

**Un modelo para la localización de depósitos centrales y ruteo de vehículos de dos escalones
aplicado a la distribución de recursos humanitarios durante las fases de pre y pos-desastre
(2E-LRP)**

Andrés Guillermo Angarita Monroy

Trabajo de Grado para Optar al Título de Ingeniero Industrial

Director:

Karin Julieth Aguilar Imitola

MSc. Ingeniería industrial

Codirector:

Javier Eduardo Arias Osorio

Magister en administración

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Estudios Industriales y Empresariales

Bucaramanga

2018

Agradecimientos

Agradezco primeramente a Dios, quien permitió hacer este sueño realidad, al darme la energía, el ánimo, las fuerzas suficientes y el entendimiento requerido para afrontar cada uno de los retos que demandaron el presente proyecto. Gracias por ser ese amigo incondicional, padre, concejero y voz de aliento que siempre estuvo cuando creí desfallecer.

A mis padres, Guillermo Angarita Carvajal y María Deisy Monroy Oyola, quienes me dieron lo más importante: amor, comprensión y entrega absoluta; son ustedes junto a Dios, el motor de mi vida, mi norte; además de producir en mí el deseo profundo de ser alguien mejor y luchar cada día por mis sueños.

A una gran mujer, novia, amiga y compañera permanente, llamada Gennifer Lisseth Hernández, quien estuvo siempre apoyándome, sufriendo a mi lado, brindándome el ánimo y la energía que me faltó en muchos momentos. Gracias por creer en mí y tener la convicción de que podía dar más de lo que yo creía no era posible, espero que juntos sigamos forjando un mejor futuro de la mano de Dios.

A los profesores Javier Eduardo Arias y Karín Julieth Aguilar, por ofrecerme durante todo el proceso la guía, orientación, consejos y correcciones necesarias; sin ustedes hubiera sido imposible culminar con éxito el presente trabajo, quedo muy agradecido, ya que de una u otra forma aportaron significativamente en mi crecimiento profesional.

Tabla de contenido

Introducción	16
1. Generalidades de la investigación	20
1.1. Planteamiento del problema	20
1.2. Metodología	23
1.2.1. Fase 1. Definición del problema y recolección de información	24
1.2.2. Fase 2. Formulación del modelo matemático	25
1.2.3. Fase 3. Desarrollar un procedimiento a computador	25
1.2.4. Fase 4. Comprobación y preparación del algoritmo	26
1.2.5. Fase 5. Implementación del algoritmo	27
1.2.6. Fase 6. Síntesis de resultados	27
2. Objetivos	28
2.1. Objetivo general	28
2.2. Objetivos específicos	28
3. Revisión de la literatura	29
4. Marco de antecedentes	43
5. Marco teórico	46
5.1. Logística Humanitaria	46
5.2. Suministro de emergencia	47
5.3. Desastre	47
5.3.1. Principales efectos de un desastre	48
5.3.2. Gestión de desastres	48
5.3.3. Fases para la atención de un desastre	49
5.4. Optimización matemática	50

5.5.	Modelos matemáticos.....	51
5.5.1.	Modelos de programación lineal.....	51
5.5.2.	Modelos de programación no lineal.....	52
5.6.	Optimización combinatoria.....	52
5.6.1.	Definición de los problemas de optimización combinatoria.....	53
5.6.2.	Complejidad computacional.....	54
5.6.3.	Principales problemas en la optimización combinatoria.....	55
5.7.	Métodos de solución para los problemas de optimización combinatoria.....	59
5.7.1.	Métodos Exactos.....	60
5.7.2.	Métodos aproximados.....	60
5.7.3.	Métodos Heurísticos.....	61
5.7.4.	Metaheurísticas.....	62
6.	Descripción del algoritmo genético.....	69
6.1.	Orígenes.....	71
6.2.	Codificación de problemas.....	72
6.3.	Algoritmo principal.....	74
6.4.	Operadores genéticos.....	76
6.5.	Evaluación.....	81
7.	Modelo para el 2E-LRP.....	82
7.1.	Descripción del modelo.....	82
7.2.	Suposiciones de estudio.....	82
7.3.	Formulación matemática.....	84
7.3.1.	Conjuntos.....	84
7.3.2.	Índices.....	85
7.3.3.	Parámetros.....	85

7.3.4.	Variables de decisión	85
7.3.5.	Función objetivo	86
7.3.6.	Restricciones	86
7.3.7.	Interpretación del modelo matemático.....	88
7.3.8.	Representación del modelo matemático	90
7.4.	Análisis de complejidad	91
7.4.1.	Problema de localización y ruteo de vehículos.....	91
7.4.2.	Problema de localización y ruteo de vehículos para dos escalones	95
8.	Diseño del algoritmo genético.....	100
8.1.	Caracterización del algoritmo	101
8.1.1.	Etapa 1. Creación de la población inicial.....	101
8.1.2.	Etapa 2. Aplicación de los operadores genético.	101
8.1.3.	Etapa 3. Presentación de la mejor solución.	101
8.2.	Representación de la solución	101
8.2.1.	Primer escalón.....	102
8.2.2.	Segundo escalón.....	103
8.3.	Decodificación	105
8.4.	Función objetivo (Fitness).....	106
8.5.	Parámetros	106
8.6.	Pasos lógicos del procedimiento algorítmico.....	107
8.6.1.	S1. Generación de la población inicial	109
8.6.2.	S2. Operador de selección.....	116
8.6.3.	S3. Operador de cruce.....	117
8.6.4.	S4. Operador de mutación.....	120
8.6.5.	Cálculo del fitness durante el proceso de cruce y mutación	121

8.6.6. Pseudocódigo del algoritmo genético	122
9. Experimentación	122
9.1. Resultados instancia 1	123
9.2. Resultados Instancia 2	127
9.3. Resultados Instancia 3	129
10. Análisis estadístico	141
10.1. Instancia 1	142
10.2. Instancia 2	149
10.3. Instancia 3	157
11. Conclusiones	163
12. Recomendaciones	166
Referencias bibliográficas	168

Lista de Tablas

Tabla 1. Cumplimiento de objetivos.....	19
Tabla 2. Fases para la gestión de desastres.	49
Tabla 3. Parámetros de inicialización en el algoritmo.....	106
Tabla 4. Instancias de prueba para el 2E-LRP.....	123
Tabla 5. Sub-cadena de asignación de Clientes a CR habilitados.	123
Tabla 6. Sub-cadena para la asignación de vehículos a CR abiertos.	124
Tabla 7. Sub-cadena de rutas CR-CLI (Segundo escalón).	124
Tabla 8. Sub-cadena de asignación de CR a DP habilitados.	125
Tabla 9. Sub-cadena para la asignación de vehículos a DP abiertos.	126
Tabla 10. Sub-cadena de rutas DP-CR (Primer escalón).....	126
Tabla 11. Sub-cadena de asignación de Clientes a CR habilitados.	127
Tabla 12. Sub-cadena para la asignación de vehículos a CR abiertos.	129
Tabla 13. Sub-cadena de rutas CR-CLI (Segundo escalón).	130
Tabla 14. Sub-cadena de asignación de CR a DP habilitados.	131
Tabla 15. Sub-cadena para la asignación de vehículos a DP abiertos.	131
Tabla 16. Sub-cadena de rutas DP-CR (Primer escalón).....	131
Tabla 17. Sub-cadena de asignación de Clientes a CR habilitados	132
Tabla 18. Sub-cadena para la asignación de vehículos a CR abiertos.	136
Tabla 19. Matriz de rutas CR-CLI (Segundo escalón).	137
Tabla 20. Sub-cadena de asignación de CR a DP habilitados.	140
Tabla 21. Sub-cadena para la asignación de vehículos a DP abiertos.	140
Tabla 22. Sub-cadena de rutas DP-CR (Primer escalón).....	140
Tabla 23. Diseño factorial para el algoritmo genético.....	142
Tabla 24. Estructura del diseño de experimentos (Pequeña instancia).	142
Tabla 25. Análisis de varianza (ANOVA) para pequeña instancia.	144
Tabla 26. Resumen del modelo para la F.O (Pequeña instancia).	148
Tabla 27. Estructura del diseño de experimentos (Mediana instancia).	149
Tabla 28. Resumen del modelo para la F.O (Mediana instancia).....	151

Tabla 29. Análisis de varianza (ANOVA) para mediana instancia.	151
Tabla 30. Estructura del diseño de experimentos (Instancia robusta).	157
Tabla 31. Análisis de varianza (ANOVA) para instancia robusta.	158
Tabla 32. Resumen del modelo para la F.O (Instancia robusta).	159

Lista de Figuras

Figura 1. Fases metodológicas para un estudio en investigación de operaciones.	23
Figura 2. Representación esquemática del 2E-LRP.....	59
Figura 3. Diagrama de flujo de un algoritmo genético.	71
Figura 4. Individuo genético binario.....	73
Figura 5. Pseudocódigo de un algoritmo genético.....	75
Figura 6. Representación cruce de 1 punto.	79
Figura 7. Representación cruce de 2 puntos.	80
Figura 8. Representación cruce uniforme.	80
Figura 9. Representación del modelo matemático para el 2E-LRP.....	90
Figura 10. Sub-cadena de asignación de CR a DP habilitados.	104
Figura 11. Sub-cadena para la asignación de vehículos a los DP abiertos.	104
Figura 12. Sub-cadena de rutas (Primer escalón).	104
Figura 13. Sub-cadena de asignación de clientes a los CR habilitados.	104
Figura 14. Sub-cadena para la asignación de vehículos a los CR abiertos.....	104
Figura 15. Sub-cadena de rutas (Segundo escalón).	105
Figura 16. Procedimiento general del algoritmo genético.....	108
Figura 17. Parámetros del modelo (Segundo escalón).....	110
Figura 18. Apertura del CR (Método de ahorro).	110
Figura 19. Procedimiento lógico del método de ahorro.....	111
Figura 20. Matriz de asignación de clientes (Método de ahorro).	111
Figura 21. Apertura del CR (Vecino más cercano).....	112
Figura 22. Procedimiento lógico del método vecino más cercano.	112
Figura 23. Sub-proceso intermedio para la asignación de clientes (Vecino más cercano).....	113
Figura 24. Sub-proceso intermedio para la asignación de clientes (Vecino más cercano).....	113
Figura 25. Apertura del CR (Método aleatorio).....	113
Figura 26. Sub-proceso intermedio para la asignación de clientes (Método aleatorio).....	114
Figura 27. Matriz de asignación de clientes (Método aleatorio).	114
Figura 28. Matriz de asignación de clientes (Método aleatorio).	115

Figura 29. Componentes del miembro, segundo escalón (2).....	115
Figura 30. Componentes del miembro, segundo escalón (3).....	115
Figura 31. Parámetros del modelo (Primer escalón).....	115
Figura 32. Sub-cadena de asignación de CR a DP habilitados.	116
Figura 33. Componentes del miembro primer escalón (1).	116
Figura 34. Componentes del miembro primer escalón (2).	116
Figura 35. Proceso lógico del cruce uniforme.	118
Figura 36. Gráfica de residuos para la F.O (Pequeña instancia).....	144
Figura 37. Diagrama de Pareto de efectos estandarizados F.O (Pequeña instancia).	145
Figura 38. Gráfica de efectos normales absolutos estandarizados F.O (Pequeña instancia).	146
Figura 39. Gráfica de efectos principales para la F.O (Pequeña instancia).	146
Figura 40. Gráfica de interacción para la F.O (Pequeña instancia).	147
Figura 41. Gráfica normal de efectos estandarizados TCO (Pequeña instancia).....	148
Figura 42. Gráfica de efectos principales para el TCO (Pequeña instancia). O	149
Figura 43. Gráfica de efectos normales absolutos estandarizados F.O (Mediana instancia).....	152
Figura 44. Diagrama de Pareto de efectos estandarizados F.O (Mediana instancia).....	152
Figura 45. Gráfica de residuos para la F.O (Mediana instancia).	153
Figura 46. Gráfica de efectos principales para la F.O (Mediana instancia).....	154
Figura 47. Gráfica de efectos principales para la F.O (Mediana instancia).....	154
Figura 48. Diagrama de Pareto de efectos estandarizados TCO (Mediana instancia).....	155
Figura 49. Gráfica normal de efectos estandarizados TCO (Mediana instancia).	156
Figura 50. Gráfica de efectos principales para el TCO (Mediana instancia).....	156
Figura 51. Diagrama de Pareto de efectos estandarizados F.O (Instancia robusta).....	159
Figura 52. Gráfica de efectos normales absolutos estandarizados F.O (Instancia robusta).....	160
Figura 53. Gráfica de efectos principales para la F.O (Instancia robusta).....	160
Figura 54. Diagrama de Pareto de efectos estandarizados TCO (Instancia robusta).....	161
Figura 55. Gráfica normal de efectos estandarizados TCO (Instancia robusta).	162
Figura 56. Gráfica de efectos principales para el TCO (Instancia robusta).....	162

Lista de Apéndices

(Los apéndices están adjuntos en el CD y se pueden visualizar en él)

Apéndice A. Análisis bibliométrico.....	163
Apéndice B. Construcción de la población inicial.....	109
Apéndice C. Sub-proceso de selección por torneo determinístico y aleatorio.....	116
Apéndice D. Sub-proceso de cruce uniforme.....	117
Apéndice E. Sub-proceso de mutación puntual.....	120
Apéndice F. Pseudocódigo del algoritmo genético.....	122
Apéndice G. Marco de trabajo para el algoritmo genético.....	19
Apéndice H. Instancias.....	123
Apéndice I. Artículo 2E-LRP.....	19

Resumen

Título del proyecto: *

“UN MODELO PARA LA LOCALIZACIÓN DE DEPÓSITOS CENTRALES Y RUTEO DE VEHÍCULOS DE DOS ESCALONES APLICADO A LA DISTRIBUCIÓN DE RECURSOS HUMANITARIOS DURANTE LAS FASES DE PRE Y POS-DESASTRE (2E-LRP)”

Autor: Andrés Guillermo Angarita Monroy**

Palabras claves:

Problema de localización y ruteo de vehículos de dos escalones, localización y ruteo multi-escalón, ruteo con localización multi-nivel, logística humanitaria, cadena de suministro humanitaria, algoritmo genético (AG), programación lineal entera mixta (PLEM).

Descripción:

En la presente investigación se aborda el problema de localización y ruteo de vehículos de dos escalones (Two Echelon Location Routing Problem, 2E-LRP), teniendo en cuenta su importancia en la gestión de la cadena de suministro humanitaria. El problema es formulado como un modelo de programación lineal entera mixta, con el objetivo de minimizar el costo total y considerando limitaciones de capacidad en las instalaciones o depósitos centrales (depósitos primarios y centros regionales) a localizar y en los vehículos utilizados para el ruteo tanto del primer como del segundo nivel. Adicionalmente, se asume un comportamiento de tipo determinístico en la demanda que presentan los clientes y flota heterogénea en el escalón. Para dar solución al problema, se desarrolla un algoritmo genético (AG) y se propone una nueva codificación de la solución. La funcionalidad y consistencia del método propuesto es validada a través de experimentos numéricos, considerando tres tipos de instancias (pequeña, mediana y robusta) y haciendo uso del diseño de experimentos (diseño factorial 2^K). Los resultados computacionales muestran que el algoritmo genético obtiene buenas soluciones en un tiempo computacional razonable (menos de 30 minutos) dada la complejidad del problema. Finalmente, el análisis estadístico permite inferir que los parámetros: tamaño de la población, número de generaciones y probabilidad de cruce tienen una gran incidencia en la función objetivo, la cual busca minimizar los costos generados al momento de diseñar la red logística.

* Trabajo de grado.

** Facultad de Ingenierías Fisicomecánicas. Escuela de Estudios Industriales y Empresariales. Director: MSc. Karin Julieth Aguilar Imitola, Codirector: MA. Javier Eduardo Arias Osorio.

Abstract

Title: *

“A MODEL FOR THE LOCATION OF CENTRAL DEPOTS AND ROUTING OF TWO-ECHELON VEHICLES APPLIED TO THE DISTRIBUTION OF HUMANITARIAN RESOURCES DURING THE PRE- AND POST-DISASTER PHASES (2E-LRP)”

Author: Andrés Guillermo Angarita Monroy**

Keywords:

Problem of location and routing of two-echelon vehicles, multi-stage location and routing, routing with multi-level location, humanitarian logistics, humanitarian supply chain, genetic algorithm (GA), mixed integer linear programming (MILP).

