

Un algoritmo genético para el diseño de una red de logística integrada directa e inversa

Edwing Duvan Hernández Herrera y Jerson Alexander Torres Fernández

Trabajo de Grado para optar al título de Ingeniero Industrial

Director:

Henry Lamos Díaz

Ph.D. Física - Matemática

Grupo de Investigación:

Organización y Optimización de Sistemas Productivos, Administrativos y Logísticos (OPALO)

Universidad Industrial de Santander

Faculta de Ingeniería Fisicomecánicas

Escuela de Estudios Industriales y Empresariales

Bucaramanga

2021

Tabla de contenido

Introducción	10
1. Planteamiento del Problema	13
2. Justificación del Proyecto	15
3. Objetivos	18
3.1 Objetivo general.....	18
3.2 Objetivos específicos	18
4. Revisión de la Literatura.....	18
4.1 Análisis Bibliométrico	19
4.2 Análisis preliminar de la literatura.....	25
4.3 Marco de antecedentes	29
4.3.1 El diseño de la red logística y su enfoque hacia la integración.	29
4.3.2 Modelos matemáticos aplicados en los problemas de la CS.....	33
4.3.3 Enfoques de solución heurísticos comúnmente abordados.....	36
5. Marco Teórico.....	39
5.1 Logística directa.....	39
5.2 Logística Inversa.....	40
5.3 Cadena de suministro CLSC.....	41
5.4 Programación Lineal.....	42

5.4.1 Programación lineal entera	43
5.4.2 Programación entera binaria	43
5.4.3 Programación lineal entera mixta	44
5.5 Optimización multiobjetivo	44
5.5.1 Métodos exactos.....	46
5.5.2 Métodos heurísticos	47
5.6 Método de valoración del ciclo de vida (LCA)	47
5.7 Algoritmo genético	49
5.7.1 Codificación del cromosoma	50
5.7.2 Función de aptitud.....	52
5.7.3 Selección por ruleta.....	53
5.7.4 Selección por torneo.	53
5.7.5 Operador de cruce	53
5.7.6 Operador de mutación.....	55
5.7.7 Otros operadores del GA	56
6. Diseño y Modelamiento del Problema.....	56
6.1 Definición del Problema	57
6.2 Formulación Matemática	59
6.3 Obtención de los datos	70
7. Algoritmo Genético propuesto.....	71

7.1 Codificación de las soluciones.....	71
7.2 Decodificación del cromosoma.....	73
7.3 Evaluación de la Aptitud.....	78
7.3.1 Suma ponderada.....	79
7.3.2 Elitismo.....	81
7.3.3 Selección.....	81
7.3.4 Cruce.....	82
7.3.5 Mutación.....	85
8. Rendimiento del Algoritmo Genético.....	88
8.1 Ajuste de parámetros del algoritmo genético.....	89
8.1.1 Tiempo de ejecución.....	90
8.1.2 Cantidad de soluciones no dominadas.....	90
8.1.3 Instancias pequeñas.....	91
8.1.4 Instancias medianas.....	94
8.1.5 Instancias grandes.....	97
8.2 Comparación del AG con el MOMA.....	100
9. Conclusiones.....	103
10. Recomendaciones.....	104
Referencias Bibliográficas.....	106

Lista de Tablas

Tabla 1. Cumplimiento de los objetivos del proyecto	13
Tabla 2. Palabras clave de las publicaciones	20
Tabla 3. Número de publicaciones por autor	24
Tabla 4. Número de referencias por autor	24
Tabla 5. Codificación del problema de diseño de red logística	26
Tabla 6. Codificación del problema de diseño de red logística	27
Tabla 7. Artículos clasificados y codificados	28
Tabla 8. Costos unitarios de transporte del distribuidor j al cliente k.....	74
Tabla 9. Asignación de envíos del distribuidor j al cliente k.....	75
Tabla 10. Niveles de los factores del diseño 3^4	89
Tabla 11. Problemas de prueba pequeños para el rendimiento del AG.....	91
Tabla 12. Problemas de prueba medianos para el rendimiento del AG.....	94
Tabla 13. Problemas de prueba grandes para el rendimiento del AG.....	97
Tabla 14. Comparación entre el AG y el MOMA	101

Lista de Figuras

Figura 1. Ecuación de búsqueda	19
Figura 2. Términos excluidos de la ecuación de búsqueda.....	20
Figura 3. Número de publicaciones por año	21
Figura 4. Número de publicaciones por país	22
Figura 5. Colaboraciones investigativas entre países	23
Figura 6. Modelo matemático del problema de optimización	44
Figura 7. Representación del Frente de Pareto	45
Figura 8. Funcionamiento de un Algoritmo Genético	50
Figura 9. Individuo genético binario.....	51
Figura 10. Cruce de un punto.....	54
Figura 11. Cruce de dos puntos	54
Figura 12. Cruce uniforme.....	55
Figura 13. Diseño de la red logística integrada	58
Figura 14. Estructura del modelo de la IFRLN	70
Figura 15. Cromosoma de la CLSC codificado.....	72
Figura 16. Pseudocódigo de la codificación del cromosoma de la CLSC.....	72
Figura 17. Segmento j-k de un cromosoma de la CLSC codificado.....	73
Figura 18. Árbol de transporte del nodo j-k de la CLSC.....	75
Figura 19. Pseudocódigo del algoritmo de decodificación basada en la prioridad.....	76
Figura 20. Pseudocódigo del algoritmo de decodificación de la red completa	78
Figura 21. Selección por Torneo.....	82

Figura 22. Vector binario del cruce	83
Figura 23. Procedimiento de cruce de dos padres	84
Figura 24. Procedimiento de cruce de dos padres	84
Figura 25. Vector binario de la mutación	85
Figura 26. Procedimiento de mutación del descendiente	86
Figura 27. Pseudocódigo del algoritmo genético de la CLSC.....	87
Figura 28. Efectos principales para el tiempo en instancias pequeñas	92
Figura 29. Efectos principales para soluciones no dominadas en instancias pequeñas...	93
Figura 30. Soluciones obtenidas durante una corrida en instancias pequeñas.....	94
Figura 31. Efectos principales para el tiempo en instancias medianas	95
Figura 32. Efectos principales para soluciones no dominadas en instancias medianas...	96
Figura 33. Soluciones obtenidas durante una corrida en instancias medianas	97
Figura 34. Efectos principales para el tiempo en instancias grandes.....	98
Figura 35. Efectos principales para soluciones no dominadas en instancias grandes	99
Figura 36. Soluciones obtenidas durante una corrida en instancias grandes	99
Figura 37. Intervalos de cantidad de soluciones no dominadas del AG y el MOMA ...	102
Figura 38. Intervalos del tiempo de ejecución del AG y el MOMA	102

Lista de Apéndices

Los apéndices están adjuntos y pueden visualizarse en la sala de base de datos de la

Biblioteca UIS

Apéndice A. Algoritmo Genético

Apéndice B. Datos de entrada del Algoritmo Genético

Apéndice C. Artículo Publicable

Apéndice D. Resultados obtenidos del diseño factorial

Apéndice E. Problemas de prueba de comparación entre MOMA y AG

Apéndices F. Tratamientos de las corridas del Algoritmo Genético

Resumen

Título: Un algoritmo genético para el diseño de una red de logística integrada directa e inversa*

Autores: Edwing Duvan Hernández Herrera, Jerson Alexander Torres Fernández

Palabras Clave: Cadenas de suministro, multiobjetivo, algoritmo genético, programación entera, optimización, logística, costos, localización, toma de decisiones, logística inversa.

Descripción:

El problema de diseño de la red logística abordado desde el enfoque de la integración de la red directa e inversa, con el fin de consolidar cadenas de suministro de circuito cerrado (CLSC), es la clave para enfrentar los desafíos emergentes de la transición de las empresas hacia la economía circular y el desarrollo sostenible. Este tipo de red integrada permite una mayor eficiencia y ofrece ventajas en costos e impacto ambiental durante la operación de recolección, reutilización y reciclaje de residuos. En este contexto, el presente proyecto propone un diseño de red logística integrada directa e inversa para la recolección de residuos eléctricos y electrónicos (RAEE), con el fin de apoyar las decisiones de nivel estratégico de las empresas del país. La configuración de la red está basada en el trabajo de Pishvaei, quien resalta el aporte novedoso de la inclusión de plantas híbridas de distribución y recolección/inspección. El problema de asignación de recursos y aperturas de instalaciones se resuelve mediante un modelo de programación lineal entera mixta (MILP) con dos funciones objetivo: maximización de los costos totales y minimización del impacto ambiental, mediante la metodología de valoración del ciclo de vida del producto (LCA). Para la resolución del modelo se propone un algoritmo genético con codificación basada en la prioridad, función de aptitud basada en pesos aleatorios, método de selección por torneo y operadores de cruce y mutación basados en segmento. Para medir el rendimiento del algoritmo, se realiza un diseño de experimentos factorial de la forma 3^4 para tres tamaños de problema (pequeño, mediano y grande) y un contraste con el algoritmo mimético multiobjetivo (MOMA) desarrollado por Pishvaei. Los resultados muestran que, para cualquier tamaño de problema, el mejor desempeño del algoritmo se obtiene con una combinación de 500 iteraciones y 100 individuos en la población inicial. Finalmente, la prueba de contraste entre el AG y el MOMA reveló que el algoritmo genético propuesto es inferior en la cantidad de soluciones no dominadas encontradas. Es posible que esto se deba a las estrategias de búsqueda intensificada incorporadas en el MOMA. Sin embargo, esta diferencia de capacidad de búsqueda está justificada por el ahorro de tiempo de ejecución que presenta el AG.

*Trabajo de Grado

**Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Industrial. Director: Henry Lamos Diaz. Ph D Físico – Matemático

Abstract

Title: A genetic algorithm for integrated forward / reverse logistics network design

Authors: Edwing Duvan Hernández Herrera, Jerson Alexander Torres Fernández

Key Words: Supply chains, Multiobjective, Genetic algorithm, Integer programming, Optimization, Logistics, costs, Location, Decision making, Reverse logistics.

Description:

The logistics network design problem approached from the approach of direct and reverse network integration, in order to consolidate closed loop supply chains (CLSC), is the key to face the emerging challenges of the transition of the companies towards the circular economy and sustainable development. This type of integrated network allows greater efficiency and offers advantages in costs and environmental impact during the waste collection, reuse and recycling operation. In this context, this project proposes a direct and inverse integrated logistics network design for the collection of electrical and electronic waste (WEEE), in order to support the strategic level decisions of the country's companies. The configuration of the network is based on the work of Pishvae, who highlights the novel contribution of the inclusion of hybrid plants for distribution and collection / inspection. The problem of resource allocation and facility openings is solved using a mixed integer linear programming model (MILP) with two objective functions: maximization of total costs and minimization of environmental impact, through the product life cycle assessment methodology. (LCA). For the resolution of the model, a genetic algorithm with priority-based coding, fitness function based on random weights, tournament selection method and segment-based crossover and mutation operators is proposed. To measure the performance of the algorithm, a factorial design of experiments of the form 3^4 is performed for three problem sizes (small, medium and large) and a contrast with the multiobjective mimetic algorithm (MOMA) developed by Pishvae. The results show that, for any size of problem, the best performance of the algorithm is obtained with a combination of 500 iterations and 100 individuals in the initial population. Finally, the contrast test between the GA and the MOMA revealed that the proposed genetic algorithm is inferior in the amount of non-dominated solutions found. This may be due to the intensified search strategies built into the MOMA. However, this difference in search capacity is justified by the execution time savings that the AG presents.

*Degree Work

**Faculty of Physicomechanical Engineers. School of Industrial and Business Studies. Director: Henry Lamos Diaz. Ph D Physical – Mathematical.

Introducción

Con la creciente preocupación por el impacto ambiental, en los últimos años, la sociedad ha iniciado una transformación hacia la protección de los recursos naturales y el desarrollo sostenible, exigiendo a las empresas la adopción de nuevas prácticas de manejo de materias primas, manufactura y logística que hagan más eficiente su operación. Como alternativa de solución, surgió en los años 70 el concepto de “Economía Circular”.

Según Preston (2012):

“La idea central de la economía circular es que los sistemas productivos abiertos – en los que se extraen recursos, se utilizan para fabricar productos y se convierten en desechos después de que el producto se consume – deben reemplazarse por sistemas que reutilicen los recursos y conserven energía”. A partir de esta definición, se establece como estrategia principal la re inserción de productos consumidos por los clientes finales, en forma de materia prima, a un nuevo ciclo productivo presentando nuevos desafíos para la gestión de la cadena de suministro.

Diseñar redes logísticas de manera integrada, con el fin de consolidar cadenas de suministro de circuito cerrado (CLSC), es la clave para enfrentar dichos desafíos y se ha convertido en materia de estudio en el campo de la optimización e investigación de operaciones. En la literatura reciente se han propuesto diversos modelos matemáticos para diseñar redes de flujo directo, inverso e integrado que sean eficientes en costos, reduzcan el impacto ambiental y maximicen su cobertura y capacidad de respuesta. Por otra parte, frecuentemente se recurre a enfoques de solución heurísticos y, en investigaciones como la de Alshamsi & Diabat (2017), se ha comprobado el alto rendimiento de los algoritmos genéticos en la resolución de estos modelos.

Uno de los modelos más relevantes en este campo de investigación, de la última década, es el diseño de red logística integrada propuesto por Pishvae et al. (2010), quien afirma que “el modelo es de carácter genérico y puede ser aplicado a las industrias de equipo electrónico y digital o al sector automotriz”.

En Colombia, uno de los sectores con mayor generación de residuos es precisamente la industria de equipos eléctricos y electrónicos, conocidos como RAEE. “Según la Política Nacional para la Gestión Integral de RAEE, son los Residuos de Aparatos Eléctricos o Electrónicos, que cuando se desechan o descartan de forma incorrecta por parte de su dueño, pueden contaminar el suelo, las fuentes de agua, el aire y afectar la salud, pues contienen sustancias tóxicas como: plomo, cadmio, mercurio (...).” (EcoComputo, 2020).

Por esta razón, el gobierno tiene debidamente regulada la gestión de estos residuos a fin de comprometer a las empresas del país con el tratamiento y disposición responsable de los mismos.

A partir de la situación descrita y la evidente falta de integración entre la logística inversa y la logística tradicional (directa), tanto en investigación como en las cadenas de suministro del entorno económico de Colombia, en el presente proyecto de grado modalidad de investigación se busca desarrollar un modelo para el diseño de una red logística integrada, basado en el trabajo realizado por Pishvae et al. (2010), con el fin de abordar nuevas perspectivas dentro del campo de investigación y aportar a la toma de decisiones de las empresas del país frente a la problemática planteada.

El modelo será resuelto mediante un algoritmo genético (GA) que, a diferencia del trabajo original, buscará minimizar los costos fijos de abrir una nueva instalación, los costos de transporte y el impacto ambiental. Para medir el rendimiento del algoritmo, se hace uso de una serie de

problemas de prueba basados en dos casos de estudio de la vida real proporcionados en instancias de la literatura como (Fathollahi-Fard & Hajiaghaei-Keshteli, 2018) y (Zohal & Soleimani, 2016).

Tabla 1.

Cumplimiento de los objetivos del proyecto

Objetivos	Cumplimiento
Realizar una revisión de la literatura enfocada en el problema de diseño de redes de logística inversa, su planteamiento mediante modelos de optimización y los algoritmos de solución.	Numeral 4
Desarrollar la formulación matemática del modelo de logística integrada directa e inversa empleado.	Numeral 6
Desarrollar un algoritmo genético (AG) para la resolución del modelo de logística integrada directa e inversa.	Numeral 7
Medir el rendimiento del algoritmo genético a partir de pruebas de comparación con instancias de la literatura como (Fathollahi-Fard & Hajiaghaei-Keshteli, 2018) y (Zohal & Soleimani, 2016).	Numeral 8
Realizar un artículo académico de carácter publicable basado en el trabajo de investigación realizado.	Apéndice C

1. Planteamiento del Problema

El crecimiento acelerado de las principales economías del mundo, producto de la apertura de los mercados y los grandes avances científicos y tecnológicos de años recientes, sumado a la cultura consumista de la sociedad moderna han desembocado en modelos de producción

insostenibles. Las fuentes de energía y los recursos naturales han empezado a agotarse y los grandes volúmenes de desechos abandonados en rellenos sanitarios están causando significativos daños al medioambiente. Para contrarrestar esta situación, los gobiernos de cada país, los consumidores y las diversas industrias han centrado sus esfuerzos en prácticas ambientalmente sostenibles como recolectar, reciclar, reutilizar, reparar y dar disposición adecuada a los residuos no biodegradables.

Entre los principales desechos contaminantes, existe un especial interés a nivel mundial por los residuos de aparatos eléctricos y electrónicos (RAEE). Este tipo de aparatos cuenta con un ciclo de vida relativamente corto y son reemplazados por los usuarios a un ritmo intensivo marcado por los lanzamientos de nuevas tecnologías y diseños. Según el reporte de 2014 sobre el monitoreo global de este tipo de desechos realizado por el Instituto para el Estudio Avanzado de la Sostenibilidad de la Universidad de la Naciones Unidas, la generación mundial de RAEE para ese año fue de 41, 8 millones de toneladas; de las cuales, en Colombia, se generaron 252000 toneladas, equivalentes a 5,3 kilogramos por habitante. (Baldé, 2015, citado en *Política Nacional RAEE 2017.Pdf*, n.d.).

La principal preocupación del gobierno colombiano es que un gran porcentaje de estos RAEE terminan siendo arrojados en contenedores de residuos ordinarios, ríos, quebradas, bosques, etc., ocasionando que sus componentes tóxicos contaminen las fuentes hídricas, se liberen gases efecto invernadero y se afecte la fauna, la flora y la salud de las personas. Por esta razón, el país ha venido reglamentando y adelantando políticas para garantizar el desarrollo sostenible de las empresas productoras y comercializadoras de este tipo de artículos. Entre la legislación relacionada se pueden encontrar la Ley 1672 de 2013 del Ministerio de Ambiente y Desarrollo Sostenible, por la cual se establecen los lineamientos para la adopción de una política pública de gestión integral

de RAEE; la Política de Residuos o Desechos Peligrosos; la Política de Producción y Consumo Sostenible y la Política Nacional de Educación Ambiental hasta llegar a la Política Nacional de Gestión Integral de RAEE del año 2017. Esta política está basada en la ley 1672 de 2013 y recoge todas las disposiciones de años anteriores. En resumen, sus tres estrategias base son:

1. La sensibilización y educación sobre la producción y el consumo responsable de AEE.
2. Desarrollo y establecimiento de instrumentos para la recolección y gestión de residuos de aparatos eléctricos y electrónicos (RAEE).
3. Transferencia tecnológica y desarrollo de infraestructura ambientalmente segura para el aprovechamiento de los residuos de aparatos eléctricos y electrónicos (RAEE). (*Política Nacional RAEE 2017.Pdf*, n.d.).

Considerando la segunda estrategia propuesta en el plan de acción de la política nacional, resulta evidente que las empresas estarán obligadas a disponer de canales de recolección de RAEE e infraestructura adecuada para el tratamiento, la disposición y la recuperación de los mismos. En este sentido, este proyecto busca aportar a la transición de dichas empresas mediante una herramienta de toma de decisiones efectiva, que les permita considerar los costos asociados al manejo de los RAEE, el impacto ambiental generado durante la operación y los tipos de instalaciones y volúmenes necesarios para mantener la factibilidad del negocio.

2. Justificación del Proyecto

El país se encuentra en un momento clave de transición hacia la implantación de la economía circular, donde el gobierno a través de su Plan Nacional de Gestión de RAEE ha definido la hoja de ruta a seguir hasta el año 2032. En este plan se consignan las obligaciones, los beneficios

y las estrategias que deberán seguir las empresas presentes en el territorio nacional respecto a la producción y el manejo de los desechos de aparatos eléctricos y electrónicos. En este contexto, el presente proyecto surge para apoyar las decisiones de nivel estratégico que deberán afrontar las empresas del país para adaptarse a las nuevas regulaciones. Además de cumplir con la legislación vigente, la gestión de los RAEE presenta nuevas oportunidades para empresas, emprendedores y para la población asalariada en general.

Uno de los principales beneficios de la gestión de los RAEE es la generación de empleos en diferentes actividades del proceso. Se estima que en Europa el reciclaje global ocupa cerca de 1,5 millones de personas; sin embargo, desde que se implementaron políticas de gestión de RAEE se produjo un crecimiento en el número de empleos en todos los países europeos. Por ejemplo, en Alemania se abrieron 3870 nuevos puestos de trabajo, mientras que en Lituania la cifra fue de 290 empleos relacionados con el reciclaje de RAEE. Además, la reutilización de estos artículos emplea a unas 42000 personas, mientras que la preparación para la reutilización de RAEE puede generar hasta 5 veces más empleos por cada 1000 toneladas que su reciclaje. (Pronet-ISE, 2013, citado en *Política Nacional RAEE 2017.Pdf*, n.d.). En países en vía de desarrollo, como Nigeria y Ghana, las actividades de reacondicionamiento de RAEE proporcionan empleo a más de 30000 personas en cada país. (United Nations University/StEP Initiative, 2014, citado en *Política Nacional RAEE 2017.Pdf*, n.d.).

Otros beneficios identificados tras la implantación de un sistema de gestión de RAEE son los ahorros económicos para las empresas; en Europa, la reutilización de RAEE significó un ahorro hasta de 720 millones de libras; la mejora de la imagen corporativa y el aumento en la calidad de vida y la salud de las personas. (Pronet-ISE, 2013, citado en *Política Nacional RAEE 2017.Pdf*, n.d.).

Por otra parte, desde el punto de vista académico, este proyecto abarca temas de actualidad como la medición del impacto ambiental de las actividades logísticas mediante el método de valoración del ciclo de vida del producto (LCA), abordado por (Fathollahi-Fard & Hajiaghaei-Keshteli, 2018); la integración de la logística tradicional con la logística inversa para la consolidación de la CLSC, propuesta por (Pishvae et al., 2010) y sirve de referencia para futuras investigaciones, ya que esta temática no está lo suficientemente desarrollada en el país.

3. Objetivos

3.1 Objetivo general

Desarrollar un algoritmo genético para el diseño de una red de logística integrada directa e inversa.

3.2 Objetivos específicos

- Realizar una revisión de la literatura enfocada en el problema de diseño de redes de logística inversa, su planteamiento mediante modelos de optimización y los algoritmos de solución.
- Desarrollar la formulación matemática del modelo de logística integrada directa e inversa empleado.
- Desarrollar un algoritmo genético (AG) para la resolución del modelo de logística integrada directa e inversa.
- Medir el rendimiento del algoritmo genético a partir de pruebas de comparación con instancias de la literatura como (Fathollahi-Fard & Hajiaghahi-Keshteli, 2018) y (Zohal & Soleimani, 2016).
- Realizar un artículo académico de carácter publicable basado en el trabajo de investigación realizado.

4. Revisión de la Literatura

Para abordar el problema planteado en la presente investigación, es necesario elaborar un análisis exhaustivo de los trabajos desarrollados con anterioridad en esta materia a fin de establecer las bases conceptuales y comprender las mejores prácticas para alcanzar el objetivo de

investigación propuesto. Para ello, se presenta a continuación un análisis preliminar de la literatura, de carácter cuantitativo, y posteriormente, se establece un marco de antecedentes; el cual es de naturaleza cualitativa.

4.1 Análisis Bibliométrico

Con el fin de monitorear el comportamiento de la investigación en temas relacionados con el problema de diseño de redes de logística directa e inversa, dentro de las cadenas de suministro de ciclo cerrado, e identificar la tendencia en modelos matemáticos, algoritmos de resolución y métodos de medición del rendimiento de los mismos, en los últimos 10 años, se realiza una búsqueda en la base de datos SCOPUS, recurso dispuesto por la Universidad Industrial de Santander; empleando la siguiente ecuación. (Figura 1).

Figura 1.

Ecuación de búsqueda

Scopus:

```
( TITLE-ABS-KEY ( ( "integrated logistics" OR "supply chain" OR "circ*
economy" OR "CLSC*" OR "logistics" ) AND ( "inverse" OR "reverse" OR "green" OR "forward
/inverse" OR "forward/reverse" OR "forward" OR "closed loop" ) ) AND (design*
OR redesign* OR optim* OR network OR "facility location") AND ( ( "genetic
algorithm*" OR algorithm* OR nsga* OR "GA" ) AND ( " single-objective" OR "multi-
objective" OR "bi-objective" ) ) )
```

Tras una revisión inicial de los resultados obtenidos en las condiciones previamente descritas, se decide excluir los siguientes términos en la ecuación de búsqueda por considerarse no relacionados con el tema de la presente investigación. (Figura 2)

Figura 2.*Términos excluidos de la ecuación de búsqueda***Scopus:**

*AND NOT TITLE-ABS-KEY ("vehicle routing problem" OR "production planning" OR "MRP"
OR "inventory management" OR "inventory decision*" OR "provider selection" OR "supplier selection"
OR pickup OR forecasting)*

Posteriormente, se filtran los resultados limitando la ventana de tiempo al período comprendido entre el año 2009 y 2020, y seleccionando el tipo de los documentos como “artículos”. Con esto, se obtienen 130 documentos que sirven de base para realizar el análisis, mediante el uso del software VANTAGE POINT, que se presenta a continuación.

