde quitar equipos con una subutilización crítica.

Para abordar este desafío, la literatura distingue dos modelos:

- Modelo de Localización Fija (Fixed Location Model): Se consideran n DEAs preinstalados y se van a poder instalar m nuevos equipos sin afectar la distribución original.
- Modelo de Localización Flexible (Flexible Location Model): Se consideran n DEAs preinstalados y un presupuesto P. Este presupuesto sirve para adquirir nuevos equipos o reubicar equipos preinstalados hacia otras zonas.

Para los efectos de esta memoria, se adopta el modelo de localización flexible, ya que, a diferencia del modelo fijo, que solo permite agregar nuevos equipos sin evaluar la distribución actual, el modelo flexible permite desplazar equipos de zonas con sobrecobertura a zonas críticas, cubriendo las falencias de la distribución inicial. Estudios previos han demostrado que en el modelo flexible se logra una cobertura superior a la del modelo fijo [Tierney *et al.*, 2018, Buter *et al.*, 2024].

Para formalizar este modelo, el entorno se discretiza definiendo su espacio de búsqueda a

través de dos conjuntos. El primero corresponde a los puntos de demanda, que son coordenadas geográficas que poseen una probabilidad de ocurrencia de un PCEH y requieren ser cubiertos. El segundo conjunto incluye los puntos candidatos, que representan las ubicaciones factibles donde se puede instalar un equipo. Además, siguiendo métodos establecidos en la literatura, se considera que los mismos puntos de demanda pueden actuar como puntos candidatos, y que las ubicaciones preinstaladas se incorporan como parte inicial del conjunto candidato.

Finalmente, para la modelación, se consideran los siguientes supuestos:

- Un evento PCEH está cubierto si existe al menos un DEA a una distancia menor o igual a un radio de cobertura predefinido.
- Se asume que todos los equipos preinstalados son candidatos viables a ser reubicados si el modelo lo considera favorable, independientemente del recinto normativo donde se encuentren actualmente (p. ej., colegios o instituciones públicas), con el fin de corregir las ineficiencias espaciales a nivel de ciudad.

La formulación matemática de este modelo se presenta en la Sección 1.4.3, junto con la del OCP, aprovechando la notación común a ambos problemas.

1.4.2. Problema de Ubicación de Cámaras (OCP)

El problema de Ubicación de Cámaras (conocido en la literatura por sus siglas en inglés OCP, correspondientes a Optimal Camera Placement) es un problema de optimización diseñado para implementar estratégicamente sistemas de videovigilancia en lugares públicos, con el fin de maximizar las detecciones y la prevención de delitos. Desde un punto de vista teórico, el OCP proviene del Problema de la Galería de Arte (Art Gallery Problem, AGP), que aborda la cobertura y la visibilidad desde una perspectiva geométrica continua. No obstante, para esta investigación, el espacio continuo se discretiza, permitiendo traducir la formulación geométrica del AGP hacia la estructura de un SCP. Este cambio es clave porque permite abordar el OCP bajo el mismo marco algorítmico que se usa para el DRP.

A diferencia del DRP, la infraestructura de videovigilancia exige un enfoque diferente en términos de modelación. En primer lugar, el OCP se define bajo un modelo de instalación fija, debido a que desinstalar y reubicar una cámara conlleva altos costos (mano de obra, cableado eléctrico y de red). Por ello, el modelo se centra únicamente en la instalación estratégica de nuevas cámaras. En segundo lugar, en la práctica, la efectividad de las cámaras se ve limitada por factores tridimensionales (altura, ángulo, profundidad) y obstrucciones visuales (árboles, infraestructura). Si bien el problema real involucra estos parámetros, este trabajo modeló el OCP en un espacio de instalación bidimensional (2D). Lo anterior es necesario para mantener la complejidad computacional manejable, enfocándose en la planificación y distribución macro-espacial del territorio.

Para formalizar este modelo, el entorno se discretiza definiendo su espacio de búsqueda a través de dos conjuntos. El primero corresponde a los puntos de demanda, que son coordenadas geográficas que poseen una probabilidad de incidencia delictiva y requieren ser cubiertos. El segundo conjunto incluye los puntos candidatos, que representan las ubicaciones factibles donde se puede erigir un poste de vigilancia. Al igual que en el DRP, se asume que los puntos de demanda pueden actuar como puntos candidatos. La diferencia principal es que los equipos preinstalados actúan como nodos fijos, los cuales no pueden ser retirados ni reubicados por el algoritmo.

Bajo este enfoque bidimensional, la resolución del modelo considera los siguientes supuestos y simplificaciones:

- Un evento delictivo se considera cubierto si existe al menos una cámara a una distancia menor o igual a un radio de cobertura predefinido.
- Se considera un tipo de cámara con un radio de cobertura R fijo y un ángulo de visión omnidireccional ($360°$), sin incorporar parámetros de altura o inclinación.
- Para los efectos de la optimización en 2D, no se consideran oclusiones físicas, asumiendo una visión total dentro del radio de alcance. Esto es aceptable a nivel macro, ya que el algoritmo identifica las áreas geográficas óptimas y los ajustes tácticos se realizan en la fase de ingeniería en terreno.

La formulación matemática de este modelo se presenta en la Sección 1.4.3, donde se formaliza conjuntamente con el DRP bajo una notación unificada.

1.4.3. Formulación Matemática Unificada

A pesar de sus diferencias contextuales, el DRP y el OCP comparten la misma estructura matemática base: ambos buscan seleccionar un subconjunto de ubicaciones candidatas para maximizar la cobertura probabilística de eventos críticos bajo una restricción presupuestaria. Esto permite formalizarlos bajo una notación común, inspirada en el modelo de [Tierney *et al.*, 2018]. A continuación se definen los conjuntos, parámetros y variables de decisión compartidos, seguidos de las formulaciones específicas de cada problema: el modelo de localización para el OCP y el modelo de reubicación para el DRP.

Conjuntos

- $N = \{1, \ldots, |N|\}$: Conjunto de sitios candidatos y puntos de demanda. En esta formulación, un mismo sitio $i \in N$ actúa al mismo tiempo como ubicación candidata para un equipo y como punto de demanda.
- $\Omega_j = \{i \in N \mid d_{ij} \leq R\}$: Conjunto de sitios candidatos i que pueden cubrir al evento j.

Parámetros

- P: Presupuesto total disponible.
- R: Radio de cobertura del equipo.
- c_1: Costo de instalar un nuevo equipo.
- c_2: Costo de reubicar (mover) un equipo.
- Pr_j: Probabilidad de ocurrencia de un evento en el sitio j.
- $flag_i$: Parámetro binario definido como:

$$flag_i = \begin{cases} 1 & \text{Si ya existe un equipo preinstalado en } i \\ 0 & \text{caso contrario} \end{cases}$$

- N_0: Cantidad inicial de equipos existentes ($N_0 = \sum_{i \in N} flag_i$).

Variables de Decisión

- x_j: Variable de cobertura.

$$x_j = \begin{cases} 1 & \text{Si el evento } j \text{ está cubierto} \\ 0 & \text{caso contrario} \end{cases}$$

- En localización (para el OCP):
  - y_i: Variable de instalación.

$$y_i = \begin{cases} 1 & \text{Si se instala un nuevo equipo en el sitio } i \\ 0 & \text{caso contrario} \end{cases}$$

- En reubicación (para el DRP):
  - y_i: Variable de configuración final.

$$y_i = \begin{cases} 1 & \text{Si al final existe un equipo en el sitio } i \text{ (nuevo, mantenido o movido)} \\ 0 & \text{caso contrario} \end{cases}$$

  - n_{nuevos}: Cantidad de nuevos equipos adquiridos (Variable entera auxiliar).

Modelo de Localización (Aplicado al OCP)

En este modelo, el objetivo es determinar dónde instalar nuevos dispositivos sin reubicar (mover) los existentes.

$$\text{Minimizar} \quad F_1 = -\sum_{j \in N} x_j \cdot \mathit{Pr}_j \tag{1}$$

$$\text{Minimizar} \quad F_2 = \sum_{i \in N} c_1 \cdot y_i \tag{2}$$

$$\text{Sujeto a:} \quad y_i \leq 1 - \mathit{flag}_i \qquad \forall i \in N \tag{3}$$

$$x_j \leq \sum_{i \in \Omega_j} (y_i + \mathit{flag}_i) \qquad \forall j \in N \tag{4}$$

$$x_j \geq y_i + \mathit{flag}_i \qquad \forall j \in N, \forall i \in \Omega_j \tag{5}$$

$$F_2 \leq P \tag{6}$$

$$x_j, y_i \in \{0, 1\} \qquad \forall i, j \in N \tag{7}$$

A continuación se detalla cada restricción:

- Funciones Objetivo: La ecuación (1) minimiza el negativo de la cobertura probabilística (equivalente a maximizar la cobertura). La ecuación (2) minimiza el costo total de instalación.
- Restricción (3): Garantiza que no se instale un equipo nuevo en un sitio que ya cuenta con uno previamente instalado.
- Restricciones (4) y (5): La inecuación (4) establece que un evento j solo puede estar cubierto si la suma de equipos (nuevos o existentes) en su radio de alcance Ω_j es al menos 1. La inecuación (5) garantiza que si hay un equipo en algún sitio i que cubre a j, entonces x_j debe tomar el valor 1.
- Restricción (6): Asegura que los costos de instalación no superen el presupuesto P.
- Restricción (7): Define la naturaleza binaria de las variables de decisión.

Modelo de Reubicación (Aplicado al DRP)

En este modelo, se permite mover los dispositivos existentes y comprar nuevos.

$$\text{Minimizar} \quad F_1 = -\sum_{j \in N} x_j \cdot Pr_j \tag{8}$$

$$\text{Minimizar} \quad F_2 = (c_1 \cdot n_{\text{nuevos}}) + \sum_{i \in N} c_2 \cdot flag_i \cdot (1 - y_i) \tag{9}$$

$$\text{Sujeto a:} \quad n_{\text{nuevos}} = \sum_{i \in N} y_i - N_0 \tag{10}$$

$$\sum_{i \in N} y_i \geq N_0 \tag{11}$$

$$x_j \leq \sum_{i \in \Omega_j} y_i \qquad \forall j \in N \tag{12}$$

$$x_j \geq y_i \qquad \forall j \in N, \forall i \in \Omega_j \tag{13}$$

$$F_2 \leq P \tag{14}$$

$$x_j, y_i \in \{0, 1\}, \quad n_{\text{nuevos}} \geq 0 \qquad \forall i, j \in N \tag{15}$$

A continuación se detalla cada restricción:

- Funciones Objetivo: La ecuación (8) minimiza el negativo de la cobertura probabilística (equivalente a maximizar la cobertura). La ecuación (9) minimiza el costo total sumando dos componentes: el costo de instalación y el costo de reubicación.
- Restricción (10): Variable que calcula la cantidad de equipos nuevos adquiridos.
- Restricción (11): Asegura que el número total de equipos en el sistema no disminuya respecto al estado inicial.
- Restricciones (12) y (13): Vinculan la cobertura (x_j) con la configuración final (y_i). La inecuación (12) impide que un evento esté cubierto si no hay equipos asignados en su vecindario, mientras que (13) fuerza la cobertura si existe al menos un equipo activo que alcance al evento.
- Restricción (14): Asegura que los costos de instalación y/o reubicación no superen el presupuesto P.
- Restricción (15): Define la naturaleza binaria de las variables de decisión.

1.5. Objetivos y Alcances de la Memoria

Objetivo General

Desarrollar y evaluar un algoritmo de optimización multi-objetivo basado en descomposición (MOEA/D) para resolver los problemas de reubicación de desfibriladores (DRP) y ubicación de

cámaras (OCP), generando un conjunto de soluciones eficientes que represente el equilibrio entre cobertura y costos en escenarios urbanos reales.

Objetivos Específicos

1. Analizar el estado del arte respecto a los problemas de reubicación de desfibriladores (DRP) y ubicación de cámaras (OCP), identificando los modelos matemáticos y algoritmos de resolución.
2. Diseñar y adaptar el algoritmo MOEA/D para abordar restricciones y criterios propios del OCP y del DRP.
3. Implementar el algoritmo propuesto y optimizar su desempeño mediante la sintonización de parámetros.
4. Evaluar la eficacia del modelo propuesto utilizando instancias basadas en escenarios reales, correspondientes a los condados de la Ciudad de Nueva York y las alcaldías de la Ciudad de México.
5. Comparar el rendimiento del enfoque multi-objetivo frente a métodos exactos en términos de calidad de la solución y tiempo de cómputo.

Alcances y limitaciones

El alcance de esta memoria comprende el diseño, implementación y evaluación del algoritmo MOEA/D aplicado a los problemas DRP y OCP bajo un marco metodológico común. La validación se realizará utilizando datos geográficos y probabilísticos reales de la Ciudad de Nueva York y de la Ciudad de México. Para medir el desempeño y la calidad de las soluciones, el algoritmo propuesto se someterá a una sintonización de parámetros y sus resultados se compararán directamente contra métodos exactos. El sistema entregará como salida un conjunto de soluciones eficientes (frente de Pareto), lo que evidenciará cómo la optimización combinatoria puede producir un amplio rango de alternativas para asistir a la toma de decisiones estratégicas.

Por otro lado, la investigación establece ciertas limitaciones y simplificaciones teóricas para mantener la complejidad del modelo a un nivel manejable. En primer lugar, ambos problemas funcionan bajo una demanda estática, es decir, no consideran las fluctuaciones temporales. En el DRP, no se tiene en cuenta la disponibilidad operativa real de los equipos, suponiendo accesibilidad las 24 horas del día. Para el OCP, el entorno se modeló en dos dimensiones, lo cual es un enfoque de carácter macro-espacial que no sustituye el diseño micro ni la ingeniería en terreno necesaria para analizar oclusiones físicas tridimensionales, como lo son los ángulos ciegos o la altura del montaje. Por último, cada problema tiene su propio tipo de equipo: en el DRP es un modelo estándar de DEA y en el OCP un único tipo de cámara. En ambos casos, no se consideran variantes con diferentes costos operativos o características técnicas.

CAPÍTULO 2
ESTADO DEL ARTE

En este capítulo se presenta el estado del arte de los dos problemas estudiados en este trabajo de memoria. El problema de ubicación de desfibriladores externos automáticos y el problema de ubicación óptima de cámaras. Primero, se presenta el marco conceptual común asociado a los problemas de cobertura y, posteriormente, se revisan los principales enfoques propuestos en la literatura para cada problema.

2.1. Problemas de cobertura

En esta memoria se estudian dos problemas de optimización que, aunque provienen de líneas de investigación distintas, comparten una misma estructura: seleccionar un subconjunto de ubicaciones para cubrir un conjunto de puntos de demanda. Esto se puede entender como la generalización del Set Covering Problem (SCP), donde a partir de un subconjunto (posibles ubicaciones) se busca seleccionar la menor cantidad de ellos para cubrir todos los elementos de un universo (demanda). En la práctica, muchas variantes surgen al modificar la definición de cobertura, el presupuesto de instalaciones y/o la forma de medir la demanda que puede ser determinística, ponderada o probabilística.

En el contexto de servicios de emergencia, el SCP dió origen a problemas de localización con cobertura, en los cuales la cobertura depende de un umbral de distancia o de tiempo de respuesta. Uno de los primeros modelos fue el Location Set Covering Problem [Toregas *et al.*, 1971], cuyo objetivo es minimizar el número de instalaciones asegurando que toda la demanda sea cubierta. Por ejemplo, el tiempo de respuesta de una estación de bomberos ante un incendio no puede abarcar toda la ciudad, pero sí un radio específico dentro del cual se garantiza la atención. Sin embargo, en la práctica no siempre es posible instalar todas las estaciones necesarias, ya que existen limitaciones de presupuesto/recursos. Para reflejar esta realidad se incorporó una restricción de recursos, lo que ímplica que no siempre se logra cubrir el 100 % de la demanda, pero sí un porcentaje mínimo. A partir de esta idea se define el Maximal Covering Location Problem (MCLP, [Church y ReVelle, 1974]) cuyo objetivo es ubicar un número máximo de instalaciones de manera que se maximice la cobertura sobre la demanda.

Con base en lo anterior, se sitúa el DRP, orientado a la instalación y/o reubicación de DEAs con el fin de mejorar la cobertura frente a eventos PCEHs, bajo un presupuesto. En términos de estructura, se puede ver como una variante del MCLP, pero con características adicionales: (i) puede haber infraestructura previamente instalada, (ii) es posible mover equipos ya existentes y (iii) la demanda/cobertura puede modelarse de forma ponderada o probabilística, dependiendo del enfoque. Al igual que el MCLP, el objetivo sigue siendo maximizar la cobertura en función del presupuesto disponible, aunque incorporando estas características

que lo hacen más real y complejo.

En paralelo, en visión computacional y seguridad aparece el Art Gallery Problem (AGP, [Chvátal, 1975]), que estudió el número de guardias necesarios para poder cubrir una galería de arte. A diferencia de la cobertura radial típica en servicios de emergencia, aquí la cobertura depende de la línea de visión, oclusiones y, en escenarios más realistas, un campo de visión (Field of View, FoV) y la orientación, además de otros parámetros. Estas consideraciones conducen al Optimal Camera Placement (OCP) a decidir dónde instalar cámaras —y, en casos más realistas, con qué parámetros— para maximizar la visibilidad o cubrir objetivos relevantes. El OCP puede representarse como una variante del SCP, donde cada configuración o tipo de cámara indica un conjunto de puntos que puede cubrir. Así, la tarea es seleccionar un subconjunto de cámaras que maximice la cobertura, minimizando la cantidad de equipos o ajustándose a un presupuesto.

En síntesis, el DRP como el OCP comparten la misma estructura, seleccionar ubicaciones para cubrir demanda, la única diferencia está en la definición de cobertura:

- DRP: Cobertura por distancia ($360°$), con demanda probabilística y posibles reubicaciones.
- OCP: Cobertura por visibilidad geométrica (direccional, con oclusiones) y decisiones adicionales como orientación y campo de visión.

Esto permite tratarlos bajo un concepto en común de problemas de cobertura y selección de subconjuntos, mientras que cada uno mantiene sus propias características que afectan al modelamiento y a los métodos de solución.

A continuación, se presenta la revisión del estado del arte detallada para cada uno de estos problemas.

2.2. Problema de Desfibriladores

La literatura sobre la ubicación de DEAs ha evolucionado desde modelos simplificados hacia enfoques más complejos que integran mayor realismo y consideraciones sobre el comportamiento humano. Para estructurar esta revisión, los trabajos se separan en dos categorías según su enfoque de optimización: las propuestas mono-objetivo, orientadas principalmente a maximizar la cobertura utilizando métodos exactos y heurísticos, y las propuestas multi-objetivo, diseñadas para explorar simultáneamente un equilibrio entre objetivos en conflicto. Esto último es importante para los tomadores de decisiones, quienes deben evaluar los múltiples escenarios antes de comprometer los recursos.

Antes de presentar la revisión de la literatura, vamos a mencionar estudios que tratan temas relacionados pero que no se incluyen en el análisis debido a sus características

específicas. Todos ellos adoptan un enfoque mono-objetivo o equivalente. Por ejemplo, en [Huang y Wen, 2014] determinan las ubicaciones óptimas de DEAs utilizando la red de tiendas 7-eleven como infraestructura candidata, aunque es sólida, su formulación es mono-objetivo. En segundo lugar [Lin *et al.*, 2023] aborda el despliegue de DEAs en áreas unidimensionales, como trenes, túneles o pasillos largos, pese a emplear un criterio de evaluación compuesto, en la práctica se reduce a la búsqueda de una sola configuración óptima. Finalmente, [Lorenzo *et al.*, 2020] propone un marco basado en Sistemas de Información Geográfica (GIS) y aprendizaje automático para instalar y reubicar DEAs, en zonas residenciales, mediante una función mono-objetivo de costo-eficiencia. En conjunto, los estudios confirman que existen más investigaciones de optimización de DEAs, aunque con formulación mono-objetivo, que difieren del enfoque bi-objetivo y urbano estudiado en esta memoria.

Mayor importancia tienen los trabajos que presentan un enfoque multi-objetivo. En la búsqueda de este tipo de formulaciones, se encontraron cuya base son variantes del Problema de Localización de Instalaciones (FLP) aplicadas tanto a servicios generales, como centros de evacuación [Rico *et al.*, 2024] o redes de telecomunicaciones [Babaei *et al.*, 2025], como a los Servicios de Emergencia Médica (SEM o EMS por sus siglas en inglés: Emergency Medical Services). En este último caso, los modelos tienen como base el MCLP, el LSCP o el p-Median Problem (PMP). Aunque el DEA es en sí un recurso de emergencia, en estos estudios dichos modelos se aplican en un sentido más amplio, abarcando ambulancias y centros hospitalarios, y no DEAs específicamente. En esta línea, [El Itani *et al.*, 2019] formula la localización de ambulancias de la Cruz Roja Libanesa en Beirut como un problema bi-objetivo, buscando maximizar la cobertura y minimizar el costo de usar ambulancias privadas, resuelto mediante ϵ-constraint. En [Escobar *et al.*, 2023] se busca optimizar la red pública de servicios de salud del Valle del Cauca bajo dos objetivos, minimizar costos y maximizar cobertura, utilizando un método exacto y aplicando MinMax para determinar la solución de mayor equilibrio del frente de Pareto. En [Song *et al.*, 2020] se optimiza la ubicación de estaciones de SEM en Shanghai bajo cuatro objetivos con prioridades jerárquicas explícitas, resuelta con una variante modificada de NSGA-II. En [Li *et al.*, 2025] se aplica también NSGA-II integrado con GIS para decidir qué instalaciones de SEM mantener, expandir o construir en una ciudad de rápido crecimiento. Como aporte adicional, se agrupa el frente de Pareto mediante K-means en cuatro estrategias interpretables para los tomadores de decisiones. Finalmente, [Khalilzadeh y Bahari, 2023] busca ubicar instalaciones de SEM empleando el concepto de p-envy, buscando garantizar un acceso equitativo en todas las zonas de localización.

A continuación se presentan los estudios incorporados al análisis, organizados según su enfoque de optimización.

En este contexto, un trabajo fundamental es el de [Chan *et al.*, 2016] para el problema de cobertura probabilística en la localización de DEAs. A diferencia de trabajos donde la cobertura es binaria, los autores modelan la probabilidad de recuperación y uso efectivo del DEA como una función monotonamente decreciente de la distancia al dispositivo, reconociendo que el acceso al DEA disminuye con la distancia, lo que impacta directamente en la supervivencia. El estudio propone una extensión probabilística del MCLP y formula tres modelos matemáticos

para distintos escenarios de comportamiento del *respondedor*: (i) múltiples respondedores buscando dispositivos de manera independiente, (ii) un único respondedor en el peor caso, y (iii) un único respondedor en el mejor caso. Para evaluar los modelos se utilizaron datos reales de Toronto, Canadá, considerando $1{,}310$ PCEHs y $1{,}669$ DEAs registrados. Además, se empleó Kernel Density Estimation (KDE), para estimar de manera continua la distribución espacial del riesgo en la ciudad. Los resultados muestran que un despliegue optimizado podría mejorar la cobertura en aproximadamente un $40\,\%$. Asimismo, mediante la reubicación de DEAs se podrían generar ganancias sustanciales de cobertura. Lo que destaca es que una optimización en la distribución y planificación de DEAs tiene un potencial impacto en la supervivencia ante un PCEH. Reconociendo una limitación, el estudio señala la falta de datos sobre el comportamiento real de los respondedores durante emergencias. Como línea futura, los autores sugieren avanzar hacia modelos que integren información adicional y mecanismos de coordinación institucional que permitan una planificación centralizada de DEAs.

A diferencia del estudio anterior centrado en la optimización matemática exacta, otros autores han optado por evaluar la accesibilidad espacial antes de proponer nuevas ubicaciones. En esta línea, [Lin *et al.*, 2016] abordan la ubicación óptima de DEAs en comunidades, con el objetivo de identificar brechas entre demanda y oferta y establecer prioridades geográficas. La metodología empleada se divide en dos fases. Inicialmente, aplicaron un análisis de regresión bayesiana, utilizando el método INLA, para estimar el riesgo de los PCEHs. Posteriormente, integraron este riesgo en el marco Multi-Criterion Two-Step Floating Catchment Area (MC2SFCA). Este enfoque combina la evaluación de accesibilidad espacial (considerando distancia, población y riesgo) con un ranking de prioridad para orientar nuevas localizaciones. El estudio se valida en Kaohsiung, Taiwán, utilizando datos de $6{,}135$ pacientes con PCEH (2011-2013), 476 DEAs registrados en octubre de 2014 y 51 estaciones de servicio médico de emergencia, además de información demográfica y de uso de suelo. Los resultados muestran que la mayoría de los PCEHs ocurren en áreas residenciales, reforzando la necesidad de una ubicación comunitaria óptima. Además, se identifican disparidades territoriales: exceso de equipos en zonas urbanas y escasez en zonas rurales. El trabajo concluye que una redistribución optimizada de DEAs puede mejorar la cobertura de los servicios de emergencia y reducir las desigualdades. Entre las limitaciones se mencionan la calidad incompleta de la geocodificación, el subregistro de DEAs (por ser voluntario) y la variabilidad en tiempos de respuesta (por ejemplo, tanto la velocidad de un adulto caminando como el tiempo de llegada de una ambulancia pueden variar bajo distintas circunstancias). Como trabajo futuro, los autores proponen incorporar datos sobre la frecuencia real de uso de los DEAs para refinar la evaluación.

Aunque identificar las zonas de riesgo es crucial, los modelos tradicionales frecuentemente ignoran las barreras físicas del entorno urbano que afectan los tiempos de desplazamiento. Para mitigar esta limitación y considerar la topografía real de la ciudad, en [Kwon *et al.*, 2017], los autores abordaron el problema de la ubicación óptima de DEAs en entornos urbanos complicados, incorporando restricciones realistas como autopistas, ríos, túneles, pasos subterráneos, entre otros. Para resolverlo utilizaron el location-allocation solver de ArcGIS, el cual implementa la heurística de sustitución de vértices de Teitz y Bart

[Teitz y Bart, 1968], con el objetivo de minimizar la distancia ponderada entre nodos de demanda y nodos candidatos. Los nodos de demanda se definieron modelando la población flotante de alto riesgo (pacientes sobre 60 años ubicados mediante tráfico móvil) que podrían sufrir un paro, mientras que los candidatos correspondían a intersecciones peatonales. El estudio se basó en datos de Corea del Sur del año 2014, con 634 PCEHs y 227 DEAs disponibles en exteriores. Los resultados mostraron que la instalación adicional de 228 DEAs permitió cubrir entre un 10 % y 30 % más casos de PCEH, y se estimó que si los DEAs fueran instalados basados en el estudio, hasta un 45 % de los PCEH podrían haber recibido primeros auxilios. Una limitación del estudio fue la reducida cantidad de datos de PCEHs (634 casos), lo que puede introducir sesgos en los resultados. A ello se suma la exclusión de DEAs no registrados, que podrían modificar el análisis si fueran considerados. Como proyección futura, se plantea la necesidad de ampliar la muestra de datos para validar con mayor fuerza las locaciones propuestas. El trabajo destaca la importancia de considerar redes peatonales y barreras urbanas para lograr ubicaciones más realistas y efectivas.

Los estudios mencionados se enfocaban principalmente en la instalación de nuevos equipos. Sin embargo, ante la limitación de recursos, surgió la necesidad de optimizar la infraestructura existente mediante la reubicación. En ese aspecto, en [Tierney *et al.*, 2018] abordan el problema de ubicación y reubicación de DEAs mediante dos enfoques: un modelo fijo, que únicamente permitía agregar nuevos dispositivos, y un modelo flexible, que incorporaba además la posibilidad de reubicar los ya existentes. El objetivo en ambos casos fue maximizar la cobertura de eventos PCEH. Para validar los modelos, se utilizaron datos reales de Canton Ticino, en Suiza, correspondientes al periodo 2005-2015, registrando $2{,}802$ PCEHs y 719 DEAs, distribuidos en zonas urbanas y rurales. Los resultados mostraron que el modelo flexible alcanzó una cobertura superior al modelo fijo, evidenciando que reubicar todos los DEAs, si es necesario, tiene mejor rendimiento que solo instalar cierta cantidad sin modificar los actuales. Asimismo, se destacó que las zonas rurales son más desafiantes para lograr una cobertura adecuada, por lo que se recomienda utilizar distintas estrategias según el contexto geográfico. Dentro de las limitaciones, el estudio asume que la distribución histórica de los PCEHs es representativa del futuro, lo que podría no reflejar cambios en patrones de ocurrencia. Para futuras investigaciones, los autores sugieren considerar casos en los que múltiples DEAs se encuentren próximos a un mismo evento, así como introducir métricas de distancia más realistas, por ejemplo, basadas en patrones de movilidad, lo que permitiría modelar de manera más precisa el comportamiento de los testigos y mejorar la planificación.