Description:

This research addresses the problem of locating and routing two-echelon vehicles (Two Echelon Location Routing Problem, 2E-LRP), considering their importance in management of the humanitarian supply chain. The problem is formulated as a mixed integer linear programming model, with the objective of minimizing the total cost and considering capacity limitations in the facilities or central depots (primary depots and regional centers) to be located and in the vehicles used for routing both first and second level. In addition, a deterministic type of behavior is assumed in the demand presented by customers and heterogeneous fleet in the echelon. To provide a solution to the problem, a genetic algorithm (GA) is developed and a new coding of the solution is proposed. The functionality and consistency of the proposed method is validated through numerical experiments, considering three types of instances (small, medium and robust) and making use of the design of experiments (factorial design 2^K). The computational results show that the genetic algorithm obtains satisfactory solutions in a reasonable computational time (less than 30 minutes) given the complexity of the problem. Finally, the statistical analysis allows to infer that the parameters: population size, number of generations and probability of crossing have a great incidence in the objective function, which seeks to minimize the generated costs at the time of designing the logistic network.

* Degree project

** Faculty of Physico-Mechanical Engineering. School of Industrial and Business Studies. Director: MSc. Karin Julieth Aguilar Imitola, Codirector: MA. Javier Eduardo Arias Osorio.

Introducción

La ocurrencia de desastres naturales y sus consecuencias devastadoras son una realidad que se vive año tras año alrededor del mundo. Aproximadamente el 75% de la población mundial vive en regiones afectadas, al menos una vez entre 1980 y 2000, por un terremoto, un ciclón tropical, una inundación o una sequía. Como consecuencia de estos fenómenos, cada día mueren más de 184 personas en distintas partes del mundo y arrojan un saldo que incluye la destrucción de activos fijos, capital físico, la interrupción de la producción, el comercio y el agotamiento de los ahorros e inversiones públicas y privadas, que acaban con el progreso en materia de desarrollo económico (Programa de las Naciones Unidas para el Desarrollo [PNUD], 2004). Esta problemática ha llamado la atención de diversos actores en la sociedad, particularmente de los académicos y gobernantes, quienes se han preocupado por buscar y establecer los mecanismos necesarios que permitan mejorar la respuesta a situaciones de emergencia, dando así lugar al surgimiento de la logística humanitaria como un medio para afrontar los efectos negativos de eventos adversos que ponen en riesgo la integridad o la vida propia del ser humano.

La dificultad para predecir el lugar donde ocurrirá un desastre, el momento y magnitud con la cual se presentará, además de la incertidumbre asociada a las características propias de la población, las condiciones de infraestructura existentes y la demanda requerida para atender la situación de emergencia, dan lugar a uno de los mayores desafíos en la logística humanitaria, como lo es, la imprevisibilidad, definida como la ocurrencia de sucesos inesperados (Balcik, Beamon, Krejci, Muramatsu, y Ramirez, 2010). L'Hermitte, Tatham, Bowles y Brooks (2016) afirman que la imprevisibilidad, crea barreras y afecta la eficiencia en la cadena de suministro. Así, el adecuado manejo de la cadena de abastecimiento logístico para la atención de desastres y apoyo humanitario,

se convierte en un reto muy importante a nivel mundial, pues esta se encarga de estimar, proveer, almacenar, transportar y distribuir el personal, los recursos y servicios requeridos a las zonas afectadas (Sharif y Salari, 2015), a través de un conjunto de actividades realizadas en diferentes instancias del tiempo, las cuales tienen como finalidad asistir a las personas sobrevivientes luego de un desastre (Kovács y Spens, 2007). Por esta razón, el diseño y la gestión necesarias en la red logística durante las fases de pre y pos-desastre no pueden ser improvisadas, deben ser el resultado de una correcta y rigurosa planificación, en la cual se pueda identificar y establecer con anterioridad aspectos muy importantes, como lo es, la ubicación de las instalaciones (depósitos primarios y secundarios), la disponibilidad y calidad de los recursos, la flexibilidad en los planes de ruta según el presupuesto establecido, entre otros, que permiten en última instancia garantizar una respuesta óptima cuando se realiza el despliegue de las operaciones humanitarias.

La relación que existe entre la gestión de la cadena de suministro humanitaria y el problema de ruteo de vehículos (Vehicle Routing Problem, VRP) es muy estrecha, pues a medida que se presentan diferentes escenarios de desastres naturales, la ayuda humanitaria se convierte en una necesidad apremiante, y el tiempo de respuesta, obtenido a partir de un adecuado plan de rutas, juega un papel sumamente importante e implica una serie de desafíos, los cuales deben ser superados, con el fin de lograr una atención y entrega oportuna de los recursos necesarios a la población afectada. Diferentes variaciones del VRP se han propuesto con el ánimo de acercarse a contextos reales del problema, los cuales incluyen la adición de variables, restricciones, objetivos en conflicto, entre otros. Una de las variantes más significativas a resaltar en este campo, es la consideración de decisiones de localización y ruteo simultáneamente. Los diferentes aspectos de estas decisiones han sido estudiados generalmente de manera independiente; este hecho puede ser explicado debido a que la localización es una decisión estratégica, la cual es tomada por un largo

período de tiempo, mientras que el ruteo es una decisión operacional modificada dinámicamente en un período corto. Sin embargo, estas decisiones están íntimamente relacionadas, teniendo en cuenta que la decisión de localizar un depósito es frecuentemente influenciada por los costos de transporte y viceversa (Rand, 1976). Por lo tanto, el presente trabajo de investigación aborda un problema, conocido en la literatura como el 2E-LRP (Two Echelon Location Routing Problem) bajo un enfoque de logística humanitaria, que consiste en determinar simultáneamente la localización de los depósitos primarios (primer escalón) y centros regionales (segundo escalón) junto con los planes de ruteo, considerando restricciones de capacidad y alineado con el objetivo de minimizar los costos en la red logística, entendidos como los costos de localización (apertura), ruteo y utilización de vehículos.

Con la finalidad de brindar una perspectiva global y coherente de los temas a tratar en el presente documento, la estructura es organizada como se muestra continuación: en la sección 1 se dan a conocer las generalidades de la investigación (planteamiento del problema y metodología); la sección 2 presenta los objetivos (general y específicos); la revisión de literatura y el marco de antecedentes son descritos en la sección 3 y 4 respectivamente. La sección 5 está vinculada al marco teórico junto con la sección 6, dedicada exclusivamente a la descripción formal del algoritmo genético. La sección 7 contiene la formulación del modelo matemático para el 2E-LRP; en la sección 8 es presentado el diseño del algoritmo genético, con el propósito de dar solución al problema abordado, además, la sección 9 muestra la experimentación llevada a cabo, es decir, el conjunto de instancias utilizadas para verificar la funcionalidad y consistencia del marco de trabajo. La sección 10 corresponde al análisis estadístico, el cual permite identificar el conjunto de factores claves que intervienen en la calidad del algoritmo metaheurístico. Finalmente, en la

sección 11 y 12 se dan a conocer las conclusiones y recomendaciones, producto de la investigación realizada. El cumplimiento de los objetivos propuestos, son presentados en la *Tabla 1*.

Tabla 1.
Cumplimiento de objetivos

Objetivos específicos	Cumplimiento
Realizar una revisión de literatura en bases de datos científicas para el problema de ruteo de vehículos de dos escalones con localización (2E-LRP), teniendo en cuenta un enfoque de búsqueda multidisciplinaria.	Sección 3
Desarrollar un modelo de optimización para el 2E-LRP (Two Echelon-Location-Routing Problem) aplicado a la distribución de recursos humanitarios durante las fases de pre y pos-desastre.	Sección 7
Construir un algoritmo genético para la solución del 2E-LRP en el lenguaje de programación Matlab.	Sección 8 Apéndice G
Validar el algoritmo de solución a través de experimentos numéricos en el que se simule un escenario bajo ciertas condiciones pre y pos-desastre.	Sección 9 Sección 10
Elaborar un artículo académico de carácter publicable con base en la investigación realizada y los resultados obtenidos.	Apéndice I

1. Generalidades de la investigación

1.1. Planteamiento del problema

La frecuencia de los desastres naturales, como huracanes, tormentas, sequías, inundaciones, movimientos telúricos, entre otros, están aumentando sin lugar a duda. En los últimos veinte años estos han cobrado un promedio anual de 30000 vidas y causado más de 4000 millones de heridos o damnificados, según información suministrada por la Coordinación de Asuntos Humanitarios (OCHA por sus siglas en inglés) (Guha-Sapir, Hoyois, y Below, 2016). Por otro lado, la empresa Munich Reinsurance Company, señala que las pérdidas mundiales causadas por fenómenos naturales adversos se estimaron en USD 4200 billones entre 1980 y 2014, además, durante este periodo, tales pérdidas aumentaron rápidamente, subiendo de USD 50000 millones anuales en los años ochenta a casi USD 200000 millones anuales en la última década. Es por esto que, el impacto económico de un evento catastrófico puede llegar a ser devastador para cualquier nación, especialmente para aquellas en vía de desarrollo, como se evidencia en el informe *Natural Hazards, Unnatural Disasters* (Peligros naturales, desastres antinaturales), el cual señala que la repercusión de las catástrofes naturales en el producto interno bruto (PIB) es 20 veces mayor en los países en desarrollo que en las naciones industrializadas. Por ejemplo, el valor total de los daños y las pérdidas provocadas por los terremotos en Nepal en abril y mayo de 2015 representaron alrededor de una tercera parte del PIB del país, según una evaluación de necesidades posteriores a los sucesos ocurridos (Banco Mundial, 2016).

En la actualidad, los desastres, independientemente de su origen (sea natural o humano), son considerados fenómenos sociales cuyos daños sería posible prevenir y mitigar para disminuir o al

menos controlar sus efectos (Cecchini, Sunkel, y Barrantes, 2017). Así, la incorporación de la gestión de riesgos para la atención de desastres naturales cobra una gran importancia, pues es el medio con mayor eficacia para revertir los impactos negativos que ocasionan estos tipos de eventos en las regiones afectadas. Por lo tanto, es en este punto donde la logística humanitaria juega uno de los roles más importantes, ya que se encarga de planificar, implementar y controlar la eficiencia, costo-efectividad, flujo y almacenamiento de bienes y materiales, así como la información relacionada, desde el punto de origen hasta el punto de consumo, con el fin de aliviar el sufrimiento de personas vulnerables, abarcando de esta manera una amplia gama de actividades, incluida la preparación, adquisición, transporte, seguimiento y rastreo, las cuales son cruciales para la efectividad y velocidad en las actividades de respuesta (Thomas y Kopczak, 2005).

La variedad de las operaciones logísticas en el alivio de desastres es tan extensa, que hacer logística humanitaria se convierte en la parte más costosa de las operaciones de socorro en casos de desastre, representando aproximadamente el 80% de los costos totales (Tomasini y Wassenhove, 2009); es por esto que, los estudios y constantes esfuerzos que se llevan a cabo en esta área, se concentran principalmente en el desarrollo de herramientas que permitan aprovechar de la mejor forma los recursos disponibles para afrontar amenazas futuras.

Atendiendo a lo expuesto anteriormente, surge la necesidad de crear un modelo capaz de proporcionar la información suficiente al responsable de la red logística, para que éste tome las mejores decisiones relacionadas con la ubicación y distribución de recursos humanitarios, que garanticen finalmente una entrega oportuna de los suministros a las regiones afectadas, al menor costo y tiempo posible, minimizando así los impactos negativos de tipo económico y social, ocasionados por la ocurrencia de eventos adversos. En consecuencia, se plantea el diseño de un modelo de optimización para el ruteo de dos niveles con localización de depósitos centrales

(depósitos primarios y centros regionales), enfocado a la distribución de recursos humanitarios, como una herramienta para la planeación logística en la fase de preparación y respuesta ante un desastre natural. Dicho problema es conocido en la literatura como el 2E-LRP, el cual atiende dos tipos de decisiones muy importantes a las que se encuentra expuesto el responsable de diseñar la red logística, es decir, decisiones de tipo estratégico (dónde ubicar el o los depósitos centrales) y operativo (cuál es el mejor conjunto de rutas para transportar los recursos desde los depósitos primarios hasta los centros regionales, y desde estos, hasta las regiones afectadas), las cuales determinan finalmente la capacidad de respuesta, flexibilidad, eficiencia y eficacia que posee la cadena de suministro.

Este tipo de modelo resulta relevante para Colombia, pues se encuentra localizada en una de las zonas sísmicas más activas de la tierra, conocida como el Anillo Circumpacífico, el cual corresponde al borde del océano Pacífico, que es precisamente donde han ocurrido los últimos grandes sismos en países como Chile, Japón y Ecuador (Correal, 2016).

Según estudios de amenaza sísmica realizados a nivel nacional por la Asociación Colombiana de Ingeniería Sísmica -AIS-, cerca del 40% de los colombianos se encuentran expuestos a una amenaza sísmica alta, y el 47% está ubicado en zonas de amenaza sísmica intermedia, es decir, el 87% del territorio nacional se encuentra bajo un nivel de riesgo sísmico considerable. Además, el problema se presenta no solo por el nivel de amenaza sísmica, sino también por el grado de vulnerabilidad en las edificaciones, puentes, carreteras, presas, redes eléctricas y de gas, entre otras (Correal, 2016).

Ahora bien, como el 2E-LRP es de naturaleza NP-Hard (tiempo de solución no polinomial), se hace necesario explorar alternativas de solución que permitan obtener buenos resultados en tiempos computacionales razonables. En este caso, se plantea el uso de la metaheurística evolutiva

conocida como algoritmo genético, el cual es un método adaptativo que puede usarse para resolver problemas de búsqueda y optimización matemática.

Finalmente, el estudio de esta problemática es muy importante, como medio para fortalecer la línea de investigación en logística humanitaria dentro del grupo de investigación OPALO, y a su vez, contribuir a una de las mayores necesidades de tipo social a la que se encuentra expuesta Colombia y el mundo entero, permitiendo así el desarrollo de futuros proyectos de investigación, que generen un impacto positivo en la calidad de vida de la población.

1.2. Metodología

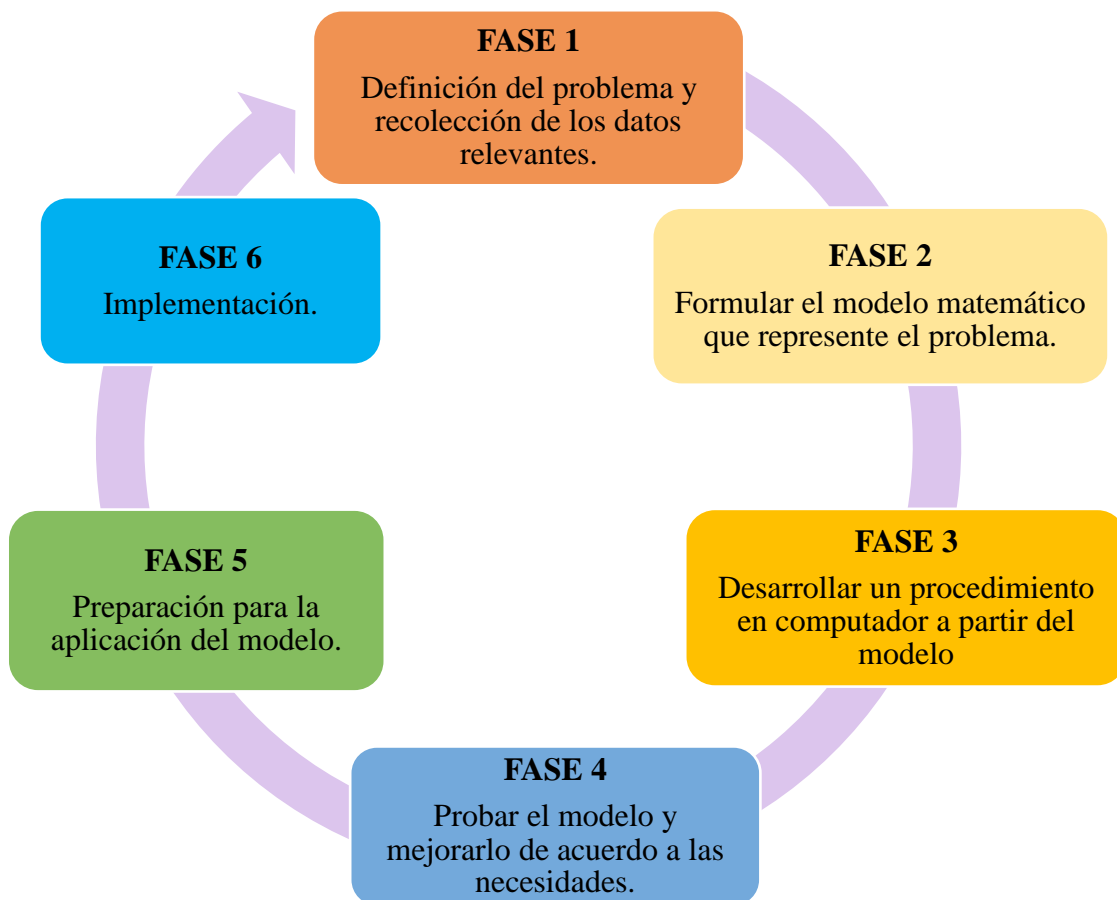


Figura 1. Fases metodológicas para un estudio en investigación de operaciones. Adaptado de Hillier y Lieberman (2010)

La metodología que guiará el desarrollo de este trabajo de investigación consta de seis fases, las cuales se fundamentan en las etapas usuales -no secuenciales- de un estudio de investigación de operaciones (*ver Figura 1*), que usa como base el método científico para explorar los problemas. Estas fases son presentadas por Hillier y Lieberman (2010).