Con el fin de validar la exactitud de la ecuación de búsqueda y establecer los términos más relevantes, el primer punto del análisis se centra en las palabras clave y su frecuencia de aparición. Los resultados con las 10 palabras más utilizadas se recogen en la Tabla 2.

Tabla 2.*Palabras clave de las publicaciones*

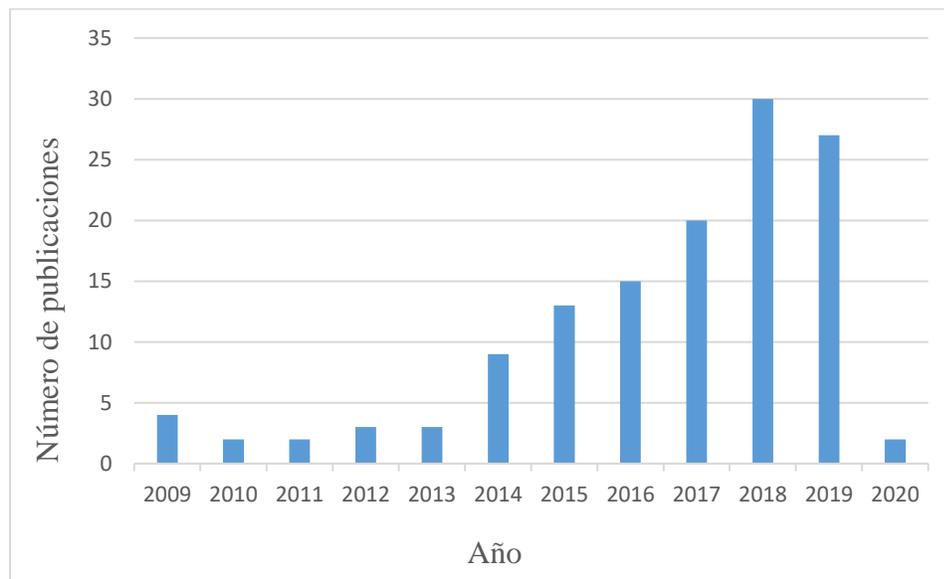
<i>Palabras clave</i>	<i>Número de publicaciones</i>
Supply Chains	69
Multi Objective	68
Genetic Algorithm	35
Integer Programming	30
Optimization	30
Logistics	28
Costs	20
Location	20
Decision Making	18
Reverse Logistics	17

Al realizar un análisis de la ocurrencia de dichas palabras, se encuentran 98 artículos que incluyen al menos una de las palabras clave más destacadas. Sin embargo, a partir de la coocurrencia entre las palabras del autor y las palabras de la Tabla 2, se reduce esta cifra a 64 registros.

En el siguiente paso, se presenta un diagrama de barras que muestra el número de publicaciones realizadas por año. En la gráfica se puede ver que la mayor actividad se ha presentado entre los años 2014 y 2019, con porcentajes entre el 7% y el 21%, representado un 89% del total de artículos publicados durante el período relevante a la presente investigación. (Figura 3).

Figura 3.

Número de publicaciones por año

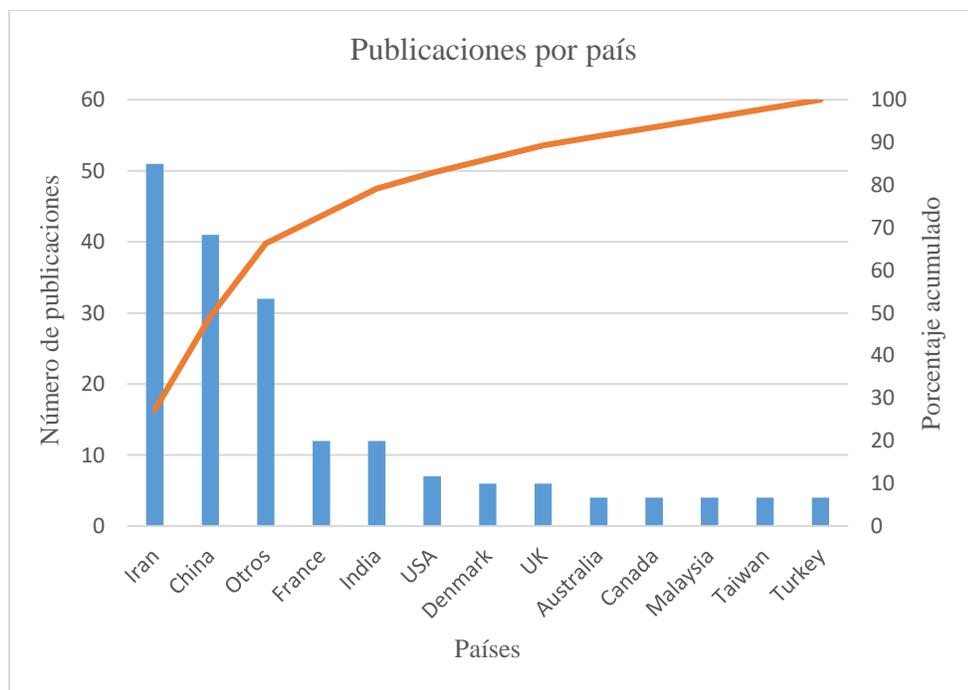


Luego de conocer los años con mayor número de publicaciones, se pasa a identificar las zonas donde se origina la mayor cantidad de estas. La Figura 4 presenta un diagrama de Pareto con la frecuencia de publicaciones por país y el peso acumulado respecto a los demás. Allí, se

identifican a China e Irán como los países con mayor investigación en el tema tratado, representando aproximadamente el 50% de la producción mundial. Otros países que resaltan, aunque en menor proporción, son Francia, India y Estados Unidos. En este punto, es importante aclarar que los países con menos de 3 publicaciones fueron reunidos en el grupo “Otros”. En total se obtuvieron 33 países en toda la muestra.

Figura 4.

Número de publicaciones por país



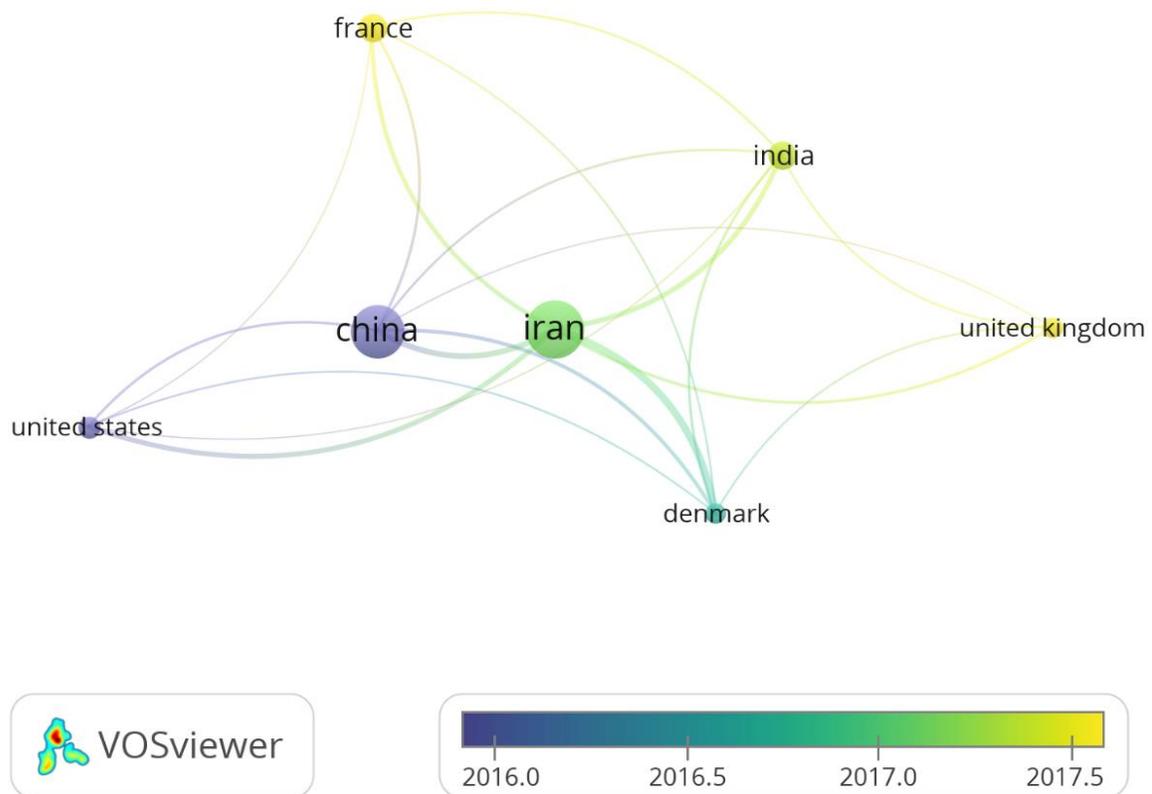
Al analizar las colaboraciones realizadas entre estos 5 países, se encuentra que efectivamente los países más influyentes son China e Irán. Y países como Dinamarca, Francia y Reino Unido, son zonas emergentes en este campo de estudio. (Figura 5).

La Figura 5 fue tomada de un análisis de coautoría entre países realizada en el software VOSVIEWER. En ella, se presenta un mapa con los 7 países con mayor número de publicaciones

en coautoría. Cada país está representado por un nodo y su relación con los demás por una línea. Al mismo tiempo, la cantidad actual de 98 artículos disminuye a 83.

Figura 5.

Colaboraciones investigativas entre países



Por otra parte, es imprescindible llevar a cabo un análisis de los principales autores para encontrar los referentes literarios y las tendencias de los últimos años en materia de conceptos, metodologías y avances. Para ello, se resumen en la Tabla 3 los 10 autores con mayor número de publicaciones.

Tabla 3.*Número de publicaciones por autor*

<i>Número de publicaciones</i>	<i>Autor</i>
7	Hajiaghaei-Keshteli, M.
5	Tavakkoli-Moghaddam, R.
4	Fathollahi-Fard, A.M.
4	Govindan, K.
3	Farrokhi-Asl, H.
3	Karimi, B.
3	Paydar, M.M.
3	Wang, L.
3	Wang, Y.
3	Xia, X.

Adicionalmente al número de artículos por autor, se hace necesario revisar el indicador de referencias. Como se puede observar en la Tabla 4, los autores más referenciados son Govindan, Pishvae, y Gen, m.

Tabla 4.*Número de referencias por autor*

<i>Autor</i>	<i>Citas</i>
govindan, k.	150
pishvae, m.s.	136
gen, m.	91
soleimani, h.	88
tavakkoli-moghaddam, r.	81
deb, k.	76
hajiaghaei-keshteli, m.	70
diabat, a.	67
kannan, g.	66
torabi, s.a.	66

Tras combinar los subconjuntos de datos de autores más referenciados y autores con mayor número de publicaciones, se obtienen 57 artículos.

Finalmente, los 57 documentos pasan a una etapa de revisión del resumen y/o la introducción, como último filtro de aprobación, y se obtiene un total de 38 publicaciones finales que serán la base del análisis literario.

4.2 Análisis preliminar de la literatura

La dirección de una organización involucra la toma de decisiones en tres distintos niveles: estratégico, táctico y operativo. De estos, el problema de diseño de la red logística como uno de los más importantes y complejos dentro de la gestión de la cadena de suministro, se encuentra clasificado entre las decisiones de nivel estratégico (Pishvae et al., 2010). Por esta razón, con el paso de los años los investigadores han abordado este problema desde distintas perspectivas. Al principio, la investigación se centró en el diseño de redes de logística directa o logística tradicional. Posteriormente, se amplió el modelo hacia las redes de logística inversa y su integración con la logística directa debido a que las compañías centraron su interés en este tipo de red como consecuencia del incremento de la conciencia social y ambiental, además de los beneficios económicos adicionales (Mehrbod et al., 2015). En los últimos años, este tipo de sistema integrado se ha ido transformando, dando lugar al concepto de cadena de suministro de circuito cerrado. A pesar de las diferencias existentes respecto a configuración y objetivos de cada uno de estos tipos de red, el problema de diseño generalmente se engloba en alguno de los siguientes enfoques:

- Problema de ruteo de vehículos.
- Problema de localización de instalaciones.
- Problema de selección de proveedores.
- Problema de gestión de inventario.
- Problema de asignación de recursos.
- Problema de definición de la capacidad del sistema.

- Problema de selección del medio de transporte.

Con estas consideraciones en mente, se decidió clasificar los documentos resultantes del análisis bibliométrico, haciendo uso de una adaptación del método de codificación propuesto por Devika et al. (2014), para facilitar su análisis en la presente sección. (Tabla 5)

Tabla 5.

Codificación del problema de diseño de red logística

Componentes del diseño	Abreviatura
<i>Tipo de Red</i>	
Logística directa	LD
Logística inversa	LI
Logística integrada	LIN
Cadena de Suministro de Circuito Cerrado	CSCC
<i>Función Objetivo</i>	
Costo / Ingreso	C
Capacidad de Respuesta	CR
Responsabilidad Social	S
Riesgo	R
Medioambiente	M
<i>Salidas del Modelo</i>	
Localización / Asignación	L
Cantidad transportada	CT
Modo de transporte	MT

Capacidad	C
Tecnología	T
Inventario	I
Precio del producto	PP

Tabla 6.

Codificación del problema de diseño de red logística

Componentes del diseño	Abreviatura
Cantidad producida	CP
Múltiples productos	MP
<i>Tipo de Modelo</i>	
Programación lineal entera mixta	MILP
Programación lineal difusa interactiva	IFMOLP
Programación no lineal entera mixta	MINLP
Programación matemática difusa	FMP
Programación por intervalos	IP
Programación estocástica	SP
Optimización robusta	RO

La clasificación de los artículos se resume en la Tabla 7. De allí, se destaca que la mayoría de los autores consultados han optado por plantear el problema de diseño de red logística como un modelo de programación lineal entera mixta. Adicionalmente, la revisión de la tabla sirve de guía para definir los tres temas en los que se centrará el análisis de antecedentes literarios, que son: el diseño de la red logística y su enfoque hacia la integración, modelos matemáticos aplicados a los problemas de la cadena de suministro y enfoques de solución heurísticos comúnmente abordados.

Tabla 7.
Artículos clasificados y codificados

Autor	Red	Objetivos	Modelo	Salidas	Algoritmo
(Jamshidi et al., 2012)	LD	C, M	MILP	L, TA, TM, MP	AM, Método Taguchi
(Sabegh et al., 2017)	LD	C, CR, M	MOP	L, TA, PQ	BP, AG, PSO
(Diabat & Deskoors, 2016)	LD	C	MINLP	L, TA, I	AG
(Govindan et al., 2016)	LI	C, M, S	FMP	L, TA, PQ, T	MOPSO
(Li et al., 2016)	LI	C, CR	MILP	L, TA, PQ	NSAG II
(Farrokhi-Asl et al., 2017)	LI	C, S	MOP	L, TM	NSAG II y PSO
(Shi et al., 2020)	LI	C, CR	MILP	L, TA	NSGA II local
(Alshamsi & Diabat, 2017)	LI	C	MILP	L, TA, TM, C, MP	AG
(Roghanian & Pazhoheshfar, 2014)	LI	C	PMILP	L, TA, MP	GA basado en prioridad
(Pishvae et al., 2010)	LIN	C, CR	MILP	L, C, TA, PQ	MOMA
(Soleimani et al., 2017)	CSCC	C, CR, R	MILP	L, TA, PQ, MP	AG
(Vahdani & Mohammadi, 2015)	CSCC	C, CR	RO-FMP	L, TA, PQ	SAICA
(Zohal & Soleimani, 2016)	CSCC	C, M	ILP	L, C, TA, TM, PQ	ACO y MOGA-II
(Sahebjamnia et al., 2018)	CSCC	C, M, S	MILP	L, C, TA, T, MP	AG, SA, TS, RDA
(Fathollahi-Fard et al., 2018)	CSCC	C, S, R	SMIP	L, TA, PQ, T	Metahurísticos Híbridos
(Fathollahi-Fard & Hajiaghaei-Keshteli, 2018)	CSCC	C, M, R	SP	L, TA, PQ, T	GA, KA, VNS, VCS
(Mirakhorli, 2014)	CSCC	C, CR	IFMOLP	L, TA, PQ	AG
(Shi et al., 2017)	CSCC	C, CR, M	MIP	L, TA, TM, PQ	NSAG II
(Hajiaghaei-Keshteli & Fathollahi Fard, 2019)	CSCC	C, S, M	MINLP	L, TA, PQ, T	AG, SA, TS
(Pedram et al., 2017)	CSCC	C, S	MILP	L, TA, PQ	NSGA II
(Liu et al., 2018)	CSCC	C, CR	MILP	L, TA, TM, MP	NSGA II y MOSA

4.3 Marco de antecedentes

Con el propósito de conocer las diferentes teorías que han surgido y profundizar en los componentes del problema de diseño más recientes, a continuación, se exponen los trabajos que se encuentran más relevantes para los tres focos temáticos antes mencionados.

4.3.1 El diseño de la red logística y su enfoque hacia la integración.

Según Govindan et al. (2015) “una cadena de suministro clásica o directa consiste de una red de proveedores, productores y distribuidores que está formada para producir y entregar un producto o servicio” (Citado en Soleimani et al., 2017). Por su parte, Stevens (1989) agrega que los objetivos principales de este tipo de red son mantener el más alto servicio al cliente, el mínimo nivel de inventario y el mínimo costo unitario. Y para lograrlo, se debe sincronizar dicha red desde el proveedor hasta el cliente (Citado en Diabat & Deskoors, 2016). Por tal motivo, el diseño de una red directa a menudo se centra en el problema de localización de centros de manufactura y distribución, transporte de productos, manejo de inventario, capacidad y asignación de zonas de consumo.

Un ejemplo que ilustra el diseño de una red logística clásica es presentado en el trabajo de Jamshidi et al. (2012), quienes consideran una cadena de suministro verde conformada por 5 nodos principales: proveedores, productores, almacenes, centros de distribución y clientes. Además, existen dos tipos de productos fluyendo dentro de la red (materias primas y productos terminados), para los cuales se cuenta con múltiples tipos de transporte entre los nodos. Las decisiones principales dentro del modelo son la localización y apertura de las plantas, la asignación de demandas entre nodos y la asignación del medio de transporte. Años más tarde, Zavvar Sabegh et al. (2017) presentaron una aplicación práctica para el diseño de redes logísticas directas con un enfoque más flexible; en su modelo buscan minimizar los costos, el impacto ambiental y los

esfuerzos humanitarios para la atención inmediata de desastres naturales mediante una cadena de suministro farmacéutica. Luego, comparan tres métodos de solución, tales como, la red neuronal de propagación (BP), el algoritmo genético (GA) y la red neuronal artificial. Donde se concluye que la red neuronal de propagación (BP) es la mejor opción para este tipo de diseño por su alto rendimiento y eficiencia de recursos en la planeación bajo circunstancias de adversidad. Con una configuración de red más sencilla, Diabat & Deskoores (2016) lograron desarrollar un modelo de programación no lineal entera mixta y resolverlo mediante un algoritmo genético, obteniendo muy buenas soluciones para las decisiones de localización y gestión de inventario con una sola función objetivo (Minimizar costos) y un único producto.

Con el avance de los años, se empezaron a considerar aspectos sostenibles, sociales e incluso se popularizó el término de logística verde. Todo este movimiento derivó en el surgimiento de una nueva línea de investigación dedicada al flujo inverso de productos dentro de la red. Meade et al. (2007) sostienen que todo este creciente interés e inversión en logística inversa se debe a dos razones principales. La primera de ellas, es la preocupación ambiental generada por el efecto que tienen los productos usados sobre la naturaleza. La segunda motivación son los beneficios económicos obtenidos del reciclaje de dichos productos. (Citado en Mirakhorli, 2014).

Una aplicación de este tipo de red es presentada por Alshamsi & Diabat (2017), quienes proponen un modelo de programación lineal entera mixta para administrar el flujo inverso de diferentes electrodomésticos en una región llamada GULF COOPERATION COUNCIL, compuesta por 6 países árabes. En su diseño de red aparecen nuevos tipos de instalaciones como centros de reciclaje, remanufactura y mercados secundarios que nunca habían sido tomados en cuenta dentro de las redes clásicas estudiadas hasta entonces. Por otra parte, dentro de los supuestos del modelo se consideran distintos modos de transporte con la opción de contratar terceros o

adquirir flota vehicular propia y la función de maximización de ganancias ahora incluye ahorros derivados de la reutilización de productos e ingresos provenientes de los mercados secundarios.

Otra forma de optimizar los beneficios de una red inversa es la minimización de los costos totales. Para tal fin, Roghanian & Pazhoheshfar (2014) diseñan una red de retorno de múltiples productos, basándose en la decisión de establecer nuevos centros de desensamble y procesamiento. Para aproximar su modelo a la realidad, asumen incertidumbre en la demanda. Farrokhi-Asl et al. (2017) se enfrentan al problema de ruteo y localización de instalaciones, de manera simultánea, para apoyar el proceso de recolección y disposición de residuos. En su modelo, se tienen diferentes tecnologías mientras se busca mantener el mínimo costo y maximizar la responsabilidad social. Al emplear un algoritmo genético de clasificación no dominada (NSGA II), lograron obtener un mejor rendimiento que con la optimización de enjambre de partículas (PSO), utilizada en ocasiones para problemas con un nivel de complejidad similar. Para evidenciar la efectividad de la optimización de enjambre de partículas en la minimización de los costos, es necesario remitirse al trabajo publicado un año antes por Govindan et al. (2016), en el cual se observa el uso de la PSO para tratar con el problema de diseño de una red de logística inversa de un productor de jeringas en India. Los productos al final de su ciclo de vida son recolectados y transportados a los centros de reciclaje de metal, plástico o centros de incineración, según sea el caso.

Como se ha visto hasta ahora, muchos investigadores han encaminado sus diseños en logística inversa hacia la recolección de productos de fin de vida (EOL). Pero, Li et al. (2016) presentan en su trabajo un camino bastante diferente al elegido por los autores antes mencionados. Su modelo está orientado a prestar el servicio de mantenimiento o reparación de productos electrónicos defectuosos, como parte de la garantía de los mismos. Las decisiones sobre la

ubicación de los centros de recolección y reparación son tomadas con base en un modelo MILP y un algoritmo híbrido tipo NSGA II.

A pesar de la variedad de aplicaciones y beneficios de la logística inversa presentados hasta el momento, Mirakhorli (2014) hace énfasis en que “no es una opción apropiada considerar de forma separada la logística directa y la logística inversa, al diseñar la cadena de suministro, debido a que esto incrementa el costo total y conlleva a ineficiencias en todo el sistema”. Por este motivo, en los últimos años los investigadores se enfocaron en el diseño de redes logísticas integradas, hasta llegar al concepto generalizado de Cadena de Suministro de Circuito Cerrado (CLSC).

Uno de los diseños integrados más relevante de la última década es sin duda el de Pishvaei et al. (2010), quienes diseñaron una red logística integrada directa/inversa (IFRLN, por sus siglas en inglés) con múltiples estaciones y múltiples niveles de capacidad. Esta red está compuesta por centros de manufactura, remanufactura, producción, recuperación, disposición y zonas de consumo. Además, los centros de distribución y los centros de recolección cuentan con la posibilidad de ser híbridos, ubicarse en una misma instalación, como una decisión variable dentro del modelo. Por otra parte, la red considera el flujo de productos nuevos hacia las zonas de consumo y el flujo inverso de productos desechados hacia las plantas de recuperación, con el propósito de reinsertarlos al mercado primario. La característica principal de una CSCL es aprovechar al máximo los recursos naturales, ya sea que los productos sean reciclados o que sirvan de materia prima para otras industrias. Por ejemplo, Cheraghalipour et al. (2018) trabajaron en el diseño de una cadena de suministro de cítricos, donde se buscaba localizar centros de compostaje para convertir los productos devueltos en fertilizante útil en diferentes actividades agrícolas. Su modelo se centra en determinar el costo mínimo y maximizar la capacidad de respuesta en diferentes períodos de siembra y, para ello, desarrollaron un algoritmo khestel (MOKA) y lo compararon con

varios GA's. Tras ejecutar 12 problemas de prueba, encontraron que el NRGGA tuvo el mejor rendimiento en todas las instancias.