Recientemente, la literatura ha avanzado en integrar los dispositivos físicos con la respuesta humana. En este contexto de sistemas híbridos, en [Buter *et al.*, 2024], los autores abordan el problema de ubicación y reubicación de DEAs, incorporando sistemas de voluntarios (Volunteer Responder Systems o VRS). El VRS es un sistema de alerta que guía a rescatistas al lugar de la emergencia. Se considera una función de cobertura gradual y realista que integra el modo de transporte del voluntario (a pie, bicicleta o auto) y su impacto en el tiempo de respuesta. El estudio se basó en datos históricos de $4{,}229$ PCEHs y $1{,}149$ DEAs, registrados en 29 municipios de los Países Bajos. El problema se formuló como un MCLP con cobertura gradual, resuelto mediante tres métodos: BIP, Greedy y GRASP. Los resultados mostraron

que BIP y GRASP alcanzaban desempeños parecidos, pero mucho mejores que el algoritmo Greedy. En el escenario de instalación adicional, bastaba con instalar entre cinco y diez DEAs para lograr un aumento sustancial en la cobertura. En el escenario de reubicación, se evidenció que las ubicaciones actuales eran subóptimas y que reubicar los DEAs podía aumentar la cobertura promedio de 36 % a 49 %, con mejoras de hasta 175 % en algunos municipios. Este estudio aporta una visión más realista del problema de ubicación de DEAs, incorporando voluntarios, diferentes medios de transporte y múltiples funciones de cobertura, contribuyendo a mejorar la planificación de respuesta ante PCEHs en distintos lugares. Como limitación, los autores mencionan su dependencia de una única base de datos de DEAs, que podría no capturar dispositivos no registrados y afectar las estimaciones de cobertura. Asimismo, el modelo opera bajo la suposición de que todos los DEAs son de acceso público las 24 horas del día, sin tener en cuenta su disponibilidad temporal real. Como línea de investigación futura, se propone desarrollar modelos que incorporen la localización y el comportamiento de los voluntarios, con el fin de identificar estrategias de ubicación de DEAs y de mejora de la red de voluntarios, permitiendo una planificación más robusta ante eventos PCEH.

Continuando con las propuestas más actuales, dado el aumento complejo de la infraestructura urbana y el aumento poblacional, es necesario considerar metaheurísticas más avanzadas junto con análisis espaciales profundos. En ese sentido, [Shi *et al.*, 2025] abordan la ubicación óptima de DEAs en áreas urbanas. Los autores analizan la distribución actual mediante técnicas espaciales y luego optimizan su distribución construyendo un modelo de cobertura utilizando un algoritmo genético, cuyo objetivo es maximizar una función compuesta por: (1) población promedio cubierta, (2) nuevo número de puntos de cobertura y (3) capacidad promedio de servicio. El estudio se valida en el distrito urbano central de Nanjing, considerando: (i) distribución de $1{,}030$ DEAs, (ii) datos básicos de la ciudad y (iii) indicadores socioeconómicos. La modelación se construye sobre una grilla de $200 \times 200\ m^2$ que define puntos de demanda y sitios candidatos. Se definen tres niveles de servicio para los DEAs: servicio óptimo (100 m), máximo corriendo (200 m) y máximo en bicicleta (400 m), basados en la regla de los cuatro minutos. Los análisis revelan: (1) distribución concentrada (clustered), (2) cobertura >90 % a 400 m, pero se reduce a ~ 50 % a 200 m y ~ 16 % a 100 m, y (3) predominio de DEAs en áreas residenciales y servicios públicos, con escasa presencia en recintos deportivos. La aplicación del algoritmo permitió: (a) llenar vacíos con 90 nuevos puntos, (b) mejorar la cobertura a 200 m y 100 m (+5.26 % y +2.17 % de población servida), y (c) reforzar la presencia en recintos educativos, comunidades y grandes instalaciones deportivas. El trabajo concluye recomendando: (1) equilibrar la distribución regional, (2) fortalecer la cobertura y los servicios de emergencia, y (3) priorizar lugares clave. Una limitación del estudio fue la exclusión de DEAs privados y movibles. Como trabajo futuro, se propone integrar una dimensión temporal para desarrollar una distribución dinámica de DEAs.

Tras revisar los enfoques mono-objetivo, es necesario abordar la optimización multi-objetivo aplicada específicamente al DRP. Como se indicó anteriormente, si bien el enfoque multi-objetivo está bien explorado en la localización de servicios de emergencia, su aplicación específica en la ubicación de DEAs ha recibido menor atención en la literatura. Bajo este enfoque, en el estudio de [Zhong y Wei, 2024], se aborda el problema de la optimización de

la ubicación de DEAs en el área urbana central de Guangzhou, China, mediante un enfoque de regresión con random forest y optimización multi-objetivo con el algoritmo NSGA-II. El análisis se basó en un registro inicial de 373 DEAs y cuatro conjuntos de datos complementarios: factores de instalaciones públicas, vulnerabilidad poblacional, accesibilidad de la red vial y riesgos asociados al uso del suelo. A partir de estos factores se construyó un índice de riesgo compuesto, mediante la combinación ponderada de las dimensiones, que sirvió de base para la optimización. Los resultados mostraron que los factores de instalaciones tuvieron el mayor peso en la priorización ($51.15\,\%$), seguidos por la vulnerabilidad poblacional ($19.68\,\%$), accesibilidad ($16.78\,\%$) y el uso del suelo ($12.39\,\%$). El estudio propone además una estrategia de implementación en tres fases: (i) despliegue inicial de $1{,}990$ DEAs en áreas de alto riesgo, (ii) instalación de 144 unidades adicionales en zonas con beneficios marginales optimizados e (iii) instalación de 215 unidades más para lograr una cobertura completa en áreas de prioridad media y baja. Esta investigación confirma el papel central de los factores de instalación en la selección óptima de ubicaciones y sugiere que en entornos urbanos de alta densidad se requieren nuevas estrategias de planificación. Una limitación clave identificada por los autores es que confiar en los datos de los teléfonos móviles podría sesgar las estimaciones de vulnerabilidad, en particular en áreas privadas o en grupos con bajo uso de teléfono, como los adultos mayores. Para futuras investigaciones, se propone el desarrollo de modelos dinámicos que integren información poblacional en tiempo real y patrones de movilidad cambiantes, permitiendo así una mayor adaptabilidad.

Como se observó en el estado del arte del DRP, los estudios no se limitaron únicamente al objetivo clásico de maximizar cobertura, sino que algunos también abordaron la combinación de ubicación y reubicación de DEAs, utilizando en su mayoría instancias basadas en datos reales, lo que demuestra la relevancia práctica del problema y la posibilidad de optimizar la planificación de estos equipos críticos. En general, se concluyó que la reubicación permite alcanzar una mejor cobertura que la simple instalación adicional. Con el paso del tiempo, los modelos incorporaron mayor realismo, integrando no solo información de PCEHs y DEAs, sino también información complementaria como redes viales, densidad poblacional, lo que permitió aproximar con mayor fidelidad las condiciones del entorno. En cuanto a los métodos de resolución, se emplearon enfoques diversos, desde heurísticas hasta métodos exactos. Sin embargo, la gran mayoría de los estudios adoptaron enfoques mono-objetivo, y solo recientemente se han abordado propuestas multi-objetivo aplicadas específicamente al DRP. Esta escasa presencia del enfoque multi-objetivo es la que esta memoria busca contribuir a llenar.

La Tabla 1 presenta un resumen de los estudios analizados para el DRP, detallando los objetivos de optimización, los métodos de solución y las características de los conjuntos de datos empleados.

Referencia	Problema	Objetivos	Método de Solución	Dataset				
				Origen del dataset	Fuentes de datos	#PCEH	#DEA	Fecha dataset
[Chan *et al.*, 2016]	Ubicación estratégica de DEAs bajo incertidumbre espacial mediante modelos de cobertura probabilística	- Max. cobertura probabilística	Exacto	Toronto, Canadá	ROC Cardiac Arrest Database (PCEHs), Toronto EMS (DEAs)	1,310	1,669	16/12/2005 a 05/07/2010
[Lin *et al.*, 2016]	Priorización estratégica de DEAs en comunidades, basada en la accesibilidad espacial y el riesgo comunitario	Identificar brechas demanda-oferta y definir prioridad geográfica	Regresión Bayesiana (INLA) + MC2SFCA	Kaohsiung, Taiwán	Kaohsiung DOH (PCEHs) , Taiwan AED Registry, Ministerio del Interior (Uso del suelo y datos censales)	6,135	476	PCEHs: 2011 - 2013 DEA: Hasta Oct. 2014
[Kwon *et al.*, 2017]	Ubicación de DEAs en entornos urbanos utilizando la red peatonal y barreras físicas	- Min. distancia ponderada	ArcGIS + algoritmo de Teitz and Bart	Dos distritos de Seoul (Yeongdeungpo y Dongjak), Corea del Sur	Seoul EMS (PCEHs), Inventario Municipal de DEAs, Datos Censales y red peatonal	634 (348 y 286, respectivamente)	227	Solo año 2014
[Tierney *et al.*, 2018]	Ubicación y reubicación de DEAs, evaluando diferencias entre zonas urbanas y rurales	- Max. cobertura	Exacto	Canton Ticino, Suiza	Registro de PCEHs, inventario de DEAs, datos estadísticos de edificios (Suiza FSO)	2,802	719	01/01/2005 a 31/12/2015
[Buter *et al.*, 2024]	Ubicación y reubicación óptima de DEAs en sistemas VRS, con cobertura gradual dependiente del modo de transporte	- Max. la cobertura gradual	BIP, GRASP, Greedy	29 municipios de Países Bajos	Amsterdam REsuscitation STudies (ARREST, PCEHs), VRS HartslagNu (inventario DEAs y transporte)	4,429	1,149	01/01/2006 a 31/12/2016
[Shi *et al.*, 2025]	Evaluación y optimización de la distribución espacial de DEAs existente y nuevos en áreas urbanas	- Max. función compuesta (Población + cobertura + capacidad de servicio)	Algoritmo Genético (GA)	Distrito urbano central de Nanjing, China	Nanjing Red Cross (DEAs), Anuarios estadísticos y Datos geográficos del YRD (Población y entorno)	-	1,030	Hasta 2024
[Zhong y Wei, 2024]	Optimización multi-objetivo de la ubicación de DEAs en áreas urbanas considerando factores de instalaciones, vulnerabilidad poblacional, accesibilidad y uso del suelo	- Multi-obj: Min. número de DEAs y Max. cobertura	Random Forest Regression + NSGA−II	Cuatro distritos de Guangzhou (Yuexiu, Liwan, Haizhu y Tianhue), China	inventario de DEAs (AED City Map), movilidad poblacional (Telefonía móvil), red vial (OpenStreetMap), instalaciones publicas (Gaode OpenPlatform) y uso del suelo (EULUC-China)	-	373	Hasta Mayo 2024

Tabla 1: Resumen de estudios sobre el Defibrillator Relocation Problem (DRP)

En la Tabla 1 es posible identificar una evolución sostenida en tres dimensiones: el modelado del problema, las fuentes de datos y los métodos de resolución empleados. En cuanto al modelado, los trabajos más tempranos se enfocaron exclusivamente en la instalación de DEAs. Con el paso del tiempo, los modelos incorporaron mayor realismo, como funciones de cobertura gradual, la consideración de barreras urbanas y la distinción entre instalación y reubicación de equipos. Estos avances reflejan una maduración del campo, donde el foco se desplaza de lo simple hacia la fidelidad del entorno real.

Respecto a las fuentes de datos, se observa una tendencia hacia la diversificación geográfica: los estudios han sido aplicados en distintos contextos, como Taiwán, China o Canadá, evidenciando que el problema no está restringido a un solo contexto. Esta heterogeneidad también se aplica a los datos disponibles, que condicionan el diseño del modelo adoptado para cada caso.

Finalmente, en lo relativo a los métodos de resolución, se aprecia una transición clara de los métodos exactos a algoritmos metaheurísticos. Esta transición va de la mano del crecimiento de la escala y complejidad de los problemas abordados, a medida que las instancias incluyen más información y restricciones, los métodos exactos se vuelven muy caros computacionalmente, cediendo terreno a métodos aproximados capaces de entregar soluciones de calidad en tiempos razonables.

2.3. Problema de instalación de cámaras de videovigilancia

La literatura sobre la ubicación óptima de cámaras de vigilancia ha evolucionado desde modelos geométricos simplificados hacia enfoques que integran múltiples restricciones, distintos dominios de aplicación, tanto en entornos de dos y tres dimensiones, y una gran variedad de algoritmos validados en instancias reales. Al igual que en el caso de los desfibriladores externos automáticos, esta sección se va a dividir en dos partes: enfoques mono-objetivo, centrados principalmente en maximizar la cobertura o minimizar el número de cámaras, y enfoques multi-objetivo, buscando equilibrar esos mismos criterios incorporando algún objetivo adicional.

Sin embargo, antes de presentar la revisión, vamos a mencionar estudios que abordan variantes del OCP, pero que, por sus características y dominios específicos, no se incluyen en el análisis principal. Por ejemplo, en [Xu *et al.*, 2025] se investiga cómo desplegar sensores de cámaras en carreteras como parte del sistema de percepción de vehículos autónomos, considerando los errores de localización que afectan directamente al rendimiento y control del vehículo, lo cual lo aleja del objetivo de vigilancia urbana. En [Puligandla y Lončarić, 2020] se aborda el OCP aplicado a maquinaria pesada, determinando cómo instalar las cámaras para obtener una visión periférica ($360°$) y eliminar puntos ciegos en excavadoras, grúas, entre otros, aunque la lógica de cobertura es equivalente, el dominio es un vehículo y no una red urbana. En tercer lugar, [Cao *et al.*, 2021] buscan optimizar el despliegue de cámaras montadas en drones sobre terreno 3D, lo que introduce una complejidad geométrica que

no está tan presente en el OCP clásico. Luego, [Emoto y Ryo, 2025] buscan determinar las posiciones exactas de inicio y fin de cuerdas para el despliegue de cámaras suspendidas en ellas para el monitoreo de plagas de fauna silvestre, lo cual no es compatible con cámaras fijas. En [Yue *et al.*, 2025] y [Liao *et al.*, 2026] se aplican formulaciones multi-objetivo para determinar las posiciones de cámaras, pero en contextos muy distintos: el primero para detectar la caída de escombros de cohetes durante lanzamientos espaciales, y el segundo para la detección temprana de colisiones entre barcos y puentes. En conjunto, estos trabajos evidencian que la lógica del OCP se ha extendido a dominios muy diversos, lo cual es distinto a la aplicación tradicional de vigilancia urbana que se va a revisar a continuación.

En este contexto, un trabajo inicial es el de [Ahn *et al.*, 2016], donde los autores abordaron el OCP, considerando la instalación de cámaras en un entorno tridimensional (parámetros como orientación horizontal y vertical, altura, tipo de cámara), pero modelado en un espacio bidimensional. Para resolver el problema, propusieron un algoritmo de dos fases. En la primera fase, formularon un BIP a baja resolución, cuyo objetivo fue minimizar el número de cámaras necesarias. En la segunda fase, partiendo de la solución inicial obtenida, aplicaron el algoritmo de Hill Climbing (HC) a mayor resolución, con el fin de maximizar la cobertura bajo la restricción de las cámaras previamente determinada. El estudio se validó en cuatro instancias del mundo real de ciudades ubicadas en Seúl, Corea del Sur, utilizando diferentes configuraciones de grillas para representar los espacios. Los resultados mostraron que el algoritmo propuesto logró menores tiempos computacionales en comparación con métodos existentes, manteniendo la calidad de las soluciones. Además, demostró ser eficiente en instancias más complejas, bajo condiciones que no se podían resolver eficientemente con el método BIP tradicional. La principal limitación identificada fue que el método HC tiende a converger a óptimos locales. En cambio, otros algoritmos como PSO o GA presentan mayor capacidad para evadir estos óptimos locales. Como línea futura, los autores sugieren implementar nuevos algoritmos híbridos que mantengan un equilibrio entre calidad y tiempo.

Aunque es vital considerar la representación geométrica de las cámaras, en la literatura surgió la necesidad de incorporar el propósito específico de la vigilancia en el modelo. Por ello, en [Altahir *et al.*, 2018], los autores abordaron el OCP, considerando un modelamiento bidimensional, pero integrando dos factores: la tarea de la cámara, definida en cinco niveles: monitorear, detectar, observar, reconocer e identificar; y el área de riesgo clasificada en cuatro categorías: alto, moderado, bajo y ninguno. Para resolver el problema, propusieron un algoritmo greedy, cuyo objetivo fue optimizar la efectividad de la cobertura. Esta se calculó combinando la importancia de las regiones monitoreadas (según el nivel de riesgo) con la evaluación de la tarea de la cámara. El estudio no presenta imágenes detalladas de las instancias utilizadas, lo que limita la comprensión de los escenarios de validación. Aun así, los resultados mostraron que el método propuesto fue más eficiente que el enfoque de costo uniforme, el cual asigna la misma relevancia a todas las áreas, sin diferenciar niveles de riesgo ni tareas de vigilancia. Así, el algoritmo propuesto logró soluciones que priorizan las zonas críticas y las tareas de vigilancia, ofreciendo una instalación más realista y efectiva de cámaras. Como futura extensión, los autores plantean desarrollar un modelo que considere la superposición de coberturas basadas en el mapeo de riesgo y tareas, lo que permitiría

mejorar la planificación de cámaras en entornos con distintos niveles de prioridad.

Otro desafío fundamental en la literatura ha sido mejorar el rendimiento algorítmico para resolver estas instancias, evitando caer en óptimos locales. En esta línea, en [Wang *et al.*, 2019], los autores abordaron el OCP, considerando la instalación de cámaras en un entorno tridimensional (cuatro tipos de cámaras con parámetros fijos) y un modelamiento bidimensional del espacio. Para resolverlo, propusieron un nuevo algoritmo denominado LH-RPSO (Latin Hypercube-Resampling Particle Swarm Optimization), aplicado a dos variantes del problema: el problema de mínimo costo, cuyo objetivo fue determinar la instalación de cámaras con la menor inversión posible, garantizando un nivel mínimo de cobertura. Y el problema de máxima cobertura buscaba optimizar la cobertura total a partir del número de cámaras obtenido en la primera fase. La validación se realizó en una instancia real de un campus universitario, utilizando una imagen satelital de 782×732 píxeles, posteriormente preprocesada a 681×592 píxeles. El desempeño del algoritmo se compara con enfoques tradicionales como PSO (Particle Swarm Optimization) y RPSO (Resampling PSO). Los resultados mostraron que el LH-RPSO superó a los métodos comparados en ambos problemas, logrando soluciones más eficientes tanto en costo como en cobertura. Además, se demostró que el algoritmo es aplicable a instancias de gran escala, lo que refuerza su potencial para escenarios complejos de OCP. Como trabajo futuro, los autores señalaron la necesidad de mejorar la configuración de parámetros, así como la velocidad y eficacia del algoritmo, además de perfeccionar los modelos matemáticos para presentar entornos más realistas.

Llevando la aplicación de estos modelos hacia instancias más complejas, más recientemente en [Fuentes y Orozco, 2025], los autores abordaron el problema de OCP en la CDMX (Ciudad de México). El sistema se diseñó considerando cámaras y el espacio bajo una representación bidimensional. El objetivo de optimización se formuló como la suma de la evaluación de riesgo de cada región propuesta, incorporando: un factor de prioridad por población, una penalización por el número actual de cámaras colocadas en la región y una penalización adicional para regiones vecinas inmediatas. El estudio se aplicó a 16 alcaldías de la CDMX. Para resolver el problema, se implementaron dos modelos: PSO y un Algoritmo Genético (GA) con representación real. Las soluciones se representaron como hotspots, generados a partir de una cuadrícula que recomendaba las ubicaciones óptimas para instalar nuevas cámaras. Los resultados mostraron que el enfoque es prometedor para apoyar la toma de decisiones en seguridad urbana, y los autores señalaron que el sistema puede desarrollarse aún más mediante la aplicación de otros algoritmos bioinspirados, el diseño de estrategias híbridas, la incorporación de conjuntos de datos más amplios y diversos, la colaboración con otras disciplinas para mejorar la función objetivo y mejorar la calidad de las soluciones.

Tras revisar los trabajos anteriores que se limitaban a un solo criterio de optimización donde el costo o la cobertura se optimizan de forma aislada, lo que limita la perspectiva de un tomador de decisiones, surge la necesidad de evaluar ambos factores simultáneamente. En ese sentido, en [Yang *et al.*, 2018], los autores abordaron el OCP en sitios de construcción, caracterizados por disposiciones espaciales cambiantes y restricciones de costo, lo que aumenta la

complejidad asociada a la ubicación de múltiples cámaras. El estudio se centra en un entorno 2D y se aplica a un caso real en un sitio de construcción en Hong Kong, donde el área monitoreada correspondía a $6{,}000\,\mathrm{m}^2$. Se formularon tres problemas de optimización: maximizar la cobertura, minimizar el costo y un problema multi-objetivo que combina ambos objetivos. Para abordar estos problemas, el área fue discretizada en grillas de distintos tamaños, cuyos puntos fueron utilizados como ubicaciones candidatas y puntos de demanda. El modelo consideró parámetros como posición, ángulo de visión y tipo de cámara. Para la resolución, se emplearon distintos métodos según el objetivo: programación dinámica para el problema de máxima cobertura, Branch and Bound basado en programación lineal para el problema de mínimo costo, y el algoritmo NSGA-II para el problema combinado. Los resultados mostraron que los enfoques discretos fueron suficientes para producir buenos resultados usando distintos tipos de cámara, con tiempos computacionales razonables. Además, se sugiere que el modelo se puede extender a otros dispositivos de monitoreo o detección (por ejemplo, lectores RFID, routers WiFi o escáneres LiDAR, etc), debido a la similitud de cobertura. Como limitación, el estudio se basa en una discretización 2D, lo que constituye una aproximación del problema en un espacio continuo. Como línea futura, los autores proponen considerar un dominio 3D, explorar otros algoritmos de optimización y evaluar el sistema ante fallas de cámaras.

Extendiendo este enfoque hacia escenarios más reales, en [Heyns, 2021], el autor abordó el problema de OCP considerando múltiples factores: la existencia de varias zonas de cobertura, el uso de sistemas con cámaras de rotación completa ($360°$) y cámaras con cobertura limitada por su campo de visión (FOV), además de la diferenciación entre condiciones diurnas y nocturnas. En particular, algunas cámaras operaban con rotación completa durante el día, pero quedaban fijas hacia zonas de alto riesgo durante la noche. Los parámetros de las cámaras fueron definidos de manera fija: altura constante, rango máximo de $300\,\mathrm{m}$ en modo infrarrojo y un campo de visión horizontal de $70°$. El estudio planteó cuatro objetivos de cobertura: maximizar la cobertura nocturna en zonas de alto riesgo, maximizar la cobertura perimetral, maximizar la cobertura de respaldo de alto riesgo y maximizar la cobertura interior. La investigación fue desarrollada para proporcionar soluciones de vigilancia en un área protegida por la Rhino Pride Foundation (RPF) en Sudáfrica, utilizando una instancia representativa de la vida real. Para resolver el problema, se implementó una versión modificada del algoritmo NSGA-II, con variaciones en sus operadores para adaptarse a los requerimientos específicos. Los resultados mostraron que el algoritmo generó soluciones de alta calidad, maximizando la visibilidad en las tres zonas de cobertura y cumpliendo los cuatro objetivos planteados. La solución finalmente adoptada por la RPF ofreció una cobertura robusta con menos cámaras de las inicialmente planificadas, lo que resultó en una reducción significativa de costos de adquisición y mantenimiento. El estudio concluyó que este enfoque no es solo aplicable al OCP en contextos de conservación, sino que también presenta la oportunidad de extensión hacia otros dominios como sistemas de radar militar, sistemas de armas y detección de incendios forestales, donde la optimización de cobertura tiene un impacto directo en la seguridad y la gestión de recursos. Como línea futura de investigación, se propone comparar el modelo con métodos exactos para evaluar la calidad de las soluciones, así como incorporar modelos de decaimiento de distancia que representen de manera realista

la pérdida de efectividad de la cobertura.

Llevando esta dualidad de objetivos a un caso de estudio institucional, en [Agurob *et al.*, 2024], los autores abordaron el problema de CCTV Placement en un entorno bidimensional, formulado como un problema multi-objetivo: maximizar la cobertura de vigilancia y minimizar los costos de instalación. Desde el inicio, enfatizaron la importancia de balancear ambos factores para obtener resultados eficientes. El estudio se validó en el campus de Bukidnon State University (BukSU), donde las áreas abiertas representan un desafío de vigilancia. Para resolver el problema, se implementó el algoritmo NSGA-II, tomando como base el enfoque multi-objetivo propuesto por [Yang *et al.*, 2018] y adaptándolo a las condiciones del campus de BukSU. Esta adaptación permitió introducir refinamientos como distintas densidades de grilla y variaciones en la orientación de las cámaras, logrando soluciones más ajustadas a la realidad del campus. Los resultados mostraron que el enfoque propuesto permitió mejorar la cobertura sin incrementar mucho los costos, ofreciendo un marco práctico para optimizar los sistemas de vigilancia en instituciones educativas. Sin embargo, el estudio tiene sus limitaciones, al ser un análisis teórico-simulado, no se exploraron variables como condiciones ambientales, los obstáculos físicos y el comportamiento humano, factores que podrían afectar al rendimiento y cobertura. Los autores sugieren que proyectos futuros deberían integrar pruebas empíricas en entornos reales, ya que esto proporcionaría información valiosa que podría refinar las estrategias de planificación y evaluar la efectividad de los modelos.

Finalmente, para consolidar la base de todas estas variantes y abordarlas bajo una teoría unificada, en [Almousa, 2025], el autor ha abordado el OCP desde la perspectiva del SCP, recalcando cómo las técnicas desarrolladas para este último pueden aplicarse al primero. El estudio consideró cámaras en un entorno tridimensional y espacio en 3D, y se enfocó en dos variantes del problema: una mono-objetivo, cuyo objetivo es minimizar el número de cámaras necesarias, y otra multi-objetivo, que además de minimizar cámaras buscaba maximizar la cobertura. Para la validación se utilizaron 32 instancias académicas y 37 instancias basadas en escenarios reales. En el caso del problema mono-objetivo, se aplicaron técnicas de reducción de instancias provenientes de la literatura del SCP, lo que permitió disminuir significativamente los tiempos de resolución. Los modelos fueron formulados con PuLP y resueltos mediante el optimizador Gurobi. En el problema multi-objetivo se implementó el método de ϵ-constraint, resolviendo las instancias tanto antes como después de la reducción, lo que nuevamente mostró mejoras en eficiencia y calidad de las soluciones. Las conclusiones señalaron la necesidad de seguir explotando la relación entre el OCP y SCP, implementar técnicas de reducción que aun no han sido exploradas, y probar algoritmos para abordar tanto el problema mono-objetivo como el multi-objetivo. El principal desafío identificado continúa siendo el tiempo computacional, especialmente en instancias de gran escala.

Como se observó en el estado del arte del OCP, los estudios se centraron principalmente en dos objetivos: minimizar el número de cámaras a instalar (o minimizar costos) y maximizar la cobertura. En varios casos, estos objetivos se trabajaron de forma secuencial, utilizando los resultados del primero como entrada para el segundo, lo que limitaba la exploración de

escenarios alternativos de presupuesto y recursos. Con el paso del tiempo, ciertos modelos incorporaron mayor realismo en la representación del entorno físico, transitando desde formulaciones bidimensionales simplificadas hacia enfoques que incorporaban parámetros tridimensionales como oclusiones y variaciones del campo visual. En cuanto a los algoritmos, predominó el uso de metaheurísticas sobre métodos exactos, y al igual que en el DRP, la mayoría de los trabajos se validaron en instancias con datos reales, reforzando la relevancia práctica del problema. A pesar de que la mayoría de los estudios adoptó modelos mono-objetivo, también se identificaron enfoques multi-objetivo, aunque su aplicación en contextos urbanos a gran escala sigue siendo limitada, lo que constituye una brecha relevante que el presente trabajo busca abordar.

La Tabla 2 presenta un resumen de los estudios analizados para el OCP, detallando los objetivos de optimización, los métodos de resolución y las características de los conjuntos empleados.

