

Modelo de optimización multi-objetivo para el 2E-LIRP multi-producto aplicado a la gestión de la cadena de suministro humanitaria

Andrés Guillermo Angarita Monroy

Trabajo de investigación para optar el título de Magister en Ingeniería Industrial

Director:

Henry Lamos Díaz

PhD. Física-Matemática

Universidad Industrial de Santander

Facultad de Ingenierías Físico-Mecánicas

Escuela de Estudios Industriales y Empresariales

Maestría en Ingeniería Industrial

Bucaramanga

2021

Agradecimientos

A Dios por brindarme la salud, vida, familia y sabiduría suficiente para sobrepasar los retos de estos últimos dos años

A mis padres, María Deisy Monroy (mi primera profesora) y Guillermo Angarita Carvajal, dos personas que forman parte especial en mi vida, a ellos les debo todo lo que soy; gracias por creer siempre en mí y apoyarme incondicionalmente

Mi hermana Vivian Rocío Angarita, persona muy especial, quien con su actitud y forma de ver el mundo, hace de mi diario vivir algo fuera de lo común

Un agradecimiento muy especial para la mujer que me ha acompañado durante un largo tiempo de esta travesía, llamada “vida”; quien con sus cuidados, entrega y motivación han permitido que sea un mejor ser humano y profesional. Mi total admiración y profundo aprecio para Gennifer Lisseth Hernández

Al director del presente trabajo, Henry Lamos Díaz, un gran personaje y docente en todo el sentido de la palabra. Gracias por enseñarme a asumir retos, romper esquemas y motivarme continuamente

A los profesores, Javier Eduardo Arias, Carlos Eduardo Díaz, Aura Cecilia Pedraza, entre otros docentes y profesionales de la gran familia EEIE, quienes durante estos últimos años han aportado de diversas formas a mi crecimiento profesional; me llevo grandes enseñanzas y aprendizajes de valor

Finalmente, pero no menos importante, agradezco a mis compañeros de la cohorte 11 y más que compañeros, a la “manada”: Sonia, Daniela, Silvia, Gabriel, Samuel, Javier y Gerardo; con ustedes pasé tiempos muy agradables y viví diversas experiencias durante este proceso de formación, aprendí mucho de cada uno (personas excepcionales); gracias por la paciencia y buena actitud (ustedes entenderán)

Tabla de Contenido

	Pág.
Introducción	15
1. Revisión de Literatura	18
1.1. Modelos LIRP Multi-Escalón	18
1.2. Modelos LIRP Multi-Escalón en Logística Humanitaria.....	22
1.3. Caracterización de los Estudios LIRP Multi-escalón.....	25
1.4. Inclusión de los Costos de Privación en los Modelos Logísticos	28
1.5. Caracterización de los DC en Logística Humanitaria	36
1.6. Computación Paralela y Metaheurísticas Cooperativas	38
2. Justificación y Planteamiento del Problema.....	41
3. Objetivos.....	45
3.1. Objetivo General	45
3.2. Objetivos Específicos.....	45
4. Hipótesis	46
4.1. Hipótesis 1.....	46
4.2. Hipótesis 2.....	46
5. Marco Teórico	47
5.1. Algoritmos Evolutivos	47
5.1.1. Algoritmo genético	47

5.1.2.	Algoritmos evolutivos multi-objetivo.....	49
5.1.3.	Algoritmo genético de ordenamiento no-dominado versión II.....	50
5.1.4.	Algoritmo evolutivo de fuerza de Pareto versión II.....	51
5.2.	Optimización Multi-objetivo.....	53
5.2.1.	Dominancia de Pareto.....	54
5.2.2.	Pareto óptimo.....	54
5.2.3.	Conjunto Pareto óptimo.....	55
5.2.4.	Frente de Pareto óptimo.....	55
5.3.	Paralelización de Algoritmos Evolutivos.....	55
5.3.1.	Algoritmos evolutivos paralelos multiobjetivo.....	56
5.3.2.	Modelo maestro-esclavo.....	57
5.3.3.	Modelo de difusión.....	57
5.3.4.	Modelo de islas.....	58
5.4.	Gestión de la Cadena de Suministro Humanitaria.....	59
5.4.1.	Definición y clasificación de un desastre.....	60
5.4.2.	Definición de logística humanitaria.....	60
5.4.3.	Justificación de la cadena de suministro humanitaria.....	61
5.4.4.	Fases para la gestión de un desastre.....	62
6.	Modelo 2E-LIRP.....	64
6.1.	Ilustración del 2E-LIRP.....	64

6.2.	Descripción del 2E-LIRP	65
6.3.	Supuestos del Estudio.....	70
6.4.	Formulación Matemática.....	72
6.4.1.	Conjuntos	73
6.4.2.	Índices	73
6.4.3.	Parámetros.....	73
6.4.4.	Variables de decisión	74
6.4.5.	Función objetivo	75
6.4.6.	Restricciones	76
6.4.6.1.	Restricciones segundo escalón.	76
6.4.6.2.	Restricciones primer escalón	77
6.4.6.3.	Restricciones variables de decisión	78
6.5.	Interpretación Modelo de Optimización	78
6.5.1.	Función objetivo	78
6.5.2.	Restricciones segundo escalón.....	79
6.5.3.	Restricciones primer escalón	80
6.5.4.	Restricciones variables de decisión	81
7.	Diseño de los Algoritmos Evolutivos	82
7.1.	Lectura de Parámetros Iniciales	82
7.2.	Representación de la Solución	84

7.2.1.	Sub-cadena 1	85
7.2.2.	Sub-cadena 2	85
7.2.3.	Sub-cadena 3	87
7.3.	Generación de la Población Inicial.....	88
7.4.	Operadores Genéticos	93
7.4.1.	Operador de cruce	93
7.4.2.	Operador de mutación.....	97
7.4.3.	Operador de selección.....	98
7.5.	Función Fitness	98
8.	Construcción de los Algoritmos Evolutivos Paralelo-Cooperativo (<i>p</i> -EA_V1)	100
8.1.	Diagrama de Flujo para el <i>p</i> -GA_V1	102
8.1.1.	Análisis del coordinador en el <i>p</i> -GA_V1.....	104
8.1.1.1.	Política de funcionamiento.....	104
8.2.	Diagrama de Flujo para el <i>p</i> -NSGA-II_V1	106
8.2.1.	Análisis del coordinador en el <i>p</i> -NSGA-II_V1	108
8.2.1.1.	Política de funcionamiento	108
8.3.	Diagrama de Flujo para el <i>p</i> -SPEA-II_V1	110
8.3.1.	Análisis del coordinador en el <i>p</i> -SPEA-II_V1.....	113
8.3.1.1.	Política de funcionamiento	113
9.	Validación y Calibración de los Algoritmos Evolutivos	115

9.1.	Análisis de Resultados DOE	126
10.	Comprobación Hipótesis de Investigación	130
10.1.	Resultados Hipótesis 1.....	132
10.1.1.	Análisis prueba t de dos muestras (Hipótesis 1)	135
10.2.	Resultados Hipótesis 2.....	137
10.2.1.	Análisis prueba t de dos muestras (Hipótesis 2)	140
11.	Diseño de los Algoritmos p -GA_V2 y p -NSGA-II_V2	142
11.1.	Resultados Adaptación Hipótesis 1	144
11.1.1.	Análisis prueba t de dos muestras (Adaptación hipótesis 1).....	147
11.2.	Resultados Adaptación Hipótesis 2	149
11.2.1.	Análisis prueba t de dos muestras (Adaptación hipótesis 2).....	152
12.	Discusión.....	155
13.	Conclusiones	157
	Referencias bibliográficas.....	160

Lista de Tablas

	Pág.
Tabla 1. Características asociadas al LIRP multi-escalón.	26
Tabla 2. Clasificación de estudios relacionados al LIRP multi-escalón.	26
Tabla 3. Características de los estudios en logística humanitaria.	36
Tabla 4. Técnicas y enfoques para la estimación de la DCF.	37
Tabla 5. Suministros básicos demandados durante un desastre.	66
Tabla 6. Conjunto de instancias para la validación de los EA.	115
Tabla 7. Diseño factorial para las técnicas mono-objetivo.	116
Tabla 8. Diseño factorial para las técnicas multi-objetivo.	116
Tabla 9. Resumen DOE para el GA (MS).	118
Tabla 10. Resumen DOE para el GA (TC).	119
Tabla 11. Resumen DOE para el <i>p</i> -GA_V1 (MS).	120
Tabla 12. Resumen DOE para el <i>p</i> -GA_V1 (TC).	121
Tabla 13. Resumen DOE para el <i>p</i> -NSGA-II_V1 (SND).	122
Tabla 14. Resumen DOE para el <i>p</i> -NSGA-II_V1 (TC).	123
Tabla 15. Resumen DOE para el <i>p</i> -SPEA-II_V1 (SND).	124
Tabla 16. Resumen DOE para el <i>p</i> -SPEA-II_V1 (TC).	125
Tabla 17. Combinación óptima de factores asociados con los EA.	129
Tabla 18. Prueba de hipótesis algoritmos <i>p</i> -NSGA-II_V1 y <i>p</i> -SPEA-II_V1 (TC).	132
Tabla 19. GAP entre los algoritmos <i>p</i> -NSGA-II_V1 y <i>p</i> -SPEA-II_V1 (n = 30).	133
Tabla 20. Prueba de hipótesis algoritmos <i>p</i> -NSGA-II_V1 y <i>p</i> -SPEA-II_V1 (SND).	134
Tabla 21. Prueba de hipótesis algoritmos <i>p</i> -GA_V1 y GA (TC).	137

Tabla 22. GAP entre los algoritmos p -GA_V1 y GA ($n = 30$).....	138
Tabla 23. Prueba de hipótesis algoritmos p -GA_V1 y GA (MS).....	139
Tabla 24. GAP entre los algoritmos p -NSGA-II_V2 y p -SPEA-II_V1 ($n = 30$).....	144
Tabla 25. Prueba de hipótesis algoritmos p -NSGA-II_V2 y p -SPEA_V1 (TC).	145
Tabla 26. Prueba de hipótesis algoritmos p -NSGA-II_V2 y p -SPEA_V1 (SND).	146
Tabla 27. Comparación p -NSGA-II_V1 y p -NSGA-II_V2.....	148
Tabla 28. Prueba de hipótesis algoritmos p -GA_V2 y GA (MS).....	149
Tabla 29. Prueba de hipótesis algoritmos p -GA_V2 y GA (TC).....	150
Tabla 30. GAP entre los algoritmos p -GA_V2 y GA ($n = 30$).....	151
Tabla 31. Comparación p -GA_V1 y p -GA_V2.....	152

Lista de Figuras

	Pág.
Figura 1. Pseudocódigo del GA.....	48
Figura 2. Pseudocódigo del NSGA-II.....	51
Figura 3. Pseudocódigo del SPEA-II.....	52
Figura 4. Topologías de vecindarios en 2D utilizables en algoritmos distribuidos.....	58
Figura 5. Distribución de una población inicial en n islas con ejecución paralela.....	59
Figura 6. Representación gráfica del 2E-LIRP.....	64
Figura 7. Sub-cadena para la asignación y localización de instalaciones (Primer y segundo escalón).....	85
Figura 8. Sub-cadena para el plan de rutas (Primer y segundo escalón).....	86
Figura 9. Sub-cadena para la administración del inventario (Q e I) en las instalaciones de primer nivel.....	88
Figura 10. Estructura de localización-asignación (Segundo escalón).....	89
Figura 11. Estructura del plan de rutas (Segundo escalón).....	89
Figura 12. Estructura de localización-asignación (Primer escalón).....	90
Figura 13. Estructura del plan de rutas (Primer escalón).....	90
Figura 14. Estructura relacionada con la administración del inventario para el CR1.....	92
Figura 15. Sub-cadena 1 del padre 1.....	94
Figura 16. Sub-cadena 1 del padre 2.....	94
Figura 17. Sub-cadena 1 del hijo 1.....	94
Figura 18. Sub-cadena 1 del hijo 2.....	95
Figura 19. Estructura paralela y cooperativa del p -GA_V1 con operación asincrónica.....	103

Figura 20. Estructura paralela y cooperativa del p -NSGA-II_V1 con operación asincrónica....	108
Figura 21. Estructura paralela y cooperativa del p -SPEA-II_V1 con operación asincrónica.....	112
Figura 22. Comparación GAP p -GA_V1-GA y p -GA_V2 (MS).....	153
Figura 23. Comparación GAP p -GA_V1-GA y p -GA_V2 (TC).....	154

Lista de Apéndices

Los apéndices están adjuntos y puede visualizarlos en la base de datos de la biblioteca UIS.

Apéndice A. Diagramas de Flujo Algoritmos Evolutivos Secuenciales

Apéndice B. Codificación del GA Secuencial y los p -EA_V1 en Python

Apéndice C. Instancias de Prueba

Apéndice D. Datos Obtenidos del DOE para los EA

Apéndice E. Análisis del DOE en los EA

Apéndice F. Datos Generados para Contrastar Hipótesis con los p -EA_V1

Apéndice G. Prueba t de Varianza Conjunta Aplicada a los EA_V1

Apéndice H. Diagrama de Flujo y Codificación en Python de los p -EA_V2

Apéndice I. Datos Generados para Contrastar Hipótesis con los p -EA_V2

Apéndice J. Prueba t de Varianza Conjunta Aplicada a los EA_V2

Resumen

Título: Modelo de optimización multi-objetivo para el 2E-LIRP multi-producto aplicado a la gestión de la cadena de suministro humanitaria*

Autor: Andrés Guillermo Angarita Monroy**

Palabras claves: Inventario, localización, logística humanitaria, multi-producto, optimización evolutiva, ruteo.

Descripción:

Los desastres en todo el mundo son cada vez más frecuentes, diversos, complejos y extremadamente desafiantes, ya que causan millones de víctimas y afectan tanto el desarrollo humano como los recursos disponibles. En consecuencia, el presente estudio aborda un problema multi-objetivo de localización, inventario y ruteo multi-escalón (2E-LIRP), el cual apoya la toma de decisiones integrales, para que el encargado de diseñar y gestionar la red logística obtenga una adecuada planeación estratégica frente a la incertidumbre y el impacto negativo que puede generar un evento adverso. Más aún, el problema es formulado como un modelo de programación lineal entera, teniendo como principales objetivos, minimizar los costos logísticos privados y su vez, maximizar el bienestar de las áreas afectadas, considerando demanda dinámica, múltiples productos y flota heterogénea. Debido a la complejidad computacional asociada al modelo, se propone un nuevo enfoque de solución, basado en el diseño de algoritmos metaheurísticos evolutivos; el primero, conocido como algoritmo genético de ordenamiento no dominado versión II (NSGA-II), el segundo, algoritmo evolutivo de fuerza de Pareto versión II (SPEA-II) y el tercero, llamado algoritmo genético (GA), programados en paralelo y ejecutados individualmente bajo un entorno de cooperación. Finalmente, la experimentación llevada a cabo permite inferir que el enfoque paralelo-cooperativo y netamente paralelo aplicado al NSGA-II, mejora sustancialmente los tiempos de procesamiento y la cantidad de soluciones no dominadas, si se compara con los resultados obtenidos por el SPEA-II, diseñado bajo idénticas condiciones. Además, al construir un GA con estas mismas características, mejora hasta el 50% de las soluciones en el conjunto de prueba utilizado, con tiempos de cómputo semejantes a su contraparte secuencial.

* Tesis de Maestría.

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Estudios Industriales y Empresariales. Maestría en Ingeniería Industrial. Director: Henry Lamos Díaz. PhD. Física-Matemática.

Abstract

Title: Multi-objective optimization model for multi-product 2E-LIRP applied to humanitarian supply chain management*

Author: Andrés Guillermo Angarita Monroy**

Keywords: Evolutionary optimization, humanitarian logistics, inventory, location, multi-product, routing.

Description:

Disasters around the world are becoming more frequent, diverse, complex and extremely challenging, causing millions of casualties and affecting both human development and available resources. Consequently, the present study addresses a multi-objective location, inventory and multi-echelon routing problem (2E-LIRP), which supports comprehensive decision making, so that the logistics network designer and manager can obtain adequate strategic planning in the face of uncertainty and the negative impact that an adverse event can generate. Moreover, the problem is formulated as an integer linear programming model, having as main objectives to minimize private logistics costs and maximize the welfare of the affected areas, considering dynamic demand, multiple products and heterogeneous fleet. Due to the computational complexity associated with the model, a new solution approach is proposed, based on the design of evolutionary metaheuristic algorithms; the first one, known as Non-dominated Sorting Genetic Algorithm version II (NSGA-II), the second one, Strength Pareto Evolutionary Algorithm version II (SPEA-II) and the third one, called Genetic Algorithm (GA), programmed in parallel and executed individually under a cooperative environment. Finally, the experimentation carried out allows inferring that the parallel-cooperative and purely parallel approach applied to the NSGA-II, substantially improves the processing times and the number of non-dominated solutions, if compared to the results obtained by the SPEA-II, designed under identical conditions. Moreover, by building a GA with these same characteristics, it improves up to 50% of the solutions in the test set used, with computation times similar to its sequential counterpart.

* Master Thesis.

** Faculty of Physical-Mechanical Engineering. School of Industrial and Business Studies. Master's Degree in Industrial Engineering. Director: Henry Lamos Díaz. PhD. Physics-Mathematics.

Introducción

La ocurrencia de desastres naturales y sus consecuencias devastadoras son una realidad que se vive año tras año alrededor del mundo. Aproximadamente el 75% de la población mundial vive en regiones afectadas, al menos una vez entre 1980 y 2017, por un terremoto, un ciclón tropical, una inundación o una sequía. Como consecuencia de estos fenómenos, cada día mueren más de 184 personas en distintas partes del mundo y arrojan un saldo que incluye la destrucción de activos fijos, capital físico, la interrupción de la producción, el comercio y la disminución de los ahorros e inversiones públicas y privadas, que acaban con el progreso en materia de desarrollo económico (Nagurney et al., 2019). Esta problemática ha generado un profundo interés por buscar y establecer los mecanismos más eficientes, que permitan mejorar la respuesta a situaciones de emergencia, dando así lugar al surgimiento de la logística humanitaria como un medio para afrontar los efectos negativos de eventos adversos que ponen en riesgo la integridad o la vida propia del ser humano.

A pesar de las investigaciones y el progreso tecnológico, todavía no es posible predecir cuándo y dónde ocurrirá un desastre natural de antemano; por lo tanto, las actividades o acciones previas, durante y posteriores a su ocurrencia, son importantes para disminuir las pérdidas asociadas. En particular, los especialistas en investigación de operaciones, han aceptado el desafío de apoyar tales actividades mediante el desarrollo de modelos, métodos y técnicas pertinentes, como lo demuestra el aumento en el número de artículos de investigación sobre logística humanitaria durante la última década (Kunz & Reiner, 2012). Más aún, cuando ocurre un desastre en cierta parte del mundo, muchas organizaciones se presentan para proporcionar los artículos de ayuda requeridos, por ejemplo, alimento, agua, medicina, entre otros, a las personas afectadas. En estas situaciones, la coordinación entre los diferentes miembros es crucial y se vuelve difícil para una sola organización llevar a cabo todas las actividades necesarias, como reparar las

infraestructuras dañadas y entregar los elementos de ayuda. Además, la logística humanitaria se convierte en una red compleja con diferentes actores, que incluyen, organizaciones no gubernamentales (ONG) de origen local o internacional, donantes, fuerzas armadas, corporaciones y empresas privadas; cada uno de ellos con intereses, obligaciones, capacidades, estructura de asignación presupuestaria y habilidades logísticas diferentes y a veces, conflictivas (Nikkhoo et al., 2018). Por esta razón, el diseño y la gestión necesarias en la red logística durante las fases de pre y pos-desastre no pueden ser improvisadas; deben ser el resultado de una correcta y rigurosa planificación, en la cual se pueda identificar y establecer con anterioridad aspectos muy importantes, como lo es, la ubicación de las instalaciones, la disponibilidad y calidad de los recursos a través de una adecuada administración del inventario, la flexibilidad en los planes de ruta según el presupuesto establecido, entre otros, que permiten en última instancia garantizar una respuesta óptima cuando se realiza el despliegue de las operaciones humanitarias.

En consecuencia, el presente estudio aborda un problema multi-objetivo de localización, inventario y ruteo multi-escalón, conocido en la literatura bajo las siglas 2E-LIRP, el cual apoya la toma de decisiones integrales, para que el encargado de diseñar la red logística obtenga una adecuada planeación estratégica, frente a la incertidumbre y el impacto negativo que puede generar un evento adverso. Debido a la complejidad computacional asociada al modelo, se propone un nuevo enfoque de solución, basado en el diseño de algoritmos metaheurísticos, programados en paralelo y ejecutados individualmente bajo un entorno de cooperación, con el fin de compartir información, que permita mejorar la eficiencia y calidad en la respuesta. Por otro lado, se propone la adición de los costos de privación en la función objetivo del modelo, como lo sugiere Holguín-Veras et al. (2013), dado que las aplicaciones humanitarias actuales en su mayoría son simples extensiones de modelos logísticos comerciales, que por lo general no tienen en cuenta las

externalidades (interrupciones en la cadena de suministro), lo cual genera altos costos sociales y en muchas ocasiones, soluciones inviables o sub-óptimas, pues los intereses no están alineados con el principal objetivo: salvar vidas y aliviar el sufrimiento humano durante y después de un desastre.

El documento es organizado de la siguiente manera: la sección 1 presenta la revisión de literatura sobre los tópicos principales de investigación; la sección 2 ofrece una justificación y planteamiento del problema abordado; mientras que los objetivos e hipótesis a probar, son descritos en la sección 3 y 4 respectivamente. La sección 5 está vinculada al marco teórico, el cual presenta los conceptos fundamentales que permiten una mejor comprensión del estudio, junto a la sección 6, donde se construye y describe con total claridad el modelo matemático; además de la sección 7, dedicada a la representación general de las técnicas de solución empleadas. Por otro lado, la sección 8, muestra el diseño específico de los algoritmos evolutivos paralelo-cooperativo, que permiten a través del testbed, la validación y calibración de los mismos en la sección 9. La sección 10, está enfocada a la comprobación de las hipótesis, seguido de la sección 11, desarrollada como un producto adicional, luego de verificar estas. Finalmente, la sección 12 y 13 presentan la discusión y conclusiones, dada la experimentación realizada.

1. Revisión de Literatura

1.1. Modelos LIRP Multi-Escalón

Las organizaciones suelen realizar una serie de actividades, como comprar materias primas a proveedores, fabricar, almacenar productos terminados en instalaciones intermedias y entregarlos a los clientes finales. Por lo tanto, es posible identificar cuatro funciones principales en una cadena de suministro: compras, fabricación, inventario y distribución. Dado que las principales funciones de la SC están fuertemente interrelacionadas por los materiales y los flujos de información, no pueden gestionarse individualmente (Vidal & Goetschalckx, 1997), por lo que una buena coordinación de ellas es un tema crítico en la mayoría de las empresas industriales, prestadoras de servicios y especialmente para las organizaciones humanitarias, en su búsqueda de reducir los costos logísticos. Una gestión de la cadena de suministro (Supply Chain Management, SCM) efectiva, ayuda a reducir sustancialmente los costos operativos y aumenta el nivel de servicio a los grupos de impacto. Para diseñar y administrar de manera efectiva redes de distribución a gran escala, Gonzalez-Feliu (2013) menciona que se debe desarrollar conjuntamente la planificación estratégica a largo plazo, la planificación táctica a mediano plazo y la planificación operativa a corto plazo, dando así origen a los sistemas multi-escalón, creados para asociar los diversos actores de la cadena de suministro, con las decisiones fundamentales que se deben tomar en las diferentes ventanas de tiempo y lograr de esta manera mayores beneficios, ser más eficientes y mantener una red mucho más sólida; para el caso de interés, se estudian específicamente los sistemas LIRP multi-escalón, también llamados NE-LIRP (N-Echelon Location Inventory Routing problem), donde N representa el número de escalones que intervienen en la red y, toma valores mayores o iguales a dos (Dondo et al., 2011).

Para ilustrar el gran campo de aplicación y las diferentes configuraciones que poseen estos sistemas, se presenta la investigación realizada por Tavakkoli-Moghaddam et al. (2013), quienes incorporan al problema de localización, ruteo e inventario de dos escalones (2E-LIRP), agrupación de riesgos; considerando así un diseño de red con fuente única, para una cadena de suministro de tres niveles. Por primera vez, se presenta un modelo matemático que considera un conjunto de riesgos, la existencia de inventario en los centros de distribución (DC) bajo incertidumbre de la demanda, la presencia de varias alternativas para transportar el producto entre las instalaciones y el ruteo de vehículos desde los DC al cliente, todo esto, bajo un sistema estocástico de cadena de suministro simultáneamente. Para dar solución al problema, usan el software Lingo, aunque señalan para futuras investigaciones, la necesidad de usar un algoritmo heurístico o metaheurístico. Por su parte, Ghorbani & Akbari Jokar (2016), plantean un algoritmo híbrido de recocido simulado-imperialista competitivo (Hybrid Imperialist Competitive-Simulated Annealing, HIC-SA) para un 2E-LIRP. Diseña un nuevo algoritmo heurístico híbrido basado en el recocido simulado y el algoritmo imperialista competitivo (Imperialist Competitive, IC) para resolver el modelo. Además, Tavakkoli-Moghaddam & Raziei (2016), construyen un problema de dos objetivos, para el LIRP multi-escalón, con demanda difusa, que considera múltiples períodos y productos, con flotas heterogéneas en los dos escalones. Los resultados numéricos demuestran la validez del modelo presentado y muestran la capacidad para enfrentar casos reales.

Siguiendo con el tema central en estudio, Zhalechian et al. (2016), diseñan una red de cadena de suministro con circuito cerrado (Closed-Loop Supply Chains, CLSCs) para el 2E-LIRP bajo incertidumbre mixta. Se proporciona un estudio de caso real para demostrar la aplicabilidad del modelo y se realizan varios análisis en profundidad, desarrollando así implicaciones de gestión. Asimismo, Nakhjirkan & Mokhtab Rafiei (2017), afirman que la tendencia creciente en el

consumo de recursos naturales ha causado pérdidas irreparables al medio ambiente; una de las formas más efectivas de lidiar con los efectos ambientales adversos, es mediante la implementación de cadenas de suministro ecológica (Green Supply Chain, GSC), por lo que proponen un modelo matemático 3E-LIRP (Three Echelon Location Inventory Routing Problem) que incluye los eslabones de suministro, producción, distribución y clientes, en la GSC. El modelo se codificó utilizando GAMS/CPLEX para el método de solución exacto y MATLAB para implementar el algoritmo genético. Por otro lado, Zhao & Ke (2017), inician su estudio argumentando que los desechos explosivos, representan amenazas crecientes para las personas y el medio ambiente, durante el proceso de transporte, recolección y almacenamiento periódico; llamando así la atención para reducir el riesgo ambiental derivado de la ubicación de las instalaciones, el nivel de inventario y el plan rutas para los vehículos en múltiples depósitos. Se propone una técnica de solución basada en la técnica para el orden de preferencia por similitud con la solución ideal (Technique for Order of Preference by Similarity to Ideal Solution, TOPSIS), que permite resolver el modelo de optimización dentro de un tiempo de cálculo razonable. Más aún, los investigadores Guo et al. (2018), formulan un modelo de programación no lineal entera mixta (Mixed Integer Non-Linear Programming, MINLP) para una cadena de suministro de circuito cerrado (Location Inventory Routing Problem in a Closed-Loop, 2E-LIRP-CL), que se ha convertido en un tema emergente e importante debido al tremendo impacto económico y ambiental, en términos de los retornos por parte de los consumidores. Dado que el problema es NP-hard, construyen un nuevo GA adaptativo, incorporando el SA para resolver este modelo de manera eficiente. El anterior estudio, puede ser comparado con la investigación expuesta por Yuchi et al. (2018), en la que se presenta un 2E-LIRP-CL, pero se considera tanto la demanda de los

clientes como las devoluciones aleatorias. Utilizan un algoritmo heurístico híbrido, basado en la búsqueda tabú y el recocido simulado, para dar solución al modelo propuesto.

Continuando con la revisión, Fatemi Ghomi & Asgarian (2019), proponen un modelo matemático novedoso para el problema de ruteo, localización y transporte de inventario de tres niveles (dos escalones) en la cadena de suministro (Transportation Inventory Location Routing Problem, 2E-TILRP), aplicado en redes de distribución para productos perecederos. Plantean tres metaheurísticas diferentes para obtener salidas al problema, la primera, conocida como optimización por enjambre de partículas (Particle Swarm Optimization, PSO), la segunda, un algoritmo evolucionario, denominado optimización basada en biogeografía (Biogeography-Based Optimization, BBO) y la última, llamada optimización basada en biogeografía por hábitat (Habitat Biogeography-Based Optimization, HBBO). Del mismo modo, Nakhjirkan et al. (2019), describen una cadena de suministro para cuatro niveles (tres escalones), que incluye proveedores, productores, distribuidores y clientes. El problema considerado, está asociado al 3E-LIRP, con demanda incierta. Para validar el modelo matemático, se han generado y resuelto varios problemas utilizando el software GAMS, además se propone un algoritmo genético basado en el análisis de envoltura de datos en red (Network Data Envelopment Analysis, NDEA).

Por otra parte, Saragih et al. (2019), exponen un algoritmo heurístico para el LIRP, en un sistema de cadena de suministro de tres niveles (dos escalones), donde las decisiones de inventario se toman en las tres entidades involucradas. El método heurístico, denominado recocido simulado, consta de dos etapas, la primera, llamada etapa constructiva y la segunda, etapa de mejora. Además, resulta importante presentar el trabajo de Biuki et al. (2020), quienes construyen un modelo integrado para el 3E-LIRP, orientado al diseño sostenible de una red de productos perecederos. Dado que encontrar la solución óptima para este problema es casi imposible a través

de métodos exactos, se utilizan dos metaheurísticas híbridas de forma combinada (serie) y en paralelo, las cuales reciben el nombre de algoritmo genético y optimización por enjambre de partículas.

1.2. Modelos LIRP Multi-Escalón en Logística Humanitaria

Luego de abordar bajo un enfoque multidisciplinario el LIRP multi-escalón, se presenta a continuación algunos de los estudios más destacados y útiles en el campo de la logística humanitaria, que servirán finalmente como referente para la presente investigación en curso.

Se inicia esta revisión, con el estudio publicado por Bozorgi-Amiri & Khorsi (2016), quienes formulan un modelo de programación lineal estocástica-dinámica multi-objetivo, para un problema logístico de ayuda humanitaria, en el que se toman decisiones antes y después del desastre. Dicho modelo se compone de dos etapas; la primera, determina la ubicación para los centros de distribución de socorro (Relief Distribution Centers, RDC) y la cantidad de inventario requerido para cada uno de los artículos almacenados, y la segunda etapa, obtiene las rutas y la cantidad de transporte necesario desde los proveedores a los RDC y desde estos a las áreas afectadas (Affected Areas, AA); cumpliendo tres objetivos, minimizar la demanda insatisfecha, el tiempo de viaje y los costos pre y pos-desastre. Por otro lado, los investigadores consideran los parámetros del tiempo de viaje, así como la demanda, la oferta y el costo bajo incertidumbre; solucionan el problema, utilizando el método de restricción ϵ . Igualmente, Rayat et al. (2017) diseñan un modelo confiable al problema 2E-LIRP multi-objetivo, multi-producto y multi-periodo en la cadena de suministro humanitaria, que tiene en cuenta los riesgos de interrupción. En el estudio, se considera un sistema de inventario con demanda estocástica, en el que la entrega del producto se interrumpe al azar en los centros de distribución. El pedido parcial se usa en caso de que se agoten las existencias, considerando la probabilidad de los impactos enfrentados en los

centros de distribución, en el momento de la interrupción. El primer objetivo minimiza los costos de localización, ruteo y los componentes del inventario, que consisten en pedidos, retención y costos parciales de solicitudes pendientes; además, el segundo objetivo, buscar minimizar los costos totales de falla, relacionados con los centros de distribución interrumpidos, que conducen a la confiabilidad de la red en la cadena de suministro. Debido a la dureza NP del modelo propuesto, ajustan el algoritmo metaheurístico de recocido simulado y archivado (Archived Multi-Objective Simulated Annealing, AMOSA) para resolver el problema a gran escala y comparan los resultados con otros tres algoritmos, los cuales son, el algoritmo genético de ordenamiento no dominado versión II, optimización por enjambre de partículas multi-objetivo (Multi-Objective Particle Swarm Optimization, MOPSO) y el algoritmo evolutivo multi-objetivo basado en descomposición (Multi-Objective Evolutionary Algorithm based on Decomposition, MOEA). Más aún, Tavana et al. (2018) construyen una red logística humanitaria de múltiples niveles, que considera la ubicación de los almacenes centrales, gestiona el inventario de productos perecederos en la fase previa al desastre y determina las rutas para los vehículos de socorro en la fase posterior al desastre. La red propuesta ha sido modelada a través de tres funciones objetivo, donde la primera minimiza el costo total de adquisición y preparación en la fase previa al desastre, es decir, los costos que se deriva de la creación de almacenes, almacenamiento, transporte de productos de socorro desde los proveedores a almacenes y la gestión de un control de inventario para productos perecederos, por otro lado, la segunda función objetivo minimiza el costo total de las operaciones de socorro en la fase posterior al desastre, estos costos incluyen transporte, carga y descarga de productos, escasez de productos y productos no utilizados, mientras que la tercera función objetivo minimiza el tiempo total de socorro operativo, en la fase de acción después de que ocurra el desastre, el cual incluye el tiempo de transporte, carga y descarga. Se propone un método de restricción ϵ

(Epsilon Constraint Method, ϵ -CM), un algoritmo genético de ordenamiento no dominado versión II (Non-dominated Sorting Genetic Algorithm, NSGA-II) y un NSGA-II modificado llamado algoritmo genético de clasificación no dominado basado en puntos de referencia-II (Reference Point Based Non-dominated Sorting Genetic Algorithm, RPBNSGA-II) para resolver el problema de programación lineal entera mixta (Mixed Integer Linear Programming, MILP).

Una investigación que ha causado interés durante la revisión, es la expuesta por Vahdani et al. (2018), los cuales manifiestan que la naturaleza accidental e impredecible de los desastres, como es el caso de los terremotos, generan la necesidad de crear algunos planes para hacer frente a problemas críticos, con el fin de reducir los peligros en el momento de su ocurrencia. La distribución efectiva de bienes y suministros de socorro, juega un papel importante en la operación de rescate luego de cualquier desastre. Por lo tanto, los investigadores presentan dos modelos matemáticos multi-objetivo, multi-periodo y multi-producto de dos fases, para el 2E-LIRP en la cadena de alivio de tres niveles (dos escalones). La principal característica diferenciadora es que, en el segundo modelo suponen entrega dividida por demanda de los clientes (áreas afectadas); además, en el primer modelo, se consideran las condiciones de incertidumbre, lo que aumenta la eficiencia de la red y la hace más realista. En ambos modelos, la primera fase aborda la gestión de inventario, ubicación de los centros de distribución, la cantidad de bienes a despachar y la asignación de áreas críticas a los centros de distribución y almacenes. En la segunda fase, se considera el diseño de la ruta para los vehículos y el momento de la distribución de los bienes a las áreas de desastre. Por otra parte, utilizaron dos algoritmos metaheurísticos, conocidos como NSGA-II y MOPSO que permiten resolver el problema dado. Finalmente, Ghorashi et al. (2019), afirman que debido al papel prominente de la sangre en la vida humana, es esencial diseñar una cadena de suministro de sangre eficiente, en caso de una situación de emergencia. Los desastres

naturales como un terremoto, un volcán y un tsunami producen una gran influencia en la vida humana; en tales casos, debido a la gran cantidad de personas lesionadas, la demanda de sangre puede aumentar significativamente en los hospitales. Teniendo en cuenta la compatibilidad de la sangre, presentan un modelo multi-objetivo para el manejo de la cadena de suministro de sangre en situaciones adversas, considerando los niveles de inventario, el ruteo y las decisiones relacionadas con la ubicación y asignación. La red consta de donantes, centros de recolección, laboratorios, centros de sangre y hospitales. El modelo matemático tiene como objetivo minimizar el costo total de la cadena de suministro y el tiempo, que maximiza la confiabilidad mínima en las rutas establecidas, al tomar decisiones con respecto a la localización, la asignación, el flujo sanguíneo, los niveles de inventario y los planes de distribución. Para resolver el problema, se utiliza un algoritmo novedoso llamado optimizador de lobo gris multi-objetivo (Multi-Objective Gray Wolf Optimizer, MOGWO) y se compara con dos algoritmos clásicos, optimización por enjambre de partículas multi-objetivo y algoritmo genético de ordenamiento no dominado versión II. El rendimiento de los algoritmos se evalúa con base a varios problemas de prueba, utilizando medidas potentes; además, la aplicación del modelo propuesto se investiga en un caso de estudio para la capital de Irán, Teherán.

1.3. Caracterización de los Estudios LIRP Multi-escalón

Hasta el momento se han expuesto los trabajos más relevantes entorno a los modelos LIRP multi-escalón y sus aplicaciones en diversos contextos del mundo real, entre ellas, la logística humanitaria. Por lo tanto, se presente a continuación la *Tabla 2*, donde se resumen las técnicas de solución más comunes, utilizadas para resolver los problemas de localización, inventario y ruteo de múltiples escalones; paralelamente, se describen algunas características (ver *Tabla 1*) consideradas de gran relevancia en los diferentes estudios encontrados hasta la fecha.

Tabla 1.
Características asociadas al LIRP multi-escalón.

Convención	Interpretación
1	Formulación matemática
2a	Mono-objetivo
2b	Multi-objetivo
3a	Multi-periodo
3b	Multi-producto
4a	Parámetros determinísticos
4b	Parámetros estocásticos
4c	Parámetros difusos
5	Método/Algoritmo de solución
6a	Técnicas de programación en paralelo
6b	Paradigma de cooperación entre metaheurísticas
7	Costos de privación en el modelo

Tabla 2.
Clasificación de estudios relacionados al LIRP multi-escalón.

Autor (año)	1*	2		3		4			5*	6		7
		a	b	a	b	a	b	c		a	b	
(Tavakkoli-Moghaddam et al., 2013)	MINLP	x				x			LINGO			
(Bozorgi-Amiri & Khorsi, 2016)	MILP	x	x	x		x			ϵ -CM			
(Ghorbani & Akbari Jokar, 2016)	MILP	x		x	x	x			HIC-SA			
(R. Tavakkoli-Moghaddam & Raziie, 2016)	MILP		x	x	x			x	GAMS CPLEX			
(Zhalechian et al., 2016)	MINLP	x	x	x		x	x		SGA/VNS			
(Nakhjirkan & Mokhatab Rafiei, 2017)	MINLP	x			x	x			GA			
(Rayat et al., 2017)	MINLP	x	x	x		x			AMOS			

Continuación Tabla 2.

Autor (año)	1*	2		3		4			5*	6		7	
		a	b	a	b	a	b	c		a	b		
(Zhao & Ke, 2017)	MILP	x				x			TOPSIS				
(Guo et al., 2018)	MINLP	x				x			GA/SA				
(Tavana et al., 2018)	MILP	x	x	x	x				ε -CM NSGA-II RPBNSGA-II				
(Vahdani et al., 2018)	MILP	x	x	x	x				NSGA-II MOPSO				
(Yuchi et al., 2018)	MINLP	x				x			TS/ SA				
(Fatemi Ghomi & Asgarian, 2019)	MINLP	x	x			x			PSO BBO HBBO				
(Ghorashi et al., 2019)	CMIP	x	x	x	x				MOGWO MOPSO NSGA-II				
(Nakhjirkan et al., 2019)	MINLP	x				x	x		GA/NDEA				
(Saragih et al., 2019)	MINLP	x				x			SA				
(Biuki et al., 2020)	MILP	x	x	x	x				GA/PSO		x		
<i>Estudio actual</i>	MILP	x				x	x		NSGA-II SPEA-II GA		x	x	x

Nota.*MILP= Mixed Integer Linear Programming; MINLP = Mixed Integer Non-Linear Programming; CMIP=Constrained Mixed Integer Programming; ε -CM= Epsilon Constraint Method ε ; HIC-SA= Hybrid Imperialist Competitive-Simulated Annealing; SGA = Self-adaptive Genetic Algorithm; VNS= Variable Neighborhood Search; GA= Genetic Algorithm; AMOSA= Archived Multi-Objective Simulated Annealing; TOPSIS= Technique for Order of Preference by Similarity to Ideal Solution; SA= Simulated Annealing; NSGA-II= Non-dominated Sorting Genetic Algorithm II; RPBNSGA-II= Reference Point Based Non-dominated Sorting Genetic Algorithm II; MOPSO= Multi-objective Particle Swarm Optimization; TS= Tabu Search; PSO= Particle Swarm Optimization; BBO= Biogeography-Based Optimization; HBBO= Habitat Biogeography-Based Optimization; MOGWO= Multi-Objective Gray Wolf Optimizer; NDEA= Network Data Envelopment Analysis.