Para concluir, se encontró que el diseño integrado es el más flexible, eficiente en costos y permite la toma de decisiones centrada en el cliente, la sociedad y el medioambiente. Además, se logra minimizar el uso de los recursos naturales y el problema de acumulación de basuras en rellenos sanitarios. Otra ventaja es la variedad de industrias en las que puede ser aplicado; desde la industria clásica de manufactura, la agricultura e incluso llegando hasta la industria de bienes perecederos. Esta última, abordada por Yavari & Geraeli (2019) en su diseño de red integrado para la cadena de suministro de las compañías de lácteos en Irán. Allí, asumen que los productos devueltos son utilizados por los productores como productos semiprocesados y vendidos a un precio más bajo. De esta forma, logran que el ciclo productivo se cierre.

4.3.2 Modelos matemáticos aplicados en los problemas de la CS.

Cómo se puede observar en la Tabla 7, gran parte de las investigaciones realizadas se basan en los modelos MILP como solución matemática del problema CS. A continuación, se entrará a analizar de forma más detallada algunos modelos propuestos hasta el momento.

4.3.2.1 La logística como ventaja competitiva. Según Pishvae et al. (2010), “el diseño de una cadena eficiente y efectiva puede constituir una ventaja competitiva para las empresas”. Partiendo de esta premisa, se relacionan a continuación los autores cuyos modelos se han enfocado en desarrollar cadenas de suministro más competitivas.

En primer lugar, el mismo Pishvae et al. (2010) establece dos objetivos dentro de su modelo para su red logística integrada. El primero es minimizar los costos totales, en el cual incluye los costos fijos de la apertura de las instalaciones, los costos de transporte y, como un aporte novedoso, considera ahorros generados por la integración de sus centros de distribución y

recolección. El segundo objetivo es la capacidad de respuesta de la red, la cual es medida en función del cumplimiento de la demanda y la recolección de los productos. El resultado es un modelo de programación lineal entera mixta bi-objetivo de tipo NP-completo. Vahdani & Mohammadi (2015) estudian una red CLSC para la industria de hierro y metal. El modelo propuesto es un novedoso enfoque híbrido entre programación de intervalos (IP), programación estocástica (SP), optimización robusta (RO) y programación difusa (FMP) a fin de minimizar dos funciones objetivo y tratar con la incertidumbre de los parámetros. Los objetivos son la minimización de los costos y del tiempo que duran los productos devueltos esperando por ser procesados y enviados al mercado. Liu et al. (2018) diseñan una red logística para apoyar las actividades de reciclaje de las la empresas de comercio electrónico en China. Para modelar dicho problema, emplea la MILP con dos funciones objetivo. Por un lado, busca minimizar los costos totales y, por otro, maximizar la satisfacción del cliente. Para medir la satisfacción del cliente se basa en el tiempo de entrega, en la calidad de los productos y en la cantidad de productos reciclados. Zavvar Sabegh et al. (2017) para modelar su red farmacéutica, antes mencionada, emplean la programación lineal entera multiobjetivo (MILP) y proponen maximizar la capacidad de respuesta de una forma diferente a las vistas hasta ahora. Debido a que su red busca suministrar medicamentos tan pronto como sea posible, tras un desastre natural, la capacidad de respuesta se mide por las fuerzas humanitarias disponibles para dicha tarea. Además, cuenta con otras funciones objetivo como costos e impacto ambiental.

De los casos presentados en esta sección, se puede ver que la optimización enfocada a la minimización de los costos o la maximización de las ganancias es el objetivo más comúnmente usado en los problemas de diseño de la red logística. A menudo, los costos incluidos son: costos de transporte, costos de recolección, costos de almacenamiento, costos de apertura, etc. Por otra

parte, la capacidad de respuesta de la red ha sido bastante estudiada, pero es abordada de diversas maneras según los intereses del investigador. Algunas de las variables más consideradas son: la calidad del producto, el tiempo de entrega o recolección, el cumplimiento de la demanda, entre otras; siempre con el propósito de brindar satisfacción al cliente. (Mirakhorli, 2014)

4.3.2.2 La logística y su aporte a la sociedad. Muchos autores han entendido la logística más allá del mundo de los negocios y la han visto como una oportunidad para que las empresas puedan retribuirle a la sociedad y al medio ambiente todos los inconvenientes generados a causa de sus actividades productivas. En ese sentido, algunos autores que enfocan el problema de diseño de la red logística hacia la minimización del impacto ambiental y la maximización de la responsabilidad social empresarial, son presentados a continuación.

Como primer ejemplo, Govindan et al. (2016) en el diseño de su cadena de suministro de jeringas proponen un modelo de programación matemática difusa con tres funciones objetivo: minimizar los costos y el impacto ambiental y maximizar la responsabilidad social. De su modelo, se destaca el método utilizado para medir el impacto ambiental. Este método es conocido como el Eco-indicador 99 y está basado en el ciclo de vida del producto (LCA). Adicionalmente, la responsabilidad social es medida con relación a la cantidad de empleos generados por la apertura de una nueva instalación dentro de la red y, para determinar el costo total, se utiliza el indicador financiero del valor presente neto (VPN).

Sahebjamnia et al. (2018) diseñan una CLSC de neumáticos y la resuelven mediante MILP multi-objetivo. Para minimizar el impacto ambiental, considera el efecto de establecer nuevas instalaciones y las consecuencias del abandono de neumáticos usados. En cuanto a la responsabilidad social, se toman en cuenta las oportunidades de empleo generadas y el número de días de trabajo perdidos por accidentes ocasionados durante la operación del sistema.

Shi et al. (2017) generalizan una CLSC de productos electrónicos hacia otros sectores como la industria automotriz. En esta red, los productos reciclados pueden ser remanufacturados y vendidos al mismo precio que los productos nuevos o no recuperables y, en ese caso, enterrados en zonas de relleno sanitario. Para modelar este problema, hacen uso de la programación entera mixta (MIP) y establecen objetivos dirigidos a los costos, el impacto ambiental y la capacidad de respuesta. Para minimizar el impacto ambiental asumen tres fuentes principales de emisión de carbono: en las plantas debido al consumo de energía en la producción, en los centros de distribución y recolección debido al consumo de energía en actividades de almacenamiento y manejo de productos y en el transporte debido al consumo de combustible.

En los trabajos analizados, se encontró que al diseñar cadenas de suministro la emisión de gases peligrosos, debida a diferentes actividades, es ampliamente usada por los investigadores para estudiar los efectos ambientales de las decisiones estratégicas. Pero, también existen otros indicadores que resultan de utilidad, tales como: el consumo de energía, los residuos sólidos, el consumo de agua y las aguas residuales. Soleimani et al. (2017)

Del mismo modo, los aspectos más frecuentes con relación a la responsabilidad social son: la generación de oportunidades de empleo, los días de trabajo perdidos por accidentes, la distancia entre las zonas residenciales y los centros de disposición final (Farrokhi-Asl et al., 2017), etc.

4.3.3 Enfoques de solución heurísticos comúnmente abordados

Generalmente, existen dos caminos a elegir para resolver problemas de optimización: los métodos de solución exacta y los enfoques heurísticos. Sin embargo, dependiendo de la complejidad del problema es posible que los métodos exactos no logren resolverlo (Soleimani et al., 2017). De hecho, Aras et al. (2008) y Fattahi et al. (2015) dicen que: “los problemas de diseño de red logística están clasificados como NP-hard y la duración del proceso de solución incrementa

exponencialmente con el tamaño del problema”(Citado en Govindan et al., 2016). Bajo estas circunstancias, los investigadores optan por desarrollar diferentes heurísticas que les permitan aproximarse a las soluciones óptimas sin consumir demasiado tiempo y recursos.

Entre ellas, “los algoritmos genéticos son ampliamente utilizados debido a su simplicidad en la aplicación y a su eficiencia al resolver problemas de gran tamaño” (Alshamsi & Diabat, 2017). Dependiendo de las características del modelo matemático, el problema puede requerir algunos tratamientos previos para ajustarse al GA. Por ejemplo, en un modelo sencillo de un solo objetivo, como el de Diabat & Deskoore (2016), el GA propuesto no requiere ajustes preliminares, el cromosoma puede ser codificado directamente y la aptitud de las soluciones es medida con relación a la función objetivo. Por el contrario, Roghanian & Pazhoheshfar (2014) proponen un complejo modelo de programación lineal entera mixta probabilística, el cual inicialmente requiere ser transformado en un modelo determinístico equivalente. Posteriormente, debe ser codificado usando un método basado en la prioridad, sin mecanismo de reparación. Y, por último, se hace uso del método de selección por torneo para generar las siguientes poblaciones a partir de los cromosomas más aptos.

En otras ocasiones, los investigadores optan por considerar demandas inciertas para aproximar el modelo a la realidad. Esta decisión lleva a la necesidad de aplicar programación difusa, que a su vez también requiere estrategias previas de adaptación al GA. Este es el caso de Mirakhorli (2014), quien desarrolló un algoritmo genético (GA) para dar solución a su modelo de programación lineal multi-objetivo difuso e interactivo, el cual describe una CLSC para la industria del pan. Para adaptar el modelo al algoritmo genético, primero transforma el problema bi-objetivo en un modelo auxiliar equivalente de un solo objetivo, empleando el método de programación difusa de Zimmermann y el enfoque de toma de decisiones difusas de Bellman y

Zadeh. Con este método, las funciones objetivo y las restricciones se transforman en funciones de membresía difusas a partir de los límites correspondientes. Al medir el rendimiento del algoritmo propuesto, en un problema real de la industria del pan en India, y compararlo con el software LINGO; se encontró que el algoritmo llega a las mismas soluciones en un tiempo mucho más corto y con un menor uso de memoria computacional. Un algoritmo genético similar es implementado por Soleimani et al. (2017) para resolver su modelo de MILP. El modelo está basado en una CLSC con enfoque verde, sostenible e incertidumbre en la demanda. Para convertir el modelo multi-objetivo a uno de objetivo único, se emplea el método de ε –restricciones. Como parte del método, la función objetivo encargada de maximizar los beneficios de la red permanece como el único objetivo del problema, mientras que las funciones que minimizan los días de trabajo perdidos y maximizan la satisfacción del cliente pasan a ser tratadas como limitaciones del problema. Finalmente, los parámetros que pueden afectar la efectividad del algoritmo son ajustados empleando el Método Taguchi (TM).

A diferencia de los autores anteriores, Pishvae et al. (2010) optaron por desarrollar un algoritmo memético multi-objetivo con búsqueda local dinámica (MOMA). Su motivación para elegir este tipo de modelo fue dotarlo de una mayor intensificación de búsqueda y, de esta forma, compararlo con el algoritmo genético MOGA de Altiparmak et al. (2006), a partir de la cantidad y calidad de soluciones de Pareto obtenidas por cada uno. El algoritmo MOMA demostró una mejora en la tasa promedio de soluciones óptimas de Pareto para problemas con un solo nivel de capacidad y una calidad de soluciones razonable para problemas de múltiple capacidad. El uso del algoritmo memético para un problema de diseño de red logística es visto nuevamente en el trabajo de Jamshidi et al. (2012), quienes combinan el MA con el método de Taguchi para el cruce de los padres y la obtención de la nueva población. Además, modifican el método de codificación

propuesto por Gen y Chen, y proponen un método de decodificación del cromosoma basado en la prioridad, de tamaño [j] y donde las celdas pueden tomar un valor de cero. Para medir el rendimiento del algoritmo, este es comparado con un algoritmo genético con método Taguchi (GATA), donde se confirma su alto desempeño en la minimización de los objetivos.

En conclusión, los algoritmos genéticos han mostrado ser una muy buena alternativa para los problemas de programación multi-objetivo dentro del diseño de red de la cadena de suministro. Sin embargo, a menudo se hace necesario contar con estrategias de adaptación que permitan el uso de estas metaheurísticas. Entre las estrategias más comunes se identificaron las siguientes: la representación basada en árbol, como el método de codificación basado en la prioridad de Gen y Chen (Citado en Jamshidi et al., 2012), para la definición de los cromosomas iniciales; la suma ponderada, el método de selección por torneo y la ponderación aleatoria, como técnicas para la medición de la aptitud de los cromosomas; y el método de E-restricciones para transformar problemas de múltiples objetivos en problemas de un solo objetivo.

5. Marco Teórico

A continuación, se relacionan los conceptos necesarios para la realización del presente trabajo.

5.1 Logística directa

Muchos investigadores no discriminan entre logística directa y cadena de suministro clásica, puesto que, ambos términos pertenecen a la gestión de la cadena de suministro y abarcan decisiones de nivel estratégico (ej. Localización, número y configuración de instalaciones, etc.) y de nivel táctico (ej. Flujo de productos entre instalaciones, inventario, producción y modos

transporte) (Ramezani et al., 2014, como citado en Yavari & Geraeli, 2019). Para ilustrarlo, es posible remitirse a las definiciones de dos autores. Sabri & Beamon (2000) afirman que “la cadena de suministro es un conjunto de instalaciones, proveedores, clientes, productos y métodos de control de inventario, compras y distribución. La cadena conecta a proveedores y clientes, comenzando con la producción de la materia prima por un proveedor, y terminando con el consumo de un producto por el cliente (...)”. (Citado en Altiparmak et al., 2006). Por su parte, Kannan et al. (2009) definen la logística inversa como “una red de instalaciones y opciones de distribución que ejecutan las funciones de: obtención de materiales, transformación de estos materiales a productos intermedios y finales; y distribución de estos productos finales a los clientes”.

A partir de estas dos definiciones, se puede concluir que el diseño de una red logística directa se compone de proveedores, centros de manufactura, canales de distribución y zonas de consumo. Además, involucra decisiones relacionadas con la compra de materias primas, la producción de bienes con valor agregado, el almacenamiento y el transporte de los mismos. Todo esto, con el fin llevar un producto al mercado que cumpla con las condiciones de tiempo, calidad y precio.

5.2 Logística Inversa

Tibben-Lembke & Rogers (2002) definen la logística inversa como: “el proceso de planificar, implementar y controlar el flujo de MP, inventario en proceso, producto terminado e información relacionada desde el punto de consumo hasta el fabricante con el propósito de reciclar, reutilizar, recuperar valor o dar una disposición adecuada”. Tal proceso, tiene lugar debido a circunstancias específicas que invierten el flujo normal de los productos dentro de la red. Por un lado, el uso eficiente de los productos que retornan del mercado se ha convertido en una estrategia rentable y sostenible que le permite a las compañías ser más competitivas en su industria

(Roghania & Pazhoheshfar, 2014). Del otro lado, la cantidad de productos reciclados está en constante aumento a causa de la creciente conciencia ambiental de los clientes y, en consecuencia, las regulaciones sobre el manejo de residuos se han vuelto cada vez más estrictas para las empresas (Alshamsi & Diabat, 2017). A parte de los beneficios económicos y la preocupación ambiental, una tercera fuente de productos devueltos recae en las condiciones de calidad y la consecuente satisfacción del cliente. Cuando las expectativas del cliente no son cumplidas por la empresa, es muy probable que se presenten devoluciones que también le conciernen a la logística inversa.

Todas estas circunstancias, presentan un grado tan alto de incertidumbre que hacen de la logística inversa un sistema mucho más complejo que el clásico (Roghania & Pazhoheshfar, 2014). Para simplificar el diseño, las redes inversas se han clasificado en cuatro grupos principales: la red directamente reutilizable (DRN), la red de remanufactura (RMN), la red de servicio de reparación (RSN) y la red de reciclaje (RN) (Liu et al., 2018). Consecuentemente, los productos devueltos están catalogados como devoluciones comerciales, devoluciones de garantía, devoluciones de fin de uso, contenedores reutilizables, etc. (Du & Evans, 2008).

Finalmente, según Mehrbod et al. (2015) la configuración de la red inversa generalmente está constituida por centros de recolección, inspección/separación, recuperación, disposición y redistribución.

5.3 Cadena de suministro CLSC

La investigación en cadenas de suministro de ciclo cerrado nació al final de los años 90, con uno de los primeros trabajos en esta área publicado por (Marín & Pelegrín, 1998). A pesar de que, inicialmente, el problema de diseño de CLSC estuvo orientado a responder a las preocupaciones sociales y ambientales de los clientes, y a cumplir con las regulaciones impuestas a las empresas en cuanto al manejo de los productos de fin de vida; con el tiempo, se convirtió en

una estrategia de eficiencia y efectividad en las operaciones que permite a las empresas ser más competitivas en su entorno. (Mehrbood et al., 2015). La forma más sencilla de definir una CLSC, es entenderla como el diseño de una red de logística directa y una red de logística inversa, de manera simultánea. Por lo tanto, la CLSC será una red integrada que contenga las instalaciones del flujo directo de productos nuevos y MP (proveedores, centros de manufactura, distribuidores y zonas de consumo), del flujo inverso de productos usados (clientes, centros de recolección/inspección, disposición, remanufactura, reciclaje y recuperación) y, en ocasiones, combinaciones entre ellas. (Soleimani et al., 2017).

Por consiguiente, las decisiones intrínsecas al diseño de CLSC son la localización de instalaciones, los niveles de capacidad, la distribución de productos y la asignación de recursos en general. Todas estas decisiones, están encaminadas hacia múltiples objetivos como: la capacidad de respuesta, la eficiencia, la efectividad, la responsabilidad social y el impacto ambiental; pero el objetivo más común entre los académicos es la minimización de los costos (Mehrbood et al., 2015). Tal vez por esa razón, la definición más reciente de CLSC está planteada como sigue: “la gestión de la CLSC es el diseño, control y operación de un sistema para maximizar la creación de valor durante todo el ciclo de vida de un producto con una recuperación dinámica del valor de diferentes tipos y volúmenes de devoluciones a lo largo del tiempo” (Govindan et al., 2015).

5.4 Programación Lineal

La programación lineal consiste en expresar mediante un modelo matemático cualquier problema relacionado con la asignación de recursos limitados a fin de encontrar la mejor combinación para una serie de actividades que compiten por ellos. En este contexto, el concepto de programación se refiere a planeación, mientras que la palabra lineal indica que todas las funciones del modelo deben ser funciones lineales. (Hillier & Lieberman, 2010).

La resolución de un modelo de programación lineal a menudo se realiza mediante el método SIMPLEX y conlleva a la obtención de un punto óptimo. El modelo general de la PL se describe como sigue.

Variables de decisión

$$x_1, \quad x_2, \quad x_3, \dots, \quad x_n$$

Función objetivo

$$\text{Minimizar} \quad Z = c_1x_1 + c_2x_2 + \dots + c_nx_n$$

Restricciones Funcionales

$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n \leq b_1$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n \leq b_2$$

$$a_{n1}x_1 + a_{n2}x_2 + \dots + a_{nn}x_n \leq b_n$$

Restricciones de no negatividad

$$x_1 \geq 0, \quad x_2 \geq 0, \quad x_3 \geq 0, \dots, \quad x_n \geq 0$$

5.4.1 Programación lineal entera

Cuando el problema requiere que todas sus variables sean enteras, se mantiene el modelo matemático original de la programación lineal y se le agrega dicha restricción para convertirlo en un modelo de programación lineal entera pura. (Hillier & Lieberman, 2010).

5.4.2 Programación entera binaria

En este caso las variables del modelo están asociadas a una decisión que solo tendrá dos respuestas posibles representadas por un 1 o un 0, como se muestra a continuación. (Hillier & Lieberman, 2010).

$$x_j = \begin{cases} 1, & \text{si la decisión } j \text{ es sí,} \\ 0, & \text{si la decisión } j \text{ es no.} \end{cases}$$

5.4.3 Programación lineal entera mixta

También conocida como programación entera mixta (PEM), este tipo de problema recoge todos los casos vistos hasta ahora. Mantiene el modelo general de programación lineal con variables de decisión restringidas a valores enteros, variables continuas comunes y variables binarias. (Hillier & Lieberman, 2010).

5.5 Optimización multiobjetivo

La optimización es el foco central de la investigación de operaciones y se emplea para modelar problemas como el diseño de red, el ruteo de vehículos y la programación de actividades; conocidos como problemas de optimización. Según Duarte Muñoz et al. (2007) “un problema de optimización es simplemente un problema en el que hay varias (en general muchas) posibles soluciones y alguna forma clara de comparación entre ellas, de manera que éste existe si y sólo si se dispone un conjunto de soluciones candidatas diferentes que pueden ser comparadas”. La forma matemática de un problema de optimización es presentada en la Figura 6.

Figura 6.

Modelo matemático del problema de optimización

$$P = \begin{cases} \text{opt: } \vec{f}(x), & \text{Función Objetivo} \\ \text{s. a.}, & \\ x \in F \subset SS & \text{Restricciones} \end{cases}$$

Nota. Adaptado de *Formulación de un modelo de optimización multiobjetivo* (p. 1), de Muñoz et al., 2007, DYKINSON.

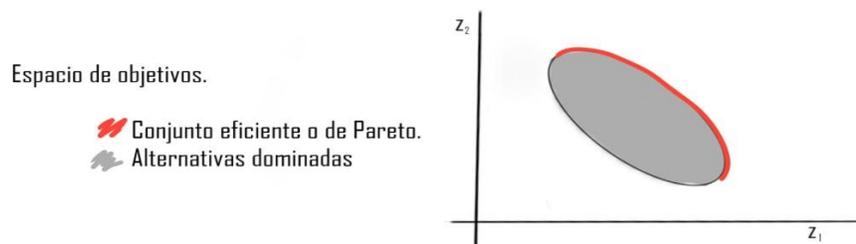
Adicionalmente, señala que los problemas de optimización pueden ser separados en dos tipos: problemas continuos (con solución codificada en los números reales) y problemas discretos (con solución codificada en los números enteros). Entre los problemas discretos, los aplicados al diseño de redes se encuentran en la clasificación de problemas de optimización combinatoria. En

esta área, a menudo se consideran problemas de optimización con dos o más objetivos en conflicto, referidos como problemas de optimización multiobjetivo. De hecho, si la optimización de un objetivo también optimiza al otro, simultáneamente, no se puede considerar como optimización multiobjetivo. (Wiley & Sons, 2001, citado en Pedram et al., 2017).

Finalmente, la optimización multiobjetivo se centra en buscar el conjunto de soluciones óptimas de Pareto, el cual está basado en el criterio de optimalidad paretiana, enunciado por Pareto en 1896. Según el criterio mencionado “una alternativa es eficiente (o Pareto óptima) si toda alternativa que proporcione una mejora en un atributo produce un empeoramiento en al menos otro de los atributos.” Estas alternativas eficientes también son conocidas como soluciones no dominadas y de este último término se deriva la definición de su contraparte, las alternativas dominadas, que son todas aquellas soluciones no eficientes para las que existe otra alternativa que presenta mejores atributos. (Vitoriano, 2009). El conjunto de todas las soluciones no dominadas de un problema de optimización en particular se define como Frente de Pareto y se caracteriza por contener una variedad de alternativas factibles para el decisor, quien elegirá la más conveniente basado en criterios previamente establecidos. (Vitoriano, 2007). A continuación, se evidencia un ejemplo gráfico del Frente de Pareto. (Figura 7).

Figura 7.

Representación del Frente de Pareto



Nota. Adaptado de *Decisión con Incertidumbre, decisión multicriterio y teoría de juegos*, de Vitoriano (2007).

La búsqueda de la frontera de Pareto se puede abordar desde dos perspectivas: los métodos exactos y los métodos heurísticos.

5.5.1 Métodos exactos

Este tipo de métodos generalmente convierten el problema multiobjetivo en un problema de un solo objetivo. Además, vienen implementados en paquetes de software como LINGO y GAMS, y consumen mucho tiempo en encontrar las soluciones, puesto que, tienen que ser corridos varias veces para encontrar un conjunto de soluciones óptimas de Pareto (Li et al., 2016). La ventaja es que cuando logran dar con la solución, se tiene la seguridad de que será la óptima. A continuación, se presentan los dos métodos más conocidos.

5.5.1.1 Método de las ε -restricciones.

Según Soleimani et al. (2017), este método consiste en transformar el problema multiobjetivo en un problema de único objetivo. La función objetivo más relevante para la toma de decisiones se mantiene como el único objetivo del nuevo problema, mientras que las demás se convierten en restricciones. Para obtener el conjunto de soluciones no dominadas, se debe ir variando el parámetro ε .

5.5.1.2 Método de suma ponderada.

Este método consiste en asignar un peso w a cada función objetivo y realizar una suma ponderada. Cuando las funciones objetivo tienen unidades en escalas diferentes es importante realizar una normalización para no afectar los resultados. Existen diferentes estrategias para seleccionar los valores w , una de ellas es hacerlo de forma aleatoria, con la cual se logra explorar todo el espacio de búsqueda de soluciones óptimas de Pareto. (Altıparmak et al., 2006).

El criterio de evaluación del rendimiento con un vector de pesos w está basado en la demostración de (Zadeh, 1963). En ese trabajo se encontró que es posible reducir el problema

multiobjetivo a un problema monobjetivo, en el cual se busca optimizar la suma ponderada del vector w con las funciones objetivo del problema original. De esta forma, el punto óptimo encontrado será un punto del frente de Pareto del problema multiobjetivo y para cada combinación posible del vector de pesos w , se obtendrá el resto de la frontera.