Referencia	Problema	Entorno	Objetivos	Método de Solución	Datos
[Ahn *et al.*, 2016]	OCP (Secuencial)	Instalación 3D Espacio 2D	1) Min. cámaras (Baja res.) $\rightarrow$ 2) Max. Cobertura (Alta res.)	BIP + HC	4 instancias reales (Seoul)
[Altahir *et al.*, 2018]	OCP con riesgo y tareas	Instalación 2D Espacio 2D	- Max. Cobertura efectiva	Greedy	Instancias no detalladas
[Wang *et al.*, 2019]	OCP (Secuencial)	Instalación 2D Espacio 2D	1) Min. costo $\rightarrow$ 2) Max. cobertura	LH-RPSO, RPSO, PSO	Campus universitario
[Fuentes y Orozco, 2025]	OCP	Instalación 2D Espacio 2D	- Max. función compuesta (Riesgo + Población + Penalización)	PSO, GA	16 alcaldías de CDMX
[Yang *et al.*, 2018]	OCP (construcción)	Instalación 3D Espacio 2D	- Max. Cobertura - Min. Costo - Multi-obj: Costo vs Cobertura	NSGA-II modificado	1 caso real (Hong Kong)
[Heyns, 2021]	OCP (Vigilancia)	Instalación 3D Espacio 2D	- Multi-obj: Max. riesgo cubierto, perímetro, respaldo y cobertura interior	NSGA-II modificado	Área protegida Sudáfrica.
[Agurob *et al.*, 2024]	OCP (Multi-obj)	Instalación 2D Espacio 2D	- Multi-obj: Max. Cobertura vs Min. Costo	NSGA-II	Campus BukSU (Filipinas)
[Almousa, 2025]	OCP como SCP	Instalación 3D Espacio 3D	- Min. Cámaras - Max. Cobertura - Multi-obj: Min. Cámaras vs Max. Cobertura	Gurobi, ϵ-constraint	32 instancias académicas y 37 instancias reales

Tabla 2: Resumen de estudios sobre el Optimal Camera Placement (OCP). La flecha ($\rightarrow$) indica optimización secuencial (por fases). Instalación 3D: Parámetros físicos como altura, campo de visión, orientación, etc. Instalación 2D: Considerar que la cámara cubre un sector circular. Espacio 3D: plano de cobertura discretizado en tres dimensiones. Espacio 2D: plano de cobertura discretizado en cuadrícula.

Acá es posible identificar dos ejes de evolución, el modelado del problema y las técnicas de resolución adoptadas.

En cuanto al modelado, los primeros trabajos se formularon bajo supuestos simplificados, siendo la representación del entorno en planos bidimensionales una de las simplificaciones más recurrentes para mantener la complejidad computacional en niveles manejables. A

medida que la literatura avanzó, algunos modelos incorporaron mayor fidelidad al entorno físico, introduciendo parámetros tridimensionales para la instalación. Si bien estas representaciones aumentan el realismo del modelo, implican un costo computacional mucho mayor y restringen su aplicación a instancias de menor escala.

En cuanto a los métodos de resolución, predominaron las metaheurísticas, en específico los algoritmos genéticos (AG), justificado por la naturaleza, donde el espacio de búsqueda crece exponencialmente haciendo inviables los métodos exactos en instancias grandes. Asimismo, se aprecia una transición desde formulaciones mono-objetivo hacia multi-objetivo que permite explorar simultáneamente el equilibrio entre cobertura y costos de instalación. Sin embargo, los trabajos que adoptan el enfoque multi-objetivo se validan predominantemente en instancias de pequeña o mediana escala, dejando abierta la pregunta de su efectividad en entornos reales de mayor envergadura.

2.4. Resumen

Del análisis comparativo de ambos problemas emergen tanto similitudes estructurales como brechas metodológicas que motivan la presente investigación. En cuanto a las similitudes, ambos problemas comparten la misma lógica que consiste en seleccionar ubicaciones para cubrir la demanda bajo restricciones de recursos. Esta equivalencia estructural ha sido reconocida en la literatura que los vincula con formulaciones clásicas como el Set Covering Problem (SCP). Sin embargo, ambos problemas han sido abordados de manera independiente en la literatura, sin que exista un marco algorítmico unificado que los trate conjuntamente. En cuanto a las brechas, la revisión revela diferencias relevantes en el nivel de madurez de cada dominio. En el OCP, el enfoque multi-objetivo ya ha sido explorado, aunque su validación se ha limitado a instancias de pequeña o mediana escala. En el DRP, en cambio, los trabajos multi-objetivo son escasos. La gran mayoría de la literatura aborda el problema bajo un único criterio de optimización, siendo habitual asumir un número fijo de equipos sin considerar el costo como objetivo, lo que restringe al tomador de decisiones para evaluar escenarios alternativos. Esta asimetría en el tratamiento multi-objetivo del DRP constituye un vacío que la presente memoria busca cubrir.

La contribución de este trabajo se sustenta en tres pilares diferenciadores respecto a la literatura existente. Primero, integra el DRP y el OCP bajo un mismo marco algorítmico (MOEA/D), aprovechando su equivalencia estructural para proponer una solución unificada y transferible. Segundo, introduce el enfoque multi-objetivo en el DRP, generando un frente de Pareto que permite al tomador de decisiones evaluar soluciones eficientes. Tercero, la validación se realiza sobre instancias a gran escala derivadas de datos geográficos y probabilísticos reales (condados de la ciudad de Nueva York y alcaldías de la Ciudad de México), lo que confiere credibilidad empírica a los resultados y demuestra la aplicabilidad del enfoque.

CAPÍTULO 3
PROPUESTA DE SOLUCIÓN

En este capítulo se detalla la propuesta de solución para abordar el problema de optimización multi-objetivo que integra la reubicación de desfibriladores (DRP) y la ubicación de cámaras de video-vigilancia (OCP). La implementación se basa en el algoritmo evolutivo multi-objetivo MOEA/D.

El capítulo se organiza de la siguiente manera. Primero se comienza con la descripción del algoritmo MOEA/D, sus métodos de descomposición y la generación de vectores de peso (Secciones 3.1–3.3). Luego se presenta la adaptación realizada, incluyendo la representación y codificación de las soluciones, las funciones objetivo a optimizar del problema, las restricciones de factibilidad, las estrategias de inicialización de la población y los operadores de transformación (Secciones 3.4–3.8). Por último, se describe el mecanismo de reparación de factibilidad y se presenta un resumen de los parámetros del algoritmo (Secciones 3.9–3.10).

3.1. Multi Objetive Evolutionary Algorithm with Decomposition (MOEA/D)

Para abordar el problema de optimización multiobjetivo, se seleccionó el algoritmo MOEA/D (Multi-Objective Evolutionary Algorithm based on Decomposition) propuesto en [Zhang y Li, 2007]. El principio de este enfoque es descomponer un problema de optimización multi-objetivo en un conjunto de N subproblemas escalares (mono-objetivo). Esta descomposición se logra empleando un conjunto de vectores de pesos bien distribuidos, donde cada vector define un único subproblema. Posteriormente, el algoritmo resuelve de manera simultánea estos subproblemas, evolucionando una población, en la cual cada individuo representa la mejor solución encontrada para un subproblema específico.

La Figura 1 presenta el flujo conceptual del algoritmo MOEA/D. En la Figura se identifican dos fases principales:

- Inicialización: Aquí se leen los parámetros para la ejecución del algoritmo (tamaño de la población, tamaño de vecindades, entre otros). Inicialización de la población inicial y la vecindad. Definición de los N subproblemas e inicialización del punto ideal $\vec{z}$.
- Evolución: Se iteran los subproblemas aleatoriamente hasta cumplir el criterio de parada (por ejemplo, tiempo máximo o número de evaluaciones). Para cada subproblema se eligen padres para generar descendencia utilizando operadores de cruzamiento y mutación. Y se actualiza el vector $\vec{z}$. En caso de mejoras, se actualizan los vecinos.

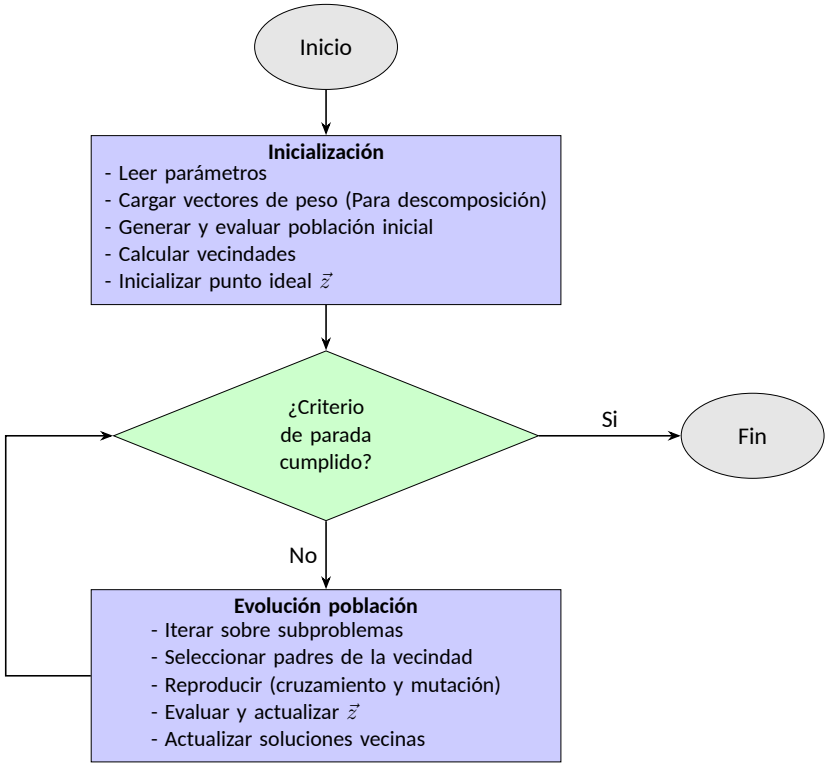


Figura 1: Diagrama de flujo del algoritmo MOEA/D.
Fuente: Elaboración propia.

En su propuesta original [Zhang y Li, 2007], el algoritmo es aplicado tanto a problemas continuos como a binarios. En el caso clásico de problemas continuos, los operadores de transformación son el Simulated Binary Crossover (SBX) para el cruzamiento y la Polynomial Mutation para la mutación. En cambio, para el caso de problemas binarios, se utiliza comúnmente el cruzamiento en un punto (One-point Crossover) y la mutación estándar (Bit-Flip Mutation).

Un componente importante en este algoritmo es el conjunto de vectores de peso. Estos vectores dividen el espacio de objetivos en múltiples regiones, permitiendo optimizar distintas partes del Frente de Pareto simultáneamente. Una distribución uniforme de los vectores de peso λ es crucial, ya que promueve la diversidad de la población y evita la convergencia prematura a una única zona del espacio de objetivos.

El Algoritmo 1 presenta el pseudocódigo del método implementado. Las líneas 1-5 corresponden a la fase de inicialización. Primero, en la línea 1, se inicializa el punto ideal $\vec{z}$ con valores positivos grandes, dado que MOEA/D trata todos los objetivos como problemas de minimización. Así, cualquier solución evaluada actualizará progresivamente este vector hacia valores menores. Este vector almacena el mejor valor encontrado para el objetivo individualmente y sirve como referencia para guiar la búsqueda en los métodos de descomposición. A continuación, en la línea 2 se genera la población inicial P. En la línea 4 se calculan las vecindades de cada subproblema, tomando las T soluciones con vectores de peso más cercanos

según la distancia euclidiana.

Algorithm 1: MOEA/D

Input:
n_{eval}: Numero máximo de evaluaciones;
N: Numero de subproblemas a descomponer;
W: un conjunto de vectores de peso bien distribuidos $\{\vec{w}^1, \ldots, \vec{w}^N\}$;
T: Tamaño de la vecindad;
Output:
P: La aproximación final del PF;

1 $\vec{z} = (+\infty, \ldots, +\infty)^\intercal$;
2 Generar un conjunto de soluciones aleatorias $P = \{\vec{x}^1, \ldots, \vec{x}^N\}$ in Ω;
3 **for** $i = 1, \ldots, N$ **do**
4 $\quad B^i \leftarrow \{i_1, \ldots, i_T\}$, tal que: $\vec{w}^{i_1}, \ldots, \vec{w}^{i_T}$ son los T vectores de peso mas cercanos a $\vec{w}^i$;
5 $\quad z_j \leftarrow$ mín$(z_j, f_j(\vec{x}^i))$; // $j \in \{1, \ldots, k\}$
6 **while** *no se cumple criterio de parada* **do**
7 $\quad$ **foreach** $i \in perm(\{1, \ldots, N\})$ **do**
8 $\quad\quad$ Reproducción: Generar una solución de prueba "$\vec{y}$" utilizando una solución con índices en B^i;
9 $\quad\quad$ Actualización de $\vec{z}$: $z_j \leftarrow$ mín$(z_j, f_j(\vec{y}))$; // $j \in \{1, \ldots, k\}$
10 $\quad\quad$ Actualización del vecindario:
11 $\quad\quad$ **foreach** $j \in B^i$ **do**
12 $\quad\quad\quad$ **if** $g^{pbi}(\vec{y}|\vec{w}^j) < g^{pbi}(\vec{x}^j|\vec{w}^j)$ **then**
13 $\quad\quad\quad\quad \vec{x}^j = \vec{y}$;
14 **return** P;

Las líneas 7-13 muestran la fase de evolución, que se ejecuta iterativamente hasta satisfacer el criterio de parada. En cada generación se recorren los subproblemas y se generan nuevas soluciones mediante los operadores de reproducción (línea 8), descritos en la sección 3.8. Tras evaluar al hijo, se actualiza el vector $\vec{z}$ si se ha encontrado un nuevo mejor valor para algún objetivo (línea 9).

Finalmente, entre las líneas 11-13, la nueva solución se compara con las soluciones actuales del vecindario utilizando una función de agregación escalar. En caso de que sea mejor, la solución de este subproblema es reemplazada. En el algoritmo 1 se ilustra este paso con la función PBI, cuya formulación matemática (junto a otros métodos de descomposición) se profundiza en la Sección 3.2. Además, si se desea cambiar el enfoque de descomposición, solo sería necesario modificar la función de la línea 12.

3.2. Métodos de descomposición

El enfoque principal de MOEA/D se basa en la idea de descomponer un problema multi-objetivo en varios subproblemas escalares, es decir, mono-objetivo. Esto se realiza mediante una función de agregación que combina distintos objetivos en un solo valor. En la implementación de [Zhang y Li, 2007] del algoritmo MOEA/D, se analizan tres enfoques, los cuales se detallan en [Miettinen, 1999]. A continuación, se describen brevemente estos tres enfoques:

- Suma ponderada (Weighted Sum Approach): Combina los objetivos mediante una suma lineal ponderada. Cada problema de optimización escalar se define de la forma:

$$\text{mín} \quad g^{ws}(x|\lambda) = \sum_{i=1}^{m} \lambda_i f_i(x), \quad \text{sujeto a } x \in \Omega$$

  donde λ corresponde a cada uno de los vectores de pesos.

  - Ventajas: Fácil de implementar.
  - Desventajas: Esta limitado a encontrar solución con Frentes de Pareto cóncavos para el caso de maximización y para el caso de minimización con Frentes de Pareto convexos.

- Tchebycheff (Tchebycheff Approach): Su objetivo es minimizar la distancia máxima entre una solución y un punto de referencia ideal. En este enfoque, cada problema de optimización escalar se define como:

$$\text{mín} \quad g^{te}(x|\lambda, z^*) = \underset{1 \le i \le m}{\text{máx}} \{\lambda_i |f_i(x) - z_i^*|\} \quad \text{sujeto a } x \in \Omega$$

  - Ventajas: Fácil de entender y flexible.
  - Desventajas: La función de agregación no es tan suave para un problema de optimización multi-objetivo continuo. Se necesita una gran cantidad de cálculos por cada iteración de los cuales varios resultados se descartarán.

- Intersección de límites (Boundary Intersection (BI) Approach): También conocido como Penalty Boundary Intersection, PBI. En este enfoque cada problema de optimización escalar se define de la forma:

$$\text{mín} \quad g^{bip}(x|\lambda, z^*) = d_1 + \theta d_2 \quad \text{sujeto a } x \in \Omega$$

  con θ un parámetro de penalización predefinido.

  - Ventajas: Ideal para abordar frentes de Pareto no cóncavos, para el mismo conjunto de parámetros PBI obtiene mejores soluciones que Tchebycheff, siendo las soluciones de PBI mucho más uniformes y mejor distribuidas.

- Desventajas: Hay que elegir un valor de θ. Un valor demasiado grande o pequeño va a disminuir la eficacia del método de penalización, afectando el equilibrio entre convergencia y diversidad.

Recalcar que la eficacia del algoritmo depende de manera importante de la configuración de sus parámetros. El proceso de selección de valores de parámetros se detalla en la Sección 4.2.

Finalmente, el resultado que se obtiene es el conjunto de mejores soluciones encontradas para cada uno de los N subproblemas, lo que constituye la aproximación final del Frente de Pareto.

A continuación, en la Sección 3.3 se describe la estrategia de generación de vectores de peso empleada. Posteriormente, las Secciones 3.4 en adelante detallan la adaptación del algoritmo para abordar el problema de reubicación de desfibriladores (DRP) y el problema de ubicación de cámaras (OCP), garantizando en todo momento que las soluciones pertenezcan al espacio factible.

3.3. Generación de Vectores de Peso

En el algoritmo MOEA/D, la descomposición se basa en un conjunto de vectores de peso $\lambda = (\lambda_1, \lambda_2)$, que cumple con las condiciones de no negatividad ($\lambda_1, \lambda_2 \geq 0$) y normalización ($\lambda_1 + \lambda_2 = 1$). Dado que el problema se planteó con dos objetivos, los pesos se generan sobre una recta, utilizando un paso $1/H$. La definición del i-ésimo vector se define como:

$$\lambda^{(i)} = \left(\frac{i}{H}, \frac{H-i}{H} \right), \quad i = 0, 1, \ldots, H \tag{16}$$

La cantidad de vectores generados está determinada por el parámetro H. Al considerar un rango $i = 0, 1, \ldots, H$, se obtiene un conjunto de tamaño $N = H + 1$. Por lo tanto, para obtener los vectores de peso de una población de $N = 100$ individuos, se estableció $H = 99$. Dando como resultado 100 vectores de peso equiespaciados, comenzando en $(0, 1)$ y terminando en $(1, 0)$. La distribución uniforme de estos vectores y su dirección desde el origen se ilustran en la Figura 2.

3.4. Representación

Una representación adecuada permite explorar eficientemente el espacio de búsqueda, facilitando el uso de operadores de transformación y garantizando que las soluciones sean interpretables dentro del contexto.

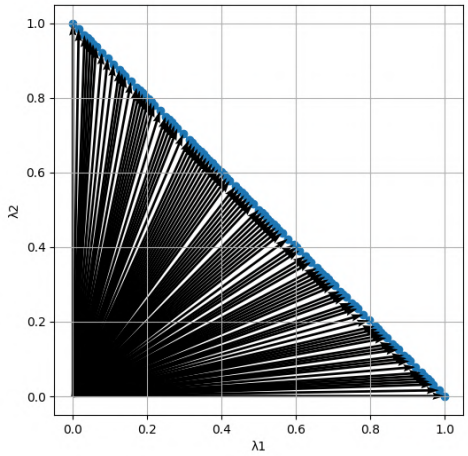


Figura 2: Representación gráfica de los vectores de peso para un problema de dos objetivos y una población de 100 individuos. Cada flecha representa un vector λ.

En la adaptación propuesta, las soluciones se representan mediante un vector binario de tamaño L. Donde L representa el número total de posibles ubicaciones para instalar un equipo. Cuando hay un valor de 1 en la posición i del vector, significa que se tiene o se ha instalado un equipo en la ubicación i, mientras que un valor de 0 indica que no se ha instalado.

La codificación binaria utilizada es simple y se ajusta de forma natural a la decisión modelada (instalar o no un equipo), lo que facilita tanto su interpretación como su implementación en los operadores de cruzamiento y mutación, permitiendo un control más directo de las soluciones durante el proceso evolutivo. Además, esta codificación acota el espacio de búsqueda al restringir las decisiones a variables binarias. En comparación, las codificaciones enteras o reales requerirían mecanismos adicionales de redondeo o reparación para garantizar la factibilidad, aumentando así la complejidad computacional. Finalmente, una representación explícita binaria simplifica la lectura e interpretación de la solución, lo que resulta determinante cuando se requiere tomar decisiones operativas.

En la Figura 3 se presenta un ejemplo de un cromosoma con $L = 7$ ubicaciones, numeradas desde 0 hasta 6. En el ejemplo hay instalados dos equipos en las posiciones 1 y 3.

Ubicación	0	1	2	3	4	5	6
Vector binario	0	1	0	1	0	0	0

Figura 3: Ejemplo de solución utilizando la representación.
Fuente: Elaboración propia.

3.5. Funciones Objetivo

Se consideran dos funciones objetivo, la primera siendo la cobertura de eventos y la segunda vinculada al costo de instalación de equipos.

3.5.1. Maximizar Cobertura

Se busca maximizar la cobertura probabilística de los eventos, ya que cada punto posee una cierta probabilidad de ocurrencia. Un evento nodo estará cubierto solo si existe al menos un equipo instalado dentro de un radio R de su posición. En la ecuación (17), M es el número total de eventos, Pr_j es la probabilidad de que ocurra un evento en la ubicación j y B_j es una variable binaria que indica si el evento j está cubierto o no.

Dado que MOEA/D está enfocado en objetivos de minimización, el valor de esta función se multiplica por -1, al momento de su evaluación, como se muestra en la Ecuación (18).

$$\text{máx} \sum_{j=1}^{M} Pr_j \cdot B_j \tag{17}$$

La función transformada para minimización queda expresada como:

$$\text{mín} \left(-1 \cdot \sum_{j=1}^{M} Pr_j \cdot B_j \right) \tag{18}$$

3.5.2. Minimizar Costos

Se busca minimizar los costos de instalación y/o reubicación de los equipos. Se considera un costo fijo c_1 por cada instalación y un costo c_2 en caso de reubicación, tal como se muestra en la ecuación (19)

$$\text{mín} \quad \#instalados \cdot c_1 + \#reubicados \cdot c_2 \tag{19}$$

3.6. Factibilidad

Una solución se considera factible si el costo total asociado a los equipos instalados (c_1) y reubicados (c_2) no excede un presupuesto máximo P, es decir, se tiene que cumplir que: $\#instalados \cdot c_1 + \#reubicados \cdot c_2 \leq P$.

3.7. Inicialización

El proceso de inicialización tiene como objetivo generar una población diversa de soluciones factibles, lo que resulta esencial para favorecer una adecuada exploración del espacio de búsqueda desde la primera etapa del algoritmo. Este proceso se estructura en dos: primero determinar la cantidad de recursos (los equipos) que utilizara cada individuo, y segundo la selección de la estrategia de ubicación para distribuir dichos recursos.

3.7.1. Cantidad de recursos a instalar

Con el fin de asegurar la diversidad poblacional y explorar el conjunto completo de combinaciones costo-cobertura, se implementaron cuatro estrategias para definir el número de equipos a instalar (denotado como α) en cada solución. Se definió el parámetro de selección de distribución (denotado como D_{init}) para configurar el comportamiento del algoritmo.

1. Aleatoria uniforme: se selecciona un número aleatorio con distribución uniforme entre 0 y el presupuesto máximo P ($\alpha \sim \mathcal{U}(0, P)$).
2. Aleatoria con distribución normal: se genera el número de equipos utilizando una distribución normal discreta truncada al intervalo $[0, P]$, centrada en la mitad del presupuesto ($\alpha \sim \mathcal{N}(\mu = P/2, \sigma = P/6)$). Como consecuencia, las configuraciones extremas de costo tienen menor representación en la población inicial.
3. Aleatoria normal con extremos anclados: Para asegurar que el algoritmo tenga conocimiento de los límites del problema, se refuerzan los extremos que son críticos para delimitar el frente de Pareto. Se fuerza a que el primer individuo se inicialice con $\alpha = 0$ y el último individuo con $\alpha = P$. El resto se genera utilizando la estrategia anterior.
4. Asignación estructurada : Esta estrategia busca un mayor control sobre la cantidad que se le asigna a cada individuo. En vez de usar la aleatoriedad, se asigna una cantidad creciente de equipos a los individuos según su índice en la población $(0, 1, \ldots, N)$. Al igual que la estrategia anterior, los extremos se mantienen anclados para garantizar la cobertura en el rango completo. Se controla con dos parámetros:
   - Exponente (γ): Controla la curva de distribución. Si el exponente es 1, la distribución es lineal, dejando las soluciones equidistantes. Si es mayor que 1, la distribución se comporta de manera exponencial, explorando con más énfasis soluciones de bajo costo y dispersando más las de alto costo.
   - Ruido (η): Se introduce una perturbación porcentual para evitar que cada población sea idéntica en cada ejecución.

3.7.2. Estrategia de Inicialización

Una vez definida la cantidad de equipos α asignada a un individuo, este valor se utiliza como parámetro de entrada para inicializar la solución. Para ello, se diseñó un parámetro de selección de estrategia (denotado como T_{init}) que define cómo interactúa el algoritmo con la infraestructura ya existente y con la adquisición de nuevos recursos.

Es importante destacar que la aplicabilidad de estas estrategias depende de la naturaleza del problema a resolver:

- En reubicación: dado que el modelo es flexible, las cuatro estrategias que se presentan a continuación son válidas y su uso se determina mediante el proceso de sintonización.
- En localización: al tener equipos inamovibles, el modelo se restringe exclusivamente a la estrategia de "Solo Comprar".

Las cuatro estrategias de inicialización son:

1. Estrategia de Solo Reubicar (OnlyMove): Se centra en redistribuir las posiciones de equipos ya existentes. El algoritmo selecciona de manera aleatoria α equipos de las posiciones preinstaladas y los desinstala temporalmente. Luego estos mismos α equipos se reinsertan aleatoriamente en los espacios vacíos. Cabe señalar que las posiciones liberadas vuelven a ser elegibles para la reinserción, por lo que existe una probabilidad de que un equipo vuelva a su posición original.
2. Estrategia de Solo Comprar (OnlyBuy): su objetivo es la expansión de la red. Respeta las ubicaciones con equipos preinstalados y utiliza la cantidad α para añadir esa cantidad exacta de nuevos equipos en ubicaciones candidatas vacías aleatoriamente.
3. Estrategia de Solo Reubicar o Solo Comprar (MoveOrBuy): combina las dos estrategias anteriores, bajo una lógica excluyente por individuo. En la cual cada individuo selecciona dinámicamente una de las dos estrategias mediante una probabilidad de selección denotada como p_{move}, es decir, elige si su comportamiento para esa ejecución será exclusivamente reubicar α equipos (OnlyMove) o exclusivamente adquirir α equipos nuevos (OnlyBuy).
4. Estrategia Híbrida: Combina ambas operaciones de manera simultánea en un mismo individuo dividiendo la cantidad de equipos α mediante un parámetro de proporción $\alpha_{split} \in [0, 1]$. De la cantidad total α, se calcula una fracción $\alpha_{move} = redondear(\alpha \cdot \alpha_{split})$ correspondiente a la cantidad de equipos preinstalados que serían desinstalados para su reubicación. La cantidad restante, $\alpha_{buy} = \alpha - \alpha_{move}$, corresponde a los equipos nuevos que serán adquiridos. El procedimiento opera de forma secuencial, primero se desinstalan los equipos activos liberando sus posiciones, luego se reubican

los α_{move} equipos en los espacios vacíos, y finalmente se instalan los α_{buy} equipos nuevos. Bajo esta configuración, el mecanismo permite que las nuevas unidades ocupen locaciones liberadas previamente por la operación de mover.

3.8. Operadores de Transformación

En el contexto del algoritmo MOEA/D, el proceso de transformación corresponde al uso de operadores evolutivos, en este caso, de cruzamiento y de mutación. Los operadores han sido adaptados a la naturaleza del problema para evitar soluciones infactibles.

3.8.1. Filtro de validación heurística

Antes de describir los operadores de cruzamiento y mutación, es necesario introducir un componente auxiliar que es usado en algunos casos. Con el objetivo de evitar la instalación de equipos en posiciones que no aporten al sistema, se diseñó una función heurística de validación denominada `EsBuenCandidato`. Esta función actúa como filtro de calidad en algunos operadores de cruzamiento y mutación, retornando verdadero cuando la posición candidata cumple un criterio mínimo de aporte, y falso en caso contrario. Su comportamiento se adapta según el problema abordado:

- En el problema de reubicación: Una posición es considerada válida si su aporte de cobertura marginal supera un umbral mínimo (≥ 0.0001).
- En el problema de localización: una posición es válida si el equipo cubre al menos un nodo que no esté cubierto por los equipos preinstalados.