1.4. Inclusión de los Costos de Privación en los Modelos Logísticos

La mayoría de los problemas que surgen en una situación de desastre coinciden con el hecho de que las necesidades de la población aumentan; el uso de la moneda es limitado y los suministros y servicios de emergencia se deben proporcionar de forma gratuita a los sobrevivientes. En esta etapa, cuando se brinda asistencia humanitaria, existen varias dificultades, como el poco tiempo con el que se cuenta para ayudar a las personas necesitadas y las distancias de viaje entre los centros de distribución y los puntos de demanda (Cotes & Cantillo, 2019). Además, todo se vuelve más crítico, pues la incertidumbre aumenta, la demanda generada es desconocida (es decir, el número de personas afectadas y sus requerimientos) y la ausencia de mercados funcionales, impiden a las personas comprar, vender o intercambiar bienes o servicios, causando así un gran sufrimiento personal (Holguín-Veras et al., 2013). Por lo tanto, dicha situación, conduce a la generación de los llamados costos de privación (Deprivation Cost, DC), que de acuerdo con Holguín-Veras et al. (2012), se definen como el valor económico del “sufrimiento humano causado por la falta de un bien o servicio”. Más aún, los DC son una externalidad negativa resultante de la pérdida de bienestar que experimentan las personas, debido a la falta de acceso a bienes o servicios esenciales. Desde el punto de vista de la respuesta a desastres y la logística humanitaria, las personas afectadas por un evento adverso experimentan ciclos de privación, debido a la necesidad de suministros críticos que garantizan la supervivencia, como agua, medicamentos y alimentos, los cuales son escasos o difíciles de conseguir (distribuir), conduciendo así a un aumento progresivo del sufrimiento. Generalmente, en entornos posteriores a una catástrofe, los recursos disponibles son insuficientes para satisfacer las necesidades de todos los afectados; luego, las agencias de ayuda deben decidir cuál es la mejor manera de asignarlos y al mismo tiempo, tener en cuenta sus costos logísticos, pues esta compensación entre el impacto a

los beneficiarios y los costos operativos, es según la literatura científica, la mejor manera de brindar asistencia en momentos críticos para salvar vidas a las personas necesitadas (Macea et al., 2018).

En cuanto a la identificación de las funciones objetivo más adecuadas, tenemos que, a diferencia de la logística privada, en la logística humanitaria los investigadores persiguen fines sociales en lugar de financieros. Por lo tanto, estudios recientes en esta área brindan diversos tipos de funciones no relacionadas con los costos, como es el caso de la justicia o equidad en la entrega de productos y además, medidas indirectas que minimizan el sufrimiento humano; ejemplo de esto es el estudio realizado por Yi & Özdamar (2007), quienes construyen un modelo dinámico de coordinación logística para la evacuación y el apoyo en las actividades que brindan respuesta a desastres. El modelo propuesto coordina el transporte de productos básicos, desde los principales centros de suministro a los centros de distribución en las áreas afectadas y el transporte de personas heridas, desde las áreas afectadas a las unidades de emergencia temporales y permanentes. El objetivo es minimizar la demora en la prestación de servicios prioritarios, relacionados con atención médica y productos esenciales. Tanto las personas heridas como los productos básicos se clasifican en una jerarquía de prioridades, donde se utilizan diferentes tipos de vehículos para atender las necesidades de transporte. Asimismo, Mete & Zabinsky (2010) proponen un enfoque de optimización estocástica para el problema de almacenamiento y entrega de suministros médicos pos-desastre, el cual permite hallar ubicaciones estratégicas y el nivel de inventario requerido para cada tipo de suministro. El objetivo del modelo es minimizar la demanda insatisfecha y el tiempo requerido para la entrega de los productos a las zonas que lo requieren. Además, Döyen et al. (2012) formulan un modelo estocástico de dos etapas para un problema en logística humanitaria, donde se toman decisiones pre y pos-desastre en los centros de rescate, específicamente, aquellas

relacionadas con la cantidad de artículos de ayuda que se almacenarán, el flujo en cada escalón y el número aceptable de faltantes. El objetivo es minimizar el costo total de localización para las instalaciones, gestión de inventario, transporte y escasez (demanda insatisfecha) correspondiente a cada punto de demanda. Más aún, Yushimito et al. (2012) diseñan un algoritmo heurístico basado en el diagrama de Voronoi, para localizar centros de distribución en casos de desastre. El método propuesto, maximiza la cobertura de las regiones afectadas, mientras minimiza el sufrimiento humano utilizando una función de costo social, definida como el costo generado por la entrega de urgencia, el cual se basa en la distancia y da como resultado un modelo no lineal-no convexo.

Continuando con la revisión, Khayal et al. (2015) proponen un modelo de flujo en red para la selección dinámica de instalaciones, necesarias durante la distribución y asignación temporal de recursos, que permiten planificar una respuesta oportuna a emergencias. El modelo permite analizar la transferencia de recursos excedentes entre instalaciones temporales que operan en diferentes períodos de tiempo, con el fin de reducir la privación, entendida como el producto entre las unidades demoradas y el costo de penalización por demora unitaria. También, resulta importante presentar la investigación realizada por Rivera-Royero et al. (2016), quienes construyen un modelo dinámico para atender la demanda que se genera luego de un desastre natural, priorizando la respuesta, según el nivel de urgencia, definido con base a las siguientes consideraciones: (i) accesibilidad a los puntos de demanda, (ii) tiempo en que las personas ubicadas en los puntos de demanda, han estado esperando los artículos de socorro, y (iii) la importancia o urgencia del producto humanitario. El sufrimiento humano abordado en el estudio, se define como la proporción de demanda insatisfecha en cada zona afectada, ponderada por una puntuación de prioridad, la cual se relaciona indirectamente con la minimización del tiempo de

respuesta, ya que esta es función del tiempo requerido para que una persona reciba los artículos de socorro.

De acuerdo con lo expuesto hasta el momento, es posible apreciar que el proceso para la obtención de los DC no es una tarea trivial, pues se ha demostrado que dependen no solo del tiempo de privación, sino también de las variables socioeconómicas de los individuos (Macea et al., 2018). Estas funciones se han estimado utilizando el método de valoración contingente (Contingent Valuation, CV) y, más recientemente, modelos de elección discreta, aplicando para ello encuestas de elección declarada. A partir de los modelos de elección discreta, ha sido posible obtener medidas de bienestar, aplicando la tasa de sustitución marginal y el cambio en el excedente del consumidor (Balza-Franco et al., 2017); por lo que el costo de privación se aproxima matemáticamente a una DCF, empleando parámetros que describen el bien o servicio, el tiempo de carencia experimentado y las características individuales. Con el fin de ilustrar tan importante avance, se presenta el trabajo de Holguín-Veras et al. (2016), los cuales realizan una estimación econométrica de las funciones costo de privación para el agua potable, utilizando el método CV; las DCF obtenidas, proporcionan una métrica coherente que podría incorporarse en modelos matemáticos relacionados con el ámbito logístico-humanitario, eliminando así la necesidad de utilizar métricas proxy y proporcionando una mejor manera de evaluar los impactos en las opciones y acciones de entrega. En este mismo año, Pérez-Rodríguez & Holguín-Veras (2016) desarrollan un conjunto de modelos matemáticos para maximizar los beneficios, derivados de la distribución de suministros críticos a las poblaciones necesitadas luego de un desastre. Las formulaciones se basan en la economía del bienestar y el uso de los costos sociales en los que incurren los segmentos de la sociedad involucrados y afectados por la estrategia de distribución. Los costos para el grupo de socorro se evalúan como costos logísticos, mientras que los impactos

para los beneficiarios se miden como los efectos que tiene la distribución de socorro en sus costos de privación, que son el valor económico del sufrimiento humano. Los impactos sobre los beneficiarios tienen en cuenta dos componentes: la reducción de los costos de privación para quienes reciben la ayuda y por otro lado, el aumento progresivo de estos costos, para aquellas personas que no reciben la ayuda en una época de entrega (costo de oportunidad para la estrategia de entrega). El propósito es generar el mejor plan de rutas y gestión de inventario, que permitan la asignación óptima de suministros críticos para minimizar los costos sociales. Por otro lado, Cantillo et al. (2018) utilizan la teoría de elecciones discretas a fin de evaluar los costos de privación que se generan por el tiempo de espera en la entrega de una canasta con insumos básicos, definidos como el cambio en el bienestar de las personas afectadas por un desastre. Para poder estimar la DCF, construyen una encuesta de elección declarada, la cual aplican a personas que viven en áreas afectadas por inundaciones y terremotos en Colombia. Los modelos estimados consideran la influencia de las características socioeconómicas del individuo y efectos aleatorios sobre las funciones de costos de privación. A diferencias de las propuestas mencionadas hasta el momento, Macea et al. (2018) utilizan un enfoque de modelos de elección discreta con variables latentes híbridas (Hybrid Latent Variable – Discrete Choice Models, HLVDChMs) para estudiar la influencia que poseen las actitudes y percepciones personales, en la preparación de un individuo para casos de desastres. El artículo explora la relación entre estos factores psicosociales y las características socioeconómicas de los individuos, por lo que las actitudes y percepciones son incluidas como variables explicativas en la estimación de las DCF. Como resultado, se estimaron dos HLVDChMs con diferentes formas funcionales, utilizando datos de preferencia declarados. Los modelos permiten construir una DCF convexa, no lineal y monótonamente creciente con respecto al tiempo de privación (Deprivation Time, DT), lo cual indica que un período más prolongado de

privación reduce significativamente el bienestar individual, demostrando así que la percepción del riesgo, el concepto de seguridad y la confianza en los sistemas de respuesta a emergencias, juegan un papel importante en la preparación de una persona ante posibles desastres y en la captura de la heterogeneidad que esta posee para la estimación de las DCF. Además, Cantillo et al. (2019) evalúan matemáticamente la vulnerabilidad que poseen las redes de transporte en operaciones de respuesta a emergencias, obteniendo así una herramienta que permite identificar vínculos críticos para el desarrollo de operaciones humanitarias con un alto impacto. El estudio se basa en un análisis económico que considera los costos logísticos de las operaciones de distribución y los efectos externos derivados de los retrasos en la provisión de suministros básicos (costos de privación), por lo que el enfoque abordado, resulta útil a la hora de generar planes de acción frente a desastres resilientes en la etapa de preparación, priorizando así la inversión para la mitigación, adaptación y rehabilitación (restauración) de los enlaces interrumpidos en las etapas de respuesta y recuperación.

La investigación en gestión de operaciones ha creado modelos logísticos humanitarios para decidir cómo asignar mejor los escasos recursos. Sin embargo, las metodologías actuales suelen utilizar enfoques basados en la logística comercial, que son inapropiados para fines de logística humanitaria (Cantillo et al., 2018); la cual tiene como objetivo principal asistir oportunamente las personas afectadas en una situación de desastre, más allá de los costos privados que esto pueden representar (Holguín-Veras et al., 2012). En consecuencia, los modelos adecuados deben basarse en la minimización de los costos sociales, permitiendo así un nivel “socialmente” óptimo para la distribución de los recursos disponibles.

Basado en lo expuesto anteriormente, el bienestar económico incluye dos componentes principales, a saber, los costos privados y externos, que en conjunto constituyen la suma de los

costos sociales. En un entorno de mercado normal, el costo de la internalización por parte de compradores y vendedores se denomina costo privado, en la cadena de suministro humanitaria este “costo privado” se refiere a los costos logísticos (Holguín-Veras et al., 2013). Factores externos, como por ejemplo, un terremoto, inundación o huracán, ponen en peligro o destruyen las actividades normales de los mercados, lo que resulta en costos externos (Macea et al., 2018). Los costos de privación, que presentan tales externalidades, tienen una gran relevancia para la logística humanitaria y los esfuerzos de socorro ante desastres (Holguín-Veras et al., 2012; Holguín-Veras et al., 2013).

En respuesta a esta necesidad, nuevos enfoques han propuesto modelos logísticos humanitarios basados en los costos sociales. Tal es el caso de Gutjahr & Nolz (2016) quienes presentan el término “angustia” como “costos psicológicos o sociales”. Por otro lado, Hu & Sheu (2013) y Sheu (2007), incluyen sentimientos como el estrés, la ansiedad, el dolor y la depresión como costos sociales. Mientras tanto, Balza-Franco et al. (2017), Cotes & Cantillo (2019) y Rivera-Royero et al., (2016) mencionan que los modelos de logística humanitaria, deben basarse en enfoques que incorporen el costo asociado con el sufrimiento humano en el proceso de entrega de ayuda humanitaria. Sin embargo, incluirlos en los modelos requiere estimar adecuadamente la función de costo de privación (Deprivation Cost Function, DCF) para los suministros y servicios críticos, como es el caso del agua, los alimentos, medicamentos, entre otros. Por otro lado, Loree & Aros-Vera (2018) minimizan los costos sociales (privación, logísticos y otros) para abordar los problemas de ubicación de las instalaciones en los puntos de distribución y la asignación de inventario. Asimismo, Paul & Zhang (2019), Kelle et al. (2014) y Khayal et al. (2015) tienen en cuenta los costos sociales como única función objetivo, en problemas relacionados con gestión y distribución de productos críticos; sin embargo, existen estudios donde se plantean múltiples

objetivos, teniendo en cuenta los costos de privación como uno de ellos, es el caso de Huang et al. (2015), Moreno et al. (2018), Serrato-Garcia et al. (2016), Yu et al. (2018), Yu et al. (2019) y Zhu et al. (2019).

Es importante mencionar que Holguín-Veras et al. (2016), revisaron varias técnicas de evaluación económica, concluyendo que la valoración contingente (Contingent Valuation, CV) y la elección declarada (Stated Choice, SC) se consideran dos opciones correctas en la estimación de la DFC; además, este autor es pionero en la estimación de una función para el suministro de agua mediante el método CV. Luego, Cantillo et al. (2018), Delgado-Lindeman et al. (2019) y Macea et al. (2018) emplean el método SC con modelos de elección discreta (Discrete Choice Model, DCM) para estimar la DCF. Sin embargo, las estimaciones son diferentes en cuanto a los modelos, algoritmos, variables y bienes o servicios propuestos. Más aún, el primer estudio utilizó un modelo logit mixto (Mixed Logit, ML) como un tipo de DCM; el segundo estudio desarrolló un enfoque de modelado logit multinomial (Multi-Nomial Logit, MNL) y ML; mientras que el tercer estudio empleó un modelo MNL, que hace parte de los modelos DCM.

En resumen, la revisión de la literatura muestra un cambio sustancial en la tendencia sobre el enfoque de modelado utilizado en logística humanitaria. Los investigadores reconocen la necesidad de considerar los costos sociales, que implican los costos de privación y costos logísticos. Sin embargo, esto genera varios desafíos, el primero, está asociado con la estimación adecuada de las funciones de costo de privación; el segundo gran reto, es desarrollar modelos apropiados, incorporando los costos de privación en todos los niveles (estratégico, táctico y operativo) y el tercer desafío no menor, es proponer métodos de solución eficientes, considerando la naturaleza no lineal del problema.

1.5. Caracterización de los DC en Logística Humanitaria

Con el propósito de sintetizar la revisión bibliográfica asociada al nuevo enfoque de modelado matemático en operaciones humanitarias, se presenta a continuación, un cuadro comparativo (*ver Tabla 4*), que permite evidenciar las principales estrategias y técnicas utilizadas a la hora de estimar la función de costo de privación (DCF), en los problemas que involucran un despliegue oportuno de recursos; además, se describen ciertas características distintivas (*ver Tabla 3*) para cada uno de los estudios seleccionados, permitiendo así una mayor comprensión del contexto, aplicación y enfoque abordado.

Tabla 3.
Características de los estudios en logística humanitaria.

Convención	Interpretación
1	Tipo de desastre
2a	Objetivo Humanitario: Maximizar
2b	Objetivo Humanitario: Minimizar
3	Problema abordado
4a	Estimación proxy de la DCF : Demora/tiempo en la entrega
4b	Estimación proxy de la DCF : Demanda insatisfecha/Escasez
4c	Estimación proxy de la DCF : Cobertura de la región afectada
4d	Estimación proxy de la DCF : Priorización de las áreas afectadas/Equidad
4e	Estimación media de la DCF: Función de sufrimiento / impacto en la región afectada
5	Estimación econométrica de la DCF: Economía del bienestar/Disposición a pagar (DAP)

Tabla 4.*Técnicas y enfoques para la estimación de la DCF.*

Autor (Año)	1	2		3	4					5
		a	b		a	b	c	d	e	
(Yi & Özdamar, 2007)	General	x	x	Distribución Asignación	x				x	
(Mete & Zabinsky, 2010)	General/ Terremoto		x	Almacenamiento Distribución	x	x				
(Döyen et al., 2012)	General		x	Localización Inventario Transporte		x				
(Yushimito et al., 2012)	General/ Huracanes	x		Localización				x		
(Kelle et al., 2014)	Huracanes	x	x	Pre-posicionamiento de recursos		x				
(Huang et al., 2015)	Terremoto	x	x	Asignación Distribución	x				x	
(Khayal et al., 2015)	General		x	Ubicación Asignación	x					
(Holguín-Veras et al., 2016)	General		x	Distribución						x
(Pérez-Rodríguez & Holguín-Veras, 2016)	General		x	Distribución Inventario						x
(Rivera-Royero et al., 2016)	Inundaciones		x	Distribución	x	x				
(Serrato-García et al., 2016)	Inundaciones		x	Recolección Inventarios Distribución	x	x				
(Cantillo et al., 2018)	General		x	Distribución						x
(Macea et al., 2018)	General		x	Distribución						x

Continuación Tabla 4.

Autor (Año)	1	2		3	4					5
		a	b		a	b	c	d	e	
(Macea et al., 2018)	General/ Terremotos		x	Impacto de las actitudes y percepciones						x
(Moreno et al., 2018)	Inundaciones Deslizamientos		x	Localización Transporte Tamaño de flota						x
(Yu et al., 2018)	General		x	Asignación de suministros críticos						x
(Cantillo et al., 2019)	General		x	Vulnerabilidad en las redes de transporte						x
(Cotes & Cantillo, 2019)	Inundaciones		x	Localización Pre-posicionamiento						x
(Paul & Zhang, 2019)	Huracanes		x	Transporte Localización						x
(Yu et al., 2019)	General		x	Asignación de recursos humanitarios						x
(Zhu et al., 2019)	Inundaciones Huracanes	x	x	Ruteo de emergencia	x			x		
<i>Estudio Actual</i>	General		x	Localización Inventario Ruteo						x

1.6. Computación Paralela y Metaheurísticas Cooperativas

En los últimos años, las metaheurísticas cooperativas paralelas se han utilizado cada vez más para resolver una gran variedad de problemas combinatorios difíciles (Bouthillier & Crainic, 2005). Dichas metaheurísticas, utilizan con frecuencia múltiples procesos (hilos) que trabajan simultáneamente en los procesadores disponibles, con diversos grados de cooperación, para resolver una instancia de problema dada. La justificación detrás de esta idea es doble; primero, se

ha demostrado que los algoritmos paralelos son capaces de acelerar la búsqueda, mejorar la robustez (capacidad de proporcionar soluciones igualmente buenas, para un conjunto amplio y variado de instancias en un problema) y la calidad de las soluciones obtenidas (Crainic, 2008). En segundo lugar, los recursos de computación paralela están cada vez más disponibles, con la llegada de los clústeres de computadoras y los procesadores de múltiples núcleos.

Crainic & Toulouse (2010), definen la computación paralela como “varios procesos trabajando simultáneamente, en diferentes procesadores que resuelven una instancia del problema dado”. Según los autores, “el paralelismo se deriva de una descomposición de la carga computacional total y la distribución de las tareas resultantes a los procesadores disponibles. La descomposición puede referirse al algoritmo, los datos de la instancia del problema o su estructura”. Por otro lado, la cooperación entre metaheurísticas se utiliza como estrategia para el intercambio de información entre los algoritmos involucrados en la búsqueda de la solución al problema. Este intercambio de información tiene como objetivo principal guiar la búsqueda de las regiones más prometedoras del espacio de solución. A su vez, el paralelismo permite la ejecución simultánea de métodos y la reducción del tiempo de búsqueda, por lo que la combinación entre cooperación y paralelismo se está desarrollando intensamente y cada día es más importante en el contexto de Optimización (Lopes Silva et al., 2018). Más aún, Blum & Roli (2003) definen formalmente la búsqueda cooperativa, como un proceso de optimización para la resolución de problemas, realizado por diversos algoritmos (o instancias del mismo algoritmo), que comparten información, por ejemplo, etapas de procesamiento, soluciones y subproblemas, en el espacio de búsqueda. Otra definición muy utilizada, hace referencia a una categoría de algoritmos paralelos, en la que diferentes algoritmos o ramificaciones de sí mismo, se ejecutan simultáneamente para resolver el problema de optimización en cuestión (El-Abd & Kamel, 2005).

De acuerdo con la taxonomía introducida por Talbi (2002), la búsqueda cooperativa puede realizarse de manera secuencial (retransmisión) o de forma paralela (trabajo en equipo). Algunos ejemplos de trabajos que muestran cómo lograr la búsqueda cooperativa son Alba et al. (2006), Amaya et al. (2010), Jin et al. (2014) y Villaverde et al. (2012). Además, Crainic & Toulouse (2006) presentan una taxonomía de metaheurísticas paralelas, con relación a la fuente de paralelismo utilizada, es decir, paralelismo tipo 1 o paralelismo de bajo nivel dentro de una iteración del método heurístico; paralelismo tipo 2 o paralelismo de descomposición de dominio, el cual surge al dividir el conjunto de variables de decisión y finalmente, paralelismo de tipo 3 o paralelismo de búsqueda múltiple, obtenido de múltiples exploraciones concurrentes en el espacio de solución.

La estrategia propuesta en este documento se encuentra asociada con el paralelismo tipo 3, específicamente a las estrategias cooperativas, utilizadas con frecuencia para mejorar la exploración de un espacio de búsqueda. Varios estudios (Barbucha, 2014; Bouthillier & Crainic, 2005; Crainic et al., 2004; Du & Li, 2008; Jin et al., 2012; Polat, 2017; Seow & Sim, 2008; Tsai et al., 2004), han demostrado que las técnicas de subprocesos múltiples proporcionan mejores soluciones, tomando como referencia sus componentes secuenciales, incluso cuando el tiempo de ejecución disponible para cada subproceso es menor que el asignado a las estrategias secuenciales. Por otro lado, estas investigaciones también han comprobado que la unión de múltiples hilos, cada uno de ellos con una estrategia diferente, aumenta la robustez de la búsqueda global con respecto a los cambios en las instancias del problema, indicando así que, si bien las estrategias de búsqueda independientes son fáciles de implementar y obtienen buenos resultados, pueden mejorarse mediante el uso de una técnica conjunta.

2. Justificación y Planteamiento del Problema

La frecuencia de los desastres naturales, como huracanes, tormentas, sequías, inundaciones, movimientos telúricos, entre otros, están aumentando sin lugar a duda. Por ejemplo, los terremotos fatales en Turquía (Izmit, 1999), Taiwán (Chichi, 1999), India (Gujurat, 2001), Irán (Bam, 2003), Pakistán (Cachemira, 2004), China (Sichuan, 2008) y Haití (2010), ocasionaron que aproximadamente 450.000 personas perdieran la vida. Además, el tsunami en Indonesia (2004), el huracán Katrina en los EE.UU. (2005) y las inundaciones en Pakistán (2010), han causado la muerte a más de 300.000 personas, la pérdida de miles de millones de dólares en activos y han dejado un saldo estimado de 20 millones de personas sin hogar (Tavana et al., 2018). Según la información suministrada por el Centro para la Investigación sobre la Epidemiología de los Desastres (Centre for Research on the Epidemiology of Disasters, CRED) y la base de datos internacional de desastres (The International Disaster Database, EMDAT), el número de desastres naturales a nivel mundial entre 1980 y 2017 fue de 11.495, lo que resultó en más de 2.5 millones de muertes, 4.400 millones de personas resultaron heridas o quedaron sin hogar y condujo a una pérdida económica global de 2.71 billones de dólares (CRED, 2018; EM-DAT, 2017). Es por esto que, el impacto económico de un evento catastrófico puede llegar a ser devastador para cualquier nación, especialmente para aquellas en vía de desarrollo, como se evidencia en el informe *Natural Hazards - UnNatural Disasters*, el cual señala que la repercusión de las catástrofes naturales en el producto interno bruto (PIB) es 20 veces mayor en los países en desarrollo que en las naciones industrializadas (World Bank, United Nations, 2010). Por ejemplo, el valor total de los daños y las pérdidas provocadas por los terremotos en Nepal durante abril y mayo de 2015, representaron alrededor de una tercera parte del PIB del país, según una evaluación de necesidades posteriores a los sucesos ocurridos (Banco Mundial, 2016).

En la actualidad, los desastres, independientemente de su origen (sea natural o humano), son considerados fenómenos sociales cuyos daños sería posible prevenir y mitigar para disminuir o al menos controlar sus efectos (Cecchini et al., 2017). La dificultad para predecir el lugar donde ocurrirá, el momento y magnitud con la cual se presentará, además de la incertidumbre asociada a las características propias de la población, las condiciones de infraestructura existentes y la demanda requerida para atender la situación de emergencia, dan lugar a uno de los mayores desafíos en la logística humanitaria, como lo es, la imprevisibilidad, definida como la ocurrencia de sucesos inesperados (Balcik et al., 2010). L'Hermitte et al. (2016) afirman que la imprevisibilidad, crea barreras y afecta la eficiencia en la cadena de suministro. Así, el adecuado manejo de la cadena de abastecimiento logístico para la atención de desastres y apoyo humanitario, se convierte en un reto muy importante a nivel mundial, pues esta se encarga de estimar, proveer, almacenar, transportar y distribuir el personal, los recursos y servicios requeridos a las zonas afectadas (Talebian Sharif & Salari, 2015), a través de un conjunto de actividades realizadas en diferentes instancias del tiempo, las cuales tienen como finalidad asistir a las personas sobrevivientes luego de un desastre, reducir su impacto y mantener la estabilidad social (Aghajani et al., 2020; Vahdani et al., 2018).

La variedad de las operaciones logísticas en el alivio de desastres es tan extensa, que hacer logística humanitaria se convierte en la parte más costosa y crítica en casos de desastre; como lo afirman Wang et al. (2014), la logística representa el 80% de las actividades en HSCM y enfatiza que la coordinación es clave para mejorar el desempeño de la cadena de ayuda. Es por esto que, los estudios y constantes esfuerzos llevados a cabo en esta área, se concentran principalmente en el desarrollo de herramientas eficientes, que permitan aprovechar de la mejor forma los recursos disponibles para afrontar amenazas futuras (Díaz et al., 2019).

Por esta razón, surge la necesidad de desarrollar un modelo capaz de proporcionar la información suficiente al responsable de la red logística, para que éste tome las mejores decisiones relacionadas con la ubicación, distribución y gestión de inventario, que garantizan finalmente una entrega oportuna de los bienes (productos o servicios) a los grupos de interés (áreas afectadas), minimizando así los impactos negativos de tipo económico y social, ocasionados por la ocurrencia de eventos adversos. Dicho modelo se encuentra asociado al 2E-LIRP, el cual integra tres tipos de decisiones muy importantes dentro de la planeación integral de la logística humanitaria, como lo exponen Rafie-Majd et al. (2018), es decir, decisiones de tipo estratégico: con efectos a largo plazo (ubicación y asignación de instalaciones); decisiones tácticas: a mediano plazo (control de inventario y transporte) y decisiones operativas: diarias o semanales (programación y ruteo), las cuales determinan finalmente la capacidad de respuesta, flexibilidad, eficiencia y eficacia que posee la cadena de suministro. Como el 2E-LIRP está clasificado dentro de la complejidad computacional, como un problema tipo NP-Hard (Dai et al., 2019), se hace necesario el uso de métodos alternativos que permitan obtener buenas soluciones en tiempos de cómputo razonable; por lo tanto, se desarrollan tres algoritmos metaheurísticos, el primero, conocido como algoritmo genético de ordenamiento no dominado versión II (NSGA-II), el segundo, algoritmo evolutivo de fuerza de Pareto versión II (SPEA-II) y el tercero, llamado algoritmo genético (GA), los cuales hacen uso de la programación en paralelo y se apoyan en el paradigma de cooperación; esto con la finalidad de obtener métodos de solución más eficientes y robustos, que reduzcan el tiempo de procesamiento y en algunos casos, mejoren la calidad de la solución, al distribuir la información de búsqueda en diferentes unidades informáticas (Toutouh & Alba, 2012). Asimismo, el modelo propuesto es formulado como un problema de programación lineal entera mixta multi-objetivo, el cual de acuerdo con la revisión y a lo expuesto por Gutjahr & Fischer (2018), Holguín-Veras et al.

(2013), Loree & Aros-Vera (2018) y Pérez & Holguín-Veras (2016), es necesario incorporarle los costos sociales, es decir, costos logísticos y de privación en su función objetivo, pues a través de este nuevo enfoque, se ha logrado unificar los modelos de optimización para aplicaciones en logística humanitaria, dado que estos eran simplemente extensiones de modelos logísticos comerciales, los cuales por lo general no tienen en cuenta las externalidades, entendidas como aquellos efectos negativos ocasionados por la falta de acceso a bienes o servicios vitales, generando así altos costos sociales y con frecuencia, soluciones inviables o sub-óptimas en la entrega de suministros críticos a las áreas afectadas.

Finalmente, este tipo de modelo resulta relevante para Colombia, pues se encuentra localizada en una de las zonas sísmicas más activas de la tierra, conocida como el Anillo Circumpacífico, el cual corresponde al borde del océano Pacífico, que es precisamente donde han ocurrido los últimos grandes sismos en países como Chile, Japón y Ecuador (Correal, 2016). Según estudios de amenaza sísmica realizados a nivel nacional por la Asociación Colombiana de Ingeniería Sísmica (AIS), cerca del 40% de los colombianos se encuentran expuestos a una amenaza sísmica alta, y el 47% está ubicado en zonas de amenaza sísmica intermedia, es decir, el 87% del territorio nacional pertenece a un nivel de riesgo sísmico considerable. Además, el problema se presenta no solo por el nivel de amenaza sísmica, sino también por el grado de vulnerabilidad en las edificaciones, puentes, carreteras, presas, redes eléctricas y de gas, entre otras (AIS, 2020; Cotes & Cantillo, 2019).

3. Objetivos

3.1. Objetivo General

Desarrollar un modelo de optimización multi-objetivo para el problema de localización, ruteo e inventario de dos escalones (2E-LIRP), considerando múltiples productos en la gestión de la cadena de suministro humanitaria.

3.2. Objetivos Específicos

- Identificar en la literatura formulaciones matemáticas asociadas al problema de localización, ruteo e inventario multi-escalón, junto a las metodologías propuestas para la inclusión de los costos sociales en operaciones humanitarias, con el fin de establecer una estrategia de modelado.
- Construir un modelo de optimización multi-objetivo (2E-LIRP), que apoye la toma de decisiones integrales y tenga en cuenta los costos sociales, requeridos para una adecuada gestión de la cadena de suministro humanitaria.
- Diseñar algoritmos de solución para el modelo de optimización, haciendo uso de las metaheurísticas NSGA-II, SPEA-II y GA programadas en paralelo, utilizando el paradigma de cooperación.
- Validar los algoritmos de solución a través de un testbed, en el que se simulan algunas instancias pre y pos-desastre.

4. Hipótesis

4.1.Hipótesis 1

El problema de localización, ruteo e inventario de dos escalones (2E-LIRP) para la gestión de la cadena de suministro humanitaria, resuelto a través de la metaheurística NSGA-II programada en paralelo y bajo un entorno de cooperación, genera un rendimiento mayor o igual, en términos de tiempo computacional, que el algoritmo SPEA-II ejecutado bajo las mismas condiciones.

4.2.Hipótesis 2

Utilizar la programación en paralelo junto al paradigma de cooperación, en el diseño de un algoritmo genético (GA), para la solución del 2E-LIRP aplicado a la gestión de la cadena de suministro humanitaria, permite lograr mejores resultados, en función del tiempo computacional o la calidad de la solución, que los obtenidos al implementar un algoritmo genético (GA) secuencial.

5. Marco Teórico

5.1. Algoritmos Evolutivos

Los Algoritmos Evolutivos (Evolutionary Algorithm, EA) son procedimientos de búsqueda y optimización, que tienen sus orígenes e inspiración en el mundo biológico. Se caracterizan por imitar procesos adaptativos de los sistemas naturales y se basan en la supervivencia del mejor individuo, siendo este una solución potencial del problema, que se implementa como una estructura de datos y trabajando sobre poblaciones de soluciones que evolucionan de generación en generación, mediante operadores genéticos adaptados al problema (Câmara, 2015). Una virtud de este tipo de algoritmos, es que requieren poca información del problema y permiten generalmente la obtención de buenas soluciones aproximadas en tiempos razonables.

5.1.1. Algoritmo genético

Dentro de los EA se encuentran los Algoritmos Genéticos (Genetic Algorithm, GA), que son métodos adaptativos, generalmente usados en problemas de búsqueda y optimización de parámetros, basados en la reproducción sexual y en el principio de supervivencia del más apto (Fogel, 2000). Con mayor formalidad y siguiendo la definición dada por Goldberg, “Los GA, son técnicas de búsqueda basadas en la mecánica de selección y de la genética natural. Combinan la supervivencia del más apto entre cadenas de secuencias, con un intercambio de información estructurado, aunque aleatorizado, para constituir así un algoritmo de búsqueda que tenga algo de las genialidades humanas” (Goldberg, 1989). Para alcanzar la solución a un problema se parte de un conjunto inicial de individuos, llamado población, generado de manera aleatoria, donde cada uno de estos individuos representan una posible solución. Estos individuos evolucionarán tomando

como base los esquemas propuestos por Darwin sobre la selección natural, y se adaptarán en mayor medida tras el paso de cada generación a la solución requerida.

El desarrollo de los GA se debe en gran medida a John Holland, investigador de la Universidad de Michigan, quien a finales de la década de los 60 desarrolló una técnica que imitaba en su funcionamiento a la selección natural. Aunque originalmente esta técnica recibió el nombre de “planes reproductivos”, a raíz de la publicación en 1975 de su libro “Adaptation in Natural and Artificial Systems” (Holland, 1975) se conoce principalmente con el nombre de Algoritmos Genéticos. A grandes rasgos, un Algoritmo Genético consiste en una población de soluciones codificadas de forma similar a cromosomas. Cada uno de estos cromosomas tendrá asociado un ajuste, valor de bondad o fitness, que cuantifica su validez como solución al problema. En función de este valor, se le darán más o menos oportunidades de reproducción, añadiendo cierta probabilidad de mutación (Goldberg, 2002). El funcionamiento general de un Algoritmo Genético puede apreciarse en el pseudocódigo, presentado en la *Figura 1*.

```

INICIALIZAR población actual aleatoriamente
MIENTRAS no se cumpla el criterio de terminación
    Crear población temporal vacía
    SI elitismo: copiar en población temporal mejores individuos
    MIENTRAS población temporal no llena
        Seleccionar padres
        Cruzar padres con probabilidad  $P_c$ 
        SI se ha producido el cruce
            Mutar uno de los descendientes (prob.  $P_m$ )
            Evaluar descendientes
            Añadir descendientes a la población temporal
        SINO
            Añadir padres a la población temporal
    FIN SI
FIN MIENTRAS
Aumentar contador generaciones
Establecer como nueva población actual la población temporal
FIN MIENTRAS

```

Figura 1. Pseudocódigo del GA. Adaptado de Gestal et al. (2010).

5.1.2. Algoritmos evolutivos multi-objetivo

En la mayoría de los problemas de optimización multi-objetivo, el conocimiento del Frente Pareto óptimo ayuda al tomador de decisiones a seleccionar aquella solución que representa el mejor compromiso. Generar dicho frente puede ser computacionalmente costoso o incluso imposible, en especial, para problemas reales de ingeniería. Por consiguiente, lo único que se puede pretender es una buena aproximación al Frente Pareto óptimo verdadero. Los algoritmos evolutivos multi-objetivo (Multi-objective Evolutionary Algorithms, MOEA) son una alternativa práctica en la búsqueda de estas soluciones eficientes, donde los métodos exactos son inaplicables o poco útiles. Más aún, su popularidad se debe principalmente a que resultan promisorios en la integración de los aspectos de búsqueda y toma de decisiones que plantean los MOP; pueden realizar múltiples exploraciones aún en espacios ilimitados y altamente complejos; tienen la habilidad de mantener toda una población de soluciones y además, son una alternativa válida para el adecuado tratamiento de los MOP, pues conducen la búsqueda hacia el frente de Pareto, manteniendo la diversidad de la población en dicha frontera (Zitzler et al., 2000). Los MOEA se pueden dividir en dos categorías, los algoritmos de primera generación, que a pesar de su rotundo éxito, una vez encuentran soluciones no dominadas durante una iteración específica, estas pueden perderse cuando se aplican los operadores genéticos en iteraciones sucesivas. Para evitar la pérdida de buenas soluciones, se optó por aplicar el concepto de *elitismo*, surgiendo así la segunda generación, que posee mecanismos explícitos de esta característica tan importante, en la búsqueda de soluciones (Veldhuizen et al., 2003). La presente investigación, utiliza dos algoritmos evolutivos de segunda generación, los cuales son descritos a continuación.

5.1.3. Algoritmo genético de ordenamiento no-dominado versión II

El NSGA-II fue propuesto por Deb et al. (2002), como solución a las continuas críticas (complejidad computacional, enfoque no elitista y la necesidad de especificar un parámetro para poder compartir) que presentaban los MOEA basados en la clasificación y el intercambio no dominado. Son varias las características que lo hacen diferente del NSGA original; para empezar, incorpora un mecanismo de preservación de elites, que asegura el mantenimiento de las buenas soluciones encontradas con anterioridad, además, utiliza un procedimiento rápido de clasificación por no-dominancia, el cual incorpora una metodología especial de almacenamiento, a fin de reducir la complejidad computacional del algoritmo y por último, a diferencia de su antecesor, abandona la utilización de distancia *Sharing*, para emplear un operador de selección por torneo de *Crowding*, como método de preservación de la diversidad (Hui Li & Qingfu Zhang, 2009).

En este nuevo algoritmo, la población descendiente Q_t (tamaño N) es creada en primera instancia, usando la población de padres P_t (tamaño N). Después de esto, las dos poblaciones son combinadas para formar R_t (tamaño $2N$). Luego de realizar lo anterior, mediante un ordenamiento no dominado se clasifica la población R_t en diferentes frentes de Pareto. Aunque esto requiere un mayor esfuerzo, se justifica por el hecho de permitir una verificación global de dominancia entre la población de padres y descendientes. Una vez el proceso de ordenamiento no dominado ha finalizado, la nueva población es generada a partir de las configuraciones de los frentes no dominados, la cual empieza a ser construida con el mejor frente no dominado (F_1), continúa con las soluciones del segundo frente (F_2), tercero (F_3) y así sucesivamente hasta completarla. Como la población R_t es de tamaño $2N$ y solamente existen N configuraciones que conforman la población descendiente, no todas las soluciones de los frentes pertenecientes a la población R_t ,

podrán ser acomodados en la nueva población (Veldhuizen & Lamont, 2000). El procedimiento general efectuado por este tipo de algoritmos, puede ser apreciado en la *Figura 2*.

```

INICIALIZAR  $P_t$ 
 $t = 0$ 
  Evaluar  $P_t$ 
  MIENTRAS (No Criterio de Parada) HACER
     $R_t = P_t \cup Q_t$ 
    Frentes = Sorting No Dominado ( $R_t$ )
 $P_{t+1} = \emptyset$ 
 $i = 1$ 
  MIENTRAS  $|P_{t+1}| + |Frente(i)| \leq size(P_{t+1})$ 
    Calcular Distancia de CROWDING ( $Frente(i)$ )
     $P_{t+1} = P_{t+1} \cup Frente(i)$ 
 $i++$ 
  FIN MIENTRAS
  Sorting por Distancia ( $Frente(i)$ )
   $P_{t+1} = P_{t+1} \cup Frente(i)[1: (size(P_{t+1}) - |P_{t+1}|)]$ 
  Hijos = Selección y Reproducción ( $P_{t+1}$ )
 $generación++$ 
 $P(generacion) = P_{t+1}$ 
  FIN MIENTRAS
RETORNAR Mejor Solución Hallada

```

Figura 2. Pseudocódigo del NSGA-II. Adaptado de Deb et al. (2002).

5.1.4. Algoritmo evolutivo de fuerza de Pareto versión II

La versión revisada del SPEA (llamada SPEA-II) fue propuesta por Zitzler et al. (2001) y tiene tres diferencias principales con respecto a su antecesor el SPEA: (1) incorpora una estrategia de grano fino para asignar la aptitud, la cual tiene en cuenta para cada individuo el número de individuos que lo dominan y el número de individuos a los que domina; (2) utiliza una técnica de estimación de densidad de vecinos más cercanos que guía la búsqueda de manera más eficiente, y (3) tiene un método mejorado de truncamiento de archivo que garantiza la preservación de soluciones de frontera. Por otro lado, este algoritmo utiliza un archivo externo (el llamado conjunto no dominado externo), el cual contiene soluciones no dominadas encontradas previamente, permitiendo que en cada generación, los mejores individuos se copian a este conjunto. El punto

clave para entender la optimización multi-objetivo que realiza, reside en el diseño de la función de “fitness”, que se construye de la siguiente manera. Sean A_t y P_t los subconjuntos de una partición de una población de soluciones potenciales en la iteración t –ésima, donde A_t contiene las soluciones no dominadas, es decir, A_t es una aproximación a la frontera de Pareto en la iteración t y P_t contiene las soluciones restantes. De esta forma, la partición constituye un recurso elitista para evitar perder buenas soluciones durante el proceso de búsqueda (Zitzler et al., 2001). Posteriormente, a cada solución i de la población $A_t \cup P_t$, se le asigna un valor de “fuerza” S , que es el número de individuos de este conjunto dominados por i y luego se calcula para cada i la sumatoria de las “fuerzas” de todos los individuos que dominan a i , valor al que se llamara fitness base $R(i)$. Con el fin de evitar soluciones repetidas en la frontera de Pareto (muy similares) utiliza la función estimador de densidad poblacional, $D(i)$, que calcula para cada individuo i su densidad poblacional, con base al método del k –ésimo vecino más próximo (Zitzler et al., 2003). En resúmen, se presenta la *Figura 3*, con el propósito de ilustrar el funcionamiento general que presenta el SPEA-II.