Las fases descritas anteriormente, son adaptadas a las necesidades de esta investigación y son descritas a continuación.

1.2.1. Fase 1. Definición del problema y recolección de información. En esta etapa se llevará a cabo una revisión y análisis de artículos científicos, relacionados con el problema de localización y ruteo de dos escalones bajo un enfoque multidisciplinario, sin perder de vista su aplicación en la logística humanitaria, con el fin de construir un marco referencial y conceptualizar el tema de investigación. Además, se estudian los principales algoritmos de solución propuestos hasta el momento para resolver el problema.

Actividad 1. Definir las palabras claves para realizar la búsqueda en bases de datos científicas.

Actividad 2. Construir la ecuación de búsqueda.

Actividad 3. Establecer los filtros necesarios para depurar la información.

Actividad 4. Ejecutar la ecuación de búsqueda en la base de datos Web Of Science, disponible en la Universidad Industrial de Santander.

Actividad 5. Analizar la información obtenida (análisis bibliométrico).

Actividad 6. Revisar la literatura obtenida sobre el 2E-LRP y sus métodos de solución (comprensión de la estructura, aplicabilidad e identificación de los principales algoritmos de solución para el 2E-LRP).

1.2.2. Fase 2. Formulación del modelo matemático. Esta fase consiste en formular el problema de manera conveniente para su análisis. La forma convencional en que la OR (Operation Research) logra esto, es mediante la construcción de un modelo matemático que represente la esencia del problema, por lo cual se realizarán las siguientes actividades:

Actividad 1. Comprender las bases teóricas que involucran el problema de localización de depósitos centrales y ruteo de vehículos de dos escalones aplicado a la distribución de recursos humanitarios durante las fases de pre y pos-desastre.

Actividad 2. Definir la estructura del modelo con base en las variantes encontradas durante la revisión literaria y a las condiciones especificadas por el investigador (modelo conceptual).

Actividad 3. Establecer el propósito del modelo (objetivo que se desea cumplir).

Actividad 4. Definir los parámetros o datos de entrada para el 2E-LRP.

Actividad 5. Determinar el conjunto de variables de decisión para el 2E-LRP.

Actividad 6. Especificar el conjunto de restricciones que debe cumplir el modelo.

Actividad 7. Verificar la consistencia del modelo, es decir, que la función objetivo, variables de decisión y el conjunto de restricciones estén relacionadas correctamente.

1.2.3. Fase 3. Desarrollar un procedimiento a computador. Esta fase está compuesta por dos etapas:

1.2.3.1. Etapa 3.1. Construcción y aplicación del algoritmo de solución. Una vez analizada la información más relevante en torno al problema y formulado el modelo matemático, se da paso al desarrollo de un algoritmo de solución, que para este caso particular consiste en la metaheurística

evolutiva conocida como algoritmo genético. En el cumplimiento de esta etapa se realizan las siguientes actividades:

Actividad 1. Analizar y comprender el método de solución que propone el algoritmo genético.

Actividad 2. Definir los principales elementos necesarios para ejecutar el algoritmo metaheurístico (población inicial, operador de selección, cruce y mutación, etc.).

Actividad 3. Describir el conjunto de pasos lógicos que permiten dar solución al problema del 2E-LRP aplicado a la distribución de recursos humanitarios durante las fases de pre y pos-desastre.

1.2.3.2. Etapa 3.2. Codificación del algoritmo de solución en Matlab. Con el diseño e implementación del algoritmo genético para el 2E-LRP, se realiza finalmente la construcción del marco de trabajo (framework) en el lenguaje de programación Matlab, con el propósito de encontrar soluciones factibles al problema, ejecutando las actividades:

Actividad 1. Estudiar cada una de las herramientas necesarias para programar el algoritmo de solución en el software Matlab.

Actividad 2. Programar el algoritmo genético para la solución del 2E-LRP en Matlab.

1.2.4. Fase 4. Comprobación y preparación del algoritmo. El modelo es probado con el propósito de encontrar fallas y errores, por lo cual:

Actividad 1. Ejecutar el programa y determinar si genera resultados válidos de acuerdo con las restricciones asociadas al problema, la función objetivo y demás características del modelo.

Actividad 2. En caso de ser necesario, ajustar el modelo según los resultados preliminares.

Actividad 3. Desarrollar instancias de prueba (experimentos numéricos) para el 2E-LRP aplicado a la distribución de recursos humanitarios durante las fases de pre y pos-desastre.

Actividad 4. Validar el modelo programado a través de las instancias de prueba, con la finalidad de corroborar la coherencia en los resultados.

Actividad 5. Si se requiere, modificar y ajustar nuevamente el modelo a las necesidades de la investigación (objetivos propuestos).

1.2.5. Fase 5. Implementación del algoritmo. Una vez corregida las inconsistencias, hecho los ajustes requeridos y superada la validación del modelo programado, el marco de trabajo queda listo para aplicarse en contextos académicos, y a su vez, atender necesidades de la vida real, que estén directamente ligadas con la gestión de la cadena de abastecimiento logístico para la atención de desastres y ayuda humanitaria.

1.2.6. Fase 6. Síntesis de resultados. En esta última fase se recopila la información y los resultados obtenidos durante el proceso investigativo, con la finalidad de:

Actividad 1. Elaborar el libro de proyecto de grado.

Actividad 2. Construir un artículo académico de carácter publicable en el que se presente la formulación del 2E-LRP y los resultados obtenidos con el método de solución.

2. Objetivos

2.1. Objetivo general

Desarrollar un modelo matemático para dar solución al problema de localización de depósitos centrales y ruteo de vehículos de dos escalones aplicado a la distribución de recursos humanitarios durante las fases de pre y pos-desastre.

2.2. Objetivos específicos

- Realizar una revisión de literatura en bases de datos científicas para el problema de ruteo de vehículos de dos escalones con localización (2E-LRP), teniendo en cuenta un enfoque de búsqueda multidisciplinaria.
- Desarrollar un modelo de optimización para el 2E-LRP (Two Echelon-Location-Routing Problem) aplicado a la distribución de recursos humanitarios durante las fases de pre y pos-desastre.
- Construir un algoritmo genético para la solución del 2E-LRP en el lenguaje de programación Matlab.
- Validar el algoritmo de solución a través de experimentos numéricos en el que se simule un escenario bajo ciertas condiciones pre y pos-desastre.
- Elaborar un artículo académico de carácter publicable con base en la investigación realizada y los resultados obtenidos.

3. Revisión de la literatura

La mayoría de los desastres suceden de forma inesperada, impactando a la población, el ambiente y los recursos económicos. Con el fin de mitigar dichos impactos, los países recurren a una adecuada gestión de desastres, la cual se ha convertido en un tema relevante en el mundo actual. La comunidad académica y profesional ha incrementado su interés en desarrollar sistemas logísticos ágiles y capaces que puedan atender diferentes tipos de eventos adversos, que ponen en riesgo la integridad o la vida propia del ser humano, siempre bajo la premisa de reducir el sufrimiento y garantizar la seguridad de la población. Alcanzar tales objetivos no es una tarea fácil, debido a los recursos limitados con los que se cuentan al momento de atender una catástrofe o situación de emergencia; por esta razón, la logística humanitaria toma un gran valor, como medio para desarrollar planes de acción que permitan lograr una adecuada gestión de los recursos existentes en la atención de situaciones críticas, donde la inversión humana y económica es requerida en grandes proporciones.

Day, Melnyk, Larson, Davis y Whybark (2012) mencionan cinco razones por las que el estudio de la cadena de suministro humanitaria es muy importante. La primera, hace referencia a los métodos de solución, los cuales no son muy eficientes a la hora de hacer frente a un desastre, luego se debe hacer un mayor esfuerzo en los procesos investigativos con la finalidad de mejorar la logística para la atención de desastres; la segunda razón, es muy importante considerar los costos referentes a las operaciones de socorro y al sufrimiento humano, los cuales siempre están en constante crecimiento, por lo tanto, los trabajos realizados deben concentrarse en la atención oportuna y minimización de todo tipo de necesidad a las regiones afectadas. La tercera razón, hay

muchas organizaciones gubernamentales y no gubernamentales que donan una gran cantidad de recursos para apoyar las operaciones de ayuda humanitaria ante un desastre, así que el encontrar la mejor forma de invertir y distribuir esos aportes recibidos implica una gran responsabilidad. La cuarta razón está relacionada con la forma de organizar los sistemas de distribución para brindar una respuesta oportuna, frente a la incertidumbre generada por un evento adverso. La quinta razón, manifiesta que el estudio de la logística humanitaria no solo se debe limitar a la reducción de los costos asociados con las operaciones, también debe trabajar la forma para minimizar el costo del tiempo, porque este es un factor muy importante en los procesos de alivio a emergencias, donde cada segundo es vital para salvar vidas. En consecuencia, la gestión de la cadena de suministro humanitaria es un factor clave para las operaciones de apoyo frente a desastres, pues la eficiencia, efectividad y velocidad en el suministro a los beneficiarios con salud, comida, refugio, agua, medicina y saneamiento juegan un papel fundamental (Thomas y Kopczak, 2005).

Según Altay y Green (2006) las operaciones esenciales en la logística humanitaria, para lograr una atención rápida y eficaz de las zonas afectadas por un desastre, pueden dividirse en cuatro etapas, las cuales son, mitigación, preparación, respuesta y recuperación, las dos primeras etapas se clasifican como operaciones de apoyo o pre-desastre, y las dos últimas se clasifican como operaciones de desarrollo o post-desastre. La fase de mitigación hace referencia a la ejecución de actividades con el fin de reducir el riesgo a largo plazo que puede generar un desastre o disminuir sus posibles consecuencias. Por otro lado, la etapa de preparación involucra todas las actividades realizadas antes que ocurra el desastre, con el fin de lograr una atención más eficiente, ejemplo de estas son: localización y construcción de los centros de abastecimiento, reclutamiento del personal requerido para los servicios de emergencia, planificación logística y capacitación. Por su parte, la fase de respuesta implica aquellas actividades realizadas una vez ocurre el desastre y cuyos

objetivos están relacionados con el despliegue de recursos vitales para atender a la población afectada; y finalmente, la recuperación hace referencia a las actividades de corto y largo plazo realizadas con el fin de restituir el funcionamiento normal de las actividades en la comunidad.

De acuerdo con lo anterior, este proyecto está enfocado a la fase de preparación, relacionada con la localización de los depósitos centrales (depósitos primarios y centros regionales) y con la fase de respuesta, que hace referencia al suministro oportuno de recursos, a través de una correcta planificación en las rutas, permitiendo así abordar un problema reciente, conocido como el 2E-LRP que involucra la localización y el ruteo multinivel (dos escalones).

Las primeras investigaciones sobre el 2E-LRP fueron realizadas por Jacobsen y Madsen (1980), quienes llevan a cabo un estudio comparativo de heurísticas para el problema de ubicación y ruteo de dos niveles, apoyándose en un caso real, el proceso de distribución de periódico, en el cual deben ser tomadas tres decisiones muy importantes: número y ubicación de los puntos de transferencia, diseño de recorridos que se originan en la imprenta para servir los puntos de transferencia y el diseño de las rutas que parten de estos puntos hasta los minoristas. La investigación tenía como finalidad construir un algoritmo heurístico que permitiera resolver de la mejor forma el problema, por lo cual realizan una comparación de tres procedimientos diferentes: un método de construcción del recorrido con ubicación implícita del punto de transferencia, un procedimiento alternativo de asignación para la ubicación del punto de transferencia, y finalmente, un procedimiento de ahorro para el enrutamiento, seguido de un proceso de colocación para la localización y un proceso de ahorro para el enrutamiento, considerando 4500 clientes o minoristas. Asimismo, Madsen (1983) publica un estudio en el que analiza, presenta y desarrolla algunos métodos de solución para el problema de ruteo y localización multinivel en dimensiones realistas, comparando a su vez tres nuevos algoritmos heurísticos, los cuales aplica al proceso de

distribución de periódico teniendo en cuenta 4500 clientes. El autor concluye su investigación afirmando que el procedimiento alternativo de ubicación, con asignación por ahorro y un procedimiento de ahorro en el ruteo, es prometedor para la obtención de buenas soluciones factibles en el problema abordado.

A continuación, se presentan algunos de los trabajos más destacados en el área de la localización y ruteo multi-escalón, tomados como referencia para abordar el tema propuesto.

Ambrosino y Scutella (2005) proponen una formulación matemática para un conjunto de escenarios dinámicos basados en el problema de ruteo y localización general de múltiples niveles (N-Echelon Location Routing Problem, NE-LRP). Las pruebas computacionales se limitan a ubicar las instalaciones, puntos de transbordo y la asignación de grandes clientes y zonas, a los centros encargados de la distribución. Esta investigación, presenta los primeros pasos hacia el estudio de los problemas de diseño de red para la distribución, que son los más complejos si se comparan con los artículos publicados hasta ese momento. En particular, estas formulaciones permiten evaluar la "dificultad" práctica de algunas instancias de referencia, y a su vez, construir una base matemática que conlleve al diseño de métodos de solución más eficientes.

Gonzalez-Feliu (2009) conceptualiza y diseña una notación general para el problema de localización y ruteo con N-escalones en la planeación táctica y operacional. La investigación es ilustrada a través de seis casos reales: los sistemas postales y de paquetes, basados en múltiples niveles de distribución, con varias plataformas cross-docking intermedias donde se realiza el transbordado; las empresas dedicadas a repartir la prensa, pues generalmente tiene una red de transporte donde los productos se distribuyen a las tiendas, a través de un sistema de plataformas consolidadas; los sistemas logísticos para la entrega de mercancías urbanas, los cuales se han convertido en un modelo multicapa con plataformas de acumulación; el transporte multimodal,

específicamente la división por contenedores, un clásico ejemplo de un sistema de varios escalones; la distribución de comestibles, campo que presenta un grupo heterogéneo en su cadena de suministro; los servicios de entrega a domicilio y las tendencias del comercio electrónico, son sistemas operacionales multinivel, específicamente los puntos intermedios de recepción. El estudio finaliza, asegurando que independientemente del caso, el NE-LRP es un problema de optimización prominente directamente relacionado con preguntas y apuesta reales de planificación.

Boccia, Crainic, Sforza y Sterle (2010) construyen un algoritmo de búsqueda tabú (Tabu Search, TS) para dar solución al problema de localización y ruteo de vehículos de dos escalones (2E-LRP). Para lograr una correcta aplicación del método propuesto, los investigadores dividen el problema en dos partes, la primera parte corresponde a un problema de localización de instalaciones capacitadas (Capacitated Facility Location Problem, CFLP), y la segunda corresponde al problema de ruteo de vehículos con múltiples depósitos (Multi-Depot Vehicle Routing Problem, MDVRP). Finalmente, la heurística es probada en tres conjuntos de instancias pequeñas, medianas y grandes; los resultados obtenidos fueron comparados con los límites derivados de los modelos exactos, permitiendo así demostrar que el TS propuesto es efectivo en términos de calidad en la solución y tiempo de cálculo para la mayoría de instancias resueltas, además, concluyen que dicho algoritmo podría adaptarse fácilmente a restricciones adicionales, como en el caso asimétrico propuesto para el ruteo de vehículos.