3.8.2. Operador de cruzamiento

El cruzamiento tiene como objetivo combinar la información genética de dos soluciones padre para generar descendencia que herede características de ambos. Para este trabajo se implementaron y adaptaron cinco operadores. Es importante indicar que el algoritmo se configura para utilizar un único operador de cruzamiento por ejecución, el cual es seleccionado globalmente mediante el parámetro de configuración T_{cx}. Durante el ciclo evolutivo, la decisión de aplicar este operador viene dada por la tasa de cruzamiento (denotada como p_c). Si el cruzamiento no se activa, el hijo se genera clonando aleatoriamente a uno de los dos padres con la misma probabilidad.

Si bien la mecánica central de cada operador es común a ambos modelos, su aplicación se adapta para respetar cada problema:

- En reubicación: todos los nodos son aptos para moverse, por lo que no existe protección de nodos preinstalados y los operadores actúan sobre la totalidad del vector.
- En localización: los operadores garantizan que los nodos preinstalados se hereden obligatoriamente y se mantengan intactos en el hijo. El cruce se limita a los nodos candidatos.

A continuación, se describen los operadores implementados:

1. Cruzamiento por cuota de equipos: este operador se centra en la densidad de los equipos.
    - Funcionamiento: primero, se calcula la cantidad de equipos de ambos padres y se define un número objetivo de equipos para el hijo. Este número objetivo se obtiene seleccionando un valor aleatorio entre las cantidades de los padres. Tras heredar los nodos fijos (si el problema lo requiere), se recorre el vector de los padres de forma circular desde una posición inicial aleatoria. Si alguno de los padres tiene un equipo en la posición actual, el hijo lo hereda. El proceso se detiene en cuanto se alcanza la cantidad objetivo.
2. Cruzamiento basado en coincidencias: Utiliza la lógica de conjuntos (intersección y unión) para determinar la herencia.
    - Funcionamiento: se analiza el vector posición por posición. Si ambos padres tienen un equipo instalado en un nodo específico, el hijo lo hereda automáticamente. Si existe diferencia (solo uno de los padres tiene el equipo), el hijo tiene un $50\,\%$ de probabilidad de heredarlo.
3. Cruzamiento heurístico guiado por Cobertura: similar al proceso anterior, pero introduce un filtro.
    - Funcionamiento: si ambos padres tienen un equipo, el hijo lo hereda. Sin embargo, si solo un padre posee el equipo, la probabilidad de heredarlo del $50\,\%$ está sujeta a la evaluación de la función heurística EsBuenCandidato.
4. Cruzamiento en un punto: Es uno de los operadores clásicos en los algoritmos genéticos. Se realiza un intercambio de segmentos.
    - Funcionamiento: se selecciona un punto de corte aleatorio a lo largo del cromosoma. El hijo se forma copiando los genes del padre 1 desde el inicio hasta el punto de corte y los genes del padre 2 desde el punto de corte hasta el final del vector.
5. Cruzamiento en dos puntos: Este operador realiza un intercambio de un segmento central.

- Funcionamiento: se seleccionan dos puntos de corte aleatorios. El hijo hereda los extremos del cromosoma del Padre 1 (desde el inicio al primer corte, y desde el segundo corte al final), mientras que el segmento central proviene del Padre 2.

3.8.3. Operador de mutación

El operador de mutación es el encargado de introducir diversidad genética, evitando que el algoritmo converja prematuramente (quede atascado en óptimos locales) y explore nuevas áreas del espacio de búsqueda. Durante la evolución, la decisión de someter a un individuo al proceso de mutación viene dada por dos niveles de probabilidad. El primero corresponde a la tasa de entrada (denotada como p_m), que valida la aplicación de mutación. El segundo es interno y controla la intensidad de la alteración (como p_{bit} en el Bit-Flip). Esta distinción es importante porque no todos los operadores requieren una tasa de entrada, ya que algunos operadores fueron diseñados para aplicarse directamente sobre el individuo seleccionado.

Al igual que en la etapa de cruzamiento, el comportamiento del operador se adapta al tipo de problema abordado:

- En reubicación: todos los nodos son aptos para mutar.
- En localización: los nodos preinstalados son inmutables, limitando la mutación únicamente a los equipos nuevos instalados por el algoritmo.

La propuesta considera cinco operadores base más un esquema de mutación híbrida, seleccionado mediante el parámetro de configuración T_{mut}.

A continuación, se describen los operadores:

1. Perturbación simple: Diseñada para realizar microajustes en la solución. Este operador resulta adecuado para ajustes finos en instancias de tamaño reducido.
   - Funcionamiento: mediante la probabilidad p_{op1} decide entre dos opciones: a) eliminar un equipo activo aleatoriamente (reduciendo el costo total), o b) mover un equipo activo hacia una posición vacía aleatoria (manteniendo el costo, pero alterando la cobertura espacial).
2. Intercambio Probabilístico con Reversión (Probabilistic Swap with Reversion): Actúa revisando la red instalada, intentando optimizar la posición de cada equipo individualmente.
   - Funcionamiento: itera sobre cada equipo activo. Con una probabilidad de activación denotada como p_{swap}, el equipo se desinstala temporalmente y se busca una

nueva posición aleatoria entre los espacios vacíos. La nueva posición se acepta solo si supera el filtro heurístico, en caso contrario, se revierte el cambio reinstalando el equipo en la posición original.

3. Reubicación en Bloque con Filtro (Filtered Block Relocation): Se enfoca en renovar la distribución espacial de los equipos activos. Dado que las reinserciones están sujetas al filtro heurístico, la cantidad final de equipos puede reducirse si no se encuentran posiciones válidas.

    - Funcionamiento: desinstala aleatoriamente un porcentaje $\alpha_{swap} \in [0, 1]$ de los equipos activos e intenta reinsertar esa misma cantidad en posiciones vacías, validando cada inserción con el filtro heurístico.

4. Eliminación en Bloque (Block Deletion): Su objetivo es la reducción agresiva de los costos de la solución, forzando al algoritmo a evaluar si la cobertura se puede mantener con menos recursos.

    - Funcionamiento: selecciona y elimina aleatoriamente un porcentaje definido, denotado como $\alpha_{del} \in [0, 1]$, del total de equipos activos en el individuo.

5. Mutación Bit-Flip Adaptada (Adapted Standard Bit-Flip): Es el operador clásico para la representación binaria. Recorre todo el vector invirtiendo el estado de los nodos basándose en una probabilidad independiente por bit (denotada por p_{bit}).

    - Adaptación: en este caso el apagado (1 a 0) es directo, pero el encendido (0 a 1) requiere superar la función de validación EsBuenCandidato para evitar movimientos espaciales ineficientes. El valor de p_{bit} es un parámetro del algoritmo, que puede configurarse dependiendo del tamaño del vector de candidatos ($1/L$), del tamaño de la población ($1/N$) o tomar valores probabilísticos fijos.

6. Mutación Híbrida: Para potenciar la capacidad de exploración del algoritmo, se implementó un operador de mutación híbrida que combina dos operadores base en una única configuración.

    - Funcionamiento: se agrupan dos operadores base (por ejemplo, combinar eliminación en bloque con perturbación simple). Durante la evolución, cuando un individuo deba ser mutado, el algoritmo no ejecuta ambas técnicas, sino que en cada iteración se selecciona dinámicamente uno de los dos operadores base mediante una probabilidad de selección denotada como p_{hyb}.

Este diseño generó un extenso espacio de configuraciones combinatorias (incluyendo los operadores base y todas las parejas posibles). La responsabilidad de explorar este espacio recayó en la herramienta de sintonización (ParamILS), que se explicará en la sección 4.2, permitiendo ver si el uso de un operador simple o de una combinación híbrida ofrece el mejor rendimiento para cada problema. En la sección C del Anexo se detalla el mapeo exacto de todos los operadores de mutación contemplados en este trabajo.

3.9. Mecanismo de Reparación de Factibilidad

Durante la aplicación de los operadores de cruzamiento y mutación, las alteraciones genéticas pueden generar individuos descendientes cuyo costo total exceda el presupuesto máximo P, convirtiéndolos en soluciones infactibles. Para garantizar que todas las soluciones pertenezcan estrictamente al espacio factible, se implementó un mecanismo de reparación heurístico.

El funcionamiento de este mecanismo consiste en revisar si hay exceso de presupuesto en la nueva solución generada. Si se detecta un exceso, el algoritmo evalúa el aporte de cada equipo instalado en la solución hija. Posteriormente, se procede a desinstalar de manera iterativa los equipos que aporten la menor cobertura marginal al sistema, deteniendo el proceso hasta que se vuelva a cumplir con la restricción P.

Es importante mencionar que, en las instancias de pruebas experimentales, el presupuesto P se consideró igual a la cantidad de nodos candidatos. Así, la restricción de presupuesto nunca se violaría. Sin embargo, este mecanismo de reparación fue diseñado e integrado a la arquitectura base para dotar al algoritmo de robustez, asegurando que el modelo sea directamente aplicable frente a escenarios más restrictivos, por ejemplo, en contextos de presupuesto limitado.

3.10. Parámetros del algoritmo

La efectividad y eficacia del algoritmo MOEA/D dependen fuertemente de los valores de los parámetros. La tabla 3 resume los parámetros. Los valores específicos de parámetros serán seleccionados y presentados en la sección 4.2.

Parámetro	Símbolo	Descripción	Rango
Configuración General			
Evaluaciones máx.	n_{eval}	Número máximo de evaluaciones	$\mathbb{N}_{>0}$
Tiempo máx.	t_{max}	Tiempo límite de ejecución (segundos)	$\mathbb{R}_{\geq 0}$
Tamaño Población	N	Número de subproblemas/individuos	$\mathbb{N}_{>0}$
Tamaño Vecindad	T	Tamaño del vecindario con respecto a N	$[0, 1]$
Inicialización			
Estrategia Distribución	D_{init}	Selección de Distribución	$\{1, 2, 3, 4\}$
Exponente	γ	Controla la curva de distribución de equipos	$\mathbb{R}_{\geq 1}$
Ruido	η	Porcentaje de perturbación	$[0, 1]$
Estrategia Inicialización	T_{init}	Selección de Estrategia	$\{1, 2, 3, 4\}$
Prob. Move or Buy	p_{move}	Prob. de elegir estrategia Move sobre Buy	$[0, 1]$
Pct. Split	α_{split}	Fracción de recursos destinada a reubicación	$[0, 1]$
Operadores evolutivos			
Tasa Cruzamiento	p_c	Prob. de aplicar el operador de cruzamiento	$[0, 1]$
Tasa Mutación	p_m	Prob. de aplicar el operador de mutación	$[0, 1]$
Tipo Cruzamiento	T_{cx}	Selección del operador de cruce	$\{1, \ldots, 10\}$[a]
Tipo Mutación	T_{mut}	Selección del operador de mutación	$\{1, \ldots, 56\}$[b]
Prob. Op. 1	p_{op1}	Prob. de eliminar un equipo activo en la Perturbación Simple (complemento: mover)	$[0, 1]$
Prob. Swap	p_{swap}	Prob. de mover un equipo especifico	$[0, 1]$
Pct. Swap	α_{swap}	Porcentaje de equipos a reubicar	$[0, 1]$
Pct. Delete	α_{del}	Porcentaje de equipos a eliminar	$[0, 1]$
Prob. Bit-Flip	p_{bit}	Probabilidad manual para Bit-Flip Fijo	$[0, 1]$
Prob. Hybrid	p_{hyb}	Prob. de seleccionar el Operador A en esquemas de mutación híbrida	$[0, 1]$

[a] Los valores $\{1, \ldots, 5\}$ corresponden a operadores de localización (OCP) y $\{6, \ldots, 10\}$ a operadores de reubicación (DRP).

[b] Los valores $\{1, \ldots, 28\}$ corresponden a operadores de localización (OCP) y $\{29, \ldots, 56\}$ a operadores de reubicación (DRP).

Tabla 3: Resumen de parámetros configurables del algoritmo MOEA/D propuesto.
Fuente: Elaboración propia.

CAPÍTULO 4
EXPERIMENTOS Y RESULTADOS

En este capítulo se presentan los casos de prueba utilizados para la evaluación de la propuesta algorítmica para resolver el Problema de Reubicación de Desfibriladores (DRP) y el Problema de Ubicación de Cámaras (OCP). Primero, se describe el formato de las instancias ocupadas y los parámetros utilizados, luego se detalla el proceso de sintonización y, por último, se presentan los resultados obtenidos comparándolos con el método exacto (AMPL/Gurobi) para evaluar la calidad de las soluciones obtenidas.

4.1. Formato Instancias

Los archivos de entrada poseen una sintaxis compatible con AMPL/Gurobi. La Figura 4 muestra un ejemplo del formato de los casos de prueba utilizados en este estudio. A continuación se describe cada uno de estos parámetros:

- N_total: Número total de puntos (posibles ubicaciones de equipos más ubicaciones de eventos).
- P: Presupuesto máximo para la instalación de equipos.
- R: Radio de cobertura de un equipo.
- c1: Costo de instalación de un equipo.
- c2: Costo de reubicación de un equipo.
- nombre_instancia: Nombre de la instancia.
- coordx, coordy, flag, prob: Representan las características de cada punto de la instancia.
    - coordx, coordy: Coordenadas espaciales del punto (equipo o evento), expresadas en el sistema de referencia utilizado.
    - Flag: Indicador binario de si existe un equipo preinstalado ($flag = 1$) o no ($flag = 0$).
    - prob: Probabilidad asociada al evento. Su valor se encuentra en el intervalo $0 < prob_evento \leq 1$. En el problema de ubicación de desfibriladores corresponde a la probabilidad de un paro cardíaco y en el problema de ubicación de cámaras corresponde a la probabilidad de ocurrencia de delitos.

En ambos problemas, lo único que cambia son los radios de cobertura y las probabilidades asociadas a los eventos. Los demás parámetros se fijaron de acuerdo a las siguientes reglas:

- Presupuesto (P): Se estableció en el máximo posible con la idea de explorar distintos escenarios de cobertura y analizar el impacto de las restricciones de gasto. Se estableció igual a la suma de los costos de instalar en todos los puntos candidatos disponibles
- Costos (c1, c2): El costo de instalación (c1) se fijó en un valor unitario $(1{,}0)$, asumiendo que se utiliza solo un tipo de equipo. En el caso de desfibriladores, se consideró tanto la instalación como la reubicación. Se asumió que el costo de reubicación (c2) es un $20\,\%$ del costo de instalación, mostrando que mover un equipo es mucho más económico que adquirir e instalar uno nuevo. En el caso de las cámaras no se utilizó la opción de reubicación, ya que mover un sistema completo de cámaras implica problemas adicionales (electricidad, conexión, etc.). Por ello, en el primer problema se considera tanto c1 como c2, mientras que en el segundo solamente c1.

```
param N_total:= 1390 ;

param P:= 1175.0 ;
param R:= 200.0 ;
param c1:= 1.0 ;
param c2:= 0.2 ;
param nombre_instancia := "milpa alta_alto_impacto.dat" ;

param : coordx coordy flag prob_ohca:=
1 492372.991791 2121489.956805 1 0.0000
2 492552.062536 2121307.310484 1 0.0000
3 492354.061512 2121222.302079 1 0.0000
...
216 498400.918374 2121203.515846 0 0.2496
217 500562.345636 2125077.318721 0 0.3372
218 492546.161073 2121531.379358 0 0.0381
;
```

Figura 4: Ejemplo de archivo en formato AMPL/Gurobi

El formato utilizado corresponde al estándar de AMPL/Gurobi, lo que permite comparar los resultados algorítmicos con un método exacto de manera directa.

Simplificaciones del modelo Siguiendo una práctica común en problemas de localización y cobertura, se consideró que los puntos de demanda también pueden utilizarse como ubicaciones candidatas de instalación ([Zarandi *et al.*, 2011], [Máximo *et al.*, 2017],

[Atta *et al.*, 2018]). En los casos de pruebas utilizados en este trabajo, la demanda se representa mediante valores de probabilidad asociados a los puntos.

4.1.1. Instancias para el Problema de Reubicación de Desfibriladores (DRP)

Las instancias utilizadas para el problema de ubicación de desfibriladores (AEDs) fueron construidas para este trabajo. Como referencia metodológica, se tomó la idea de generar puntos de demanda a partir de la información censal [Máximo *et al.*, 2017]. En particular, se emplearon datos públicos provenientes del Censo de Estados Unidos (2010) [Federal User Community,] y del inventario público de desfibriladores externos automáticos (DEAs) de la Ciudad de Nueva York [Department of Health and Mental Hygiene (DOHMH),]. El proceso de obtención y preprocesamiento se detalla en el Anexo D.

Puntos candidatos (Block Groups del Censo 2010) Para representar la demanda y definir ubicaciones candidatas de instalación, se utilizó la capa geográfica Block Group (Grupo de bloques) del conjunto "Housing Demographics in the 2010 Census" provisto como servicio GIS ([Federal User Community,]). Cada grupo de bloques tiene un polígono con atributos geográficos. A partir de cada polígono se obtuvo su centroide y se extrajo la población asociada (`TOTPOP10`). Obteniendo un conjunto de 6,252 puntos candidatos en NYC. Los datos se encuentran en el sistema de referencia *EPSG:4326*[3]. Más detalles del proceso se incluyen en el Anexo D, Sección D.1.

Ubicaciones preinstaladas (Inventario público de desfibriladores externos automáticos) Las ubicaciones de DEAs se obtuvieron del portal NYC Open Data mediante el conjunto de datos "New York City Automated External Defibrillator (AED) Inventory" ([Department of Health and Mental Hygiene (DOHMH),]). El registro original contenía 7,315 registros. Tras una revisión inicial, se aplicó un preprocesamiento que consistió en: (1) la eliminación de atributos irrelevantes para el modelo y (2) la corrección de inconsistencias espaciales, corrigiendo registros cuya etiqueta de condado no coincidía con sus coordenadas geográficas, generando una versión depurada y homogénea para la integración con los puntos candidatos. El conjunto de datos incluye la ubicación geográfica de cada DEA en coordenadas EPSG:4326, lo que permitió su integración directa con la información censal. Más detalles del proceso se incluyen en el Anexo D, Sección D.2.

[3]EPSG:4326 corresponde al sistema de coordenadas geográficas WGS84 (World Geodetic System 1984). Este sistema utiliza coordenadas geográficas en grados decimales (latitud y longitud) sobre una proyección esférica de la Tierra y es el estándar más utilizado en aplicaciones como Google Earth o en sistemas de información geográfica (SIG).

Fronteras administrativas Para contextualizar y visualizar los datos se incorporaron las fronteras administrativas de los cinco borough/condado[4] de NYC (Staten Island, Bronx, Queens, Brooklyn y Manhattan), obtenidas desde servicios GIS públicos [Deparment of City Planning (DCP), 2020]. Estas fronteras también se encuentran en formato EPSG:4326. Más detalles del proceso se incluyen en el Anexo D, Sección D.3.

Justificación de Parámetros

- Radio de cobertura (R): Se fijó en 100 metros, siguiendo la metodología de [Tierney *et al.*, 2018] y la referencia previa de [Chan *et al.*, 2013]. Ese valor corresponde a la distancia máxima que un desfibrilador puede ser transportado por un transeúnte en aproximadamente 1.5 minutos, de acuerdo con las recomendaciones de la American Heart Association para la ubicación comunitaria de desfibriladores externos automáticos [Aufderheide y Hazinski, 2006]

- Probabilidades (prob_ohca): Para cada punto candidato i se definió una probabilidad proporcional a su población, normalizada por la población total del condado al que pertenece:

$$\texttt{prob}_i \;=\; \frac{\texttt{TOTPOP10}_i}{\sum\limits_{j \in \mathcal{B}(b(i))} \texttt{TOTPOP10}_j}$$

, donde $\texttt{TOTPOP10}_i$ corresponde a la población total del grupo de bloques i, $b(i)$ indica el condado de i, $\mathcal{B}(b(i))$ es el conjunto del grupo de bloques del mismo condado. De este modo, esto refleja que donde hay mayor cantidad de gente, hay mayor probabilidad de ocurrencia de un paro cardíaco extrahospitalario. Las poblaciones totales por condado se presentan en la Tabla 4.

Condado	Población
Staten Island	468,730
Bronx	1,385,108
Queens	2,230,722
Brooklyn	2,504,700
Manhattan	1,585,873

Tabla 4: Población total por condado (Censo 2010).

[4]En NYC, cada uno de los cinco boroughs se corresponde uno a uno con un county específico, aunque los nombres pueden variar según la fuente. En particular: Manhattan corresponde a New York County, Brooklyn a Kings County, Queens a Queens County, The Bronx a Bronx County y Staten Island a Richmond County.

Instancias generadas Para construir las instancias y calcular distancias en unidades métricas, los puntos en EPSG:4326 se reproyectaron a EPSG:32618 [5] , correspondiente al área de NYC. Luego se construyeron cinco instancias, una por condado. La Tabla 5 resume el número de puntos candidatos y desfibriladores externos automáticos por condado. Además, la Figura 5 muestra la distribución espacial de los puntos candidatos y los desfibriladores externos automáticos en la Ciudad de Nueva York, a través de sus cinco condados.

Tamaño Instancia	N°	Condado	#Candidatos	#DEAs	Total
Small	1	Staten Island	307	350	657
Medium	2	Bronx	1,123	1,028	2,151
	3	Queens	1,694	1,191	2,885
Large	4	Brooklyn	2,043	1,399	3,442
	5	Manhattan	1,085	3,347	4,432

Tabla 5: Tamaño de las instancias por condado (candidatos, desfibriladores externos automáticos (DEAS) y total).

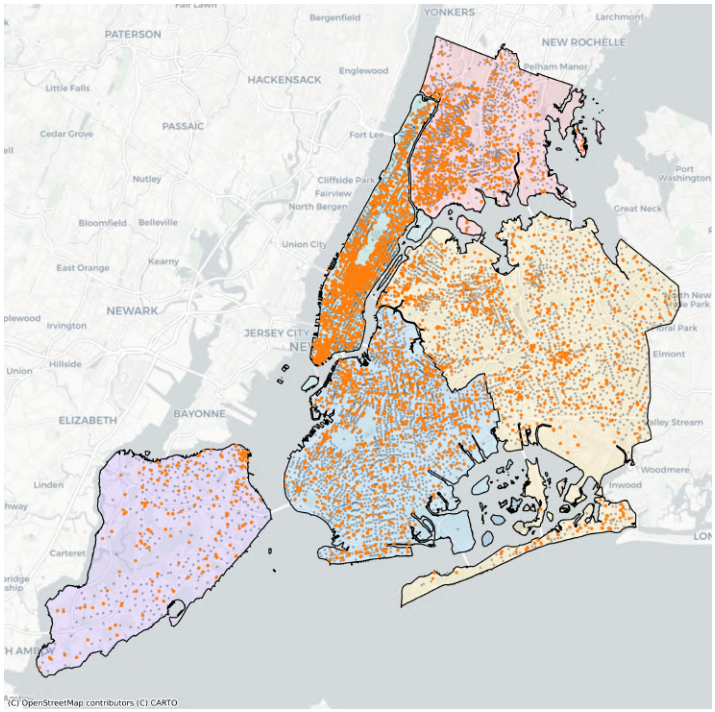


Figura 5: Distribución espacial de los puntos candidatos de instalación (puntos grises, centroides de grupos de bloques censales) y desfibriladores externos automáticos (DEAs) preinstalados (puntos naranjas) en la Ciudad de Nueva York, segmentada por condado (cada color representa un condado distinto).

[5]Corresponde a un sistema de coordenadas proyectadas (UTM), lo que permite trabajar directamente con distancias en metros (Por ejemplo: radios de cobertura).

4.1.2. Instancias para el Problema de Ubicación de Cámaras (OCP)

La información utilizada para construir las instancias del problema de cámaras proviene de [Fuentes y Orozco, 2025]. En este estudio, los autores recopilaron datos de fuentes oficiales y unificaron la información mediante flujos de trabajo en KNIME, generando archivos estandarizados en formato GeoJSON, lo que permitió integrarlos de manera directa en la creación de instancias para los experimentos.

En este trabajo se utilizaron directamente las versiones ya trabajadas por los autores correspondientes a cámaras de videovigilancia, reportes de incidencia delictiva y una capa geográfica para representar la división territorial (alcaldías).

Formato y sistemas de referencia (GeoJSON) Los conjuntos de datos de cámaras y reportes incluyen dos representaciones de coordenadas: (1) geometría proyectada en metros (EPSG:32614) y (2) latitud y longitud (EPSG:4326) en grados decimales. Además, la capa de división territorial se encontraba solamente en el formato proyectado (1). Dado que el cálculo de coberturas requiere utilizar medidas en unidades métricas, se usó el sistema EPSG:32614, manteniendo así el procedimiento empleado en las instancias de desfibriladores de utilizar un sistema de coordenadas proyectadas.

Es importante notar la diferencia respecto a las instancias de Nueva York detalladas anteriormente. Mientras que para la CDMX se utilizó EPSG:32614, para NYC se empleó EPSG:32618. Ambos estándares corresponden a proyecciones UTM (Universal Transverse Mercator), un sistema que permite medir distancias en metros sobre un plano 2D. La diferencia entre ambos códigos se debe a la ubicación geográfica de cada ciudad. La CDMX se encuentra en la zona 14 norte y NYC se encuentra en la zona 18 norte.

Cámaras de videovigilancia La información provino del C5 (Centro de Comando, Control, Cómputo, Comunicaciones y Contacto Ciudadano de la Ciudad de México) a través del INAI (Instituto Nacional de Transparencia, Acceso a la Información y Protección de Datos Personales). El conjunto original contenía 14,745 registros, y luego de nuestro preprocesamiento se eliminaron 35 cámaras sin información de alcaldía, obteniendo un total de 14,710 registros. Se consideraron únicamente los atributos relevantes para localizar y agrupar cámaras (alcaldía y posición geográfica). Otros atributos como identificadores, calle o esquina fueron descartados por no ser relevantes para el modelo.

Reportes de incidencia delictiva Los datos se obtuvieron del portal de datos abiertos de la CDMX, específicamente, la sección de Víctimas en carpetas de investigación de la FGJ. El conjunto inicial incluía 1,415,763 registros y contenía los eventos clasificados por los autores en tres niveles: no delictivos, delitos de bajo impacto y delitos de alto impacto. En este trabajo se aplicó un filtrado adicional para conservar únicamente los delitos de alto impacto,

obteniendo 193,371 registros. Se conservaron los atributos relevantes para el análisis espacial y la agregación territorial (categoría del delito, impacto, alcaldía y ubicación geográfica). Asimismo, se consideraron las categorías de delitos de alto impacto definidas en el estudio (ver Tabla 6).

Justificación de parámetros

- Radio de cobertura (R): Se fijó en 200 metros, de acuerdo con estudios de la CDMX [Díaz-Roman *et al.*, 2025] que reportan este alcance como estándar, aunque existen cámaras con radios mayores (hasta 1 kilómetro). Igualmente, se consideró un ángulo de cobertura de 360°, dado que este estándar se encuentra en proceso de implementación en la mayoría de los sistemas de videovigilancia en la CDMX. Por ende, todas las cámaras fueron modeladas con cobertura total en su radio de alcance.
- Probabilidades de delitos: Se calcularon a partir de los delitos de alto impacto (193,371 registros), distribuidos en 14 categorías (Tabla 6). Para cada categoría k, se definió su probabilidad como su frecuencia relativa:

$$\texttt{prob}_k \;=\; \frac{n_k}{\sum_{h=1}^{14} n_h},$$

, donde n_k corresponde al número total de registros asociado a la categoría k. A cada punto de demanda (delito) se le asignó la probabilidad correspondiente a su categoría.

Instancias generadas Utilizando la información espacial proyectada en el sistema EPSG:32614, se construyeron 16 instancias independientes, correspondientes a cada una de las alcaldías de la CDMX. La Tabla 7 presenta el tamaño y las características de cada instancia. Además, la Figura 6 ilustra la distribución espacial de los delitos de alto impacto y las cámaras en la CDMX, a través de las 16 alcaldías.