INICIALIZAR

M (Tamaño de la población)

N (Tamaño del archivo)

T (Número de generaciones)

SALIDA: A^* (*Conjunto No Dominado*)

Generar P_0 y crear un archivo vacío o conjunto externo $A_0 = \emptyset$. Fijar $t = 0$

Fadapabilidad (P_t y A_t)

SELECCIÓN AMBIENTAL. Copiar todos los individuos no dominados de P_t y A_t a A_{t+1} .

Si $|A_{t+1}| > N$ reducir A_{t+1} por una función de truncamiento $T(A_{t+1})$. En caso contrario, completar A_{t+1} con individuos dominados de P_t y A_t .

TERMINACIÓN. Si $t = T$ o se cumple algún otro criterio de parada, entonces A^* equivale al conjunto de vectores de decisión, representados por los individuos no dominados en A_{t+1} . *PARAR*.

SELECCIÓN DE PADRES. Llevar a cabo un torneo binario con reemplazo en A_{t+1}

VARIACIÓN. Aplicar operadores de cruzamiento y al conjunto a fin de obtener el conjunto P_{t+1} .

INCREMENTAR $t = t + 1$ e ir nuevamente a la línea 7 (*Fadapabilidad*)

Figura 3. Pseudocódigo del SPEA-II. Adaptado de King et al. (2010).

5.2.Optimización Multi-objetivo

Los problemas de decisión en la vida real involucran, la mayoría de las veces, múltiples criterios de evaluación, generalmente bajo conflicto. Por ejemplo, con el presupuesto limitado que posee un supermercado, se intenta comprar los productos necesarios de mayor calidad al menor precio posible. Otro caso ilustrativo sucede cuando se decide el lugar para ir de vacaciones; seguramente se consideran cuestiones como distancia, costo de las diferentes alternativas, las opciones de entretenimiento, extensión del período de vacaciones, etc. Estos dos ejemplos, permiten entender la naturaleza básica de la optimización multi-objetivo, la cual trata de la búsqueda de opciones, considerando la optimización de varios objetivos normalmente contrapuestos (Lücken et al., 2004).

Un problema multi-objetivo difiere de un problema mono-objetivo, dado que los primeros requieren la optimización simultánea de más de una función objetivo en paralelo y la noción de óptimo tiene que ser redefinida en este contexto, ya que, en lugar de buscar la mejor solución, se intenta producir un conjunto de buenas soluciones de compromiso. Por lo tanto, el desafío principal de los algoritmos de optimización multi-objetivo, consiste en encontrar este conjunto de soluciones o su mejor aproximación, con el fin de ofrecer al tomador de decisiones (Decision Maker, DM) las mejores alternativas entre las disponibles, para que este último seleccione una de ellas (López, 2013).

Formalmente, el problema de optimización multi-objetivo (Multi-Objective Problem, MOP), puede ser representado matemáticamente como lo expresa Audet et al. (2020), quienes destacan los siguientes aspectos,

Optimizar (Maximizar ó Minimizar):

$$\mathbf{y} = \mathbf{F}(\mathbf{x}); \mathbf{y} \in Y \subseteq \mathbb{R}^m \wedge \mathbf{x} \in X \subseteq \mathbb{R}^n, \text{ es decir,}$$

$$\mathbf{Max} \text{ ó } \mathbf{Min} \{f_1(x), f_2(x), \dots, f_m(x)\} \text{ con } x = [x_1, x_2, \dots, x_n]$$

Sujeto a:

$$g_i(x) \leq 0 \quad \forall i \in \{1, 2, \dots, h\}$$

$$h_j(x) = 0 \quad \forall j \in \{1, 2, \dots, p\}$$

Donde, x representa un vector de decisión n -dimensional, X relaciona el espacio de decisión, y denota el vector objetivo m -dimensional, mientras que Y se encuentra asociada al espacio objetivo.

5.2.1. Dominancia de Pareto

Sean los vectores objetivo $y = [y_1, y_2, \dots, y_n]$ y $y^* = [y_1^*, y_2^*, \dots, y_n^*]$; se dice que y domina a y^* (para un problema de minimización), representado por $y > y^*$, si y solo si, $\forall i \in \{1, 2, \dots, n\}: y_i \leq y_i^* \wedge \exists i \in \{1, 2, \dots, n\}: y_i < y_i^*$. Expresado en otros términos, y domina a y^* , si y es mejor o igual a y^* en todos los objetivos y estrictamente mejor en al menos un objetivo. Si ninguno de los vectores domina al otro, se dice que son indiferentes (no existe punto de comparación) entre sí, ya que ninguno puede ser considerado mejor, teniendo en cuenta los objetivos establecidos.

5.2.2. Pareto óptimo

Se dice que una solución $x \in X$, es un Pareto óptimo respecto a un conjunto $\Omega \subseteq X$, si y solo si, $\nexists x^* \in \Omega: y^* = F(x^*) \text{ domina } (>) \text{ a } y = F(x)$. En otras palabras, un vector x es Pareto óptimo, si no existe otro vector de decisión factible x^* que lo domine. Las soluciones Pareto óptimas son también llamadas soluciones no inferiores, admisibles, de compromiso o eficientes, mientras que sus vectores objetivo correspondientes, son considerados como soluciones no dominadas.

5.2.3. *Conjunto Pareto óptimo*

Dado un problema de optimización multi-objetivo $y = F(x)$, el conjunto Pareto óptimo, denotado por P^* , se define como, $P^* = \{x \in X | \nexists x^* \in X: F(x^*) \text{ domina } (>) \text{ a } F(x)\}$.

5.2.4. *Frente de Pareto óptimo*

Tomando como referencia la definición presentada anteriormente, respecto al conjunto Pareto óptimo, es posible definir el Frente de Pareto óptimo, representado por PF^* , de la siguiente manera, $PF^* = \{y = F(x) | x \in P^*\}$. Es decir, se denomina frente de Pareto al conjunto de soluciones óptimas en el espacio objetivo, integrado por aquellos puntos que se corresponden con las soluciones no dominadas, según el criterio de dominancia establecido.

5.3. Paralelización de Algoritmos Evolutivos

Los grandes esfuerzos computacionales requeridos al abordar problemas de gran complejidad con metodologías evolutivas, hacen razonable la aplicación de técnicas de procesamiento paralelo y distribuido en estos algoritmos. Es importante mencionar que la *paralelización* tiene como propósito, reducir el tiempo de ejecución de los algoritmos y/o encontrar nuevas formas de resolución a los problemas. En el ámbito de la Computación Evolutiva, al igual que en las Ciencias de Computación, se hace referencia a paralelización en los siguientes dos casos (López, 2013):

1. Cuando se utiliza más de un procesador o núcleo de procesador, para resolver un problema o cuando se ejecutan más de una instancia del algoritmo en forma simultánea.
2. Para hacer referencia a diseños de algoritmos con poblaciones distribuidas espacialmente, sin importar que el algoritmo se implemente utilizando procesamiento en simultáneo.

5.3.1. Algoritmos evolutivos paralelos multiobjetivo

La integración de la computación paralela y la computación evolutiva dan origen a los algoritmos evolutivos paralelos multi-objetivo (Parallel Multi-Objective Evolutionary Algorithm, p -MOEA). La implementación de estas nuevas técnicas, presenta importantes beneficios con respecto a otros métodos, ya que reúnen las características propias de los MOEA, con las ventajas del cómputo paralelo. Básicamente, los p -MOEA buscan encontrar soluciones tan buenas o mejores que sus contrapartes secuenciales en menos tiempo y/o explorar un espacio mayor de posibles soluciones; es decir, siendo fácilmente paralelizables, los p -MOEA ofrecen al menos una de las siguientes ventajas adicionales, con relación a otras técnicas de resolución de MOP (Flynn & Sherman, 1995):

- Capacidad de explorar espacios de búsqueda complejos y de alta dimensionalidad.
- Capacidad de explorar espacios de búsqueda mayores que sus contrapartes secuenciales.
- Reducción del tiempo total de ejecución.
- Mejora en la calidad de las soluciones obtenidas.

En la actualidad existen varios modelos propuestos para el desarrollo de EAs paralelos. Los tres modelos (esquemas de paralelización) más importantes son (Fernández, 2005):

- Modelo maestro-esclavo (Master-slave Model)
- Modelo de difusión (Diffusion Model)
- Modelo de islas (Island Model)

Asimismo, es importante señalar que, en el presente estudio, se utiliza un esquema paralelo asociado con el modelo de islas, operando bajo un ambiente sincrónico de interconexión continua, permitiendo así generar una estrategia paralela y cooperativa entre los algoritmos seleccionados.

La descripción de cada enfoque se presenta a continuación, teniendo en cuenta el estudio realizado por Sudholt (2015).

5.3.2. *Modelo maestro-esclavo*

Esta técnica de paralelización implica realizar una implementación estándar (secuencial) del algoritmo en cuestión y aquellas tareas que demandan más procesador, realizarlas en forma descentralizada y paralela. Normalmente, la evaluación de las funciones objetivo son las tareas que demandan mayor capacidad de procesamiento, por lo que el algoritmo una vez llega a este paso dentro del hilo ejecutado, distribuye (delega) en n procesadores la evaluación de la función fitness, recoge los resultados y continúa con los siguientes pasos del procedimiento establecido. Los resultados son cualitativamente iguales a la aplicación secuencial del algoritmo original, con la única diferencia que se reduce el tiempo de ejecución.

5.3.3. *Modelo de difusión*

Este tipo de algoritmos han sido diseñados para ser implementados en computadores masivamente paralelos, pues la población se encuentra dividida espacialmente entre los distintos procesadores e idealmente, cada procesador debería albergar un único individuo. El cruce y la selección se hará entre individuos pertenecientes a un mismo vecindario, formado por un conjunto de elementos adyacentes, teniendo en cuenta la representación espacial establecida (*ver Figura 4*). De esta forma, al limitar las posibilidades de selección, teniendo en cuenta el alcance definido por la región, se hace más lenta la transferencia de las mejores soluciones globales, aumentando así la capacidad exploratoria que posee el algoritmo y reduciendo la convergencia a óptimos locales. Sin embargo, es permitido el solapamiento entre vecindarios para propiciar la interacción, aunque leve, entre todos los individuos de la población. Está demostrado que en estos modelos, los vecindarios

tienden a formar nichos, es decir, poblaciones separadas, por lo que el costo de la comunicación puede llegar a ser muy alto.

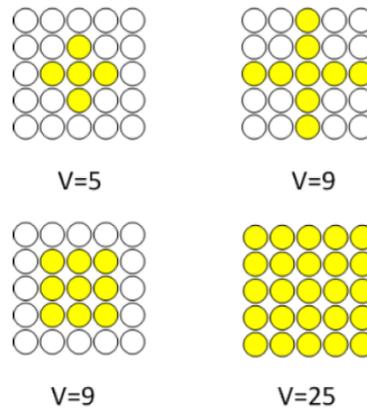


Figura 4. Topologías de vecindarios en 2D utilizables en algoritmos distribuidos. Tomado de López (2013).

5.3.4. Modelo de islas

El modelo de islas está basado en el fenómeno natural de que las poblaciones se encuentran usualmente aisladas entre sí. Los p -MOEA diseñados bajo este esquema operativo, son conocidos como MOEA multi-población o distribuidos y su característica principal se relaciona con la posibilidad que tienen los individuos de una población particular, para migrar ocasionalmente a alguna otra, durante el proceso iterativo.

Conceptualmente, la población se divide en un número específico de regiones (islas) separadas e independientes (*ver Figura 5*). Los diferentes operadores evolutivos trabajan en cada isla, lo cual implica que estas se encuentren explorando en zonas posiblemente diferentes del espacio de búsqueda. Cada isla también puede tener sus propios parámetros, así como estructuras particulares de MOEA; además, como se mencionó anteriormente, individuos de una isla podrían migrar a otra, de acuerdo a algún criterio y los diversos procesos que intervienen en la búsqueda de soluciones, pueden comunicarse entre sí, utilizando distintas topologías de interconexión, tanto

lógicas como físicas. En general, la selección de políticas que permite compartir información, deberá establecer como mínimo los siguientes aspectos:

1. La manera en que los individuos migrarán.
2. El número de migrantes.
3. La frecuencia de migración.
4. De dónde se seleccionarán los elementos a migrar y como se realizará el reemplazo de los elementos en una población, por los migrantes provenientes de otras poblaciones.
5. Los distintos parámetros y algoritmos a utilizar en cada una de las diferentes subpoblaciones o regiones.

Es fácil realizar implementaciones paralelas de este modelo distribuido, separando cada población en nodos diferentes de una red o en distintos procesadores de una máquina multiprocesador.

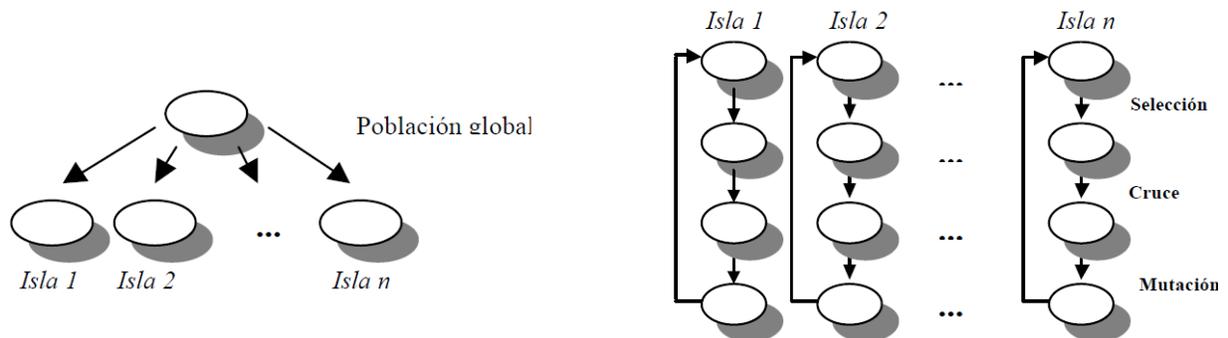


Figura 5. Distribución de una población inicial en n islas con ejecución paralela. Tomado de Stark & Salto (2005).

5.4. Gestión de la Cadena de Suministro Humanitaria

La tasa y el impacto de los desastres naturales han aumentado dramáticamente en las últimas décadas, debido al crecimiento de la población, la tendencia mundial en el urbanismo, el uso de la tierra y la explotación indiscriminada de los ecosistemas. Un ejemplo reciente de esto es el huracán Harvey en agosto de 2017, que causó daños por más de 180 mil millones de dólares y

afectó a 13 millones de personas en Texas, Louisiana, Mississippi, Tennessee y Kentucky (S. Hu & Dong, 2019).

5.4.1. Definición y clasificación de un desastre

Según la Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres (United Nations Office for Disaster Risk Reduction, UNDRR), un desastre se define como:

[...] cualquier interrupción grave del funcionamiento de la sociedad, que representa una amenaza significativa y generalizada para la vida humana, la salud, la propiedad o el medio ambiente, ya sea causado por un accidente, la naturaleza o actividad humana, y si se desarrolla repentinamente o como resultado de procesos complejos a largo plazo (Living with risk: a global review of disaster reduction initiatives, UNDRR).

Por otro lado, Galindo & Batta (2013), ofrecen una clasificación general, en la cual la palabra “desastre”, para el contexto de logística humanitaria, se refiere primordialmente a: (1) Huracanes, ciclones y tifones, (2) Inundaciones, (3) Sequías, (4) Terremotos, (5) Erupción volcánica, (6) Epidemias, (7) Hambruna e inseguridad alimentaria, (8) Desastres provocados por el hombre, (9) Movimiento de la población y (10) Desastres tecnológicos.

5.4.2. Definición de logística humanitaria

Bajo todo este panorama, la comunidad académica y profesional ha incrementado su interés en desarrollar sistemas logísticos ágiles y capaces que puedan atender diferentes tipos de eventos adversos, los cuales ponen en riesgo la integridad o la vida propia del ser humano, siempre bajo la premisa de reducir el sufrimiento y garantizar la seguridad de la población. Alcanzar tales objetivos no es una tarea fácil, debido a los recursos limitados con los que se cuentan al momento de atender una catástrofe o situación de emergencia; por esta razón, la gestión de la cadena de suministro humanitaria (Humanitarian Supply Chain Management, HSCM) o logística humanitaria

(Humanitarian Logistic, HL) toma un gran valor, como medio para “[...] planificar, implementar y controlar el flujo eficiente y rentable de bienes y materiales, así como la información relacionada, desde el punto de origen hasta el punto de consumo con el fin de aliviar el sufrimiento de las personas vulnerables [...]” (Thomas & kopczak, 2005).

5.4.3. Justificación de la cadena de suministro humanitaria

Más aún, Day et al. (2012) mencionan cinco razones por las que el estudio de la cadena de suministro humanitaria es muy importante. La primera, hace referencia a los métodos de solución, los cuales no son muy eficientes a la hora de hacer frente a un desastre, luego se debe hacer un mayor esfuerzo en los procesos investigativos con la finalidad de mejorar la logística para la atención de desastres; la segunda razón, es muy importante considerar los costos asociados a las operaciones de socorro y al sufrimiento humano, los cuales siempre están en constante crecimiento, por lo tanto, los trabajos realizados deben concentrarse en la atención oportuna y minimización de todo tipo de necesidad a las regiones afectadas. La tercera razón, hay muchas organizaciones gubernamentales y no gubernamentales que donan una gran cantidad de recursos, para apoyar las operaciones de ayuda humanitaria ante un desastre, así que encontrar la mejor forma de invertir y distribuir esos aportes recibidos implica una gran responsabilidad. La cuarta razón está relacionada con la forma de organizar los sistemas de distribución para brindar una respuesta oportuna, frente a la incertidumbre generada por un evento adverso. La quinta razón, manifiesta que el estudio de la logística humanitaria no solo se debe limitar a la reducción de los costos asociados con las operaciones, también debe trabajar la forma para minimizar el costo del tiempo, puesto que es un factor muy importante en los procesos de alivio a emergencias, donde cada segundo es vital para salvar vidas. En consecuencia, la gestión de la cadena de suministro humanitaria es un factor clave para las operaciones de apoyo frente a desastres, pues la eficiencia,

efectividad y velocidad en el suministro a los beneficiarios con salud, comida, refugio, agua, medicina y saneamiento juegan un papel fundamental.

5.4.4. Fases para la gestión de un desastre

Según Altay & Green (2006), las operaciones esenciales en la logística humanitaria, para lograr una atención rápida y eficaz de las zonas afectadas por un desastre, pueden dividirse en cuatro etapas, las cuales son, mitigación, preparación, respuesta y recuperación, las dos primeras etapas se clasifican como operaciones de apoyo o pre-desastre, y las dos últimas se clasifican como operaciones de desarrollo o pos-desastre. La *fase de mitigación*, se define como la aplicación de iniciativas destinadas a prevenir un desastre o reducir los impactos en caso de que ocurra, ejemplos de tales medidas incluyen: controles en el uso del suelo para evitar la ocupación de áreas catalogadas como riesgosas, construcción de barreras para desviar la fuerza de desastres y análisis de riesgos para estimar el potencial de los peligros. La *fase de preparación* involucra todas las actividades realizadas antes que ocurra el desastre, con el fin de lograr una atención más eficiente, ejemplo de estas son: localización y construcción de los centros de abastecimiento, administración de los recursos humanitarios, reclutamiento del personal requerido para los servicios de emergencia, planificación logística y capacitación. Por su parte, la *fase de respuesta* implica aquellas actividades realizadas una vez ocurre el desastre y cuyos objetivos están relacionados con el despliegue de recursos vitales para atender a la población afectada; actividades como la evacuación de poblaciones amenazadas, la búsqueda y el rescate urbano, la atención médica de emergencia y el manejo de heridos, estarían incluidas en esta categoría. Finalmente, la *fase de recuperación* implica acciones tomadas a largo plazo para estabilizar la comunidad y devolver la normalidad a la vida de las personas afectadas, ejemplos de esto son los siguientes: limpieza de

escombros, reconstrucción de carreteras e instalaciones claves, restauración completa de servicios vitales y atención psicológica (Hashemi Petrudi et al., 2020).

De acuerdo con lo anterior, el presente estudio está enfocado a la *fase de preparación*, relacionada con la localización de las instalaciones y la gestión de inventario para los diversos productos requeridos en las zonas afectadas y además, con la *fase de respuesta*, que hace referencia al suministro oportuno de recursos, a través de una correcta planificación en las rutas; permitiendo de esta manera abordar el problema, conocido en la literatura científica como el 2E-LIRP (Two Echelon Location Inventory Routing Problem), que involucra la localización, el inventario y el ruteo multi-nivel (dos escalones).

6. Modelo 2E-LIRP

6.1. Ilustración del 2E-LIRP

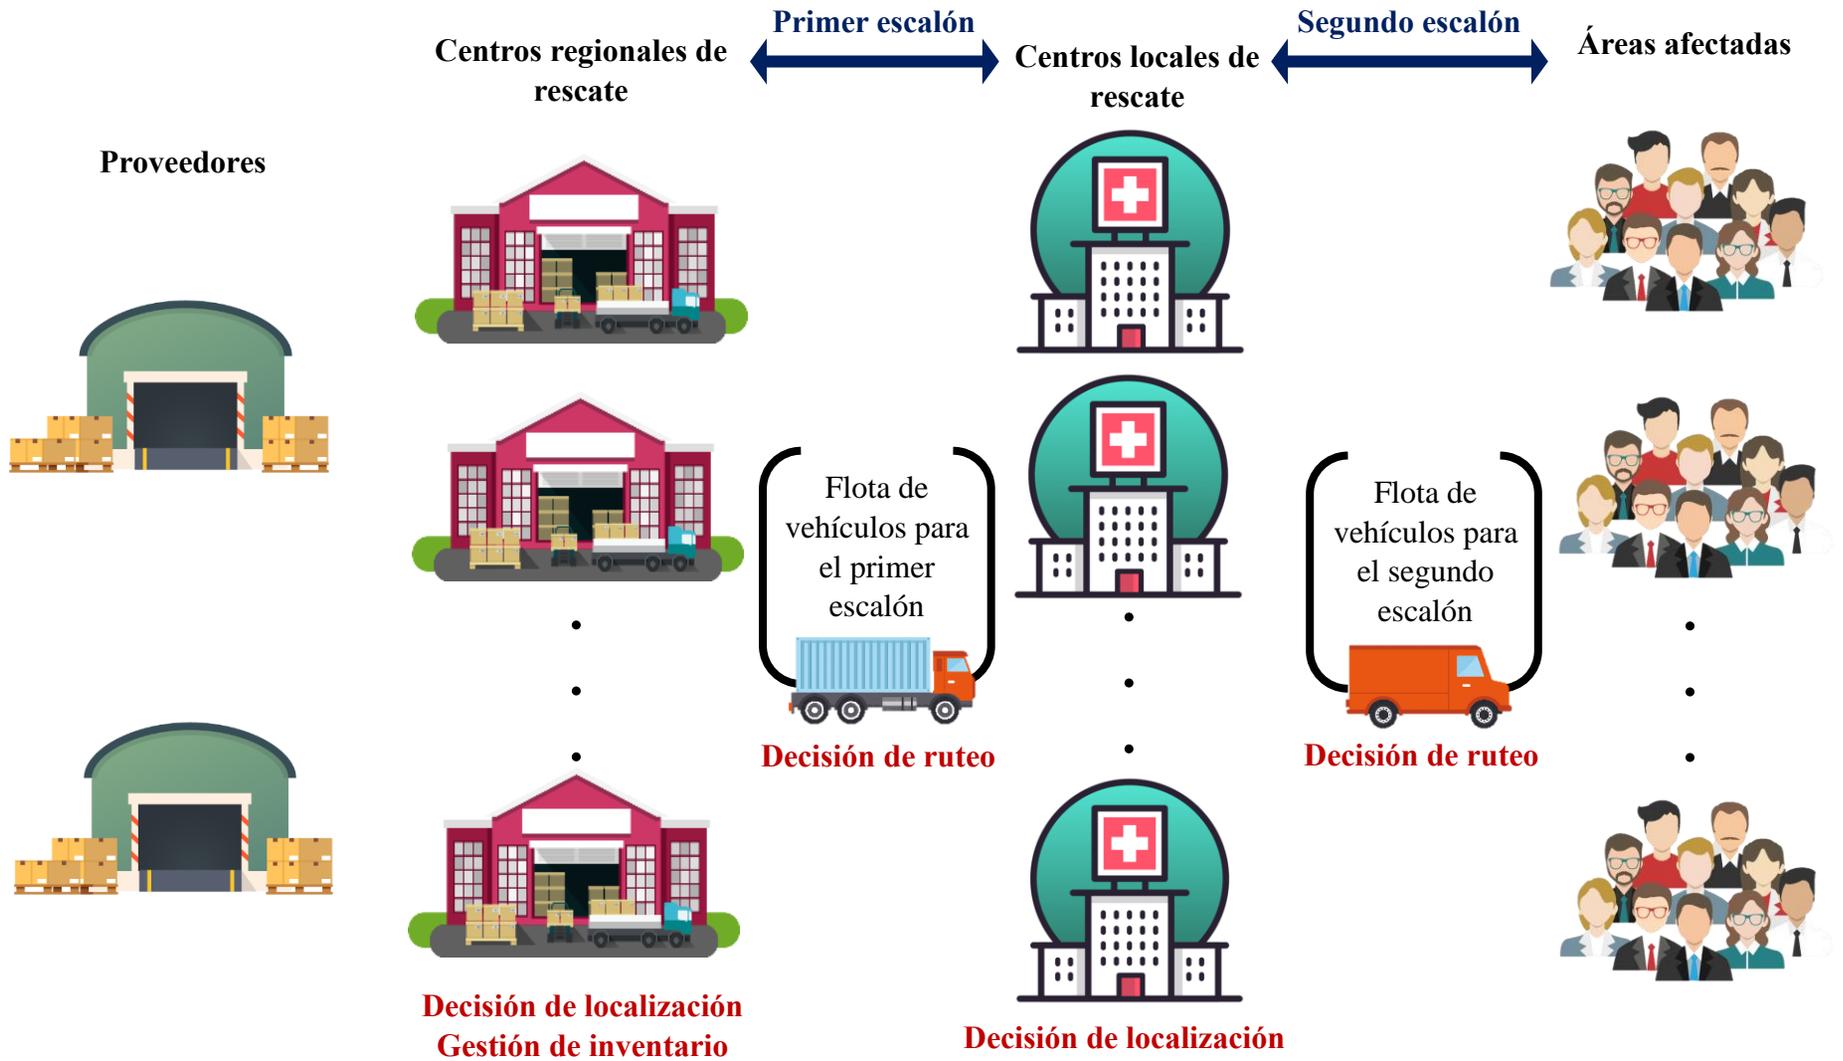


Figura 6. Representación gráfica del 2E-LIRP.

6.2.Descripción del 2E-LIRP

Como se mencionó anteriormente, el problema abordado considera dos aspectos muy importantes en la planificación y gestión de un desastre, es decir, las fases de preparación (actividades realizadas antes que ocurra el desastre, con el fin de lograr una atención más eficiente) y respuesta (actividades realizadas una vez ocurre el desastre y cuyos objetivos están relacionados con el despliegue de recursos vitales para atender a la población afectada), las cuales pueden ser contextualizadas de la siguiente manera: dado un conjunto de centros regionales de rescate y un conjunto de centros locales de rescate, donde la interacción, centros regionales – centros locales define el primer escalón y además, dada una flota de vehículos para el primer escalón y un conjunto de áreas afectadas por un desastre, para el cual la interacción, centros locales – áreas afectadas representa el segundo escalón, además de una flota de vehículos para el segundo escalón; se pide determinar qué instalaciones habilitar en cada nivel (fase de preparación) y cómo gestionar un adecuado plan de rutas que permitan distribuir los productos humanitarios desde los centros regionales hasta los centros locales y desde estos últimos a las áreas afectadas, administrando adecuadamente el inventario en las instalaciones de primer nivel (fase de respuesta), bajo los objetivos de minimizar los costos privados (localización - inventario - ruteo) y maximizar el bienestar de las regiones afectadas (sufrimiento humano), sintetizados en tres funciones, la primera, relaciona el costo total de las instalaciones habilitadas y el uso de vehículos, la segunda, asocia el costo global por ruteo en cada escalón más la administración del inventario y la tercera función, representa el costo total del sufrimiento humano, causado por la privación en los suministros de socorro y el impacto que genera la estrategia de entrega en las regiones afectadas. Por otro lado, es importante mencionar que los centros regionales designados, deben ubicarse en algún lugar alejado del área crítica o potencial de emergencia y también, a una distancia razonable

de los centros locales, pues son estos quienes tienen el contacto directo con los puntos afectados. Asimismo, se debe aclarar que los proveedores mostrados en la *Figura 6* se incluyen en la ilustración, simplemente con el propósito de representar el mercado disponible, a partir del cual, las instalaciones de primer nivel obtendrán los productos humanitarios requeridos para atender la demanda durante los periodos de socorro, manteniendo a su vez ciertos niveles de inventario. En cuanto a los suministros de emergencia, estos pueden ser clasificados siguiendo el estudio desarrollado por Holguín-Veras & Jaller (2012), quienes se centran en el análisis cuantitativo de las necesidades generadas después de un desastre, el cual es uno de los aspectos menos estudiados de la logística humanitaria; permitiendo así que los investigadores realizaran estimaciones numéricas de estos requisitos y sus patrones temporales, a través de un conjunto de datos reunidos mediante el pos-procesamiento de las solicitudes efectuadas por los servicios de emergencia, luego de ocurrida la catástrofe con el huracán Katrina. Dicha información es presentada en la *Tabla 5*, donde se resumen las principales categorías y productos humanitarios demandados, los cuales son una excelente aproximación a las necesidades reales en una situación de desastre.

Tabla 5.
Suministros básicos demandados durante un desastre.

Subsector de la industria	Productos reales solicitados	Número de solicitudes
Fabricación de equipos, electrodomésticos y componentes eléctricos	Iluminación portátil, linternas, ventilador y generador	88
Fabricación de bebidas y productos de tabaco	Galones de agua	71
Fabricación de productos de plástico y caucho	Duchas portátiles	57
Servicios administrativos y de apoyo	Personal, seguridad particular y armada	53

Continuación Tabla 5.

Subsector de la industria	Productos reales solicitados	Número de solicitudes
Fabricación de productos químicos	Nitrógeno y repelente contra insectos	51
Fabricación de alimentos	Alimentos básicos (azúcar, café, leche en polvo, harina de maíz, panela, arroz, chocolate, sal y pasta), comidas listas para ingerir (enlatados) y papillas para bebés	51
Fabricación de muebles y productos relacionados	Sillas, catres, bancos y mesas plegables	46
Servicios de atención médica ambulatoria	Médico, ambulancias, técnicos médicos y camas de campaña.	45
Fábricas de productos textiles	Mantas, carpas y sacos de dormir	41
Fabricación de Maquinaria	Remolque de lavandería, congelador, fotocopidora, bomba, compresor, montacargas y secadora comercial	25
Alojamiento	Vivienda y campamento base	25
Fabricación miscelánea	Suministros médicos, espuma, jeringas y botiquines de primeros auxilios	24
Manufactura de Productos de Petróleo y Carbón	Combustible	23
Servicios de gestión y remediación de residuos	Remoción de escombros	22
Telecomunicaciones	Teléfonos satelitales, sistemas telefónicos, puntos de respuesta de seguridad pública (líneas de emergencia), soporte de comunicación integrado de las fuerzas armadas	20

Continuación Tabla 5.

Subsector de la industria	Productos reales solicitados	Número de solicitudes
Servicios de alquiler y arrendamiento	Botellas de oxígeno y cuarto de bote	20
Transporte de camiones	Camiones cisterna de combustible	16
Vehículo de motor y piezas	Autobuses	14
Productos metálicos prefabricados	Alojamiento portátil, tanques, cercas, lavamanos y puños flexibles	13
fabricación de productos informáticos y electrónicos	Computadora, plotter para sistema de información geográfica y soporte de teledetección	12
Asistencia social	Cocina móvil y centro de recuperación ante desastres	12
Fabricación de papel	Pañales y papel higiénico	10
Alojamiento	Vivienda y campamento base	25
Fabricación miscelánea	Suministros médicos, espuma, jeringas y botiquines de primeros auxilios	24
Manufactura de Productos de Petróleo y Carbón	Combustible	23
Servicios de gestión y remediación de residuos	Remoción de escombros	22

Continuación Tabla 5.

Subsector de la industria	Productos reales solicitados	Número de solicitudes
Telecomunicaciones	Teléfonos satelitales, sistemas telefónicos, puntos de respuesta de seguridad pública (líneas de emergencia), soporte de comunicación integrado de las fuerzas armadas	20
Servicios de alquiler y arrendamiento	Botellas de oxígeno y cuarto de bote	20
Transporte de camiones	Camiones cisterna de combustible	16
Vehículo de motor y piezas	Autobuses	14
Productos metálicos prefabricados	Alojamiento portátil, tanques, cercas, lavamanos y puños flexibles	13
fabricación de productos informáticos y electrónicos	Computadora, plotter para sistema de información geográfica y soporte de teledetección	12
Asistencia social	Cocina móvil y centro de recuperación ante desastres	12
Fabricación de papel	Pañales y papel higiénico	10
Servicios profesionales, científicos y técnicos	Rótulos, equipo de comunicación, adquisición de imágenes aéreas y equipos de asistencia médica veterinaria	9
Fabricación de productos de madera	Remolques de oficina	4
Fábricas textiles	Paño facial / toalla de baño	4
Manufactura de ropa	Puños, overol de uso general y trajes antilíquido	4
Radiodifusión y telecomunicaciones	Líneas telefónicas, terminales de proveedores de Internet móvil	4
Utilidades	Tienda de servicios eléctricos	2
Comercio al por mayor y bienes duraderos	Aviones y dispositivos de comunicación	2

Continuación Tabla 5.

Subsector de la industria	Productos reales solicitados	Número de solicitudes
Fabricación de productos de cuero y afines	Botas de goma y botas de trabajo utilitarias	2
Construcción	Soporte de ingeniería / construcción	2
Mensajeros	Entrega de bienes donados	1
Servicios de alimentación y lugares para beber	Campamento base y servicios de abastecimiento	1
Administración de programas de recursos humanos	Personal de los centros de salud para el control de enfermedades	1

Nota. Adaptado de Holguín-Veras & Jaller (2012).

6.3. Supuestos del Estudio

Para desarrollar el modelo matemático, se tiene en cuenta las siguientes consideraciones fundamentales:

- Se conoce previamente la demanda generada por las áreas afectadas, en cada periodo de distribución (demanda dinámica).
- Siempre se cuenta con la cantidad suficiente de producto, para atender los puntos de demanda (no se presenta escasez).
- La capacidad de los vehículos es limitada y heterogénea en el mismo escalón.
- La carga (cantidad de producto requerida) no puede gestionarse mediante el envío directo desde los centros regionales de rescate a las áreas afectadas, sino que debe ser entregada por los centros locales de rescate. En particular, las primeras rutas escalonadas comienzan desde los centros regionales, sirven a uno o más centros locales y terminan en el mismo

centro regional; las rutas del segundo escalón comienzan desde un centro local, prestan su servicio a una o más regiones afectadas y termina en el mismo centro local (ruteo cerrado).

- Para el primer escalón (relación centros regionales y centros locales), no se tiene en cuenta las conexiones (arcos) entre centros regionales y para el segundo escalón (relación centros locales y áreas afectadas), no se consideran conexiones entre centros locales.
- La capacidad de los centros regionales y locales de rescate son limitadas. Más aún, la capacidad de los centros regionales es más alta que la capacidad de los centros locales, y a su vez, la capacidad de los centros locales es considerablemente mayor a la demanda de las regiones afectadas.
- Las instalaciones que pertenecen al mismo escalón tienen diferentes capacidades.
- Cada centro local debe ser atendido por un solo centro regional y por un solo vehículo, así mismo, cada área afectada debe ser atendida por un único centro local y por un solo vehículo, es decir, no se admiten entregas divididas para ningún nivel.
- Los centros regionales y locales de rescate habilitados en el primer periodo, establecen las instalaciones disponibles para planear las actividades posteriores de socorro (no hay cambio dinámico en el tiempo). Además, es posible reasignar un cliente a una nueva instalación, siempre y cuando inicie un nuevo periodo de abastecimiento.
- La capacidad de cada vehículo en el primer escalón es más alta, que la capacidad de cada vehículo para el segundo escalón, y a su vez, la capacidad de cada vehículo para el segundo escalón es más alta que la demanda del área asignada.
- Las rutas de la red difieren en las condiciones físicas y el tiempo de viaje relativo a cada ruta, refleja la condición de tráfico correspondiente.

- La gestión de inventario se realiza únicamente en los centros regionales habilitados, para cada uno de los productos disponibles, durante los periodos previstos.
- El flujo de productos no presenta pérdidas durante su tránsito por los centros locales, pues en estos no existe inventario.
- Los productos despachados no presentan restricciones entre sí para su envío, es decir, un vehículo cualquiera, puede ser cargado con una combinación de estos sin ningún problema.

6.4. Formulación Matemática

De acuerdo con las especificaciones propuestas por Cuda et al. (2015), el problema en estudio puede ser representado como un grafo completo $G = (N, A)$, en el que N representa el conjunto de nodos y A el conjunto de aristas dirigidas; más aún, $N = R \cup L \cup C$, donde R hace referencia al conjunto de centros regionales de rescate, L está asociado con el conjunto de centros locales de rescate y C representa el conjunto de áreas afectadas por un desastre (clientes), por otro lado, $A = E_1 \cup E_2$, en el que E_1 representa el conjunto de aristas dirigidas que conectan a un centro regional $r \in R$ con un centro local $l \in L$ (primer escalón), excluyendo cualquier conexión entre centros regionales, es decir, $E_1 = \{ (i, j) : i, j \in R \cup L \wedge (i, j) \notin R \cup R \}$, y de igual forma, E_2 es el conjunto de aristas dirigidas que conectan a un centro local $l \in L$ con una región/área afectada $c \in C$ (segundo escalón), excluyendo las conexiones posibles entre centros locales, es decir, $E_2 = \{ (i, j) : i, j \in L \cup C \wedge (i, j) \notin L \cup L \}$.

Tomando como referencia las investigaciones desarrolladas por Pérez-Rodríguez & Holguín-Veras (2016), Tavana et al. (2018), Cotes & Cantillo (2019) y Dai et al. (2019), además de tener en cuenta las consideraciones establecidas por el investigador, el modelo matemático es formulado como se presenta a continuación.