5.5.2 Métodos heurísticos

Otra forma de resolver los modelos de optimización es mediante métodos heurísticos. Zanakis et al. (1981) define los métodos heurísticos como: “procedimientos simples, a menudo basados en el sentido común, que se supone que obtendrán una buena solución (no necesariamente óptima) a problemas difíciles de un modo sencillo y rápido” (Duarte Muñoz et al., 2007). Su uso se debe a las limitaciones de los métodos exactos en cuanto a tiempo y a recursos computacionales. Sin embargo, una de las limitaciones de las heurísticas es su dificultad para escapar de óptimos locales. (Duarte Muñoz et al., 2007). Entre los métodos heurísticos más utilizados se encuentran: los algoritmos evolutivos (NSGA, NSGAI, GA y MA), la optimización de enjambre (PSO, ACO), entre otros. (Li et al., 2016). En el siguiente numeral se definirá el algoritmo genético, ya que, es el más empleado en diseño de redes y es el propuesto para esta investigación.

5.6 Método de valoración del ciclo de vida (LCA)

El método de valoración del ciclo de vida (LCA, por sus siglas en inglés) es una técnica que permite considerar los aspectos medioambientales e impactos potenciales de un producto a lo largo de todas las etapas de su vida; tales como: la extracción de la materia prima, producción, distribución, uso, reparación y reciclado. (Fathollahi-Fard & Hajiaghahi-Keshteli, 2018). La planeación de un sistema o red logística basada en el LCA es conocida como Ecodiseño y se centra en sus cuatro fases metodológicas (Vivancos Bono et al., 2005), que según la norma ISO 14040 son:

- Definición de objetivo y alcance del estudio.
- Análisis de inventario.
- Evaluación de impactos.
- Interpretación de resultados.

El desarrollo de cada una de estas etapas está contemplado en la familia de normas ISO 14000 Sistema de Gestión Ambiental, donde se destacan para el propósito del presente proyecto la norma ISO 14040 Análisis del ciclo de vida y la ISO 14042 Evaluación del impacto del ciclo de vida. En estas dos normas se especifican los requisitos y principios del LCA y los procedimientos necesarios para la fase de evaluación. El primer procedimiento de evaluación es la agrupación, donde se ordenan y clasifican las categorías de impacto. El segundo procedimiento es la ponderación, la cual consiste en la conversión, combinación y/o agregación de los resultados obtenidos de la medición realizada para cada categoría mediante el uso de un método de valoración cuantitativo o cualitativo. (Vivancos Bono et al., 2005). Uno de los métodos cuantitativos más relevantes de la última década ha sido el uso de los denominados Ecoindicadores (como el Ecoindicador 95 o el Ecoindicador 99), los cuales permiten evaluar el efecto de la producción y distribución del producto sobre la calidad del ecosistema, el daño de los productos y sus materias primas al ambiente y el efecto de toda la operación sobre la salud humana a través de una asignación numérica conocida como ecopuntos. (Vivancos Bono et al., 2005).

En el trabajo de (Fathollahi-Fard & Hajiaghaei-Keshteli, 2018) se implementó esta metodología para evaluar el impacto ambiental de su modelo de cadena de suministro de circuito cerrado estocástica multiobjetivo, teniendo en cuenta cinco factores medioambientales; que incluían: apertura de instalaciones, manufactura, tipos de tecnologías, envío de materiales y manipulación de productos, con una asignación de pesos de 70% para la salud humana y 30% para

la diversidad del ecosistema. Por otra parte, (Sahebjamnia et al., 2018) desarrollaron una cadena de suministro de circuito cerrado sostenible de neumáticos con objetivos de tipo económico, social y ambiental. En la dimensión ambiental implementaron la metodología LCA para evaluar el impacto de los neumáticos usados abandonados en la naturaleza, considerando una ponderación de 20% para la salud humana y 80% para la diversidad del ecosistema. Finalmente, es importante precisar que la magnitud (en ecopuntos) del Ecoindicador representa el daño potencial del factor evaluado sobre el medioambiente y, cuanto mayor sea el valor nominal, más grave es el impacto del mismo.

5.7 Algoritmo genético

Los algoritmos genéticos fueron presentados por primera vez por Henry Holland en el año 1975 (Mirakhorli, 2014). Este tipo de algoritmos pertenece a las técnicas de optimización heurísticas y, en particular, a la clasificación de algoritmos evolutivos (Roghalian & Pazhoheshfar, 2014). Su base conceptual se fundamenta en la evolución biológica y la genética (Hajiaghaei-Keshteli & Fathollahi Fard, 2019).

El GA parte de una población inicial conformada por una variedad de cromosomas que han sido codificados como características o combinaciones de las variables del modelo matemático (posibles soluciones). En seguida, una función de aptitud es aplicada a cada cromosoma para seleccionar los que presenten un mejor valor y descartar los restantes. Los cromosomas con mejor valor de aptitud son conocidos como “padres” y se les aplica un operador de cruce a fin de generar una nueva población descendiente llamada “hijos”. Los hijos conservan algunas características de los padres, pero en busca de diversificar el espacio de soluciones se les aplica un operador de mutación, el cual cambia de forma aleatoria algunos de sus genes. Tras obtener los cromosomas resultantes de las fases de cruce y mutación, se seleccionan nuevamente los mejores para

conformar la nueva población. Este proceso se repite de forma cíclica hasta alcanzar un criterio de parada preestablecido (Soleimani et al., 2017). En la Figura 8 se presenta el pseudocódigo del funcionamiento general de un GA.

Figura 8.

Funcionamiento de un Algoritmo Genético

```
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
```

Nota. Adaptado de *Funcionamiento de un Algoritmo Genético* (p. 16), Gestal et al., 2010, Universidade da Coruña.

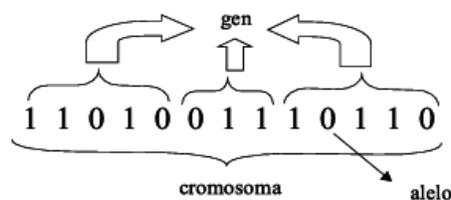
5.7.1 Codificación del cromosoma

La representación del modelo mediante cromosomas es uno de los problemas que pueden afectar el rendimiento del GA (Roghalian & Pazhoheshfar, 2014). Por esta razón, a continuación, se define el cromosoma y se presenta uno de los métodos más usados para su codificación.

5.7.1.1 Cromosoma. En semejanza con la genética, en los GA's el cromosoma está compuesto de varios genes que, a su vez, son los encargados de llevar la información de los individuos en cada generación. Esta información corresponde a las posibles soluciones al modelo matemático propuesto. Según Deb (1999) “cada cromosoma puede ser pensado como un punto en el espacio de búsqueda de las soluciones candidatas”. El cromosoma está compuesto por dos factores: la posición y el valor del gen. El valor del gen se representa de forma binaria, cadenas de 1 y 0, conocidas como alelos (Alshamsi & Diabat, 2017). Mientras que la posición de cada gen dentro de su estructura se conoce como locus (Altiparmak et al., 2006). En la Figura 9 se muestra la estructura básica de un cromosoma.

Figura 9.

Individuo genético binario



Nota. Adaptado de *Individuo genético binario* (p. 15), Gestal et al., 2010, Universidade da Coruña.

5.7.1.2 Método de codificación basado en la prioridad.

Según Gen & Cheng (2000) “la representación basada en árbol es conocida por ser una forma de representar problemas de red. Hay tres formas de árbol de codificación: (1) codificación basada en bordes, (2) codificación basada en vértices y (3) codificación basada en bordes y vértices”. (Citado en Roghanian & Pazhoheshfar, 2014). Entre ellas, se encuentra el método de codificación basada en la prioridad, introducido por Gen y Cheng (2000, citado en Jamshidi et al., 2012). Este método se centra en la representación del cromosoma como una matriz $k \times j$, donde k

corresponde al número de recursos y j al número de instalaciones de la red. Además, la posición de cada celda representa el recurso y el depósito, y el valor numérico indica la prioridad. De esta forma, las soluciones terminarán codificadas en arreglos de tamaño $k + j$. (Jamshidi et al., 2012).

5.7.2 Función de aptitud

Luego de tener una población inicial, se procede a realizar una evaluación de cada individuo y una selección de los más aptos. Para la evaluación de los individuos, es necesario establecer una forma de medir su capacidad de generar buenas soluciones con respecto al resto de la población; a esto se le conoce como función de adaptación. La función de adaptación, se define de forma particular según el tipo de problema. Si en el modelo se busca la minimización de una función objetivo, la función de adaptación calificará con un mayor valor de ajuste a los cromosomas que obtengan las soluciones más pequeñas y, de forma semejante, para el caso contrario. De hecho, la función de adaptación no se describe necesariamente como una expresión algebraica y, puede ser clasificada en dos grupos: funciones probabilísticas y determinísticas. (Kuri Morales & Galvis Casas, 2002). Entre las funciones probabilísticas, las más conocidas son la selección por ruleta, selección por torneo y peso aleatorio. Mientras que las funciones determinísticas más utilizadas son sobranste estocástico, universal estocástica y muestreo determinístico. (Gestal et al., 2010).

En cuanto a la selección, se eligen los cromosomas con mayor valor de ajuste para generar la siguiente población. Este criterio, se basa en la premisa de que los individuos más aptos tendrán mayor probabilidad de sobrevivir y, al reproducirse, las siguientes generaciones heredarán sus características e incluso mejores.

5.7.3 Selección por ruleta.

En este método se divide una ruleta en n partes (donde n es el número de individuos). Cada parte tendrá un tamaño proporcional al valor de ajuste de su respectivo individuo. Por lo tanto, la suma de las porciones de la ruleta será igual a 1. Para seleccionar un individuo, se genera un valor aleatorio entre $[0, 1]$ y se elige el individuo que ocupa esa posición en la ruleta. (Gestal et al., 2010).

5.7.4 Selección por torneo.

Este método consiste en escoger un número p de individuos de la población para compararlos entre sí. A medida que el número p aumenta la presión de selección también lo hace, es decir, los peores individuos tendrán menor probabilidad de ser elegidos. La selección del ganador del torneo puede ser probabilística o determinística. Cuando es determinística, simplemente se elige el individuo con mejor valor de ajuste. Mientras que, en el caso probabilístico se genera un número aleatorio entre $[0, 1]$ y se establece una condición para decidir cuál individuo elegir con base en ese número. (Gestal et al., 2010).

5.7.5 Operador de cruce

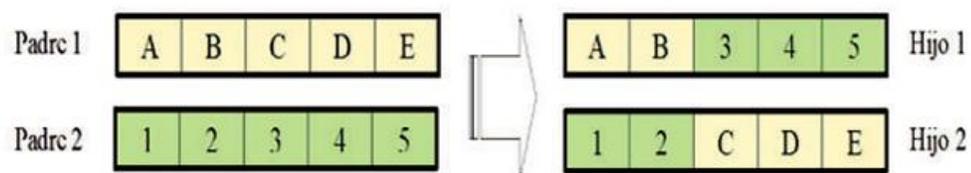
Los operadores de un GA son utilizados a fin de evitar la convergencia prematura del mismo. La función de aptitud hace que el algoritmo seleccione siempre los mejores cromosomas entre la población evaluada, lo que se conoce como explotación de las soluciones. Pero, durante la explotación es posible que el algoritmo termine convergiendo hacia óptimos locales. Para evitarlo, se hace necesaria también la exploración de todo el espacio de búsqueda posible y, para ello, existen los operadores del GA (Gestal et al., 2010). Según Altiparmak et al. (2006), el operador de cruce se emplea para explorar nuevos espacios de solución y consiste en intercambiar partes de las cadenas entre los padres seleccionados. Aunque el cruce de los individuos se basa en que la

combinación de dos padres con un buen nivel de ajuste generará hijos con un nivel superior, esto no siempre se cumple. En este punto, es preciso diferenciar entre una estrategia destructiva y una no destructiva. En la primera, los descendientes serán aceptados para conformar la nueva generación, aún, cuando sus padres tengan mejor ajuste. Mientras que, en la segunda, tales descendientes serán rechazados. Entre los algoritmos de cruce más conocidos está el cruce de 1 punto (SPX), de 2 puntos (DPX) y el cruce uniforme. (Gestal et al., 2010).

5.7.5.1 Cruce de un punto (SPX). En este método un par de cromosomas padres es dividido por un punto aleatorio en dos partes, llamadas cabeza y cola. Luego, la cabeza de un cromosoma se une con la cola del otro y viceversa. (Figura 10).

Figura 10.

Cruce de un punto

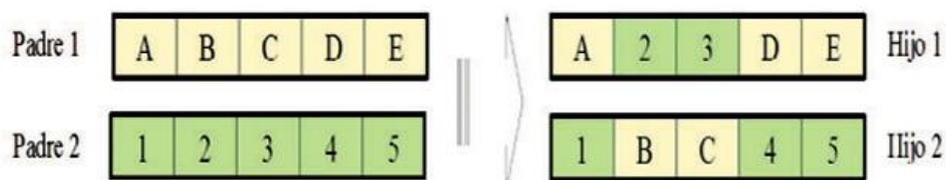


Nota. Adaptado de *Cruce de un punto* (p. 21), Gestal et al., 2010, Universidade da Coruña.

5.7.5.2 Cruce de dos puntos (DPX). Se divide cada cromosoma de los padres en tres segmentos aleatoriamente. Luego, el segmento central de un padre es unido con los dos segmentos laterales del otro. (Figura 11).

Figura 11.

Cruce de dos puntos

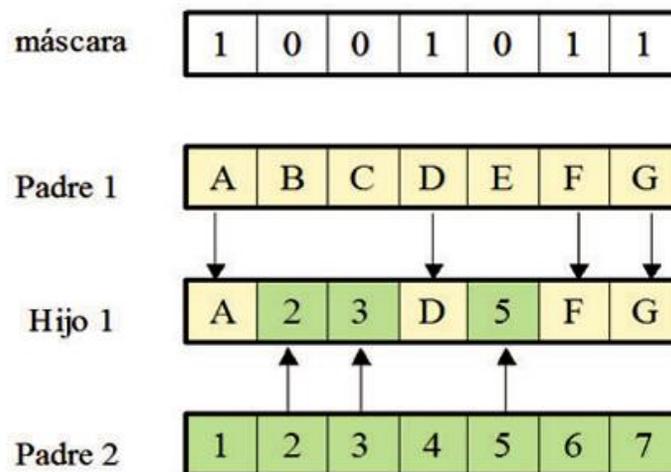


Nota. Adaptado de *Cruce de dos puntos* (p. 22), Gestal et al., 2010, Universidade da Coruña.

5.7.5.3 Cruce uniforme. “La técnica implica la generación de una máscara de cruce con valores binarios. Si en una de las posiciones de la máscara hay un 1, el gen situado en esa posición en uno de los descendientes se copia del primer padre. Si por el contrario hay un 0 el gen se copia del segundo padre”. (Gestal et al., 2010). (Figura 12).

Figura 12.

Cruce uniforme



Nota. Adaptado de *Cruce uniforme* (p. 23), Gestal et al., 2010, Universidade da Coruña.

5.7.6 Operador de mutación

Según (Gestal et al., 2010) “se realizan mutaciones para garantizar que ningún punto del espacio de búsqueda tenga una probabilidad nula de ser examinado”. Para ello, se establece una probabilidad de mutación adecuada y se selecciona de forma aleatoria el gen que será mutado. Altıparmak et al. (2006) agrega que “a diferencia del cruce, la mutación usualmente se hace para modificar genes dentro de un cromosoma”. Esta afirmación, parte del hecho de que el valor correspondiente al gen seleccionado para ser mutado, será reemplazado por un nuevo valor determinado con alguna estrategia de búsqueda en todo el espacio de soluciones.

5.7.7 Otros operadores del GA

En el desarrollo de un GA hay dos opciones con respecto al manejo de las poblaciones tras cada generación. La primera opción es trabajar con una población temporal entre dos generaciones distintas. En tal caso, solo se hace necesario el uso de los operadores antes mencionados. La segunda opción es trabajar con una única población e ir reemplazando los individuos. En este escenario, se hace necesario el uso de los siguientes operadores.

5.7.7.1 Algoritmo de reemplazo.

Con una sola población, se hace necesario eliminar un individuo de la misma cuando se desea inserta uno nuevo. En tal caso, el reemplazo se puede hacer eliminando: otros individuos de forma aleatoria, a los padres, a los peores o a individuos con un valor de ajuste similar al del nuevo.

5.7.7.2 Copia.

Este operador consiste en pasar un individuo de una generación a otra, sin modificarlo. Esto se hace generalmente cuando no se efectúa el cruce.

5.7.7.3 Elitismo. Consiste en elegir siempre al mejor individuo para ser copiado de una generación a otra. De esta manera, se garantiza una mejora en el valor de ajuste con cada nueva generación.

6. Diseño y Modelamiento del Problema

En el presente capítulo, se define el problema abordado a lo largo de la investigación; se ilustra el tipo de red logística central del estudio y se describe el modelo matemático derivado de la misma.

6.1 Definición del Problema

Como se mencionó antes, el problema abordado en la presente investigación está basado en el diseño de red logística integrada de Pishvae et al. (2010). La red originalmente está conformada por centros de Producción/Recuperación, centros de distribución, centros de disposición, zonas de consumo y centros de distribución y recolección/inspección que tienen la opción de ser híbridos, como una decisión variable del modelo. Con la intención de consolidar el sistema como una red de CLSC, se decidió añadirle al diseño original un nodo correspondiente a proveedores. A través de la red fluyen materias primas, productos nuevos y productos retornados. Las materias primas son enviadas desde los proveedores hacia los centros de producción/recuperación. Los productos nuevos viajan desde los centros de producción/recuperación hacia los centros de distribución y, desde allí, hasta las zonas de consumo. En cambio, los productos retornados siguen un flujo inverso; empezando en las zonas de consumo, pasando por los centros de recolección/inspección - donde son clasificados en dañados o recuperables - y llegando a los centros de disposición o recuperación, respectivamente. (Figura 13).

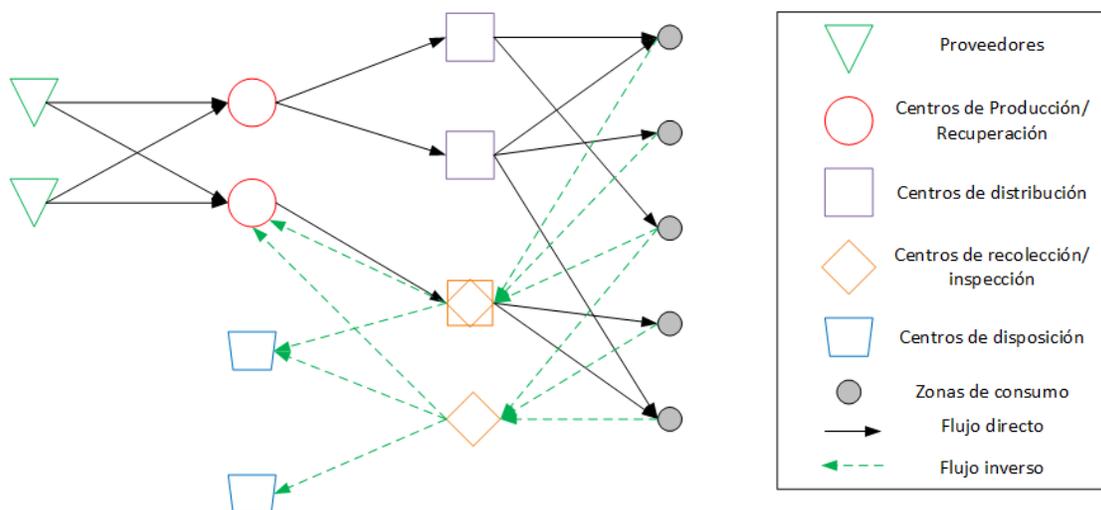
En cuanto al modelo, se busca determinar la cantidad necesaria de los centros de producción/recuperación, distribución, recolección/inspección y disposición dentro de la red; su ubicación, su capacidad y el flujo de productos entre ellos minimizando los costos fijos de abrir una nueva instalación, los costos de envío y el impacto ambiental generado por la apertura de una nueva instalación y la emisión de CO₂ durante el transporte. El modelo resultante se puede describir mediante la MILP y se desarrolla un algoritmo genético para resolverlo. La red está pensada en forma genérica, pero se estudiará con un caso de la industria de productos eléctricos y electrónicos a fin de medir el rendimiento del GA.

Finalmente, se tienen en cuenta los siguientes supuestos:

- Las ubicaciones y la cantidad de clientes y proveedores son conocidas y fijas.
- Los productos recuperados entran al mercado al mismo precio que los productos nuevos.
- Los productos retornados son un porcentaje fijo de la demanda.
- La tasa de productos dañados es un valor predeterminado.
- Existe un sólo tipo de MP necesario para la producción.
- Existe una única opción de transporte y tiene capacidad ilimitada.
- Existe un conjunto de ubicaciones potenciales E , que es una intersección entre el conjunto de ubicaciones potenciales de centros de distribución J y el conjunto de ubicaciones potenciales de centros de recolección/inspección L .
- Una planta se define como híbrida cuando se decide abrir una instalación de distribución ($Y_{jn} = 1$) en una ubicación $e \in E$ y una instalación de recolección/inspección ($z_{ln} = 1$) en una ubicación $e \in E$. En otras palabras, se abre una sola planta para las operaciones de distribución y recolección/inspección.

Figura 13.

Diseño de la red logística integrada



Nota. Adaptado de *Un algoritmo memético para el diseño de una red logística integrada directa/inversa biobjetivo* (p. 1103), por Pishvae et al., 2010, *Computers & Operations Research*, 37.

6.2 Formulación Matemática

A continuación, se presenta la caracterización de los parámetros y variables, y se definen los objetivos y limitaciones del modelo. La mayor parte del modelo está adaptada de la formulación planteada por Pishvae et al. (2010), con un ajuste en las variables y restricciones derivado de la inclusión del nodo de Proveedores. Además, la minimización del impacto ambiental está basada en el trabajo de Fathollahi-Fard & Hajiaghaei-Keshteli (2018).

Conjuntos de índices

- S Conjunto de proveedores en ubicaciones fijas $s \in S$.
- I Conjunto de ubicaciones potenciales de centros de Producción/Recuperación $i \in I$.
- J Conjunto de ubicaciones potenciales de centros de Distribución $j \in J$.
- K Ubicaciones fijas de las zonas de consumo $k \in K$.
- L Conjunto de ubicaciones potenciales de centros de Recolección/Inspección $l \in L$.
- M Conjunto de ubicaciones potenciales de centros de Disposición Final $m \in M$.
- N Conjunto de niveles de capacidad disponibles para las instalaciones $n, n' \in N$.
- E Conjunto de sitios potenciales para la instalación de centros de Recolección/Inspección y Distribución híbridos $e \in E$; $E \subset J$, $E \subset L$.

Parámetros

- d_k Demanda de la zona de consumo k .
- r_k Tasa de retorno de productos usados de la zona de consumo k .
- $disp.$ Fracción de disposición promedio.

mp Cantidad de MP prima necesario para elaborar una unidad de producto.

fp_{in} Costo fijo de abrir un centro de Producción/Recuperación en la ubicación i con nivel de capacidad n .

fd_{jn} Costo fijo de abrir un centro de Distribución en la ubicación j con nivel de capacidad n .

fr_{ln} Costo fijo de abrir un centro de Recolección/Inspección en la ubicación l con nivel de capacidad n .

ff_{mn} Costo fijo de abrir un centro de Disposición Final en la ubicación m con nivel de capacidad n .

$fh_{enn'}$ Ahorro en los costos fijos asociados a la apertura de un centro de Recolección/Inspección con nivel de capacidad n' y un centro de Distribución con nivel de capacidad n , en la ubicación e .

cs_{si} Costo unitario de envío de MP desde el proveedor s hasta el centro de Producción/Recuperación i .

cx_{ij} Costo de envío por unidad de producto desde el centro de Producción/Recuperación i hasta el centro de Distribución j .

cu_{jk} Costo de envío por unidad de producto desde el centro de Distribución j hasta la Zona de Consumo k .

cq_{kl} Costo de envío por unidad de producto devuelto desde la Zona de Consumo k hasta el centro de Recolección/Inspección l .

cp_{li} Costo de envío por unidad de producto recuperable desde el centro de Recolección/Inspección l hasta el centro de Producción/Recuperación i .

ct_{lm} Costo de envío por unidad de producto dañado desde el centro de Recolección/Inspección l hasta el centro de Disposición Final m .

caw_{in} Capacidad de producción del centro de Producción/Recuperación i con nivel n .

ca_{jn} Capacidad del centro de Distribución j con nivel n .

ca_{zn} Capacidad del centro de Recolección/Inspección l con nivel n .

ca_{vn} Capacidad del centro de Disposición Final m con nivel n .

car_{in} Capacidad de recuperación del centro de Producción/Recuperación i con nivel n .