Boccia et al. (2011) presentan un estudio detallado de los modelos de enrutamiento para dos escalones en sistemas de distribución (Location-Routing Models for Two-Echelon Freight Distribution System Design, 2E-LRMFDSD). El problema surge al considerar dentro del mismo proceso de decisión la ubicación de instalaciones en dos niveles adyacentes, junto con los planes de ruteo para los vehículos que pertenecen a cada nivel. Realizan tres formulaciones basadas en

programación entera mixta (Mixed Integer Programming, MIP) y descritas por los autores como modelo de tres, dos y un índice (Three Index Formulation, 3i-2E-LRP; Two Index Formulation, 2i-2E-LRP; One Index Formulation, 1i-2E-LRP), los cuales son comparados posteriormente, con la finalidad de evaluar factores como la flexibilidad y simplicidad del modelo obtenido. El estudio concluye, resaltando el gran uso y aplicabilidad de los sistemas 2E-LRP en la solución de problemas reales y la potencial fuente de investigación que presenta el tema.

Perboli, Tadeo y Vigo (2011) formulan un modelo para el ruteo de vehículos capacitados de dos escalones (Two Echelon Capacited Routing Problem, 2E-CVRP), el cual tiene por objetivo minimizar el costo total de los vehículos involucrados en ambos niveles. El artículo tiene dos propósitos, en primer lugar, presentar la familia de problemas de enrutamiento de vehículos con dos niveles (Two Levels Vehicle Routing Problem, 2L-VRP), un término que cubre ampliamente tales configuraciones, donde la entrega desde un depósito a cada cliente, se gestiona enrutando y consolidando el flete a través de depósitos intermedios, y en segundo lugar, considerar en detalle la versión básica de VRP de dos niveles y el VRP capacitado de dos niveles, que es una extensión del VRP clásico, en el cual la entrega se realiza obligatoriamente a través de depósitos intermedios, llamados satélites. Además, se presentan algunas desigualdades válidas para verificar el modelo propuesto, y dos heurísticas matemáticas. Los resultados computacionales en instancias de hasta 50 clientes y cuatro satélites muestran una gran flexibilidad y eficiencia de los métodos desarrollados.

Contardo, Hemmelmayr y Crainic (2012) introducen dos algoritmos para abordar el problema de ruteo y localización multinivel con vehículos capacitados, los cuales permiten tratar de una mejor forma las interdependencias entre la localización y decisiones relacionadas con el ruteo. El primero, es un algoritmo de ramificación y corte (Branch and Cut), que se fortalece con varias

familias de desigualdades válidas, y el segundo, una metaheurística adaptativa de búsqueda de vecindarios grandes (Adaptative Large Neighbourhood Search, ALNS), construidos con la finalidad de hallar soluciones de buena calidad rápidamente. Los resultados muestran que los métodos propuestos son capaces de resolver instancias de optimalidad pequeñas y medianas que contengan hasta 50 clientes en tiempos computacionales razonables, además, proporcionan límites ajustados para las instancias que no se pueden resolver. Finalmente, al comparar los dos algoritmos, se observa que los límites más bajos obtenidos con Branch and Cut no se encuentran más allá del 3.06% por debajo de los valores obtenidos con ANLS, permitiendo así validar la solidez y calidad de ambos enfoques.

Forouzanfar y Tavakkoli-Moghaddam (2012) construyen un algoritmo genético (Genetic Algorithm, GA) para minimizar el costo total asociado al problema de localización, ruteo e inventario multi-escalón con agrupación de riesgos en la cadena de suministro (Multi-Echelon Inventory Location Routing Problem with Risk Pooling, ME-ILRPRP). Además, desarrollan un modelo matemático novedoso en el que se presenta por primera vez la unión de riesgos, tiempo de entrega, gestión del inventario con demanda incierta y planes de ruteo para una cadena de suministro estocástica, con el objetivo de minimizar el costo total de operación, compuesto a su vez por el costo fijo de abrir los centros de distribución con cierto nivel de capacidad, el costo anual de inventario y los costos de transporte. La viabilidad del modelo propuesto se verificó solucionando al azar pequeñas instancias del problema y comparando los resultados obtenidos con el software GAMS (General Algebraic Modeling System), igualmente, los resultados obtenidos con el GA fueron contrastados con GAMS en diferentes instancias para validarlo. Los resultados muestran que los tiempos de CPU (Central Processing Unit) fueron menores para el GA en comparación con los de GAMS. Por último, los investigadores destacan la importancia y

aplicabilidad del algoritmo construido, pues una gran parte de los problemas que combinan ruteo, inventario y localización multinivel son de naturaleza NP-Hard (Non-deterministic Polynomial Hard), lo cual impide el uso de modelos exactos para solucionarlos.

Nguyen, Prins y Prodhon (2012) desarrollan un híbrido para dar solución al problema de localización-ruteo de dos escalones, el cual está compuesto por un procedimiento de búsqueda voraz adaptativo aleatorio (Greedy Randomized Adaptive Search Procedure, GRASP) completado por un proceso de aprendizaje (Learning Process, LP) y reencaminamiento de ruta (Path Relinking, PR), que exigen el uso de tres heurísticas voraces para generar soluciones de prueba y dos procedimientos de descenso de vecindad variable (Variable Neighbourhood Descent, VND). Para la construcción del algoritmo, los autores se apoyan en cuatro heurísticas constructivas, las cuales trabajan en dos fases, la primera hace referencia a la construcción de rutas para el segundo nivel con la sección de los satélites abiertos, y luego, realiza la construcción de rutas para el primer nivel. Por otra parte, GRASP, es un método sin memoria multi-inicio donde cada iteración realizada se compone de dos etapas, la construcción de un ensayo-solución, utilizando una heurística codificada codiciosa, y luego, mejora esta solución por búsqueda local. Las pruebas numéricas muestran que para instancias de hasta 200 clientes y 10 satélites, GRASP con LP y PR superan los tiempos de ejecución ofrecidos por la heurística simple, además, afirman que este nuevo híbrido compite con las mejores metaheurísticas publicadas hasta el momento.

Dalfard, Kaveh y Nosratián (2013) modelan el problema de localización-ruteo de dos niveles con restricciones de capacidad en los vehículos y longitud máxima en la ruta, el cual tiene como finalidad, determinar la ubicación y el tipo de instalación, el tamaño de las flotas de transporte y el ruteo para cada nivel, cumpliendo con el objetivo de minimizar los costos de ubicación, adquisición y transporte. Los investigadores formulan dos métodos para solucionar el problema,

un algoritmo genético híbrido (Hybrid Genetic Algorithm, HGA) y la heurística de recocido simulado (Simulated Annealing, SA), con el propósito de brindar dos enfoques opuestos a la solución. Resultados de experimentos numéricos muestran que el híbrido y la heurística aplicada, brindan soluciones mucho más eficientes que las soluciones obtenidas con el software LINGO, pues básicamente, el resolver problemas de gran tamaño utilizando la herramienta computacional, condujo a soluciones con alta desviación de las óptimas o ninguna solución óptima en un tiempo razonable (20 horas). Sin embargo, la propuesta de HGA y SA obtuvo soluciones óptimas o con muy baja desviación en poco tiempo (menos de 20 horas).

Tavakkoli-Moghaddam, Forouzanfar y Ebrahimnejad (2013) presentan una investigación basada en la incorporación de decisiones relacionadas con la ubicación, ruteo e inventario en los problemas multi-objetivo para el diseño de la cadena de suministro. El modelo matemático considera el agrupamiento de riesgos, la existencia de inventario en los centros de distribución (Distribution center, DC) con demanda incierta, varias alternativas para transportar el producto entre instalaciones, y ruteo desde los centros de distribución al cliente, bajo un enfoque de cadena de suministro estocástico multinivel simultáneamente. El problema se formula haciendo uso de la programación no lineal entera estocástica, y su finalidad es hallar el número de centros de distribución, localización y niveles de capacidad, asignando clientes y proveedores a cada DC abierto, la cantidad de inventario, los planes de enrutamiento y el control requerido en los productos solicitados con su respectiva asignación de vehículo para el transporte, todo esto, bajo el objetivo de minimizar el costo total asociado al sistema y el tiempo total de transporte. Los autores resuelven el modelo haciendo uso del software LINGO (LINear Generalize Optimizer) y concluyen su investigación resaltando la importancia que tiene el tema tratado, como medio para enfrentar las decisiones estratégicas (localización), tácticas (administración del inventario) y

operativas (planes de ruteo) a las que se encuentra expuesto el encargado de diseñar y gestionar la cadena de suministro.

Rahmani, Cherif-Khetta y Oulamara (2014) proponen un modelo de localización-ruteo multiproducto de dos etapas con recogida y entrega (Two-Echelon Multi-Products Location-Routing Problem with Pickup and Delivery, LRP-MPPD-2E) utilizando la programación lineal entera mixta (Mixed Integer Linear Programming, MILP), el cual incluye restricciones que no se habían considerado en investigaciones previas del VRP, como lo son: recolección y entrega en la misma ruta, uso de uno o más centros de procesamiento intermedios en la misma ruta y demanda de múltiples productos. Finalmente, el modelo es resuelto a través de la heurística del vecino más cercano (Nearest Neighbor Heuristic, NNH) y el algoritmo de agrupamiento híbrido (Hybrid Clustering Algorithm, HCA), obteniendo buenos resultados computacionales en los dos métodos de solución para instancias menores a 200 clientes y 10 depósitos.

Cuda, Guastaroba y Speranza (2015) realizan un estudio de la literatura referente a problemas de ruteo de dos escalones. Los autores presentan una introducción donde describen estos tipos de problemas y mencionan varias aplicaciones. Detalladamente abordan el 2E-LRP, el problema de ruteo de vehículos de dos niveles (Two Levels Vehicle Routing Problem, 2E-VRP) y el problema de ruteo de camiones y remolques (Truck and Trailer Routing Problem, TTRP), muestran en qué consiste cada uno y presentan parte de la literatura más relevante. Concluyen el trabajo realizado, destacando la aplicabilidad e importancia que presentan estos problemas en la comprensión de necesidades reales, así como el hecho de que esta área en estudio aún es relativamente nueva e inexplorada, por lo que describen brevemente algunas variantes posibles en futuras investigaciones.

Pradhananga, Mutlu, Pokharel, Holguín y Seth (2016) plantean un modelo en red de tres escalones para la planificación integrada de preparación y respuesta ante un desastre. El modelo minimiza el costo social de identificar un conjunto de puntos potenciales en el escalón más alto, donde los artículos de suministro se consolidan y se envían a las instalaciones de preposicionamiento. También considera las decisiones de compras previas y posteriores a un desastre en los puntos de suministro, y permite envíos directos desde estos puntos a las regiones afectadas. El análisis numérico muestra que múltiples fuentes de suministro pueden asegurar una distribución eficiente de los recursos y reducir los costos de privación, asimismo, los resultados indican que la preposición parcial y las compras posteriores al desastre, pueden reducir la escasez de suministros cuando ocurre la emergencia.

Tavakkoli-Moghaddam y Raziei (2016) realizan un estudio enfocado al problema multi-objetivo para la localización, ruteo e inventario multinivel con demanda difusa (Multi-objective Inventory Location Routing Problem With Fuzzy Demands, MO-ILRPFD). El modelo considera varias periodos y múltiples productos con flotas heterogéneas en una red de distribución de doble escalón, cumpliendo con dos objetivos bajo conflicto: minimizar el costo total de los vehículos (combustible consumido), mantenimiento por inventario, transporte y ubicación de los centros de distribución, y a su vez, minimizar la escasez de producto para cada cliente. Los resultados numéricos para pequeñas y medianas instancias, demuestran la validez del modelo presentado y muestran su capacidad para enfrentar casos reales. Los estudios realizados proporcionan un algoritmo eficiente para resolver problemas a gran escala.

Nakhjirkan y Rafiei (2017) proponen un modelo para la localización, ruteo e inventario multinivel con demanda estocástica. La investigación se justifica en el hecho de que la tendencia creciente en el consumo de recursos naturales ha causado daños irreparables al medio ambiente,

por lo tanto, una de las maneras más efectivas de lidiar con los efectos ambientales adversos, es mediante la implementación de una cadena de suministro verde. Para dar solución al problema estudiado, se construye un algoritmo genético (GA), el cual presenta una codificación no binaria; además, los autores presentan un nuevo enfoque para la aplicación e interpretación de los operadores de cruce y mutación. Los resultados confirman la eficiencia del modelo propuesto como una herramienta práctica para los tomadores de decisiones en la red logística, inmersos en problemas de localización, inventario y ruteo multiescalón. Finalmente, el GA propuesto reduce el tiempo de solución hasta en un 15%, mientras alcanza en promedio 97% de las soluciones óptimas si se compara con el método exacto, para pequeñas y medianas instancias.

Samani y Hosseini-Motlagh (2017) presentan un algoritmo híbrido para dar solución al problema de localización-ruteo de dos escalones con recogida y entrega simultánea, considerando demanda difusa. Dicho algoritmo está compuesto por la metaheurística conocida como algoritmo genético (GA) y la heurística de recocido simulado (SA). La efectividad del método se examina mediante experimentos numéricos exhaustivos. Los resultados obtenidos al resolver el problema para diferentes tamaños, permiten verificar que el algoritmo híbrido propuesto supera a otros algoritmos respecto al tiempo computacional, en un lapso razonable. A su vez, los investigadores proponen extender una serie de consideraciones para futuros estudios. Por ejemplo, los métodos de reducción de escenarios podrían usarse para disminuir el tamaño del problema cuando se trabajan dimensiones robustas. Además, el uso de métodos de agrupamiento puede llegar a disminuir el tiempo de cálculo y la complejidad inmersa en el tema estudiado. También, sería interesante analizar el problema para un horizonte de planificación multi-periodo, considerando inventario en los depósitos intermedios y los clientes. Por último, el idear varios enfoques, como

la optimización robusta, para manejar las incertidumbres en los datos, permitirán acercarse a condiciones reales del problema abordado.

Tavana, Abtahi, Di Caprio, Hashemi y Yousefi-Zenouz (2017) diseñan un modelo multi-escalón para la cadena de suministro humanitaria, el cual considera la ubicación de los almacenes centrales, gestiona el inventario de productos perecederos en la fase previa al desastre y fija los planes de ruteo para los vehículos de socorro en la fase posterior al desastre, bajo los objetivos de minimizar el costo total de adquisición (localización, almacenamiento y transporte), costo operacional de socorro (transporte, carga y descarga de suministros) y el tiempo de socorro. Los autores proponen dos métodos de solución, el algoritmo genético de ordenación no dominado II (Non-dominated Sorting Genetic Algorithm, NSGA-II) y la frontera de Pareto para el algoritmo genético de ordenación no dominado basado en el punto de referencia II (Reference Pareto Based Non-dominated Strength Genetic Algorithm, RPBNSGA-II). A través del análisis de varianza, concluyen que el NSGA-II ofrece un mejor rendimiento que RPBNSGA-II para instancias pequeñas, pero si se quiere abordar problemas robustos, el RPBNSGA-II es superior al NSGA-II en cuanto al tiempo de ejecución.

Dai, Aqlan, Gao y Zhou (2018) abordan el problema de localización y ruteo multinivel, justificados en la importancia que tiene la solución de dichos escenarios para tomar decisiones en la red logística. El principal producto de esta investigación es desarrollar un método de dos fases basado en un algoritmo de ahorro mejorado de Clarke y Wright para LRP de dos, tres y cuatro niveles, minimizando el costo total, entendido como el costo de transporte, costo fijo por utilizar los vehículos y costo fijo de las instalaciones. Las instancias de prueba muestran que, en comparación con otros métodos, el método propuesto puede obtener la solución al 2E-LRP en un tiempo más corto. Además, los experimentos computacionales permiten inferir que el algoritmo

desarrollado puede resolver el problema de tres y cuatro niveles en un tiempo razonable. Aunque la calidad de las soluciones obtenidas por el método propuesto no son muy buenas, la velocidad computacional es más alta que la proporcionada por otros métodos discutidos en la literatura, y el tiempo computacional incrementa lentamente a medida que aumenta las dimensiones del problema. Finalmente, los autores ponen a consideración algunos factores adicionales en futuras investigaciones para LRP multi-escalón, como lo son: las limitaciones de tiempo, los parámetros inciertos (difusos y estocásticos) y el control de inventario, que involucra la decisión sobre el ciclo de reposición y la cantidad requerida, el cual es un problema operacional muy importante en la gestión de la cadena de suministro.