6.4.1. Conjuntos

R = Conjunto de posibles centros regionales de rescate

L = Conjunto de posibles centros locales de rescate

C = Conjunto de áreas afectadas (AA) por un desastre

V = Conjunto de vehículos para las rutas de primer nivel

W = Conjunto de vehículos para las rutas de segundo nivel

P = Conjunto de productos requeridos en las AA

T = Periodos de tiempo en los que se realiza el despliegue humanitario

6.4.2. Índices

r = Índice para los posibles centros regionales de rescate

l = Índice para los posibles centros locales de rescate

c = Índice para las áreas afectadas (AA) por un desastre

v = Índice para los vehículos de primer nivel

w = Índice para los vehículos de segundo nivel

p = Índice para los productos requeridos en las AA

t = Índice para los periodos de tiempo

6.4.3. Parámetros

K_{ip} = Capacidad de la instalación $i \in R \cup L$, para el producto $p \in P$

H_{ip} = Capacidad del vehículo $i \in W \cup V$, para el producto $p \in P$

F_i = Costo de abrir la instalación $i \in R \cup L$

G_i = Costo de utilizar el vehículo $i \in W \cup V$

D_{cp}^t = Demanda del cliente $c \in C$, para el producto $p \in P$, en el periodo $t \in T$

S_{ij} = Costo de viajar entre el nodo i y el nodo j para el primer escalón

E_{ij} = Costo de viajar entre el nodo i y el nodo j para el segundo escalón

CS_p^t = Costo de comprar el producto $p \in P$ en el periodo $t \in T$

CT_{pr}^t = Costo unitario de transportar el producto $p \in P$ desde el proveedor, hasta el centro regional de rescate $r \in R$ durante el periodo $t \in T$

CMI_{pr} = Costo unitario de mantener en inventario el producto $p \in P$, en el centro regional de rescate $r \in R$

I_{pr}^0 = Inventario inicial del producto $p \in P$, en el centro regional de rescate $r \in R$

F_{jt} = Tiempo de privación que presenta el área afectada $j \in C$ en el periodo $t \in T$

TV_{ij} = Tiempo de viaje entre el nodo i y el nodo j , para $i \wedge j \in L \cup C$

P_j = Número de individuos en el punto de demanda (área afectada) $j \in C$

VP_j^t = Valor económico promedio del bienestar percibido por un individuo en la región afectada $j \in C$ (es posible tomar como valor base, el PIB Per cápita del último año) para el periodo $t \in T$

$(VP_j^t * F_{jt} * P_j)$ = Función de privación (FP)

$(VP_j^t * TV_{ij} * P_j)$ = Función de impacto en la distribución (FID)

6.4.4. Variables de decisión

$y_i = \begin{cases} 1 & \text{Si la instalación } i \in R \cup L \text{ es abierta} \\ 0 & \text{D.L.C} \end{cases}$

$$m_{ijt}^v = \begin{cases} 1 & \text{Si el vehículo } v \in V, \text{ viaja desde el nodo } i \in R \cup L, \text{ hasta el nodo} \\ & j \in R \cup L, \text{ en la ruta de primer nivel, durante el periodo } t \in T \\ 0 & \text{D. L. C} \end{cases}$$

$$n_{ijt}^w = \begin{cases} 1 & \text{Si el vehículo } w \in W, \text{ viaja desde el nodo } i \in L \cup C, \text{ hasta el nodo} \\ & j \in L \cup C, \text{ en la ruta de segundo nivel, durante el periodo } t \in T \\ 0 & \text{D. L. C} \end{cases}$$

$$L_{rl}^t = \begin{cases} 1 & \text{Si el centro local de rescate } l \in L, \text{ es asignado al centro regional de} \\ & \text{rescate } r \in R, \text{ en el periodo } t \in T \\ 0 & \text{D. L. C} \end{cases}$$

$$P_{rc}^t = \begin{cases} 1 & \text{Si el área afectada } c \in C, \text{ es asignada al centro local de rescate } l \in L, \\ & \text{en el periodo } t \in T \\ 0 & \text{D. L. C} \end{cases}$$

$$q_i^t = \begin{cases} 1 & \text{Si el vehículo } i \in W \cup V, \text{ es usado en una ruta, en el periodo } t \in T \\ 0 & \text{D. L. C} \end{cases}$$

FN_{prlv}^t = Flujo de producto $p \in P$ a transportar, desde el centro regional de rescate $r \in R$ hasta el centro local de rescate $l \in L$ en el vehículo $v \in V$, para el periodo $t \in T$

Q_{pr}^t = Cantidad de producto $p \in P$ a comprar en el centro regional de rescate $r \in R$, en el periodo $t \in T$

I_{pr}^t = Unidades de producto $p \in P$ en inventario, para el centro regional de rescate $r \in R$, durante el periodo $t \in T$

Z_1 = Costo logístico total (Costos Privados)

Z_2 = Bienestar total de las áreas afectadas ($-Z_2$ = Costos Externos/Sufrimiento humano)

6.4.5. Función objetivo

$$\text{Minimizar } \{Z_1\} = \text{Minimizar } \left\{ \sum_{r \in R} F_r * y_r + \sum_{l \in L} F_l * y_l + \sum_{t \in T} \sum_{v \in V} G_v * q_v^t + \right.$$

$$\begin{aligned}
& + \sum_{t \in T} \sum_{v \in V} G_w * q_w^t + \sum_{t \in T} \sum_{(i,j) \in RUL} \sum_{v \in V} S_{ij} * m_{ijt}^v + \sum_{t \in T} \sum_{(i,j) \in LUC} \sum_{w \in W} E_{ij} * n_{ijt}^w + \\
& + \left. \sum_{p \in P} \sum_{r \in R} \sum_{t \in T} C S_p^t * Q_{pr}^t + \sum_{p \in P} \sum_{r \in R} \sum_{t \in T} C T_{pr}^t * Q_{pr}^t + \sum_{p \in P} \sum_{r \in R} \sum_{t \in T} C M I_{pr} * I_{pr}^t \right\} (1)
\end{aligned}$$

$$\text{Maximizar } \{Z_2\} = \text{Maximizar } \left\{ \sum_{w \in W} \sum_{t \in T} \sum_{(i,j) \in LUC} [V P_j^t * P_j * (F_{jt} + T V_{ij})] * n_{ijt}^w \right\} (2)$$

6.4.6. Restricciones

6.4.6.1. Restricciones segundo escalón.

$$\sum_{l \in L} P_{lc}^t = 1; \forall c \in C \wedge \forall t \in T \quad (3)$$

$$\sum_{c \in C} D_{cp}^t * P_{lc}^t \leq K_{lp} * y_l; \forall l \in L, \forall p \in P \wedge \forall t \in T \quad (4)$$

$$\sum_{w \in W} \sum_{j \in LUC} n_{jct}^w = 1; \forall c \in C, \forall t \in T \wedge j \neq c \quad (5)$$

$$\sum_{h \in LUC} n_{hjt}^w - \sum_{h \in LUC} n_{jht}^w = 0; \forall j \in L \cup C, \forall w \in W, \forall t \in T \wedge h \neq j \quad (6)$$

$$\sum_{i \in A'} \sum_{j \in A'} n_{ijt}^w \leq |A'| - 1; \forall w \in W, \forall t \in T, A' \subseteq A, |A'| \geq 2 \wedge i \neq j \quad (7)$$

$$\sum_{i \in L} \sum_{j \in C} n_{ijt}^w \leq 1; \forall w \in W \wedge \forall t \in T \quad (8)$$

$$\sum_{b \in LUC} n_{cbt}^w + \sum_{b \in LUC} n_{ibt}^w - P_{lc}^t \leq 1; \forall l \in L, \forall c \in C, \forall w \in W, \forall t \in T, c \neq b \wedge l \neq b \quad (9)$$

$$\sum_{c \in C} \sum_{j \in LUC} D_{cp}^t * n_{cjt}^w \leq H_{wp} * q_w^t; \forall w \in W, \forall t \in T, \forall p \in P \wedge c \neq j \quad (10)$$

6.4.6.2. Restricciones primer escalón

$$\sum_{r \in R} L_{rl}^t = y_l; \forall l \in L \wedge \forall t \in T \quad (11)$$

$$\sum_{l \in L} K_{lp} * L_{rl}^t \leq K_{rp} * y_r; \forall r \in R, \forall p \in P \wedge \forall t \in T \quad (12)$$

$$\sum_{h \in R \cup L} m_{hjt}^v - \sum_{h \in R \cup L} m_{jht}^v = 0; \forall j \in R \cup L, \forall v \in V, \forall t \in T \wedge h \neq j \quad (13)$$

$$\sum_{i \in Q'} \sum_{j \in Q'} m_{ijt}^v \leq |Q'| - 1; \forall v \in V, \forall t \in T, Q' \subseteq Q, |Q'| \geq 2 \wedge i \neq j \quad (14)$$

$$\sum_{i \in R} \sum_{j \in L} m_{ijt}^v \leq 1; \forall v \in V \wedge \forall t \in T \quad (15)$$

$$\sum_{s \in R \cup L} m_{lst}^v + \sum_{s \in R \cup L} m_{rst}^v - L_{rl}^t \leq 1; \forall r \in R, \forall l \in L, \forall v \in V, \forall t \in T, l \neq s \wedge r \neq s \quad (16)$$

$$\sum_{r \in R} \sum_{v \in V} FN_{prlv}^t - \sum_{c \in C} D_{cp}^t * P_{lc}^t = 0; \forall l \in L, \forall t \in T \wedge \forall p \in P \quad (17)$$

$$H_{vp} \sum_{h \in R \cup L} m_{lht}^v - FN_{prlv}^t \geq 0; \forall v \in V, \forall l \in L, \forall r \in R, \forall p \in P, \forall t \in T \wedge l \neq h \quad (18)$$

$$H_{vp} \sum_{h \in R \cup L} m_{rht}^v - FN_{prlv}^t \geq 0; \forall v \in V, \forall r \in R, \forall l \in L, \forall p \in P, \forall t \in T \wedge r \neq h \quad (19)$$

$$\sum_{r \in R} \sum_{l \in L} FN_{prlv}^t \leq H_{vp} * q_v^t; \forall v \in V, \forall p \in P \wedge \forall t \in T \quad (20)$$

$$I_{pr}^t = I_{pr}^0; \forall p \in P, \forall r \in R \wedge t = 0 \quad (21)$$

$$I_{pr}^t = I_{pr}^{t-1} + Q_{pr}^t - \sum_{v \in V} \sum_{l \in L} FN_{prlv}^t; \forall p \in P, \forall r \in R \wedge \forall t \in T \quad (22)$$

$$I_{pr}^t \leq K_{rp} * y_r; \forall p \in P, \forall t \in T \wedge \forall r \in R \quad (23)$$

$$I_{pr}^t = 0; \forall p \in P, \forall r \in R \wedge t = T \quad (24)$$

6.4.6.3. Restricciones variables de decisión

$$y_l \in \{0,1\}; \forall l \in L \quad (25)$$

$$n_{ijt}^w \in \{0,1\}; \forall i \in L \cup C, \forall j \in L \cup C, \forall w \in W \wedge \forall t \in T \quad (26)$$

$$P_{lc}^t \in \{0,1\}; \forall l \in L, \forall c \in C \wedge \forall t \in T \quad (27)$$

$$q_w^t \in \{0,1\}; \forall w \in W \wedge \forall t \in T \quad (28)$$

$$y_r \in \{0,1\}; \forall r \in R \quad (29)$$

$$m_{ijt}^v \in \{0,1\}; \forall i \in R \cup L, \forall j \in R \cup L, \forall v \in V \wedge \forall t \in T \quad (30)$$

$$L_{rl}^t \in \{0,1\}; \forall r \in R, \forall l \in L \wedge \forall t \in T \quad (31)$$

$$q_v^t \in \{0,1\}; \forall v \in V \wedge \forall t \in T \quad (32)$$

$$FN_{prlv}^t \in \mathbb{Z}^+ \cup \{0\}; \forall v \in V, \forall l \in L, \forall r \in R, \forall p \in P \wedge \forall t \in T \quad (33)$$

$$I_{pr}^t \in \mathbb{Z}^+ \cup \{0\}; \forall p \in P, \forall r \in R \wedge \forall t \in T \quad (34)$$

$$Q_{pr}^t \in \mathbb{Z}^+ \cup \{0\}; \forall p \in P, \forall r \in R \wedge \forall t \in T \quad (35)$$

6.5. Interpretación Modelo de Optimización

6.5.1. Función objetivo

La ecuación (1) está asociada a la primera función objetivo, que tiene como finalidad minimizar los costos privados, relacionados con la apertura de centros regionales de rescate (primer término) y centros locales de rescate (segundo término), el uso de los vehículos en el primer y segundo nivel (tercer y cuarto término), el ruteo en cada escalón (quinto y sexto término) y además, los costos causados por gestionar el inventario en las instalaciones de primer nivel

(centros regionales), compuestos por la cantidad comprada (séptimo término), transportada (octavo término) y en inventario (noveno término). Más aún, el segundo objetivo abordado se presenta en la ecuación (2) y consiste en maximizar el bienestar total de los puntos de demanda, el cual por conveniencia, se traduce a una función de costo de privación (DCF), entendida como el bienestar que puede dejar de percibir un área afectada, dado un tiempo de privación (F_{jt}) y un tiempo requerido para suministrar los productos humanitarios (TV_{ij}) hasta dicha área; obteniendo así dos componentes muy importantes: la función de privación (primer sub-término, $VP_j^t * P_j * F_{jt}$) y la función de impacto en la distribución (segundo sub-término, $VP_j^t * P_j * TV_{ij}$), que de forma conjunta representan la DCF, cuando se define el plan de rutas en el segundo escalón (tercer sub-término, n_{ijt}^w). Como se requiere minimizar la DCF, dada en términos de bienestar, se multiplica por -1 toda la expresión, a fin de representar el costo del sufrimiento humano o malestar, causado durante las operaciones humanitarias.

6.5.2. Restricciones segundo escalón

Por otro lado, la ecuación (3) garantizan la asignación de cada área afectada a un único centro local de rescate; la ecuación (4) asegura que la demanda de las regiones asignadas a un mismo centro local de rescate, no excedan la capacidad de dicha instalación; la ecuación (5) impone que cada área afectada debe ser visitada por exactamente un vehículo de segundo nivel; la ecuación (6) permite que cada vehículo en uso regrese al mismo centro local del cual partió. Además, la ecuación (7) evita la formación de sub-tours o rutas ilegales en el segundo escalón; la ecuación (8) asegura la asignación única de un vehículo a un centro local de rescate específico, si este es habilitado; la ecuación (9) asegura que el centro local de rescate l sirve a la región afectada c , si y solo si, existe un vehículo w abandonando l y arribando a c y la ecuación (10) permite que

la demanda satisfecha por un vehículo en el segundo escalón, no exceda su capacidad, si este es usado en una instalación durante el periodo t .

6.5.3. Restricciones primer escalón

Continuando con el interpretación del modelo, la ecuación (11) permite la asignación de cada centro local de rescate habilitado a un solo centro regional de rescate; la ecuación (12) hace referencia a la restricción de capacidad en los centros regionales, pues como se puede apreciar, la capacidad de un centro regional habilitado debe ser mayor o igual a la capacidad de los centros locales que le fueron asignados; la ecuación (13) garantiza el retorno al mismo centro regional de rescate, el vehículo v asignado. La ecuación (14) evita la formación de sub-tours o rutas ilegales en el primer escalón; la ecuación (15) permite que un vehículo sea asignado como máximo a un centro regional de rescate, si este es usado; la ecuación (16) asegura que el centro regional r sirve al centro local l , si allí existe un vehículo v abandonando r y arribando a l ; la ecuación (17) está asociada a la conservación del flujo en el centro local de rescate l , teniendo en cuenta que la cantidad de producto p ingresado en este debe ser igual a la demanda total de las áreas/regiones asignadas. Las ecuaciones (18) y (19) garantizan que la cantidad de flujo en un vehículo v , desde un centro regional de rescate r a un centro local de rescate l es positiva, si y solo si, tanto el centro regional como el centro local de rescate, son visitados por el mismo vehículo v ; la ecuación (20) está relacionada con la limitación de capacidad para un vehículo v (el flujo o cantidad de producto p transportado en un vehículo v , desde un centro regional r a un centro local l , debe ser menor o igual a la capacidad de dicho vehículo). La ecuación (21) permite incluir un nivel de inventario inicial para cada uno de los productos, en los centros regionales r habilitados; la ecuación (22) representa el balance de inventario, lo cual dicho en otras palabras, significa que la cantidad de inventario para un periodo t , es igual a las unidades almacenadas en el periodo anterior, más las

compras realizadas en t , menos la cantidad transportada a cada punto de demanda; la ecuación (23) evita que la unidades en inventario para cada uno de los productos humanitarios, exceda la capacidad vinculada a las instalaciones habilitadas en el primer nivel y la ecuación (24) impone un nivel de inventario nulo para el último periodo de ayuda humanitaria en las diferentes instalaciones (centros regionales de rescate).

6.5.4. Restricciones variables de decisión

Finalmente, las ecuaciones (25)-(35) establecen la naturaleza de las variables de decisión consideradas en el modelo matemático, las cuales como se puede apreciar son en su mayoría binarias (25-32) y una pequeña porción toman valores en el conjunto de enteros positivos (32-35), permitiendo así abordar un problema de programación lineal entera (Integer Linear Programming, ILP).

7. Diseño de los Algoritmos Evolutivos

En la presente investigación, se hará uso de los algoritmos evolutivos, específicamente se utilizan dos de tipo multi-objetivo, conocidos por sus siglas en inglés como NSGA-II y SPEA-II, además, de un tercer algoritmo, llamado GA, el cual permite solucionar el problema mono-objetivo, al aplicar la técnica de pesos o ponderaciones, sobre las dos funciones objetivo bajo conflicto, consideradas en el problema abordado. Más aún, resulta importante mencionar que los algoritmos son programados en Python, utilizando el entorno PyCharm versión 2020.3 y se desarrollan bajo una misma representación esquemática (solución), así como lógica, respecto a la generación de la población inicial y aplicación de los operadores genéticos (selección, cruce y mutación). A continuación, se presenta una descripción detallada sobre los diferentes componentes que permiten entender con claridad el funcionamiento de los algoritmos propuestos, especialmente, el proceso interno que se lleva a cabo para obtener una solución particular y la forma como se deben interpretar las salidas.

7.1.Lectura de Parámetros Iniciales

El usuario debe empezar el proceso, digitando manualmente las dimensiones asociadas con el problema que desea abordar (parámetros del problema). Esta lectura se realiza directamente en el código, la cual permitirá conocer a detalle:

- $n_clientes$ = Número de clientes
- $n_centroslocales$ = Número de centros locales
- $n_centrosregionales$ = Número centros regionales
- $n_vehiculos_s$ = Número de vehículos de segundo nivel
- $n_vehiculos_p$ = Número de vehículos de primer nivel

- $n_productos$ = Número de productos
- $n_periodos$ = Número de periodos
- $w1$ = Importancia de la función objetivo 1
- $w2$ = Importancia de la función objetivo 2

Por otro lado, utilizando un archivo de Microsoft Excel, se importa toda la información requerida (estructurada en pestañas) para evaluar la instancia establecida anteriormente (parámetros de la instancia); dicho procedimiento se realiza a través de una función llamada “*functions.py*”, la cual permite leer y extraer los siguientes datos:

- $demanda_clientes$: Demanda de los clientes por producto y periodo.
- $capacidad_vehiculos_p$: Capacidad que presentan los vehículos de primer escalón para cada producto.
- $capacidad_vehiculos_s$: Capacidad de los vehículos de segundo escalón para cada producto.
- $capacidad_cr$: Capacidad de los centros regionales en cada periodo.
- $capacidad_cl$: Capacidad de los centros locales en cada periodo.
- $inventario$: Inventario inicial de cada producto en cada centro regional.
- $costo_inventario$: Costo de mantener en inventario cada producto en cada centro regional.
- $costo_instalaciones_cr$: Costo de localizar o habilitar los centros regionales.
- $costo_instalaciones_cl$: Costo de localizar los centros locales.
- $costo_vehiculos_p$: Costo relacionado con la utilización de vehículos en el primer escalón.
- $costo_vehiculos_s$: Costo por utilización de vehículos en el segundo escalón.
- $costo_compraproductos$: Costo de comprar un producto en cada periodo.

- *costo_transporte*: Costo unitario de transporte de cada producto en cada periodo, para un centro regional determinado.
- *costo_rutas_p*: Costo de ruteo en el primer escalón (centros regionales y centros locales).
- *costo_rutas_s*: Costo de ruteo en el segundo escalón (centros locales y clientes).
- *costo_humano*: Costo del sufrimiento humano (dado en términos de bienestar), donde cada matriz corresponde a un periodo.

Como paso final antes de la ejecución, es necesario digitar nuevamente en el código, los parámetros generales del algoritmo seleccionado (NSGA-II, SPEA-II o GA), permitiendo así conocer las siguientes características:

- *n_poblacion* = Tamaño de la población.
- *n_generaciones* = Número de generaciones.
- *prob_mut* = Probabilidad de mutación.

7.2.Representación de la Solución

Los individuos o miembros que conforman la población, están representados por una codificación no binaria propuesta por el investigador y desarrollada con el objetivo de facilitar los diferentes procesos algorítmicos que se deben llevar a cabo en cada etapa; para lograr esto, se tomó como referencia los estudios presentados por Hiassat et al. (2017), Fazayeli et al. (2018) y Wu et al. (2021), junto a las recomendaciones hechas por Park et al. (2016). Es importante mencionar que cada miembro se compone de tres sub-cadenas, las cuales representan una solución al problema en estudio y están definidas como se muestra a continuación.

7.2.1. Sub-cadena 1

Como se puede apreciar, esta sub-cadena se encarga de llevar a cabo la asignación de clientes “C” a centros locales habilitados “CL” (segmento 1) y posteriormente efectúa la asignación de estos centros locales “CL” a los centros regionales “CR” habilitados (segmento 2); el proceso es realizado para cada uno de los periodos establecidos, dando así respuesta al problema de localización-asignación. El valor de -2 significa cambio de escalón y el -1 cambio de periodo (ver Figura 7).

Interpretación de la Figura 7: En el ejemplo presentado, puede observarse que para el periodo 1, el cliente 1 es asignado al centro local 5, el cliente 2 al centro local 2, el cliente 3 al centro local 1 y así sucesivamente. Durante el periodo 2, el cliente 1 nuevamente es asignado al centro local 5, mientras que el cliente 2 cambia de centro local, asignándose al 4. Para el periodo 3, el cliente 1 es reasignado al centro local 1 y el cliente 2 al 5; esto sucede generalmente por la naturaleza dinámica que presenta la demanda.

Sub-cadena 1														
Segmento 1									Segmento 2					
C	1	2	3	4	5	6	7	-2	CL	1	2	4	5	7
CL	5	2	1	4	5	4	7	-2	CR	3	1	3	3	3
-1														
C	1	2	3	4	5	6	7	-2	CL	1	2	4	5	7
CL	5	4	1	1	2	7	5	-2	CR	1	3	3	3	3
-1														
C	1	2	3	4	5	6	7	-2	CL	1	2	4	5	7
CL	1	5	2	7	4	4	1	-2	CR	1	3	1	1	1

Figura 7. Sub-cadena para la asignación y localización de instalaciones (Primer y segundo escalón).

7.2.2. Sub-cadena 2

Esta estructura permite ilustrar el plan de rutas para cada uno de los escalones, en los diferentes periodos. Por lo tanto, análogamente a la sub-cadena anterior, el segmento 1 representa

el segundo escalón, con exactitud, el ruteo que se genera para cada uno de los centros locales habilitados, respecto a los clientes asignados; mientras que el segmento 2, se encuentra asociado al primer escalón, el cual muestra las rutas generadas con base a los centros regionales habilitados y los respectivos centros locales que necesitan ser atendidos (ver Figura 8).

Sub-cadena 2																						
Segmento 1									Segmento 2													
CL1	9	0	3	0				-2	CR1	2	0	2	0									
CL2	1	0	2	0				-2	CR3	6	0	5	7	0	3	0	4	1	0			
CL4	5	0	4	0	6	0	6	0	-2													
CL5	7	0	5	1	0			-2														
CL7	2	0	7	0				-2														
-1																						
CL1	5	0	3	0	2	0	4	0	-2	CR1	3	0	1	0								
CL2	9	0	5	0				-2	CR3	4	0	7	2	0	6	0	4	0	2	0	5	0
CL4	1	0	2	0				-2														
CL5	8	0	7	0	6	0	1	0	-2													
CL7	3	0	6	0				-2														
-1																						
CL1	6	0	7	0	4	0	1	0	-2	CR1	5	0	1	5	0	2	0	4	7	0		
CL2	8	0	3	0				-2	CR3	1	0	2	0									
CL4	1	0	5	0	5	0	6	0	-2													
CL5	3	0	2	0				-2														
CL7	7	0	4	0				-2														

Figura 8. Sub-cadena para el plan de rutas (Primer y segundo escalón).

Interpretación de la Figura 8: Como puede observarse, en el primer periodo, se construyen rutas utilizando las instalaciones que fueron habilitadas previamente en la sub-cadena anterior (manteniendo equivalencia temporal), es decir, con los centros locales 1, 2, 4, 5 y 7; particularmente, el primer valor que aparece en cada una de estas instalaciones, siempre hará referencia a un tipo de vehículo que fue asignado para realizar una ruta, mientras que los valores cero puede ser interpretados como la finalización de una visita o el inicio de una nueva ruta con otro tipo de vehículo, lo cual resulta necesario, dada las limitaciones de capacidad para atender

todos los puntos asignados. Por ejemplo, al centro local 4, se le asigna el vehículo tipo 4, el cero indica el inicio de ruta, visita el cliente 4 y finaliza su viaje (valor cero), regresando a la instalación de la cual partió; posteriormente, se asigna un nuevo vehículo al centro local 4, en este caso, el tipo 6, se asigna cero para representar el inicio de la ruta y luego este visita el cliente 6, para así finalizar una vez más con valor cero. Análogamente se interpretan las rutas de todos los demás centros locales habilitados, durante los diferentes periodos.

7.2.3. *Sub-cadena 3*

En este caso, la última estructura del individuo se encuentra relacionada con el problema de gestionar inventario en las instalaciones de primer escalón, teniendo en cuenta que la demanda, los costos de comprar y transportar productos son dinámicos en el tiempo, es por esto que, el segmento 1 establece la cantidad a comprar, según el tipo de producto y el segmento 2, da respuesta a cuantas unidades deben almacenarse en un centro regional habilitado, para los diferentes periodos. El valor -2 cumple el rol de separador entre la información que relaciona la cantidad a comprar Q y las unidades en inventario I (ver Figura 9).

Interpretación de la Figura 9: De acuerdo con el ejemplo y teniendo presente los centros regionales que fueron habilitados en la sub-cadena 3, la gestión de inventario se realiza en este caso sobre las instalaciones tipo 1 y 3. Particularmente el centro regional 1 necesita comprar 8344 unidades de producto 1 durante el periodo 1, 2167 unidades el periodo 2 y 1624 unidades el periodo 3; en cuanto al producto 2, deben comprarse 2893 unidades el periodo 1, 4842 unidades en el periodo 2 y 2294 unidades para el periodo 3. Al apreciar los niveles de stock, es posible inferir que debe mantenerse un nivel equivalente a 7326 unidades de producto 1 en el periodo 1, 6210 unidades el periodo 2 y cero para el último periodo, dado que finaliza el servicio planeado y resulta innecesario dejar suministros sin utilizar. Aplicando la lógica descrita anteriormente, es posible

interpretar las cantidades Q e I , para cada uno de los productos, en las diferentes instalaciones que puedan presentarse.

		Sub-cadena 3						
		Segmento 1				Segmento 2		
		t1	t2	t3		t1	t2	t3
CR1	P1	8344	2167	1624	-2	7326	6210	0
	P2	2893	4842	2294	-2	2011	4939	0
	P3	6087	1695	1491	-2	6558	5241	0
-1								
CR3	P1	11679	3266	351	-2	4178	479	0
	P2	4699	1384	5	-2	5919	1143	0
	P3	1910	4539	472	-2	1910	155	0

Figura 9. Sub-cadena para la administración del inventario (Q e I) en las instalaciones de primer nivel.

7.3. Generación de la Población Inicial

Los individuos que componen esta primera etapa, fueron creados de forma aleatoria, siguiendo un procedimiento lógico y teniendo en cuenta las principales restricciones (capacidad, disponibilidad de vehículos, entre otras) presentadas en el modelo matemático. A grandes rasgos, las operaciones efectuadas son las siguientes:

1. *Habilitación de centros locales y asignación de área afectas o clientes (segundo escalón):*

Se genera un número aleatorio entre 1 y la cantidad máxima de centros locales, luego se procede a realizar la asignación (aleatoriamente) de los clientes, siempre y cuando la demanda no exceda la capacidad disponible de dicha instalación y el cliente no haya sido asignado previamente a otro centro local. El proceso finaliza cuando todos los clientes se asignen a una instalación específica, obteniendo así la estructura presenta en la *Figura 10*, correspondiente al primer periodo.

C	1	2	3	4	5	6	7
CL	5	2	1	4	5	4	7

Figura 10. Estructura de localización-asignación (Segundo escalón).

2. *Construcción de rutas para el segundo escalón:* En función de las instalaciones habilitadas, el algoritmo procede a generar las rutas, teniendo presente los clientes que fueron asignados a cada una de estas. Inicialmente se establece un número aleatorio entre 1 y la cantidad máxima de vehículos disponibles, luego verifica si este tiene la capacidad suficiente para visitar por lo menos un cliente, de ser posible, el vehículo es asignado a la instalación y paralelamente se crea de forma aleatoria, un orden para visitar los nodos demanda. Posteriormente, se relaciona el vehículo con la cantidad de clientes que este puede atender, de acuerdo a su capacidad; en el momento que este no pueda suplir las exigencias (teniendo presente el orden), la ruta finaliza y se asigna un nuevo vehículo. El procedimiento concluye, una vez que todos los clientes hacen parte de una ruta particular, obteniendo así la estructura presentada en la *Figura 11*, que relaciona el primer periodo.

CL1	9	0	3	0				
CL2	1	0	2	0				
CL4	5	0	4	0	6	0	6	0
CL5	7	0	5	1	0			
CL7	2	0	7	0				

Figura 11. Estructura del plan de rutas (Segundo escalón).

3. *Habilitación de centros regionales y asignación de centros locales (primer escalón):* Similar al proceso anterior, es necesario generar números aleatorios entre 1 y el valor máximo de centros regionales disponibles, posteriormente se agregan los centros locales que fueron habilitados, cumpliendo las restricciones de capacidad y de asignación a una única instalación, pues no se considera entrega dividida. Cuando todas las instalaciones de segundo nivel son asignadas, se genera la estructura mostrada en la *Figura 12*, que corresponde al primer periodo (equivalencia temporal).

CL	1	2	4	5	7
CR	3	1	3	3	3

Figura 12. Estructura de localización-asignación (Primer escalón).

4. *Construcción de rutas para el primer escalón:* Como se ha ilustrado hasta el momento con las rutas del segundo escalón, es indispensable conocer previamente la estructura de localización-asignación; para este caso en específico, la asignación de los centros locales a los centros regionales (siempre con el propósito de utilizar la menor cantidad posible), ya que, con esta información, el algoritmo procede nuevamente a la selección de vehículos bajo un enfoque aleatorio, establecimiento de un orden para la atención y verificación en el cumplimiento de las restricciones asociadas con la capacidad. El procedimiento finaliza, si todos los centros regionales habilitados poseen una estructura definida para enviar los recursos demandados por los diferentes centros locales, resumiendo así su estructura en la *Figura 13*, que pertenece al primer periodo.

CR1	2	0	2	0									
CR3	6	0	5	7	0	3	0	4	1	0			

Figura 13. Estructura del plan de rutas (Primer escalón).

5. *Administración del inventario en las instalaciones de primer escalón:* El problema que se aborda en este apartado, se encuentra enfocado particularmente en dos interrogantes fundamentales: ¿Cuánto producto tipo p comprar en el periodo t ? y ¿Cuál debe ser el inventario I del producto tipo p en el periodo t ?, teniendo presente que la gestión se realiza exclusivamente en los centros regionales. Por lo tanto, con el objetivo de dar respuesta a estos dos cuestionamientos, se desarrolló un procedimiento algorítmico, el cual se presenta a continuación:

$$I(t) = I(t - 1) + Q(t) - D(CL)(t)$$

$I(t)$ = Inventario final en el periodo t

$I(t - 1)$ = Inventario inicial

$Q(t)$ = Cantidad de producto a comprar en el periodo t (Variable desconocida)

$D(CL)(t)$ = Demanda del centro local asignado en el periodo t

Cálculo general de la carga

Si $t = 1$ Entonces: $CARG-P(t1) =$ Carga total de todos los periodos para el producto p

Si $t = 2$ Entonces: $CARG-P(t2) = CARG-P(t1) - D(t1) - I(t1)$

Si $3 \leq t \leq T$ Entonces: $CARG-P(t) = CARG-P(t-1) - Q(t-1)$

Para cada periodo t en cada instalación y producto p , se debe verificar las siguientes condiciones, con el fin de hallar la cantidad a comprar $Q(t)$ y consecuentemente, el inventario $I(t)$:

Mientras $t = 1$

Si: $I(t-1) \geq D(t)$ **AND** $CARG-P(t) > CAP(CR)$

Si: $CAP(CR) + D(t) \leq CARG-P(t)$

Entonces: $Q = NA \in [0; CAP(CR) + D(t) - I(t-1)]$

De lo contrario

$Q = NA \in [0; CARG-P(t) - I(t-1)]$

Si: $I(t-1) < D(t)$ **AND** $CARG-P(t) > CAP(CR)$

Si: $CAP(CR) + D(t) - I(t-1) \leq CARG-P(t)$

Entonces: $Q = NA \in [D(t) - I(t-1); CAP(CR) + D(t) - I(t-1)]$

De lo contrario

$Q = NA \in [D(t) - I(t-1); CARG-P(t) - I(t-1)]$

Si: $I(t-1) \geq D(t)$ **AND** $CARG-P(t) \leq CAP(CR)$

Entonces: $Q = NA \in [0; CARG-P(t) - I(t-1)]$

Si: $I(t-1) < D(t)$ AND $CARG-P(t) \leq CAP(CR)$

Entonces: $Q = NA \in [D(t)-I(t-1); CARG-P(t) - I(t-1)]$

Mientras $2 \leq t < T$

Si: $I(t-1) \geq D(t)$ AND $CARG-P(t) > CAP(CR)$

Si: $CAP(CR)+D(t) \leq CARG-P(t)$

Entonces: $Q = NA \in [0; CAP(CR) + D(t) - I(t-1)]$

De lo contrario:

$Q = NA \in [0; CARG-P(t)]$

Si: $I(t-1) < D(t)$ AND $CARG-P(t) > CAP(CR)$

Si: $CAP(CR)+D(t)-I(t-1) \leq CARG-P(t)$

Entonces: $Q = NA \in [D(t)-I(t-1); CAP(CR) + D(t)-I(t-1)]$

De lo contrario

$Q = NA \in [D(t)-I(t-1); CARG-P(t)]$

Si: $I(t-1) \geq D(t)$ AND $CARG-P(t) \leq CAP(CR)$

Entonces: $Q = NA \in [0; CARG-P(t)]$

Si: $I(t-1) < D(t)$ AND $CARG-P(t) \leq CAP(CR)$

Entonces: $Q = NA \in [D(t)-I(t-1); CARG-P(t)]$

Mientras $t = T$

Entonces: $Q = CARG-P(T)$

Al aplicar el procedimiento anterior para cada uno de los productos y periodos que requiere planear la instalación CR1 de primer nivel, se obtiene la estructura apreciada en la *Figura 14*.

		t1	t2	t3		t1	t2	t3
CR1	P1	8344	2167	1624	-2	7326	6210	0
	P2	2893	4842	2294	-2	2011	4939	0
	P3	6087	1695	1491	-2	6558	5241	0

Figura 14. Estructura relacionada con la administración del inventario para el CR1.

La metodología descrita hasta el momento, está enfocada en gran parte al primer periodo, pero su lógica es aplicable a cualquier otra instancia temporal, por lo tanto, esto se convierte en un ciclo iterativo, que culmina cuando se haya establecido la asignación, localización, ruteo y administración del inventario, para cada uno de los periodos, obteniendo al final las tres sub-cadenas apreciadas en la *Figura 7*, *Figura 8* y *Figura 9* respectivamente.

7.4. Operadores Genéticos

Una vez se obtiene la población inicial, el siguiente paso en el proceso evolutivo consiste en la aplicación de los operadores genéticos sobre la población actual, con el propósito de generar una nueva descendencia que tenga como característica ideal, un mayor grado de ajuste (mejores soluciones) respecto a la población anterior. Con la finalidad de ilustrar dicho proceso, se resume en el siguiente apartado cada uno de los operadores utilizados, teniendo claro que este procedimiento fue ajustado posteriormente, según la lógica particular que presenta cada metodología evolutiva (NSGA-II, SPEA-II y GA).

7.4.1. Operador de cruce

Este proceso inicia conformando parejas (padres) aleatoriamente, es decir, generando números al azar entre 1 y N (tamaño de la población) para relacionar dos individuos de P_t . Al finalizar esta primera parte, se obtiene un conjunto de padres con cardinalidad igual a $N/2$; luego de esto, se toma cada pareja (ver *Figura 15* y *Figura 16*) y se aplica el *cruce de 1 punto* sobre la sub-cadena 1, lo cual permite crear un par de hijos (ver *Figura 17* y *Figura 18*). El conjunto que representa a los hijos, posee un tamaño equivalente a N .

Padre 1														
Segmento 1									Segmento 2					
C	1	2	3	4	5	6	7	-1	CL	1	2	4	5	7
CL	5	2	1	4	5	4	7	-1	CR	3	1	3	3	3
-2														
C	1	2	3	4	5	6	7	-1	CL	1	2	4	5	7
CL	5	4	1	1	2	7	5	-1	CR	1	3	3	3	3
-2														
C	1	2	3	4	5	6	7	-1	CL	1	2	4	5	7
CL	1	5	2	7	4	4	1	-1	CR	1	3	1	1	1

Figura 15. Sub-cadena 1 del padre 1.

Padre 2														
Segmento 1									Segmento 2					
C	1	2	3	4	5	6	7	-1	CL	2	3	4	5	6
CL	3	5	6	2	4	6	4	-1	CR	3	2	2	3	4
-2														
C	1	2	3	4	5	6	7	-1	CL	2	3	4	5	6
CL	5	4	6	6	2	5	3	-1	CR	2	3	3	4	2
-2														
C	1	2	3	4	5	6	7	-1	CL	2	3	4	5	6
CL	6	6	2	3	4	5	6	-1	CR	4	2	4	2	3

Figura 16. Sub-cadena 1 del padre 2.

Hijo 1														
Segmento 1: Padre #2									Segmento Parcial 2: Padre #1					
C	1	2	3	4	5	6	7	-1	CL	1	2	4	5	7
CL	3	5	6	2	4	6	4	-1	CR	3	1	3	3	3
-2														
C	1	2	3	4	5	6	7	-1	CL	1	2	4	5	7
CL	5	4	6	6	2	5	3	-1	CR	1	3	3	3	3
-2														
C	1	2	3	4	5	6	7	-1	CL	1	2	4	5	7
CL	6	6	2	3	4	5	6	-1	CR	1	3	1	1	1

Figura 17. Sub-cadena 1 del hijo 1.

Hijo 2														
Segmento Parcial 1: Padre #1									Segmento 2: Padre #2					
C	1	2	3	4	5	6	7	-1	CL	2	3	4	5	6
CL	5	2	1	4	5	4	7	-1	CR	3	2	2	3	4
-2														
C	1	2	3	4	5	6	7	-1	CL	2	3	4	5	6
CL	5	4	1	1	2	7	5	-1	CR	2	3	3	4	2
-2														
C	1	2	3	4	5	6	7	-1	CL	2	3	4	5	6
CL	1	5	2	7	4	4	1	-1	CR	4	2	4	2	3

Figura 18. Sub-cadena 1 del hijo 2.

Como se puede apreciar en el ejemplo anterior (ver figura 17 y Figura 18), el *Hijo 1* hereda el segmento 1 del padre 2 y el segmento 2 del padre 1, mientras que el *Hijo 2* adquiere el segmento 1 del padre 1 y el segmento 2 del padre 2 para conformar la sub-cadena 1 respectivamente; sin embargo, aparece en algunos casos el término *parcial*, lo cual sucede por cuestiones de coherencia entre segmentos de la sub-cadena (primer y segundo escalón). Para definir cuál segmento se parcializa, es necesario generar nuevamente un número aleatorio entre 1 y 2 para el caso del Hijo 1, mientras que en el Hijo 2, el segmento a parcializar corresponde al segmento opuesto que se parcializa en el Hijo 1.

Con el propósito de heredar la mayor cantidad posible de información genética que presentan los padres, comprender el proceso de parcialización y obtener las sub-cadenas faltantes (2 y 3) de los hijos, las cuales deben ser reconstruidas, el algoritmo tiene cuenta los siguientes pasos:

Si (Parcializa el segmento heredado 1)

Entonces:

Hereda (Padres)

- *Sub-cadena 1 (Segmento 2)*

Instalaciones habilitadas que corresponden a los CR y CL.

- *Sub-cadena 2 (Segmento 1 y 2)*

Vehículos utilizados en los planes de ruta para los diferentes periodos de tiempo.

Reconstruye (Hijo)

- *Sub-cadena 1 (Segmento 1)*

Asignación de los clientes, teniendo en cuenta los CL heredados.

- *Sub-cadena 1 (Segmento 2)*

Asignación de los CL, de acuerdo a los CR heredados.

- *Sub-cadena 2 (Segmento 1)*

Plan de rutas para los CL habilitados.

- *Sub-cadena 2 (Segmento 2)*

Plan de rutas para los CR habilitados.

- *Sub-cadena 3 (Segmento 1 y 2)*

Administración del inventario en las instalaciones de primer nivel.

Si (Parcializa el segmento heredado 2)

Entonces:

Hereda (Padres)

- *Sub-cadena 1 (Segmento 1)*

Toda la configuración correspondiente a la localización y asignación del segundo escalón.

- *Sub-cadena 1 (Segmento 2)*

Instalaciones CR habilitadas.

- *Sub-cadena 2 (Segmento 1)*

Toda la configuración mostrada para el plan de rutas en el segundo escalón.

- *Sub-cadena 2 (Segmento 2)*

Vehículos utilizados en el plan de rutas para el primer escalón, en los diferentes periodos de tiempo.

Reconstruye (Hijo)

- *Sub-cadena 1 (Segmento 2)*

Asignación de los CL, de acuerdo a los CR heredados.

- **Sub-cadena 2 (Segmento 2)**
Plan de rutas para los CR habilitados.
- **Sub-cadena 3 (Segmento 1 y 2)**
Administración del inventario en las instalaciones de primer nivel.

Al aplicar el procedimiento descrito hasta el momento y teniendo en cuenta la lógica presentada en la generación de la población inicial, se obtiene finalmente un par de hijos, compuesto cada uno por tres sub-cadenas, que cumplen con todos los criterios y condiciones establecidas, es decir, representan nuevas soluciones al problema, de las cuales se espera una mejor función fitness y un buen nivel de diversidad, clave en futuras iteraciones.

7.4.2. Operador de mutación

Obtenida la población de hijos en la generación o iteración t , representado por $H_t(N)$, el siguiente paso consiste en aplicar sobre este conjunto el proceso de mutación, con un porcentaje P_m ajustado por el usuario. La lógica que implica este procedimiento, puede ser explicada de la siguiente manera:

Paso 1 (Hijo a mutar). Seleccionar al azar un individuo $k \in H_t$.