Ip_{in} Impacto ambiental de abrir un centro de Producción/Recuperación en la ubicación i con nivel de capacidad n .

Id_{jn} Impacto ambiental de abrir un centro de Distribución en la ubicación j con nivel de capacidad n .

Ir_{ln} Impacto ambiental de abrir un centro de Recolección/Inspección en la ubicación l con nivel de capacidad n .

If_{mn} Impacto ambiental de abrir un centro de Disposición Final en la ubicación m con nivel de capacidad n .

$Ih_{enn'}$ Impacto ambiental asociado a la apertura de un centro de Recolección/Inspección con nivel de capacidad n' y un centro de Distribución con nivel de capacidad n , en la ubicación e .

Es_{si} Emisión de CO_2 por unidad de MP transportada desde el proveedor s hasta el centro de Producción/Recuperación i .

Ex_{ij} Emisión de CO_2 por unidad de producto transportado desde el centro de Producción/Recuperación i hasta el centro de Distribución j .

Eu_{jk} Emisión de CO_2 por unidad de producto transportado desde el centro de Distribución j hasta la Zona de Consumo k .

Eq_{kl} Emisión de CO_2 por unidad de producto devuelto transportado desde la Zona de Consumo k hasta el centro de Recolección/Inspección l .

E_{pli} Emisión de CO_2 por unidad de producto recuperable transportado desde el centro de Recolección/Inspección l hasta el centro de Producción/Recuperación i .

$E_{t_{lm}}$ Emisión de CO_2 por unidad de producto dañado transportado desde el centro de Recolección/Inspección l hasta el centro de Disposición Final m .

Variables de decisión

A_{si} Cantidad de MP enviada desde el proveedor s hasta el centro de Producción/Recuperación i .

X_{ij} Cantidad de productos enviados desde el centro de Producción/Recuperación i hasta el centro de Distribución j .

U_{jk} Cantidad de productos enviados desde el centro de Distribución j hasta la Zona de Consumo k .

Q_{kl} Cantidad de productos reciclables enviados desde la Zona de Consumo k hasta el centro de Recolección/Inspección l .

P_{li} Cantidad de productos recuperables enviados desde el centro de Recolección/Inspección l hasta el centro de Producción/Recuperación i .

T_{lm} Cantidad de productos recuperables enviados desde el centro de Recolección/Inspección l hasta el centro de Disposición Final m .

Variables Binarias

$$W_{in} = \begin{cases} 1, & \text{Si el centro de Producción/Recuperación es abierto en la ubicación } i. \\ 0, & \text{En caso contrario.} \end{cases}$$

$$Y_{jn} = \begin{cases} 1, & \text{Si el centro de Distribución es abierto en la ubicación } j. \\ 0, & \text{En caso contrario.} \end{cases}$$

$$Z_{ln} = \begin{cases} 1, & \text{Si el centro de Recolección/Inspección es abierto en la ubicación } l. \\ 0, & \text{En caso contrario.} \end{cases}$$

$$V_{mn} = \begin{cases} 1, & \text{Si el centro de Disposición es abierto en la ubicación } m. \\ 0, & \text{En caso contrario.} \end{cases}$$

Funciones Objetivo

Objetivo 1: Minimizar el costo total

Costo total (Z_1) = Costo fijo de abrir una nueva instalación (i, j, l, m) + Costo de transportar los productos entre las instalaciones – ahorro en los costos por abrir plantas híbridas.

$$\begin{aligned} Z_1 = & \sum_i \sum_n fp_{in}W_{in} + \sum_j \sum_n fd_{jn}Y_{jn} + \sum_l \sum_n fr_{ln}Z_{ln} + \sum_m \sum_n ff_{mn}V_{mn} \\ & - \sum_e \sum_n \sum_{n'} fh_{enn'}Z_{en'}Y_{en} + \sum_s \sum_i cs_{si}A_{si} + \sum_i \sum_j cx_{ij}X_{ij} \\ & + \sum_j \sum_k cu_{jk}U_{jk} + \sum_k \sum_l cq_{kl}Q_{kl} \\ & + \sum_l \sum_m ct_{lm}T_{lm} + \sum_l \sum_i cp_{li}P_{li} \end{aligned} \quad (1)$$

La ecuación (1) resume el costo total de la red logística integrada, compuesto por los costos de abrir una nueva instalación, los costos de enviar productos entre las distintas instalaciones y el ahorro debido a la integración de plantas. El primer tipo de costo es calculado como el producto entre el costo fijo (fp, fd, fr, ff) de abrir una instalación (i, j, l, m) con un nivel de capacidad n y la variable de decisión de apertura de cada instalación (W, Y, Z, V). De forma similar, el costo de transporte se calcula como el costo de transporte unitario (cs, cx, cu, cq, ct, cp) por la cantidad de

producto enviada entre las plantas (A, X, U, Q, T, P). El último término correspondiente al ahorro es negativo, puesto que disminuirá el costo de toda la red.

Objetivo 2: Minimizar el impacto ambiental

Impacto ambiental de la red (Z_2) = Impacto ambiental generado por la apertura de una nueva instalación (i, j, l, m) + impacto generado por abrir instalaciones híbridas + Emisiones de CO_2 durante el transporte de productos y MP.

$$\begin{aligned}
 Z_2 = & \sum_i \sum_n I p_{in} W_{in} + \sum_j \sum_n I d_{jn} Y_{jn} + \sum_l \sum_n I r_{ln} Z_{ln} + \sum_m \sum_n I f_{mn} V_{mn} \\
 & + \sum_e \sum_n \sum_{n'} I h_{enn'} Z_{en'} Y_{en} + \sum_s \sum_i E s_{si} A_{si} + \sum_i \sum_j E x_{ij} X_{ij} \\
 & + \sum_j \sum_k E u_{jk} U_{jk} + \sum_k \sum_l E q_{kl} Q_{kl} \\
 & + \sum_l \sum_m E t_{lm} T_{lm} + \sum_l \sum_i E p_{li} P_{li}
 \end{aligned} \tag{2}$$

La ecuación (2), correspondiente a la minimización del impacto ambiental, está expresada de forma semejante a la ecuación del costo. En esta ecuación se calcula el impacto ambiental de abrir una nueva instalación en la red, el impacto ambiental de abrir instalaciones híbridas y la emisión de CO_2 atribuida al transporte de productos y MP. En este sentido, la ecuación (2) difiere de la ecuación (1), únicamente en dos aspectos: en lugar de utilizar costos fijos de apertura y costos unitarios de transporte, se emplean los parámetros de impacto ambiental por apertura de una instalación (I_p, I_d, I_r, I_f) y tasa unitaria de emisión de CO_2 ($E_s, E_x, E_u, E_q, E_t, E_p$); y el término negativo correspondiente al ahorro en los costos pasa a ser positivo, ya que, se considera que la instalación de centros híbridos no reduce el impacto ambiental.

Hasta este punto, se han definido los objetivos principales del modelo matemático. Sin embargo, al observar las ecuaciones (1) y (2), es posible identificar que el modelo planteado no pertenece a la MILP como se esperaba. La anterior afirmación está basada en que los términos $\sum_e \sum_{n'} \sum_n fh_{in'n} Z_{en'} Y_{en}$ y $\sum_e \sum_{n'} \sum_n Ih_{in'n} Z_{en'} Y_{en}$, correspondientes a la instalación de centros híbridos, condicionan el modelo a la MILNP porque involucran la multiplicación de dos variables binarias. Para evitar tal situación y disminuir la complejidad de la programación no lineal, se define una nueva variable y se reformulan las funciones objetivo a fin de linealizar el modelo inicial.

Nueva variable para la apertura de instalaciones híbridas

$$H_{enn'} = Z_{en'} * Y_{en} \quad (3)$$

$$H_{enn'} \in \{0, 1\} ; \forall e \in E, \forall n' \in N, \forall n \in N \quad (4)$$

Funciones objetivo reformuladas

Objetivo 1: Minimizar el costo total

$$\begin{aligned} Z_1 = & \sum_i \sum_n fp_{in} W_{in} + \sum_j \sum_n fd_{jn} Y_{jn} + \sum_l \sum_n fr_{ln} Z_{ln} + \sum_m \sum_n ff_{mn} V_{mn} \\ & - \sum_e \sum_n \sum_{n'} fh_{enn'} H_{enn'} + \sum_s \sum_i cS_{si} A_{si} + \sum_i \sum_j cx_{ij} X_{ij} \\ & + \sum_j \sum_k cu_{jk} U_{jk} + \sum_k \sum_l cq_{kl} Q_{kl} \\ & + \sum_l \sum_m ct_{lm} T_{lm} + \sum_l \sum_i cp_{li} P_{li} \end{aligned} \quad (5)$$

Objetivo 2: Minimizar el impacto ambiental

$$\begin{aligned}
Z_2 = & \sum_i \sum_n I p_{in} W_{in} + \sum_j \sum_n I d_{jn} Y_{jn} + \sum_l \sum_n I r_{ln} Z_{ln} + \sum_m \sum_n I f_{mn} V_{mn} \\
& + \sum_e \sum_n \sum_{n'} I h_{enn'} H_{enn'} + \sum_s \sum_i E s_{si} A_{si} + \sum_i \sum_j E x_{ij} X_{ij} \\
& + \sum_j \sum_k E u_{jk} U_{jk} + \sum_k \sum_l E q_{kl} Q_{kl} + \sum_l \sum_m E t_{lm} T_{lm} + \sum_l \sum_i E p_{li} P_{li}
\end{aligned} \tag{6}$$

Restricciones

Linealización del modelo

La primera restricción que se requiere surge de la reformulación del modelo inicial y de la creación de la nueva variable $H_{enn'}$. Debido a que la función objetivo que minimiza el costo tiene una tendencia a asignar el valor de 1 a la variable $H_{enn'}$, se hace necesaria la ecuación para los casos en que $Z_{en'}$, Y_{en} o ambas son cero.

$$2H_{enn'} \leq Z_{en'} + Y_{en} ; \quad \forall e \in E, \quad \forall n \in N, \quad \forall n' \in N \tag{7}$$

Capacidad de respuesta

A continuación, se presentan las restricciones (5) y (6), las cuales aseguran que se atienda la demanda del cliente por completo y se recojan todos los productos devueltos de las zonas de consumo.

$$\sum_{j \in J} U_{jk} = d_k ; \quad \forall k \in K \tag{8}$$

$$\sum_{l \in L} Q_{kl} = r_k d_k ; \quad \forall k \in K \tag{9}$$

Balance de flujos

Las ecuaciones (10) a (13) corresponden al balance de flujos entre los nodos de la red. Primero, se asegura que la cantidad de MP enviada desde el proveedor hasta el productor sea la necesaria para fabricar y enviar X_{ij} productos al centro de distribución. Luego, se equilibran los flujos de productos nuevos entre el productor y el distribuidor, productos recuperables entre el centro de Recolección/Inspección y el centro de Producción/Recuperación, y productos dañados entre el centro de Recolección/Inspección y el centro de Disposición.

$$\sum_{s \in S} \frac{A_{si}}{mp} + \sum_{l \in L} P_{il} = \sum_{j \in J} X_{ij} ; \forall i \in I \quad (10)$$

$$\sum_{i \in I} X_{ij} = \sum_{k \in K} U_{jk} ; \forall j \in J \quad (11)$$

$$\sum_{m \in M} T_{lm} = disp * \sum_{k \in K} Q_{kl} ; \forall l \in L \quad (12)$$

$$\sum_{i \in I} P_{li} = (1 - disp) * \sum_{k \in K} Q_{kl} ; \forall l \in L \quad (13)$$

Capacidad

Las ecuaciones (14) a (21), limitan el flujo enviado entre dos nodos al nivel de capacidad de la instalación emisora e impiden que dicho flujo exceda la capacidad de la instalación receptora.

Además, las variables binarias presentes en las ecuaciones garantizan que se envíe producto sólo a instalaciones abiertas.

$$\sum_{s \in S} A_{si} \leq mp * \sum_{n \in N} W_{in} caw_{in} ; \forall i \in I \quad (14)$$

$$\sum_{j \in J} X_{ij} \leq \sum_{n \in N} W_{in} caw_{in} ; \forall i \in I \quad (15)$$

$$\sum_{i \in I} X_{ij} \leq \sum_{n \in N} Y_{jn} cay_{jn} ; \forall j \in J \quad (16)$$

$$\sum_{k \in K} U_{jk} \leq \sum_{n \in N} Y_{jn} cay_{jn} ; \forall j \in J \quad (17)$$

$$\sum_{k \in K} Q_{kl} \leq \sum_{n \in N} Z_{ln} caz_{ln} ; \forall l \in L \quad (18)$$

$$\sum_{l \in L} T_{lm} \leq \sum_{n \in N} V_{mn} cav_{mn} ; \forall m \in M \quad (19)$$

$$\sum_{l \in L} P_{li} \leq \sum_{n \in N} W_{in} car_{in} ; \forall i \in I \quad (20)$$

$$\sum_{m \in M} T_{lm} + \sum_{i \in I} P_{li} \leq \sum_{n \in N} Z_{ln} caz_{ln} ; \forall l \in L \quad (21)$$

Finalmente, se presentan las restricciones para las variables binarias y las restricciones de no negatividad.

$$\sum_{n \in N} W_{in} \leq 1; \forall i \in I \quad (22)$$

$$\sum_{n \in N} Y_{jn} \leq 1; \forall j \in J \quad (23)$$

$$\sum_{n \in N} Z_{ln} \leq 1; \forall l \in L \quad (24)$$

$$\sum_{n \in N} V_{mn} \leq 1; \forall m \in M \quad (25)$$

$$W_{in}, Y_{jn}, Z_{ln}, V_{mn} \in \{0,1\} ; \forall i \in I, \quad \forall j \in J, \quad \forall l \in L, \quad \forall m \in M, \\ \forall n \in N \quad (26)$$

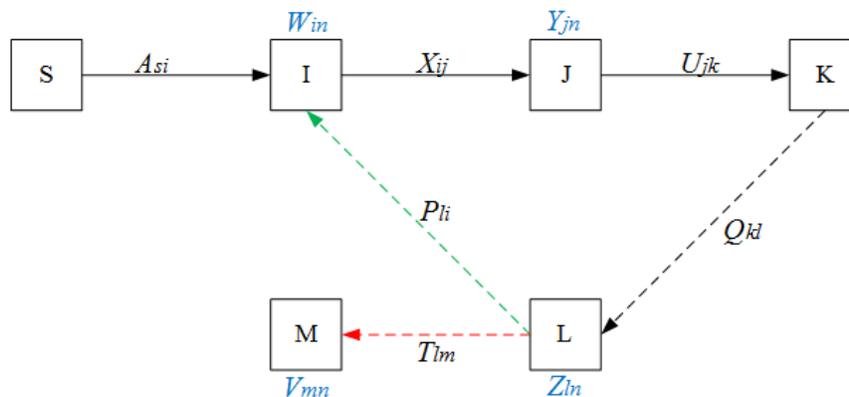
$$A_{si}, X_{ij}, U_{jk}, Q_{kl}, T_{lm}, P_{li} \geq 0 ; \forall s \in S, \quad \forall i \in I, \quad \forall j \in J, \quad \forall l \in L, \\ \forall m \in M \quad (27)$$

En la Figura 14 se reúnen las variables y se resumen las relaciones anteriormente descritas. Allí, es posible observar los flujos de producto ($A_{si}, X_{ij}, U_{jk}, Q_{kl}, T_{lm}, P_{li}$) entre los diferentes nodos de

la red (S, I, J, K, L, M). También, aparecen las variables binarias (W_{in} , Y_{jn} , Z_{ln} , V_{mn}) que determinan si se abre o no su instalación correspondiente.

Figura 14.

Estructura del modelo de la IFRLN



Nota. Un algoritmo memético para el diseño de una red logística integrada directa/inversa biobjetivo (p. 1105), por Pishvae et al., 2010, *Computers & Operations Research*, 37.

6.3 Obtención de los datos

Para resolver el modelo matemático se hace uso de un conjunto de datos de entrada presentados en el Apéndice B. Los datos relacionados con el número potencial de instalaciones dentro de la red provienen de dos casos de estudio de la industria de productos electrónicos y digitales, abordados en los trabajos de (Lee & Dong, 2008) y (Zohal & Soleimani, 2016). Mientras que los valores de impacto ambiental para el objetivo 2 son generados con una distribución normal a partir de los límites propuestos por (Fathollahi-Fard & Hajiaghaei-Keshteli, 2018), quienes utilizaron la base de datos del RECIPE 2008 y el software ECO-it para su estimación.

7. Algoritmo Genético propuesto

El enfoque de solución heurístico propuesto es un algoritmo genético con función de aptitud basada en pesos aleatorios, método de selección por torneo y operadores de cruce y mutación basados en segmento. Debido a la naturaleza evolutiva de los algoritmos genéticos a partir de una población inicial, se requiere codificar previamente el problema mediante el método de codificación basado en la prioridad, como se muestra a continuación.

7.1 Codificación de las soluciones

Como se mencionó en el marco teórico, el método de codificación basado en la prioridad está fundamentado en una matriz de $j \times k$, donde j corresponde a los recursos y k a los depósitos. Siendo así, la ubicación de una celda dentro de la matriz representa un nodo de la red logística, donde se efectúa una interacción entre un recurso y un depósito, y el valor contenido en ella, indica la prioridad de atención que debe tener tal nodo. (Jamshidi et al., 2012).

Para el caso de la CLSC, tratada en este trabajo, se cuenta con 5 tipos de instalaciones y una región de clientes a servir. De tal modo, existen 6 escalones a lo largo de la red, donde cada instalación puede ser un recurso o un depósito, dependiendo del escalón. La salvedad antes mencionada deriva en que un cromosoma de la CLSC está representado por una matriz de 6 segmentos, donde cada segmento tiene a su vez j recursos más k depósitos. Debido a que el diseño de red abordado tiene S, I, J, K, L, M instalaciones, la matriz resultante contiene entonces $(S+I+I+J+J+K+L+K+L+M+L+I)$ columnas. Adicionalmente, se dispone de una fila para la prioridad y otra para el nivel de capacidad de cada instalación, como se muestra en la

Figura 15.

Figura 15.

Cromosoma de la CLSC codificado

	Segmento 1				Segmento 2					Segmento 3					Segmento 4					Segmento 5				Segmento 6				
	S-I				I-J					J-K					L-K					M-L				I-L				
Nodo	1	2	1	2	1	2	1	2	3	1	2	3	1	2	3	1	2	1	2	3	1	2	1	2	1	2	1	2
Prioridad	2	3	4	1	3	4	5	2	1	2	4	6	3	1	5	5	3	1	4	2	4	2	1	3	1	2	4	3
Nivel	3	1	2	3	3	1	3	1	1	3	2	1	1	1	1	1	1	2	3	3	1	2	2	1	3	1	2	1

De la figura es importante resaltar que se establecieron 3 niveles de capacidad posibles para cada instalación y que, tanto el nivel como el valor de la prioridad, son generados aleatoriamente durante la creación de los cromosomas de la población inicial. El pseudocódigo para la codificación de las soluciones queda como sigue (Figura 16)

Figura 16.

Pseudocódigo de la codificación del cromosoma de la CLSC

Algoritmo 1. Codificación del cromosoma	
<hr/>	
1.	Inicio
2.	<i>Entradas</i>
3.	pop_Size Tamaño de la población
4.	N Niveles de capacidad
5.	j Recursos
6.	k Depósitos
7.	<i>Salidas</i>
8.	Vjk Matriz con cromosomas de la población inicial
9.	Inicializar variables
10.	Njk Vector niveles
11.	Cromjk Vector prioridades
12.	for n=1:1:8*pop_Size
13.	Paso 1: generar la fila n del vector Njk con números aleatorios entre 1 y N;
14.	Paso 2: generar la fila n del vector Cromjk con números aleatorios entre 1 y (j + k), sin repetir valores;
15.	Paso 3: Unir los dos vectores en la matriz Vjk;
16.	Fin
17.	Mostrar la matriz Vjk
19.	Fin

7.2 Decodificación del cromosoma

Una vez que se cuenta con una población inicial suficiente de cromosomas, generados por el algoritmo de codificación, se procede a decodificar cada cromosoma para obtener las variables de decisión y los valores de las funciones objetivo contenidas en el mismo. Para esto, se hace uso de la estructura de árbol de transporte, como forma de representación de los nodos de la red logística, y la asignación mediante el mínimo costo de transporte. A continuación, se resume el procedimiento de asignación y la generación del árbol de transporte para el segmento J-K del cromosoma de la Figura 15.

El procedimiento parte de un gen que contiene los recursos y depósitos, las prioridades de cada uno y los niveles de capacidad de cada instalación, generados aleatoriamente. (Ver Figura 17).

Figura 17.

Segmento j-k de un cromosoma de la CLSC codificado

Segmento 3						
J-K						
Nodo	1	2	3	1	2	3
Prioridad	2	4	6	3	1	5
Nivel	3	2	1	1	1	1

Cabe destacar que el gen representado en la Figura 17 corresponde al tercer escalón de la red logística, donde se encuentran los nodos de Centros de Distribución (J) y Clientes (K). Para el ejemplo, existen 3 posibles centros de distribución y 3 clientes; aquí, los centros de distribución se comportan como recursos (los recursos siempre van primero en la matriz) y los clientes son los depósitos a surtir (siempre van al final de la matriz). A partir de esta información, se selecciona el

recurso (o depósito) que contenga el mayor valor de prioridad y se procede a revisar en la matriz de costos unitarios de transporte el depósito (o recurso) relacionado, con el menor costo posible.

Para este ejemplo, el centro de distribución 3 tiene la mayor prioridad con un valor de 6 (Ver Figura 17). Al revisar los clientes a los que este recurso puede servir, se encuentra que el menor costo generado por concepto de transporte es 4, cuando se atiende al cliente 1. (Ver Tabla 8)

Tabla 8.

Costos unitarios de transporte del distribuidor j al cliente k

Distribuidor/ Cliente	1	2	3
1	8	8	10
2	11	11	4
3	4	9	12

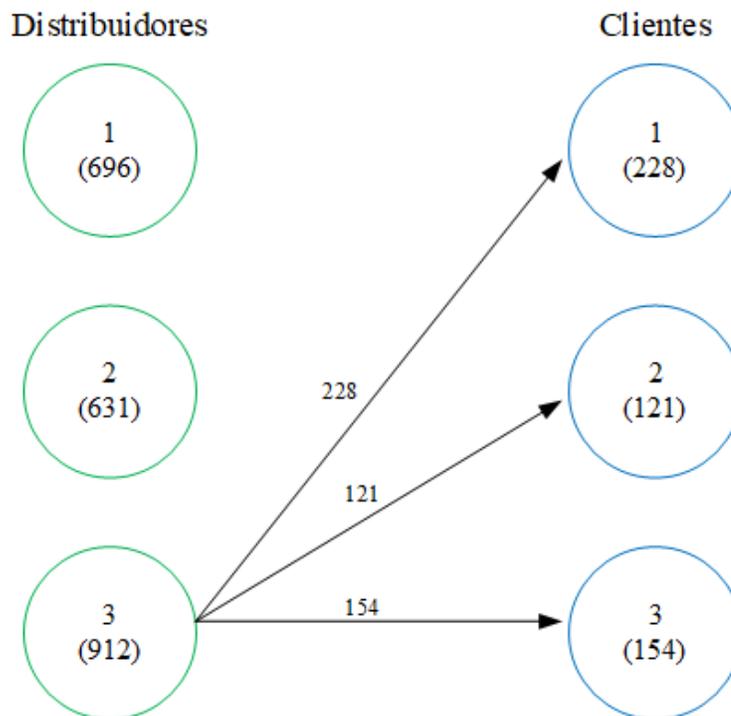
Luego de determinar el recurso emisor del producto y el depósito demandante, se procede a decidir la cantidad enviada; esta se establece como el menor valor entre la capacidad del recurso y la demanda del depósito, a fin de garantizar el cumplimiento de la entrega. En el ejemplo, se ve claramente que la capacidad del recurso 3 es suficiente para satisfacer la demanda total del cliente 1: 228 unidades de producto; por lo tanto, ese será el tamaño del envío. Cuando un recurso o un depósito llega a su límite, inmediatamente su capacidad (o demanda) es llevada a cero, al igual que su prioridad. (Ver Tabla 9).

Al continuar el procedimiento arriba descrito, se llega a la Tabla 9, la cual registra cada asignación realizada con el mínimo costo y la más alta prioridad posible hasta satisfacer la demanda de todos los clientes.