Vahdani, Veysmoradi, Noori y Mansour (2018) proponen un modelo multi-objetivo, multi-periodo y multi-producto para la localización, enrutamiento e inventario de dos etapas en el diseño de redes logísticas humanitarias bajo incertidumbre (Two-stage Multi-objective location-routing-inventory model for Humanitarian Logistics Network design Under Uncertainty, 2S- MOLRIU). El objetivo del modelo es minimizar los costos de establecer almacenes, depósitos y mantenimiento de inventario en el primer nivel, mientras que maximiza la fiabilidad, entendida como la confiabilidad de las rutas definidas entre almacenes-centros de distribución local y depósitos-clientes, minimizando a su vez, el tiempo y costo de transporte para la flota de vehículos en el segundo nivel. Presentan dos métodos de solución, el algoritmo genético de ordenación no dominado II y el algoritmo, optimización multi-objetivo por enjambre de partículas (Multi-objective Particle Swarm Optimization, MOPSO). Los resultados obtenidos al implementar cada algoritmo se evaluaron de acuerdo con cinco criterios: número de soluciones Pareto, la extensión máxima, el espaciado, diversidad y el tiempo requerido para solucionar 35 problemas diferentes; en consecuencia, la comparación estadística bajo condiciones de certidumbre permitió concluir

que el MOPSO es más eficiente en todos los criterios, pero si se establecen condiciones inciertas, el NSGA-II muestra mejores resultados con respecto a diversidad. Finalmente, a través del análisis de sensibilidad sobre el cambio de valor en el parámetro tiempo de viaje, los investigadores concluyen que la función objetivo relacionada con el costo de transporte, mejora y empeora con relación a ciertos puntos críticos, mientras que la función objetivo de fiabilidad en la ruta aumenta, a medida que incrementa el factor demanda y el costo total en la red de distribución, observando a su vez, que un aumento significativo de la incertidumbre, empeora los resultados obtenidos con cada función objetivo.

4. Marco de antecedentes

En la Universidad Industrial de Santander se han realizado algunos trabajos de investigación a nivel de pregrado y maestría que buscan solucionar problemas de localización-ruteo y ruteo de dos escalones, sub-problemas que hacen parte del tema tratado en el presente estudio. A continuación, se dan a conocer algunos de los proyectos más relevantes que se han llevado a cabo, los cuales son afines y aportan significativamente al desarrollo de la investigación.

Nier y Niño (2015) desarrollan un algoritmo híbrido para resolver el problema de localización-ruteo con múltiples depósitos capacitados y un vehículo por depósito, usando la metaheurística de optimización por colonia de hormigas (Ant Colony Optimization, ACO) junto con el método, búsqueda local iterativa (Iterative Local Search, ILS). El modelo cumple con el objetivo de minimizar los costos para ubicar depósitos y los costos asociados a cada viaje (costo de transporte). Los resultados computacionales muestran que el algoritmo híbrido construido para resolver el problema conjunto de localización de instalaciones y ruteo de vehículos es válido, y presenta buena

eficiencia en cuanto a tiempo de ejecución, además, se evidencia un mayor rendimiento con relación a costos, si se compara con el algoritmo ACO tradicional.

Barreto y Niño (2016) estudian el problema de localización-ruteo con ventanas de tiempo (Location Routing Problem with Time Windows, LRPTW) para la atención de desastres sísmicos en la ciudad de Bucaramanga. El objetivo principal del LRPTW es localizar un número de depósitos y establecer una serie de rutas óptimas que permiten satisfacer las ventanas de tiempo de los clientes a servir. Para la solución del problema se diseñó un algoritmo memético, que hace uso de los operadores de búsqueda local, con el objetivo de minimizar el tiempo total de respuesta. Dicho algoritmo fue validado con las instancias de literatura que presenta Prodhon para el problema de localización-ruteo capacitado (Capacitated Location Routing Problem, CLRP), usando el lenguaje de programación Matlab, debido a la inexistencia de instancias para el modelo. Los resultados obtenidos muestran que el algoritmo encuentra soluciones cercanas al óptimo de las instancias validadas, haciendo una comparación respecto al número de vehículos usados, ya que al tener funciones objetivo diferentes no se puede comparar directamente con los costos.

Aguilar (2017) presenta en su tesis de maestría un modelo para la localización-ruteo multi-objetivo capacitado (Multi-objective Capacitated Location Routing Problem, MCLRP) en la planeación logística durante la fase de preparación a sismos en Bucaramanga, el cual tiene como propósito, minimizar el tiempo de viaje total de los clientes a los albergues (tiempo global de evacuación), y a su vez, maximizar el grado de confiabilidad en los albergues habilitados, minimizando la suma de los índices de vulnerabilidad sísmica asociados a estos. El método utilizado para dar solución al problema corresponde a un algoritmo memético (Memetic Algorithm, MA), compuesto por un algoritmo genético de ordenación no dominado II (Non-dominated Sorting Genetic Algorithm, NSGA-II) y un procedimiento de búsqueda local (Local

Search Procedure, LSP). Los resultados permiten concluir que el procedimiento elitista del algoritmo NSGA II, aporta un conjunto de soluciones óptimas de Pareto en lugar de un solo objetivo, ofreciendo al usuario de la herramienta diferentes opciones de solución ajustadas a sus necesidades, lo cual resulta oportuno en el campo de la logística humanitaria, donde existen diferentes objetivos en conflicto y resulta muy difícil satisfacerlos a todos.

Niño (2017) presenta una investigación en la que aborda el problema de ruteo de vehículos capacitados de dos escalones (Two Echelon Capacited Vehicle Routing Problem, 2E-CVRP). Para la solución del modelo, que tiene por objetivo minimizar los costos de transporte asociados a las rutas de primer y segundo nivel, el autor optó por implementar un híbrido metaheurístico, la primera técnica denominada procedimiento de búsqueda voraz adaptativo aleatorio (Greedy Randomized Adaptative Search Procedures, GRASP), el cual se enfoca en la formación de una solución inicial para el problema al hacer uso de un procedimiento de división, dando así paso a la segunda técnica, conocida como recocido simulado (Simulated Annealing, SA), en el que por medio de los operadores de construcción de vecindades 2-opt, Or-opt y Exchange, se intensifica la inquisición de mejora de la solución inicial. La forma en la que trabaja el método híbrido permitió proponer una extensión, la cual encuentra soluciones favorables respecto del método inicial, al ser probada sobre las instancias encontradas en la literatura para el 2E-CVRP, observando a su vez, como el procedimiento de división toma protagonismo por su función en la construcción de soluciones iniciales en la primera etapa, mientras que en la segunda, son los operadores de construcción de vecindades los que determinan una mayor intensificación en la búsqueda de soluciones de mayor calidad.

Por último, Niño y Vargas (2018) abordan el problema de localización y ruteo de vehículos con ventanas de tiempo (Location Routing Problem with Time Windows, LRPTW) en el proceso de

recolección de residuos sólidos en el centro de la ciudad de Bucaramanga para la empresa de aseo EMAB. El objetivo del LRPTW es localizar estaciones de transferencia en los parques del centro de la ciudad, destinados al almacenamiento temporal de residuos sólidos y la generación de rutas óptimas que permitan satisfacer las ventanas de tiempo de los clientes. Para dar solución al problema se elaboró un algoritmo memético, el cual combina operadores genéticos y de búsqueda local, con el objetivo de minimizar el costo. El algoritmo fue ejecutado por medio del lenguaje de programación Python y validado con las instancias presentadas por Prodhon y Barreto para el problema de localización - ruteo capacitado (CLRP), debido a la no existencia de instancias para el LRPTW en su momento. Los resultados obtenidos con el algoritmo memético muestran que este se acerca a las mejores soluciones encontradas en las instancias de baja complejidad. Asimismo, se evaluó el caso de estudio (la EMAB), determinando la ubicación de las estaciones de transferencia con sus respectivas rutas para cada grupo de clientes que conforman la empresa, respetando la capacidad de los vehículos y las ventanas de tiempo establecidas para los usuarios.

5. Marco teórico

5.1. Logística Humanitaria.

La logística humanitaria es definida formalmente por Thomas y Mizushima (2005) como:

El proceso de planeación, ejecución y control de la eficiencia, rentabilidad, flujo y almacenamiento de bienes y materiales, así como la información relacionada, desde el punto de origen al punto de consumo, con el propósito de satisfacer las necesidades de los beneficiarios finales (p. 60).

Esta definición es quizás la más completa, pues abarca en su descripción una amplia gama de operaciones logísticas que incluyen la distribución de medicamentos, alimentos en la lucha contra el hambre, suministros para desastres, etc.

Otra definición de logística humanitaria es dada por Gaytan, Arroyo y Enríquez (2010) quienes la definen como el proceso de planear, implementar y controlar efectiva y eficientemente los flujos de productos, materiales e información desde los donadores —individuos y organizaciones— hasta las personas afectadas, con el fin de atender sus necesidades de supervivencia. La aplicación de conocimientos y habilidades, más la movilización de personas y recursos, es de gran importancia para atender rápida y efectivamente a la población afectada.

5.2. Suministro de emergencia.

Se entiende como suministros de emergencia o humanitarios, aquellos materiales, productos y equipos utilizados por las organizaciones para la atención de los desastres, así como los requeridos para el cuidado de la población afectada. Estos suministros cubren una amplia gama, que incluye desde los productos y materiales para uso y consumo de la población, hasta aquellos requeridos por las organizaciones para brindar la asistencia o rescate. Algunos suministros son adquiridos o canalizados por las propias organizaciones, respondiendo a las necesidades determinadas en el terreno, pero la gran mayoría son el producto de la solidaridad espontánea de la comunidad nacional e internacional (Organización Panamericana de la Salud [OPS] y Organización Mundial de la Salud [OMS], 2001).

5.3. Desastre.

La OMS define un "desastre" como cualquier evento que causa daño, destrucción, alteración ecológica, pérdida de la vida humana, sufrimiento humano, deterioro de los servicios sanitarios y

de salud en una escala suficiente para justificar una respuesta extraordinaria desde fuera de la comunidad o área afectada (Safeer, Anbuudayasankar, Balkumar, y Ganesh, 2014).

Un desastre es un evento, generalmente repentino e imprevisto, que ocasiona daños, pérdidas y paralización temporal de actividades en cierta área y afecta a una parte importante de la población. De acuerdo con el fenómeno que los originan, los desastres pueden clasificarse en dos grandes grupos: los que son provocados por fenómenos naturales y los que se derivan de actividades humanas. Los principales efectos primarios de los desastres son: la pérdida de vidas y lesiones en la población, la pérdida de bienes, el daño e interrupción de los servicios básicos, los daños en la infraestructura, la desorganización social y física de la comunidad, y las alteraciones orgánicas y conductuales de las personas (CEPAL, 2005).

5.3.1. Principales efectos de un desastre. Tras la ocurrencia de un desastre, sus efectos están determinados por el grado de impacto del mismo y la forma como éste afecta a una región, ya que generan diferentes tipos de necesidades sobre la población y su entorno. Algunos de los principales efectos que se pueden presentar son las enfermedades por contaminación del agua, desplazamientos de la población y exposición a la intemperie, escasez de alimentos, afectación de la salud mental y daños a las infraestructuras de servicios vitales. Por este motivo es importante contar con un plan local de emergencia que permita dar respuesta oportuna y evitar situaciones no deseadas, para así mitigar los efectos adversos (Baas, Ramasamy, Pryck, y Battista, 2009).

5.3.2. Gestión de desastres. La gestión de desastres es un conjunto de procesos diseñados para ser implementados antes, durante y después de un desastre, con la finalidad de prevenir o mitigar sus efectos. En general, se lleva a cabo en un sistema de ciclo que consiste en varias etapas principales. Entes gubernamentales y organizaciones están implicados en la gestión de desastres. El éxito de estos sistemas depende en gran medida de la cooperación y la coordinación de las

organizaciones que participan en las operaciones de socorro eficaz y eficiente. A fin de reducir las vulnerabilidades físicas, sociales, económicas, ambientales y disminuir el impacto de los eventos naturales extremos, se requiere de un marco estratégico para enfrentar los desastres naturales. Este marco estratégico debe tener en cuenta e incorporar las variables ambientales en las diferentes fases del ciclo de gestión de desastres (pre y pos-desastre) (Manopiniwes y Irohara, 2014).

5.3.3. Fases para la atención de un desastre. Las etapas para la atención de un desastre son descritas en la *Tabla 2*.

Tabla 2.
Fases para la gestión de desastres.

	Descripción	Fase
Antes del desastre (pre-desastres)	Se aprecian los valores de riesgo del territorio y se evalúa el nivel de preparación de la población ante las amenazas. Se educa a la población, se adiestra al recurso humano necesario, se realizan inventarios y se acopian los recursos para su movilización rápida. Es el período más importante del proceso de planificación, el más largo y de mayores posibilidades para cumplir medidas de prevención, mitigación y preparación contra emergencia y desastre, según el fenómeno que se esté analizando. Es también la fase de reducción de riesgo previo al desastre.	<p><i>Mitigación:</i> Actividades que se realizan antes de un desastre, para reducir o atenuar el efecto de su impacto en la población, la economía y el medio ambiente. Se hace con el fin de modificar las características de un fenómeno, con el objetivo de reducir el impacto de la amenaza.</p> <p><i>Preparación:</i> Conjunto de medidas (educar, capacitar, adiestrar a la población y localizar instalaciones) cuyo objetivo es organizar y estructurar la respuesta de la comunidad a las condiciones adversas.</p>

Continuación Tabla 2.

	Descripción	Fase
Después del desastre (pos-desastre)	Esta fase comprende la respuesta planificada y oportuna, se lleva a cabo inmediatamente después de ocurrido un evento adverso y requiere la realización de un conjunto de acciones integradas, multifactoriales y multisectoriales, para salvar vidas, reducir sufrimientos, pérdidas económicas y daños al medioambiente. La emergencia comienza inmediatamente después del impacto y es cuando se brinda apoyo y asistencia a las víctimas. Algunas de las operaciones que se requieren son: búsqueda, rescate y primeros auxilios, asistencia médica de urgencia, evacuación de heridos, lesionados y alojamiento temporal de damnificados (evacuación del personal de áreas vulnerables).	<i>Respuesta:</i> Implica aquellas actividades realizadas una vez ocurre el desastre y cuyos objetivos están relacionados con el despliegue de recursos vitales para atender a la población afectada. <i>Recuperación:</i> Hace referencia a las actividades de corto y largo plazo realizadas con el fin de restituir el funcionamiento normal de las actividades en la comunidad.

Nota: Adaptado de Altaya y Green (2006).

5.4. Optimización matemática

La optimización es la acción de obtener el mejor resultado en un determinado evento. Con el fin de alcanzar la mejor solución posible, es vital tomar las decisiones correctas dentro de un grupo de alternativas; y la medida de que “tan buena” ha sido dicha selección es detallada por medio de la función objetivo. Además, es importante resaltar el hecho de que esta función objetivo está ligada a un conjunto de restricciones, las cuales juegan un papel fundamental puesto que agregan realismo al modelo. Formalmente y de modo general, la representación que toma un modelo equivale a:

Minimizar o Maximizar $f(X)$, $X = [x_1, x_2, x_3, \dots, x_n] \in \mathbb{R}^n$

Sujeto a:

$$g_i(X) \leq 0, i = 1, 2, \dots, m$$

$$h_j(X) = 0, j = 1, 2, \dots, l$$

$$p_k(X) \geq 0, k = 1, 2, \dots, n$$

Donde $f(X)$, $g_i(X)$, $h_j(X)$ y $p_k(X)$ son funciones escalares del vector X . Los componentes x_i de $X = [x_1, x_2, x_3, \dots, x_n]$ son llamadas variables de diseño, $f(X)$ es la función objetivo, $g_i(X)$ y $p_k(X)$ denotan las funciones restrictivas de desigualdad y $h_j(X)$ las funciones restrictivas de igualdad (Chong y Zak, 2001).