Paso 2 (Aplicado al primer escalón). Elegir un Centro Regional (CR_Actual) de forma aleatoria y reemplazarlo por un CR_Nuevo que no haya sido utilizado en la solución actual del Hijo (probar hasta con tres instalaciones de forma aleatoria), cumpliendo una condición fundamental:

$$\text{Capacidad (CR_Nuevo)} \geq \text{Carga (CR_Actual)} \text{ para cada producto } p \text{ y período } t$$

Nota: Aplicar este procedimiento sobre una cantidad de CR equivalente a la $E \left[\frac{\# \text{CR_Habilitados}}{4} \right]$ siempre y cuando sea posible. Si no se puede realizar para ningún CR_Actual/Habilitado, entonces se debe obviar esta parte. De igual Manera si el número de CR_Nuevo = 0, se debe omitir la mutación.

Paso 3 (Reemplazos respectivos sobre los segmentos afectados). Actualizar la *sub-cadena 1* /*Segmento2* (Localización CR y Asignación de CL A CR) y la *sub-cadena 2/segmento 2* (Plan de rutas para el primer escalón) del Hijo Mutado.

Paso 4 (Reemplazos respectivos sobre los segmentos afectados). Recalcular la administración del inventario para los nuevos CR habilitados o *CR_Nuevo*, es decir, actualizar la cantidad a comprar Q y las unidades en el inventario I .

Paso 5 (Actualizar el Fitness). Estimar nuevamente la función $F_T = w_1 * F_1 + w_2 * (-1 * F_2)$ del Hijo Mutado.

Mientras no se haya verificado la cantidad de hijos mutados ($N * P_m$)

Volver al *Paso 1*.

7.4.3. Operador de selección

Para aplicar este operador, resulta necesario tomar como producto inicial la población actual $P_t(N)$ y el conjunto final de hijos $H_t(N)$, los cuales se unen para formar un solo conjunto representado por $D_t(2N) = P_t(N) \cup H_t(N)$. Como el objetivo es generar la población inicial de la siguiente generación ($t + 1$), manteniendo el tamaño igual a N , se debe truncar (reducir) el conjunto $D_t(2N)$, es decir, $P_{t+1}(N) = Trun[D_t(2N)]$, que consiste básicamente en utilizar la *selección por torneo aleatorio*; dicha técnica toma al azar un par de individuos $k \wedge k^* \in D_t(2N)$, compara sus respectivos fitness y quien presente el menor valor es agregado inmediatamente al conjunto $P_{t+1}(N)$, mientras que el otro se rechaza. El proceso es realizado iterativamente hasta obtener la cardinalidad deseada.

7.5.Función Fitness

Con la finalidad de establecer un criterio que permita evaluar el grado de adaptabilidad (ajuste) que posee un individuo k creado durante la generación t , se definen las funciones F_1 y $-F_2$, que representan los costos logísticos (privados) y de privación (externos) respectivamente;

más aún, si se trata de los algoritmos evolutivos multi-objetivo (NSGA-II y SEPA-II), el individuo o solución k conserva las dos funciones independientes para su evaluación bajo el criterio de dominancia, pero en el caso del enfoque mono-objetivo (GA), estas dos funciones se combinan, utilizando el concepto de fitness total F_T , que es igual a la suma ponderada (w_1 y w_2) de los objetivos, es decir, $F_T = w_1 * F_1 + w_2 * (-1 * F_2)$. Por lado, es importante mencionar que estas dos funciones son descritas matemáticamente en la sección 6, sin embargo, a modo de ilustración pueden ser expresadas de la siguiente manera:

$F_1 =$ Costo de Localizar CR + Costo de Localizar CL + Costo de Utilizar los Vehículos VP + Costo de Utilizar los Vehículos VS + Costo de Ruteo en el Primer Escalón + Costo de Ruteo en el Segundo Escalón + Costo de Comprar Productos + Costo de Transportar los Productos + Costo de Mantener en Inventario - *Costos Privados*.

$F_2 =$ Bienestar que percibe un Área Afectada C (Si se multiplica por -1, equivale al Costo de Oportunidad/Privación en términos de bienestar) - *Costos Externos*.

8. Construcción de los Algoritmos Evolutivos Paralelo-Cooperativo (p -EA_V1)

Tomando como referencia el procedimiento lógico que posee cada uno de los algoritmos elegidos (ver *Apéndice A*), además del esquema propuesto para generar y representar un individuo o solución k , es posible construir una versión paralela y cooperativa de cada técnica, como se aprecia en los diagramas de flujo (ver *Figura 19-21*), utilizando el paradigma de “*sistemas distribuidos o islas*”, que consiste básicamente en el uso de un coordinador o colector C (*variable multi-processing*), el cual cumple una función mediadora en el intercambio de información, generada por cada una de las islas. Con la finalidad de comprender su rol en el proceso algorítmico, se presenta a continuación un resumen de su estructura, teniendo en cuenta la técnica aplicada.

1. Coordinador p -GA_V1

- 1.1. Módulo para la recepción y transferencia de información generada en la isla 1
- 1.2. Módulo para la recepción y transferencia de información generada en la isla 2
- 1.3. Módulo de almacenamiento (Inicia su funcionamiento una vez se cumple con el criterio de parada)
 - 1.3.1. Sub-módulo que guarda el conjunto de mejores individuos obtenidos en la isla 1 durante cada generación [$S^1(T)$]
 - 1.3.2. Sub-módulo que contiene el conjunto de mejores individuos obtenidos en la isla 2 durante cada generación [$S^2(T)$]

2. Coordinador p -NSGA-II_V1

- 2.1. Módulo para la recepción y transferencia de información generada en la isla 1
- 2.2. Módulo para la recepción y transferencia de información generada en la isla 2
- 2.3. Módulo de almacenamiento (Se activa una vez finaliza el proceso iterativo)
 - 2.3.1. Sub-módulo que guarda la población final [$P_T^1(N/2)$] de la isla 1

2.3.2. Sub-módulo que contiene la población final $[P_T^2(N/2)]$ de la isla 2

3. Coordinador p -SPEA-II_V1

3.1. Módulo para la recepción y transferencia de información generada en la isla 1

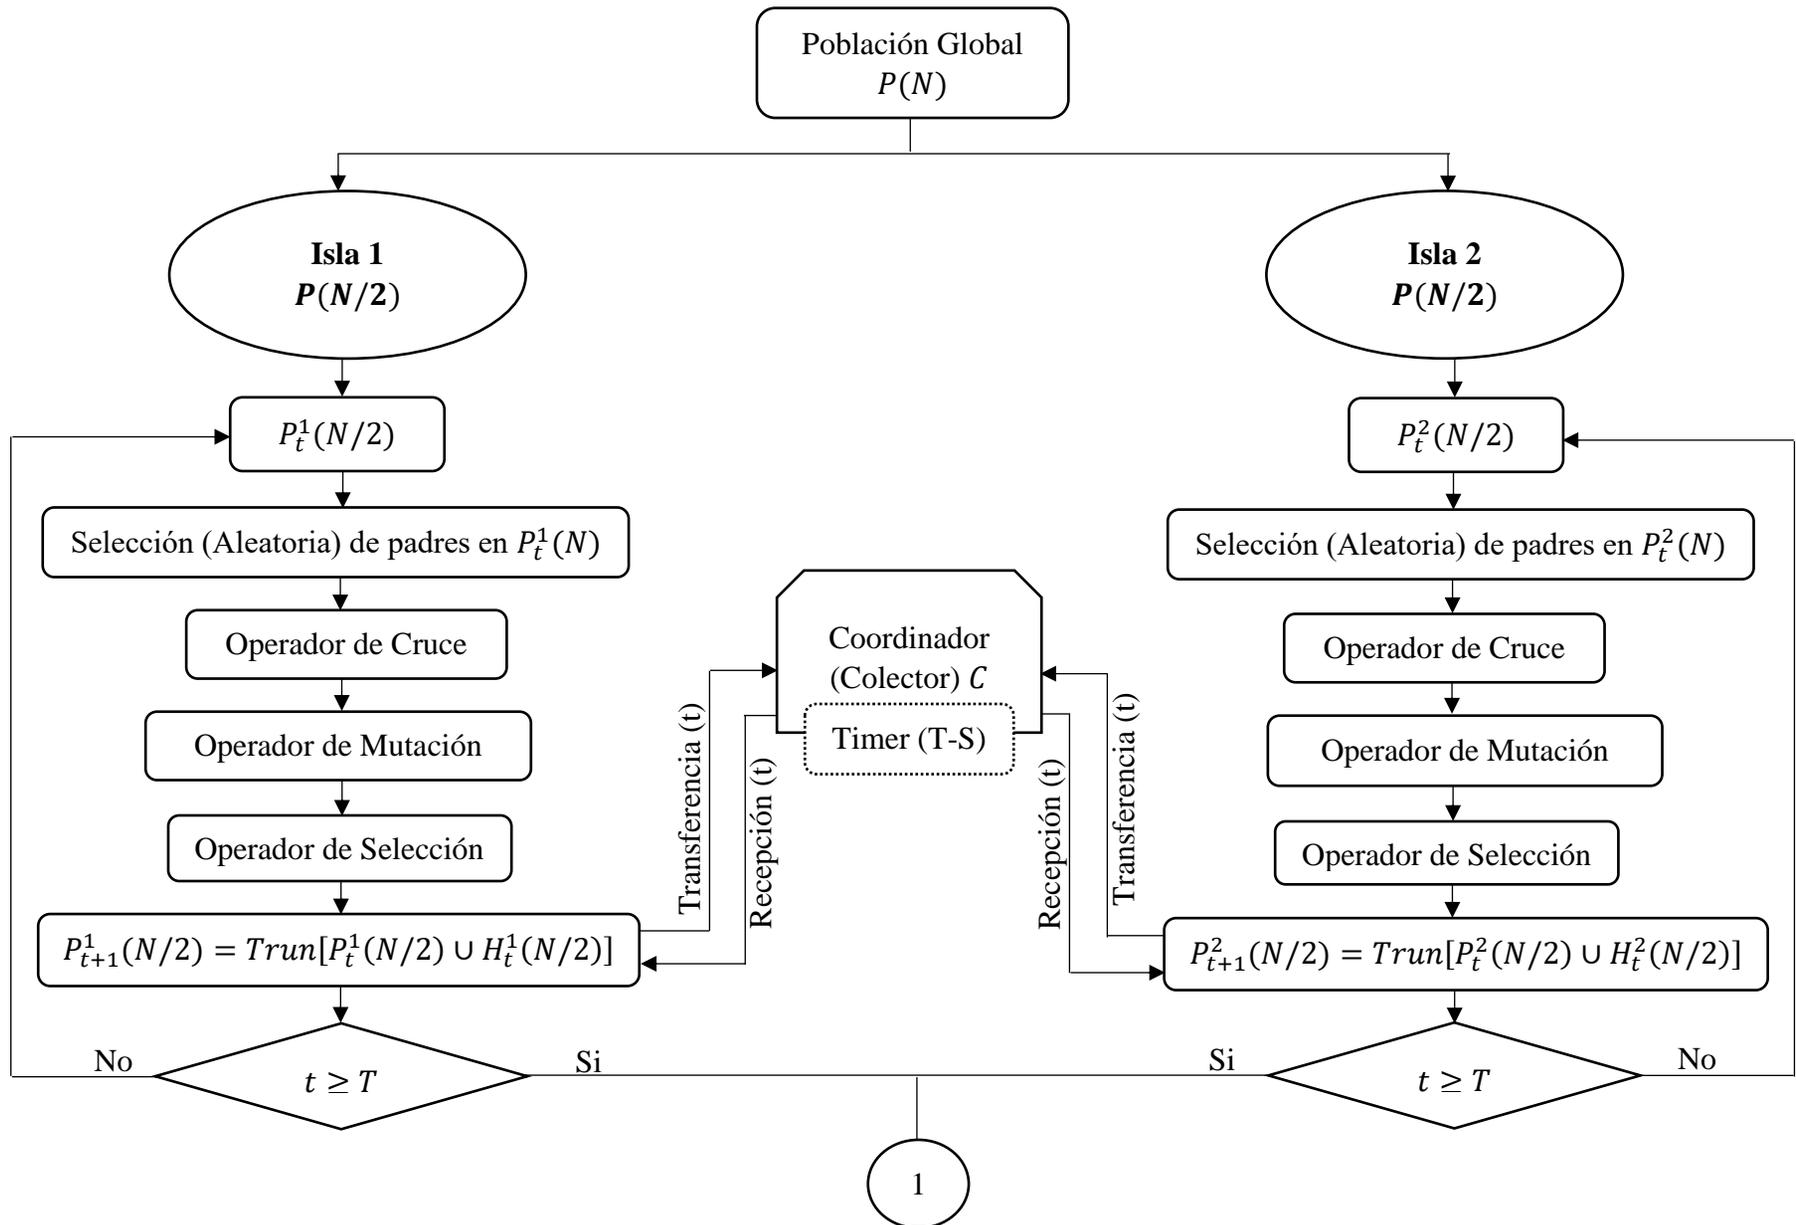
3.2. Módulo para la recepción y transferencia de información generada en la isla 2

3.3. Módulo de almacenamiento (Se ejecuta una vez finaliza el proceso iterativo)

3.3.1. Sub-módulo que guarda la población externa final $[P_{E_1}^T]$ de la isla 1

3.3.2. Sub-módulo que contiene la población externa final $[P_{E_2}^T]$ de la isla 2

8.1. Diagrama de Flujo para el *p*-GA_V1



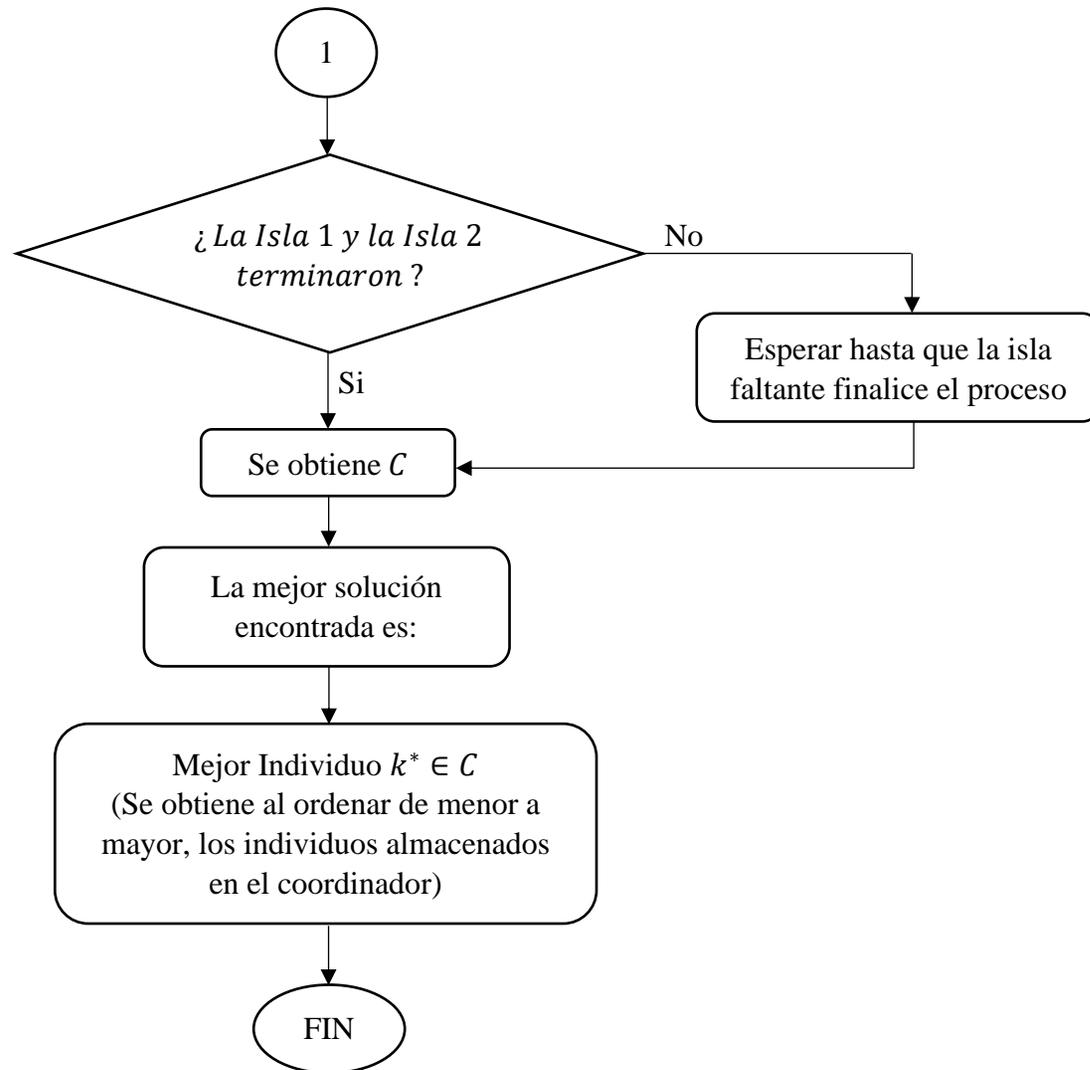


Figura 19. Estructura paralela y cooperativa del *p*-GA_V1 con operación asincrónica.

8.1.1. Análisis del coordinador en el p-GA_V1

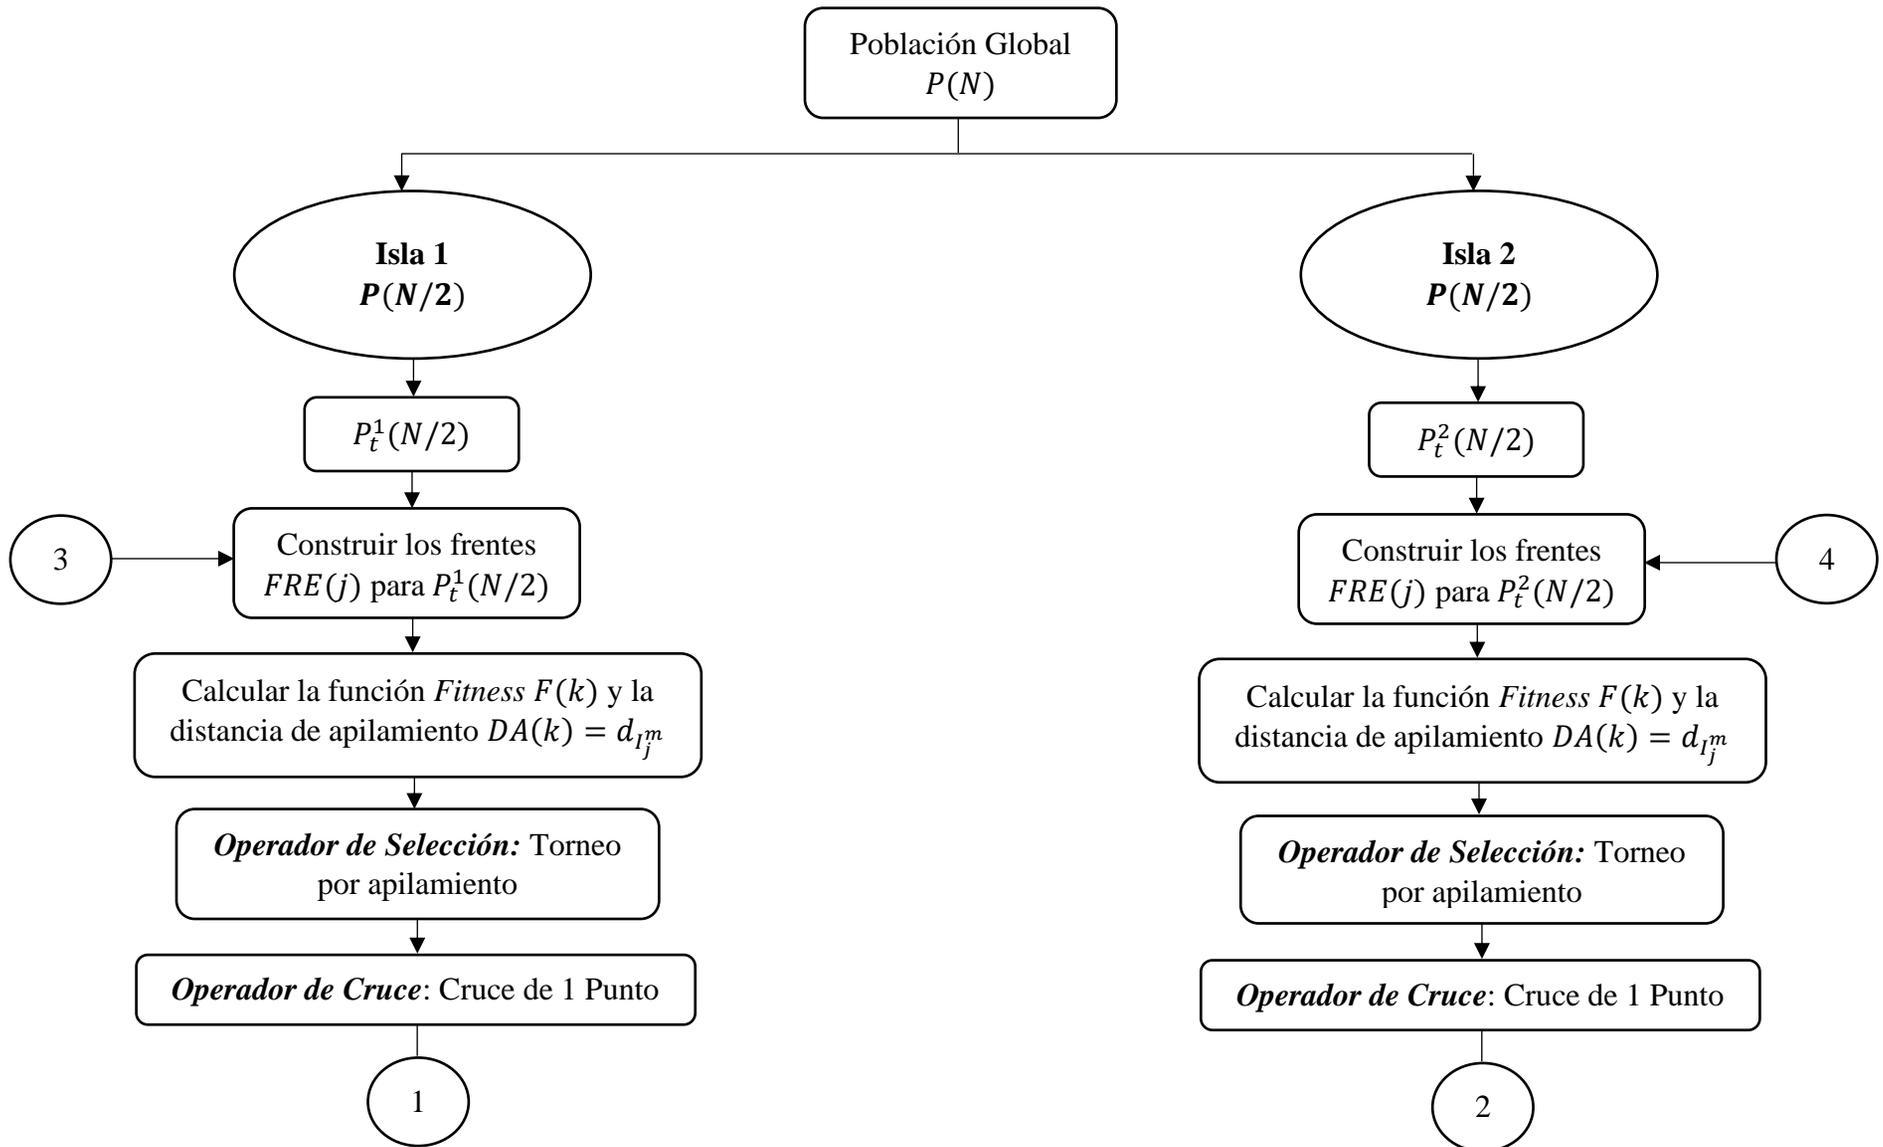
8.1.1.1. Política de funcionamiento.

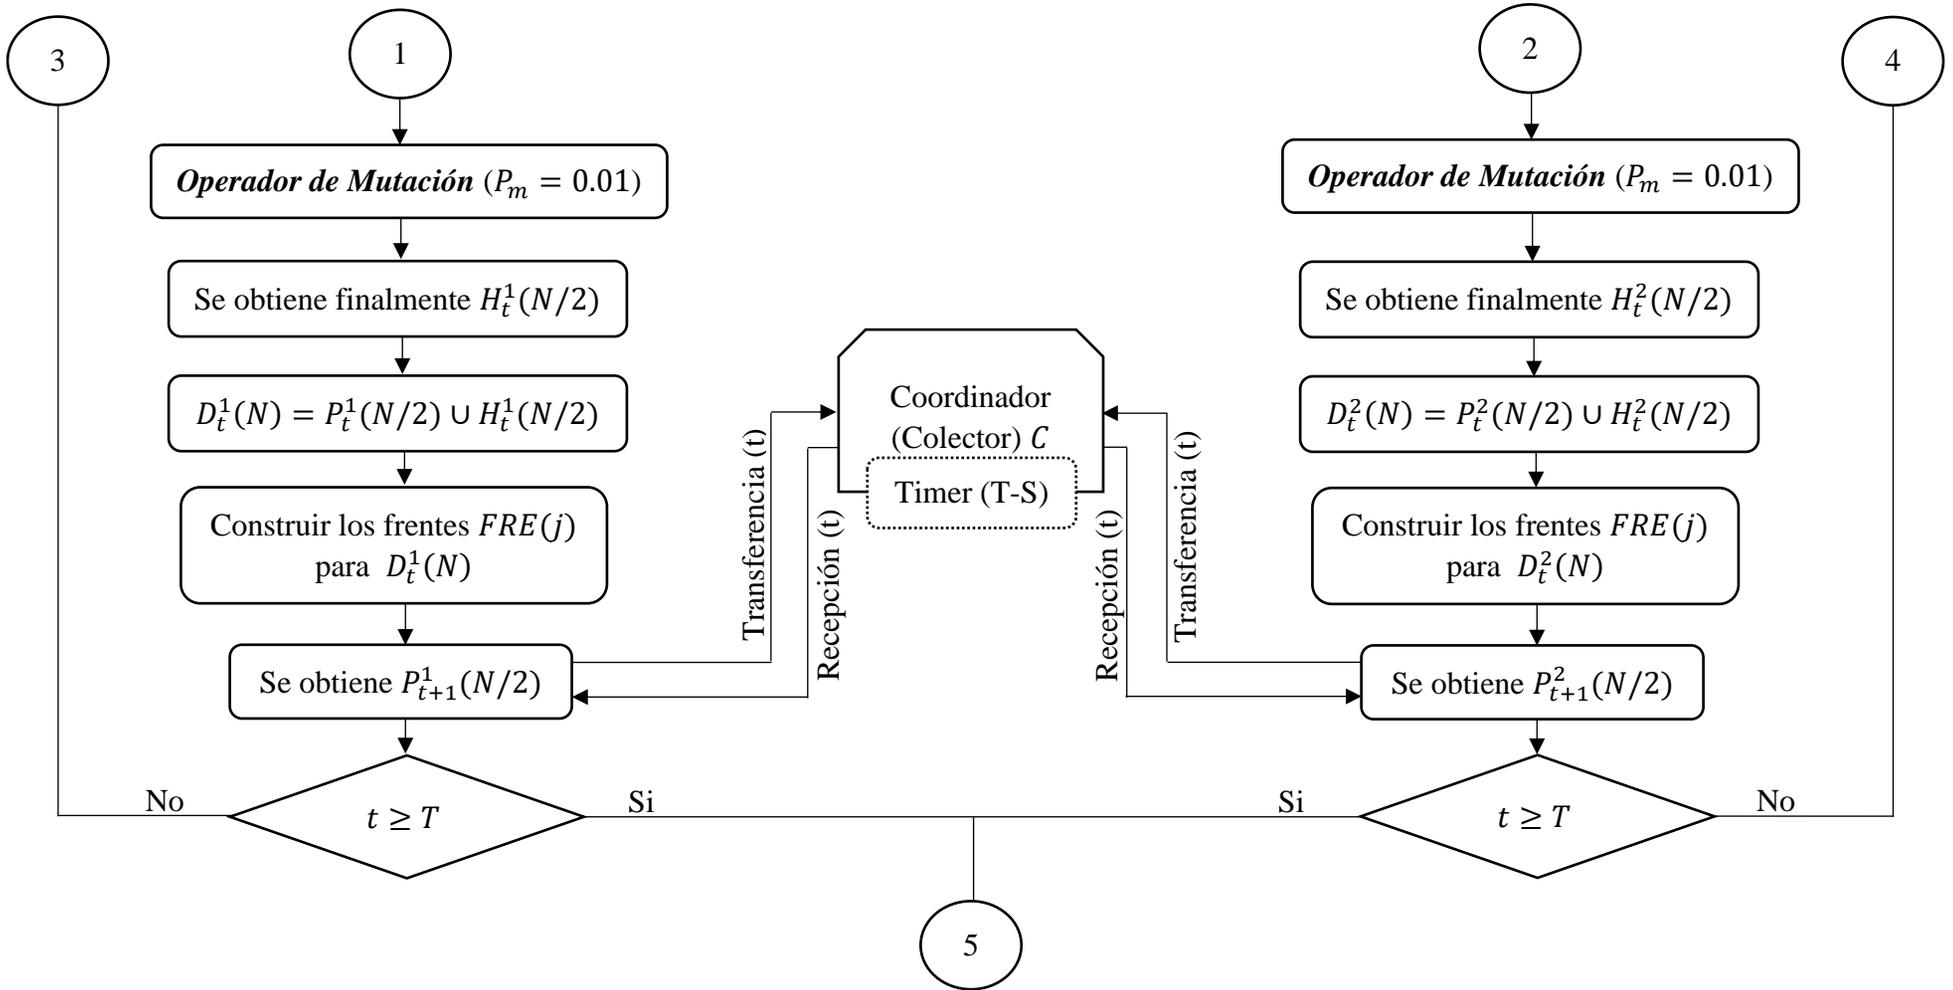
El modelo de islas requiere la selección de *políticas de migración*, que señalen las siguientes características:

- **Forma en que los individuos migrarán:** Utilizando un elemento externo a las islas, llamado coordinador o colector C , el cual cumple la función de ser el mediador en la transferencia de información genética que llega de cada una de estas. Por otro lado, se encarga de identificar y almacenar el mejor individuo k^* compartido en el periodo o generación t .
- **Número de migrantes:** $Parte - Entera_Superior \left(10\% * \frac{N}{2} \right)$, donde N representa el tamaño de la población, la cual es constante durante todo el procedimiento algorítmico.
- **Frecuencia de migración:** Cada periodo t .
- **De dónde se seleccionarán los elementos a migrar:** Los mejores individuos equivalentes a la $Parte - Entera_Superior \left(7\% * \frac{N}{2} \right)$ y los peores individuos obtenidos de la $Parte - Entera_Superior \left(3\% * \frac{N}{2} \right)$.
- **Cómo se realizará el reemplazo de los elementos en una población, por los migrantes provenientes de otras poblaciones:** El ingreso de la información genética (migrantes), consistirá en seleccionar aleatoriamente la cantidad de individuos equivalentes de la nueva población $t + 1$ en la isla $i \langle P_{t+1}^i \rangle$, los cuales cederán su lugar a los nuevos individuos transferidos.
- **Momento exacto de la transferencia y la recepción:** Se realizará cuando cada isla i obtenga la nueva población $\langle P_{t+1}^i(N/2) \rangle$.

- **Algoritmos a utilizar en cada una de las diferentes islas:** Algoritmo Genético (Genetic Algorithm, GA), con parámetros (tamaño de la población “ N ”, número de generaciones “ T ” y probabilidad de mutación “ P_m ”) similares de inicialización.

8.2. Diagrama de Flujo para el *p*-NSGA-II_V1





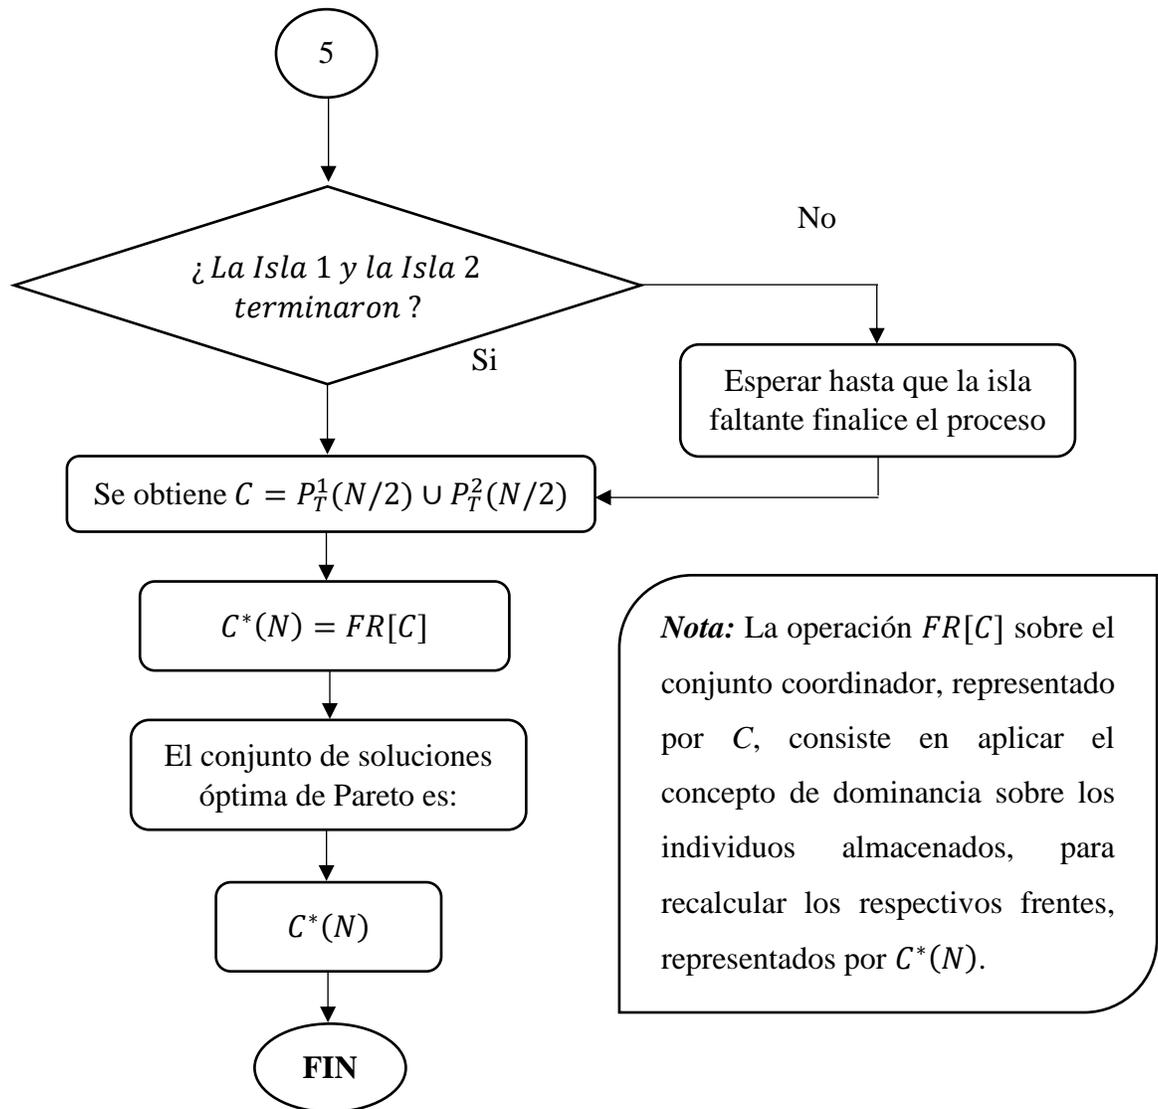


Figura 20. Estructura paralela y cooperativa del p -NSGA-II_V1 con operación asincrónica.