Categoría del delito	**Cant.**	**Prob. (%)**
Robo a transeúnte en vía pública con y sin violencia	65,212	33.72
Robo de vehículo con y sin violencia	48,263	24.96
Robo a negocio con violencia	27,212	14.07
Robo a repartidor con y sin violencia	12,424	6.42
Violación	10,177	5.26
Robo a pasajero a bordo del metro con y sin violencia robo	7,750	4.01
Homicidio doloso	7,370	3.81
Robo a pasajero a bordo de microbus con y sin violencia	4,405	2.28
Lesiones dolosas por disparo de arma de fuego	3,632	1.88
Robo a casa habitación con violencia	2,856	1.48
Robo a cuentahabiente saliendo del cajero con violencia	2,010	1.04
Robo a pasajero a bordo de taxi con violencia	1,394	0.72
Robo a transportista con y sin violencia	483	0.25
Secuestro	183	0.09
TOTAL	**193,371**	

Tabla 6: Frecuencia y probabilidad (%) de delitos de alto impacto por categoría

Tamaño Instancia	**N°**	**Alcaldía**	**#Delitos**	**#Cámaras**	**Total**
Small	1	Milpa Alta	1,175	215	1,390
	2	Cjpa. de Morelos	1,540	260	1,800
	3	La M. Contreras	2,887	318	3,205
	4	Tlahuac	6,705	551	7,256
	5	Xochimilco	6,951	457	7,408
	6	Azcapotzalco	8,915	758	9,673
Medium	7	Iztacalco	10,374	722	11,096
	8	Tlalpan	10,606	804	11,410
	9	Benito Juarez	10,598	878	11,476
	10	Coyoacan	11,346	973	12,319
	11	Miguel Hidalgo	12,780	1,022	13,802
	12	V. Carranza	13,383	1,085	14,468
	13	Alvaro Obregon	14,770	973	15,743
Large	14	Cuauhtemoc	20,675	1,563	22,238
	15	G. A. Madero	22,462	1,901	24,363
	16	Iztapalapa	38,034	2,230	40,264

Tabla 7: Instancias de Alcaldías

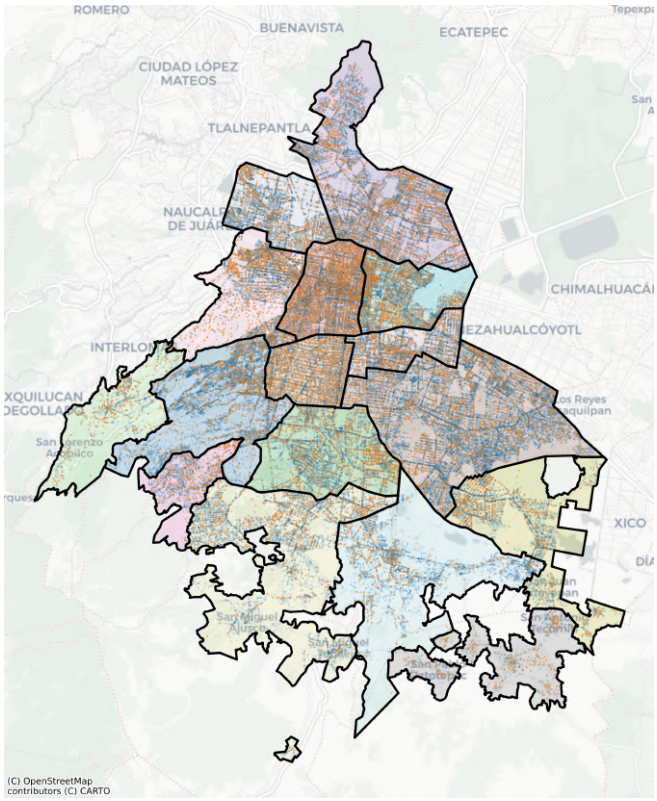


Figura 6: Distribución espacial de los reportes de incidencia delictiva (puntos azules) y ubicaciones de cámaras de video-vigilancia preinstaladas (puntos naranjas) en la Ciudad de México, segmentada por alcaldía (cada color representa una alcaldía distinta).

Simplificaciones específicas del problema de ubicación de cámaras Se adoptaron las siguientes simplificaciones para mantener el modelo abordable.

- Modelado bidimensional: Se representó el entorno en 2D.
- Sin obstrucciones físicas: No se consideraron edificios u otros elementos que pudieran bloquear la línea de visión de las cámaras.
- Modelo de cámara simplificado: No se incorporaron parámetros adicionales del dispositivo (altura, orientación, campo de visión o tipo de cámara), modelando la cobertura únicamente mediante un radio de alcance.

4.2. Sintonización de parámetros

Para garantizar un correcto desempeño del algoritmo MOEA/D en ambos problemas, se utilizó la herramienta ParamILS ([Hutter *et al.*, 2009]) para la sintonización automática de parámetros. El objetivo es investigar el espacio de configuración e identificar la combinación

ideal de parámetros y operadores que maximice la calidad de las soluciones. La descripción de los parámetros del algoritmo se presenta en la Sección 3.10 (Tabla 3).

Metodología de evaluación Dado que ParamILS requiere minimizar un solo valor objetivo, y los problemas descritos son multi-objetivo, se definió una métrica basada en la calidad del hipervolumen (HV). Específicamente, se utilizó el GAP porcentual con respecto a las soluciones de referencia obtenidas mediante el método exacto (AMPL), cuyo procedimiento de construcción se detalla en el Anexo B. La función objetivo a minimizar en el proceso se define como:

$$GAP = 100 \cdot \frac{(HV_{AMPL} - HV_{MOEAD})}{HV_{AMPL}}$$

Donde HV_{AMPL} es el hipervolumen del frente de Pareto generado por el método exacto, y HV_{MOEAD} es el obtenido por la configuración evaluada. Dado que la métrica del hipervolumen es sensible a la ubicación del punto de referencia, ambos valores se calculan empleando un punto de referencia común. Para asegurar la consistencia, los valores de referencia se determinaron aplicando el siguiente método para ambos problemas:

- Eje X (Cobertura): Se consideró la cobertura mínima posible del problema (sin instalar nada). Este número fue multiplicado por -0.99, para asegurar que ninguna solución tenga un valor de cobertura inferior.
- Eje Y (Costo): Se consideró el peor caso posible, donde se instala en todos los puntos candidatos (agotando el presupuesto), este número fue multiplicado por 1.005, así ninguna solución podrá tener un mayor valor de costo.

A continuación, la Tabla 8 presenta los valores de hipervolumen de referencia (HV_{AMPL}) y los puntos de referencia de cada instancia.

Instance	$Hv(AMPL)$	ref_1	ref_2
Staten Island	280.59	-0.01	307.31
Bronx	952.77	-0.10	1,124.12
Queens	1,474.79	-0.04	1,695.69
Brooklyn	1,757.46	-0.06	2,045.04
Manhattan	838.66	-0.20	1,086.09
Milpa Alta	62,393.41	-178.60	1,176.17
Cjpa. de Morelos	78,589.62	-254.91	1,541.54
La M. Contreras	154,291.95	-523.55	2,889.89
Tlahuac	915,235.15	-1,195.76	6,711.70
Xochimilco	2,348,314.29	-1,098.75	6,957.95
Azcapotzalco	583,529.53	-1,796.96	8,923.92
Iztacalco	424,363.52	-2,037.50	10,384.37
Tlalpan	3,938,879.71	-1,773.72	10,616.61
Benito Juarez	313,443.87	-2,296.56	10,608.60
Coyoacan	2,220,831.10	-2,341.45	11,357.35
Miguel Hidalgo	901,110.00	-2,654.80	12,792.78
V. Carranza	802,044.95	-2,668.24	13,396.38
Alvaro Obregon	4,177,035.52	-2,839.70	14,784.77
Cuauhtemoc	942,453.38	-4,283.19	20,695.67
G. A. Madero	3,025,853.35	-4,461.03	22,484.46

Tabla 8: Puntos de referencia e hipervolumen obtenidos por el método exacto (AMPL) por instancia

Es importante mencionar una diferencia clave en el proceso de sintonización para cada problema. Para el problema de desfibriladores, se utilizaron las cinco instancias disponibles. En cambio, para el problema de cámaras, se utilizaron las primeras quince instancias. La última instancia fue excluida del proceso debido a que el método exacto no logró resolverla. Esta limitación impidió que se pueda calcular el GAP de esa instancia, lo cual es clave para guiar a ParamILS.

Espacio de configuración y operadores Para evitar sesgos hacia un operador especifico, el espacio de búsqueda se diseñó para incluir múltiples variantes de cada componente algorítmico. Para el caso de desfibriladores se incluyeron múltiples operadores de inicialización, cruzamiento y mutación, y para el problema de cámaras se incluyeron múltiples operadores de cruzamiento y mutación. Además mencionar que, para todos los experimentos de sintonización, el parámetro numero de evaluaciones se fijo en $150,000$.

Las Tablas 9 y 10 muestran la configuración de parámetros para cada problema. Los parámetros se organizan en dos bloques: parámetros generales, activos en toda ejecución, y parámetros condicionales, cuya activación depende del tipo de operador seleccionado.

Parámetro	Símbolo	Valores Posibles	Valor Inicial
Tamaño Población	N	{200, 250, ..., 700} (Paso 50)	[500]
Tamaño Vecindad	T	{0.05, 0.1, 0.15, 0.2, 0.25}	[0.1]
Estrategia Distribución	D_{init}	{1, 2, 3, 4}	[4]
Exponente	γ	{1.0, 2.0, 3.0, 4.0, 5.0, 6.0, 7.0, 8.0, 9.0, 10.0}	[6.0]
Ruido	η	{0.05, 0.1, 0.15, 0.2, 0.25}	[0.1]
Estrategia Inicialización	T_{init}	{1, 2, 3, 4}	[3]
Prob. Move or Buy	p_{move}	{0.3, 0.4, 0.5, 0.6, 0.7}	[0.5]
Pct Split	α_{split}	{0.1, 0.2, 0.3, 0.4}	[0.3]
Tasa Cruzamiento	p_c	{0.7, 0.75, 0.8, 0.85, 0.9}	[0.8]
Tasa Mutación	p_m	{0.01, 0.05, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 0.99, 0.995}	[0.9]
Tipo Cruzamiento	T_{cx}	{6, 7, 8, 9, 10}	[7]
Tipo Mutación	T_{mut}	{29, 30, ..., 56} (28 variantes)	[33]
Prob. Op. 1	p_{op1}	{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9}	[0.5]
Prob. Swap	p_{swap}	{0.05, 0.1, 0.15, 0.2, 0.25}	[0.2]
Pct. Swap	α_{swap}	{0.05, 0.1, 0.15, 0.2}	[0.2]
Pct. Delete	α_{del}	{0.05, 0.1, 0.15, 0.2}	[0.2]
Prob. Bit-Flip	p_{bit}	{0.001, 0.005, 0.01, 0.05, 0.1}	[0.01]
Prob. Hybrid	p_{hyb}	{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9}	[0.5]

Tabla 9: Espacio de configuración de parámetros para el problema de desfibriladores (DRP).

Resultados de la sintonización Tras la convergencia del proceso de búsqueda con ParamILS, se obtuvieron las siguientes configuraciones de parámetros diferenciadas para cada problema, reflejo de sus distintas características estructurales. La Tabla 11 consolida los valores seleccionados. Para el problema de desfibriladores, la configuración resulta en una población de tamaño moderado ($N = 550$) con vecindarios reducidos ($T = 0{,}05 \cdot N$), combinando un cruzamiento heurístico guiado por cobertura con una mutación híbrida tipo Bit-Flip adaptada y perturbación simple. Por otro lado, para el problema de las cámaras, el proceso determinó una población más grande ($N = 650$) pero igual con un vecindario reducido ($T = 0{,}1 \cdot N$), con un cruzamiento basado en coincidencias con un operador base de mutación Bit-Flip adaptado, sin estrategia de inicialización dada por la estructura del problema.

4.3. Configuraciones experimentales

Los experimentos fueron ejecutados en un servidor con las siguientes características:

- Procesador: Intel Xeon Gold 5416S.

Parámetro	Símbolo	Valores Posibles	Valor Inicial
Tamaño Población	N	{400, 450, ..., 900} (Paso 50)	[650]
Tamaño Vecindad	T	{0.05, 0.1, 0.15, 0.2, 0.25}	[0.1]
Estrategia Distribución	D_{init}	{1, 2, 3, 4}	[4]
Exponente	γ	{1.0, 2.0, 3.0, 4.0, 5.0, 6.0, 7.0, 8.0, 9.0, 10.0}	[6.0]
Ruido	η	{0.05, 0.1, 0.15, 0.2, 0.25}	[0.1]
Estrategia Inicialización	T_{init}	-	-
Prob. Move or Buy	p_{move}	-	-
Pct. Split	α_{split}	-	-
Tasa Cruzamiento	p_c	{0.7, 0.75, 0.8, 0.85, 0.9}	[0.8]
Tasa Mutación	p_m	{0.01, 0.05, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 0.99, 0.995}	[0.9]
Tipo Cruzamiento	T_{cx}	{1, 2, 3, 4, 5}	[3]
Tipo Mutación	T_{mut}	{1, 2, ..., 28} (28 variantes)	[5]
Prob. Op. 1	p_{op1}	{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9}	[0.5]
Prob. Swap	p_{swap}	{0.05, 0.1, 0.15, 0.2, 0.25}	[0.2]
Pct. Swap	α_{swap}	{0.05, 0.1, 0.15, 0.2}	[0.2]
Pct. Delete	α_{del}	{0.05, 0.1, 0.15, 0.2}	[0.2]
Prob. Bit-Flip	p_{bit}	{0.001, 0.005, 0.01, 0.05, 0.1}	[0.01]
Prob. Hybrid	p_{hyb}	{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9}	[0.5]

Tabla 10: Espacio de configuración de parámetros para el problema de Cámaras (OCP).

- Memoria RAM: 32GB.

Cada una de las instancias fue ejecutada con 10 semillas diferentes, debido a la naturaleza estocástica del algoritmo propuesto. En cuanto a la configuración del algoritmo MOEA/D, se utilizaron los parámetros seleccionados mediante el proceso de sintonización (ver Tabla 11).El criterio de detención para todas las instancias se estableció en 150,000 evaluaciones de soluciones.

4.4. Resultados

Esta sección presenta los resultados experimentales obtenidos para ambos problemas de optimización. Para cada problema, los resultados se organizan en cuatro niveles de análisis: (i) la calidad algorítmica del método propuesto mediante métricas de hipervolumen, cantidad de soluciones y tiempo; (ii) el análisis espacial de las soluciones obtenidas mediante el Average Nearest Neighbor (ANN); (iii) un plan de implementación en fases; y (iv) indicadores de accesibilidad que cuantifican la mejora de la distancia del servicio antes y después de la optimización.

Parámetro	**Símbolo**	**Valor (Desfibriladores)**	**Valor (Cámaras)**
Tamaño Población	N	550	650
Tamaño Vecindad	T	0.05	0.1
Estrategia Distribución	D_{init}	3 (Aleatoria Normal con extremos anclados)	4 (Asignación Estructurada)
Exponente	γ	-	6.0
Ruido	η	-	0.1
Estrategia Inicialización	T_{init}	2 (Only Buy)	N/A
Prob. Move or Buy	p_{move}	-	N/A
Pct. Split	α_{split}	-	N/A
Tasa Cruzamiento	p_c	0.9	0.8
Tasa Mutación	p_m	0.6	-
Tipo Cruzamiento	T_{cx}	7 (Cruzamiento Heurístico guiado por Cobertura)	2 (Cruzamiento basado en Coincidencias)
Tipo Mutación	T_{mut}	47 (Mutación Híbrida: Bit-Flip Adaptado + Perturbación Simple)	5 (Mutación Bit-Flip Adaptado $p_{bit} = 1/N$)
Prob. Op. 1	p_{op1}	0.4	-
Prob. Swap	p_{swap}	-	-
Pct. Swap	α_{swap}	-	-
Pct. Delete	α_{del}	-	-
Prob. Bit-Flip	p_{bit}	0.005	-
Prob. Hybrid	p_{hyb}	0.5	-

Tabla 11: Configuración de parámetros seleccionada tras la sintonización.

4.4.1. Problema de Reubicación de Desfibriladores (DRP)

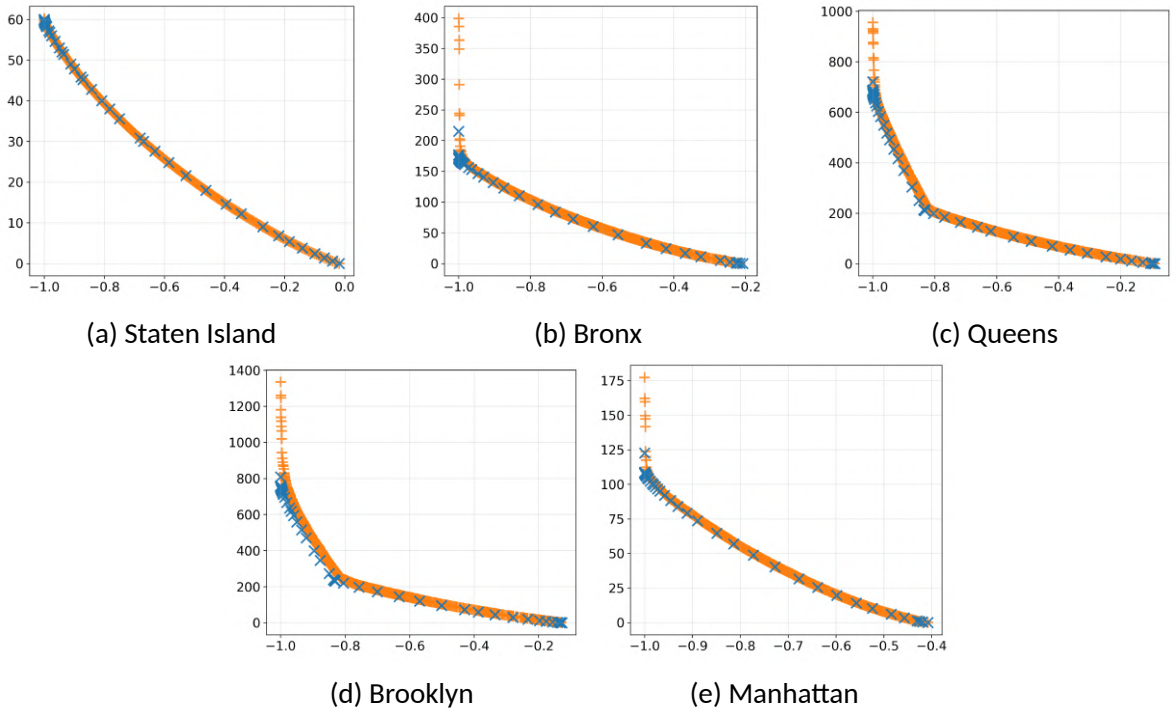
Calidad Algorítmica Las Tablas 12 y 13 presentan las métricas de calidad para las cinco instancias del problema de desfibriladores. Se reportan el número de soluciones no dominadas obtenidas por AMPL y MOEA/D (agregado a partir de diez ejecuciones con diferentes semillas), los valores de hipervolumen con su diferencia porcentual (gap) y los tiempos de ejecución con su respectiva diferencia porcentual.

Instancia	#Cand.	#DEAs	Total	Número de soluciones			y_{ref1}	y_{ref2}	Hipervolumen		Gap HV
				AMPL	MOEA/D	Ratio			AMPL	MOEA/D	
Staten Island	307	350	657	40	**300**	7.50x	-0.02	60.26	35.27	**36.37**	-3.13 %
Bronx	1,123	1,028	2,151	51	**686**	13.45x	-0.21	399.00	262.28	**263.92**	-0.63 %
Queens	1,694	1,191	2,885	60	**853**	14.22x	-0.09	956.76	**726.93**	726.40	+0.07 %
Brooklyn	2,043	1,399	3,442	67	**736**	10.99x	-0.13	1,335.73	**1,009.82**	1,000.10	+0.96 %
Manhattan	1,085	3,347	4,432	42	**515**	12.26x	-0.40	177.38	79.77	**80.68**	-1.14 %

Tabla 12: Métricas de calidad para instancias del DRP

Instancia	T_{AMPL} (s)	$T_{MOEA/D}$ (s)		Gap T
		Prom.	Total	
Staten Island	**12.85**	3.63	36.26	-182.26 %
Bronx	**41.59**	13.25	132.47	-218.53 %
Queens	**34.85**	16.28	162.83	-367.23 %
Brooklyn	**43.74**	20.66	206.58	-372.31 %
Manhattan	**327.16**	33.47	334.66	-2.29 %

Tabla 13: Tiempos de ejecución para instancias del DRP



(a) Staten Island (b) Bronx (c) Queens

(d) Brooklyn (e) Manhattan

Figura 7: Frentes de Pareto para las instancias del Problema de Reubicación de Desfibriladores (DRP). El eje-y muestra el costo y el eje-x muestra la cobertura probabilística. Los símbolos naranjas representan el frente agregado de las diez ejecuciones de MOEA/D. Los símbolos azules corresponden al frente obtenido por AMPL

En cuanto al número de soluciones no dominadas, MOEA/D genera entre 7 y 14 veces más soluciones que AMPL en todas las instancias (columna Ratio). Este resultado es esperable: al agregar diez ejecuciones independientes, el frente de MOEA/D acumula diversas soluciones provenientes de distintas trayectorias de búsqueda (factor estocástico), lo que se traduce en un mayor hipervolumen agregado.

En términos de hipervolumen, las diferencias porcentuales oscilan entre -3.13 % y +0.96 %.

Además, recordar que un valor negativo indica que MOEA/D supera a AMPL en hipervolumen. Las instancias donde MOEA/D obtiene un mejor resultado son Staten Island, Bronx y Manhattan. Por otro lado, Queens y Brooklyn, son los únicos casos donde AMPL supera a MOEA/D, lo que puede atribuirse a que ambas instancias concentran la mayor cantidad de puntos candidatos. La Figura 7 ilustra los frentes de Pareto para cada instancia. En los casos de Bronx, Queens y Brooklyn se puede observar un gran quiebre, que marca el umbral a partir del cual las soluciones necesitan instalar nuevos desfibriladores externos automáticos, dado que las soluciones anteriores a ese punto operan exclusivamente mediante reubicación.

En términos de tiempo de ejecución, ambos métodos se ejecutaron diez veces por instancia. Dado que AMPL es determinista, todas sus ejecuciones producen el mismo resultado, por lo que se muestra el tiempo promedio. Por otro lado, MOEA/D es estocástico y cada ejecución produce un resultado distinto. Sus resultados se agregan para construir el frente final, por lo que se reportan tanto el tiempo promedio por ejecución como el tiempo total acumulado. La diferencia porcentual se calcula sobre el tiempo promedio de AMPL y el tiempo acumulado de MOEA/D. Bajo esta comparación, AMPL resulta más rápido en todas las instancias. Sin embargo, el tiempo promedio de MOEA/D es entre 2 y 4 veces menor que el de AMPL en las cuatro primeras instancias. La excepción es Manhattan, donde el tiempo que se demora AMPL en resolver una vez esta instancia, MOEA/D puede completar aproximadamente diez ejecuciones independientes.

Análisis Espacial Con el objetivo de evaluar la distribución geográfica de DEAs en las soluciones obtenidas, se calculó el Índice de Vecino más Cercano Promedio (ANN, Average Nearest Neighbor), utilizado en estudios previos de distribución de DEAs ([Shi *et al.*, 2025]). Un valor $R < 1$, indica que los DEAs siguen una distribución agrupada (clustered), $R \approx 1$ sugiere una distribución aleatoria, y $R > 1$ indica una tendencia hacia una distribución uniforme espacial.

Borough	**Área (km^2)**	R_{ant}	p-value$_{\text{ant}}$	R_{opt}	p-value$_{\text{opt}}$	ΔR
Staten Island	151	0.2352	$<$0.001	1.2114	$<$0.001	+0.9762
Bronx	110	0.2432	$<$0.001	1.0227	0.121	+0.7795
Queens	283	0.2572	$<$0.001	1.0615	$<$0.001	+0.8044
Brooklyn	180	0.2515	$<$0.001	1.0586	$<$0.001	+0.8070
Manhattan	59	0.2186	$<$0.001	0.6996	$<$0.001	+0.4811

Tabla 14: Índice ANN antes y después de MOEA/D — DRP

Como se observa en la Tabla 14, todas las instancias presentan valores iniciales cercanos a $R \approx 0{,}23$ ($p < 0.05$), lo que confirma la existencia de zonas concentradas de DEAs en la distribución actual. Tras la optimización, cuatro de los cinco condados alcanzan valores $R > 1.0$, pero solo en tres de ellos (Staten Island, Queens y Brooklyn) el resultado es significativo ($p < 0.05$), lo que permite afirmar que la redistribución hacia patrones más uni-

formes es robusta. En el caso de Bronx, el valor $R = 1.02$ no es significativo ($p = 0.121$), por lo que la distribución conseguida no difiere estadísticamente de un patrón aleatorio. Hay solo una excepción que es Manhattan, con un valor $R = 0.7$ ($p < 0.05$), lo que indica que la redistribución aun exhibe un agrupamiento, esto puede atribuirse a que la superficie es significativamente menor que la del resto de zonas, lo que condiciona de manera natural la aglomeración de los DEAs.

Plan de implementación por fases La Tabla 15 presenta un plan de implementación incremental en tres fases, derivado de la selección de soluciones representativas del frente de Pareto que se aproximan a niveles de cobertura del $33\,\%$, $67\,\%$ y $100\,\%$ del total de puntos de demanda.

Borough	**Fase 0**			**Fase 1**			**Fase 2**			**Fase 3**			**Total**		
	R.	C.	$	R.	C.	$	R.	C.	$	R.	C.	$	R.	C.	$
Staten Island	0	0	0.0	60	0	12.0	89	0	17.8	152	0	30.4	301	0	60.2
Bronx	2	0	0.4	167	0	33.4	262	0	52.4	312	250	312.4	743	250	398.6
Queens	3	0	0.6	327	0	65.4	464	0	92.8	100	777	797.0	894	777	955.8
Brooklyn	4	0	0.8	374	0	74.8	542	0	108.4	-53	1,161	1,150.4	867	1,161	1,334.4
Manhattan	0	0	0.0	104	0	20.8	171	0	34.2	611	0	122.2	886	0	177.2
Total	9	0	1.8	1,032	0	206.4	1,528	0	305.6	1,122	2,188	2,412.4	3,691	2,188	2,926.2

Tabla 15: Plan de implementación en fases para el DRP. R.: desfibriladores externos automáticos reubicados, C.: desfibriladores externos automáticos comprados (nuevos), $: costo incremental acumulado de la fase. Los valores de costo corresponden a: reubicación: 0.2, compra: 1.0

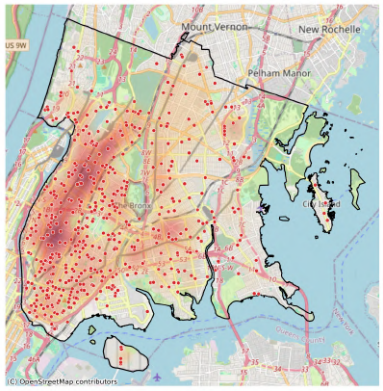
Lo primero a observar es que las dos primeras fases operan exclusivamente mediante reubicación en todos los condados, lo que permite alcanzar niveles intermedios de cobertura sin incurrir en costos de adquisición. Recién la compra de desfibriladores externos automáticos se reserva para la Fase 3, con excepción de Staten Island y Manhattan, donde la solución de mayor cobertura encontrada se logra exclusivamente a través de la reubicación.

Cabe mencionar tres aspectos particulares. Primero, en tres condados (Bronx, Queens y Brooklyn) la Fase 0 contempla la reubicación de un número pequeño de desfibriladores (entre 2 y 4), en lugar de partir desde cero. Esto se debe a que el algoritmo no garantiza preservar la solución trivial de costo nulo a través de las generaciones, lo que constituye una limitación del diseño actual. Segundo, en Brooklyn la Fase 3 reduce la cantidad de reubicaciones respecto a la Fase 2 (-53 unidades), dado que en esa etapa la solución de mayor cobertura encontrada combina menor reubicación con instalación masiva (1161 DEAs nuevos). Tercero, en Staten Island y Manhattan el vector de solución no estaba restringido a mantener el número mínimo de DEAs preinstalados, por lo que el algoritmo prescindió de equipos cuya ubicación no contribuía a la cobertura: Staten Island utiliza 301 DEAs (49 menos que los originales), y Manhattan utiliza solo 2,105 DEAs (1,242 menos que los preinstalados).

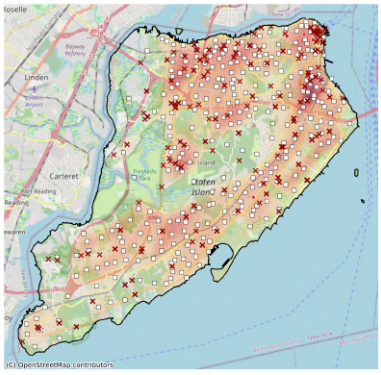
La Figura 8 presenta la visualización geográfica de las soluciones para las instancias de Staten Island y Bronx, comparando el estado inicial (Fase 0) con la solución optimizada (Fase 3). El fondo de color corresponde a una estimación de densidad de Kernel (KDE) construida a partir de los puntos de demanda ponderados por su probabilidad de ocurrencia de paro cardíaco: las zonas con mayor intensidad (rojo) indican alta concentración de demanda, mientras que las zonas transparentes reflejan baja densidad. Sobre este fondo se representan las instalaciones mediante tres símbolos: un círculo rojo (●) indica un DEA preinstalado que se mantiene en la solución, un cuadrado blanco (□) indica una instalación nueva propuesta por el algoritmo, y una cruz roja (×) indica un DEA preinstalado que fue removido durante la optimización. Las instancias restantes se presentan en el Anexo E.