Tabla 9.*Asignación de envíos del distribuidor j al cliente k*

Iteración	$V(j+k)$	Capacidad	Demanda	J	K	g
0	[2 4 6 3 1 5]	(696 631 912)	(228 121 154)	3	1	228
1	[2 4 6 0 1 5]	(696 631 684)	(0 121 154)	3	2	121
2	[2 4 6 0 0 5]	(696 631 563)	(0 0 154)	3	3	154
3	[2 4 6 0 0 0]	(696 631 409)	(0 0 0)			

A partir de la revisión de la Tabla 9, donde se tienen los centros de distribución potenciales (1, 2, 3) y los clientes (1, 2, 3), se puede deducir que el centro 3, con un nivel de capacidad 1, es suficiente para atender la demanda de todos los clientes. Este hallazgo también puede ser visto de manera gráfica mediante la representación de árbol de transporte mostrado en la Figura 18

Figura 18.*Árbol de transporte del nodo $j-k$ de la CLSC*

El procedimiento descrito anteriormente se desarrolla de manera general mediante un algoritmo de decodificación modificado, presentado por Pishvae et al. (2010), quien asegura que con esta codificación es posible llegar a soluciones factibles sin la necesidad de un algoritmo de reparación. En la Figura 19, se relaciona el pseudocódigo del algoritmo de decodificación basado en la prioridad de Pishvae et al. (2010), con algunos ajustes realizados para acoplarlo a los supuestos del modelo de la CLSC.

Figura 19.

Pseudocódigo del algoritmo de decodificación basada en la prioridad

Algoritmo 2. Decodificación basada en la prioridad

```

1. Inicio
2. Entradas
3. N           Niveles
4. pop_Size   Tamaño de la población
5. j           Recursos
6. k           Depósitos
7. b           Demanda
8. Ca         Capacidad disponible
9. Cjk        Costo unitario de transporte entre j y k
10. Vjk       Matriz de cromosomas
11.
12. Salidas
13. g           Cantidades a enviar entre instalaciones
14. Z           Instalaciones abiertas
15.
16.           while b > 0
17.               Paso 1:           Inicializar las variables g y Z en cero
18.               Paso 2:           Seleccionar el recurso (o depósito) con el mayor valor de prioridad
19.               y llamarlo l
20.                   l = max(Vjk(1,:));
21.
22.               Paso 3:           Seleccionar recursos y depósitos por prioridad y costo
23.               if l ∈ j si l pertenece a los recursos, entonces:
24.                   j=l; seleccionar un recurso j
25.                   k=min(Cjk(j, :)); seleccionar el depósito con mínimo costo para el
26.                   recurso j
27.               else
28.                   k=l; seleccionar un depósito k
29.                   j=min(Cjk(:, k)); seleccionar el recurso con mínimo costo para el depósito k
30.               Fin

```

```

31.          n= Vjk(2, j) seleccionar el nivel de capacidad del recurso j
32.          Paso 4:          Actualizar las demandas y capacidades
33.          g(j, k) = min(Ca(j,nivel), b(k)); Asignar la cantidad a ser enviada entre j y k
34.          Ca(j,nivel) = Ca(j,nivel) - g(j, k);
35.          b(k) = b(k)- g(j,k);
36.          Paso 5:          Actualizar las prioridades del cromosoma
37.          if (Ca(j,nivel)==0)
38.              Vjk(1,j)=0;
39.          Fin
40.          if (b(k)==0)
41.              Vjk(1, (k + max(j)))=0;
42.          Fin
43.          Fin
44.          Paso 6:          Asignar las variables binarias de instalaciones abiertas.
45.          if sum(b(j, k)>0)
46.              Z(j, k)=1;
47.          Fin
48.          Fin
49.

```

El Algoritmo 2 es capaz de decodificar cualquier escalón de la red; pero lo hace de forma individual e independiente. En otras palabras, para decodificar la red completa, se debe decodificar cada escalón siguiendo un orden estricto. Esta limitación surge de las características de conformación propias de la CLSC. Debido a que la CLSC se puede entender como dos redes, una directa y otra inversa, la decodificación de algunos escalones de la red dependerá de otros. En la red directa, se debe iniciar con el tercer segmento, para luego proceder con la decodificación del segundo segmento y del primero; y en la red inversa, es imposible decodificar los escalones 5 y 6 sin antes haber decodificado el cuarto segmento. Esta situación se debe a que la red directa es un sistema pull y la red inversa es un sistema push; por lo tanto, en ambos casos la apertura de las instalaciones y la asignación de envíos y capacidades dependerán de la demanda de los clientes, los cuales se encuentran en el tercer y cuarto segmento. Siguiendo esta lógica, la red completa se puede decodificar aplicando el algoritmo 3 (Figura 20)

Figura 20.*Pseudocódigo del algoritmo de decodificación de la red completa***Algoritmo 3. Decodificación de la red completa**

-
1. **Inicio**
 2. *Entradas:* $d_k, r_k, disp, cs_{si}, cx_{ij}, cu_{jk}, cq_{kl}, cpl_i, ct_{lm}, caw_{in}, cay_{jn}, caz_{ln}, cav_{mn}, car_{in}$
 3. *Salidas:* $A_{si}, X_{ij}, U_{jk}, Q_{kl}, P_{li}, T_{lm}, W_{in}, Y_{jn}, Z_{ln}, V_{mn}$
 4. *Paso 1:* Calcular U_{jk}, Y_{jn} usando el Algoritmo 1;
 5. *Paso 2:* Calcular X_{ij}, W_{in} usando el Algoritmo 1;
 6. *Paso 3:* Calcular A_{si} usando el Algoritmo 1;
 7. *Paso 4:* Calcular Q_{kl}, Z_{ln} usando el Algoritmo 1;
 8. *Paso 5:* Calcular T_{lm}, V_{mn} usando el Algoritmo 1;
 9. *Paso 6:* Calcular P_{li} usando el Algoritmo 1.
 10. **Fin**
-

El algoritmo 3 permite conocer las variables de decisión del modelo asociadas a cada uno de los cromosomas – instalaciones abiertas, cantidades de envío, costos totales e impacto ambiental – a partir de las cuales es posible compararlos entre sí para seleccionar aquellos que provean las mejores soluciones durante el ciclo evolutivo. En el siguiente numeral se encuentran explicadas y ejemplificadas cada una de las etapas del ciclo evolutivo.

7.3 Evaluación de la Aptitud

La importancia de conocer el valor de aptitud de cada cromosoma radica en que, a partir de este valor, es posible determinar los cromosomas que sobrevivirán a la siguiente generación y los que no (Altıparmak et al., 2006). La aptitud de un cromosoma es un indicador de la capacidad del mismo para cumplir con los objetivos del modelo; por esta razón, solo los cromosomas con el mejor valor de aptitud son seleccionados para conformar la siguiente generación o reproducirse. (Altıparmak et al., 2006). En este trabajo, previamente a la medición de la aptitud, se seleccionó una población inicial de pop_Size cromosomas, de entre todos los generados en la fase 1. La mitad de los cromosomas ($pop_Size/2$) fue elegida a partir de la función de costos totales, y la otra mitad,

del objetivo de impacto ambiental, siguiendo el criterio del valor mínimo. Una vez obtenidos los cromosomas a ser evaluados, se emplea la técnica de suma de pesos aleatorios, como sigue.

7.3.1 Suma ponderada

En esta técnica, la función de aptitud se calcula como la combinación de las n funciones objetivo presentes en el modelo (Altıparmak et al., 2006). Para combinarlas, se hace necesario que todas las funciones se encuentren en la misma escala de referencia, a fin de que sean comparables. El modelo de la CLSC cuenta con 2 funciones objetivo que se miden en órdenes de magnitud muy diferentes; por lo cual, se hace necesario aplicar una transformación previa. Este paso se conoce como normalización de los objetivos y, para efectos del presente trabajo, se optó por imponer un límite inferior igual a la unidad, dividiendo todos los valores de cada uno de los objetivos entre el mínimo de su grupo, buscando así convertir los datos en cifras adimensionales, como se muestra en la ecuación 28.

$$f^{norm}_i = \frac{f_i}{f_{mínima}} ; i = 1, 2, \dots, N \quad (28)$$

Al aplicar la ecuación 28 a los dos objetivos de la CLSC, se obtienen las siguientes expresiones:

$$Costo^{norm}_i = \frac{Costo_i}{Costo_{mínimo}} ; i = 1, 2, \dots, N \quad (29)$$

$$Impacto^{norm}_i = \frac{Impacto_i}{Impacto_{mínimo}} ; i = 1, 2, \dots, N \quad (30)$$

Después, se realiza una combinación lineal entre las funciones normalizadas y un vector de pesos w , que es generado de manera aleatoria, siguiendo el enfoque de pesos aleatorios de Murata et al. (1996). Como se puede observar en la ecuación 31, se generan n números aleatorios r_i , tales que, cada r_i dividido en la suma total r , sea igual a w_i . Con esto, se busca que la suma del vector de pesos w_i sea equivalente a 1.

$$w_i = \frac{r_i}{\sum_{i=1}^n r_i} ; i = 1, 2, \dots, n \quad (31)$$

Para el caso de dos funciones objetivo, los pesos w se calculan con las ecuaciones 31 y 33

$$W_{costo_i} = \frac{rcosto_i}{rcosto_i + rimpacto_i} ; i = 1, 2, \dots, n \quad (32)$$

$$W_{impacto_i} = \frac{rimpacto_i}{rcosto_i + rimpacto_i} ; i = 1, 2, \dots, n \quad (33)$$

Y finalmente, la aptitud de cada cromosoma se calcula de forma general con la ecuación.

$$z = \sum_{i=1}^n w_i \times fnorm_i \quad (34)$$

A partir de esta forma general, es posible llegar a la ecuación (34), que es una forma particular aplicable al caso de dos funciones objetivo.

$$z_i = (W_{costo_i} \times Costo^{norm_i}) + (W_{impacto_i} \times Impacto^{norm_i}) \quad (35)$$

Puesto que la ecuación (35), está basada en un problema de minimización, cuanto menor sea el valor de z_i , mayor será la aptitud de supervivencia de un cromosoma. Y dicho valor permite compararlo con el resto de la población, para decidir si debe pertenecer al grupo de candidatos a reproducirse. Este paso se conoce como elitismo y se aborda en el siguiente apartado.

7.3.2 Elitismo

El grupo élite está conformado por los individuos más aptos para sobrevivir o reproducirse en la siguiente generación. El algoritmo genera el tamaño que tendrá este grupo en cada generación, de forma aleatoria, y lo denomina `pareto_Size`. La diferencia entre el tamaño de la población inicial (`pop_Size`) y el tamaño del grupo élite (`pareto_Size`) indica la cantidad de individuos a generar mediante el ciclo reproductivo. El ciclo reproductivo es la denominación asignada en el presente trabajo al proceso de aplicar los operadores genéticos al grupo élite, hasta completar el tamaño de la población original y pasar a la siguiente generación. A continuación, se describe cada una de las fases del ciclo con sus respectivos operadores genéticos.

7.3.3 Selección

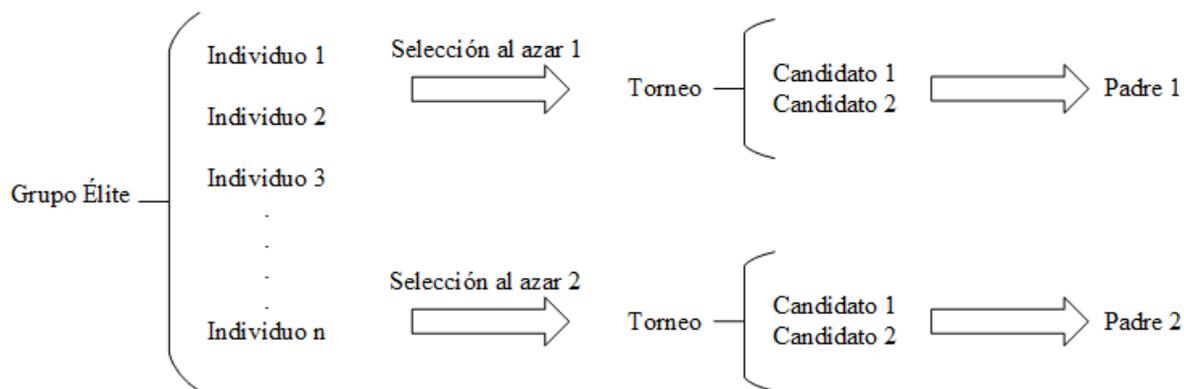
La selección por torneo ha demostrado ser una de las técnicas más comunes y con mejores resultados en investigaciones recientes, además de aportar diversificación de las soluciones por su naturaleza aleatoria. De los diversos formatos de torneo existentes, se decidió efectuar una competencia uno contra uno, donde se eligen dos candidatos pertenecientes al grupo élite y se enfrentan para determinar quién se podrá reproducir. En cada enfrentamiento se eligen los

candidatos al azar y se conserva el candidato con mejor valor de aptitud, entendido como padre. Cada dos enfrentamientos, se obtiene una pareja que será llevada a la fase de cruce.

Para una mejor comprensión del funcionamiento del operador de selección, en la Figura 21, se observa en detalle el procedimiento.

Figura 21.

Selección por Torneo



7.3.4 Cruce

En la fase de cruce, cada uno de los padres dona su material genético para la creación de los descendientes. Como se mencionó antes, los genes de cada padre están representados mediante segmentos matriciales equivalentes a cada escalón de la red. Por ese motivo, se decidió emplear la técnica de cruce basado en segmento. En esta técnica, los segmentos de un padre serán combinados con los segmentos del otro.

Antes de iniciar el cruce, se genera un valor aleatorio entre 0 y 1, denominado probabilidad de cruce. Si la probabilidad de cruce de una pareja procedente de la fase de selección es inferior al valor límite P_c establecido entre los valores de iniciación del AG, el cruce se hará efectivo; de lo contrario, el mejor padre pasará a la etapa de mutación.

Para el caso del cruce, a partir de un vector binario, generado de forma aleatoria, se seleccionan los segmentos de cada padre que conformarán al cromosoma descendiente. De esta

manera, se garantiza que cada uno de los segmentos que hacen parte de la estructura de los cromosomas donantes (padres) tengan la misma probabilidad de ser elegidos. El vector binario consta de seis casillas que representan la estructura del cromosoma descendiente. De este modo, si los padres son etiquetados como padre 1 y padre 2, las casillas del vector binario que contengan el número cero indican que los segmentos correspondientes para generar el descendiente deben ser tomados del padre 1; y las casillas que contengan el número 1, indican que sus segmentos correspondientes los donará el padre 2. Por último, es preciso agregar que, para cada pareja a cruzar, se genera un vector binario, y su opuesto, a fin de obtener dos descendientes en cada cruce.

En la

Figura 22, se presenta un vector binario con su opuesto generados durante una de las corridas del AG. Debido a que en las plantas se realizan labores de producción de artículos nuevos y también de recuperación de productos reciclados, el sexto valor del vector binario debe contener siempre el mismo valor de la casilla 2, con tal que el nivel de capacidad sea consistente en el descendiente.

Figura 22.

Vector binario del cruce

Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5	Segmento 6
0	1	0	1	1	1
1	0	1	0	0	0

Posteriormente, en la Figura 23 se desarrolla el cruce de dos padres empleando el vector binario antes presentado.

Figura 23.

Procedimiento de cruce de dos padres

<i>Padre 1</i>	Segmento 1				Segmento 2				Segmento 3				Segmento 4				Segmento 5				Segmento 6							
	<i>S-I</i>				<i>I-J</i>				<i>J-K</i>				<i>L-K</i>				<i>M-L</i>				<i>I-L</i>							
Nodo	1	2	1	2	1	2	1	2	3	1	2	3	1	2	3	1	2	1	2	3	1	2	1	2	1	2	1	2
Prioridad	2	1	3	4	2	4	5	1	3	5	1	6	3	2	4	5	3	4	2	1	2	4	3	1	4	3	1	2
Nivel	3	1	1	2	1	1	2	2	2	1	3	2	1	2	3	2	2	2	1	1	3	3	3	3	1	1	3	3

<i>Padre 2</i>	Segmento 1				Segmento 2				Segmento 3				Segmento 4				Segmento 5				Segmento 6							
	<i>S-I</i>				<i>I-J</i>				<i>J-K</i>				<i>L-K</i>				<i>M-L</i>				<i>I-L</i>							
Nodo	1	2	1	2	1	2	1	2	3	1	2	3	1	2	3	1	2	1	2	3	1	2	1	2	1	2	1	2
Prioridad	3	1	2	4	3	5	2	4	1	5	4	6	3	1	2	5	3	2	1	4	3	4	2	1	3	2	4	1
Nivel	1	3	1	1	3	2	3	2	3	1	1	1	3	3	3	1	3	3	2	1	2	1	1	1	3	2	1	2

<i>Des. 1</i>	Segmento 1				Segmento 2				Segmento 3				Segmento 4				Segmento 5				Segmento 6							
	<i>S-I</i>				<i>I-J</i>				<i>J-K</i>				<i>L-K</i>				<i>M-L</i>				<i>I-L</i>							
Nodo	1	2	1	2	1	2	1	2	3	1	2	3	1	2	3	1	2	1	2	3	1	2	1	2	1	2	1	2
Prioridad	2	1	3	4	3	5	2	4	1	5	1	6	3	2	4	5	3	2	1	4	3	4	2	1	3	2	4	1
Nivel	3	1	1	2	3	2	3	2	3	1	3	2	1	2	3	1	3	3	2	1	2	1	1	1	3	2	1	2
Vector	0				1				0				1				1											

Figura 24.

Procedimiento de cruce de dos padres

<i>Des. 2</i>	Segmento 1				Segmento 2				Segmento 3				Segmento 4				Segmento 5				Segmento 6							
	<i>S-I</i>				<i>I-J</i>				<i>J-K</i>				<i>L-K</i>				<i>M-L</i>				<i>I-L</i>							
Nodo	1	2	1	2	1	2	1	2	3	1	2	3	1	2	3	1	2	1	2	3	1	2	1	2	1	2	1	2
Prioridad	3	1	2	4	2	4	5	1	3	5	4	6	3	1	2	5	3	4	2	1	2	4	3	1	4	3	1	2
Nivel	1	3	1	1	1	1	2	2	2	1	1	1	3	3	3	2	2	2	1	1	3	3	3	3	1	1	3	3
Vector	1				0				1				0				0											

Una vez obtenidos los dos descendientes, nuevamente son evaluados con las ecuaciones abordadas en la sección 7.3.1, para determinar cuál de ellos debe ser desechado y continuar a la fase de mutación con el cromosoma más apto, denominado hijo.

7.3.5 Mutación

Con el propósito de evitar la convergencia del algoritmo hacia un punto local, se realiza una mutación basada en segmento, que consiste en buscar valores de forma aleatoria en todo el espacio y reemplazarlos en la cadena del cromosoma. (Altıparmak et al., 2006)

En principio, es necesario decidir cuáles segmentos del cromosoma serán mutados. Esta primera parte es realizada por el algoritmo mediante la generación de un vector binario de seis posiciones, de forma similar al operador de cruce, en el cual el número 1 indica que a dicho segmento se le debe aplicar el operador de mutación, y el cero indica lo contrario. (Ver Figura 25.).

Figura 25.

Vector binario de la mutación

Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5	Segmento 6
1	1	0	1	0	0

Tras conocer los n segmentos que sufrirán la mutación, se genera un número G para cada uno de ellos, entre 1 y el valor de prioridad máximo del segmento en cuestión, para establecer la casilla exacta a reemplazar dentro del mismo. Por ejemplo, a partir del vector binario de la Figura 25, se sabe que se deben mutar los segmentos 1, 2 y 4, pertenecientes al descendiente 1. Entonces, se generan tres valores aleatorios: el primero entre 1 y 4, para el segmento 1; y los otros dos entre 1 y 5, para el segmento 2 y segmento 4. A partir de este punto, el procedimiento de mutación difiere levemente entre la fila correspondiente a las prioridades y la fila del nivel de capacidad.

En cuanto a las prioridades, para cada segmento a ser mutado, se genera un valor aleatorio V , de forma semejante al valor G , que será reemplazado en la posición G .

Debido a que la codificación del cromosoma no admite que se repitan valores de prioridad dentro de un mismo segmento, el algoritmo debe buscar el valor V , dentro del segmento, y reemplazarlo con el valor que ocupaba la casilla G , antes de su mutación. Para mayor claridad, el ejemplo de la mutación del descendiente 1 es presentado en la Figura 26, con los siguientes parámetros:

$Q = 3$ Q : Cuántos segmentos serán mutados (Vector binario).

$C = [1, 2, 4]$ C : Cuáles segmentos serán mutados (Vector binario).

$G = [3, 5, 1]$ G : Cuáles casillas dentro del segmento serán mutadas.

$V = [4, 3, 3]$ V : Valores del espacio de búsqueda a reemplazar.

Figura 26.

Procedimiento de mutación del descendiente

<i>Des. 1</i>	Segmento 1				Segmento 2				Segmento 3				Segmento 4				Segmento 5				Segmento 6							
	<i>S-I</i>				<i>I-J</i>				<i>J-K</i>				<i>L-K</i>				<i>M-L</i>				<i>I-L</i>							
Nodo	1	2	1	2	1	2	1	2	3	1	2	3	1	2	3	1	2	1	2	3	1	2	1	2	1	2	1	2
Prioridad	2	1	3	4	3	5	2	4	1	5	1	6	3	2	4	5	3	2	1	4	3	4	2	1	3	2	4	1
Nivel	3	1	1	2	3	2	3	2	3	1	3	2	1	2	3	1	3	3	2	1	2	1	1	1	3	2	1	2
Vector	1				1				0				1				0				0							

<i>NuevoInd</i>	Segmento 1				Segmento 2				Segmento 3				Segmento 4				Segmento 5				Segmento 6							
	<i>S-I</i>				<i>I-J</i>				<i>J-K</i>				<i>L-K</i>				<i>M-L</i>				<i>I-L</i>							
Nodo	1	2	1	2	1	2	1	2	3	1	2	3	1	2	3	1	2	1	2	3	1	2	1	2	1	2	1	2
Prioridad	2	1	4	3	1	5	2	4	3	5	1	6	3	2	4	3	5	2	1	4	3	4	2	1	3	2	4	1
Nivel	3	1	2	2	3	2	3	2	2	1	3	2	1	2	3	1	3	3	2	1	2	1	1	1	3	2	1	2

En el ejemplo, la casilla $G=1$ (en gris), del segmento 4, debe mutar hacia el valor $V=3$. Puesto que el valor 3 ya pertenece al segmento 4 y se encuentra en la casilla 2, el valor 5 que ocupaba la casilla $G=1$, antes de la mutación, debe ser reemplazado en la casilla 2 (en rojo).

Por su parte, la fila de niveles de capacidad sí permite valores repetidos dentro de un mismo segmento y, además, el máximo nivel es 3, por lo cual, para su mutación se debe generar un valor aleatorio N (entre 1 y 3), para cada segmento, y reemplazarlo en la posición G . (Figura 26)

Con esto queda completa la fase de mutación y se obtiene un cromosoma denominado *Nuevo Individuo*; no obstante, este individuo será agregado a la nueva población solamente si la probabilidad de mutación es menor al parámetro P_m , establecido en el AG. Así las cosas, cuando no se cumpla la condición de mutación, el hijo pasará directamente a hacer parte de la nueva población. Finalmente, el funcionamiento del AG completo se resume en la Figura 27.

Figura 27.

Pseudocódigo del algoritmo genético de la CLSC

Algoritmo 4. Algoritmo Genético basado en la CLSC

1. **Inicio**
 2. Inicialización de parámetros
 3. Codificación – Generar $4 * \text{pop_Size}$ cromosomas
 4. Decodificación – Traducir los cromosomas
 5. Población inicial – Elegir $\text{pop_Size}/2$ cromosomas respecto a cada objetivo
 6. Hacer una copia de la población inicial denominada población actual
 7. **Ciclo evolutivo: Repetir cada generación**
 8. Evaluar la aptitud de los cromosomas de la población actual
 9. Grupo Élite – Seleccionar Pareto_Size cromosomas más aptos de la población actual
 10. **Ciclo reproductivo: Repetir hasta que pareto_Size sea igual a pop_Size**
-

11.	Guardar los individuos del Grupo Élite en una población temporal
12.	Seleccionar aleatoriamente candidatos al torneo
13.	Enfrentar candidatos y obtener padres a cruzar
14.	Aplicar el operador de cruce a los padres
15.	Obtener dos descendientes
16.	Evaluar la aptitud de los descendientes
17.	Obtener un hijo
18.	Aplicar el operador de mutación al hijo
19.	Obtener un nuevo individuo
20.	Actualizar la población temporal
21.	Fin
22.	Actualizar la población actual
23.	Fin
24.	Fin

8. Rendimiento del Algoritmo Genético

El algoritmo genético diseñado para la CLSC fue desarrollado en MATLAB R2019a y ejecutado en un ordenador Levono S145 con memoria RAM de 4 GB y procesador AMD E1-1500 con 1,5 GHz. Para la medición del rendimiento del AG se realizaron dos pruebas: un diseño de experimentos variando los parámetros de entrada del algoritmo para diferentes tamaños de problemas y un contraste con el MOMA desarrollado por (Pishvae et al., 2010). Todos los datos de inicialización utilizados para la ejecución del algoritmo pertenecen a casos de estudio encontrados en instancias de la literatura como (Zohal & Soleimani, 2016) y (Fathollahi-Fard & Hajiaghaei-Keshteli, 2018). (Ver Apéndice B).