8.2.1. Análisis del coordinador en el p -NSGA-II_V1

8.2.1.1. Política de funcionamiento

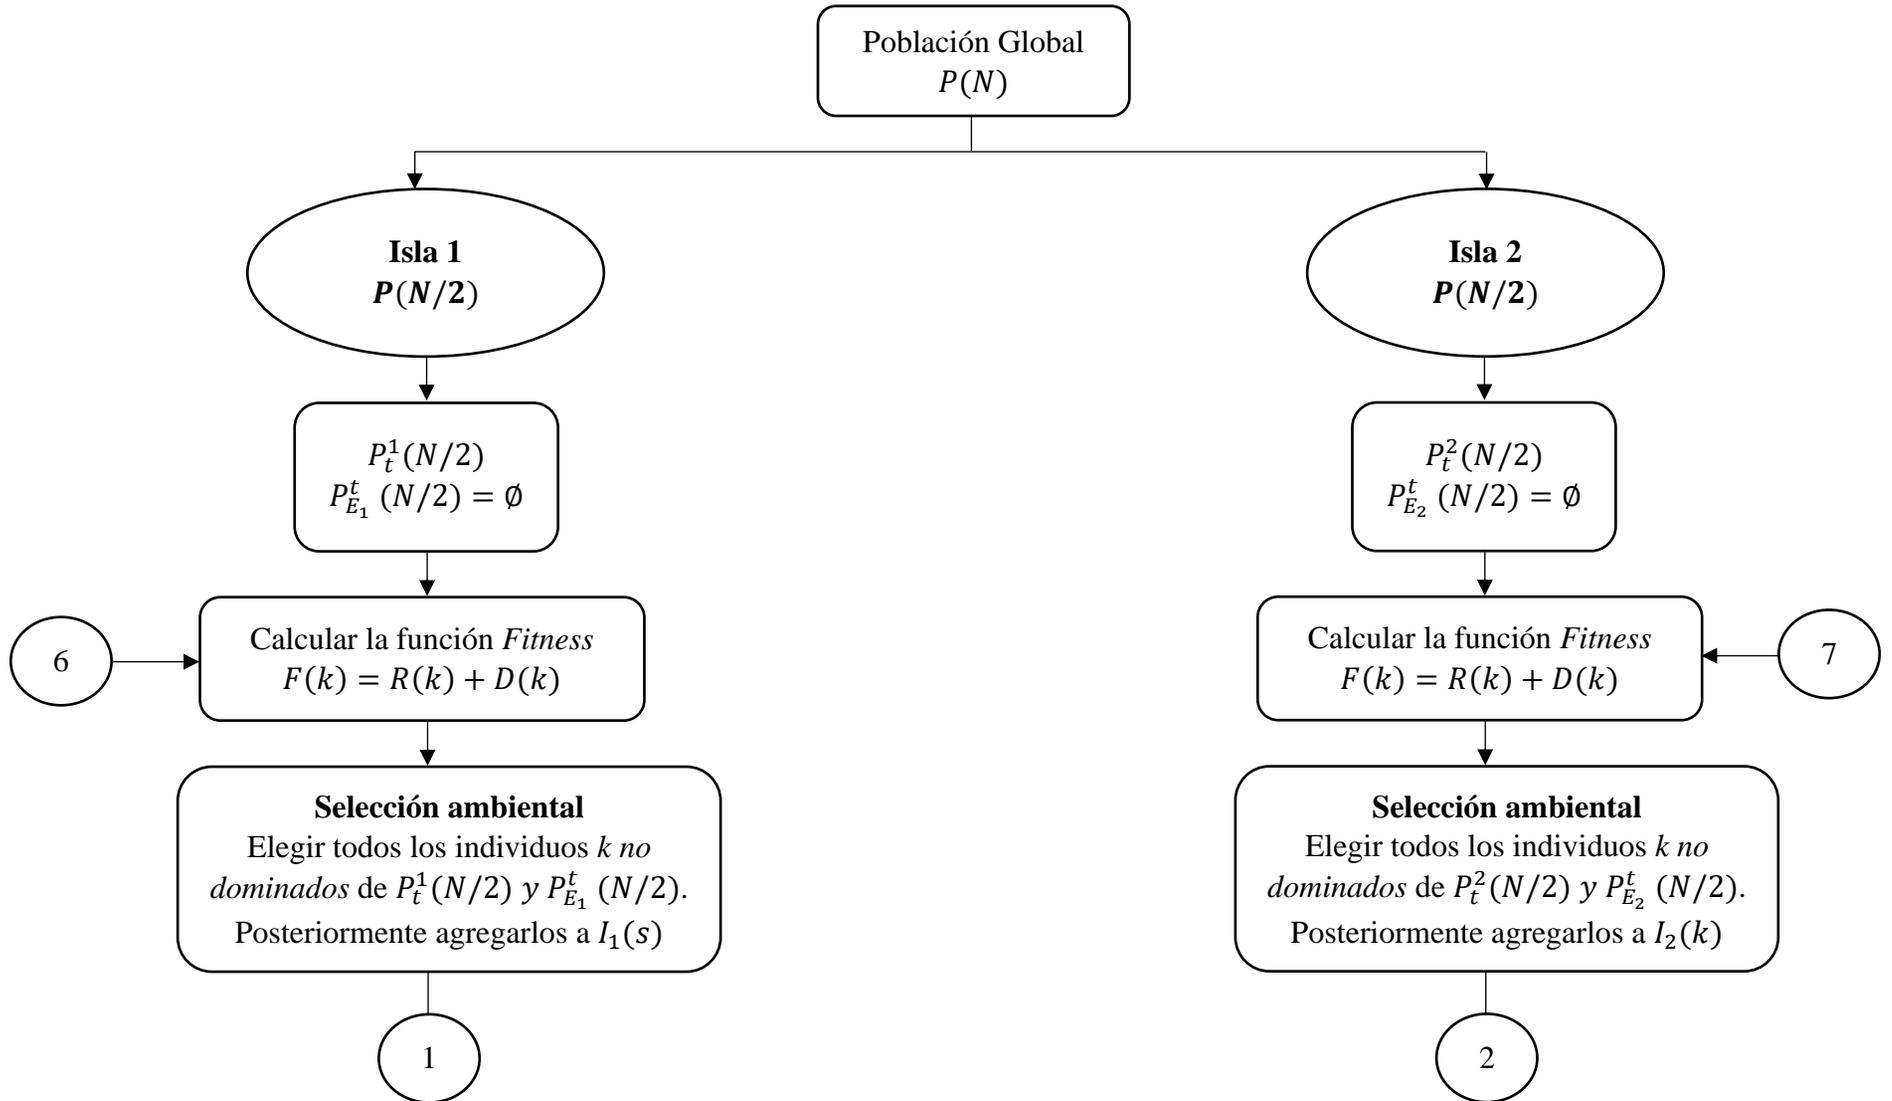
El modelo de islas requiere la selección de *políticas de migración*, que señalen las siguientes características:

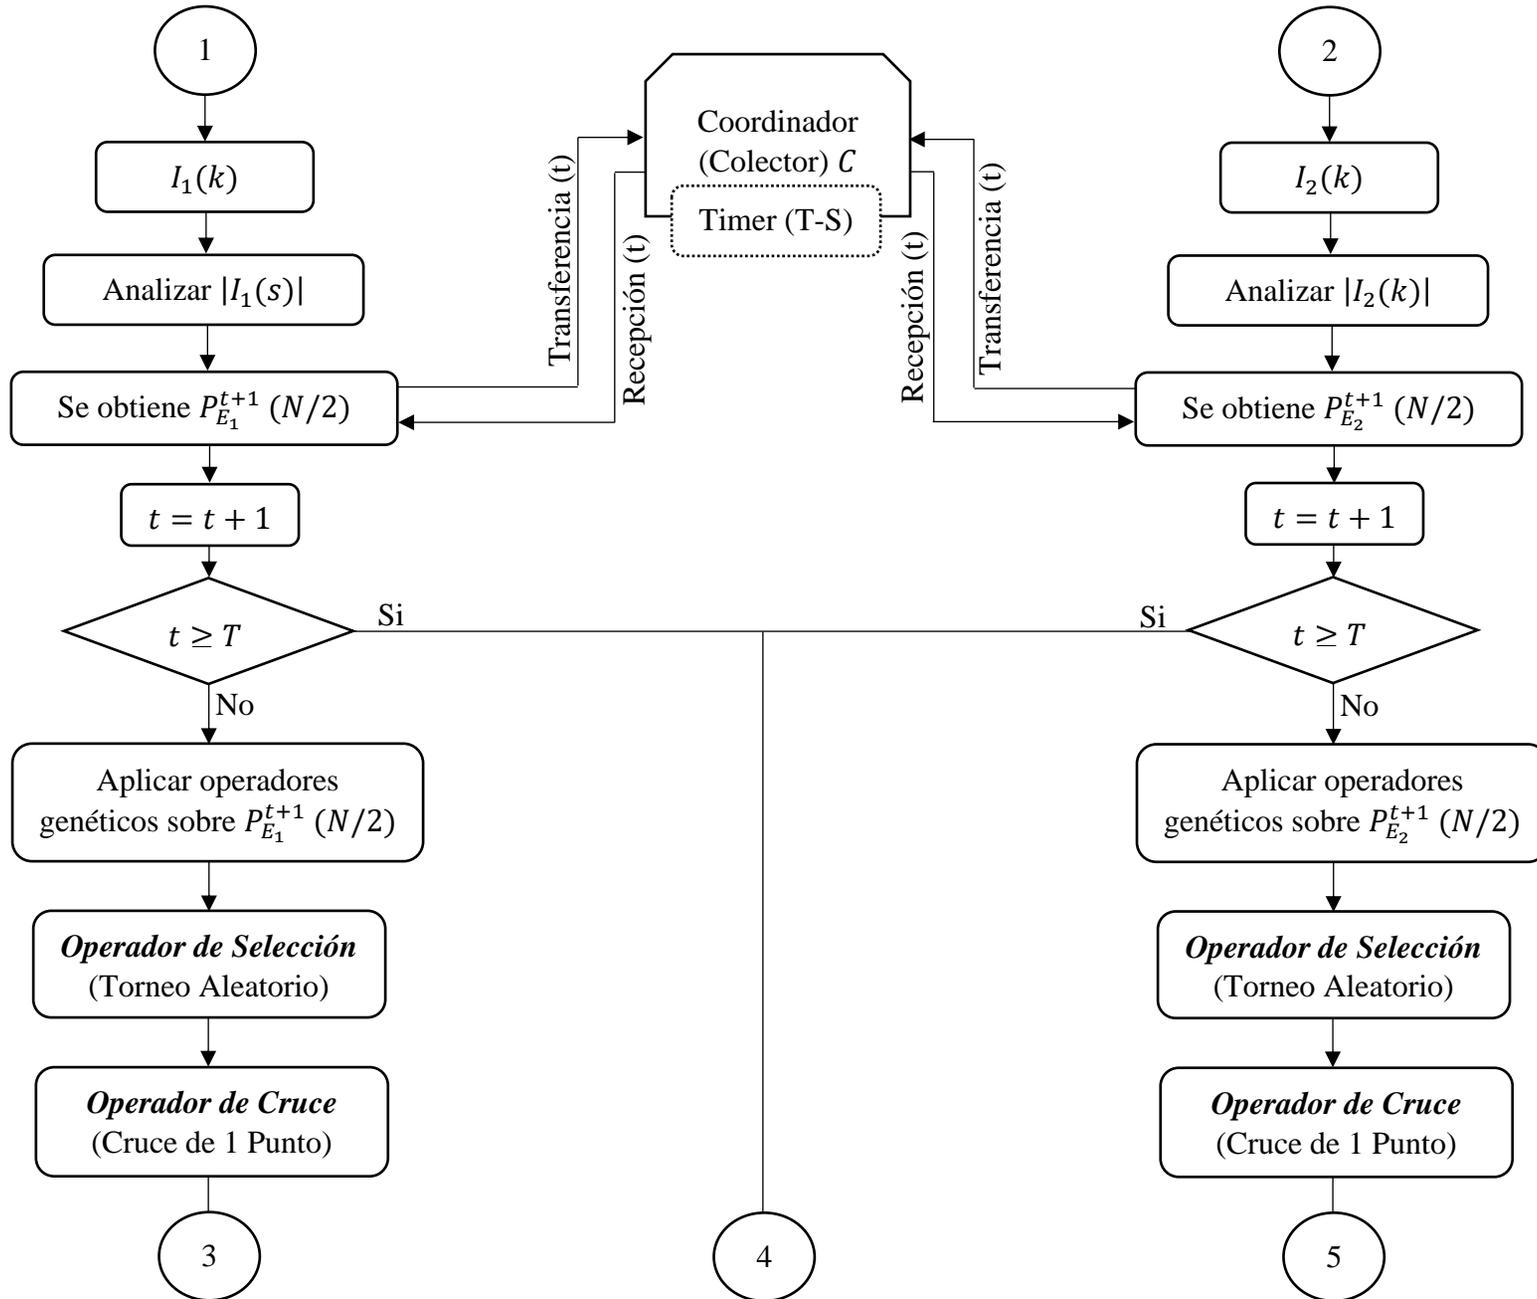
- **Forma en que los individuos migrarán:** Utilizando un elemento externo a las islas, llamado coordinador o colector C , el cual cumple la función de ser el mediador (puente) en la transferencia de información genética que debe ser compartida. Por otro lado, se encarga

de almacenar los mejores frentes F^* compartidos en el periodo t e identificar una vez se cumple el criterio de parada (T –Número máximo de generaciones o iteraciones), los N primeros individuos según los frentes establecidos.

- **Número de migrantes:** *Parte – Entera_Superior* $\left(10\% * \frac{N}{2}\right)$, donde N representa el tamaño de la población, la cual es constante durante todo el procedimiento algorítmico.
- **Frecuencia de migración:** Cada periodo o generación t
- **De dónde se seleccionarán los elementos a migrar:** Los individuos que pertenecen al mejor frente (F_i^*) hallado en cada generación t e isla i , con cardinalidad menor o igual a la *Parte – Entera_Superior* $\left(10\% * \frac{N}{2}\right)$.
- **Cómo se realizará el reemplazo de los elementos en una población, por los migrantes provenientes de otras poblaciones:** El ingreso de la información genética (migrantes), consistirá en seleccionar aleatoriamente la cantidad de individuos equivalentes de la población $t + 1$ en la isla i $\langle P_{t+1}^i(N/2) \rangle$, los cuales cederán su lugar a los nuevos individuos transferidos, siempre y cuando estos no sean dominados.
- **Momento exacto de la transferencia y recepción:** Se realizará cuando cada isla i obtenga la nueva población $\langle P_{t+1}^i(N/2) \rangle$.
- **Algoritmos a utilizar en cada una de las diferentes islas:** Algoritmo Genético de ordenamiento no dominado versión II (Non-dominated Sorting Genetic Algorithm, NSGA-II).

8.3. Diagrama de Flujo para el *p*-SPEA-II_V1





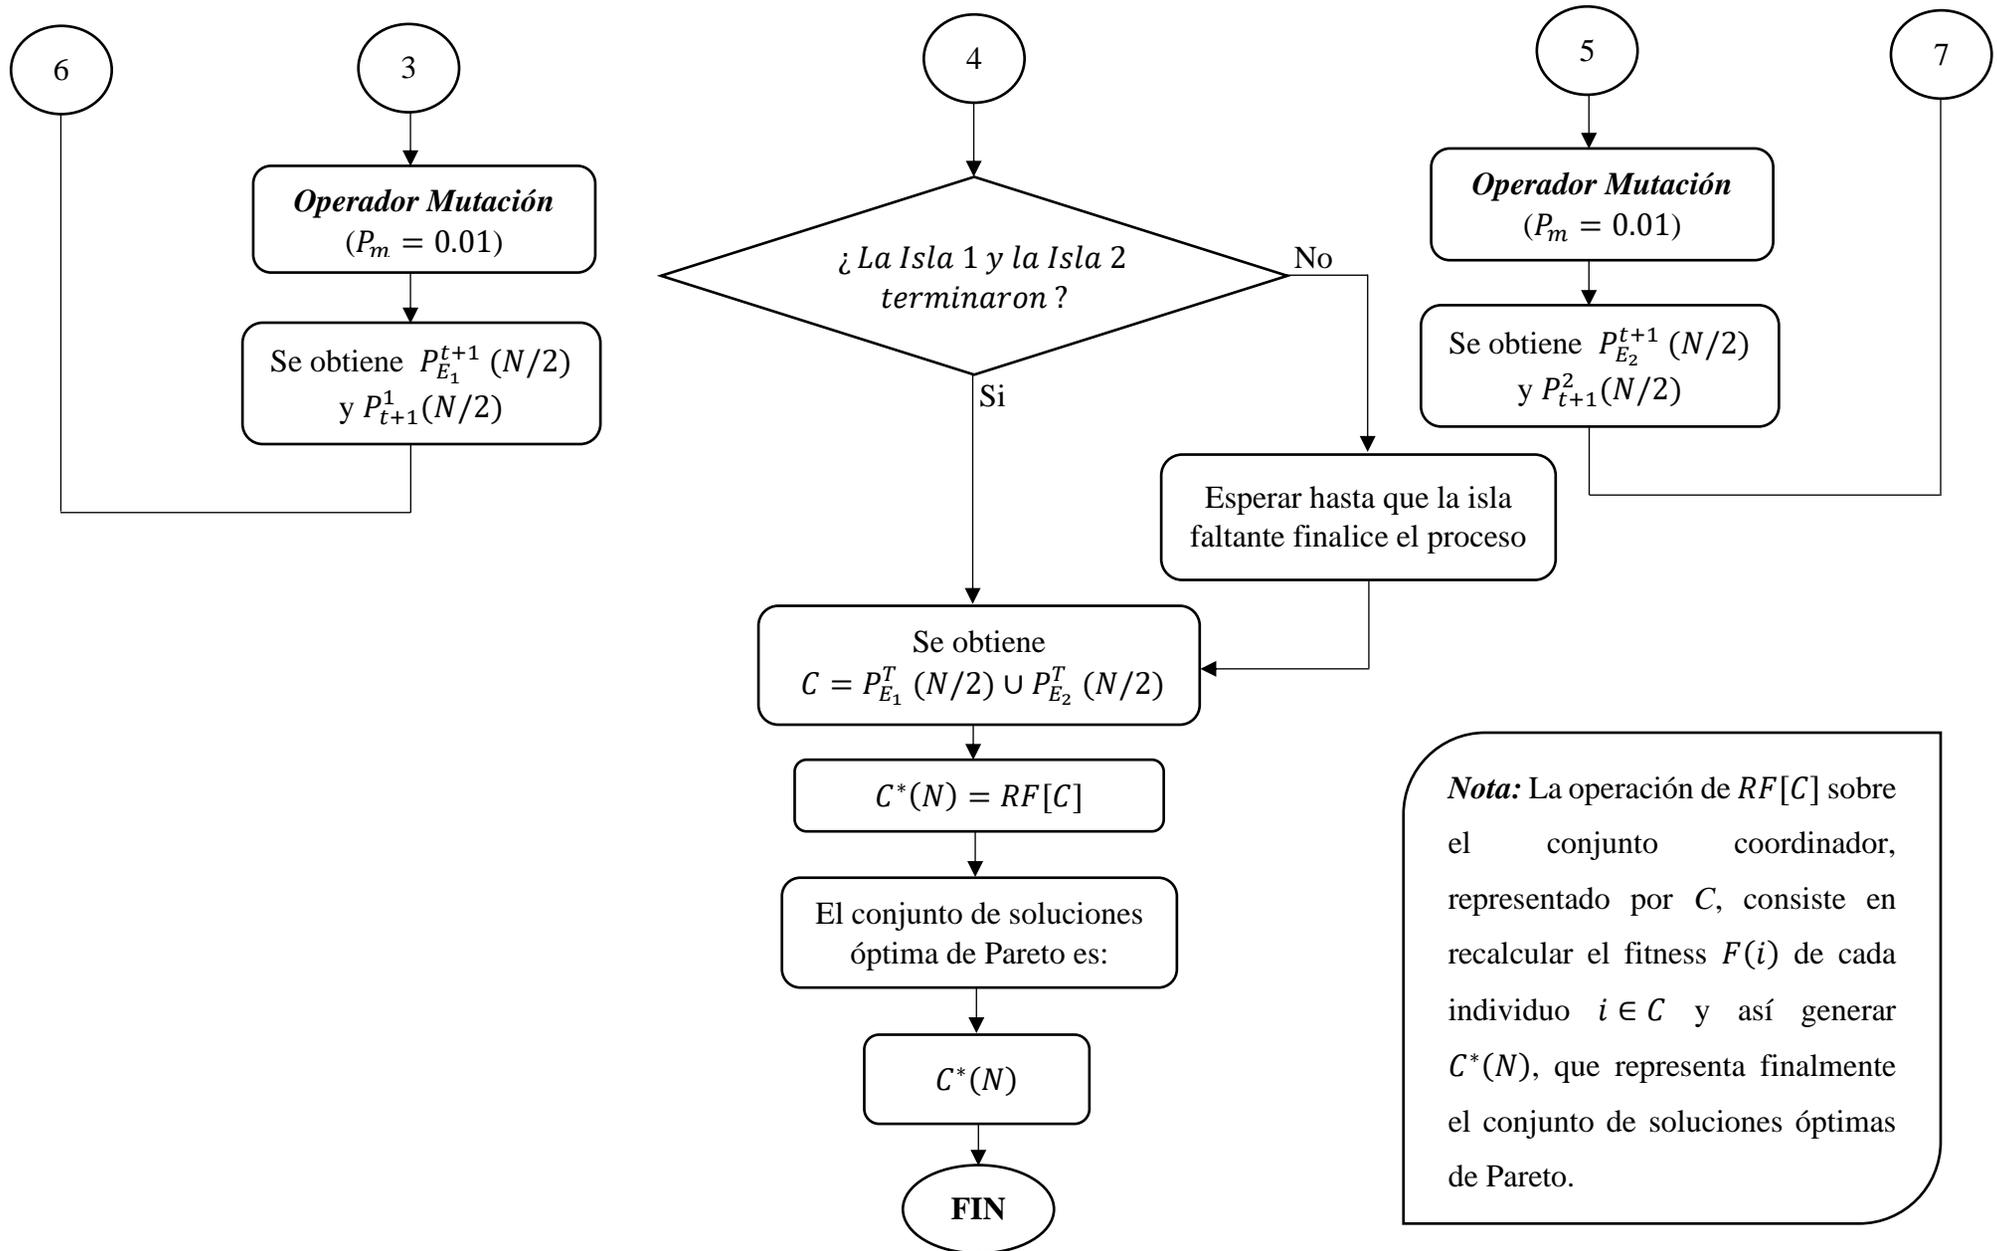


Figura 21. Estructura paralela y cooperativa del p-SPEA-II_V1 con operación asincrónica.

8.3.1. Análisis del coordinador en el p-SPEA-II_VI

8.3.1.1. Política de funcionamiento

El modelo de islas requiere la selección de *políticas de migración*, que señalen las siguientes características:

- **Forma en que los individuos migrarán:** Utilizando un elemento externo a las islas, llamado coordinador o colector C , el cual cumple la función de ser el mediador (puente) en la transferencia de información genética que debe ser compartida. Por otro lado, se encarga de almacenar los mejores individuos k *compartidos en el periodo t e identificar una vez se cumple el criterio de parada (T –Número máximo de generaciones o iteraciones), las N primeras soluciones de acuerdo a las condiciones establecidas en el algoritmo.
- **Número de migrantes:** *Parte – Entera_Superior* $\left(10\% * \frac{N}{2}\right)$, donde N representa el tamaño de la población, la cual es constante durante todo el procedimiento algorítmico.
- **Frecuencia de migración:** Cada periodo o generación t
- **De dónde se seleccionarán los elementos a migrar:** Conjunto de individuos no dominados $\langle F(k) \leq 1 \rangle$, que se hallan en cada generación t e isla i , con cardinalidad menor o igual a la *Parte – Entera_Superior* $\left(10\% * \frac{N}{2}\right)$.
- **Cómo se realizará el reemplazo de los elementos en una población, por los migrantes provenientes de otras poblaciones:** El ingreso de la información genética (migrantes), consistirá en seleccionar aleatoriamente la cantidad de individuos equivalentes de la nueva población externa en la isla i $\langle P_{E_i}^{t+1} (N/2) \rangle$, los cuales cederán su lugar a los individuos transferidos.

- **Momento exacto de la transferencia y recepción:** Se realizará cuando cada isla i obtenga la nueva población externa $\langle P_{E_i}^{t+1} (N/2) \rangle$.
- **Algoritmos a utilizar en cada una de las diferentes islas:** Algoritmo Evolutivo de Fuerza de Pareto versión II (Strength Pareto Evolutionary Algorithm, SPEA-II).

9. Validación y Calibración de los Algoritmos Evolutivos

Una vez codificadas las técnicas de solución en el lenguaje de programación Python (*ver Apéndice B*), resulta indispensable validarlas, con el fin de comprobar salidas coherentes, en función del problema abordado y los supuestos establecidos. Para llevar a cabo este procedimiento, fue necesario crear a la medida un conjunto de instancias de prueba (testbed), teniendo en cuenta las diseñadas por Albareda-Sambola et al. (2005) y Prodhon (2006), pues actualmente no existen en la literatura escenarios que sean de fácil adaptación; dichas instancias se encuentran consolidadas en el *Apéndice C*, bajo la nomenclatura presentada en la *Tabla 6*.

Tabla 6.
Conjunto de instancias para la validación de los EA.

Tipo de Instancia	Nomenclatura							Referencia
	C	L	R	W	V	P	T	
1	30	10	7	11	6	8	7	I1_30C-10L-7R-11W-6V-8P-7T
2	50	8	4	10	6	3	4	I2_50C-8L-4R-10W-6V-3P-4T
3	100	20	14	30	22	4	3	I3_100C-20L-14R-30W-22V-4P-3T
4	65	12	9	17	12	2	2	I4_65C-12L-9R-17W-12V-2P-2T
5	26	9	5	10	8	6	3	I5_26C-9L-5R-10W-8V-6P-3T
6	40	12	12	11	7	5	3	I6_40C-12L-12R-11W-7V-5P-3T
7	57	10	12	14	10	11	2	I7_57C-10L-12R-14W-10V-11P-2T
8	32	11	9	14	14	5	5	I8_32C-11L-9R-14W-14V-5P-5T
9	125	8	11	13	9	2	2	I9_125C-8L-11R-13W-9V-2P-2T
10	91	6	7	16	10	3	2	I10_91C-6L-7R-16W-10V-3P-2T
11	75	7	6	9	8	4	4	I11_75C-7L-6R-9W-8V-4P-4T
12	140	5	3	12	11	2	2	I12_140C-5L-3R-12W-11V-2P-2T
13	45	15	10	7	5	7	2	I13_45C-15L-10R-7W-5V-7P-2T
14	60	4	8	8	4	3	4	I14_60C-4L-8R-8W-4V-3P-4T
15	80	7	13	12	8	3	3	I15_80C-7L-13R-12W-8V-3P-3T
16	35	6	7	9	5	4	5	I16_35C-6L-7R-9W-5V-4P-5T
17	70	16	16	13	9	2	3	I17_70C-16L-16R-13W-9V-2P-3T
18	38	5	7	8	10	6	4	I18_38C-5L-7R-8W-10V-6P-4T
19	54	3	10	15	13	5	5	I19_54C-3L-10R-15W-13V-5P-5T
20	28	4	8	10	7	9	6	I20_28C-4L-8R-10W-7V-9P-6T

Nota. C= Número de clientes, L= Centros locales potenciales, R= Centros regionales potenciales, W= Vehículos de segundo escalón, V= Vehículos de primer escalón, P= Productos y T= Periodos de socorro.

Corregido los errores y depurado los códigos, es posible dar paso al proceso de calibración, que consiste en identificar las principales variables influyentes en el rendimiento (calidad de la solución y tiempo computacional) de los algoritmos (GA, p -NSGA-II_V1 y p -SPEA-II_V1); por lo tanto, se decide utilizar un diseño factorial (DOE) 2^k , compuesto por los parámetros propios de los algoritmos evolutivos (factores), es decir, el tamaño de la población (TP), número de generaciones (NG) y probabilidad de mutación (PM); teniendo en cuenta como variables respuesta, la mejor solución encontrada (MS), si la metodología es de tipo mono-objetivo, el número de soluciones no dominadas (SND), para los enfoques multi-objetivo y una variable común a las dos técnicas, el tiempo computacional (TC) requerido. Por otro lado, las configuraciones establecidas para este experimento, se encuentran plasmadas en la *Tabla 7* y *Tabla 8*, donde los niveles o tratamientos, se eligieron con base a la experimentación y la revisión de estudios previos.

Tabla 7.

Diseño factorial para las técnicas mono-objetivo.

Factores	Niveles	
	Bajo (-)	Alto (+)
TP	100	200
NG	150	300
PM	0,05	0,10

Tabla 8.

Diseño factorial para las técnicas multi-objetivo.

Factores	Niveles	
	Bajo (-)	Alto (+)
TP	240	480
NG	50	100
PM	0,05	0,10

Es importante mencionar que las pruebas fueron realizadas en un computador portátil, con procesador Core i5-1035G4, memoria RAM de 8 GB y disco duro en estado sólido, utilizando un total de 5 réplicas para cada una de las combinaciones posibles de los niveles que poseen los

factores principales; además, las hipótesis de significancia para las variables MS y SND, fueron contrastadas bajo un nivel de confianza equivalente al 80% y para el caso del TC, se tuvo en cuenta un nivel igual al 95%.

Luego de aplicar el testbed sobre las técnicas desarrolladas (ver *Apéndice D*) y comprobar que los resultados obtenidos a través del DOE son válidos (ver *Apéndice E*), se construye la *Tabla 9-16*, mostradas a continuación, con el objetivo de resumir los aspectos fundamentales del experimento realizado, especialmente, aquellos relacionados con el grado de influencia (ANOVA) que poseen los factores establecidos y sus posibles interacciones en la eficiencia algorítmica.

Tabla 9.
Resumen DOE para el GA (MS).

Instancia	Variable respuesta: MS - Significancia de las fuentes ($\alpha = 0,20$)							Factor/interacción de mayor importancia	Combinación de factores que genera la mejor respuesta en la instancia
	Efectos principales			Interacción de dos términos			Interacción de tres términos		
	TP	NG	PM	TP*NG	TP*PM	NG*PM	TP*NG*PM		
I1	x	x						NG y TP	TP(200) + NG(300) + PM(0,05)
I2	x							TP	TP(200) + NG(300) + PM(0,05)
I3	x							TP	TP(200) + NG(300) + PM(0,10)
I4	x	x						TP	TP(200) + NG(300) + PM(0,05)
I5	x	x				x		TP	TP(200) + NG(300) + PM(0,05)
I6	x	x			x			NG	TP(200) + NG(300) + PM(0,10)
I7	x	x		x		x	x	NG	TP(200) + NG(300) + PM(0,10)
I8	x	x						TP	TP(200) + NG(300) + PM(0,10)
I9	x	x						NG	TP(200) + NG(300) + PM(0,10)
I10	x							TP	TP(200) + NG(150) + PM(0,05)
I11	x			x	x		x	TP*NG*PM	TP(200) + NG(150) + PM(0,10)
I12						x	x	TP*NG*PM	TP(100) + NG(150) + PM(0,05)
I13	x	x						TP	TP(200) + NG(300) + PM(0,10)
I14	x	x	x					TP	TP(200) + NG(300) + PM(0,10)
I15	x	x	x	x	x			TP y PM	TP(200) + NG(300) + PM(0,05)
I16	x	x	x		x	x	x	TP	TP(200) + NG(300) + PM(0,10)
I17	x						x	TP	TP(200) + NG(150) + PM(0,10)
I18		x	x				x	NG	TP(100) + NG(300) + PM(0,10)
I19	x		x			x	x	TP y PM	TP(200) + NG(300) + PM(0,05)
I20	x	x					x	NG	TP(200) + NG(300) + PM(0,05)

Nota. Adaptado del software estadístico Minitab 19.

Tabla 10.
Resumen DOE para el GA (TC).

Instancia	Variable respuesta: TC - Significancia de las fuentes ($\alpha = 0,05$)							Factor/interacción de mayor importancia	Combinación de factores que genera la mejor respuesta en la instancia
	Efectos principales			Interacción de dos términos			Interacción de tres términos		
	TP	NG	PM	TP*NG	TP*PM	NG*PM	TP*NG*PM		
I1	x	x	x	x				NG y TP	TP(100) + NG(150) + PM(0,10)
I2	x	x	x	x				TP y NG	TP(100) + NG(150) + PM(0,05)
I3	x	x	x	x	x	x	x	NG y TP	TP(100) + NG(150) + PM(0,10)
I4	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,05)
I5	x	x	x	x	x	x	x	TP y NG	TP(100) + NG(150) + PM(0,05)
I6	x	x	x	x	x	x	x	TP y NG	TP(100) + NG(150) + PM(0,10)
I7	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,10)
I8	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,10)
I9	x	x	x	x	x	x	x	NG y TP	TP(100) + NG(150) + PM(0,10)
I10	x	x	x	x	x	x	x	TP y NG	TP(100) + NG(150) + PM(0,05)
I11	x	x	x	x	x	x	x	TP y NG	TP(100) + NG(150) + PM(0,10)
I12	x	x	x	x	x	x	x	TP y NG	TP(100) + NG(150) + PM(0,10)
I13	x	x	x	x	x	x		TP	TP(100) + NG(150) + PM(0,05)
I14	x	x	x	x	x			NG y TP	TP(100) + NG(150) + PM(0,05)
I15	x	x	x	x	x		x	TP	TP(100) + NG(150) + PM(0,10)
I16	x	x		x	x	x	x	TP y NG	TP(100) + NG(150) + PM(0,05)
I17	x	x	x	x	x	x		NG	TP(100) + NG(150) + PM(0,05)
I18	x	x	x	x		x		TP y NG	TP(100) + NG(150) + PM(0,05)
I19	x	x	x	x	x	x	x	TP y NG	TP(100) + NG(150) + PM(0,05)
I20	x	x	x	x	x	x	x	NG y TP	TP(100) + NG(150) + PM(0,10)

Nota. Adaptado del software estadístico Minitab 19.

Tabla 11.
Resumen DOE para el p-GA_VI (MS).

Instancia	Variable respuesta: MS - Significancia de las fuentes ($\alpha = 0,20$)						Factor/interacción de mayor importancia	Combinación de factores que genera la mejor respuesta en la instancia	
	Efectos principales			Interacción de dos términos					Interacción de tres términos
	TP	NG	PM	TP*NG	TP*PM	NG*PM			TP*NG*PM
I1	x							TP	TP(200) + NG(300) + PM(0,10)
I2	x			x	x	x		TP*NG	TP(200) + NG(300) + PM(0,10)
I3	x							TP	TP(200) + NG(300) + PM(0,10)
I4		x			x		x	TP*NG*PM	TP(200) + NG(300) + PM(0,10)
I5	x			x				TP*NG	TP(200) + NG(150) + PM(0,10)
I6	x				x			TP	TP(200) + NG(300) + PM(0,10)
I7	x							TP	TP(200) + NG(150) + PM(0,10)
I8						x		NG*PM	TP(200) + NG(300) + PM(0,05)
I9	x		x					TP	TP(200) + NG(300) + PM(0,10)
I10	x							TP	TP(200) + NG(300) + PM(0,10)
I11		x					x	NG	TP(200) + NG(300) + PM(0,05)
I12	x			x				TP	TP(200) + NG(150) + PM(0,05)
I13	x	x				x		TP	TP(200) + NG(300) + PM(0,05)
I14				x		x		TP*NG	TP(200) + NG(300) + PM(0,05)
I15	x		x	x				TP	TP(200) + NG(300) + PM(0,05)
I16	x			x			x	TP*NG*PM	TP(100) + NG(300) + PM(0,10)
I17									
I18	x				x			TP	TP(200) + NG(150) + PM(0,05)
I19									
I20		x			x			NG	TP(200) + NG(300) + PM(0,10)

Nota. Adaptado del software estadístico Minitab 19.

Tabla 12.

Resumen DOE para el p-GA_VI (TC).

Instancia	Variable respuesta: TC - Significancia de las fuentes ($\alpha = 0,05$)							Factor/interacción de mayor importancia	Combinación de factores que genera la mejor respuesta en la instancia
	Efectos principales			Interacción de dos términos			Interacción de tres términos		
	TP	NG	PM	TP*NG	TP*PM	NG*PM	TP*NG*PM		
I1	x	x		x		x	x	NG	TP(100) + NG(150) + PM(0,05)
I2	x	x	x	x	x	x	x	NG	TP(100) + NG(150) + PM(0,10)
I3	x	x	x	x	x	x		NG	TP(100) + NG(150) + PM(0,10)
I4	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,05)
I5	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,10)
I6	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,10)
I7	x	x		x	x	x		TP	TP(100) + NG(150) + PM(0,10)
I8	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,05)
I9	x	x	x	x	x	x		NG y TP	TP(100) + NG(150) + PM(0,10)
I10	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,05)
I11	x	x	x	x	x	x	x	NG y TP	TP(100) + NG(150) + PM(0,10)
I12	x	x	x	x			x	TP	TP(100) + NG(150) + PM(0,05)
I13	x	x	x	x	x		x	TP	TP(100) + NG(150) + PM(0,10)
I14	x	x	x	x	x	x		NG y TP	TP(100) + NG(150) + PM(0,10)
I15	x	x	x	x	x	x	x	NG y TP	TP(100) + NG(150) + PM(0,10)
I16	x	x	x	x		x		NG y TP	TP(100) + NG(150) + PM(0,05)
I17	x	x	x	x	x	x	x	NG	TP(100) + NG(150) + PM(0,05)
I18	x	x	x	x		x		TP	TP(100) + NG(150) + PM(0,05)
I19	x	x	x	x	x	x		TP y NG	TP(100) + NG(150) + PM(0,05)
I20	x	x	x	x	x	x	x	TP	TP(100) + NG(150) + PM(0,05)

Nota. Adaptado del software estadístico Minitab 19.

Tabla 13.*Resumen DOE para el p-NSGA-II_V1 (SND).*

Instancia	Variable respuesta: SND - Significancia de las fuentes ($\alpha = 0,20$)						Factor/interacción de mayor importancia	Combinación de factores que genera la mejor respuesta en la instancia	
	Efectos principales			Interacción de dos términos					Interacción de tres términos
	TP	NG	PM	TP*NG	TP*PM	NG*PM			TP*NG*PM
I1		x	x					NG	TP(240) + NG(50) + PM(0,10)
I2				x		x		TP*NG	TP(480) + NG(100) + PM(0,05)
I3		x			x			TP*PM	TP(480) + NG(50) + PM(0,10)
I4		x	x					NG	TP(480) + NG(50) + PM(0,10)
I5			x					PM	TP(480) + NG(100) + PM(0,10)
I6	x							TP	TP(480) + NG(100) + PM(0,05)
I7		x						NG	TP(480) + NG(50) + PM(0,05)
I8		x						NG	TP(480) + NG(50) + PM(0,10)
I9		x				x		NG	TP(480) + NG(50) + PM(0,05)
I10			x			x	x	TP*NG*PM	TP(240) + NG(50) + PM(0,05)
I11			x					PM	TP(240) + NG(100) + PM(0,10)
I12	x							TP	TP(480) + NG(100) + PM(0,05)
I13		x						NG	TP(480) + NG(50) + PM(0,10)
I14				x		x		NG*PM	TP(240) + NG(50) + PM(0,05)
I15	x	x		x				TP	TP(480) + NG(50) + PM(0,10)
I16									
I17			x	x				TP*NG	TP(240) + NG(50) + PM(0,05)
I18	x		x		x			TP*PM	TP(480) + NG(50) + PM(0,05)
I19		x			x			NG	TP(240) + NG(50) + PM(0,10)
I20				x				TP*NG	TP(240) + NG(50) + PM(0,10)

Nota. Adaptado del software estadístico Minitab 19.

Tabla 14.*Resumen DOE para el p-NSGA-II_V1 (TC).*

Instancia	Variable respuesta: TC - Significancia de las fuentes ($\alpha = 0,05$)							Factor/interacción de mayor importancia	Combinación de factores que genera la mejor respuesta en la instancia
	Efectos principales			Interacción de dos términos			Interacción de tres términos		
	TP	NG	PM	TP*NG	TP*PM	NG*PM	TP*NG*PM		
I1	x	x		x	x			TP	TP(240) + NG(50) + PM(0,05)
I2	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,05)
I3	x	x		x	x			TP	TP(240) + NG(50) + PM(0,10)
I4	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I5	x	x	x	x	x	x		NG	TP(240) + NG(50) + PM(0,05)
I6	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,05)
I7	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I8	x	x	x	x	x	x		TP	TP(240) + NG(50) + PM(0,05)
I9	x	x		x			x	TP	TP(240) + NG(50) + PM(0,05)
I10	x	x	x	x		x		TP	TP(240) + NG(50) + PM(0,05)
I11	x	x		x				TP y NG	TP(240) + NG(50) + PM(0,05)
I12	x	x	x	x	x			TP	TP(240) + NG(50) + PM(0,10)
I13	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,05)
I14	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,05)
I15	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,05)
I16	x	x	x	x	x	x		TP	TP(240) + NG(50) + PM(0,10)
I17	x	x	x	x				TP	TP(240) + NG(50) + PM(0,05)
I18	x	x	x	x			x	TP	TP(240) + NG(50) + PM(0,05)
I19	x	x		x	x	x		TP	TP(240) + NG(50) + PM(0,05)
I20	x	x		x	x		x	TP	TP(240) + NG(50) + PM(0,05)

Nota. Adaptado del software estadístico Minitab 19.

Tabla 15.*Resumen DOE para el p-SPEA-II_V1 (SND).*

Instancia	Variable respuesta: SND - Significancia de las fuentes ($\alpha = 0,20$)						Factor/interacción de mayor importancia	Combinación de factores que genera la mejor respuesta en la instancia		
	Efectos principales			Interacción de dos términos					Interacción de tres términos	
	TP	NG	PM	TP*NG	TP*PM	NG*PM			TP*NG*PM	
I1							x	TP*NG*PM	TP(240) + NG(50) + PM(0,10)	
I2			x					x	TP*NG*PM	TP(240) + NG(50) + PM(0,05)
I3										
I4				x					TP*NG	TP(480) + NG(50) + PM(0,05)
I5	x			x	x				TP	TP(480) + NG(100) + PM(0,10)
I6	x					x			TP	TP(480) + NG(100) + PM(0,05)
I7	x	x			x				TP*PM	TP(480) + NG(50) + PM(0,10)
I8						x	x		TP*NG*PM	TP(240) + NG(100) + PM(0,10)
I9					x				TP*PM	TP(480) + NG(50) + PM(0,10)
I10										
I11	x				x				TP	TP(480) + NG(100) + PM(0,05)
I12	x								TP	TP(480) + NG(100) + PM(0,05)
I13	x	x							TP	TP(480) + NG(50) + PM(0,10)
I14										
I15	x	x							TP	TP(480) + NG(50) + PM(0,05)
I16	x			x					TP*NG	TP(480) + NG(100) + PM(0,10)
I17				x	x				TP*NG y TP*PM	TP(480) + NG(50) + PM(0,10)
I18	x						x		TP	TP(480) + NG(100) + PM(0,05)
I19	x								TP	TP(480) + NG(100) + PM(0,10)
I20	x					x			TP	TP(480) + NG(100) + PM(0,10)

Nota. Adaptado del software estadístico Minitab 19.

Tabla 16.*Resumen DOE para el p-SPEA-II_VI (TC).*

Instancia	Variable respuesta: TC - Significancia de las fuentes ($\alpha = 0,05$)							Factor/interacción de mayor importancia	Combinación de factores que genera la mejor respuesta en la instancia
	Efectos principales			Interacción de dos términos			Interacción de tres términos		
	TP	NG	PM	TP*NG	TP*PM	NG*PM	TP*NG*PM		
I1	x	x	x	x		x	x	TP	TP(240) + NG(50) + PM(0,10)
I2	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I3	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I4	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,05)
I5	x	x		x		x	x	TP	TP(240) + NG(50) + PM(0,10)
I6	x	x	x	x				TP	TP(240) + NG(50) + PM(0,10)
I7	x	x	x	x	x		x	TP	TP(240) + NG(50) + PM(0,05)
I8	x	x		x	x	x	x	TP	TP(240) + NG(50) + PM(0,05)
I9	x	x		x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I10	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I11	x	x	x	x		x	x	TP	TP(240) + NG(50) + PM(0,10)
I12	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I13	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,05)
I14	x	x		x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I15	x	x	x	x	x	x		TP	TP(240) + NG(50) + PM(0,10)
I16	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I17	x	x	x	x	x	x		TP	TP(240) + NG(50) + PM(0,10)
I18	x	x	x	x	x		x	TP	TP(240) + NG(50) + PM(0,10)
I19	x	x	x	x	x	x	x	TP	TP(240) + NG(50) + PM(0,10)
I20	x	x	x	x	x	x		TP	TP(240) + NG(50) + PM(0,05)

Nota. Adaptado del software estadístico Minitab 19.

9.1. Análisis de Resultados DOE

Con el fin de lograr una adecuada lectura e interpretación de las tablas mostradas anteriormente, es fundamental aclarar que el símbolo “x” señala el factor principal o la interacción respectiva (dos o tres términos) en dicha instancia, estadísticamente significativa, para el nivel de confianza propuesto y en los casos atípicos donde aparece un escenario resaltado en color azul claro, significa que este no tiene validez bajo el nivel de confianza establecido. Asimismo, cabe aclarar que en las pruebas ejecutadas con los enfoques mono-objetivo (GA y p -GA_V1), se asumió un peso (w_1 y w_2) entre funciones de 1 (considerado como valor estándar), pues no existe un método exacto el cual permita hallar una estimación única, evitando así posibles sesgos.

Tomando como referencia la *Tabla 9*, que presenta el análisis de varianza (ANOVA) para los factores evolutivos; es posible inferir con una confianza del 80% que el tamaño de la población (TP) y el número de generaciones (NG), son los dos factores con mayor impacto en la calidad de la solución (MS), pues como se puede apreciar (observaciones por columna), NG afecta el 90% de las instancias probadas, mientras que el TP tiene una presencia del 65%. Esta conclusión es reafirmada al observar el conjunto de factores/interacciones de mayor efecto, donde se puede apreciar nuevamente una dominancia por parte de TP y NG (teniendo en cuenta las interacciones de tres términos); particularmente los niveles TP(200) y NG(300), generan al parecer, los mejores resultados en la mayoría de instancias, cuando se aplica la metaheurística GA. Más aún, al estudiar la *Tabla 10*, asociada con el análisis de la variable TC, puede observarse que no existe una tendencia muy bien marcada de los principales factores, pero al revisar la columna del “factor/interacción” con mayor efecto sobre cada una de las instancias, puede concluirse bajo una confianza equivalente al 95%, que los factores: tamaño de la población (TP) y número de generaciones (NG), poseen la mayor significancia estadística para dicha variable, específicamente,

los niveles TP(100) y NG(150), como se esperaba, permiten obtener soluciones al problema abordado, en el menor tiempo posible.