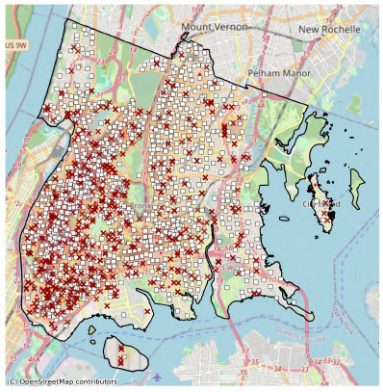
(a) Fase 0 Staten Island.



(b) Fase 0 Bronx.



(c) Fase 3 Staten Island.



(d) Fase 3 Bronx.

Figura 8: Visualización geográfica de las Fases 0 y 3 para Staten Island y Bronx. El fondo representa la densidad de demanda estimada mediante KDE, donde las zonas más rojas, indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a DEAs preinstalados, los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D, y las cruces rojas a DEAs removidos durante la optimización. Las filas superiores e inferiores muestran el estado inicial y optimizado respectivamente

Análisis de accesibilidad Las Tablas 16 y 17 reportan dos indicadores de accesibilidad comparando la Fase 0 con la Fase 3: la distancia máxima de servicio (Z_1) y la distancia promedio ($\bar{d}$). La primera, definida como la mayor distancia entre un punto de demanda y el desfibrilador externo automático más cercano, representa el criterio minimax de evaluación del peor caso posible. Este indicador es un estándar en la literatura de localización de emergencias para evaluar la equidad espacial (véase, por ejemplo, [Li *et al.*, 2025]). Se consideraron dos escenarios. El primero evalúa únicamente los puntos de demanda (16). El segundo in-

cluye además los puntos cuyos desfibriladores externos automáticos preinstalados fueron removidos durante la optimización (17), dado que a estas ubicaciones no se les asignó una probabilidad de demanda en la instancia, por lo que el algoritmo no tenía incentivo para cubrirlas, lo que constituye una limitación a considerar.

Borough	$Z_{1,\text{ant}}$ (m)	$Z_{1,\text{opt}}$ (m)	ΔZ_1 (m)	ΔZ_1 (%)	$\bar{d}_{\text{ant}}$ (m)	$\bar{d}_{\text{opt}}$ (m)
Staten Island	1,283	1,106	-177	-13.8	445	4
Bronx	1,735	1,757	+22	+1.2	222	12
Queens	1,766	1,042	-723	-41.0	321	5
Brooklyn	2,841	1,903	-938	-33.0	234	3
Manhattan	2,654	2,692	+37	+1.4	132	16

Tabla 16: Z_1 y distancia promedio antes/después — Escenario 1: puntos de demanda

Borough	$Z_{1,\text{ant}}$ (m)	$Z_{1,\text{opt}}$ (m)	ΔZ_1 (m)	ΔZ_1 (%)	$\bar{d}_{\text{ant}}$ (m)	$\bar{d}_{\text{opt}}$ (m)
Staten Island	1,283	1,106	-177	-13.8	208	143
Bronx	1,735	1,757	+22	+1.2	116	58
Queens	1,766	2,567	+802	+45.4	188	75
Brooklyn	2,841	1,903	-938	-33.0	139	39
Manhattan	2,654	2,692	+37	+1.4	32	67

Tabla 17: Z_1 y distancia promedio antes/después — Escenario 2: incluye ubicaciones con desfibriladores externos automáticos preinstalados removidos

En el primer escenario, tres instancias reducen Z_1 en más de 150 metros, con Brooklyn registrando la mayor mejora (-938 m). Sin embargo, Bronx y Manhattan presentan pequeños incrementos en Z_1, lo que sugiere que en esas instancias la optimización no logró cubrir la totalidad de los puntos de demanda. Cabe señalar que en todos los condados $Z_{1,opt}$ supera los 1000 metros, lo que confirma que aún existen puntos de demanda sin cobertura efectiva. Por otro lado, la distancia promedio disminuyó en todos los casos, con valores menores a 20 metros. Este resultado se explica por la reubicación de desfibriladores externos automáticos directamente sobre los puntos de demanda, lo que reduce la distancia a cero en esos puntos.

En el segundo escenario, los resultados son consistentes con el primer escenario en cuatro de las cinco instancias. La excepción es Queens, donde Z_1 aumenta en 802 metros. Este incremento se debe a una ubicación con un desfibrilador externo automático preinstalado que fue removido, quedando a más de 2,500 metros del siguiente desfibrilador más cercano, lo que refleja directamente la ausencia de incentivo en el modelo para cubrir estas ubicaciones. La distancia promedio disminuye en cuatro instancias y solo Manhattan registra un aumento, atribuible parcialmente a la eliminación de desfibriladores externos automáticos en ubicaciones preinstaladas bien posicionadas.

Conclusiones del problema de reubicación de desfibriladores En síntesis, los resultados del DRP muestran que MOEA/D obtiene un desempeño competitivo frente al método exacto, logrando superar a AMPL en 3 de las 5 instancias comparables en términos de hipervolumen, con diferencias porcentuales que oscilan entre -3.13 % y +0.96 % (donde un valor negativo indica que MOEA/D supera a AMPL). El análisis espacial confirma que la optimización mejora consistentemente la distribución geográfica de los desfibriladores externos automáticos, con distribuciones post-optimización significativamente más uniformes en tres de los cinco condados, mientras que Manhattan exhibe una distribución aún agrupada. El plan de fases evidencia que las dos primeras fases son suficientes para alcanzar niveles intermedios de cobertura exclusivamente mediante reubicación, sin incurrir en costos de adquisición, y que la compra de nuevos desfibriladores externos automáticos se concentra en la Fase 3. Finalmente, el análisis de accesibilidad muestra una reducción de Z_1 de hasta 938 metros en Brooklyn, aunque Bronx y Manhattan presentan incrementos pequeños.

La principal limitación identificada es que ninguna instancia alcanza cobertura total, por lo que las soluciones de la Fase 3 corresponden a la mejor cobertura encontrada y no necesariamente a la cobertura completa del territorio. Adicionalmente, el algoritmo eliminó DEAs preinstalados en Staten Island y Manhattan al no existir un incentivo explícito para mantenerlos, lo que constituye una limitación del modelo actual que se aborda en las líneas de trabajo futuras.

4.4.2. Problema de Ubicación de Cámaras (OCP)

Calidad Algorítmica Las Tablas 18 y 19 presentan las métricas de calidad para las 16 instancias del problema de cámaras. Al igual que en el análisis anterior, se reportan el número de soluciones no dominadas obtenidas por AMPL y MOEA/D (agregado a partir de diez ejecuciones independientes), los valores de hipervolumen con su diferencia porcentual (gap) y los tiempos de ejecución con su respectiva diferencia porcentual.

En cuanto al número de soluciones no dominadas, MOEA/D genera entre 1 y 6 veces más soluciones que AMPL en todas las instancias (columna Ratio). Este resultado es esperable: al agregar diez ejecuciones independientes, el frente de MOEA/D acumula diversas soluciones provenientes de distintas trayectorias de búsqueda (factor estocástico), lo que se traduce en un mayor hipervolumen agregado.

En términos de hipervolumen, las diferencias porcentuales oscilan entre -4.53 % y +2.84 %, excluyendo a Iztapalapa, para la cual no es posible calcular la diferencia dado que AMPL no encontró una solución. Además, recordar que una diferencia negativa indica que MOEA/D supera a AMPL en hipervolumen. Bajo este criterio, MOEA/D obtiene un mayor hipervolumen en 9 de las 15 instancias comparables, destacando los casos de Iztacalco, Venustiano Carranza y Milpa Alta. Por el contrario, en los escenarios donde AMPL logra superar a MOEA/D, los resultados más favorables para el solver se presentan en Tlalpan, Xochimilco y Tlahuac.

Instancia	#Crím.	#Cám.	Total	Número de soluciones			y_{ref1}	y_{ref2}	Hipervolumen		Gap HV
				AMPL	MOEA/D	Ratio			AMPL	MOEA/D	
Milpa Alta	1,175	215	1,390	34	**121**	3.56x	-178.60	120.12	4,804.84	**4**, **917**.**45**	-2.34 %
Cjpa. de Morelos	1,540	260	1,800	37	**106**	2.86x	-254.91	105.10	4,249.23	**4**, **298**.**06**	-1.15 %
La M. Contreras	2,887	318	3,205	22	**56**	2.55x	-523.55	57.06	2,285.70	**2**, **336**.**21**	-2.21 %
Tlahuac	6,705	551	7,256	35	**132**	3.77x	-1,195.76	142.14	**15**, **486**.**86**	15,301.80	+1.19 %
Xochimilco	6,951	457	7,408	49	**300**	6.12x	-1,098.75	369.37	**103**, **521**.**82**	100,618.76	+2.80 %
Azcapotzalco	8,915	758	9,673	19	**57**	3.00x	-1,796.96	56.06	3,032.38	**3**, **076**.**73**	-1.46 %
Iztacalco	10,374	722	11,096	9	**16**	1.78x	-2,037.50	15.01	494.19	**516**.**58**	-4.53 %
Tlalpan	10,606	804	11,410	47	**321**	6.83x	-1,773.72	465.46	**144**, **398**.**43**	140,295.78	+2.84 %
Benito Juarez	10,598	878	11,476	7	**10**	1.43x	-2,296.56	9.01	239.79	**244**.**56**	-1.99 %
Coyoacan	11,346	973	12,319	31	**133**	4.29x	-2,341.45	139.14	**22**, **537**.**06**	22,276.72	+1.16 %
Miguel Hidalgo	12,780	1,022	13,802	27	**69**	2.56x	-2,654.80	68.07	4,105.60	**4**, **126**.**56**	-0.51 %
V. Carranza	13,383	1,085	14,468	16	**31**	1.94x	-2,668.24	30.03	1,508.67	**1**, **553**.**59**	-2.98 %
Alvaro Obregon	14,770	973	15,743	40	**211**	5.28x	-2,839.70	239.24	**57**, **108**.**40**	56,623.89	+0.85 %
Cuauhtemoc	20,675	1,563	22,238	5	**6**	1.20x	-4,283.19	5.00	223.03	**223**.**70**	-0.30 %
G. A. Madero	22,462	1,901	24,363	28	**105**	3.75x	-4,461.03	111.11	**12**, **690**.**98**	12,666.68	+0.19 %
Iztapalapa	38,034	2,230	40,264	0	**180**	-	-7,324.70	232.23	0.00	**65**, **307**.**85**	-

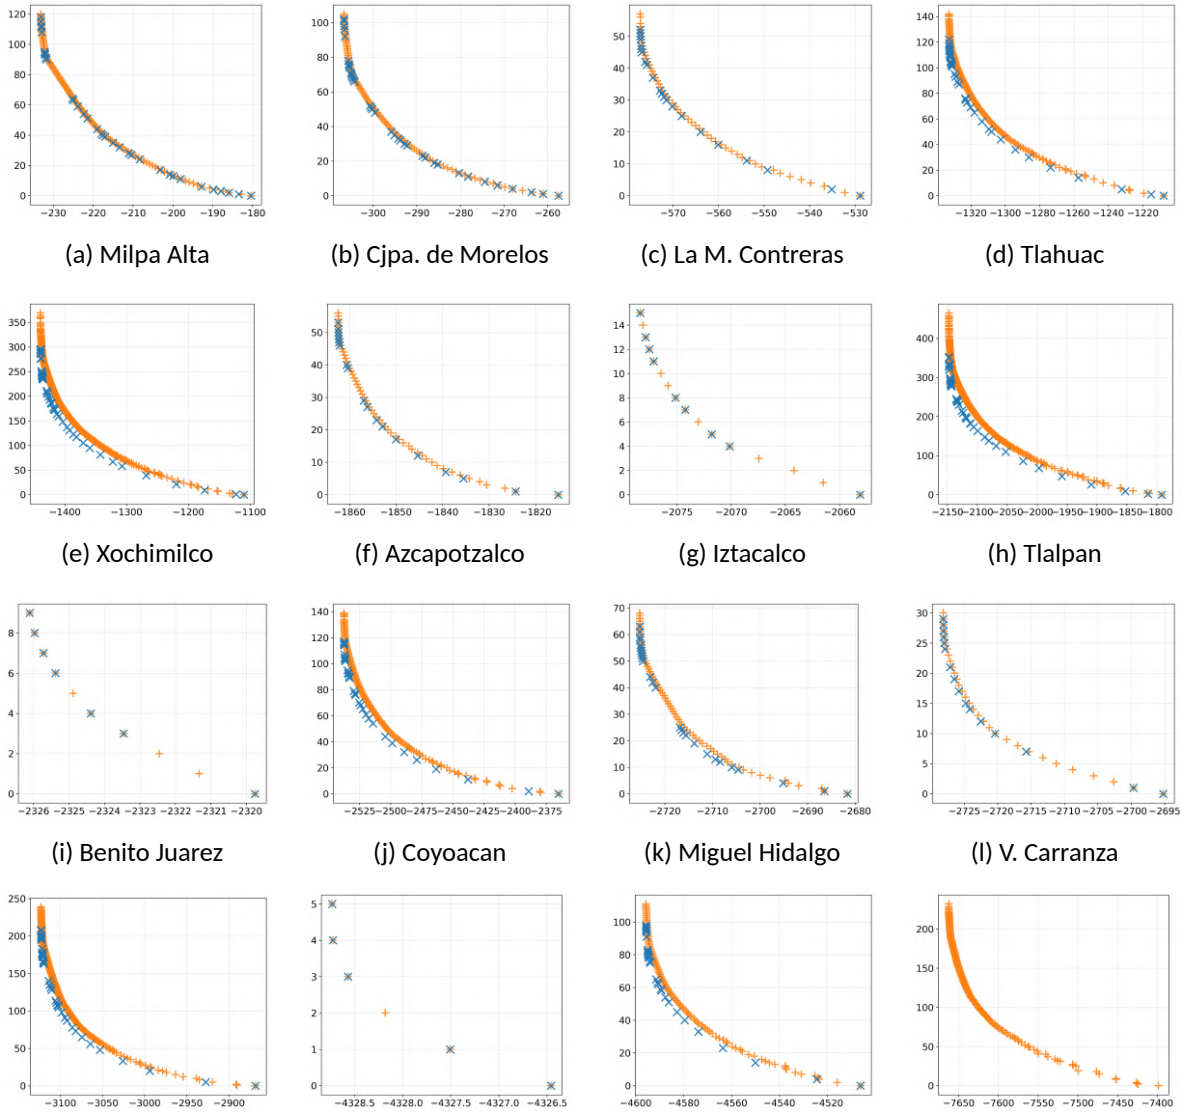
Tabla 18: Métricas de calidad para instancias del OCP

Instancia	T_{AMPL} (s)	$T_{MOEA/D}$ (s)		Gap T
		Prom.	Total	
Milpa Alta	**14**.**19**	5.56	55.59	-291.80 %
Cjpa. de Morelos	**19**.**71**	6.96	69.64	-253.28 %
La M. Contreras	**36**.**00**	12.44	124.37	-245.50 %
Tlahuac	**100**.**65**	28.76	287.63	-185.77 %
Xochimilco	**133**.**54**	30.58	305.84	-129.01 %
Azcapotzalco	**173**.**77**	39.16	391.57	-125.34 %
Iztacalco	**306**.**75**	47.96	479.57	-56.34 %
Tlalpan	**194**.**00**	47.20	472.01	-143.30 %
Benito Juarez	**305**.**73**	49.59	495.87	-62.19 %
Coyoacan	**261**.**75**	50.25	502.49	-91.97 %
Miguel Hidalgo	**645**.**82**	65.94	659.43	-2.11 %
V. Carranza	**585**.**34**	81.21	812.11	-38.74 %
Alvaro Obregon	**513**.**35**	88.99	889.91	-73.35 %
Cuauhtemoc	**1**, **569**.**36**	161.05	1,610.55	-2.62 %
G. A. Madero	1,823.52	143.32	**1**, **433**.**20**	+21.40 %
Iztapalapa	-	227.24	2,272.45	-

Tabla 19: Tiempos de ejecución para instancias del OCP

Con lo anterior se observa una relación entre el desempeño de ambos métodos y el número mínimo de cámaras requeridas para alcanzar cobertura completa según cada algoritmo. En instancias donde este número es reducido, como Cuauhtemoc (5 cámaras), Benito Juarez (9) e Iztacalco (15), MOEA/D logra superar a AMPL, dado que con pocas cámaras se puede alcanzar la cobertura total. En cambio, en instancias donde la cobertura completa requiere una cantidad elevada de cámaras, como Xochimilco (295 según AMPL, 369 según MOEA/D) y Tlahuac (122 según AMPL, 142 según MOEA/D), MOEA/D requiere más cámaras que AMPL para alcanzar cobertura completa, incurriendo en un mayor costo que penaliza su desempeño en hipervolumen.

La Figura 9 ilustra los frentes de Pareto para cada instancia.



(a) Milpa Alta (b) Cjpa. de Morelos (c) La M. Contreras (d) Tlahuac

(e) Xochimilco (f) Azcapotzalco (g) Iztacalco (h) Tlalpan

(i) Benito Juarez (j) Coyoacan (k) Miguel Hidalgo (l) V. Carranza

(m) Alvaro Obregon (n) Cuauhtemoc (ñ) G. A. Madero (o) Iztapalapa

Figura 9: Frentes de Pareto para las instancias del Problema de Ubicación de Cámaras (OCP). El eje-y muestra el costo y el eje-x muestra la cobertura probabilística. Los símbolos naranjas representan el frente agregado de las diez ejecuciones de MOEA/D. Los símbolos azules corresponden al frente obtenido por AMPL

En términos de tiempo de ejecución, ambos métodos se ejecutaron diez veces por instancia, siguiendo el mismo esquema descrito para el problema de desfibriladores. AMPL resulta más rápido en 14 de las 15 instancias comparables. Sin embargo, a medida que las instancias crecen, se reduce la diferencia de tiempo, y además el tiempo promedio por ejecución de MOEA/D es entre 2 y 12 veces menor que el de AMPL. La única excepción es Gustavo A. Madero donde el tiempo agregado de MOEA/D es inferior al de AMPL, lo que implica que en el tiempo que se demora AMPL en resolver una vez esta instancia, MOEA/D puede completar

diez ejecuciones independientes. Para Iztapalapa no se dispone del tiempo de referencia de AMPL, ya que el método exacto no logró resolver la instancia.

Alcaldía	**Área (km^2)**	R_{ant}	p-value$_{\text{ant}}$	R_{opt}	p-value$_{\text{opt}}$	ΔR
Milpa Alta	46	0.8185	$<$0.001	1.0617	0.031	+0.2432
Cjpa. de Morelos	45	0.9071	0.004	1.0685	0.012	+0.1614
La M. Contreras	24	1.0067	0.819	1.1168	$<$0.001	+0.1101
Tlahuac	65	0.9331	0.003	1.0349	0.079	+0.1018
Xochimilco	106	0.7978	$<$0.001	1.0047	0.798	+0.2068
Azcapotzalco	34	1.1824	$<$0.001	1.2377	$<$0.001	+0.0552
Iztacalco	23	1.3038	$<$0.001	1.3244	$<$0.001	+0.0206
Tlalpan	112	0.9416	0.002	1.1102	$<$0.001	+0.1686
Benito Juarez	27	1.3135	$<$0.001	1.3207	$<$0.001	+0.0072
Coyoacan	54	1.1271	$<$0.001	1.2293	$<$0.001	+0.1023
Miguel Hidalgo	47	1.1349	$<$0.001	1.1913	$<$0.001	+0.0564
V. Carranza	34	1.1902	$<$0.001	1.2237	$<$0.001	+0.0335
Alvaro Obregon	70	1.0461	0.006	1.1792	$<$0.001	+0.1331
Cuauhtemoc	33	1.3382	$<$0.001	1.3403	$<$0.001	+0.0022
G. A. Madero	87	1.1394	$<$0.001	1.1893	$<$0.001	+0.0499
Iztapalapa	114	1.1957	$<$0.001	1.2300	$<$0.001	+0.0342

Tabla 20: Índice ANN antes y después de MOEA/D — OCP

Análisis Espacial Como se observa en la Tabla 20, la distribución inicial de cámaras es heterogénea entre alcaldías. Los valores de R_{ant} oscilan entre 0.80 (Xochimilco) y 1.34 (Cuauhtemoc). A diferencia del problema de desfibriladores, donde todas las instancias partían con distribuciones fuertemente agrupadas, en este caso varias alcaldías ya presentan distribuciones iniciales uniformes ($R > 1, p < 0{,}05$). La única excepción es La Magdalena Contreras, cuyo valor p es más alto que $p > 0{,}05$, lo que indica que no es significativo, es decir, la distribución conseguida no difiere estadísticamente de un patrón aleatorio.

Tras la optimización, todas las alcaldías alcanzan valores $R > 1.0$. En catorce de ellas el resultado es significativo ($p < 0.05$), lo que permite afirmar que la redistribución hacia patrones más uniformes es robusta. En las dos instancias restantes (Tlahuac y Xochimilco), el valor R es mucho más cercano a 1 con ($p > 0.05$), por lo que no es posible afirmar que la distribución optimizada difiera de un patrón aleatorio.

Plan de implementación por fases La Tabla 21 presenta un plan de implementación incremental en tres fases, que funciona igual a lo planteado en el problema de los desfibriladores.

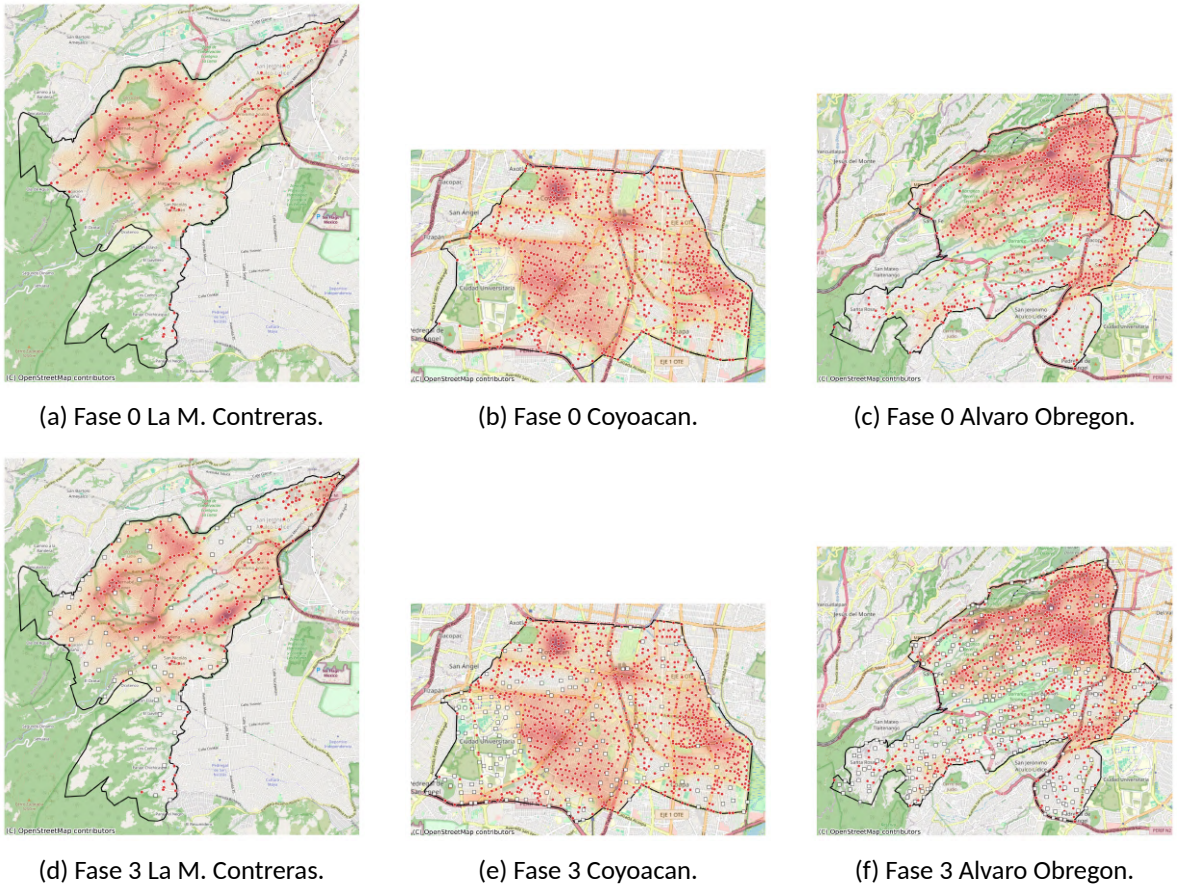
Alcaldía	Fase 0	Fase 1	Fase 2	Fase 3	Total
Milpa Alta	0	11	25	84	120
Cjpa. de Morelos	0	8	18	79	105
La M. Contreras	0	6	11	40	57
Tlahuac	0	13	24	105	142
Xochimilco	0	28	59	282	369
Azcapotzalco	0	3	11	42	56
Iztacalco	0	2	3	10	15
Tlalpan	0	36	74	355	465
Benito Juarez	0	1	3	5	9
Coyoacan	0	9	23	107	139
Miguel Hidalgo	0	5	12	51	68
V. Carranza	0	3	5	22	30
Alvaro Obregon	0	12	34	193	239
Cuauhtemoc	0	1	1	3	5
G. A. Madero	0	10	19	82	111
Iztapalapa	0	18	37	177	232
Total	0	166	359	1,637	2,162

Tabla 21: Plan de implementación en fases (cámaras nuevas por fase) — OCP

A diferencia del problema de desfibriladores, en este caso las instancias preservaron la solución trivial (Fase 0 = 0 cámaras) y el algoritmo encontró soluciones de cobertura completa en todas las alcaldías. Esto contrasta con los resultados del DRP, donde ninguna instancia alcanzó cobertura total.

Se observa que la distribución de cámaras entre fases es asimétrica: las Fases 1 y 2 concentran una fracción menor de instalaciones (166 y 359), mientras que la Fase 3 requiere la mayor inversión (1,637 cámaras). Este comportamiento es esperable dado que lograr cobertura completa implica atender los puntos más alejados y dispersos del territorio. En total, para alcanzar cobertura completa en las 16 alcaldías de la Ciudad de México se requieren 2,162 cámaras nuevas, distribuidas en tres fases de implementación.

La Figura 10 presenta la visualización geográfica de las soluciones para las instancias de La Magdalena Contreras, Coyoacan y Alvaro Obregon, comparando el estado inicial (Fase 0) con la solución optimizada (Fase 3). El fondo de color corresponde a una estimación de densidad de Kernel (KDE) construida a partir de los puntos de demanda ponderados por su frecuencia de ocurrencia de crímenes: las zonas con mayor intensidad (rojo) indican alta concentración de demanda, mientras que las zonas transparentes reflejan baja densidad. A diferencia del problema de desfibriladores, en este caso no se mueven instalaciones preexistentes, por lo que se emplean únicamente dos símbolos: un círculo rojo (●) indica una cámara preinstalada y un cuadrado blanco (□) indica una nueva cámara propuesta por MOEA/D. Las instancias restantes se presentan en el Anexo F.



(a) Fase 0 La M. Contreras. (b) Fase 0 Coyoacan. (c) Fase 0 Alvaro Obregon.

(d) Fase 3 La M. Contreras. (e) Fase 3 Coyoacan. (f) Fase 3 Alvaro Obregon.

Figura 10: Visualización geográfica de las Fases 0 y 3 para La Magdalena Contreras, Coyoacan y Alvaro Obregon. El fondo representa la densidad de crímenes estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a cámaras preinstaladas y los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D. Las filas superior e inferior muestran el estado inicial y la solución optimizada respectivamente

Análisis de accesibilidad La Tabla 22 reporta dos indicadores de accesibilidad Z_1 y $\bar{d}$ comparando la Fase 0 con la Fase 3. A diferencia del problema de desfibriladores, en este caso se considera un solo escenario dado que las cámaras son instalaciones nuevas, sin equipos preexistentes que puedan ser removidos.