8.1 Ajuste de parámetros del algoritmo genético

En el campo de investigación en redes logísticas mediante técnicas metaheurísticas, se ha identificado que el rendimiento del algoritmo genético está directamente relacionado con la selección de sus cuatro parámetros principales: el número de iteraciones, el tamaño de la población, la probabilidad de cruce y la probabilidad de mutación.

Es por ello que, para determinar la combinación de parámetros que genera el mayor rendimiento del AG desarrollado, se propuso un diseño de experimentos factorial de la forma 3^4 ; es decir, se estudiaron los efectos principales de cada uno de los cuatro factores a tres distintos niveles (bajo, medio, alto). Durante el experimento se realizaron dos réplicas, para un total de 162 corridas por cada problema de prueba, y la elección de los niveles de cada factor se basó en el diseño de experimentos propuesto por (Soleimani et al., 2017). (Tabla 10)

Tabla 10.

Niveles de los factores del diseño 3^4

Factor	Nivel		
	Bajo	Medio	Alto
Número de iteraciones	50	200	500
Tamaño de población	30	100	300
Probabilidad de cruce	0,5	0,7	0,8
Probabilidad de mutación	0,5	0,7	0,8

Por otra parte, las variables de respuesta comúnmente usadas para analizar el rendimiento de los algoritmos son: el tiempo de ejecución y la cantidad de soluciones no dominadas encontradas en cada corrida.

8.1.1 Tiempo de ejecución

El criterio de parada del AG es alcanzar el número máximo de generaciones; por lo que, parece razonable que cuanto mayor sea el número de iteraciones, más tiempo tardará el AG en detenerse. Sin embargo, no se conoce con exactitud la influencia de los demás parámetros sobre esta variable y, al ser el tiempo un recurso tan valioso en el ámbito computacional, es indispensable tenerlo en cuenta en la medición del rendimiento. Este es un valor registrado por MATLAB en cada ejecución y en unidades de segundos.

8.1.2 Cantidad de soluciones no dominadas

El AG busca aproximarse al frente de Pareto mediante el método de ponderación propuesto por Zadeh (1963). Por esta razón, en cada iteración el individuo más apto es guardado en un grupo denominado *Óptimos de Pareto*. De este modo, al finalizar una corrida, las soluciones no dominadas encontradas son todos aquellos puntos pertenecientes al grupo de óptimos, y la cantidad de estas, se calcula como el número de valores no repetidos dentro del grupo.

La última consideración importante en el diseño es la clasificación de instancias de prueba existente en la literatura; los problemas de modelamiento de la cadena de suministro se dividen en tres grupos: instancias pequeñas, medianas y grandes. Para el experimento, se seleccionaron al azar tres problemas de prueba de cada grupo y se utilizó el promedio de las tres corridas para el análisis estadístico.

A continuación, se presentan los hallazgos de esta etapa, ordenados según el tamaño del problema.

8.1.3 Instancias pequeñas

Este primer grupo está constituido por todas aquellas configuraciones de red en donde el número de instalaciones de cualquier tipo es menor a 10. Los tres problemas seleccionados para este grupo de instancias se presentan en la Tabla 11.

Tabla 11.

Problemas de prueba pequeños para el rendimiento del AG

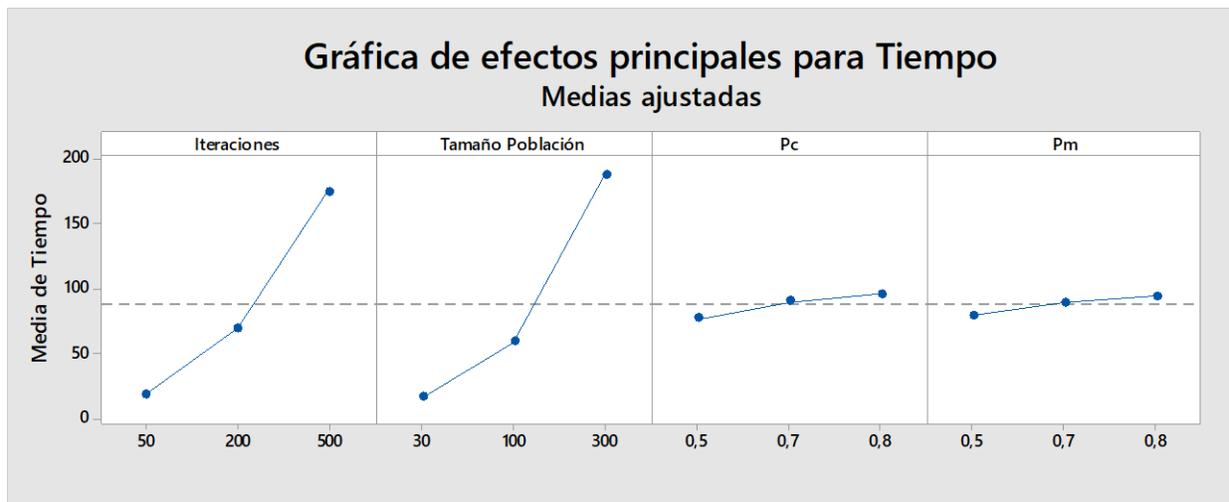
Instancias	Réplicas	Proveedores	Plantas	Centros de Distribución	Centros de Recolección	Centros de Disposición	Clientes
1	2	5	4	2	3	3	3
2	2	3	4	4	4	3	3
3	2	3	3	2	3	2	3

Tras realizar las 162 corridas del AG para cada instancia, se saca el promedio de los valores obtenidos para las variables respuesta tiempos de ejecución y soluciones no dominadas. Con estos promedios se realiza el análisis estadístico del diseño factorial 3^4 .

La Figura 28 presenta los efectos principales de cada factor sobre el tiempo de ejecución del AG. Según estos resultados, el menor tiempo de ejecución se obtiene cuando el número de iteraciones es 50 y el tamaño de la población 30. Para el caso de los factores de probabilidad, P_c y P_m , el valor de iniciación debe ser 0,5 para obtener el menor tiempo de ejecución.

Figura 28.

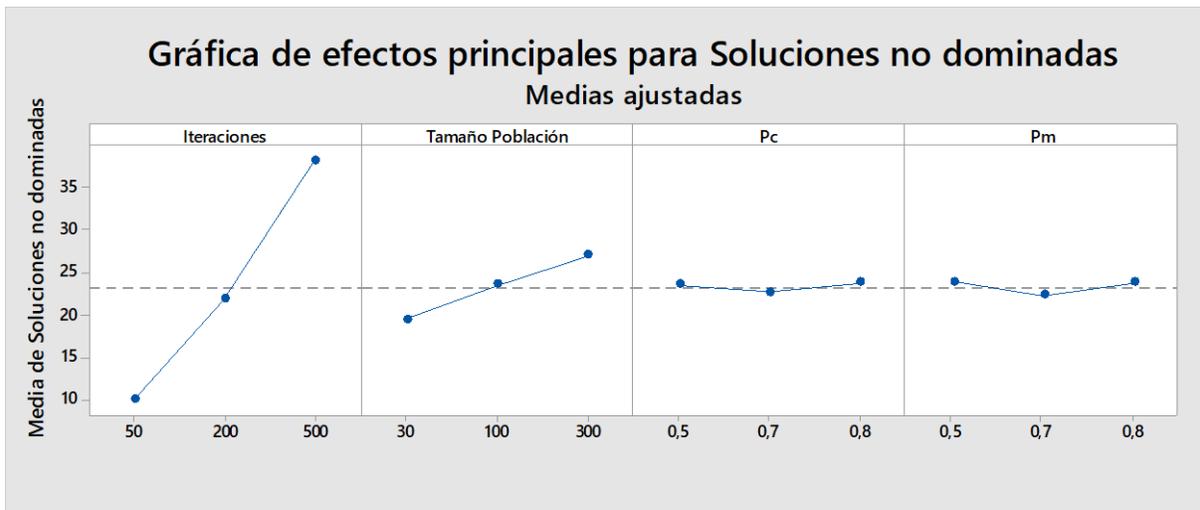
Efectos principales para el tiempo en instancias pequeñas



Por otra parte, la segunda variable respuesta considerada en el experimento (soluciones no dominadas) sugiere una elección de factores diferente. En la Figura 29, es posible ver que la mayor cantidad de soluciones no dominadas se encuentra cuando el número de iteraciones es 500 y el tamaño de la población 300. En cuanto a los factores Pc y Pm, los resultados del análisis de varianza no presentan una evidencia significativa para concluir que dichos factores tengan efecto sobre las soluciones no dominadas, con valores p de 0,481 y 0,255, respectivamente.

Figura 29.

Efectos principales para soluciones no dominadas en instancias pequeñas

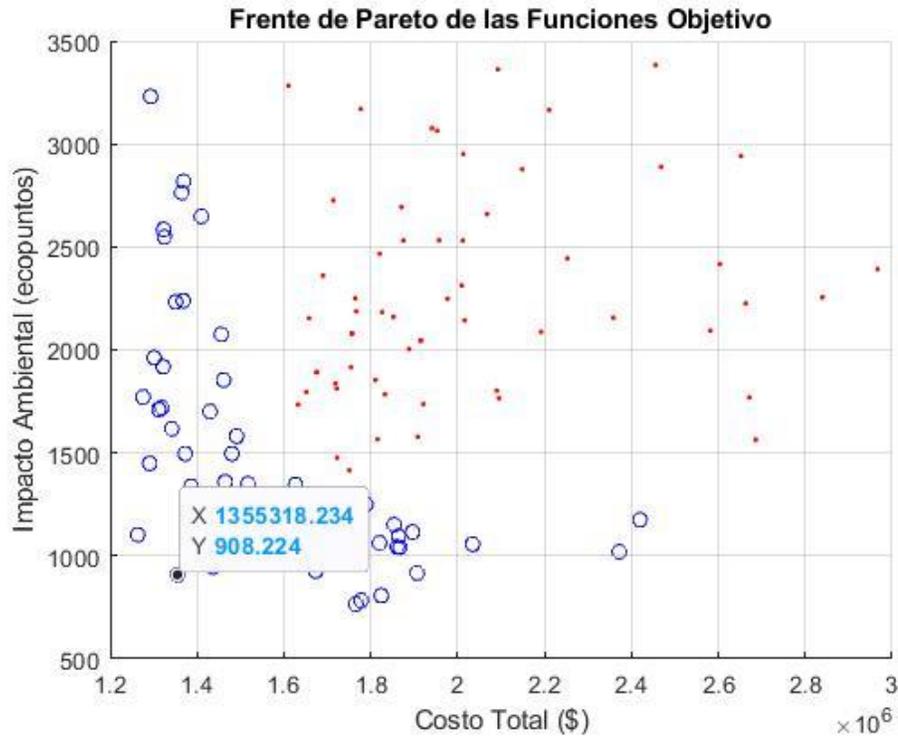


Para resumir, los resultados sugieren que los factores iteraciones y tamaño de la población presentan un comportamiento similar y su elección dependerá de la priorización o distinción que haga el tomador de decisiones entre las variables tiempo de ejecución y cantidad de soluciones no dominadas. No obstante, al revisar la interacción de segundo orden (iteraciones – tamaño de población), se encuentra que una combinación que presenta gran cantidad de soluciones no dominadas en un tiempo aceptable es 500 iteraciones con una población de 100 individuos. En contraste, los factores Pc y Pm, deben ser inicializados en un mismo nivel de 0,5 para minimizar el tiempo de corrida.

A continuación, se presentan los resultados obtenidos para cada función objetivo durante una de las corridas del AG con sus valores ajustados a los parámetros antes descritos. (Ver Figura 30). En la gráfica es posible observar el espacio de soluciones explorado durante la corrida (puntos rojos) y el grupo de soluciones no dominadas o frente de Pareto encontradas por el algoritmo (círculos azules).

Figura 30.

Soluciones obtenidas durante una corrida en instancias pequeñas



8.1.4 Instancias medianas

En la literatura, una instancia considerada de tamaño mediano a menudo cuenta con un número de instalaciones mayor a 10. Adicionalmente, el número de clientes no debe ser mayor a 100. En la Tabla 12, se presentan los problemas de prueba elegidos para este grupo.

Tabla 12.

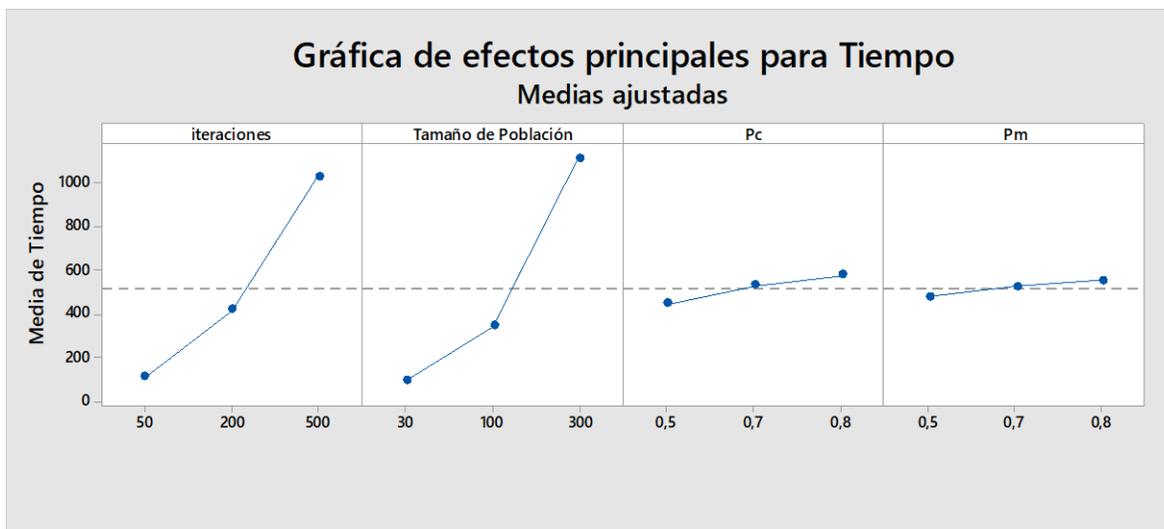
Problemas de prueba medianos para el rendimiento del AG

Instancias	Réplicas	Proveedores	Plantas	Centros de Distribución	Centros de Recolección	Centros de Disposición	Clientes
1	2	15	15	18	17	16	20
2	2	63	33	35	20	18	57
3	2	30	27	29	28	25	35

Al realizar el análisis de los efectos principales de cada factor, se encuentra que, de forma semejante a las instancias pequeñas, en este grupo el comportamiento de los factores iteraciones y tamaño de la población es muy parecido. El menor tiempo de ejecución del AG se obtiene con un nivel de 50 iteraciones y 30 individuos iniciales en la población. Además, las probabilidades P_c y P_m deben ajustarse al valor de 0,5 para obtener el menor tiempo de corrida. (Ver Figura 31).

Figura 31.

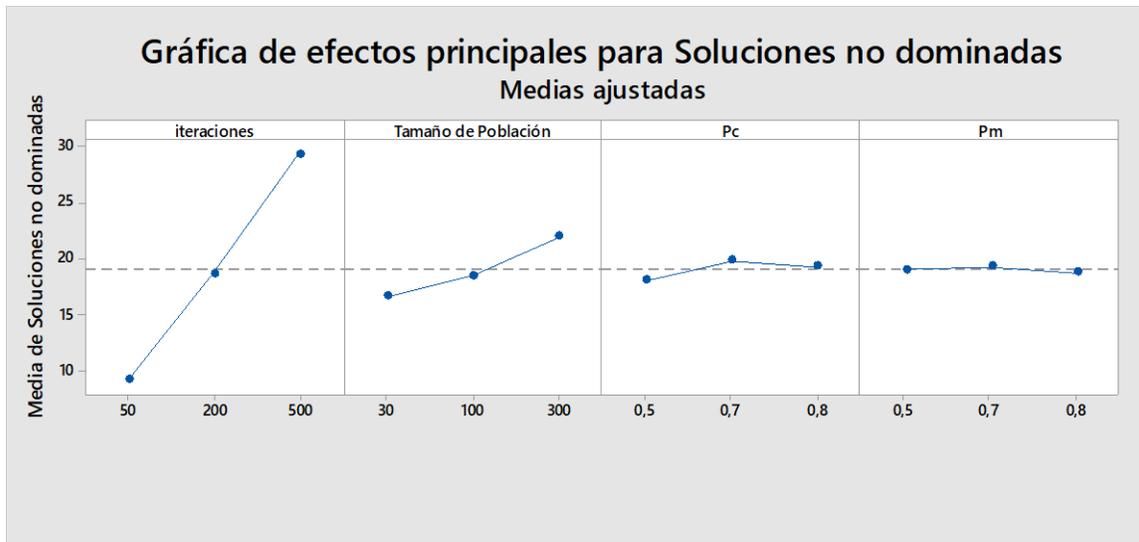
Efectos principales para el tiempo en instancias medianas



En cuanto a la cantidad de soluciones no dominadas encontradas durante la corrida del AG, la Figura 32 muestra que nuevamente los niveles que maximizan esta variable son 500 iteraciones y un tamaño de población de 300 individuos. Mientras que el análisis del valor p (con valores de 0,172 y 0,858) no presenta evidencia suficiente para concluir que los factores P_c y P_m tengan efecto sobre el número de soluciones no dominadas. (Ver Apéndice D).

Figura 32.

Efectos principales para soluciones no dominadas en instancias medianas

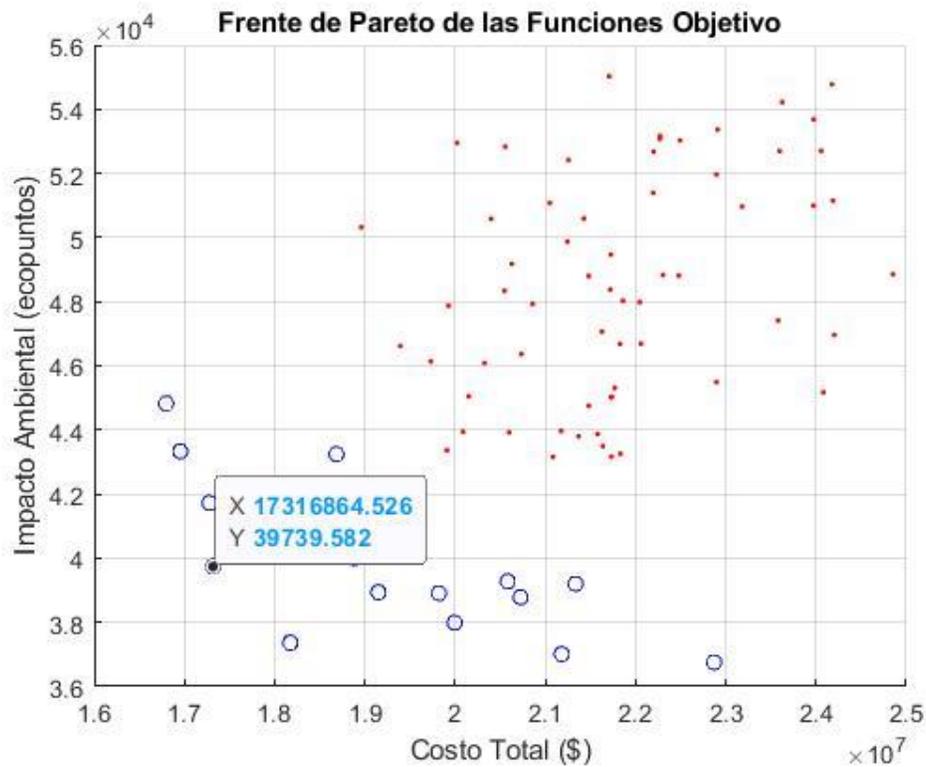


En síntesis, los resultados muestran que la elección del nivel para los factores iteraciones y tamaño de la población está ligada nuevamente a la decisión de cuál variable respuesta priorizar. En otras palabras, si se desea dar prioridad al recurso tiempo, se deben elegir los niveles 50 y 30 para cada factor, respectivamente. En caso de que sea más importante la cantidad de soluciones no dominadas encontradas, la configuración de niveles adecuada será 500 – 300. Cabe resaltar que, nuevamente, la configuración 500 – 100 ofrece buenos resultados en las dos variables respuesta. En cuanto a los factores Pc y Pm; debido a la poca evidencia de su efecto sobre las soluciones no dominadas, la elección de niveles queda determinada por la variable tiempo de ejecución en 0,5.

Un ejemplo de los valores obtenidos para el costo total y el impacto ambiental durante una corrida del AG con los parámetros indicados arriba es presentado en la Figura 33.

Figura 33.

Soluciones obtenidas durante una corrida en instancias medianas



8.1.5 Instancias grandes

Las instancias grandes se caracterizan particularmente por redes de distribución extensas, en donde el número de clientes es mayor a 100. La Tabla 13 recoge las tres instancias de prueba grandes seleccionadas.

Tabla 13.

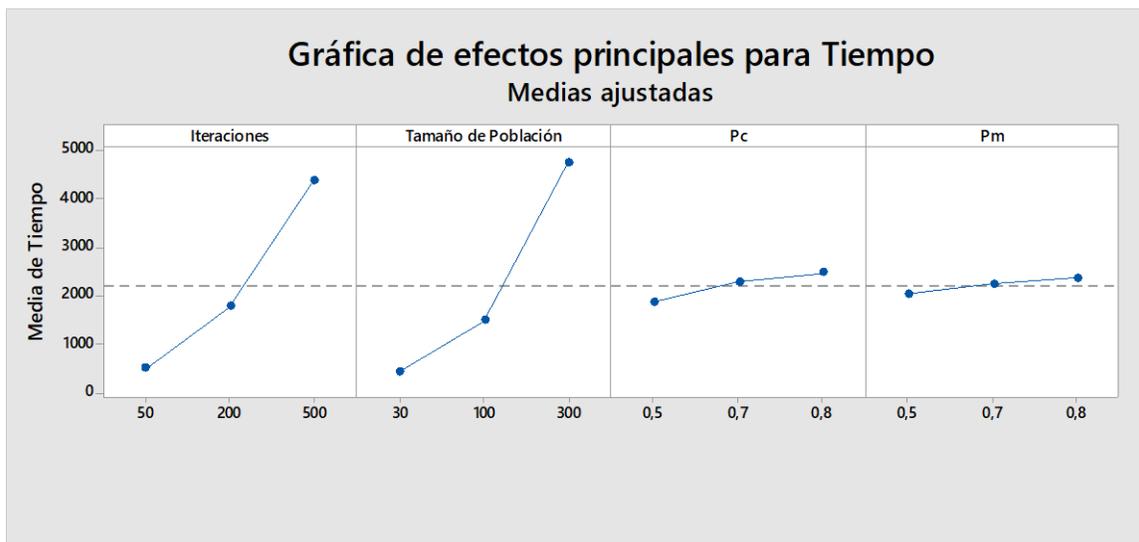
Problemas de prueba grandes para el rendimiento del AG

Instancias	Réplicas	Proveedores	Plantas	Centros de Distribución	Centros de Recolección	Centros de Disposición	Clientes
1	2	100	110	105	100	90	130
2	2	115	59	63	39	31	119
3	2	123	63	67	42	33	127

El análisis de la variable tiempo revela que el comportamiento de los factores en este grupo de instancias permanece exactamente igual que en las instancias medianas y pequeñas. El menor tiempo de ejecución se logra cuando el número de iteraciones es 50, el tamaño de la población 30 y las probabilidades P_c y P_m 0,5. (Ver Figura 34).

Figura 34.