5.5. Modelos matemáticos

Hay varias formas de clasificar los modelos matemáticos, ya sea por la existencia de restricciones, en la que el modelo podría ser restringido o no restringido; la naturaleza de la ecuación en donde el modelo puede ser lineal o no lineal; o dependiendo de los valores que pueden tomar las variables, donde estos pueden ser reales o enteros, y determinísticos o estocásticos. Se procede a dar una explicación de los modelos matemáticos de acuerdo a la naturaleza de la ecuación, abordando los dos siguientes modelos (Hillier y Lieberman, 2010):

5.5.1. Modelos de programación lineal. “La programación lineal resuelve problemas donde todas las relaciones entre las variables son lineales, tanto en las restricciones como en la función objetivo”, si llega a existir alguna relación no lineal, entonces todo el modelo deja de serlo; este tipo de modelo tiene aplicaciones en áreas como la ingeniería, la ciencia y la industria entre otros. Un problema de este tipo puede plantearse generalmente de la siguiente forma:

$$\text{Min ó Max } Z = f(X) = \sum_{j=1}^n C_j * x_j$$

Sujeto a:

$$\sum_{j=1}^n a_{ij} * x_j = b_i, \quad i = 1, 2, \dots, m$$

$$\sum_{j=1}^c h_{kj} * x_j \geq t_k, \quad k = 1, 2, \dots, r$$

$$\sum_{j=1}^a p_{lj} * x_j \geq d_l, \quad l = 1, 2, \dots, s$$

5.5.2. Modelos de programación no lineal. Este tipo de modelo permite romper con la suposición de linealidad. Hay una gran variedad de problemas que se modelan por medio de programación no lineal. Estos modelos tienen aplicaciones en topología y economía, así como también en problemas que implican distancias, siendo un claro ejemplo los problemas de localización. La representación general es la siguiente:

$$\text{Min ó Max } \mathbf{Z} = f(X), \quad X = [x_1, x_2, x_3, \dots, x_n]$$

Sujeto a:

$$g_i(X) \leq 0, i = 1, 2, \dots, m$$

$$h_j(X) = 0, j = 1, 2, \dots, l$$

Donde $g_i(X)$ y $h_j(X)$ son funciones restrictivas de n variables de decisión.

5.6. Optimización combinatoria

Es una rama de la optimización en matemáticas aplicadas y la ciencia de la computación, la cual estudia los problemas que se caracterizan por presentar una cantidad finita de soluciones factibles y trabajar con variables discretas.

5.6.1. Definición de los problemas de optimización combinatoria. En términos generales, un problema de optimización consiste en encontrar el valor de ciertas variables de decisión para maximizar o minimizar determinada función objetivo, sujeta a un conjunto de restricciones. Comúnmente, se trata de maximizar cuando se hace referencia a utilidades o ganancias, y cuando se trata de minimizar, se habla de costos.

Un problema de optimización combinatoria puede ser definido por:

- Un conjunto de variables $X = (X_0, X_1, X_2, \dots, X_n)$
- Un dominio de las variables $D_0, D_1, D_2, \dots, D_n$
- Restricciones entre variables
- Una o varias funciones objetivo para maximizar o minimizar, donde $f: D \rightarrow R$

El conjunto de todas las posibles asignaciones factibles es:

$$S = \{s: (X_1, V_1), \dots, (X_n, V_n)\}$$

Donde $X_1 \in D_1$, y s satisface todas las restricciones.

Así, resolver un problema de optimización combinatoria consistirá en encontrar una solución $s^* \in S$ tal que, $f(s^*) \leq f(s)$ para cualquier $s \in S$ si se minimiza o $f(s^*) \geq f(s)$ si se maximiza (Blum y Roli, 2003).

En este tipo de problemas, las variables se agrupan en varios conjuntos que representan objetos e incluyen una estructura de datos compleja, como permutaciones, grafos, árboles, etc. Cada una de las variables del problema es ubicada en ciertas posiciones generando una configuración. La combinatoria se encarga de estudiar dichas configuraciones. En los problemas combinatorios se trata de buscar cuál es la mejor configuración, para conocerla se construyen una o más funciones de valor sobre el espacio de las configuraciones; según la cantidad de funciones de valor

construidas, los problemas combinatorios pueden ser de un solo objetivo (una función de valor) o multi-objetivo (más de una) (Sánchez, 2000).

En general, los problemas de optimización combinatoria (Combinatorial Optimization, CO) son clasificados de acuerdo a su complejidad computacional, y esto ha llevado al desarrollo de muchos algoritmos para hallar la solución del problema. La CO no solo es útil para comprender la complejidad de los algoritmos, también permite verificar si una propuesta de solución a un problema de optimización discreto es óptima (Lange, 2010).

5.6.2. Complejidad computacional. Teniendo en cuenta la teoría de complejidad computacional, los problemas de optimización pueden ser clasificados de acuerdo al tiempo computacional requerido para encontrar una solución, en clases de complejidad, como lo establecen Johnson y Garey (1979):

Clase P: Contiene aquellos problemas de decisión que una máquina de Turing determinística puede resolver en tiempo polinómico. Este tipo de problemas pueden ser resueltos en un tiempo computacional razonable, por ejemplo, ejercicios de ordenación, búsqueda, entre otros.

Clase NP: Esta clase está conformada por aquellos problemas que no pueden resolverse en un tiempo polinomial. Este conjunto de problemas puede ser resuelto en tiempo polinómico por una máquina de Turing no determinista. Cabe resaltar que los problemas de tipo NP son verificables en tiempos polinómicos, es decir, dada una posible solución para una instancia, es posible comprobar que es válida en un tiempo n^k .

Clase NP-Complete: Es un subconjunto de la clase NP, este tipo de problemas se caracterizan por ser los de mayor complejidad dentro de su grupo, por lo cual es menos probable encontrar una

solución en tiempo polinómico, dado que cualquier problema en NP se puede reducir a cada uno de los problemas de NP-Complete.

Clase NP-Hard: En esta clase se encuentran los problemas que son por lo menos tan difíciles como los NP; sin embargo, no se encuentra establecida su complejidad, por tanto, puede ser más difícil un problema de esta categoría, que uno clasificado como NP-Complete. El tiempo de ejecución de un algoritmo que intenta solucionar un problema de clase NP-Hard, aumenta de forma exponencial respecto al tamaño del problema.

5.6.3. Principales problemas en la optimización combinatoria

5.6.3.1. Conceptos importantes. Ruteo: Proceso mediante el cual se especifica o determina un camino entre dos puntos de la red, es decir, entre el nodo de origen y nodo de destino.

Localización: Hace referencia al lugar físico donde se ubicará la instalación o depósito, el conjunto de ubicaciones es llamado espacio de solución y puede ser representado de forma continua, discreta o sobre redes como lo describe Álvarez (2009):

- *Espacio continuo:* Se conoce generalmente un conjunto de sitios potenciales para la localización de una instalación específica en el espacio geográfico que se está considerando y el resultado, es la selección de uno o varios sitios potenciales.
- *Espacio discreto:* Se tiene un espacio determinado por coordenadas que varían de modo continuo y en la cuales la generación de los sitios candidatos para la localización se deja al modelo, asumiendo que no se conocen estos sitios previamente.
- *Representación en redes:* Comúnmente llamado grafo, puede ser continuo, cuando los posibles lugares de ubicación se encuentran tanto en vértices como en cualquier otro punto

sobre los arcos del grafo, o discreto, si únicamente los vértices son candidatos para ubicar las instalaciones.

Cliente: Este término se usa para denotar los objetos que requieren o demandan acceso a un producto o servicio. De los clientes se debe conocer su comportamiento, demanda y distribución.

- *Comportamiento*: Se refiere a las preferencias del cliente por seleccionar la instalación que le presta el servicio u ofrece el producto.
- *Demanda*: A cada cliente se le asigna un valor que representa la cantidad de servicio o producto que requiere. Esta demanda puede ser estocástica o determinista.
- *Distribución*: Los clientes se distribuyen uniformemente en el espacio o en los vértices de una red.

5.6.3.2. Problema de ruteo de vehículos. El problema del VRP es uno de los más comunes en la optimización de operaciones logísticas y uno de los más estudiados; plantea la búsqueda de la solución óptima con diferentes restricciones tales como: número de vehículos, su capacidad, localización de los centros de distribución, lugares de destino (clientes) y demanda de los clientes, entre otras. Una formulación de este tipo puede incluir un amplio número de variables y diversos parámetros; además, este tema presenta un interés práctico y académico por constituirse en un problema de optimización combinatoria que pertenece en su mayoría a la clase NP-Hard, pues no es posible resolverlos en tiempo polinomial (Rocha, González, y Orjuela, 2011).

El primer problema planteado tipo VRP fue el del agente viajero o TSP (Travelling Salesman Problem) introducido por Flood en 1956. Dicho problema recibe este nombre porque puede describirse en términos de un agente vendedor que debe visitar cierta cantidad de ciudades en un solo viaje, de tal manera que inicie y termine su recorrido en la ciudad “origen”; el agente necesita

determinar cuál ruta debe seguir para visitar cada ciudad una sola vez y regresar de tal manera que la distancia total recorrida sea mínima. De la formulación propuesta por Flood, nacen variaciones como el TPS generalizado en 1959 con Dantzing y Ramser; trabajo en el cual se modeló el despacho de combustible a través de una flota de camiones a diferentes estaciones de servicio, desde una terminal (Rocha, González, y Orjuela, 2011).

5.6.3.3. Problema de localización-ruteo. Un enfoque importante en los problemas de logística es la integración de las decisiones concernientes a diferentes niveles jerárquicos (estratégico, táctico y operativo) y la solución simultánea de éstas. Por lo tanto, los efectos de la localización de instalaciones, transporte y ruteo, control de inventarios, planeación y programación de la producción, deben considerarse conjuntamente, pues una perspectiva global impide la optimización local de problemas con decisiones dependientes, como en el caso de la localización y el ruteo (Min, Jayaraman, y Srivastava, 1998).

El problema de localización y ruteo (Location Routing Problem, LRP) constituye un aspecto fundamental en la gestión de desastres y es definido según Bruns (1998), como la planificación de ubicación con aspectos de recorrido tomados en cuenta. Por lo tanto, el problema es jerarquizado, es decir, se debe resolver el problema principal de localización, teniendo en cuenta el sub-problema de enrutamiento, ya que, si se tratan por separado, es posible encontrar soluciones sub-óptimas. El objetivo principal es minimizar los costos totales de logística, los cuales incluyen: costo fijo de apertura de depósitos, costo variable asociado a rutas establecidas y costo fijo por el uso de los vehículos. Finalmente, Nagy y Salhi (2007) destacan que las decisiones en estos problemas se interrelacionan, y son de gran importancia para lograr una adecuada gestión de las operaciones logísticas.

5.6.3.4. Problema de localización y ruteo de dos escalones. Al igual que el LRP, el problema de localización y ruteo de dos escalones (2E-LRP) consiste en la determinación de rutas óptimas, en este caso, para la distribución oportuna de los suministros requeridos entre depósitos primario-centros regionales y centros regionales-clientes, los cuales deben ser localizados simultáneamente teniendo en cuenta un conjunto de sitios disponibles. El primer nivel o escalón corresponde a la relación depósitos primarios-centros regionales, y el segundo nivel, la relación existente entre centros regionales-clientes, reduciéndose de esta manera el problema, a la aplicación de un doble ruteo con localización (Rahmani et al., 2014). De acuerdo con la notación establecida por Laporte (1988) y luego modificada por Boccia et al. (2011), el problema abordado tiene la forma $3/\bar{T}/\bar{T}$, donde el número “3” hace referencia al número de capas, la letra “T” significa que un vehículo cualquiera parte de un vértice-orígen, visita dos o más vértices-destino y finaliza su viaje en el mismo vértice-orígen, y la línea “—” sobre la letra T señala si en el nivel o escalón “k-ésimo” se toman decisiones de localización. Siguiendo así con la representación propuesta, la primera capa corresponde a los depósitos primarios, la segunda tiene que ver con los centros regionales y la tercer capa está asociada con los clientes; asimismo, las “ \bar{T} ” indican que se consideran decisiones de localización para el primer y segundo escalón. A continuación, se presenta un esquema general del problema tratado (ver Figura 2).

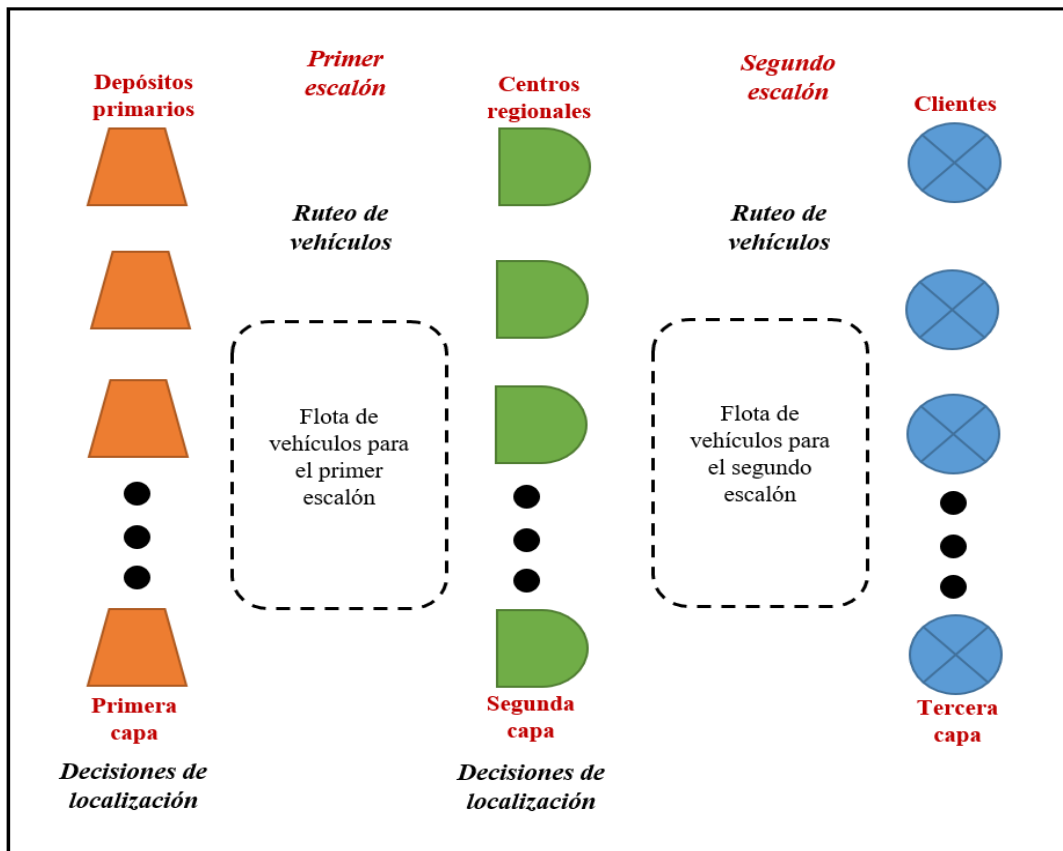


Figura 2. Representación esquemática del 2E-LRP. Adaptado de Dai, Aqlan, Gao y Zhou (2018)

5.7. Métodos de solución para los problemas de optimización combinatoria

Los problemas de optimización combinatoria han presentado diversas aplicaciones prácticas en el mundo real, convirtiéndose así en temas atractivos para investigación y extensión. Dada la existencia de los problemas con una complejidad computacional NP, surgen diferentes métodos de solución entre los cuales se encuentran los *métodos exactos* y los *métodos aproximados*; estos últimos son utilizados para los problemas NP-Hard debido a que con las características de estos problemas, el tiempo computacional utilizado para obtener la solución óptima es muy elevado, pero gracias a los métodos aproximados, se logra establecer una respuesta muy cercana a la óptima en un tiempo razonable. En este grupo de métodos se encuentran las heurísticas y las metaheurísticas.

5.7.1. Métodos Exactos. Son aquellos capaces de ofrecer la respuesta óptima de un problema determinado en un tiempo determinado. Para problemas con una complejidad computacional NP-HARD suelen tener tiempos de desarrollo bastante elevados (este tiempo crece exponencial al tamaño de la entrada del problema). Algunos de los métodos exactos son nombrados a continuación.

- **Método simplex:** Es un procedimiento desarrollado por George Dantzing en 1947, con gran utilización debido a su extraordinaria eficiencia para solucionar problemas de programación lineal. Este método parte de una solución inicial (si es posible se selecciona el origen), y examina si alguna de las aristas de la posición actual conduce a una tasa positiva de mejoramiento de la función objetivo. En caso de presentarse una mejor solución, se realiza una iteración para moverse a esta posición y se examina la tasa de mejoramiento de cada arista de la misma. El algoritmo finaliza, cuando ninguna de las aristas de la actual posición conlleva a una tasa de mejoramiento positiva, estableciendo esta como la solución óptima (Hillier y Lieberman, 2010).
- **Branch and Bound:** Es uno de los métodos exactos más utilizados para la resolución de problemas de optimización combinatoria NP-Hard. Este método funciona a través de un árbol de búsqueda que comienza con un nodo denominado nodo raíz y es quien está directamente relacionado con el problema a resolver. A partir de éste, surgen nuevos nodos correspondientes a sub-problemas que se van optimizando de forma individual y se van ramificando hasta llegar a la solución óptima del problema en cuestión (Li y Li, 2009).