Alcaldía	$Z_{1,\text{ant}}$ (m)	$Z_{1,\text{opt}}$ (m)	ΔZ_1 (m)	ΔZ_1 (%)	$\bar{d}_{\text{ant}}$ (m)	$\bar{d}_{\text{opt}}$ (m)
Milpa Alta	1,253	199	-1,054	-84.1	137	66
Cjpa. de Morelos	1,035	200	-835	-80.7	110	67
La M. Contreras	617	200	-417	-67.6	88	70
Tlahuac	870	200	-671	-77.1	93	70
Xochimilco	2,625	200	-2,425	-92.4	150	73
Azcapotzalco	372	199	-173	-46.5	70	63
Iztacalco	356	200	-157	-44.0	64	61
Tlalpan	1,700	200	-1,500	-88.2	127	72
Benito Juarez	225	197	-28	-12.4	60	59
Coyoacan	776	200	-577	-74.3	84	65
Miguel Hidalgo	864	200	-664	-76.9	59	54
V. Carranza	816	200	-617	-75.5	57	53
Alvaro Obregon	994	200	-794	-79.9	89	68
Cuauhtemoc	251	195	-56	-22.2	46	45
G. A. Madero	651	200	-451	-69.3	68	62
Iztapalapa	506	200	-306	-60.5	78	69

Tabla 22: Z_1 y distancia promedio antes/después — OCP

El resultado más importante es que $Z_{1,\text{opt}}$ converge a un rango de entre 195 y 200 metros en todas las alcaldías. Este comportamiento es una consecuencia directa de que el algoritmo alcanzó cobertura completa en todas las instancias. Cuando todos los puntos de demanda están cubiertos, el punto más alejado de cualquier cámara no puede superar el radio de cobertura definido en el modelo de 200 metros. Las mayores en Z_1 corresponden a Xochimilco (-2,425 metros) y Tlalpan (-1,500 metros), instancias que presentaban las mayores brechas de cobertura iniciales.

En términos de la distancia promedio, disminuye en todas las alcaldías, con valores finales que oscilan entre 45 metros y 73 metros. Esto indica que, en promedio, cada punto de demanda queda a menos de 75 metros de la cámara más cercana, lo que representa una mejora sustancial respecto a las distancias iniciales, que en algunos casos superan los 130 metros.

Conclusiones del problema de ubicación de cámaras En síntesis, los resultados del OCP, muestran que MOEA/D obtiene un desempeño competitivo frente al método exacto, logrando superar a AMPL en 9 de las 15 instancias comparables en términos de hipervolumen, e

incluyendo la resolución de una instancia (Iztapalapa) que el método exacto no logró resolver. El análisis espacial confirma que la optimización mejora consistentemente la distribución geográfica de las cámaras, con distribuciones post optimización significativamente más uniformes en 14 de las 16 alcaldías. El plan de fases evidencia que la cobertura completa de la Ciudad de México requiere un total de 2,162 cámaras nuevas, y que las dos primeras fases son suficientes para cubrir aproximadamente el 67 % de los puntos de demanda con una inversión notablemente menor. Finalmente, el análisis de accesibilidad muestra que la optimización reduce Z_1 a valores cercanos al radio de cobertura del modelo en todas las alcaldías, confirmando que las soluciones de Fase 3 logran cobertura efectiva del territorio.

La principal limitación identificada es que, en ciertas instancias, MOEA/D no logra encontrar la solución de mínimo costo para la cobertura completa, requiriendo más cámaras que AMPL para cubrir el mismo territorio.

4.5. Conclusiones

El principal desafío identificado en ambos problemas es que MOEA/D no logra alcanzar la solución de mínimo costo para la cobertura completa. En el problema de ubicación de desfibriladores ninguna instancia alcanza cobertura total, mientras que en el problema de ubicación de cámaras se alcanza cobertura completa, pero incurriendo en un mayor costo que el método exacto.

Una limitación transversal a ambos problemas es la escala de los ejes en los frentes de Pareto. En el problema de ubicación de desfibriladores, el eje y varía desde 0 hasta 2,043 según la instancia, y el rango del eje x varía desde 0.59 hasta 0.98 según la instancia. En el problema de ubicación de cámaras el eje y puede alcanzar hasta 38,034, y el rango del eje x varía entre 2.27 y 355.88. Esta disparidad puede inducir al algoritmo a priorizar la minimización del costo sobre la cobertura debido a la diferencia de magnitud entre ambos ejes, efecto que, si bien puede mitigarse mediante normalización, no siempre se elimina por completo tras dicho proceso.

CAPÍTULO 5
CONCLUSIONES

La ubicación óptima de dispositivos de atención de emergencias y de sistemas de vigilancia urbana constituye un desafío de alto impacto social en contextos metropolitanos donde los recursos son escasos y la distribución espacial de la demanda es heterogénea. En este marco, el presente trabajo abordó simultáneamente dos problemas de cobertura espacial, la reubicación e instalación de desfibriladores externos automáticos y la instalación de cámaras de video-vigilancia. Ambos problemas comparten una estructura bi-objetivo que maximiza la cobertura probabilística de eventos críticos y minimiza el costo total de instalación y reubicación, lo que hace posible tratarlos bajo una arquitectura algorítmica unificada.

Como respuesta a esta dualidad, se propuso el diseño, implementación y evaluación del algoritmo evolutivo multi-objetivo basado en descomposición (MOEA/D), adaptado a las restricciones y características propias de cada problema. La sintonización de parámetros se realizó mediante ParamILS, y la evaluación se llevó a cabo sobre instancias reales georreferenciadas construidas a partir de información de ambas ciudades. La elección de MOEA/D se fundamentó en su capacidad para descomponer el problema bi-objetivo en subproblemas escalares, permitiendo una exploración eficiente del frente de Pareto.

5.1. Cumplimiento de Objetivos

Los cinco objetivos específicos formulados al inicio de esta investigación fueron abordados de manera coherente y progresiva, constituyendo cada uno una etapa necesaria para el desarrollo y validación de la propuesta.

Objetivo 1 - Analizar el estado del arte: En el capítulo 2 se llevó a cabo una revisión exhaustiva del estado del arte de los problemas de reubicación de desfibriladores y de ubicación de cámaras. La revisión abarco los modelos matemáticos empleados en la literatura (desde variantes del problema de cobertura hasta formulaciones bi-objetivo), y los algoritmos de resolución asociados, tanto exactos como metaheurísticos, recorriendo, enfoques mono-objetivo y multi-objetivo. Esta revisión permitió constatar que el tratamiento integrado y multi-objetivo de ambos problemas, bajo una misma arquitectura algorítmica, es escaso en la literatura, particularmente en el caso del problema de reubicación de desfibriladores, lo que refuerza la pertinencia y originalidad del trabajo.

Objetivo 2 - Diseñar y adaptar el algoritmo: En el capítulo 3 se diseñaron y adaptaron los componentes del algoritmo MOEA/D para abordar las restricciones y criterios propios de cada problema. Esto implicó decisiones de diseño en múltiples niveles relacionadas, por ejemplo, con el método de descomposición y la generación de vectores de peso, la representación de la solución y las funciones objetivo, los mecanismos de inicialización y reparación de

soluciones infactibles, y los operadores de transformación (cruzamiento y mutación). Cada componente fue adaptado a la estructura espacial discreta de los problemas, garantizando factibilidad y coherencia con los supuestos de cada problema.

Objetivo 3 - Implementar y sintonizar el algoritmo: En el capítulo 4 se presenta la propuesta algorítmica, la cual incluyó un proceso de sintonización de parámetros. En esta se introdujo todo lo que se creó en el proceso anterior para poder obtener los mejores operadores, población, entre otros, para cada problema.

Objetivo 4 - Evaluar la eficacia del modelo: En el capítulo 4, se construyeron y evaluaron instancias reales georreferenciadas para ambos problemas. Cinco instancias basadas en los condados de la Ciudad de Nueva York para el problema de reubicación de desfibriladores (DRP), y dieciséis instancias basadas en las alcaldías de la Ciudad de México para el problema de ubicación de cámaras. La evaluación de la eficacia del modelo se realizó a través de cuatro niveles de análisis que consideran calidad algorítmica (hipervolumen y soluciones no dominadas), análisis espacial de las distribuciones obtenidas (Average Nearest Neighbor), planificación operativa mediante un plan de implementación de fases, e indicadores de accesibilidad que cuantifican la mejora en la distancia al dispositivo más cercano antes y después de la optimización.

Objetivo 5 - Comparar el rendimiento frente a métodos exactos: Las soluciones obtenidas por MOEA/D fueron contrastadas sistemáticamente contra el método exacto de referencia implementado en AMPL y resuelto con Gurobi, en términos de hipervolumen, cantidad de puntos no dominados y tiempo de cómputo.

El conjunto de estos resultados permite afirmar que el objetivo general centrado en desarrollar y evaluar un algoritmo MOEA/D para el DRP y el OCP capaz de generar un conjunto de soluciones eficientes que representen el equilibrio entre cobertura y costos en escenarios urbanos reales se cumplió satisfactoriamente.

5.2. Síntesis de resultados

En el problema de desfibriladores, el algoritmo MOEA/D demostró un desempeño competitivo frente al método exacto de referencia, implementado en AMPL y resuelto con Gurobi. En tres de los cinco condados evaluados, la diferencia porcentual de hipervolumen fue negativa, lo que indica que MOEA/D superó al método exacto en la calidad del frente de Pareto aproximado, con brechas que oscilan entre $-3.13\,\%$ y $+0.96\,\%$. Estos resultados son especialmente significativos considerando que MOEA/D no consiguió la solución con cobertura completa. En cuanto al tiempo de ejecución, MOEA/D requirió más tiempo en cuatro de los cinco condados, siendo Manhattan la excepción. Ambos métodos convergieron en tiempos prácticamente equivalentes, lo que resulta destacable ya que es la instancia más densa y computacionalmente exigente del conjunto. El análisis espacial mediante Average Nearest Neighbor evidenció distribuciones post-optimización más uniformes en tres de los

cinco condados, lo que sugiere que el algoritmo tiende a dispersar los desfibriladores externos automáticos de manera más equitativa en el territorio. El plan de implementación por fases mostró que las dos primeras fases logran niveles intermedios de cobertura exclusivamente mediante reubicación de equipos preexistentes, concentrando la compra de nuevos desfibriladores externos automáticos en la Fase 3. En términos de accesibilidad, Brooklyn registró la reducción más significativa, con una disminución de hasta 938 metros en la distancia al desfibrilador externo automático más cercano, mientras que Bronx y Manhattan presentaron pequeños incrementos.

En el problema de ubicación de cámaras, el frente de Pareto obtenido por MOEA/D incluye, en las 16 alcaldías evaluadas, al menos una solución que alcanza cobertura completa de los puntos de demanda, aunque en varias instancias lo hizo instalando un número de cámaras superior al mínimo obtenido por Gurobi, lo que evidencia una tendencia a la sobreinstalación. Este comportamiento refleja la dificultad del algoritmo para identificar consistentemente las configuraciones de mínimo costo cuando la cobertura total ya ha sido completada. En cuanto a la comparación directa, de las 15 instancias comparables, MOEA/D obtuvo un mejor hipervolumen en 9 de ellas. El caso que resulta particularmente relevante es el caso de Iztapalapa (la alcaldía de mayor extensión y complejidad del conjunto de instancias del problema de ubicación de cámaras), donde el método exacto no logró encontrar una solución, mientras que MOEA/D entregó una solución factible y de buena calidad, ilustrando la ventaja práctica de los enfoques metaheurísticos ante problemas de gran escala.

5.3. Contribuciones y Limitaciones

Las contribuciones de este trabajo pueden organizarse en tres dimensiones. Desde el punto de vista metodológico, se propone una arquitectura MOEA/D unificada capaz de abordar dos problemas de cobertura espacial estructuralmente distintos mediante la misma lógica algorítmica, lo que establece un patrón de diseño reproducible para otros problemas de ubicación de instalaciones. Desde el punto de vista aplicado, se construyeron instancias reales georreferenciadas para dos ciudades (NYC y CDMX) que pueden servir como banco de prueba para investigaciones futuras. Desde un punto de vista analítico, se implementó un esquema de evaluación multinivel que combina análisis espacial, métricas de calidad algorítmica, planificación operativa por fases e indicadores de accesibilidad.

Acompañando a estas contribuciones, se deben reconocer las limitaciones del trabajo, que pueden clasificarse en tres categorías. En relación con las limitaciones del modelo, se detectaron dos comportamientos no deseados. En el problema de reubicación de desfibriladores, el algoritmo eliminó desfibriladores preinstalados, y en el problema de ubicación de cámaras, la falta de convergencia hacia soluciones de mínimo costo para la cobertura completa. Adicionalmente, ambos problemas fueron modelados en discretización bidimensional, lo que limita el realismo del modelo de cobertura. En cuanto a las limitaciones de los datos, la construcción de las instancias del problema de reubicación de desfibriladores no pudo apoyarse en registros reales de paros cardíacos extrahospitalarios, debido a que dicha información no

se encuentra disponible públicamente. Como aproximación, la probabilidad de ocurrencia de un paro en cada grupo de bloques se definió de forma proporcional a la población total del grupo, normalizada respecto a la población total del condado al que pertenece. Este enfoque se sustenta en la correlación documentada entre densidad poblacional y probabilidad de ocurrencia de un paro. No obstante, esto introduce una simplificación que puede cambiar los patrones de ubicación óptima si existieran datos reales georreferenciados. Por último, en el plano experimental, la gran diferencia entre las escalas de los ejes del frente de Pareto puede inducir al algoritmo a priorizar la minimización del costo sobre la cobertura, efecto que no siempre se corrige con los esquemas de normalización utilizados.

5.4. Trabajo Futuro

A partir de los resultados y limitaciones descritos, se identifican las siguientes líneas de trabajo futuro:

- **Mejoras al modelo.** En el DRP, se propone incorporar una restricción que garantice el número mínimo de desfibriladores externos automáticos preinstalados, evitando la eliminación de equipos operativos. Complementariamente, asignar una probabilidad de demanda basada en las ubicaciones con desfibriladores preinstalados otorgaría al algoritmo un incentivo para mantener equipos en zonas ya validadas operacionalmente. En el problema de ubicación de cámaras, se recomienda incorporar un término de penalización en la función objetivo que desincentive la sobre-instalación de cámaras más allá del mínimo necesario para la cobertura completa.
- **Mejoras al algoritmo.** Se propone explorar otras metaheurísticas multi-objetivo, con el fin de establecer comparaciones más amplias. Asimismo, incorporar operadores especializados que guíen la búsqueda hacia soluciones de mayor cobertura con menor costo y aplicar estrategias de control de parámetros adaptativos que favorezcan la exploración en etapas iniciales y la explotación en etapas finales del proceso evolutivo.
- **Mejoras a los datos.** La limitación estructural del trabajo reside en el uso de un dato poblacional para aproximar la demanda de paros cardíacos extrahospitalarios. Como línea directa de mejora, se propone incorporar registros de paros que permitan reemplazar la aproximación actual por estimaciones de riesgo más precisas. De forma análoga, para el problema de ubicación de cámaras, se plantea explorar fuentes de datos de incidencia delictual con mayor resolución espacial y/o temporal.
- **Extensiones del enfoque.** La arquitectura MOEA/D desarrollada es transferible a otros problemas de cobertura espacial, como la localización de estaciones de bomberos o puestos de primeros auxilios. Ampliar el marco propuesto a estos dominios sería una contribución metodológica de gran alcance.

En síntesis, este trabajo muestra que un algoritmo evolutivo multi-objetivo, debidamente adaptado y evaluado sobre instancias reales, es capaz de generar soluciones de alta calidad para problemas complejos de cobertura espacial en contextos urbanos, ofreciendo a los tomadores de decisiones un conjunto diverso de alternativas que explicitan el equilibrio entre cobertura y costo. La posibilidad de tratar dos problemas de naturaleza diferente, uno vinculado a la salud pública y otro a la seguridad ciudadana, bajo una misma arquitectura algorítmica abre una línea de investigación con potencial para impactar positivamente la planificación urbana en ciudades latinoamericanas y más allá.

ANEXOS

A Declaración de uso de Inteligencia Artificial

Este trabajo fue desarrollado con el apoyo de herramientas de inteligencia artificial generativa, incluyendo ChatGPT, Gemini y Claude. Estas herramientas fueron utilizadas en distintas etapas del proyecto, siempre como apoyo instrumental y bajo supervisión del autor.

Durante la revisión de literatura, se emplearon para explorar direcciones de investigación relevantes, identificar trabajos relacionados y organizar ideas iniciales. En la etapa de redacción se partió de borradores preliminares, los cuales fueron expandidos y refinados de forma iterativa. Las herramientas más utilizadas en esta etapa fueron Gemini y Claude.

En relación al desarrollo del código, se contaba con una base funcional completa, por lo que el uso de IA se orientó a la optimización y mejora del código existente.

Como excepción, la sección de conclusiones partió de una versión inicial generada por la inteligencia artificial, la cual fue posteriormente revisada, modificada y validada por el autor para asegurar su coherencia con los objetivos y resultados del trabajo.

En todos los casos, el contenido generado fue revisado críticamente por el autor. Las afirmaciones técnicas y las decisiones finales respecto al contenido, estructura y argumentación fueron tomadas por el autor. La responsabilidad integra sobre el contenido final recae en el autor.

B Construcción del frente de Pareto de referencia mediante el método exacto (AMPL)

A partir del modelo multi-objetivo definido en la Sección 1.4.3, cuyas funciones objetivo minimizan el negativo de la cobertura probabilística (F_1) y el costo total (F_2), este anexo describe el procedimiento con el que el método exacto, implementado en AMPL y resuelto con Gurobi, aproxima el frente de Pareto que se emplea como referencia en la evaluación experimental. A diferencia de la descomposición interna de MOEA/D presentada en la Sección 3.2 (donde el problema se divide en múltiples subproblemas escalares resueltos simultáneamente por una población), aquí la escalarización opera como un procedimiento externo al solver: cada vector de pesos define un problema mono-objetivo que se resuelve de forma independiente, y el frente se aproxima repitiendo este proceso mediante el método de sumas ponderadas con normalización. El procedimiento se organiza en dos fases.

Fase 1: Cálculo de Extremos (Ideal y Nadir)

Antes de combinar los objetivos, es necesario acotar su rango, ya que F_1 y F_2 operan en escalas distintas y una suma ponderada sin normalizar quedaría dominada por el objetivo de mayor magnitud. Para delimitar dicho rango se resuelve el modelo optimizando cada función objetivo k ($k \in \{1, 2\}$) de forma individual, lo que permite obtener sus valores extremos:

- z_k^{ideal} (Mejor Valor): el valor ideal alcanzado por el objetivo k.
- z_k^{nadir} (Peor Valor): el valor nadir obtenido para el objetivo k.

Fase 2: Escalarización e Iteración

Una vez obtenidos los rangos, se aproxima el frente de Pareto resolviendo el modelo iterativamente para 101 puntos, variando el peso β_1 desde 0 hasta 1 con un paso de 0.01 (donde $\beta_2 = 1 - \beta_1$) [6], mediante la siguiente función escalarizada:

$$\text{mín } z = \sum_{k=1}^{2} \beta_k \cdot \left(\frac{F_k - z_k^{\text{ideal}}}{z_k^{\text{nadir}} - z_k^{\text{ideal}}} \right) \tag{20}$$

donde:

- F_k: es el valor de la función objetivo k evaluada en la solución actual.

C Espacio de configuración de operadores de mutación

Como se mencionó anteriormente, en esta sección del anexo se detallaran los operadores base y los operadores híbridos de mutación que conformaron el espacio de búsqueda. La elección de este operador se consolida en un único parámetro discreto (T_{mut}). Debido a la naturaleza de cada problema (ubicación de cámaras vs reubicación de desfibriladores), la implementación computacional se adapta a las restricciones físicas de cada uno, por lo que el espacio de configuración emplea identificadores numéricos distintos para cada caso.

La tabla 23 detalla el mapeo de las 28 opciones formuladas. Los valores del 1 al 28 corresponden al problema de las cámaras, mientras que los valores del 29 al 56 corresponden a

[6] En los puntos extremos se utilizaron pesos cercanos a 0 y 1 en lugar de valores estrictos: en la iteración 1, $\beta_1 = \varepsilon$ y $\beta_2 = 1 - \varepsilon$, y en la iteración 101, $\beta_1 = 1 - \varepsilon$ y $\beta_2 = \varepsilon$, con $\varepsilon = 0.00001$. Esto evita que el problema se reduzca a uno estrictamente mono-objetivo cuando uno de los pesos se anula. Además, un peso pequeño en el otro objetivo ayuda como criterio de desempate en caso de encontrar varias soluciones óptimas.

lo misma lógica, pero aplicada al problema de los desfibriladores. Para los operadores híbridos, el algoritmo selecciona dinámicamente entre el operador A y el operador B en cada iteración, mediante la probabilidad de selección híbrida (p_{hyb}).

Cabe mencionar que tres de los operadores base incorporan una tasa de entrada p_m como compuerta de activación previa a su ejecución: Perturbación Simple, Reubicación en Bloque con Filtro y Eliminación en Bloque. Esto implica que, cuando se seleccione cualquiera de estos operadores (ya sea de forma aislada o dentro de un esquema híbrido), el individuo debe superar primero la probabilidad p_m para que el operador se aplique de forma efectiva. Los demás operadores se ejecutan directamente sin esta compuerta.

ID Loc.	ID Reub.	Operador A	Operador B (Solo híbridos)
		Operadores Base	
1	29	Perturbación Simple (p_{op1})	–
2	30	Intercambio Probabilístico con Reversión (p_{swap})	–
3	31	Reubicación en Bloque con Filtro (α_{swap})	–
4	32	Eliminación en Bloque (α_{del})	–
5	33	Bit-Flip Adaptada $(1/L)$	–
6	34	Bit-Flip Adaptada $(1/\text{tamaño población})$	–
7	35	Bit-Flip Adaptada (p_{bit})	–
		Operadores Híbridos (Combinaciones en Pares guiadas por p_{hyb})	
8	36	Bit-Flip Adaptada $(1/L)$	Bit-Flip Adaptada $(1/\text{tamaño población})$
9	37	Bit-Flip Adaptada $(1/L)$	Bit-Flip Adaptada (p_{bit})
10	38	Bit-Flip Adaptada $(1/L)$	Perturbación Simple (p_{op1})
11	39	Bit-Flip Adaptada $(1/L)$	Eliminación en Bloque (α_{del})
12	40	Bit-Flip Adaptada $(1/L)$	Reubicación en Bloque con Filtro (α_{swap})
13	41	Bit-Flip Adaptada $(1/L)$	Intercambio Probabilístico con Reversión (p_{swap})
14	42	Bit-Flip Adaptada $(1/\text{tamaño población})$	Bit-Flip Adaptada (p_{bit})
15	43	Bit-Flip Adaptada $(1/\text{tamaño población})$	Perturbación Simple (p_{op1})
16	44	Bit-Flip Adaptada $(1/\text{tamaño población})$	Eliminación en Bloque (α_{del})
17	45	Bit-Flip Adaptada $(1/\text{tamaño población})$	Reubicación en Bloque con Filtro (α_{swap})
18	46	Bit-Flip Adaptada $(1/\text{tamaño población})$	Intercambio Probabilístico con Reversión (p_{swap})
19	47	Bit-Flip Adaptada (p_{bit})	Perturbación Simple (p_{op1})
20	48	Bit-Flip Adaptada (p_{bit})	Eliminación en Bloque (α_{del})
21	49	Bit-Flip Adaptada (p_{bit})	Reubicación en Bloque con Filtro (α_{swap})
22	50	Bit-Flip Adaptada (p_{bit})	Intercambio Probabilístico con Reversión (p_{swap})
23	51	Perturbación Simple (p_{op1})	Eliminación en Bloque (α_{del})
24	52	Perturbación Simple (p_{op1})	Reubicación en Bloque con Filtro (α_{swap})
25	53	Perturbación Simple (p_{op1})	Intercambio Probabilístico con Reversión (p_{swap})
26	54	Eliminación en Bloque (α_{del})	Reubicación en Bloque con Filtro (α_{swap})
27	55	Eliminación en Bloque (α_{del})	Intercambio Probabilístico con Reversión (p_{swap})
28	56	Reubicación en Bloque con Filtro (α_{swap})	Intercambio Probabilístico con Reversión (p_{swap})

Tabla 23: Mapeo de configuraciones base e híbridas para el parámetro T_{mut}, detallando el parámetro interno que rige a cada operador.

D Obtención y preprocesamiento de datos para instancias de desfibriladores en NYC

Esta sección documenta el procedimiento seguido para obtener y preprocesar los conjuntos de datos utilizados en la construcción de instancias para el problema de desfibriladores (AEDs) en la Ciudad de Nueva York. El objetivo es facilitar la reproducibilidad del proceso y permitir futuras actualizaciones (Por ejemplo: Si se actualiza el inventario de AEDs, si se utiliza un servicio censal más reciente o considerar otros condados).

D.1. Puntos candidatos desde Censo 2010 (Block Groups)

Fuentes y servicio GIS Se utilizo el dataset "Housing Demographics in the 2010 Census"publicado en ArcGIS Online. El acceso se realizó mediante consultas REST al FeatureServer:

- Página: `https://www.arcgis.com/home/item.html?id=936481805c2d4639ac727938b32d8ec3`
- Servicio REST: `https://services2.arcgis.com/FiaPA4ga0iQKduv3/ArcGIS/rest/services/US_Census_Housing/FeatureServer/`

Identificación de condados (NY) Para saber los códigos de los condados (COUNTY) del estado de Nueva York se realizó una consulta sin geometría:

- Consulta utilizada: `https://services2.arcgis.com/FiaPA4ga0iQKduv3/ArcGIS/rest/services/US_Census_Housing/FeatureServer/1/query?where=ST_ABBREV%3D%27NY%27&outFields=COUNTY,NAME_1&returnGeometry=false&f=pjson`

Extraccion de Block Groups (Puntos candidatos) Con los códigos de los condados identificados, se consultó la capa de Block Group (capa 3 en el FeatureServer) para obtener atributos demográficos y centroides. En particular `TOTPOP10` (población total del Block Group) y el centroide en EPSG:4326 (coordenadas).

- Consulta Utilizada: `https://services2.arcgis.com/FiaPA4ga0iQKduv3/ArcGIS/rest/services/US_Census_Housing/FeatureServer/3/query?where=ST_ABBREV%3D%27NY%27%20AND%20COUNTY%20IN%20(%27047%27,%27005%27,%270`

```
61%27,%27081%27,%27085%27)&outFields=COUNTY,GEOID10,TOTPOP10,POPDE
NS10,STATE_NAME&returnGeometry=false&returnCentroid=true&outSR=432
6&resultOffset=0&resultRecordCount=2000&f=pjson
```

Paginación Dado que este último servicio limita la cantidad de resultados por consulta se utilizó la paginación mediante resultOffset. Se itero con resultOffset $\in \{0, 2000, 4000, 6000, 8000, ...\}$. Hasta que la respuesta retornara cero registros. En nuestro caso, este proceso genero cuatro archivos JSON, que posteriormente se formó un único archivo CSV con los campos necesarios.

D.2. Inventario de desfibriladores (AEDs) desde NYC Open Data

Fuente Las ubicaciones de AED se obtuvieron desde el portal NYC Open Data descargando el dataset en formato CSV.

- Pagina: `https://data.cityofnewyork.us/Health/New-York-City-Automated-External-Defibrillator-AED/2er2-jqsx/about_data`
- Mapa del dataset: `https://data.cityofnewyork.us/Health/NYC-Automated-External-Defibrillator-AED-Map/2ync-kihj`

Preprocesamiento A partir del CSV original se generó una nueva versión depurada ya que se detectaron columnas irrelevantes y DEAs con inconsistencias espaciales. Ademas de homogenizar los atributos para la integración con los puntos candidatos. La fecha de última actualización del archivo CSV al momento de la descarga es del 11 de diciembre del 2025.