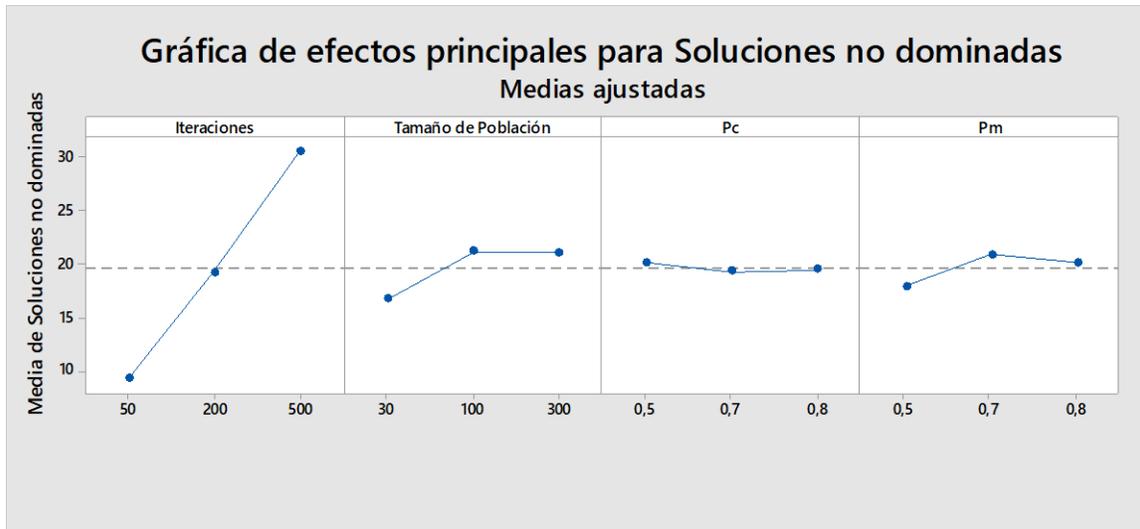
Efectos principales para el tiempo en instancias grandes



Por el contrario, el análisis de los efectos de los factores sobre la variable soluciones no dominadas presenta algunos cambios para este grupo de instancias con respecto a los dos grupos anteriores. Si bien el comportamiento de las iteraciones permanece igual, 500 iteraciones generarán la mayor cantidad de soluciones; el factor tamaño de población muestra que con un nivel de 100 o 300 se obtendrá igual cantidad de soluciones no dominadas. Otro cambio destacable es que el factor de probabilidad P_m , con un valor p de 0, presenta incidencia sobre las soluciones no dominadas, con mayor efecto a un nivel de 0,7. (Ver Figura 35)

Figura 35.

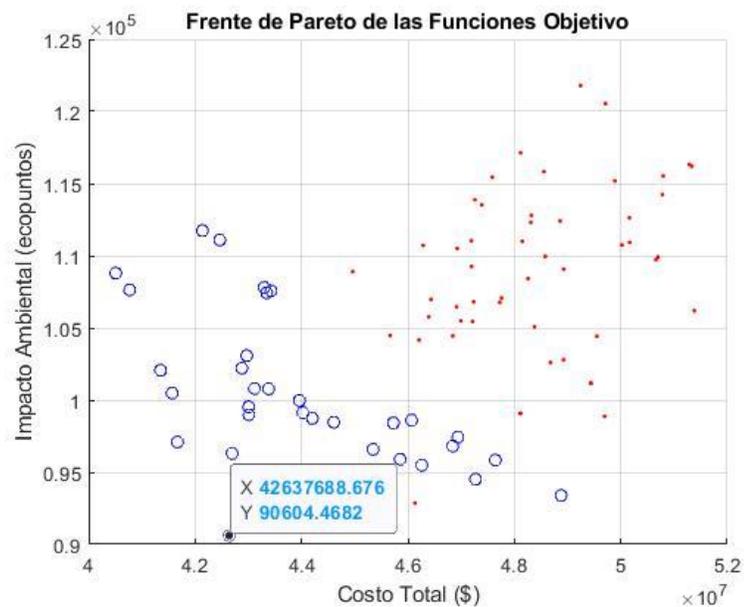
Efectos principales para soluciones no dominadas en instancias grandes



En resumen, para este grupo de instancias la configuración de los niveles de los factores deber ser: 500 iteraciones, 100 individuos en la población inicial, una probabilidad de cruce igual a 0,5 y una probabilidad de mutación de 0,7. La Figura 36 presenta un ejemplo de las soluciones encontradas durante una corrida del AG ajustado a estos parámetros.

Figura 36.

Soluciones obtenidas durante una corrida en instancias grandes



Hasta este punto, el diseño factorial permite conocer la configuración adecuada de los niveles de cada factor para obtener el mayor rendimiento del algoritmo con respecto a las dos variables de respuesta seleccionadas, en instancias de diferentes tamaños. El siguiente paso es comparar el AG desarrollado en esta investigación con el MOMA propuesto por (Pishvae et al., 2010).

8.2 Comparación del AG con el MOMA

Debido a que las funciones objetivo del AG (Costos e Impacto ambiental) difieren con los objetivos del MOMA (Costos y Capacidad de respuesta), no es posible comparar la calidad de las soluciones obtenidas por cada uno. Por esta razón, las métricas seleccionadas para comparar ambos algoritmos son el tiempo de ejecución y el número promedio de soluciones no dominadas encontradas, valores reportados por (Pishvae et al., 2010) en su trabajo.

Los algoritmos son ejecutados en 7 problemas de prueba de diferentes tamaños, provenientes de instancias de la literatura como (Lee & Dong, 2008) y (Du & Evans, 2008). Para cada problema se realizan 5 corridas y se obtiene el promedio de las dos variables respuesta analizadas.

Los parámetros de inicialización del AG son ajustados a los utilizados para la ejecución del MOMA. Un tamaño de población inicial de 30 individuos, una probabilidad de cruce (P_c) de 0,5 y probabilidad de mutación (P_m) de 0,7. Adicionalmente, el parámetro de iteraciones se formula en función del número de instalaciones como $15 + ((S + I + I + J + J + K + K + L + L + M + L + I) / 60)$. Los resultados obtenidos se resumen en la Tabla 14 donde se comparan con los resultados registrados en la literatura para el MOMA.

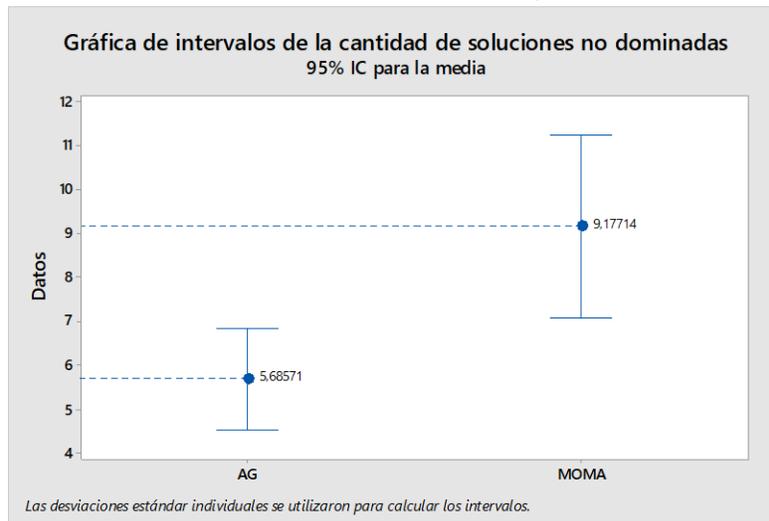
Tabla 14.*Comparación entre el AG y el MOMA*

Problema	ALGORITMO GENÉTICO		MOMA	
	Promedio de soluciones no dominadas	Tiempo de ejecución promedio (s)	Promedio de soluciones no dominadas	Tiempo de ejecución promedio (s)
1	3	2,43	5,6	28,24
2	5,8	2,44	8,33	60,58
3	6	3,40	10,4	74,45
4	6	4,43	8,93	125,2
5	6,6	11,76	13,06	247,71
6	5,6	15,80	8,46	422,84
7	6,8	24,40	9,46	650,3

Al analizar los valores contenidos en la Tabla 13, es posible observar que el MOMA supera al AG en la cantidad promedio de soluciones no dominadas encontradas en cada uno de los problemas de prueba. La cantidad promedio de soluciones encontradas por el MOMA es de 9,17, mientras que el promedio para el AG es de 5,68 soluciones. Adicionalmente, el MOMA presenta un rango de soluciones más amplio, indicando que el AG tiene un mayor grado centralización alrededor de la media. En la Figura 37, se presentan estos hallazgos de manera gráfica.

Figura 37.

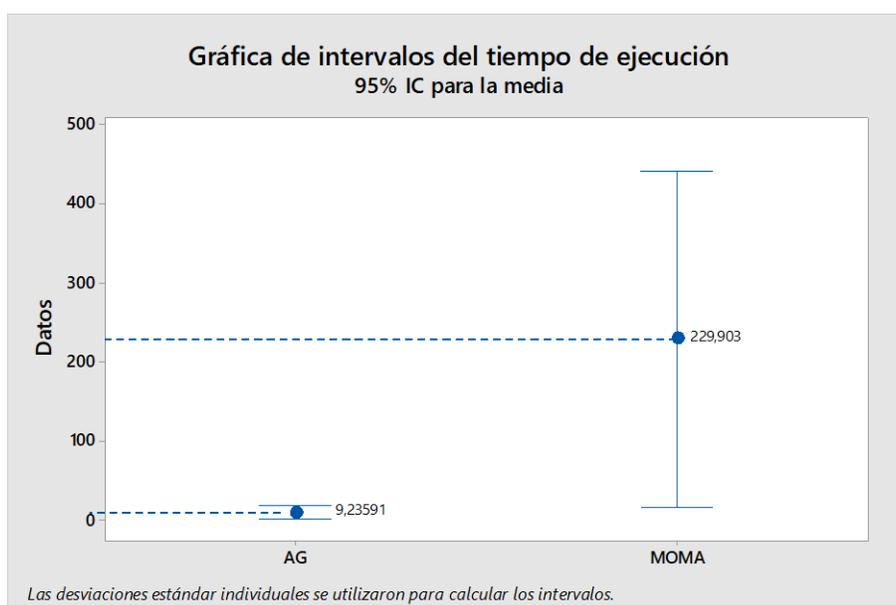
Intervalos de cantidad de soluciones no dominadas del AG y el MOMA



Por otra parte, el análisis del tiempo de ejecución de cada algoritmo refleja que el AG es superior al MOMA, empleando un menor tiempo de búsqueda en cada uno de los 7 problemas. En la Figura 38, se grafican los intervalos de tiempo para cada algoritmo y la media de cada grupo.

Figura 38.

Intervalos del tiempo de ejecución del AG y el MOMA



9. Conclusiones

La investigación en el diseño de redes logísticas ha ido evolucionando con los años hasta llegar al concepto actual de cadenas de suministro de circuito cerrado (CLSC). En esta nueva concepción del sistema, se integran la logística tradicional y la logística inversa para una planificación de la red de distribución que va más allá de la vida útil del producto. Los diseños ahora contemplan la participación de los proveedores y los clientes tanto en el flujo directo como en el flujo inverso del producto, logrando mayor eficiencia en el uso de los recursos y en los costos. Además, la literatura refleja los esfuerzos de los investigadores por incorporar modelos logísticos que cumplan con las condiciones sociales y ambientales presentes en el entorno actual para la toma de decisiones.

La mayor actividad investigativa en esta materia se localiza en países como Irán, China y Dinamarca donde los principales referentes son autores como Pishvaei, Govindan y Gen. En cambio, en países de occidente, como Colombia, se realizan muy pocas publicaciones pertenecientes a este campo investigativo. Es por ello que, el diseño de red integrada abarcado en el presente trabajo sirve como marco de referencia para futuras investigaciones en cadenas de suministro de diversas industrias locales.

A pesar de que el modelo teórico es de carácter genérico, los problemas de prueba y casos de estudios utilizados pertenecientes a la industria de productos electrónicos permiten comprender la pertinencia del trabajo frente a la preocupación y regulación vigente en el país por el reciclaje de componentes provenientes de dicha industria. Entre los aportes del presente proyecto resaltan el diseño de red integrado para la consolidación de una cadena de suministro cerrada, la medición

de los costos desde el proveedor y la evaluación del impacto ambiental mediante metodologías como el ciclo de vida del producto, basado en estándares internacionales.

Las pruebas de rendimiento del algoritmo genético propuesto muestran que, para cualquier tamaño de problema, el mejor desempeño del algoritmo se obtiene con una combinación de 500 iteraciones y 100 individuos en la población inicial. Adicionalmente, los factores P_c y P_m no presentaron pruebas suficientes de influir en el número de soluciones no dominadas para instancias pequeñas y medianas; en instancias grandes, se encontró que el factor P_m presenta un efecto positivo sobre el desempeño con un nivel de 0,7. En cuanto al tiempo de ejecución, el AG demostró ser eficiente en la búsqueda con porcentajes de cruce y mutación de 0,5.

Finalmente, la prueba de contraste entre el AG y el MOMA reveló que el algoritmo genético propuesto es inferior en la cantidad de soluciones no dominadas encontradas. Es posible que esto se deba a las estrategias de búsqueda intensificada incorporadas en el MOMA. Sin embargo, esta diferencia de capacidad de búsqueda está justificada por el ahorro de tiempo de ejecución que presenta el AG.

10. Recomendaciones

El presente trabajo puede ser extendido en futuras investigaciones mediante la modificación de alguno de sus tres aspectos fundamentales: el diseño de la red, el modelo matemático o la heurística de solución. En cuanto al diseño de red, es posible probar nuevas configuraciones en las cuales se considere la apertura de instalaciones para la operación del proveedor, distintos medios de transporte entre los nodos, localización de fuentes de recursos primarios o nuevas instalaciones propias de diferentes industrias como centros de destrucción o

incineración para la industria de equipo médico, centros de mantenimiento para la industria automotriz, entre otros. Por otra parte, los objetivos considerados en el modelo matemático podrían ampliarse para tener en cuenta la dimensión social; la cual ha sido medida en estudios anteriores como la capacidad de la red para generar empleos, la distancia entre los centros de disposición y los centros urbanos, etc. Adicionalmente, el impacto medioambiental puede ser medido bajo el mismo enfoque LCA, pero con una metodología diferente a la del *Ecoindicador*, tal como: *Ecosarcity*, *EDIP* o *Enviromental Theme*. Finalmente, los investigadores tienen la opción de explorar diversos algoritmos comúnmente aplicados en problemas de optimización, tales como el NSGA II, el algoritmo memético, el PSO o la colonia de hormigas y comparar su rendimiento con el AG aquí propuesto; e incluso, una recomendación interesante es la de evaluar el algoritmo genético utilizando estrategias diferentes dentro de su funcionamiento; por ejemplo, el método de selección por ruleta para la elección de los padres, el método de las ε -restricciones para la evaluación de la aptitud, el método Taguchi para el cruce de los padres o una codificación del cromosoma basada en matriz con algoritmo de reparación.

Referencias Bibliográficas

- Alshamsi, A., & Diabat, A. (2017). A Genetic Algorithm for Reverse Logistics network design: A case study from the GCC. *Journal of Cleaner Production*, 151, 652–669. <https://doi.org/10.1016/j.jclepro.2017.02.096>
- Altiparmak, F., Gen, M., Lin, L., & Paksoy, T. (2006). A genetic algorithm approach for multi-objective optimization of supply chain networks. *Computers and Industrial Engineering*, 51(1), 196–215. <https://doi.org/10.1016/j.cie.2006.07.011>
- Cheraghalipour, A., Paydar, M. M., & Hajiaghaei-Keshteli, M. (2018). A bi-objective optimization for citrus closed-loop supply chain using Pareto-based algorithms. *Applied Soft Computing Journal*, 69, 33–59. <https://doi.org/10.1016/j.asoc.2018.04.022>
- Deb, K. (1999). Introduction to genetic algorithms. *Sadhana - Academy Proceedings in Engineering Sciences*, 24(4), 293–315. <https://doi.org/10.1007/BF02823145>
- Devika, K., Jafarian, A., & Nourbakhsh, V. (2014). Designing a sustainable closed-loop supply chain network based on triple bottom line approach: A comparison of metaheuristics hybridization techniques. *European Journal of Operational Research*, 235(3), 594–615. <https://doi.org/10.1016/j.ejor.2013.12.032>
- Diabat, A., & Deskoors, R. (2016). A hybrid genetic algorithm based heuristic for an integrated supply chain problem. *Journal of Manufacturing Systems*, 38, 172–180. <https://doi.org/10.1016/j.jmsy.2015.04.011>
- Du, F., & Evans, G. W. (2008). A bi-objective reverse logistics network analysis for post-sale service. *Computers and Operations Research*, 35(8), 2617–2634. <https://doi.org/10.1016/j.cor.2006.12.020>

- Duarte Muñoz, A., Pantrigo Fernández, J. J., & Gallego Carrillo, M. (2007). *Metaheurísticas* (DYKINSON (ed.)). Universidad Rey Juan Carlos. www.dykinson.com
- Ética ECO / EcoComputo*. (n.d.). Retrieved March 13, 2020, from <https://ecocomputo.com/ética-eco#raee>
- Farrokhi-Asl, H., Tavakkoli-Moghaddam, R., Asgarian, B., & Sangari, E. (2017). Metaheuristics for a bi-objective location-routing-problem in waste collection management. *Journal of Industrial and Production Engineering*, 34(4), 239–252. <https://doi.org/10.1080/21681015.2016.1253619>
- Fathollahi-Fard, A. M., & Hajiaghahi-Keshteli, M. (2018). A stochastic multi-objective model for a closed-loop supply chain with environmental considerations. *Applied Soft Computing Journal*, 69, 232–249. <https://doi.org/10.1016/j.asoc.2018.04.055>
- Fathollahi-Fard, A. M., Hajiaghahi-Keshteli, M., & Mirjalili, S. (2018). Multi-objective stochastic closed-loop supply chain network design with social considerations. *Applied Soft Computing Journal*, 71, 505–525. <https://doi.org/10.1016/j.asoc.2018.07.025>
- Gestal, M., Rivero, D., Rabuñal, J. R., Dorado, J., & Pazos, A. (2010). *Introducción a los Algoritmos Genéticos y la Programación Genética* (Servizo de Publicacións Universidade da Coruña (Ed.)). CONSORCIO EDITORIAL GALEGO, BREGÁN, DIGITALIA.
- Govindan, K., Paam, P., & Abtahi, A. R. (2016). A fuzzy multi-objective optimization model for sustainable reverse logistics network design. *Ecological Indicators*, 67, 753–768. <https://doi.org/10.1016/j.ecolind.2016.03.017>
- Govindan, K., Soleimani, H., & Kannan, D. (2015). Reverse logistics and closed-loop supply chain: A comprehensive review to explore the future. *European Journal of Operational Research*, 240(3), 603–626. <https://doi.org/10.1016/j.ejor.2014.07.012>

- Hajiaghaei-Keshteli, M., & Fathollahi Fard, A. M. (2019). Sustainable closed-loop supply chain network design with discount supposition. In *Neural Computing and Applications* (Vol. 31, Issue 9). Springer London. <https://doi.org/10.1007/s00521-018-3369-5>
- Hillier, F. S., & Lieberman, G. J. (2010). *Introducción a la investigación de operaciones* (M. Hill (Ed.); 9th ed.).
- Jamshidi, R., Fatemi Ghomi, S. M. T., & Karimi, B. (2012). Multi-objective green supply chain optimization with a new hybrid memetic algorithm using the Taguchi method. *Scientia Iranica*, *19*(6), 1876–1886. <https://doi.org/10.1016/j.scient.2012.07.002>
- Kannan, G., Noorul Haq, A., & Devika, M. (2009). Analysis of closed loop supply chain using genetic algorithm and particle swarm optimisation. *International Journal of Production Research*, *47*(5), 1175–1200. <https://doi.org/10.1080/00207540701543585>
- Kuri Morales, Á., & Galvis Casas, J. (2002). *Algoritmos Genéticos* (Insituto Politécnico Nacional, Universidad Nacional Autónoma de México, & Fondo de Cultura Económica (Eds.); 1st ed.). Digitalia.
- Lee, D. H., & Dong, M. (2008). A heuristic approach to logistics network design for end-of-lease computer products recovery. *Transportation Research Part E: Logistics and Transportation Review*, *44*(3), 455–474. <https://doi.org/10.1016/j.tre.2006.11.003>
- Li, S., Wang, N., Jia, T., He, Z., & Liang, H. (2016). Multiobjective optimization for multiperiod reverse logistics network design. *IEEE Transactions on Engineering Management*, *63*(2), 223–236. <https://doi.org/10.1109/TEM.2016.2516986>
- Liu, M., Liu, R., Zhu, Z., Chu, C., & Man, X. (2018). A bi-objective green closed loop supply chain design problem with uncertain demand. *Sustainability (Switzerland)*, *10*(4), 1–22. <https://doi.org/10.3390/su10040967>

- Marín, A., & Pelegrín, B. (1998). The return plant location problem: Modelling and resolution. *European Journal of Operational Research*, *104*(2), 375–392. [https://doi.org/10.1016/S0377-2217\(97\)00192-6](https://doi.org/10.1016/S0377-2217(97)00192-6)
- Mehrbod, M., Xue, Z., Miao, L., & Lin, W. H. (2015). A straight priority-based genetic algorithm for a logistics network. *RAIRO - Operations Research*, *49*(2), 243–264. <https://doi.org/10.1051/ro/2014032>
- Mirakhorli, A. (2014). Fuzzy multi-objective optimization for closed loop logistics network design in bread-producing industries. *International Journal of Advanced Manufacturing Technology*, *70*(1–4), 349–362. <https://doi.org/10.1007/s00170-013-5264-7>
- Pedram, A., Pedram, P., Yusoff, N. Bin, & Sorooshian, S. (2017). Development of closed-loop supply chain network in terms of corporate social responsibility. *PLoS ONE*, *12*(4), 1–20. <https://doi.org/10.1371/journal.pone.0174951>
- Pishvaei, M. S., Farahani, R. Z., & Dullaert, W. (2010). A memetic algorithm for bi-objective integrated forward/reverse logistics network design. *Computers and Operations Research*, *37*(6), 1100–1112. <https://doi.org/10.1016/j.cor.2009.09.018>
- Política Nacional RAEE 2017.pdf*. (n.d.).
- Preston, F. (2012). A Global Redesign? Shaping the Circular Economy. *Energy, Environment and Resource Governance*, *March*, 1–20. <https://doi.org/10.1080/0034676042000253936>
- Roghanian, E., & Pazhoheshfar, P. (2014). An optimization model for reverse logistics network under stochastic environment by using genetic algorithm. *Journal of Manufacturing Systems*, *33*(3), 348–356. <https://doi.org/10.1016/j.jmsy.2014.02.007>
- Sahebjamnia, N., Fathollahi-Fard, A. M., & Hajiaghaei-Keshteli, M. (2018). Sustainable tire closed-loop supply chain network design: Hybrid metaheuristic algorithms for large-scale

- networks. *Journal of Cleaner Production*, 196, 273–296.
<https://doi.org/10.1016/j.jclepro.2018.05.245>
- Shi, J., Chen, W., Zhou, Z., & Zhang, G. (2020). A bi-objective multi-period facility location problem for household e-waste collection. *International Journal of Production Research*, 58(2), 526–545. <https://doi.org/10.1080/00207543.2019.1598591>
- Shi, J., Liu, Z., Tang, L., & Xiong, J. (2017). Multi-objective optimization for a closed-loop network design problem using an improved genetic algorithm. *Applied Mathematical Modelling*, 45, 14–30. <https://doi.org/10.1016/j.apm.2016.11.004>
- Soleimani, H., Govindan, K., Saghafi, H., & Jafari, H. (2017). Fuzzy multi-objective sustainable and green closed-loop supply chain network design. *Computers and Industrial Engineering*, 109, 191–203. <https://doi.org/10.1016/j.cie.2017.04.038>
- Tibben-Lembke, R. S., & Rogers, D. S. (2002). Differences between forward and reverse logistics in a retail environment. *Supply Chain Management: An International Journal*, 7(5), 271–282. <https://doi.org/10.1108/13598540210447719>
- Vahdani, B., & Mohammadi, M. (2015). A bi-objective interval-stochastic robust optimization model for designing closed loop supply chain network with multi-priority queuing system. *International Journal of Production Economics*, 170, 67–87. <https://doi.org/10.1016/j.ijpe.2015.08.020>
- Vitoriano, B. (2007). *Decisión con Incertidumbre, Decisión Multicriterio y Teoría de Juegos*.
- Vitoriano, B. (2009). *Modelos operativos de Gestión. Universidad Plutense de Madrid*.
- Vivancos Bono, J. L., Collado Ruiz, D., Bastante Ceca, M. J., Gómez Navarro, T., & Capuz Rizo,

- S. (2005). *Análisis de Diversas Metodologías de Evaluación del Impactos del Ciclo de Vida*. 46022, 963–978.
- Yavari, M., & Geraeli, M. (2019). Heuristic method for robust optimization model for green closed-loop supply chain network design of perishable goods. *Journal of Cleaner Production*, 226, 282–305. <https://doi.org/10.1016/j.jclepro.2019.03.279>
- Zadeh, L. (1963). Optimality and Non-Scalar-Valued Performance Criteria. *IEEE Transactions on Automatic Control*, 8, 59–60.
- Zavvar Sabegh, M. H., Mohammadi, M., & Naderi, B. (2017). Multi-objective optimization considering quality concepts in a green healthcare supply chain for natural disaster response: neural network approaches. *International Journal of Systems Assurance Engineering and Management*, 8, 1689–1703. <https://doi.org/10.1007/s13198-017-0645-1>
- Zohal, M., & Soleimani, H. (2016). Developing an ant colony approach for green closed-loop supply chain network design: a case study in gold industry. *Journal of Cleaner Production*, 133, 314–337. <https://doi.org/10.1016/j.jclepro.2016.05.091>