Por otro lado, la *Tabla 11*, permite visualizar como principal factor de la variable MS al factor TP, quien tiene una presencia del 65% en las instancias ejecutadas con el algoritmo *p-GA_V1*; a diferencia del experimento anterior, el factor NG en este caso, posee un bajo nivel de significancia (análisis por columnas), sin embargo, puede llegar a tener un leve impacto, para combinaciones de dos y tres términos respectivamente. Además, los tratamientos correspondientes a TP(200) y NG(300), ejercen globalmente el mayor impacto sobre los resultados generados y el objetivo establecido (minimizar la función). En cuanto a la *Tabla 12*, asociada con la variable tiempo computacional (TC), es posible concluir nuevamente, bajo una confianza del 95%, que los factores NG y TP, son estadísticamente significativos; especialmente, los niveles TP(100) y NG(150), permiten obtener la mejor combinación.

De acuerdo con lo expuesto hasta el momento, resulta interesante señalar que las configuraciones obtenidas en las variables MS y TC, son totalmente opuestas, es decir, no existe un punto de equilibrio, donde los algoritmos GA y *p-GA_V1* puedan utilizar niveles en común de cada estructura, para obtener buenas soluciones en el menor tiempo posible.

Continuando con el análisis de resultados, la *Tabla 13*, permite evidenciar para un nivel de confianza equivalente al 80%, que los factores NG y las combinaciones de TP para dos y tres términos, poseen el mayor efecto sobre el número de soluciones no dominadas (SND) generadas por el algoritmo *p-NSGA-II_V1*; más aún, la combinación de los niveles TP(480), NG(50) y PM(0,10), permiten en su mayoría, maximizar la respuesta de los escenarios propuestos. En contraste, la *Tabla 14*, que representa el experimento efectuado sobre TC, muestra como el tamaño de la población (TP), es quien posee la principal influencia sobre el tiempo requerido para obtener

un conjunto de soluciones, tomando como punto de contraste una significancia del 5%; además, al observar la última columna, puede señalarse que la mejor combinación (potencial) se genera utilizando los tratamientos TP(240) y NG(50).

En cuanto a la *Tabla 15*, relacionada con la variable SND del algoritmo *p*-SPEA-II_V1, se puede inferir, utilizando un nivel de confianza igual al 80%, que el factor TP, posee el mayor grado de significancia estadística, sin dejar a un lado el número de generaciones (NG), que produce un efecto importante al combinarse con TP y PM respectivamente. Al igual que en el experimento anterior, los niveles TP(480), NG(50) y PM(0,10), permiten obtener tentativamente las mejores respuestas. Por otra parte, la *Tabla 16*, resume el análisis de varianza para la variable TC, permitiendo resaltar a grandes rasgos (confianza del 95%) el factor TP, quien presenta el mayor impacto, junto al número de generaciones (NG), ya que poseen una influencia directa sobre todo el conjunto de prueba. Por lo tanto, la mejor interacción que se puede obtener con el fin de reducir el tiempo de procesamiento algorítmico, estaría formada aproximadamente por los niveles TP(240), NG(50) y PM(0,10).

Es importante mencionar que en el caso de los algoritmos evolutivos con enfoque multi-objetivo, sí existe un punto de convergencia para las variables SND y TC, pues como se puede apreciar, comparten el mismo valor de los tratamientos asociados con los factores NG y PM, resultando un aspecto positivo a la hora de obtener soluciones, bajo una combinación favorable *respuesta-tiempo*.

Con el propósito de elegir la mejor configuración de niveles para los factores evolutivos (parámetros de inicialización) y así permitir salidas adecuadas, teniendo en cuenta el conjunto de instancias probadas sobre cada técnica, se decidió utilizar el optimizador de respuesta que posee Minitab 19 en el apartado: “DOE>Factorial>optimizador”. Una vez ejecutada esta herramienta,

bajo un mismo nivel de importancia entre escenarios de prueba, se obtiene la estructura expuesta en la *Tabla 17*, la cual servirá como punto de partida a la hora de comprobar las hipótesis establecidas en el presente estudio.

Tabla 17.
Combinación óptima de factores asociados con los EA.

Algoritmo	Mejor combinación de tratamientos asociados con la variable respuesta (Optimizador)					
	MS/SND			TC		
	TP	NG	PM	TP	NG	PM
GA	200	300	0,05	100	150	0,10
<i>p</i> -GA_V1	200	300	0,05	100	150	0,10
<i>p</i> -NSGA-II_V1	480	50	0,10	240	50	0,10
<i>p</i> -SPEA-II_V1	480	50	0,10	240	50	0,10

Finalmente, como puede observarse en la *Tabla 17*, ha sido posible cumplir satisfactoriamente con este proceso tan importante que involucra el estudio y análisis del funcionamiento para cada método de solución. En consecuencia, es posible concluir que tanto los enfoques mono-objetivo como multi-objetivo, operan entre sí bajo un mismo esquema de inicialización, lo cual resulta favorable a la hora de comparar sus rendimientos, ya que estarán ejecutándose en las mejores condiciones, permitiendo así observaciones válidas.

10. Comprobación Hipótesis de Investigación

Tomando como referencia la configuración de los parámetros evolutivos obtenidos anteriormente, mediante el diseño factorial, se ejecuta el testbed sobre cada algoritmo, con el propósito de obtener datos suficientes que permitan verificar las afirmaciones preliminares, asociadas al rendimiento; el cual está representado en el caso de las técnicas mono-objetivo, por la variable: mejor solución encontrada (MS) y para los enfoques multi-objetivo, la variable definida como: número de soluciones no nominadas (SND), teniendo en cuenta a su vez, el tiempo computacional (TC). Para llevar a cabo este procedimiento, fue necesario utilizar un tamaño de muestra equivalente a treinta (30) por instancia probada y aplicar el estadístico de prueba t con igualdad de varianzas conjunta, para diferencias entre dos medias (la expresión matemática y los datos muestrales se encuentran en el *Apéndice F*). Más aún, las hipótesis de investigación presentadas en la sección 4, pueden ser representadas de la siguiente manera:

Hipótesis 1

$$H_0: \mu_{p-NSGA-II_V1(I_K)}^{TC} \leq \mu_{p-SPEA-II_V1(I_K)}^{TC} \quad H_0: \mu_{p-NSGA-II_V1(I_K)}^{SND} \leq \mu_{p-SPEA-II_V1(I_K)}^{SND}$$

$$H_1: \mu_{p-NSGA-II_V1(I_K)}^{TC} > \mu_{p-SPEA-II_V1(I_K)}^{TC} \quad H_1: \mu_{p-NSGA-II_V1(I_K)}^{SND} > \mu_{p-SPEA-II_V1(I_K)}^{SND}$$

Hipótesis 2

$$H_0: \mu_{p-GA_V1(I_K)}^{TC} \geq \mu_{GA(I_K)}^{TC} \quad H_0: \mu_{p-GA_V1(I_K)}^{MS} \geq \mu_{GA(I_K)}^{MS}$$

$$H_1: \mu_{p-GA_V1(I_K)}^{TC} < \mu_{GA(I_K)}^{TC} \quad H_1: \mu_{p-GA_V1(I_K)}^{MS} < \mu_{GA(I_K)}^{MS}$$

Donde:

$\mu_{p-NSGA-II(I_K)}^{TC}$ = Media poblacional del tiempo computacional (TC) para el algoritmo p -NSGA-

II_V1 en la instancia I_K

$\mu_{p\text{-NSGA-II}_V1(I_K)}^{SND}$ = Media poblacional correspondiente a la cantidad de soluciones no dominadas (SND) que obtiene el algoritmo $p\text{-NSGA-II}_V1$ en la instancia I_K

$\mu_{p\text{-GA}_V1(I_K)}^{MS}$ = Media poblacional de la mejor solución encontrada por el algoritmo $p\text{-NSGA-II}_V1$ en la instancia I_K

Con ayuda del software estadístico Minitab 19 es posible realizar las pruebas mencionadas anteriormente (ver *Apéndice G*), obteniendo así los resultados mostrados en la *Tabla 18-21*, desarrolladas con el objetivo de facilitar la comprensión e interpretación de los mismos.

10.1. Resultados Hipótesis 1

Tabla 18.

Prueba de hipótesis algoritmos *p-NSGA-II_V1* y *p-SPEA-II_V1* (TC).

Instancia (I_K)	Prueba t de 2 muestras ($\alpha = 0,05$)				Interpretación		
	$\mu_1 = \mu_{p-NSGA-II_V1(I_K)}^{TC} / \mu_2 = \mu_{p-SPEA-II_V1(I_K)}^{TC}$						
	Prueba 1		Prueba 2 (Complementaria)		$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
$H_0: \mu_1 \leq \mu_2$	$H_1: \mu_1 > \mu_2$	$H_0: \mu_1 = \mu_2$	$H_1: \mu_1 \neq \mu_2$				
I1	x			x	x		
I2	x			x	x		
I3	x			x	x		
I4	x			x	x		
I5	x			x	x		
I6	x			x	x		
I7	x			x	x		
I8	x			x	x		
I9	x			x	x		
I10	x			x	x		
I11	x			x	x		
I12	x			x	x		
I13	x			x	x		
I14	x			x	x		
I15	x			x	x		
I16	x			x	x		
I17	x			x	x		
I18	x			x	x		
I19	x			x	x		
I20	x			x	x		

Nota. Adaptado del software estadístico Minitab 19.

Tabla 19.GAP entre los algoritmos *p*-NSGA-II_V1 y *p*-SPEA-II_V1(n = 30).

Instancia	Algoritmo				GAP	
	<i>p</i> -NSGA-II_V1		<i>p</i> -SPEA-II_V1		<i>(p</i> -NSGA-II_V1- <i>p</i> -SPEA-II_V1)	
	SND	TC	SND	TC	SND	TC
I1	6,100	399,550	5,900	477,034	0,200	-77,484
I2	8,567	223,042	8,167	299,973	0,400	-76,932
I3	5,867	348,650	6,967	421,611	-1,100	-72,961
I4	6,633	163,684	8,167	233,694	-1,533	-70,009
I5	8,867	117,551	9,633	188,416	-0,767	-70,865
I6	9,200	188,290	9,200	257,267	0,000	-68,977
I7	5,567	181,082	6,400	252,590	-0,833	-71,507
I8	8,167	230,756	9,600	296,181	-1,433	-65,425
I9	5,200	238,188	6,533	303,023	-1,333	-64,835
I10	8,900	178,006	8,867	250,924	0,033	-72,918
I11	8,533	294,992	8,400	361,875	0,133	-66,883
I12	9,767	211,720	10,800	281,523	-1,033	-69,803
I13	11,100	111,218	12,667	165,437	-1,567	-54,219
I14	6,533	228,217	7,233	271,475	-0,700	-43,258
I15	6,533	259,037	6,200	296,033	0,333	-36,996
I16	9,200	214,804	9,400	265,671	-0,200	-50,867
I17	6,067	263,645	6,500	308,835	-0,433	-45,190
I18	6,400	208,508	7,633	267,172	-1,233	-58,665
I19	6,300	287,443	7,233	348,707	-0,933	-61,264
I20	5,900	242,527	7,533	305,711	-1,633	-63,184

Nota. Los resultados corresponden a un promedio y el tiempo computacional (TC) está dado en segundos.

Tabla 20.
Prueba de hipótesis algoritmos p-NSGA-II_V1 y p-SPEA-II_V1 (SND).

Instancia (I_K)	Prueba t de 2 muestras ($\alpha = 0,05$)				Interpretación		
	$\mu_1 = \mu_{p-NSGA-II_V1(I_K)}^{SND} / \mu_2 = \mu_{p-SPEA-II_V1(I_K)}^{SND}$						
	Prueba 1		Prueba 2 (Complementaria)		$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
	$H_0: \mu_1 \leq \mu_2$	$H_1: \mu_1 > \mu_2$	$H_0: \mu_1 = \mu_2$	$H_1: \mu_1 \neq \mu_2$			
I1	x		x			x	
I2	x		x			x	
I3	x			x	x		
I4	x			x	x		
I5	x		x			x	
I6	x		x			x	
I7	x		x			x	
I8	x			x	x		
I9	x			x	x		
I10	x		x			x	
I11	x		x			x	
I12	x		x			x	
I13	x			x	x		
I14	x		x			x	
I15	x		x			x	
I16	x		x			x	
I17	x		x			x	
I18	x		x			x	
I19	x		x			x	
I20	x			x	x		

Nota. Adaptado del software estadístico Minitab 19.

10.1.1. Análisis prueba *t* de dos muestras (Hipótesis 1)

De acuerdo con la información expuesta en la *Tabla 18*, que presenta un cuadro comparativo de los algoritmos *p*-NSGA-II_V1 y *p*-SPEA-II_V1 en función del tiempo computacional (TC), para un conjunto de 20 instancias de prueba, es posible destacar la superioridad de la técnica *p*-NSGA-II_V1, pues como se logra observar, la media poblacional asociada con el TC resulta estadísticamente inferior en el 100% de los escenarios propuestos (ver columna de interpretación), expresado en otros términos, para cualquier instancia evaluada del conjunto testbed, el algoritmo *p*-NSGA-II_V1 requiere un menor tiempo de ejecución que la técnica *p*-SPEA-II_V1. Esta afirmación puede ser verificada con base a la *Tabla 19*, donde es presentado el TC, la cantidad de soluciones (SND) promedio y su respectivo contraste algorítmico, teniendo en cuenta un tamaño de muestra igual a treinta (30). Adicionalmente, se realiza una segunda prueba, expuesta en la *Tabla 20*, la cual tiene como fin evaluar el número promedio de soluciones no dominadas (SND) que puede obtener cada algoritmo, lográndose apreciar en este caso, como las dos técnicas generan la misma cantidad en el 70% de las instancias, mientras que en el 30% restante, la cantidad de soluciones halladas por parte del algoritmo *p*-NSGA-II_V1 son estadísticamente menores a las del *p*-SPEA-II_V1; sin embargo, esta diferencia equivale a 0,6816 soluciones en promedio, por lo que desde el punto de vista práctico, los algoritmos poseen un comportamiento muy similar.

Basado en los resultados y el análisis expuesto hasta el momento, se puede inferir con una confianza del 95% que el enfoque *p*-NSGA-II_V1 es superior al *p*-SPEA-II_V1 en términos de TC y a su vez, posee un desempeño aproximadamente igual, tomando como punto de comparación la variable SND. Por lo tanto, existe evidencia estadísticamente significativa para validar la primera hipótesis de investigación, dando como resultado final, su aceptación indiscutible, pues

como indican los resultados, construir un algoritmo NSGA-II bajo el paradigma paralelo-cooperativo, genera un mayor rendimiento computacional, que la técnica SPEA-II, diseñada en condiciones semejantes.

10.2. Resultados Hipótesis 2

Tabla 21.

Prueba de hipótesis algoritmos p-GA_V1 y GA (TC).

Instancia (I_K)	Prueba t de 2 muestras ($\alpha = 0,05$)				Interpretación		
	$\mu_1 = \mu_{p-GA_V1(I_K)}^{TC} / \mu_2 = \mu_{GA(I_K)}^{TC}$						
	Prueba 1		Prueba 2 (Complementaria)		$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
$H_0: \mu_1 \geq \mu_2$	$H_1: \mu_1 < \mu_2$	$H_0: \mu_1 = \mu_2$	$H_1: \mu_1 \neq \mu_2$				
I1	x			x		x	
I2	x			x		x	
I3	x			x		x	
I4	x			x		x	
I5	x			x		x	
I6	x			x		x	
I7	x			x		x	
I8	x			x		x	
I9	x			x		x	
I10	x			x		x	
I11	x			x		x	
I12	x			x		x	
I13	x			x		x	
I14	x			x		x	
I15	x			x		x	
I16	x			x		x	
I17	x			x		x	
I18	x			x		x	
I19	x			x		x	
I20	x			x		x	

Nota. Adaptado del software estadístico Minitab 19.

Tabla 22.*GAP entre los algoritmos p-GA_V1 y GA (n = 30).*

Instancia	Algoritmo				GAP	
	p-GA_V1		GA		(p-GA_V1-GA)	
	MS	TC	MS	TC	MS	TC
I1	-2608329,808	693,339	-2621485,630	620,700	13155,822	72,639
I2	-118843,322	402,573	-119472,111	343,335	628,789	59,239
I3	-2666872,956	585,832	-2687137,125	535,088	20264,169	50,744
I4	-3977960,852	276,149	-3986844,367	243,198	8883,515	32,951
I5	-1421596,543	204,778	-1422258,866	178,447	662,323	26,331
I6	-1598128,210	324,961	-1597821,753	285,487	-306,457	39,474
I7	-427842,676	315,004	-436876,559	281,402	9033,883	33,603
I8	-3020121,145	398,285	-3022902,409	355,207	2781,264	43,077
I9	-4452441,767	402,390	-4460707,077	352,999	8265,310	49,391
I10	-10437775,724	299,961	-10435912,098	269,714	-1863,626	30,248
I11	-5797773,828	499,006	-5800601,257	457,315	2827,429	41,691
I12	-9914707,692	374,540	-9921649,955	331,951	6942,263	42,589
I13	-1875211,244	172,358	-1876014,889	153,123	803,645	19,234
I14	-3081713,774	361,084	-3086399,139	325,763	4685,365	35,321
I15	-4233694,198	405,131	-4240697,709	367,707	7003,511	37,424
I16	-3571773,645	355,100	-3571430,187	317,716	-343,458	37,384
I17	-3975248,726	422,269	-3987212,763	385,487	11964,037	36,781
I18	-1418874,253	341,502	-1430756,336	311,764	11882,083	29,738
I19	-2936430,644	491,022	-2939044,696	455,393	2614,053	35,630
I20	-3442215,098	414,514	-3445306,281	382,268	3091,183	32,246

Nota. Los resultados corresponden a un promedio y el tiempo computacional (TC) está dado en segundos.

Tabla 23.

Prueba de hipótesis algoritmos p-GA_V1 y GA (MS).

Instancia (I_K)	Prueba t de 2 muestras ($\alpha = 0,05$)				Interpretación		
	$\mu_1 = \mu_{p-GA_V1(I_K)}^{MS} / \mu_2 = \mu_{GA(I_K)}^{MS}$						
	Prueba 1		Prueba 2 (Complementaria)		$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
$H_0: \mu_1 \geq \mu_2$	$H_1: \mu_1 < \mu_2$	$H_0: \mu_1 = \mu_2$	$H_1: \mu_1 \neq \mu_2$				
I1	x			x		x	
I2	x		x				x
I3	x			x		x	
I4	x			x		x	
I5	x		x				x
I6	x		x				x
I7	x			x		x	
I8	x		x				x
I9	x			x		x	
I10	x		x				x
I11	x		x				x
I12	x		x				x
I13	x		x				x
I14	x			x		x	
I15	x			x		x	
I16	x		x				x
I17	x			x		x	
I18	x		x				x
I19	x		x				x
I20	x		x				x

Nota. Adaptado del software estadístico Minitab 19.

10.2.1. Análisis prueba *t* de dos muestras (Hipótesis 2)

Tomando como referencia la *Tabla 21*, utilizada para comparar los resultados obtenidos en términos de tiempo computacional (TC) por parte de los algoritmos evolutivos con enfoque mono-objetivo (GA y *p*-GA_V1); es posible inferir con una confianza del 95% que la media poblacional del algoritmo *p*-GA_V1 es estrictamente mayor a la media obtenida por el algoritmo GA, dicho en otras palabras, para cualquier instancia I_k ejecutada en el algoritmo *p*-GA_V1, el tiempo de cómputo requerido para obtener una solución excede al tiempo de ejecución por su contraparte secuencial, en el 100% de las instancia probadas (ver *Tabla 22*); aunque vale la pena aclarar que esta diferencia puede estimarse en un promedio de 39,2868 segundos, sin importar el escenario utilizado, llevando así a una segunda conclusión, la cual indicaría que desde un punto de vista práctico, las dos técnicas presentan un rendimiento aproximadamente igual. Por otro lado, al analizar la calidad de la solución (ver *Tabla 23*), entendida como la mejor respuesta (MS) que permite minimizar la función objetivo (dada en términos de costo “\$”), puede concluirse que para el 60% de las instancias utilizadas, los algoritmos obtienen soluciones iguales, sin embargo, en un 40% del testbed, los resultados generados por la técnica *p*-GA_V1 son mayores a los del algoritmo GA, lo cual resulta desfavorable en el contexto establecido, pues esto indica una mayor calidad en las salidas generadas por parte de la técnica GA, teniendo en cuenta que entre menor sea la solución (más negativa), es mejor la respuesta al problema abordado.

En consecuencia, al seleccionar como métrica de desempeño la variable MS, puede inferirse que el algoritmo *p*-GA_V1, tiene un comportamiento similar al GA con un nivel de significancia de 0.05, además, presenta un menor desempeño desde el punto vista de TC; aunque, como se indicó anteriormente, este aspecto en el sentido práctico no es muy importante, debido a que la brecha (GAP) computacional, se encuentra dada en el orden de los segundos,

específicamente, menos de 80 segundos para la peor instancia. Finalmente, existe evidencia estadísticamente significativa para rechazar la segunda hipótesis de investigación, que afirmaba la existencia de un rendimiento estrictamente superior por parte del *p*-GA_V1 sobre el GA, en función del tiempo computacional o calidad de la solución (mejor solución encontrada).

11. Diseño de los Algoritmos p -GA_V2 y p -NSGA-II_V2

Hasta el momento se han validado las dos hipótesis de investigación, relacionadas con el diseño de algoritmos evolutivos, utilizando la programación en paralelo y el paradigma de cooperación. Teniendo en cuenta el análisis estadístico realizado anteriormente, es posible mencionar a grandes rasgos que la primera hipótesis fue aceptada, pues el algoritmo p -NSGA-II_V1 presentó un mejor rendimiento, en función del tiempo computacional (TC), que la técnica p -SPEA-II_V1; sin embargo, es importante señalar que los dos algoritmos poseen un comportamiento estadístico semejante, al utilizar como medida de desempeño la cantidad de soluciones no dominadas (SND), surgiendo así el siguiente interrogante: ¿Omitir el paradigma de cooperación beneficia el rendimiento del enfoque paralelo?; sumado a esto, los resultados obtenidos en la segunda hipótesis, arrojan como conclusión final el rechazo absoluto de la afirmación que sostenía un rendimiento estrictamente superior en términos de tiempo computacional (TC) o calidad de la solución (MS) por parte del p -GA_V1 sobre el GA (contraparte secuencial), aumentando así la inquietud e incentivando el desarrollo de otros dos algoritmos, caracterizados por operar bajo un entorno netamente paralelo, sin ningún tipo de interacción entre ellos. Estas nuevas técnicas son codificadas y presentadas bajo la nomenclatura p -NSGA-II_V2 y p -GA_V2 (ver *Apéndice H*), las cuales tendrán como finalidad validar potenciales beneficios, en función de las hipótesis establecidas. Para llevar a cabo este procedimiento, fue necesario utilizar un tamaño de muestra equivalente a treinta (30) y aplicar el estadístico de prueba t con igualdad de varianzas conjunta, para diferencias entre dos medias (ver los datos muestrales en el *Apéndice I*). Además, los supuestos de investigación presentados en la sección 4, son adaptados así:

Hipótesis 1

$$H_0: \mu_{p-NSGA-II_V2(I_K)}^{TC} \leq \mu_{p-SPEA-II_V1(I_K)}^{TC}$$

$$H_0: \mu_{p-NSGA-II_V2(I_K)}^{SND} \leq \mu_{p-SPEA-II_V1(I_K)}^{SND}$$

$$H_1: \mu_{p-NSGA-II_V2(I_K)}^{TC} > \mu_{p-SPEA-II_V1(I_K)}^{TC}$$

$$H_1: \mu_{p-NSGA-II_V2(I_K)}^{SND} > \mu_{p-SPEA-II_V1(I_K)}^{SND}$$

Hipótesis 2

$$H_0: \mu_{p-GA_V2(I_K)}^{TC} \geq \mu_{GA(I_K)}^{TC}$$

$$H_0: \mu_{p-GA_V2(I_K)}^{MS} \geq \mu_{GA(I_K)}^{MS}$$

$$H_1: \mu_{p-GA_V2(I_K)}^{TC} < \mu_{GA(I_K)}^{TC}$$

$$H_1: \mu_{p-GA_V2(I_K)}^{MS} < \mu_{GA(I_K)}^{MS}$$

Apoyado en el software estadístico Minitab 19, fue posible realizar las pruebas necesarias (ver *Apéndice J*), obteniendo así los resultados mostrados en la *Tabla 24-30*, desarrolladas con el propósito de facilitar la comprensión e interpretación de los mismos.

11.1. Resultados Adaptación Hipótesis 1

Tabla 24.

GAP entre los algoritmos *p*-NSGA-II_V2 y *p*-SPEA-II_V1 ($n = 30$).

Instancia	Algoritmo				GAP	
	<i>p</i> -NSGA-II_V2		<i>p</i> -SPEA-II_V1		$(p\text{-NSGA-II_V2}-p\text{-SPEA-II_V1})$	
	SND	TC	SND	TC	SND	TC
I1	6,767	389,762	5,900	477,034	0,867	-87,272
I2	9,233	221,183	8,167	299,973	1,067	-78,791
I3	6,300	341,345	6,967	421,611	-0,667	-80,266
I4	6,667	159,942	8,167	233,694	-1,500	-73,752
I5	10,267	117,456	9,633	188,416	0,633	-70,960
I6	9,967	186,027	9,200	257,267	0,767	-71,240
I7	6,333	178,663	6,400	252,590	-0,067	-73,927
I8	8,967	223,228	9,600	296,181	-0,633	-72,953
I9	6,100	230,447	6,533	303,023	-0,433	-72,576
I10	8,933	176,165	8,867	250,924	0,067	-74,758
I11	9,533	291,936	8,400	361,875	1,133	-69,939
I12	11,067	215,053	10,800	281,523	0,267	-66,469
I13	13,267	100,823	12,667	165,437	0,600	-64,614
I14	7,467	206,141	7,233	271,475	0,233	-65,334
I15	7,767	234,765	6,200	296,033	1,567	-61,269
I16	10,500	204,194	9,400	265,671	1,100	-61,477
I17	6,500	247,296	6,500	308,835	0,000	-61,539
I18	8,100	197,680	7,633	267,172	0,467	-69,492
I19	7,400	281,774	7,233	348,707	0,167	-66,933
I20	8,533	234,325	7,533	305,711	1,000	-71,386

Nota. Los resultados corresponden a un promedio y el tiempo computacional (TC) está dado en segundos.

Tabla 25.

Prueba de hipótesis algoritmos p-NSGA-II_V2 y p-SPEA_V1 (TC).

Instancia (I_K)	Prueba t de 2 muestras ($\alpha = 0,05$)				Interpretación		
	$\mu_1 = \mu_{p-NSGA-II_V2(I_K)}^{TC} / \mu_2 = \mu_{p-SPEA-II_V1(I_K)}^{TC}$						
	Prueba 1		Prueba 2 (Complementaria)		$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
	$H_0: \mu_1 \leq \mu_2$	$H_1: \mu_1 > \mu_2$	$H_0: \mu_1 = \mu_2$	$H_1: \mu_1 \neq \mu_2$			
I1	x			x	x		
I2	x			x	x		
I3	x			x	x		
I4	x			x	x		
I5	x			x	x		
I6	x			x	x		
I7	x			x	x		
I8	x			x	x		
I9	x			x	x		
I10	x			x	x		
I11	x			x	x		
I12	x			x	x		
I13	x			x	x		
I14	x			x	x		
I15	x			x	x		
I16	x			x	x		
I17	x			x	x		
I18	x			x	x		
I19	x			x	x		
I20	x			x	x		

Nota. Adaptado del software estadístico Minitab 19.

Tabla 26.

Prueba de hipótesis algoritmos p-NSGA-II_V2 y p-SPEA_V1 (SND).

Instancia (I_K)	Prueba t de 2 muestras ($\alpha = 0,05$)				Interpretación		
	$\mu_1 = \mu_{p-NSGA-II_V2(I_K)}^{SND} / \mu_2 = \mu_{p-SPEA-II_V1(I_K)}^{SND}$						
	Prueba 1		Prueba 2 (Complementaria)		$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
	$H_0: \mu_1 \leq \mu_2$	$H_1: \mu_1 > \mu_2$	$H_0: \mu_1 = \mu_2$	$H_1: \mu_1 \neq \mu_2$			
I1		x				x	
I2	x		x				x
I3	x		x				x
I4	x			x	x		
I5	x		x				x
I6	x		x				x
I7	x		x				x
I8	x		x				x
I9	x		x				x
I10	x		x				x
I11	x		x				x
I12	x		x				x
I13	x		x				x
I14	x		x				x
I15		x				x	
I16	x		x				x
I17	x		x				x
I18	x		x				x
I19	x		x				x
I20		x				x	

Nota. Adaptado del software estadístico Minitab 19.

11.1.1. Análisis prueba *t* de dos muestras (Adaptación hipótesis 1)

Al observar la *Tabla 24*, es posible apreciar un desempeño significativo por parte del algoritmo *p*-NSGA-II_V2 respecto a la técnica *p*-SPEA-II_V1, específicamente, el GAP asociado con la variable SND, está a favor en el 70% de las instancias probadas (valores positivos significan un mayor promedio), mientras que en la variable TC, hay una superioridad total (valores negativos indican menores tiempos), convirtiéndose así en la técnica con mejores resultados, desde un punto de vista muestral. Por otro lado, al analizar la *Tabla 25*, donde se lleva a cabo un contraste estadístico relacionado con la media poblacional de la variable tiempo computacional (TC), puede concluirse con una confianza del 95% que el algoritmo *p*-NSGA-II_V2 obtiene soluciones en menor tiempo, comparado con el *p*-SPEA-II_V1, para el 100% del testbed, reafirmando así la conclusión anterior; además, si se observa la *Tabla 26*, para el 80% de las instancias, los dos algoritmos tiene igual media poblacional, asociada a la variable: soluciones no dominadas (SND) y en un 15% el *p*-NSGA-II_V2 obtiene las mejores salidas del testbed aplicado. Bajo este Panorama y teniendo en cuenta la primera hipótesis de investigación, se concluye con una confianza del 95%, que el algoritmo *p*-NSGA-II_V2, posee un desempeño superior al *p*-SPEA-II_V1, tomando como métricas las variables TC y SND. Más aún, al confrontar las versiones *p*-NSGA-II_V1 (versión paralela-cooperativa) y *p*-NSGA-II_V2 (versión paralela), se obtiene los siguientes resultados (ver *Tabla 27*), donde es representado en una escala de 0 a 100%, la dominancia que tiene el algoritmo para generar las mejores soluciones en el conjunto de prueba, es decir, entre mayor sea el porcentaje, mejor rendimiento posee.

Como indica la *Tabla 27*, el enfoque *p*-NSGA-II_V2 presenta los mejores resultados, desde un punto de vista muestral (GAP) e inferencial (prueba *t* de dos muestras), por lo tanto, se concluye

finalmente que en las técnicas multi-objetivo, omitir el paradigma cooperativo, permite una mejora en el rendimiento de los algoritmos paralelos, especialmente sobre la variable SND.

Tabla 27.

Comparación p -NSGA-II_V1 y p -NSGA-II_V2.

Algoritmo	Contraste con el algoritmo p -SPEA-II_V1			
	GAP		Prueba t de 2 muestras	
	SND	TC	SND	TC
p -NSGA-II_V1	25%	100%	0%	100%
p -NSGA-II_V2	70%	100%	15%	100%

Nota. Adaptado del software estadístico Minitab 19.

11.2. Resultados Adaptación Hipótesis 2

Tabla 28.

Prueba de hipótesis algoritmos p-GA_V2 y GA (MS).

Instancia (I_k)	Prueba t de 2 muestras ($\alpha = 0,05$)				Interpretación		
	$\mu_1 = \mu_{p-GA_V2(I_k)}^{MS} / \mu_2 = \mu_{GA(I_k)}^{MS}$						
	Prueba 1		Prueba 2 (Complementaria)		$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
$H_0: \mu_1 \geq \mu_2$	$H_1: \mu_1 < \mu_2$	$H_0: \mu_1 = \mu_2$	$H_1: \mu_1 \neq \mu_2$				
I1	x		x				x
I2	x		x				x
I3	x			x		x	
I4	x		x				x
I5	x		x				x
I6	x		x				x
I7	x		x				x
I8	x		x				x
I9	x		x				x
I10	x		x				x
I11	x		x				x
I12	x		x				x
I13	x		x				x
I14	x		x				x
I15	x		x				x
I16	x		x				x
I17	x		x				x
I18	x		x				x
I19	x		x				x
I20	x		x				x

Nota. Adaptado del software estadístico Minitab 19.

Tabla 29.
Prueba de hipótesis algoritmos p-GA_V2 y GA (TC).

Instancia (I_K)	Prueba t de 2 muestras ($\alpha = 0,05$)				Interpretación		
	$\mu_1 = \mu_{p-GA_V2(I_K)}^{TC} / \mu_2 = \mu_{GA(I_K)}^{TC}$						
	Prueba 1		Prueba 2 (Complementaria)		$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
	$H_0: \mu_1 \geq \mu_2$	$H_1: \mu_1 < \mu_2$	$H_0: \mu_1 = \mu_2$	$H_1: \mu_1 \neq \mu_2$			
I1	x			x		x	
I2	x			x		x	
I3	x			x		x	
I4	x			x		x	
I5	x			x		x	
I6	x			x		x	
I7	x			x		x	
I8	x			x		x	
I9	x			x		x	
I10	x			x		x	
I11	x			x		x	
I12	x			x		x	
I13	x			x		x	
I14	x			x		x	
I15	x		x			x	
I16	x			x		x	
I17	x			x		x	
I18	x			x		x	
I19	x			x		x	
I20	x			x		x	

Nota. Adaptado del software estadístico Minitab 19.

Tabla 30.*GAP entre los algoritmos p-GA_V2 y GA (n = 30).*

Instancia	Algoritmo				GAP	
	p-GA_V2		GA		(p-GA_V2-GA)	
	MS	TC	MS	TC	MS	TC
I1	-2619906,796	679,429	-2621485,630	620,700	1578,834	58,729
I2	-119153,886	382,557	-119472,111	343,335	318,225	39,223
I3	-2679250,089	581,146	-2687137,125	535,088	7887,036	46,057
I4	-3985067,370	271,852	-3986844,367	243,198	1776,997	28,654
I5	-1423644,349	196,921	-1422258,866	178,447	-1385,483	18,474
I6	-1597800,833	314,473	-1597821,753	285,487	20,921	28,986
I7	-435757,645	315,684	-436876,559	281,402	1118,914	34,282
I8	-3020996,654	390,588	-3022902,409	355,207	1905,756	35,380
I9	-4457008,689	393,371	-4460707,077	352,999	3698,388	40,373
I10	-10437311,884	297,082	-10435912,098	269,714	-1399,786	27,368
I11	-5799699,320	504,373	-5800601,257	457,315	901,938	47,057
I12	-9918961,427	366,633	-9921649,955	331,951	2688,527	34,682
I13	-1875070,324	169,132	-1876014,889	153,123	944,566	16,009
I14	-3084389,255	360,077	-3086399,139	325,763	2009,884	34,314
I15	-4239894,080	390,638	-4240697,709	367,707	803,629	22,931
I16	-3572521,077	346,914	-3571430,187	317,716	-1090,890	29,198
I17	-3986816,770	418,637	-3987212,763	385,487	395,993	33,150
I18	-1421781,899	339,794	-1430756,336	311,764	8974,437	28,029
I19	-2937575,106	492,697	-2939044,696	455,393	1469,590	37,305
I20	-3445063,335	414,627	-3445306,281	382,268	242,946	32,359

Nota. Los resultados corresponden a un promedio y el tiempo computacional (TC) está dado en segundos. Adaptado del software estadístico Minitab 19.

11.2.1. Análisis prueba t de dos muestras (Adaptación hipótesis 2)

Los resultados obtenidos para esta nueva versión del GA paralelo, consolidados en la *Tabla 28* y *Tabla 29*, permiten inferir (confianza del 95%) un comportamiento similar en términos de la variable: mejor solución encontrada (MS), ya que como se puede apreciar, la media poblacional en el 95% de las instancias probadas, no presentan diferencias estadísticamente significativas. Por otra parte, la métrica tiempo computacional (TC) una vez más posiciona al *p-GA_V2*, en un segundo lugar, sin embargo, al analizar con detenimiento, esta desventaja puede ser estimada en un promedio de 33,6280 segundos, resultando así poco crítico, bajo un panorama práctico, es decir, para el tomador de decisiones, esperar por una solución, una fracción de tiempo como las observadas en la *Tabla 30*, si utiliza un algoritmo paralelo, en lugar del secuencial, le resultará casi que despreciable. Adicionalmente, si se comparan los resultados de este enfoque netamente paralelo (*p-GA_V2*), con los obtenidos al añadir el paradigma cooperativo (*p-GA_V1*), es posible destacar la siguiente información, presentada a través de la *Tabla 31*, donde cada porcentaje (0-100%) indica la participación de la variable (MS y TC) para la condición establecida en el testbed, por lo tanto, en algunos casos, la versión construida presentará un mejor grado de desempeño y en otras, deberá interpretarse como un rendimiento igual o menor. Es importante recordar que las salidas son obtenidas al comparar cada algoritmo individualmente con el GA.

Tabla 31.
Comparación p-GA_V1 y p-GA_V2.

Algoritmo	Contraste con el algoritmo GA							
	GAP		Prueba t de 2 muestras					
	MS	TC	MS			TC		
			$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$	$\mu_1 < \mu_2$	$\mu_1 > \mu_2$	$\mu_1 = \mu_2$
<i>p-GA_V1</i>	15%	0%	0%	40%	60%	0%	100%	0%
<i>p-GA_V2</i>	15%	0%	0%	5%	95%	5%	95%	0%

Nota. Adaptado del software estadístico Minitab 19.

De acuerdo con la *Tabla 31* y a modo de ejemplo, se interpretan los resultados del p -GA_V2 de la siguiente manera: en cuanto al GAP, este algoritmo obtiene el 15% de las mejores soluciones y un porcentaje nulo para el tiempo de cómputo, es decir, su contraparte secuencial (GA) genera soluciones en el menor tiempo posible para todas las instancias (100%). La variable MS, muestra un comportamiento igual en el 95% de las instancias ejecutadas y un rendimiento inferior del 5%, respecto a la técnica contrastada; mientras que, para el TC, se obtiene un porcentaje global del 95%, indicando así un aspecto negativo, pues esto significa que en la mayoría de instancias probadas, la técnica requiere un tiempo más elevado de procesamiento para obtener una solución y en un 5% de las instancias, toman un TC equivalente. Al comparar bajo esta misma lógica, cada uno de los ítems en el algoritmo p -GA_V1, es evidente como la versión paralela (p -GA_V2), obtiene globalmente un mejor desempeño, dando así respuesta al interrogante que incentivó la segunda versión propuesta. A modo de conclusión (ver *Figura 22* y *Figura 23*), es posible inferir con una confianza del 95% que la técnica p -GA_V2 posee un mejor rendimiento que el enfoque p -GA_V1 y a su vez, este desempeño se ajusta más al de la técnica GA, rechazando así nuevamente la afirmación establecida en la segunda hipótesis de investigación.

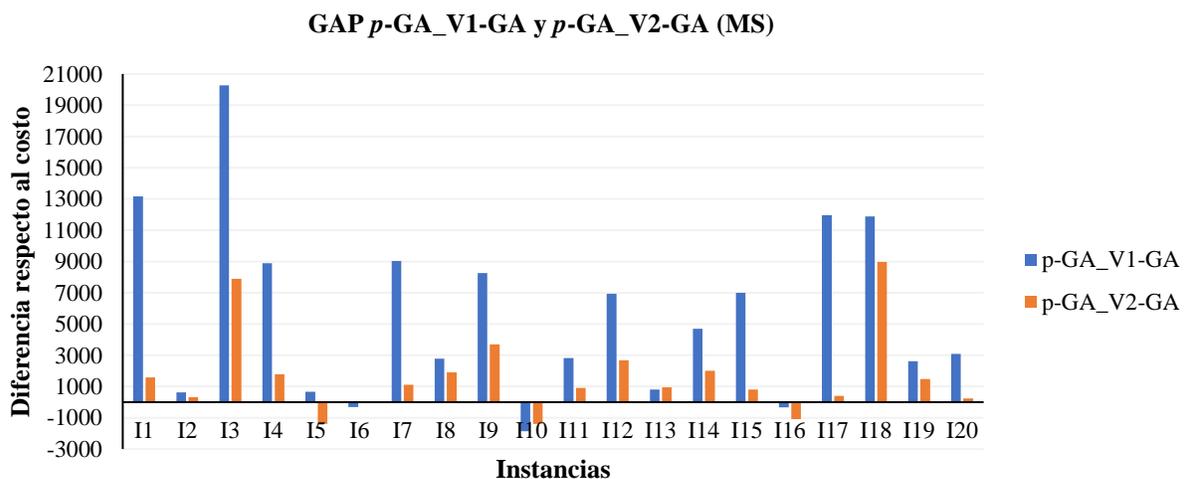


Figura 22. Comparación GAP p -GA_V1-GA y p -GA_V2 (MS).