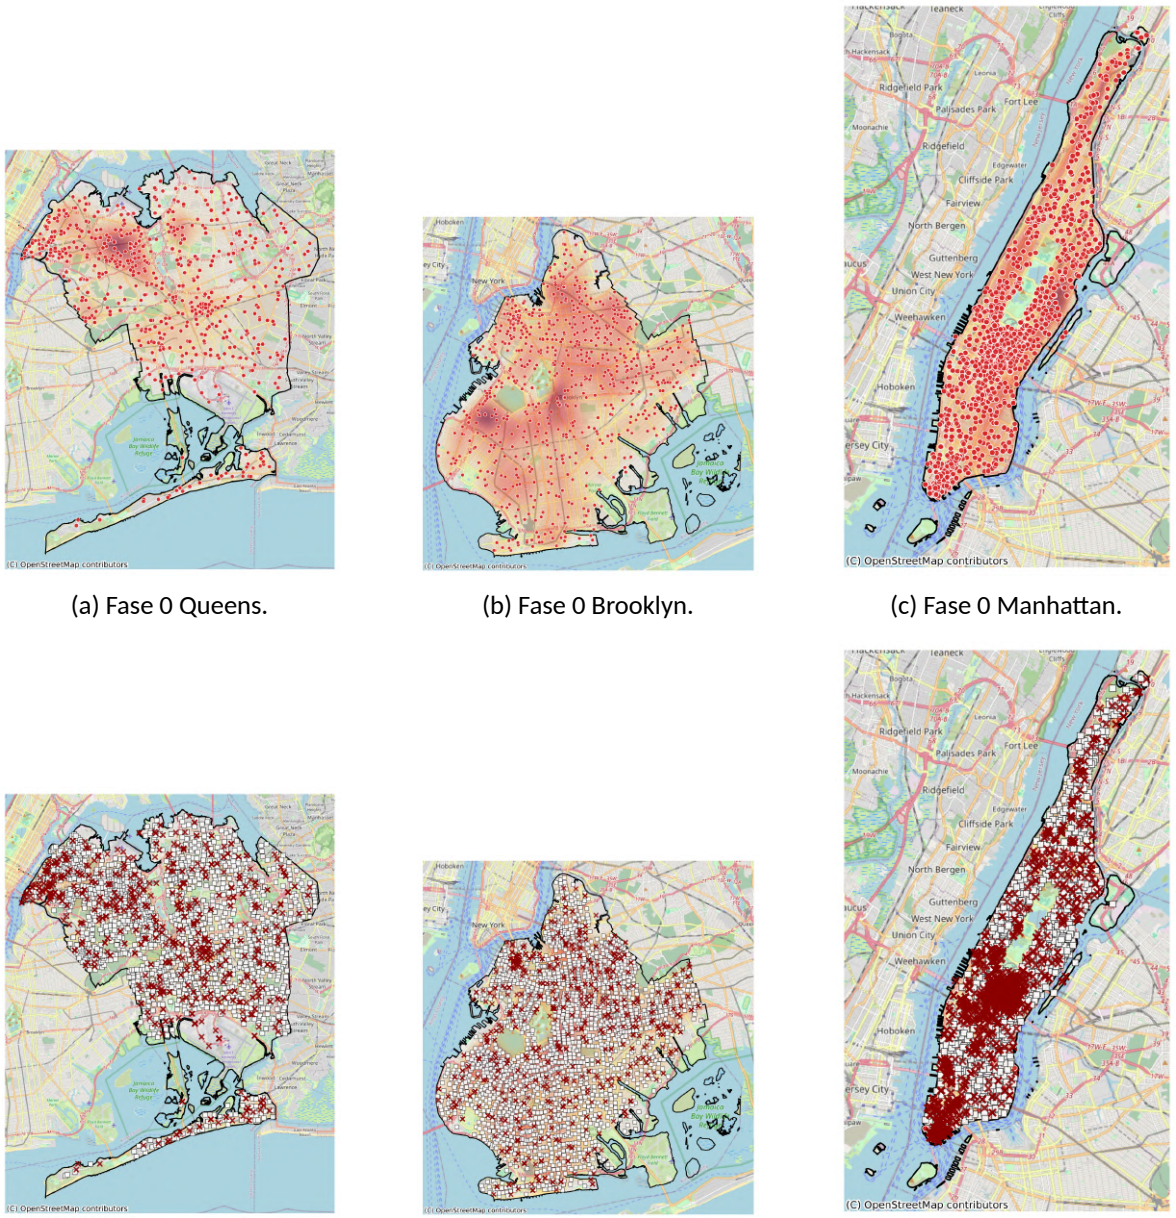
D.3. Fronteras administrativas (NYC Borough Boundaries)

Información para validar visualmente la consistencia espacial de los puntos candidatos y AEDs, y también generar los mapas por borough/condado.

- Página: `https://www.arcgis.com/home/item.html?id=1f75b59e45444d7bae27454ec7730395`
- Servicio REST: `https://services1.arcgis.com/0mhlGDIUKwQF6tnJ/arcgis/rest/services/NYC_Borough_Boundaries/FeatureServer`

- Consulta GeoJSON: `https://services1.arcgis.com/0mhlGDIUKwQF6tnJ/ArcGIS/rest/services/NYC_Borough_Boundaries/FeatureServer/0/query?where=1%3D1&outFields=boro_name%2Cboro_code&returnGeometry=true&outSR=4326&f=geojson`

E Resultados para el problema de los desfibriladores

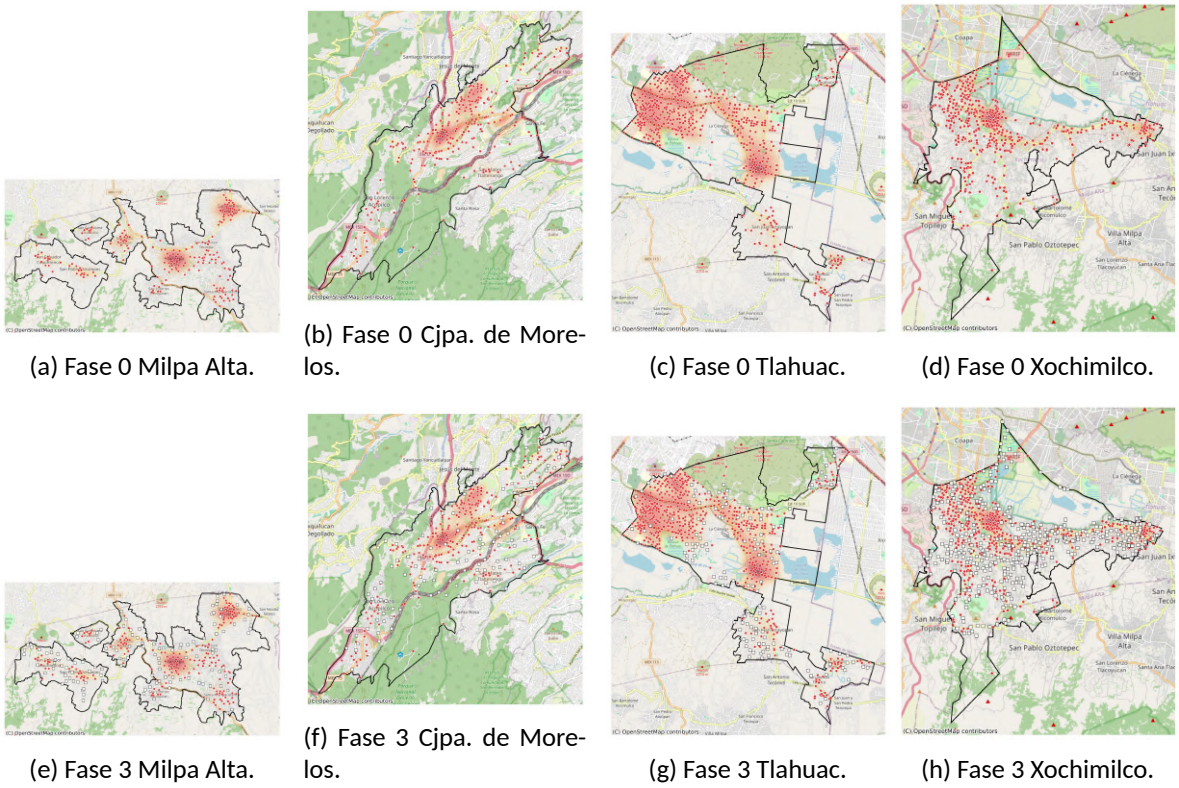


(a) Fase 0 Queens. (b) Fase 0 Brooklyn. (c) Fase 0 Manhattan.

(d) Fase 3 Queens. (e) Fase 3 Brooklyn. (f) Fase 3 Manhattan.

Figura 11: Visualización geográfica de las Fases 0 y 3 para Queens, Brooklyn y Manhattan. El fondo representa la densidad de demanda estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a desfibriladores externos automáticos preinstalados, los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D, y las cruces rojas a DEAs removidos durante la optimización. Las filas superiores e inferiores muestran el estado inicial y optimizado respectivamente.

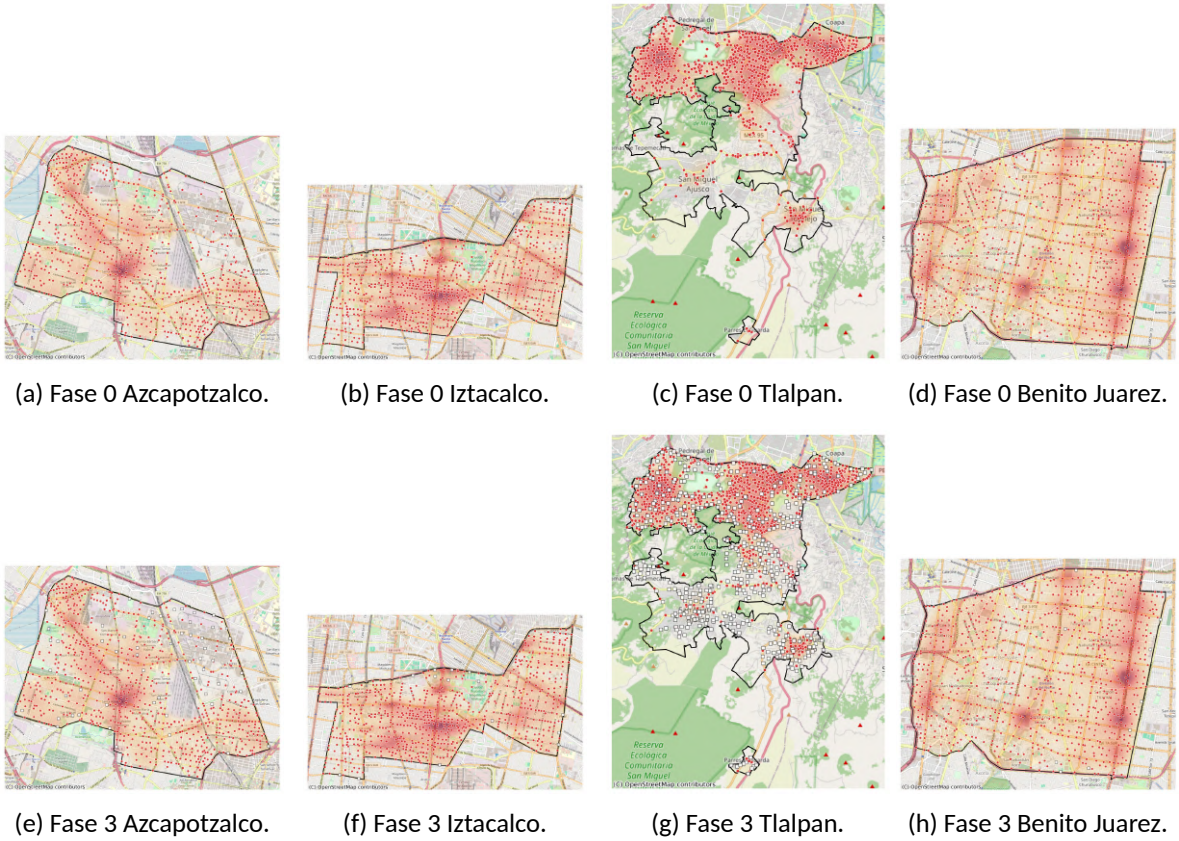
F Resultados para el problema de los desfibriladores



(a) Fase 0 Milpa Alta. (b) Fase 0 Cjpa. de Morelos. (c) Fase 0 Tlahuac. (d) Fase 0 Xochimilco.

(e) Fase 3 Milpa Alta. (f) Fase 3 Cjpa. de Morelos. (g) Fase 3 Tlahuac. (h) Fase 3 Xochimilco.

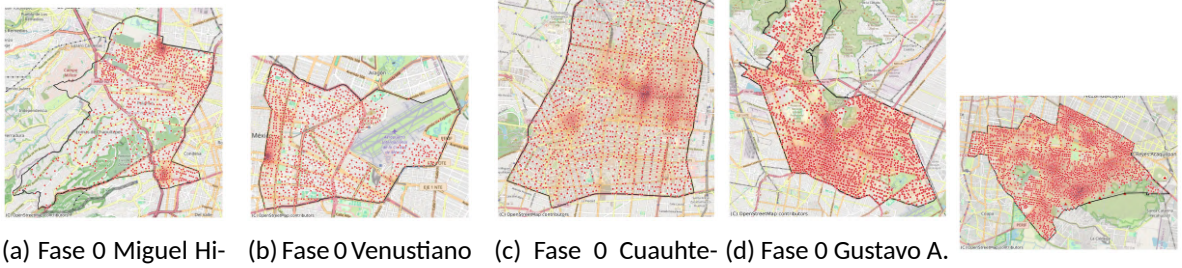
Figura 12: Visualización geográfica de las Fases 0 y 3 para Milpa Alta, Cjpa. de Morelos, Tlahuac y Xochimilco. El fondo representa la densidad de crímenes estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a cámaras preinstaladas y los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D. Las filas superior e inferior muestran el estado inicial y la solución optimizada respectivamente.



(a) Fase 0 Azcapotzalco. (b) Fase 0 Iztacalco. (c) Fase 0 Tlalpan. (d) Fase 0 Benito Juarez.

(e) Fase 3 Azcapotzalco. (f) Fase 3 Iztacalco. (g) Fase 3 Tlalpan. (h) Fase 3 Benito Juarez.

Figura 13: Visualización geográfica de las Fases 0 y 3 para Azcapotzalco, Iztacalco, Tlalpan y Benito Juarez. El fondo representa la densidad de crímenes estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a cámaras preinstaladas y los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D. Las filas superior e inferior muestran el estado inicial y la solución optimizada respectivamente.



(a) Fase 0 Miguel Hidalgo. (b) Fase 0 Venustiano Carranza. (c) Fase 0 Cuauhtemoc. (d) Fase 0 Gustavo A. Madero. (e) Fase 0 Iztapalapa.



(f) Fase 3 Miguel Hidalgo. (g) Fase 3 Venustiano Carranza. (h) Fase 3 Cuauhtemoc. (i) Fase 3 Gustavo A. Madero. (j) Fase 0 Iztapalapa.

Figura 14: Visualización geográfica de las Fases 0 y 3 para Miguel Hidalgo, V. Carranza, Cuauhtemoc, G. A. Madero e Iztapalapa. El fondo representa la densidad de crímenes estimada mediante KDE, donde las zonas más rojas indican mayor concentración de puntos de demanda. Los círculos rojos corresponden a cámaras preinstaladas y los cuadrados blancos a nuevas instalaciones propuestas por MOEA/D. Las filas superior e inferior muestran el estado inicial y la solución optimizada respectivamente.

REFERENCIAS BIBLIOGRÁFICAS

[Agurob *et al.*, 2024] Agurob, M. C. G., Lacpao, N., y Daug, U. P. (2024). Multi-objective optimization of cctv placement: A case study at bukidnon state university. *Mindanao Journal of Science and Technology*, 22(S1).

[Ahn *et al.*, 2016] Ahn, J.-W., Chang, T.-W., Lee, S.-H., y Seo, Y. W. (2016). Two-phase algorithm for optimal camera placement. *Scientific Programming*, 2016(1):4801784.

[Almousa, 2025] Almousa, M. (2025). *Exploring various set covering problem techniques to tackle the optimal camera placement problem*. Tesis doctoral, Lancaster University.

[Altahir *et al.*, 2018] Altahir, A. A., Asirvadam, V. S., Hamid, N., Sebastian, P., Saad, N., y Dass, S. C. (2018). Optimizing camera placement based on task modeling. En *2018 IEEE SENSORS*, pp. 1–4. IEEE.

[Atta *et al.*, 2018] Atta, S., Sinha Mahapatra, P. R., y Mukhopadhyay, A. (2018). Solving maximal covering location problem using genetic algorithm with local refinement. *Soft Computing*, 22(12):3891–3906.

[Aufderheide y Hazinski, 2006] Aufderheide, T. y Hazinski, M. F. (2006). Community lay rescuer automated external defibrillation programs. *Circulation*, 113(9):1260–1270.

[Babaei *et al.*, 2025] Babaei, S., Khalaj, M., Keramatpour, M., y Enayati, R. (2025). Multi-objective optimization for green bts site selection in telecommunication networks using nsga-ii and mopso. *Algorithms*, 18(1):9.

[Buter *et al.*, 2024] Buter, R., Nazarian, A., Koffijberg, H., Hans, E. W., Stieglis, R., Koster, R. W., y Demirtas, D. (2024). Strategic placement of volunteer responder system defibrillators. *Health care management science*, 27(4):503–524.

[Cao *et al.*, 2021] Cao, B., Li, M., Liu, X., Zhao, J., Cao, W., y Lv, Z. (2021). Many-objective deployment optimization for a drone-assisted camera network. *IEEE transactions on network science and engineering*, 8(4):2756–2764.

[CARES, 2025] CARES (2025). 2024 annual report. Accessed: 2026-03-08.

[CARES, 2026] CARES (2026). About cares. Accessed: 2026-03-08.

[Chan *et al.*, 2016] Chan, T. C., Demirtas, D., y Kwon, R. H. (2016). Optimizing the deployment of public access defibrillators. *Management science*, 62(12):3617–3635.

[Chan *et al.*, 2013] Chan, T. C., Li, H., Lebovic, G., Tang, S. K., Chan, J. Y., Cheng, H. C., Morrison, L. J., y Brooks, S. C. (2013). Identifying locations for public access defibrillators using mathematical optimization. *Circulation*, 127(17):1801–1809.

[Church y ReVelle, 1974] Church, R. y ReVelle, C. (1974). The maximal covering location problem. En *Papers of the regional science association*, volumen 32, pp. 101–118. Springer-Verlag Berlin/Heidelberg.

[Chvátal, 1975] Chvátal, V. (1975). A combinatorial theorem in plane geometry. *Journal of Combinatorial Theory, Series B*, 18(1):39–41.

[Congreso de la Ciudad de México, 2008] Congreso de la Ciudad de México (2008). Ley que regula el uso de tecnologÍa para la seguridad pÚblica del distrito federal. Gaceta Oficial de la Ciudad de México.

[Cunningham *et al.*, 2019] Cunningham, C., Lowe, J. R., Johnson, A., Carter, W., Whited, W. M., Shofer, F. F., Brice, J. H., y Williams, J. G. (2019). Public access defibrillation: utilisation and missed opportunities. *Australasian Journal of Paramedicine*, 16:1–8.

[Deparment of City Planning (DCP), 2020] Deparment of City Planning (DCP) (2020). Nyc borough boundaries. `https://www.arcgis.com/home/item.html?id=1f75b59e45444d7bae27454ec7730395`.

[Department of Health and Mental Hygiene (DOHMH),] Department of Health and Mental Hygiene (DOHMH). New york city automated external defibrillator (aed) inventory. `https://data.cityofnewyork.us/Health/New-York-City-Automated-External-Defibrillator-AED/2er2-jqsx/about_data`.

[Díaz-Roman *et al.*, 2025] Díaz-Roman, M. P., Jasso-González, C., y Díaz-Guarneros, J. D. (2025). Videovigilancia en la ciudad de méxico y su efecto en la disminución de la incidencia delictiva. *Revista Científica General José María Córdova*, 23(51):683–706.

[El Itani *et al.*, 2019] El Itani, B., Ben Abdelaziz, F., y Masri, H. (2019). A bi-objective covering location problem: Case of ambulance location in the beirut area, lebanon. *Management Decision*, 57(2):432–444.

[Emoto y Ryo, 2025] Emoto, H. y Ryo, K. (2025). Rope deployment method for enhancing multi-angle imaging quality of wildlife pests in rcms. En *2025 Fifteenth International Conference on Mobile Computing and Ubiquitous Networking (ICMU)*, pp. 1–7. IEEE.

[Escobar *et al.*, 2023] Escobar, J. W., Giraldo, J. L., Londoño, D. A., y Linfati, R. (2023). Multiobjective optimization of public health service delivery networks. *Ciencia e Ingeniería Neogranadina*, 33(1):41–60.

[Federal User Community,] Federal User Community. Housing demographics in the 2010 census. `https://www.arcgis.com/home/item.html?id=936481805c2d4639ac727938b32d8ec3`.

[Fuentes y Orozco, 2025] Fuentes, E. y Orozco, K. (2025). Sistema de optimización para el posicionamiento de nuevas cámaras de vigilancia para ampliar un c2 mediante algoritmos bioinspirados. Trabajo terminal, Instituto Politécnico Nacional, Escuela Superior de Cómputo, Ciudad de México, México.

[Gardett *et al.*, 2019] Gardett, I., Broadbent, M., Scott, G., Clawson, J. J., y Olola, C. (2019). Availability and use of an automated external defibrillator at emergency medical dispatch. *Prehospital Emergency Care*.

[Heyns, 2021] Heyns, A. M. (2021). Optimisation of surveillance camera site locations and viewing angles using a novel multi-attribute, multi-objective genetic algorithm: A day/-night anti-poaching application. *Computers, Environment and Urban Systems*, 88:101638.

[Huang y Wen, 2014] Huang, C.-Y. y Wen, T.-H. (2014). Optimal installation locations for automated external defibrillators in taipei 7-eleven stores: using gis and a genetic algorithm with a new stirring operator. *Computational and mathematical methods in medicine*, 2014(1):241435.

[Hutter *et al.*, 2009] Hutter, F., Hoos, H. H., Leyton-Brown, K., y Stützle, T. (2009). ParamILS: an automatic algorithm configuration framework. *Journal of Artificial Intelligence Research*, 36:267–306.

[Instituto Nacional de Estadística y Geografía (INEGI), 2025] Instituto Nacional de Estadística y Geografía (INEGI) (2025). Encuesta nacional de victimización y percepción sobre seguridad pública (envipe) 2025: Presentacion nacional. Accessed: 2026-03-08.

[Khalilzadeh y Bahari, 2023] Khalilzadeh, M. y Bahari, A. (2023). A multi-objective mathematical programing model for the problem of p-envy emergency medical service location. *Health Services Insights*, 16:11786329231195690.

[Kwon *et al.*, 2017] Kwon, P., Kim, M.-J., Lee, Y., Yu, K., y Huh, Y. (2017). Locating automated external defibrillators in a complicated urban environment considering a pedestrian-accessible network that focuses on out-of-hospital cardiac arrests. *ISPRS International Journal of Geo-Information*, 6(2):39.

[Li *et al.*, 2025] Li, J., Wang, X., Zhang, Q., y Tang, P. (2025). Multi-objective optimization of ems facilities using multi-source data: A case study in dangtu, china. *Frontiers of Architectural Research*, 14(4):1090–1107.

[Liao *et al.*, 2026] Liao, R., Zhang, Y., Wang, H., Zhao, T., y Wang, X. (2026). Multi-objective optimisation of surveillance camera placement for bridge–ship collision early-warning using an improved non-dominated sorting genetic algorithm. *Advanced Engineering Informatics*, 69:103918.

[Lin *et al.*, 2016] Lin, B.-C., Chen, C.-W., Chen, C.-C., Kuo, C.-L., Fan, I.-c., Ho, C.-K., Liu, I.-C., y Chan, T.-C. (2016). Spatial decision on allocating automated external defibrillators (aed) in communities by multi-criterion two-step floating catchment area (mc2sfca). *International journal of health geographics*, 15(1):17.

[Lin *et al.*, 2023] Lin, C.-H., Chu, K.-C., Lee, J.-T., y Kao, C.-Y. (2023). Optimal deployment of automated external defibrillators in a long and narrow environment. *Plos one*, 18(2):e0264098.

[Link *et al.*, 2010] Link, M. S., Atkins, D. L., Passman, R. S., Halperin, H. R., Samson, R. A., White, R. D., Cudnik, M. T., Berg, M. D., Kudenchuk, P. J., y Kerber, R. E. (2010). Part 6: electrical therapies: automated external defibrillators, defibrillation, cardioversion, and pacing: 2010 american heart association guidelines for cardiopulmonary resuscitation and emergency cardiovascular care. *Circulation*, 122(18 Suppl 3):S706–19.

[Lorenzo *et al.*, 2020] Lorenzo, G., Maria Antonia, B., Piero Maria, B., Andrea, P., Guido Francesco, V., y Enrico Gianluca, C. (2020). Development of a novel framework to propose new strategies for automated external defibrillators deployment targeting residential out-of-hospital cardiac arrests: Application to the city of milan. *ISPRS International Journal of Geo-Information*, 9(8):491.

[Máximo *et al.*, 2017] Máximo, V. R., Nascimento, M. C., y Carvalho, A. C. (2017). Intelligent-guided adaptive search for the maximum covering location problem. *Computers & Operations Research*, 78:129–137.

[Miettinen, 1999] Miettinen, K. (1999). *Nonlinear multiobjective optimization*, volumen 12. Springer Science & Business Media.

[Ministerio de Salud, 2019] Ministerio de Salud (2019). Ley 21156 | establece la obligaciÓn de disponer de desfibriladores externos automÁticos portÁtiles en los establecimientos y recintos que indica. Biblioteca del Congreso Nacional de Chile.

[New York City Deparment of Health and Mental Hygiene, 2006] New York City Deparment of Health and Mental Hygiene (2006). Report to City Council on Local Law 20: Public Access Defibrillator use in New York City. Technical report, NYC Deparment of Health and Mental Hygiene. Final Report.

[Puligandla y Lončarić, 2020] Puligandla, V. A. y Lončarić, S. (2020). Optimal camera placement to visualize surrounding view from heavy machinery. En *Proceedings of the 2020 2nd Asia Pacific Information Technology Conference*, pp. 52–59.

[Rico *et al.*, 2024] Rico, E., Rabajante, J., Tubay, J., Lapitan, A., y Madrid, V. R. (2024). A multi-objective site selection model for evacuation centers in taguig city, philippines. *Natural Hazards*, 120(9):8303–8321.

[Ringh *et al.*, 2015] Ringh, M., Jonsson, M., Nordberg, P., Fredman, D., Hasselqvist-Ax, I., Håkansson, F., Claesson, A., Riva, G., y Hollenberg, J. (2015). Survival after public access defibrillation in stockholm, sweden–a striking success. *Resuscitation*, 91:1–7.

[Shi *et al.*, 2025] Shi, G., Liu, J., Chen, C., Zhang, J., Xu, J., Chen, Y., Na, J., y Chen, W. (2025). Evaluation and optimization research on the spatial distribution of automated external defibrillators based on a genetic algorithm: A case study of central urban district of nanjing, china. *Systems*, 13(1):64.

[Song *et al.*, 2020] Song, J., Li, X., y Mango, J. (2020). Location optimization of urban emergency medical service stations: a hierarchical multi-objective model with a new encoding

method of genetic algorithm solution. En *International Symposium on Web and Wireless Geographical Information Systems*, pp. 68–82. Springer.

[Teitz y Bart, 1968] Teitz, M. B. y Bart, P. (1968). Heuristic methods for estimating the generalized vertex median of a weighted graph. *Operations research*, 16(5):955–961.

[Tierney *et al.*, 2018] Tierney, N. J., Reinhold, H. J., Mira, A., Weiser, M., Burkart, R., Benvenuti, C., y Auricchio, A. (2018). Novel relocation methods for automatic external defibrillator improve out-of-hospital cardiac arrest coverage under limited resources. *Resuscitation*, 125:83–89.

[Toregas *et al.*, 1971] Toregas, C., Swain, R., ReVelle, C., y Bergman, L. (1971). The location of emergency service facilities. *Operations research*, 19(6):1363–1373.

[Valenzuela *et al.*, 2000] Valenzuela, T. D., Roe, D. J., Nichol, G., Clark, L. L., Spaite, D. W., y Hardman, R. G. (2000). Outcomes of rapid defibrillation by security officers after cardiac arrest in casinos. *New England Journal of Medicine*, 343(17):1206–1209.

[Wang *et al.*, 2019] Wang, X., Zhang, H., y Gu, H. (2019). Solving optimal camera placement problems in iot using lh-rpso. *IEEE Access*, 8:40881–40891.

[Xu *et al.*, 2025] Xu, Q., Zeng, L., Gao, M., Lu, Z., y Xie, G. (2025). Roadside visual sensor deployment in urban networks considering vehicle control boundary. *IEEE Sensors Journal*, 25(6):10196–10210.

[Yang *et al.*, 2018] Yang, X., Li, H., Huang, T., Zhai, X., Wang, F., y Wang, C. (2018). Computer-aided optimization of surveillance cameras placement on construction sites. *Computer-Aided Civil and Infrastructure Engineering*, 33(12):1110–1126.

[Yue *et al.*, 2025] Yue, C., Zhang, Z., Liu, B., Du, Z., Ji, B., y Li, F. (2025). Optimization of surveillance placement in rocket debris drop zone based on weight system and improved nsga-iii. En *2025 5th International Conference on Computer Vision, Application and Algorithm (CVAA)*, pp. 292–299. IEEE.

[Zarandi *et al.*, 2011] Zarandi, M. F., Davari, S., y Sisakht, S. H. (2011). The large scale maximal covering location problem. *Scientia Iranica*, 18(6):1564–1570.

[Zhang y Li, 2007] Zhang, Q. y Li, H. (2007). Moea/d: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on evolutionary computation*, 11(6):712–731.

[Zhong y Wei, 2024] Zhong, H. y Wei, Z. (2024). Optimizing automated external defibrillator (aeds) placement through multi-objective analysis: A case study of guangzhou's core urban area. En *Proceedings of the 2024 3rd International Conference on Public Health and Data Science*, pp. 310–316.