5.7.2. Métodos aproximados. Dado los grandes tiempos de procesamiento que ofrecen los métodos exactos a la hora de resolver problemas NP-Hard, surgen los métodos aproximados, los cuales ofrecen resultados en tiempos razonables. Aunque estas soluciones no son las óptimas,

muchas se consideran soluciones muy cercanas a las óptimas. Los métodos aproximados se clasifican en métodos heurísticos y metaheurísticos.

5.7.3. Métodos Heurísticos. Basados en un algoritmo planteado por Winker y Maringer (2007), se establece que una heurística de cumplir con las siguientes condiciones:

1. Debe ser capaz de proporcionar aproximaciones de alta calidad al óptimo global.
2. Ser robusta, es decir, presentar flexibilidad a los cambios del problema.
3. Aplicable a muchas instancias del problema y de hecho, poder adaptarse a nuevos problemas a pesar de que casi siempre es desarrollada para la solución de un problema específico.
4. Las heurísticas pueden ser algoritmos estocásticos, pero no deben contener elementos subjetivos.

Según Ropke (2005), existen dos tipos de heurísticas:

Heurísticas constructivas: Este tipo de heurísticas se encargan de construir una solución factible de manera paulatina, a la vez que consideran el costo de la solución, sin embargo, no cuentan con una fase de mejora de la solución. Estas heurísticas son prácticas para problemas reales, ya que sus tiempos de respuestas son apropiados. Dentro de este tipo de heurística se encuentran:

- Heurísticas de inserción
- Heurísticas de ahorro
- Heurísticas de agrupación

Heurísticas de mejora: Este término se puede usar para describir heurísticas de búsqueda local que solamente desarrollan operaciones para mejorar la solución. Se basan en una solución actual, la cual se modifica de una manera sistemática al evaluar cambios en la configuración de la

solución, si estos cambios generan una mejora en la solución, entonces la solución actual es reemplazada por la solución mejorada. Ejemplo de estas son:

- Heurística 2-opt
- Heurística Or-opt
- Heurística Exchange

5.7.4. Metaheurísticas. El término metaheurística fue introducido por Fred Glover (1986). Los profesores Osman y Kelly (1995) citados por Suarez (2011) lo definieron como: “Una clase de métodos aproximados que están diseñados para resolver problemas difíciles de optimización combinatoria, en los que los heurísticos clásicos no son efectivos. Las metaheurísticas proporcionan un marco general para crear nuevos algoritmos híbridos, combinando diferentes conceptos derivados de la inteligencia artificial, la evolución biológica y los mecanismos estadísticos”.

Existen ciertas propiedades fundamentales que caracterizan a este tipo de métodos:

- Las metaheurísticas son estrategias o plantillas generales que guían el proceso de búsqueda.
- El objetivo es una exploración eficiente del espacio de búsqueda para encontrar soluciones casi óptimas.
- Las metaheurísticas son algoritmos no exactos y generalmente son no deterministas.
- Pueden incorporar mecanismos para evitar regiones no prometedoras del espacio de búsqueda.
- El esquema básico de cualquier metaheurística tiene una estructura predefinida.

Resumiendo, se puede acordar que una metaheurística es una estrategia de alto nivel que usa diferentes métodos para explorar el espacio de búsqueda. En otras palabras, una metaheurística es

una plantilla general no determinista, que debe ser rellena con datos específicos del problema (representación de las soluciones, operadores para manipularlas, etc.) y que permite abordar problemas con espacios de búsqueda de gran tamaño. En este tipo de técnicas es muy importante el correcto equilibrio (generalmente dinámico) que haya entre *diversificación* e *intensificación*. El término *diversificación* se refiere a la evaluación de soluciones en regiones distantes del espacio de búsqueda (de acuerdo a una distancia previamente definida entre soluciones), también se conoce como exploración del espacio de búsqueda. El término *intensificación*, por otro lado, se refiere a la evaluación de soluciones en regiones acotadas y pequeñas con respecto al espacio de búsqueda, centradas en el vecindario de soluciones concretas (explotación del espacio de búsqueda). El equilibrio entre estos dos aspectos contrapuestos es de gran importancia, ya que por un lado deben identificarse rápidamente las regiones prometedoras del espacio de búsqueda global y por otro lado, no se debe malgastar tiempo en las regiones que ya han sido exploradas o que no contienen soluciones de alta calidad.

Hay diferentes formas de clasificar y describir las técnicas metaheurísticas. Dependiendo de las características elegidas se pueden obtener diferentes taxonomías: basadas en la naturaleza y no basadas en la naturaleza, con memoria o sin ella, con una o varias estructuras de vecindario, etc. Una de las clasificaciones más populares las divide en *metaheurísticas basadas en trayectoria* y *basadas en población*. Las primeras manipulan en cada paso un único elemento del espacio de búsqueda, mientras que las segundas trabajan sobre un conjunto de ellos (población).

5.7.4.1. Metaheurísticas basadas en la trayectoria. La principal característica de estos métodos es que parten de una solución y mediante la exploración del vecindario van actualizando la solución actual, formando una trayectoria. La mayoría de estos algoritmos surgen como extensiones de los métodos de búsqueda local simples a los que se les añade algún mecanismo para escapar de los mínimos locales. Esto implica la necesidad de una condición de parada más elaborada que la de encontrar un mínimo local. Normalmente se termina la búsqueda cuando se alcanza un número máximo predefinido de iteraciones, se encuentra una solución con una calidad aceptable o se detecta un estancamiento del proceso.

- **Recocido Simulado (SA):** Esta metaheurística fue propuesta por Kirkpatrick, Gelatt y Vecchi en 1983. Es un procedimiento de búsqueda local aleatorio en el que una modificación a la solución actual (que conduce a un aumento del costo de la solución), puede ser aceptada con cierta probabilidad. Este algoritmo está inspirado en el proceso físico de templado de metales. Para conseguir que la estructura molecular del metal tenga las propiedades deseadas de resistencia o flexibilidad, es necesario controlar la velocidad del proceso de templado (enfriamiento). Si se hace adecuadamente, el estado final del metal es un estado de mínima energía.

En un contexto de optimización combinatoria, una solución corresponde a un estado del sistema físico y el costo de la solución, a la energía del sistema. En cada iteración, la solución actual es modificada por la selección aleatoria de un movimiento. Si la nueva solución ofrece una mejora, es automáticamente aceptada y se convierte en la nueva solución actual. De lo contrario, la nueva solución es aceptada de acuerdo con el criterio de Metrópolis, donde la probabilidad de aceptación está relacionada con la magnitud del aumento del costo y un parámetro llamado temperatura. Básicamente, es más probable que

sea aceptado un movimiento si la temperatura es alta y el aumento del costo es bajo. El parámetro de temperatura se reduce progresivamente, cuando la temperatura es lo suficientemente baja; sólo los movimientos que mejoran la función son aceptados y el método se detiene en un óptimo local. A diferencia de la mayoría de metaheurísticas, este método converge asintóticamente a un óptimo global (suponiendo un número infinito de iteraciones) (Dowland y Diaz, 2001).

- ***Búsqueda Tabú (TS)***: La búsqueda tabú usa mecanismos inspirados en la memoria humana como la memoria a corto y largo plazo para almacenar información del camino seguido al recorrer el espacio de búsqueda. La memoria a corto plazo es usada para prevenir que se visite la misma solución más de una vez (ciclo) y la memoria a largo plazo para buscar en diferentes áreas del espacio de solución. La búsqueda tabú empieza con una solución factible y luego se evalúan las soluciones del vecindario, de tal manera que la solución más prometedora es seleccionada. Esta estrategia permite la selección de los movimientos que deterioran la calidad de la solución con el fin de escapar de los óptimos locales.

La memoria a corto plazo contiene la información acerca de los movimientos tabú, dichos movimientos son aquellos que no pueden ser llevados a cabo durante un cierto número de iteraciones y la memoria a largo plazo contiene información acerca del número de veces que un movimiento puede realizarse (Boussaid, Lepagnot, y Siarry, 2013).

- ***Procedimiento de búsqueda voraz adaptativa aleatorizada (GRASP)***: Es un método de búsqueda de dos fases iterativo, que se ha vuelto muy popular en la optimización combinatoria. Cada iteración consta de dos fases, una fase de construcción y una fase de

búsqueda local. El resultado obtenido al final de estas dos fases es simplemente la mejor solución encontrada sobre todas las iteraciones.

En la fase de construcción, una función codiciosa aleatoria se utiliza para construir las soluciones iniciales; dicha técnica aleatoria proporciona una solución factible dentro de cada iteración. Esta fase puede ser descrita como un proceso por etapas, que añade un elemento a la vez a la solución parcial. La elección del siguiente elemento para añadir se determina ordenando todos los elementos en una lista de candidatos con respecto a una función codiciosa.

La estrategia es adaptativa porque los beneficios asociados con cada elemento se actualizan durante cada iteración de la fase de construcción, para reflejar los cambios provocados por la selección del elemento anterior. El componente probabilístico de un GRASP se caracteriza por la elección al azar de uno de los mejores candidatos en la lista, pero no necesariamente el mejor candidato

En la segunda fase, una búsqueda local se inicializa a partir de los puntos arrojados en la fase de construcción, y el resultado final es simplemente la mejor solución encontrada sobre todas las búsquedas (Resende y González, 2003).

- ***Búsqueda con Vecindario Variable (VNS)***: La búsqueda con vecindario variable fue introducida por Mladenović y Hansen en 1997. Es una metaheurística basada en la exploración sistemática de las diferentes estructuras de vecindario dentro de una rutina de búsqueda local. En términos generales, hay un cambio de vecindario cada vez que la búsqueda local se detiene alcanzando un óptimo local; esto evita que el algoritmo quede atrapado, dado que un óptimo local puede no permanecer como óptimo si se considera otra estructura de vecindad. VNS se ha aplicado con éxito a una variedad de problemas de

optimización combinatoria y tiene una aplicación simple cuando se compara con otras metaheurísticas dado que generalmente no considera muchos parámetros (Macedo, y otros, 2015).

5.7.4.2. Metaheurísticas basadas en población. Se presentan a continuación las metaheurísticas basadas en población.

- **Algoritmos Evolutivos (EA):** Los algoritmos evolutivos representan una gran clase de metodologías de resolución de problemas, como algoritmos genéticos (GA) (Holland, 1975). Estos algoritmos están motivados por la forma como las especies evolucionan y se adaptan a su medio ambiente, basado en el principio de selección natural de Darwin. Bajo este paradigma, una población de soluciones, a menudo codificada como una cadena de bits (números enteros, referidos como un cromosoma) evoluciona de una generación a la siguiente a través de la aplicación de operadores que imitan a los encontrados en la naturaleza: Selección de los más aptos, cruce y mutación. A través del proceso de selección, que está sesgado probabilísticamente hacia los mejores elementos de la población, las mejores soluciones se convierten en padres y se les permite generar descendencia.

El proceso de apareamiento, llamado cruce, toma dos soluciones de padres seleccionados y combina sus características más deseables para crear una o dos soluciones de descendencia. Esto se repite hasta que se crea una nueva población de soluciones descendientes. Antes de reemplazar la antigua población, cada miembro de la nueva población se somete (con una pequeña probabilidad) a posibles perturbaciones aleatorias a través del operador de mutación. A partir de una población inicial al azar o heurísticamente generada, este ciclo de renovación se repite para un número de iteraciones, y la mejor solución encontrada se devuelve al final. El rasgo distintivo del Algoritmo Genético

permanece en la explotación de una población de soluciones y la creación de nuevas soluciones, a través de la recombinación de las buenas cualidades presentes en un par de miembros (soluciones). Por último, es importante mencionar que el presente método será utilizado como algoritmo de solución para el problema estudiado, y sus características serán profundizadas en la siguiente sección (Gestal, s.f.).

- ***Optimización basada en Colonias de Hormigas (ACO)***: Es un método de búsqueda local estocástico inspirado en el rastro de feromonas que dejan y siguen algunas especies de hormigas. Esta técnica se inspira en la búsqueda de comida de las hormigas reales, el cual se describe como: inicialmente, las hormigas exploran el área cercana a su nido de forma aleatoria; tan pronto como una hormiga encuentra comida, la lleva al nido. Mientras que realiza este camino, la hormiga va depositando una sustancia química denominada feromona. Esta sustancia ayudará al resto de las hormigas a encontrar la comida. La comunicación indirecta entre las hormigas mediante el rastro de feromonas las capacita para encontrar el camino más corto entre el nido y la comida. Este comportamiento es el que intenta simular este método para resolver problemas de optimización. La técnica se basa en dos pasos principales: la construcción de una solución basada en el comportamiento de una hormiga y la actualización de los rastros de feromonas artificiales. El algoritmo no fija ninguna planificación o sincronización a priori entre las fases, lo cual permite que sean realizadas simultáneamente (Dorigo y Stützle, 2004, pág. 321).
- ***Optimización por enjambre de partículas (PSO)***: La Optimización por Enjambre de Partículas se basa en la observación de grupos de individuos que trabajan juntos para mejorar su rendimiento colectivo e individual en alguna tarea. Esta técnica fue desarrollada por Kennedy y Eberhart en 1995, inspirada en un comportamiento de enjambre propio de

la escolarización de los peces y las aves en la naturaleza. La idea inicial sobre el enjambre de partículas de Kennedy y Eberhart se orientó fundamentalmente a la producción de inteligencia computacional explotando análogos simples de interacción social, en lugar de las capacidades cognitivas individuales. Cada individuo en el enjambre de partículas se compone de tres vectores con D-dimensiones (donde D es la dimensionalidad del espacio de búsqueda), los cuales son: la posición actual \vec{x}_i , la mejor solución encontrada hasta entonces \vec{p}_{best} y la velocidad \vec{v}_i . La posición actual \vec{x}_i , puede ser considerada como un conjunto de coordenadas que describen un punto en el espacio. En cada iteración del algoritmo, la posición actual se evalúa como una solución del problema; si esa posición es mejor que cualquiera encontrada hasta el momento, entonces las coordenadas se almacenan en el segundo vector \vec{p}_{best} para la comparación en iteraciones posteriores. El objetivo, es mantener la búsqueda de las mejores posiciones y la actualización de \vec{p}_{best} . Los nuevos puntos se eligen a través de la adición de \vec{v}_i a las coordenadas \vec{x}_i . El algoritmo opera mediante el ajuste de \vec{v}_i (Poli, Kennedy, y Blackwell, 2007).

6. Descripción del algoritmo genético

Como se mencionó en la sección anterior, los Algoritmos Genéticos son métodos adaptativos, generalmente usados en problemas de búsqueda y optimización de parámetros, basados en la reproducción sexual y en el principio de supervivencia del más apto (Fogel, 2000).

Más formalmente, la definición dada por Goldberg (1989) afirma:

“Los Algoritmos Genéticos son algoritmos de búsqueda basados en la mecánica de selección natural y de la genética natural. Combinan la supervivencia del más apto entre

estructuras de secuencias con un intercambio de información ordenada, aunque aleatorizada, para constituir así un algoritmo de búsqueda que tenga algo de las genialidades de las búsquedas humanas” (p. 1).

Para alcanzar la solución a un problema se parte de un conjunto inicial de individuos, llamado población, generado de manera aleatoria. Cada uno de estos individuos representa una posible solución al problema. Estos individuos evolucionarán tomando como base los esquemas propuestos por Darwin sobre la selección natural, y se adaptarán en mayor medida tras el paso de cada generación a la solución requerida (Darwin, 2007). El procedimiento general de dicho algoritmo es ilustrado en la *Figura 3*.