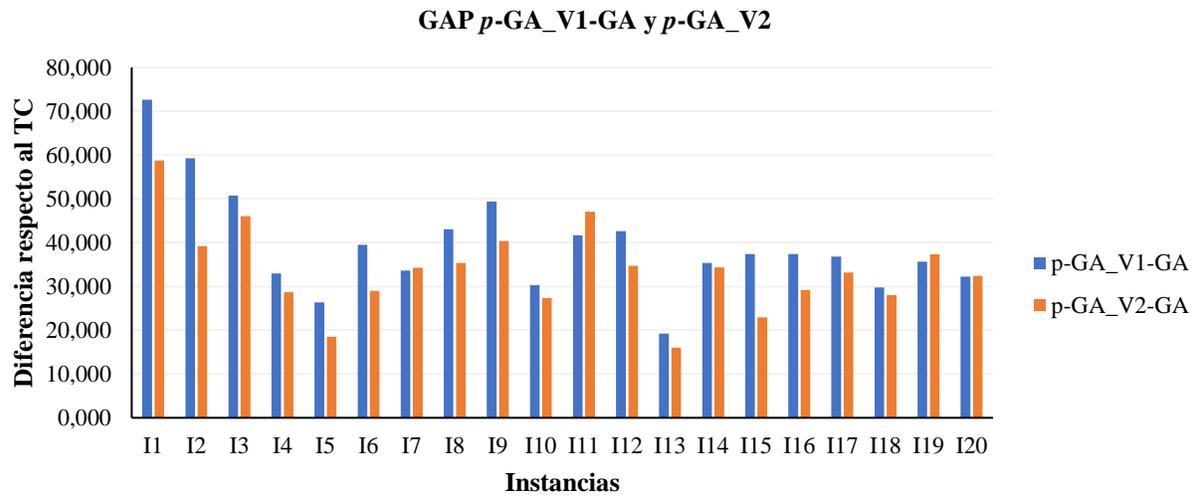


Figura 23. Comparación GAP p -GA_V1-GA y p -GA_V2 (TC).

12. Discusión

La primera hipótesis de investigación señala a los algoritmos *p*-NSGA-II_V1 y *p*-NSGA-II_V2 como las mejores alternativas para solucionar el problema 2E-LIRP multi-objetivo aplicado a la cadena de suministro humanitaria, debido a que con estos se obtienen la mayor cantidad promedio de soluciones no dominadas (SND), permitiendo al decisor contar con un conjunto prudente de posibles soluciones y además, los tiempos de ejecución (TC), son estadísticamente inferiores que el *p*-SPEA_V1.

A pesar de rechazar la segunda hipótesis de investigación, la cual señalaba un desempeño superior en términos de tiempo computacional (TC) o calidad de la solución (MS), por parte de los algoritmos genéticos (GA) programados en paralelos bajo un entorno de cooperación o simplemente con un enfoque paralelo, en comparación con su contraparte secuencial, es importante mencionar que sí existen algunas mejoras considerables para la variable MS, utilizando la técnica *p*-GA_V1 y *p*-GA_V2, las cuales son valoradas en un 45% y 50% respectivamente, tomando como referencia el conjunto testbed, es decir, el algoritmo *p*-GA_V1 mejora las soluciones para el 45% de las instancias probadas, mientras que el *p*-GA_V2 permite obtener una mejora global, equivalente al 50%.

Por otra parte, como se puede evidenciar en la sección dedicada a la comprobación de hipótesis, los algoritmos diseñados bajo los enfoques mono-objetivo y multi-objetivo, teniendo en cuenta características secuenciales, paralelas y cooperativas, presentan a modo general un tiempo de procesamiento razonable (5 a 10 minutos aproximadamente), convirtiéndose así en herramientas válidas y eficientes que apoyan la toma de decisiones integrales, para la gestión de la cadena de suministro humanitaria, la cual tiene como objetivo principal, atender las áreas afectas por un desastre en el menor tiempo posible, salvando así la mayor cantidad de vidas posibles.

Finalmente, al validar las hipótesis de investigación y analizar los resultados obtenidos en cada uno de los enfoques de solución, es posible afirmar que el presente estudio ha cumplido el propósito general, relacionado con el desarrollo de un modelo de optimización multi-objetivo para el problema de localización, ruteo e inventario de dos escalones (2E-LIRP) y consecuentemente, con el diseño de un conjunto de herramientas computacionales (código Python), las cuales permiten solucionar instancias específicas, suministrando información relevante al responsable de tomar decisiones y diseñar la red logística humanitaria.

13. Conclusiones

Uno de los aportes más significativos que proporciona esta investigación, es el desarrollo de un modelo multi-objetivo, para el problema de localización, inventario y ruteo multi-escalón, considerando demanda dinámica, flota heterogénea, múltiples periodos y productos, el cual tiene en cuenta la optimización de los costos sociales, debido a su contexto humanitario y a los nuevos enfoques en el área de desastres que buscan mediar entre los costos privados y humanitarios, despreciados hasta el momento en gran parte de la literatura existente, pues utilizan adaptaciones de la logística comercial; es decir, el modelo matemático construido, tiene como objetivos, minimizar los costos logísticos tradicionales (localización, inventario y ruteo) y a su vez, maximizar el bienestar de las áreas afectadas, utilizando una función que representa el impacto en la estrategia de distribución y el tiempo de privación experimentado.

El esquema paralelo-cooperativo o netamente paralelo, actúa favorablemente a la hora de construir técnicas de solución que siguen la metodología propuesta por el NSGA-II, permitiendo así un mayor desempeño, si se compara con el algoritmo SPEA-II, diseñado bajo idénticas condiciones, utilizando como métricas, el tiempo computacional (TC) y el número de soluciones no dominadas (SND). Más aún, es importante mencionar como el algoritmo *p*-NSGA-II_V1 y *p*-NSGA-II_V2 poseen tiempos de cómputo estrictamente menores para el 100% de las instancias ejecutadas y a su vez, la cantidad de soluciones no dominadas son por lo menos iguales o superiores, respecto a las del *p*-SPEA-II_V1.

La experimentación llevada a cabo demostró que al utilizar la programación en paralelo bajo el paradigma de cooperación o simplemente el enfoque paralelo, en el diseño de un algoritmo genético mono-objetivo (*p*-GA_V1 o *p*-GA_V2), para la solución del 2E-LIRP, permite obtener a nivel inferencial métodos de solución aproximadamente iguales, en términos de la variable, mejor

solución encontrada (MS), que su contraparte secuencial, el algoritmo genético (GA). Sin embargo, es importante mencionar que para un conjunto de réplicas (nivel muestral), los algoritmos p -GA_V1 y p -GA_V2, mejoran significativamente las soluciones obtenidas por la técnica GA, encontrando aproximadamente el 45% (algoritmo paralelo-cooperativo) y 50% (algoritmo paralelo) de las mejores soluciones globales en el testbed probado.

A pesar del esfuerzo realizado por construir un algoritmo genético paralelo-cooperativo que presentara una mejora en función del tiempo computacional (TC), la experimentación permite inferir que bajo el esquema utilizado (sistema distribuido o islas), este propósito es imposible de alcanzar, pues en la mayoría de instancias utilizadas, el rendimiento obtenido fue inferior respecto a su contraparte secuencial, lo cual se debe a dos aspectos muy importantes, el primero, la necesidad de sincronizar los dos hilos (islas) en el momento de la transferencia de información genética y el segundo, a las operaciones adicionales que este necesita realizar en el colector (mecanismo de comunicación), para obtener finalmente una solución (mejor individuo).

Al solucionar un problema multi-objetivo aplicando el método de ponderaciones, surge un interrogante muy importante: ¿Qué valor o peso asociar a cada función objetivo?, pues de acuerdo a estos, la solución puede tener algunos cambios significativos. Al intentar dar respuesta a esta inquietud, indiscutiblemente se llega a un problema subjetivo, como lo indica la revisión de literatura, dado que no existe una metodología o procedimiento específico para estimar dichos parámetros con exactitud, pues dependen finalmente del encargado de tomar decisiones. Es por esto que, en el presente estudio, se decidió dar el mismo nivel de importancia a las dos funciones bajo conflicto, específicamente el valor de uno (1), para así poder realizar la calibración de los algoritmos mono-objetivo y posteriormente dar respuesta a la segunda hipótesis de investigación; sin embargo, vale la pena aclarar que la selección de pesos estuvo sujeto a la experimentación

previa llevada a cabo y además, se encuentran parametrizados, con la finalidad de que el usuario pueda asignar valores que considere personalmente convenientes a la hora de solucionar un escenario particular.

Las técnicas evolutivas utilizadas en el presente estudio, ofrecieron un excelente rendimiento a la hora de solucionar el problema abordado, dada la complejidad computacional que exigía el uso de herramientas adecuadas, para obtener buenas soluciones en tiempos de cómputo razonables. Cada técnica propuesta se validó aplicando un testbed, compuesto por veinte instancias de prueba, donde la coherencia y validez en las salidas fueron dos aspectos muy importantes que se evaluaron, con el propósito de ofrecer al decisor, herramientas útiles que sirvan de apoyo a la gestión de la cadena de suministro humanitaria, teniendo en cuenta las necesidades (localización, inventario y ruteo) desde un panorama integral, aproximadas a la realidad y además, evaluadas desde dos puntos de vista muy importantes, el enfoque multi-objetivo, que brinda un conjunto de posibles soluciones, las cuales de acuerdo con algunos criterios o técnica específica, llevan a la selección de una alternativa y el mono-objetivo, que permite mediar o combinar los intereses bajo conflicto, al aplicar un nivel de importancia o peso, con el fin de obtener una única respuesta.

Referencias bibliográficas

- Aghajani, M., Torabi, S. A., & Heydari, J. (2020). A novel option contract integrated with supplier selection and inventory prepositioning for humanitarian relief supply chains. *Socio-Economic Planning Sciences*, 71, 100780. <https://doi.org/10.1016/j.seps.2019.100780>
- Alba, E., Almeida, F., Blesa, M., Cotta, C., Díaz, M., Dorta, I., Gabarró, J., León, C., Luque, G., Petit, J., Rodríguez, C., Rojas, A., & Xhafa, F. (2006). Efficient parallel LAN/WAN algorithms for optimization. The mallba project. *Parallel Computing*, 32(5–6), 415–440. <https://doi.org/10.1016/j.parco.2006.06.007>
- Albareda-Sambola, M., Díaz, J. A., & Fernández, E. (2005). A compact model and tight bounds for a combined location-routing problem. *Computers & Operations Research*, 32(3), 407–428. [https://doi.org/10.1016/S0305-0548\(03\)00245-4](https://doi.org/10.1016/S0305-0548(03)00245-4)
- Altay, N., & Green, W. G. (2006). OR/MS research in disaster operations management. *European Journal of Operational Research*, 175(1), 475–493. <https://doi.org/10.1016/j.ejor.2005.05.016>
- Amaya, J. E., Cotta, C., & Leiva, A. J. F. (2010). Hybrid cooperation models for the tool switching problem. *Studies in Computational Intelligence*, 284, 39–52. https://doi.org/10.1007/978-3-642-12538-6_4
- Asosismica | ASOCIACIÓN COLOMBIANA DE INGENIERÍA SÍSMICA – AIS. (n.d.). Retrieved April 19, 2020, from <https://www.asosismica.org.co/>
- Audet, C., Bigeon, J., Cartier, D., Le Digabel, S., & Salomon, L. (2020). Performance indicators in multiobjective optimization. *European Journal of Operational Research*, 292(2), 397–422. <https://doi.org/10.1016/j.ejor.2020.11.016>
- Balcik, B., Beamon, B. M., Krejci, C. C., Muramatsu, K. M., & Ramirez, M. (2010). Coordination in humanitarian relief chains: Practices, challenges and opportunities. *International Journal of Production Economics*, 126(1), 22–34. <https://doi.org/10.1016/j.ijpe.2009.09.008>
- Balza-Franco, V., Paternina-Arboleda, C. D., Cantillo, V., Macea, L. F., & Ramírez-Ríos, D. G. (2017). A collaborative supply chain model for non-for-profit networks based on cooperative game theory “A collaborative supply chain model for non-for-profit networks based on cooperative game theory” A collaborative supply chain model. *Int. J. Logistics Systems and Management*, 26(4), 475–496. <https://doi.org/10.1504/IJLSM.2017.10003405>
- Banco Mundial (2016). *Gestión del riesgo de desastres*. <https://www.bancomundial.org/es/topic/disasterriskmanagement/overview>
- Barbucha, D. (2014). A cooperative population learning algorithm for vehicle routing problem with time windows. *Neurocomputing*, 146, 210–229. <https://doi.org/10.1016/j.neucom.2014.06.033>
- Biuki, M., Kazemi, A., & Alinezhad, A. (2020). An integrated location-routing-inventory model for sustainable design of a perishable products supply chain network. *Journal of Cleaner Production*, 260. <https://doi.org/10.1016/j.jclepro.2020.120842>
- Blum, C., & Roli, A. (2003). Metaheuristics in combinatorial optimization. *ACM Computing*

- Surveys*, 35(3), 268–308. <https://doi.org/10.1145/937503.937505>
- Bouthillier, A. Le, & Crainic, T. G. (2005). A cooperative parallel meta-heuristic for the vehicle routing problem with time windows. *Computers & Operations Research*, 32(7), 1685–1708. <https://doi.org/10.1016/j.cor.2003.11.023>
- Bozorgi-Amiri, A., & Khorsi, M. (2016). A dynamic multi-objective location–routing model for relief logistic planning under uncertainty on demand, travel time, and cost parameters. *The International Journal of Advanced Manufacturing Technology*, 85, 1633–1648. <https://doi.org/10.1007/s00170-015-7923-3>
- Câmara, D. (2015). Evolution and Evolutionary Algorithms. In *Bio-inspired Networking* (pp. 1–30). Elsevier. <https://doi.org/10.1016/B978-1-78548-021-8.50001-6>
- Cantillo, V., Macea, L. F., & Jaller, M. (2019). Assessing Vulnerability of Transportation Networks for Disaster Response Operations. *Networks and Spatial Economics*, 19(1), 243–273. <https://doi.org/10.1007/s11067-017-9382-x>
- Cantillo, V., Serrano, I., Macea, L. F., & Holguín-Veras, J. (2018). Discrete choice approach for assessing deprivation cost in humanitarian relief operations. *Socio-Economic Planning Sciences*, 63, 33–46. <https://doi.org/10.1016/j.seps.2017.06.004>
- Cecchini, S., Sunkel, G., & Barrantes, A. (2017). *Protección social de la infancia frente a los desastres | Enfoques | Comisión Económica para América Latina y el Caribe*. <https://www.cepal.org/es/enfoques/proteccion-social-la-infancia-frente-desastres>
- Centre for Research on the Epidemiology of Disasters | Centre for Research on the Epidemiology of Disasters*. (2018). <https://www.cred.be/>
- Correal, J. (2016). *Posibilidades de un sismo o terremoto en Colombia - Archivo Digital de Noticias de Colombia y el Mundo desde 1.990 - eltiempo.com*. <https://www.eltiempo.com/archivo/documento/CMS-16571309>
- Cotes, N., & Cantillo, V. (2019). Including deprivation costs in facility location models for humanitarian relief logistics. *Socio-Economic Planning Sciences*, 65(March 2018), 89–100. <https://doi.org/10.1016/j.seps.2018.03.002>
- Crainic, T. G. (2008). Parallel solution methods for vehicle routing problems. *Operations Research/ Computer Science Interfaces Series*, 43, 171–198. https://doi.org/10.1007/978-0-387-77778-8_8
- Crainic, T. G., Gendreau, M., Hansen, P., & Mladenović, N. (2004). Cooperative Parallel Variable Neighborhood Search for the p-Median. *Journal of Heuristics*, 10(3), 293–314. <https://doi.org/10.1023/B:HEUR.0000026897.40171.1a>
- Crainic, T. G., & Toulouse, M. (2006). Parallel Strategies for Meta-Heuristics. In Glover F., Kochenberger G.A. (eds), *Handbook of Metaheuristics* (pp. 475–513). Kluwer Academic Publishers. https://doi.org/10.1007/0-306-48056-5_17
- Crainic, T. G., & Toulouse, M. (2010). Parallel Meta-heuristics. *International Transactions in Operational Research*, 20(1), 497–541. https://doi.org/10.1007/978-1-4419-1665-5_17
- Cuda, R., Guastaroba, G., & Speranza, M. G. (2015). A survey on two-echelon routing problems. *Computers & Operations Research*, 55, 185–199. <https://doi.org/10.1016/j.cor.2014.06.008>

- Dai, Z., Aqlan, F., Gao, K., & Zhou, Y. (2019). A two-phase method for multi-echelon location-routing problems in supply chains. *Expert Systems with Applications*, *115*, 618–634. <https://doi.org/10.1016/j.eswa.2018.06.050>
- Day, J. M., Melnyk, S. A., Larson, P. D., Davis, E. W., & Whybark, D. C. (2012). Humanitarian and Disaster Relief Supply Chains: A Matter of Life and Death. *Journal of Supply Chain Management*, *48*(2), 21–36. <https://doi.org/10.1111/j.1745-493X.2012.03267.x>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, *6*(2), 182–197. <https://doi.org/10.1109/4235.996017>
- Delgado-Lindeman, M., Arellana, J., & Cantillo, V. (2019). Willingness to pay functions for emergency ambulance services. *Journal of Choice Modelling*, *30*, 28–37. <https://doi.org/10.1016/j.jocm.2018.12.001>
- Díaz, H. L., Imitola, K. A., & Amado, R. J. A. (2019). OR/MS research perspectives in disaster operations management: A literature review. *Revista Facultad de Ingeniería*, *91*, 43–59. <https://doi.org/10.17533/udea.redin.n91a05>
- Dondo, R., Méndez, C. A., & Cerdá, J. (2011). The multi-echelon vehicle routing problem with cross docking in supply chain management. *Computers & Chemical Engineering*, *35*(12), 3002–3024. <https://doi.org/10.1016/j.compchemeng.2011.03.028>
- Döyen, A., Aras, N., & Barbarosoğlu, G. (2012). A two-echelon stochastic facility location model for humanitarian relief logistics. *Optimization Letters*, *6*(6), 1123–1145. <https://doi.org/10.1007/s11590-011-0421-0>
- Du, W., & Li, B. (2008). Multi-strategy ensemble particle swarm optimization for dynamic optimization. *Information Sciences*, *178*(15), 3096–3109. <https://doi.org/10.1016/j.ins.2008.01.020>
- El-Abd, M., & Kamel, M. (2005). A taxonomy of cooperative search algorithms. *Lecture Notes in Computer Science*, *3636*, 32–41. https://doi.org/10.1007/11546245_4
- EM-DAT | The international disasters database. (2017). <https://www.emdat.be/>
- Fatemi Ghomi, S. M. T., & Asgarian, B. (2019). Development of metaheuristics to solve a transportation inventory location routing problem considering lost sale for perishable goods. *Journal of Modelling in Management*, *14*(1), 175–198. <https://doi.org/10.1108/JM2-05-2018-0064>
- Fazayeli, S., Eydi, A., & Kamalabadi, I. N. (2018). Location-routing problem in multimodal transportation network with time windows and fuzzy demands: Presenting a two-part genetic algorithm. *Computers & Industrial Engineering*, *119*, 233–246. <https://doi.org/10.1016/j.cie.2018.03.041>
- Fernández, J. M. (2005). *Equipo de Algoritmos Evolutivos Multiobjetivo Paralelos (Team Algorithm of pMOEAs)* [Universidad Católica Nuestra Señora de la Asunción]. https://www.cnc.una.py/publicaciones/4_130.pdf
- Flynn, R., & Sherman, P. D. (1995). Multicriteria optimization of aircraft panels: Determining viable genetic algorithm configurations. *International Journal of Intelligent Systems*, *10*(11), 987–999. <https://doi.org/10.1002/int.4550101105>

- Fogel, D. B. (2000). What is evolutionary computation? *IEEE Spectrum*, 37(2), 26–32. <https://doi.org/10.1109/6.819926>
- Galindo, G., & Batta, R. (2013). Review of recent developments in OR/MS research in disaster operations management. *European Journal of Operational Research*, 230(2), 201–211. <https://doi.org/10.1016/j.ejor.2013.01.039>
- Gestal, M., Rivero, D., Rabuñal, J., Dorado, J., & Pazos, A. (2010). *Introducción a los Algoritmos Genéticos y la Programación Genética*. Consorcio Editorial Galego.
- Ghorashi, S. B., Hamed, M., & Sadeghian, R. (2019). Modeling and optimization of a reliable blood supply chain network in crisis considering blood compatibility using MOGWO. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-019-04343-1>
- Ghorbani, A., & Akbari Jokar, M. R. (2016). A hybrid imperialist competitive-simulated annealing algorithm for a multisource multi-product location-routing-inventory problem. *Computers and Industrial Engineering*, 101, 116–127. <https://doi.org/10.1016/j.cie.2016.08.027>
- Goldberg, D. E. (1989). *Genetic Algorithms in search, optimization y Machine Learning*. Addison-We.
- Goldberg, D. E. (2002). *The Design of Innovation Lessons from and for Competent Genetic Algorithm* (Vol. 7). Springer US. <https://doi.org/10.1007/978-1-4757-3643-4>
- Gonzalez-Feliu, J. (2013). Vehicle Routing in Multi-Echelon Distribution Systems with Cross-Docking: A Systematic Lexical-Metanarrative Analysis. *Computer and Information Science*, 6(3). <https://doi.org/10.5539/cis.v6n3p28>
- Guo, H., Li, C., Zhang, Y., Zhang, C., & Wang, Y. (2018). A nonlinear integer programming model for integrated location, inventory, and routing decisions in a closed-loop supply chain. *Complexity*, 2018. <https://doi.org/10.1155/2018/2726070>
- Gutjahr, W. J., & Fischer, S. (2018). Equity and deprivation costs in humanitarian logistics. *European Journal of Operational Research*, 270(1), 185–197. <https://doi.org/10.1016/j.ejor.2018.03.019>
- Gutjahr, W. J., & Nolz, P. C. (2016). Multicriteria optimization in humanitarian aid. *European Journal of Operational Research*, 252(2), 351–366. <https://doi.org/10.1016/j.ejor.2015.12.035>
- Hashemi Petrudi, S. H., Tavana, M., & Abdi, M. (2020). A comprehensive framework for analyzing challenges in humanitarian supply chain management: A case study of the Iranian Red Crescent Society. *International Journal of Disaster Risk Reduction*, 42, 101340. <https://doi.org/10.1016/j.ijdrr.2019.101340>
- Hiassat, A., Diabat, A., & Rahwan, I. (2017). A genetic algorithm approach for location-inventory-routing problem with perishable products. *Journal of Manufacturing Systems*, 42, 93–103. <https://doi.org/10.1016/j.jmsy.2016.10.004>
- Holguín-Veras, J., Amaya-Leal, J., Cantillo, V., Van Wassenhove, L. N., Aros-Vera, F., & Jaller, M. (2016). Econometric estimation of deprivation cost functions: A contingent valuation experiment. *Journal of Operations Management*, 45(1), 44–56. <https://doi.org/10.1016/j.jom.2016.05.008>

- Holguín-Veras, J., & Jaller, M. (2012). Immediate Resource Requirements after Hurricane Katrina. *Natural Hazards Review*, 13(2), 117–131. [https://doi.org/10.1061/\(ASCE\)NH.1527-6996.0000068](https://doi.org/10.1061/(ASCE)NH.1527-6996.0000068)
- Holguín-Veras, J., Jaller, M., Van Wassenhove, L. N., Pérez, N., & Wachtendorf, T. (2012). On the unique features of post-disaster humanitarian logistics. *Journal of Operations Management*, 30(7–8), 494–506. <https://doi.org/10.1016/j.jom.2012.08.003>
- Holguín-Veras, J., Pérez, N., Jaller, M., Van Wassenhove, L. N., & Aros-Vera, F. (2013). On the appropriate objective function for post-disaster humanitarian logistics models. *Journal of Operations Management*, 31(5), 262–280. <https://doi.org/10.1016/j.jom.2013.06.002>
- Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor.
- Hu, S., & Dong, Z. S. (2019). Supplier selection and pre-positioning strategy in humanitarian relief. *Omega*, 83, 287–298. <https://doi.org/10.1016/j.omega.2018.10.011>
- Hu, Z.-H., & Sheu, J.-B. (2013). Post-disaster debris reverse logistics management under psychological cost minimization. *Transportation Research Part B: Methodological*, 55, 118–141. <https://doi.org/10.1016/j.trb.2013.05.010>
- Huang, K., Jiang, Y., Yuan, Y., & Zhao, L. (2015). Modeling multiple humanitarian objectives in emergency response to large-scale disasters. *Transportation Research Part E: Logistics and Transportation Review*, 75, 1–17. <https://doi.org/10.1016/j.tre.2014.11.007>
- Hui Li, & Qingfu Zhang. (2009). Multiobjective Optimization Problems With Complicated Pareto Sets, MOEA/D and NSGA-II. *IEEE Transactions on Evolutionary Computation*, 13(2), 284–302. <https://doi.org/10.1109/TEVC.2008.925798>
- Jin, J., Crainic, T. G., & Løkketangen, A. (2012). A parallel multi-neighborhood cooperative tabu search for capacitated vehicle routing problems. *European Journal of Operational Research*, 222(3), 441–451. <https://doi.org/10.1016/j.ejor.2012.05.025>
- Jin, J., Crainic, T. G., & Løkketangen, A. (2014). A cooperative parallel metaheuristic for the capacitated vehicle routing problem. *Computers & Operations Research*, 44, 33–41. <https://doi.org/10.1016/j.cor.2013.10.004>
- Kelle, P., Schneider, H., & Yi, H. (2014). Decision alternatives between expected cost minimization and worst case scenario in emergency supply – Second revision. *International Journal of Production Economics*, 157, 250–260. <https://doi.org/10.1016/j.ijpe.2014.06.009>
- Khayal, D., Pradhananga, R., Pokharel, S., & Mutlu, F. (2015). A model for planning locations of temporary distribution facilities for emergency response. *Socio-Economic Planning Sciences*, 52, 22–30. <https://doi.org/10.1016/j.seps.2015.09.002>
- King, R. T. F. A., Deb, K., & Rughooputh, H. C. S. (2010). Comparison of NSGA-II and SPEA2 on the Multiobjective Environmental/Economic Dispatch Problem. *University of Mauritius*. <https://www.ajol.info/index.php/umrj/article/view/131124>
- Kunz, N., & Reiner, G. (2012). A meta-analysis of humanitarian logistics research. *Journal of Humanitarian Logistics and Supply Chain Management*, 2(2), 116–147. <https://doi.org/10.1108/20426741211260723>

- L'Hermitte, C., Tatham, P., Bowles, M., & Brooks, B. (2016). Developing organisational capabilities to support agility in humanitarian logistics: An exploratory study. *Journal of Humanitarian Logistics and Supply Chain Management*, 6(1), 72–99. <https://doi.org/10.1108/JHLSCM-02-2015-0006>
- Living with risk: a global review of disaster reduction initiatives / UNDRR*. (n.d.). Retrieved March 31, 2020, from <https://www.undrr.org/publication/living-risk-global-review-disaster-reduction-initiatives>
- Lopes Silva, M. A., de Souza, S. R., Freitas Souza, M. J., & de França Filho, M. F. (2018). Hybrid metaheuristics and multi-agent systems for solving optimization problems: A review of frameworks and a comparative analysis. *Applied Soft Computing*, 71, 433–459. <https://doi.org/10.1016/j.asoc.2018.06.050>
- López, J. (2013). *Optimización Multi-objetivo: Aplicaciones a problemas del mundo real*. <https://libros.unlp.edu.ar/index.php/unlp/catalog/view/152/132/418-1>
- Loree, N., & Aros-Vera, F. (2018). Points of distribution location and inventory management model for Post-Disaster Humanitarian Logistics. *Transportation Research Part E: Logistics and Transportation Review*, 116, 1–24. <https://doi.org/10.1016/j.tre.2018.05.003>
- Lücken, C., Hermosilla, A., & Barán, B. (2004). Algoritmos Evolutivos para Optimización Multiobjetivo: Un Estudio Comparativo en un Ambiente Paralelo Asíncrono. *Universidad Nacional de Asunción*. http://sedici.unlp.edu.ar/bitstream/handle/10915/22476/Documento_completo.pdf?sequence=1&isAllowed=y
- Macea, L. F., Amaya, J., Cantillo, V., & Holguín-Veras, J. (2018). Evaluating economic impacts of water deprivation in humanitarian relief distribution using stated choice experiments. *International Journal of Disaster Risk Reduction*, 28, 427–438. <https://doi.org/10.1016/j.ijdrr.2018.03.029>
- Macea, L. F., Cantillo, V., & Arellana, J. (2018). Influence of attitudes and perceptions on deprivation cost functions. *Transportation Research Part E: Logistics and Transportation Review*, 112, 125–141. <https://doi.org/10.1016/j.tre.2018.02.007>
- Mete, H. O., & Zabinsky, Z. B. (2010). Stochastic optimization of medical supply location and distribution in disaster management. *International Journal of Production Economics*, 126(1), 76–84. <https://doi.org/10.1016/j.ijpe.2009.10.004>
- Moreno, A., Alem, D., Ferreira, D., & Clark, A. (2018). An effective two-stage stochastic multi-trip location-transportation model with social concerns in relief supply chains. *European Journal of Operational Research*, 269(3), 1050–1071. <https://doi.org/10.1016/j.ejor.2018.02.022>
- Nagurney, A., Salarpour, M., & Daniele, P. (2019). An integrated financial and logistical game theory model for humanitarian organizations with purchasing costs, multiple freight service providers, and budget, capacity, and demand constraints. *International Journal of Production Economics*, 212, 212–226. <https://doi.org/10.1016/j.ijpe.2019.02.006>
- Nakhjirkan, S., & Mokhtab Rafiei, F. (2017). An Integrated Multi-Echelon Supply Chain Network Design Considering Stochastic Demand: A Genetic Algorithm Based Solution. *PROMET - Traffic & Transportation*, 29(4), 391–400. <https://doi.org/10.7307/ptt.v29i4.2193>

- Nakhjirkan, S., Mokhatab Rafiei, F., & Husseinzadeh Kashan, A. (2019). Developing an integrated decision making model in supply chain under demand uncertainty using genetic algorithm and network data envelopment analysis. In *Int. J. Mathematics in Operational Research* (Vol. 14, Issue 1).
- Nikkhoo, F., Bozorgi-Amiri, A., & Heydari, J. (2018). Coordination of relief items procurement in humanitarian logistic based on quantity flexibility contract. *International Journal of Disaster Risk Reduction*, 31, 331–340. <https://doi.org/10.1016/j.ijdr.2018.05.024>
- Park, Y.-B., Yoo, J.-S., & Park, H.-S. (2016). A genetic algorithm for the vendor-managed inventory routing problem with lost sales. *Expert Systems with Applications*, 53, 149–159. <https://doi.org/10.1016/j.eswa.2016.01.041>
- Paul, J. A., & Zhang, M. (2019). Supply location and transportation planning for hurricanes: A two-stage stochastic programming framework. *European Journal of Operational Research*, 274(1), 108–125. <https://doi.org/10.1016/j.ejor.2018.09.042>
- Pérez-Rodríguez, N., & Holguín-Veras, J. (2016). Inventory-Allocation Distribution Models for Postdisaster Humanitarian Logistics with Explicit Consideration of Deprivation Costs. *Transportation Science*, 50(4), 1261–1285. <https://doi.org/10.1287/trsc.2014.0565>
- Polat, O. (2017). A parallel variable neighborhood search for the vehicle routing problem with divisible deliveries and pickups. *Computers & Operations Research*, 85, 71–86. <https://doi.org/10.1016/j.cor.2017.03.009>
- Prodhon, C. (2006). *Le problème de localisation-routage (The location-routing problem)* [University of Technology of Troyes]. <http://prodhonc.free.fr/publi/Thesis.pdf>
- Rafie-Majd, Z., Pasandideh, S. H. R., & Naderi, B. (2018). Modelling and solving the integrated inventory-location-routing problem in a multi-period and multi-perishable product supply chain with uncertainty: Lagrangian relaxation algorithm. *Computers and Chemical Engineering*, 109, 9–22. <https://doi.org/10.1016/j.compchemeng.2017.10.013>
- Rayat, F., Musavi, M., & Bozorgi-Amiri, A. (2017). Bi-objective reliable location-inventory-routing problem with partial backordering under disruption risks: A modified AMOSA approach. *Applied Soft Computing*, 59, 622–643. <https://doi.org/10.1016/j.asoc.2017.06.036>
- Rivera-Royero, D., Galindo, G., & Yie-Pinedo, R. (2016). A dynamic model for disaster response considering prioritized demand points. *Socio-Economic Planning Sciences*, 55, 59–75. <https://doi.org/10.1016/j.seps.2016.07.001>
- Saragih, N. I., Bahagia, S. N., Suprayogi, & Syabri, I. (2019). A heuristic method for location-inventory-routing problem in a three-echelon supply chain system. *Computers and Industrial Engineering*, 127, 875–886. <https://doi.org/10.1016/j.cie.2018.11.026>
- Seow, K., & Sim, K. (2008). Collaborative assignment using belief-desire-intention agent modeling and negotiation with speedup strategies. *Information Sciences*, 178(4), 1110–1132. <https://doi.org/10.1016/j.ins.2007.09.024>
- Serrato-Garcia, M. A., Mora-Vargas, J., & Murillo, R. T. (2016). Multi objective optimization for humanitarian logistics operations through the use of mobile technologies. *Journal of Humanitarian Logistics and Supply Chain Management*, 6(3), 399–418. <https://doi.org/10.1108/JHLSCM-01-2015-0002>

- Sheu, J.-B. (2007). An emergency logistics distribution approach for quick response to urgent relief demand in disasters. *Transportation Research Part E: Logistics and Transportation Review*, 43(6), 687–709. <https://doi.org/10.1016/j.tre.2006.04.004>
- Stark, N., & Salto, C. (2005). Algoritmos Evolutivos Paralelos Distribuidos para resolver Problemas de Optimización. *Universidad Nacional de La Plata*. http://sedici.unlp.edu.ar/bitstream/handle/10915/22953/Documento_completo.pdf?sequence=1&isAllowed=y
- Sudholt, D. (2015). Parallel Evolutionary Algorithms. In Kacprzyk J., Pedrycz W. (eds), *Springer Handbook of Computational Intelligence* (pp. 929–959). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-662-43505-2_46
- Talbi, E. G. (2002). A taxonomy of hybrid metaheuristics. *Journal of Heuristics*, 8(5), 541–564. <https://doi.org/10.1023/A:1016540724870>
- Talebian Sharif, M., & Salari, M. (2015). A GRASP algorithm for a humanitarian relief transportation problem. *Engineering Applications of Artificial Intelligence*, 41, 259–269. <https://doi.org/10.1016/j.engappai.2015.02.013>
- Tavakkoli-Moghaddam, R., & Raziei, Z. (2016). A New Bi-Objective Location-Routing-Inventory Problem with Fuzzy Demands. *IFAC-PapersOnLine*, 49(12), 1116–1121. <https://doi.org/10.1016/j.ifacol.2016.07.646>
- Tavakkoli-Moghaddam, Reza, Forouzanfar, F., & Ebrahimnejad, S. (2013). Incorporating location, routing, and inventory decisions in a bi-objective supply chain design problem with risk-pooling. *Journal of Industrial Engineering International*, 9(1). <https://doi.org/10.1186/2251-712X-9-19>
- Tavana, M., Abtahi, A.-R., Di Caprio, D., Hashemi, R., & Yousefi-Zenouz, R. (2018). An integrated location-inventory-routing humanitarian supply chain network with pre- and post-disaster management considerations. *Socio-Economic Planning Sciences*, 64, 21–37. <https://doi.org/10.1016/j.seps.2017.12.004>
- Thomas, A., & Kopczak, L. (2005). From logistics to supply chain management: the path forward in the humanitarian sector. *Fritz Institute*, 1–15. <http://www.fritzinstitute.org/PDFs/WhitePaper/FromLogisticsto.pdf>
- Toutouh, J., & Alba, E. (2012). Parallel Swarm Intelligence for VANETs Optimization. *2012 Seventh International Conference on P2P, Parallel, Grid, Cloud and Internet Computing*, 285–290. <https://doi.org/10.1109/3PGCIC.2012.53>
- Tsai, C. F., Tsai, C. W., & Tseng, C. C. (2004). A new hybrid heuristic approach for solving large traveling salesman problem. *Information Sciences*, 166(1–4), 67–81. <https://doi.org/10.1016/j.ins.2003.11.008>
- Vahdani, B., Veysmoradi, D., Noori, F., & Mansour, F. (2018). Two-stage multi-objective location-routing-inventory model for humanitarian logistics network design under uncertainty. *International Journal of Disaster Risk Reduction*, 27(May 2017), 290–306. <https://doi.org/10.1016/j.ijdrr.2017.10.015>
- Veldhuizen, D. A., Zydallis, J. B., & Lamont, G. B. (2003). Considerations in engineering parallel multiobjective evolutionary algorithms. *IEEE Transactions on Evolutionary Computation*,

- 7(2), 144–173. <https://doi.org/10.1109/TEVC.2003.810751>
- Veldhuizen, D., & Lamont, G. (2000). Multiobjective Evolutionary Algorithms: Analyzing the State-of-the-Art. *Evolutionary Computation*, 8(2), 125–147. <https://doi.org/10.1162/106365600568158>
- Vidal, C. J., & Goetschalckx, M. (1997). Strategic production-distribution models: A critical review with emphasis on global supply chain models. *European Journal of Operational Research*, 98(1), 1–18. [https://doi.org/10.1016/S0377-2217\(97\)80080-X](https://doi.org/10.1016/S0377-2217(97)80080-X)
- Villaverde, A. F., Egea, J. A., & Banga, J. R. (2012). A cooperative strategy for parameter estimation in large scale systems biology models. *BMC Systems Biology*, 6(1), 75. <https://doi.org/10.1186/1752-0509-6-75>
- Wang, Y., Jung, K.-A., Yeo, G.-T., & Chou, C.-C. (2014). Selecting a cruise port of call location using the fuzzy-AHP method: A case study in East Asia. *Tourism Management*, 42, 262–270. <https://doi.org/10.1016/j.tourman.2013.11.005>
- World Bank, United Nations (2010). In *Natural Hazards, UnNatural Disasters*. The World Bank. <https://doi.org/10.1596/978-0-8213-8050-5>
- Wu, W., Zhou, W., Lin, Y., Xie, Y., & Jin, W. (2021). A hybrid metaheuristic algorithm for location inventory routing problem with time windows and fuel consumption. *Expert Systems with Applications*, 166, 114034. <https://doi.org/10.1016/j.eswa.2020.114034>
- Yi, W., & Özdamar, L. (2007). A dynamic logistics coordination model for evacuation and support in disaster response activities. *European Journal of Operational Research*, 179(3), 1177–1193. <https://doi.org/10.1016/j.ejor.2005.03.077>
- Yu, L., Yang, H., Miao, L., & Zhang, C. (2019). Rollout algorithms for resource allocation in humanitarian logistics. *IIE Transactions*, 51(8), 887–909. <https://doi.org/10.1080/24725854.2017.1417655>
- Yu, L., Zhang, C., Yang, H., & Miao, L. (2018). Novel methods for resource allocation in humanitarian logistics considering human suffering. *Computers & Industrial Engineering*, 119, 1–20. <https://doi.org/10.1016/j.cie.2018.03.009>
- Yuchi, Q., Wang, N., He, Z., & Chen, H. (2018). Hybrid heuristic for the location-inventory-routing problem in closed-loop supply chain. *International Transactions in Operational Research*. <https://doi.org/10.1111/itor.12621>
- Yushimito, W. F., Jaller, M., & Ukkusuri, S. (2012). A Voronoi-Based Heuristic Algorithm for Locating Distribution Centers in Disasters. *Networks and Spatial Economics*, 12(1), 21–39. <https://doi.org/10.1007/s11067-010-9140-9>
- Zhalechian, M., Tavakkoli-Moghaddam, R., Zahiri, B., & Mohammadi, M. (2016). Sustainable design of a closed-loop location-routing-inventory supply chain network under mixed uncertainty. *Transportation Research Part E: Logistics and Transportation Review*, 89, 182–214. <https://doi.org/10.1016/j.tre.2016.02.011>
- Zhao, J., & Ke, G. Y. (2017). Incorporating inventory risks in location-routing models for explosive waste management. *International Journal of Production Economics*, 193, 123–136. <https://doi.org/10.1016/j.ijpe.2017.07.001>

- Zhu, L., Gong, Y., Xu, Y., & Gu, J. (2019). Emergency relief routing models for injured victims considering equity and priority. *Annals of Operations Research*, 283, 1573–1606. <https://doi.org/10.1007/s10479-018-3089-3>
- Zitzler, E., Deb, K., & Thiele, L. (2000). Comparison of Multiobjective Evolutionary Algorithms: Empirical Results. *Evolutionary Computation*, 8(2), 173–195. <https://doi.org/10.1162/106365600568202>
- Zitzler, E., Laumanns, M., & Bleuler, S. (2003). A Tutorial on Evolutionary Multiobjective Optimization. *Swiss Federal Institute of Technology (ETH) Zurich*. <https://www.cs.cinvestav.mx/~emooworkgroup/zitzler04.pdf>
- Zitzler, E., Laumanns, M., & Thiele, L. (2001). Improving the Strength Pareto Evolutionary Algorithm. *Swiss Federal Institute of Technology (ETH) Zurich*. <https://doi.org/10.3929/ethz-a-004284029>