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

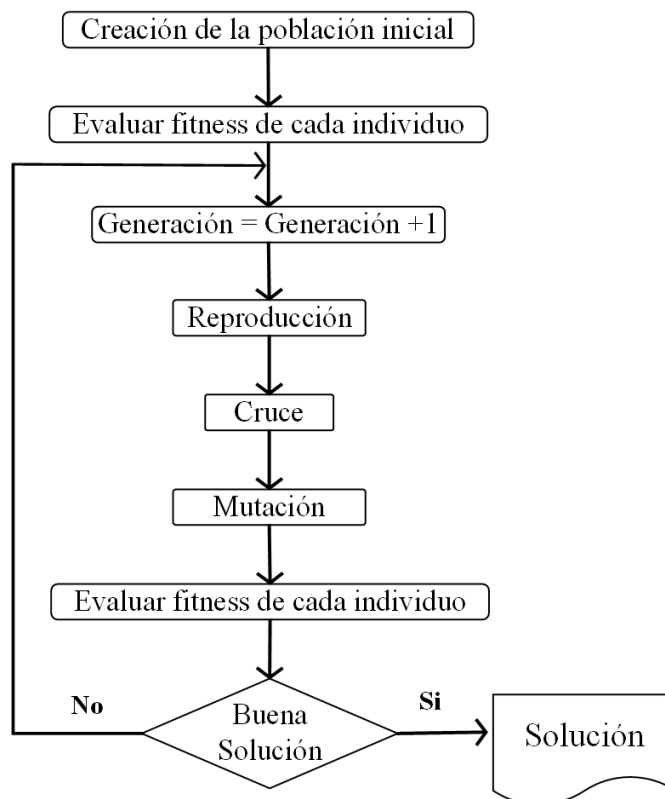


Figura 3. Diagrama de flujo de un algoritmo genético. Adaptado de Giraldo, Delgado, Riaño y Castellanos (2006).

6.1. Orígenes

Este proceso hará posible que los individuos genéticos tiendan hacia las soluciones de un problema dado, aunque las condiciones del espacio de búsqueda varíen con el transcurso del tiempo (Grefenstette, 1992). Las bases de las Estrategias de Evolución fueron apuntadas en 1973 por Rechenberg en su obra *“Evolutions strategie: Optimierung Technischer Systeme nach Prinzipien der Biologischen Evolution”* (Rechenberg, 1973). Las dos estrategias de evolución más empleadas son la $(\mu + \lambda) - ES$ y la $(\mu, \lambda) - ES$. En la primera de ellas un total de μ padres producen λ descendientes, reduciéndose nuevamente la población a μ individuos (los padres de la siguiente generación) por selección de los mejores individuos. De esta manera los padres sobreviven hasta

que son reemplazados por hijos mejores que ellos. En (μ, λ) – ES la descendencia reemplaza directamente a los padres, sin hacer ningún tipo de comprobación.

A pesar de que aún hoy en día no todos los detalles de la evolución biológica son completamente conocidos, existen algunos hechos apoyados sobre una fuerte evidencia experimental:

- La evolución es un proceso que opera, más que sobre los propios organismos, sobre los cromosomas. Estos cromosomas pueden ser considerados como herramientas orgánicas que codifican la vida o, visto al revés, una criatura es ‘creada’ decodificando la información contenida en los cromosomas.
- La selección natural es el mecanismo que relaciona los cromosomas (genotipo) con la eficiencia respecto al entorno de la entidad (fenotipo) que representan. Otorga a los individuos más adaptados al entorno un mayor número de oportunidades de reproducirse.
- Los procesos evolutivos tienen lugar durante la etapa de reproducción. Aunque existe una larga serie de mecanismos que afectan a la reproducción, los más comunes son la *mutación*, causante de que los cromosomas en la descendencia sean diferentes a los de los padres, y el *cruce* o recombinación, que combina los cromosomas de los padres para producir la descendencia.

Precisamente, sobre estos hechos se sustenta el funcionamiento de la Computación Evolutiva en general, y de los Algoritmos Genéticos en particular (Michalewicz, 1992).

6.2. Codificación de problemas

Cualquier solución potencial a un problema puede ser presentada dando valores a una serie de parámetros. El conjunto de todos los parámetros (genes en la terminología de Algoritmos Genéticos) se codifica en una cadena de valores denominada cromosoma (*ver Figura 4*).

El conjunto de los parámetros representado por un cromosoma particular recibe el nombre de *genotipo*. El genotipo contiene la información necesaria para la construcción del organismo, es decir, la solución real al problema, denominada *fenotipo*. Por ejemplo, en términos biológicos, la información genética contenida en el ADN de un individuo sería el genotipo, mientras que la expresión de ese ADN (el propio individuo) sería el fenotipo. Desde los primeros trabajos de John Holland la codificación suele hacerse mediante valores binarios. Se asigna un determinado número de bits a cada parámetro y se realiza una discretización de la variable representada por cada gen. El número de bits asignados dependerá del grado de ajuste que se desee alcanzar. Evidentemente no todos los parámetros tienen por qué estar codificados con el mismo número de bits. Cada uno de los bits pertenecientes a un gen suele recibir el nombre de *alelo*.

En la *Figura 4* se muestra un ejemplo de un individuo binario que codifica 3 parámetros.




Figura 4. Individuo genético binario. Adaptado de Gestal, Rivero, Ramón, Dorado y Pazos (2010)

Sin embargo, también existen representaciones que codifican directamente cada parámetro con un valor entero, real o en punto flotante. A pesar de que se acusa a estas representaciones de degradar el paralelismo implícito de las representaciones binarias, permiten el desarrollo de operadores genéticos más específicos al campo de aplicación del Algoritmo Genético.

6.3. Algoritmo principal

Los Algoritmos Genéticos trabajan sobre una población de individuos. Cada uno de ellos representa una posible solución al problema que se desea resolver. Todo individuo tiene asociado un ajuste de acuerdo a la bondad con respecto al problema de la solución que representa (en la naturaleza el equivalente sería una medida de la eficiencia del individuo en la lucha por los recursos).

Una generación se obtiene a partir de la anterior por medio de los operadores de reproducción.

Existen 2 tipos:

- *Cruce*: Se trata de una reproducción de tipo sexual. Se genera una descendencia a partir del mismo número de individuos (generalmente 2) de la generación anterior. Existen varios tipos que se detallarán posteriormente.
- *Copia*: Se trata de una reproducción de tipo asexual. Un determinado número de individuos pasa sin sufrir ninguna variación directamente a la siguiente generación.

El funcionamiento genérico de un Algoritmo Genético puede apreciarse en el pseudocódigo, reflejado en la *Figura 5*. Si desea optarse por una estrategia elitista, los mejores individuos de cada generación se copian siempre en la población temporal, para evitar su pérdida. A continuación, comienza a generarse la nueva población con base a la aplicación de los operadores genéticos de cruce y/o copia. Una vez generados los nuevos individuos se realiza la mutación con una probabilidad P_m . La probabilidad de mutación suele ser muy baja, por lo general entre el 0.5% y el 2%. Se sale de este proceso cuando se alcanza alguno de los criterios de parada fijados. Los más usuales suelen ser:

- Los mejores individuos de la población representan soluciones suficientemente buenas para el problema que se desea resolver.
- La población ha convergido. Un gen ha convergido cuando el 95% de la población tiene el mismo valor para él, en el caso de trabajar con codificaciones binarias, o valores dentro de un rango especificado en el caso de trabajar con otro tipo de codificaciones. Una vez que todos los genes alcanzan la convergencia se dice que la población ha convergido. Cuando esto ocurre la media de bondad de la población se aproxima a la bondad del mejor individuo.
- Se ha alcanzado el número de generaciones máximo especificado.

```

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

```

Figura 5. Pseudocódigo de un algoritmo genético. Obtenido de Gestal, Rivero, Ramón, Dorado y Pazos (2010)

6.4. Operadores genéticos

Para el paso de una generación a la siguiente se aplican una serie de operadores genéticos. Los más empleados son los *operadores de selección, cruce, copia y mutación*. En el caso de no trabajar con una población intermedia temporal también cobran relevancia los algoritmos de reemplazo. A continuación, se verán con mayor detalle.

Selección: Los algoritmos de selección serán los encargados de escoger qué individuos van a disponer de oportunidades de reproducirse y cuáles no. Puesto que se trata de imitar lo que ocurre en la naturaleza, se ha de otorgar un mayor número de oportunidades de reproducción a los individuos más aptos. Por lo tanto, la selección de un individuo estará relacionada con su valor de ajuste. No se debe, sin embargo, eliminar por completo las opciones de reproducción de los individuos menos aptos, pues en pocas generaciones la población se volvería homogénea.

En cuanto a algoritmos de selección se refiere, estos pueden ser divididos en dos grandes grupos: *probabilísticos* y *determinísticos*. Ambos tipos de algoritmos basan su funcionamiento en el principio indicado anteriormente (permitir escoger una mayor cantidad de veces a los más aptos). Sin embargo, como su nombre indica, el primer tipo adjudica estas posibilidades con un importante componente basado en el azar. Es en este grupo donde se encuentran los algoritmos de *selección por ruleta* o *por torneo* que, dado su importancia por ser los más frecuentemente utilizados, se describen con detalle en esta sección. El segundo grupo engloba una serie de algoritmos que, dado el ajuste conocido de cada individuo, permite asignar a cada uno el número de veces que será escogido para reproducirse. Esto puede evitar problemas de predominancia de ciertos individuos y cada uno de estos algoritmos presentan variaciones respecto al número de veces que se tomarán los mejores y peores y, de esta forma, se impondrá una presión en la búsqueda en el espacio de estados en la zona donde se encuentra el mejor individuo (en el caso de que se

seleccionen más veces los mejores), o bien que se tienda a repartir la búsqueda por el espacio de estados, pero sin dejar de tender a buscar en la mejor zona.

- **Selección por ruleta:** Propuesto por DeJong, es posiblemente el método más utilizado desde los orígenes de los Algoritmos Genéticos (Blickle y Thiele, 1995). A cada uno de los individuos de la población se le asigna una parte de la ruleta, la cual es proporcional a su ajuste, de tal forma que la suma de todos los porcentajes sea la unidad. Los mejores individuos recibirán una porción de la ruleta mayor que la recibida por los peores. Generalmente, la población está ordenada con base al ajuste (fitness), por lo que las porciones más grandes se encuentran al inicio de la ruleta. Para seleccionar un individuo basta con generar un número aleatorio (NA) del intervalo $[0,1]$ y devolver el individuo situado en esa posición de la ruleta. Esta posición se suele obtener recorriendo los individuos de la población y acumulando sus proporciones de ruleta hasta que la suma exceda el valor obtenido. Es un método muy sencillo pero ineficiente a medida que aumenta el tamaño de la población. Presenta además el inconveniente de que el peor individuo puede ser seleccionado más de una vez.
- **Selección por torneo:** La idea principal de este método de selección consiste en escoger a los individuos genéticos con base a comparaciones directas entre sus genotipos. Existen dos versiones de selección mediante torneo, el torneo determinístico y el torneo probabilístico.

En la versión *determinística* se selecciona al azar un número p de individuos (generalmente se escoge $p=2$). De entre los individuos seleccionados se selecciona el más apto (mejor fitness) para pasarlo a la siguiente generación.

La *versión probabilística* únicamente se diferencia en el paso de selección del ganador del torneo. En vez de escoger siempre el mejor se genera un número aleatorio del intervalo $[0,1]$, si es mayor que un parámetro R_m (fijado para todo el proceso evolutivo) se escoge el individuo más apto y en caso contrario el menos apto. Generalmente R_m toma valores en el rango $0.5 < R_m \leq 1$.

Cruce: Una vez seleccionados los individuos, éstos son recombinados para producir la descendencia que se insertará en la siguiente generación. Tal y como se ha indicado anteriormente, el cruce es una estrategia de reproducción sexual. Su importancia para la transición entre generaciones es elevada puesto que las tasas de cruce con las que se suele trabajar rondan el 90%. Los diferentes métodos de cruce podrán operar de dos formas diferentes. Si se opta por una estrategia destructiva los descendientes se insertarán en la población temporal, aunque sus padres tengan mejor ajuste (trabajando con una única población esta comparación se realizará con los individuos a reemplazar). Por el contrario, utilizando una estrategia no destructiva la descendencia pasará a la siguiente generación únicamente si supera la bondad del ajuste (fitness) de los padres (o de los individuos a reemplazar).

La idea principal del cruce se basa en que, si se toman dos individuos correctamente adaptados al medio y se obtiene una descendencia que comparta genes de ambos, existe la posibilidad de que los genes heredados sean precisamente los causantes de la bondad de los padres. Al compartir las características buenas de dos individuos, la descendencia, o al menos parte de ella, debería tener una bondad mayor que cada uno de los padres por separado. Si el cruce no agrupa las mejores características en uno de los hijos y la descendencia tiene un peor ajuste que los padres no significa que se esté dando un paso atrás. Optando por una estrategia de cruce no destructiva, se garantiza que pasen a la siguiente generación los mejores individuos. Si aún con un ajuste peor, se opta por

insertar a la descendencia, y puesto que los genes de los padres continuarán en la población (aunque dispersos y posiblemente levemente modificados por la mutación), en posteriores cruces se podrán volver a obtener estos padres, recuperando así la bondad previamente perdida.

Existen multitud de algoritmos de cruce. Sin embargo, los más empleados son:

- **Cruce de 1 punto:** Es la más sencilla de las técnicas de cruce. Una vez seleccionados dos individuos se cortan sus cromosomas por un punto seleccionado aleatoriamente para generar dos segmentos diferenciados en cada uno de ellos: la cabeza y la cola. Se intercambian las colas entre los dos individuos para generar los nuevos descendientes. De esta manera ambos descendientes heredan información genética de los padres. En la *Figura 6* se puede ver con claridad el proceso descrito anteriormente.



Figura 6. Representación cruce de 1 punto.

- **Cruce de 2 puntos:** Se trata de una generalización del cruce de 1 punto. En lugar de cortar por un único punto los cromosomas de los padres, como en el caso anterior, se realizan dos cortes. Deberá tenerse en cuenta que ninguno de estos puntos de corte coincida con el extremo de los cromosomas para garantizar que se originen tres segmentos. Para generar la descendencia se escoge el segmento central de uno de los padres y los segmentos laterales del otro padre. Generalizando, se pueden añadir más puntos de cruce dando lugar a algoritmos de cruce multipunto. En la *Figura 7* se muestra un ejemplo de cruce por dos puntos.




Figura 7. Representación cruce de 2 puntos.

- Cruce uniforme:** El cruce uniforme es una técnica completamente diferente de las vistas hasta el momento. Cada gen de la descendencia tiene las mismas probabilidades de pertenecer a uno u otro padre. Aunque se puede implementar de muy diversas formas, 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. Por el contrario, si hay un 2 el gen se copia del segundo padre. Para producir el segundo descendiente se intercambian los papeles de los padres, o bien se intercambia la interpretación de los unos y los dos de la máscara de cruce. Tal y como se puede apreciar en la *Figura 8*, la descendencia contiene una mezcla de genes de cada uno de los padres.




Figura 8. Representación cruce uniforme.

Mutación: La mutación de un individuo provoca que alguno de sus genes, generalmente uno sólo, varíe su valor de forma aleatoria. Aunque se pueden seleccionar los individuos directamente de la población actual y mutarlos antes de introducirlos en la nueva población, la mutación se suele utilizar de manera conjunta con el operador de cruce. Primeramente, se seleccionan dos individuos de la población para realizar el cruce. Si el cruce tiene éxito entonces uno de los descendientes, o ambos, se muta con cierta probabilidad P_m . Se imita de esta manera el comportamiento que se da

en la naturaleza, pues cuando se genera la descendencia siempre se produce algún tipo de error, por lo general sin mayor trascendencia, en el paso de la carga genética de padres a hijos.

La probabilidad de mutación es muy baja, generalmente menor al 2.5%. Esto se debe sobre todo a que los individuos suelen tener un ajuste menor después de mutados. Sin embargo, se realizan mutaciones para garantizar que ningún punto del espacio de búsqueda tenga una probabilidad nula de ser examinado. Tal y como se ha comentado, la mutación más usual es el reemplazo aleatorio. Este consiste en variar aleatoriamente un gen de un cromosoma. Si se trabaja con codificaciones binarias, consistirá simplemente en negar un bit.

También es posible realizar la mutación intercambiando los valores de dos alelos del cromosoma. Con otro tipo de codificaciones no binarias existen otras opciones:

- Incrementar o decrementar a un gen una pequeña cantidad generada aleatoriamente.
- Multiplicar un gen por un valor aleatorio próximo a 1.

6.5. Evaluación

Para el correcto funcionamiento de un Algoritmo Genético se debe de poseer un método que indique si los individuos de la población representan o no buenas soluciones al problema planteado. Por lo tanto, para cada tipo de problema que se desee resolver deberá derivarse un nuevo método, al igual que ocurrirá con la propia codificación de los individuos.

De esto se encarga la función de evaluación o fitness, que establece una medida numérica de la bondad de una solución, la cual recibe el nombre de ajuste. En la naturaleza el ajuste (o adecuación) de un individuo puede considerarse como la probabilidad de que ese individuo sobreviva hasta la edad de reproducción y se reproduzca. Esta probabilidad deberá estar ponderada con el número de individuos de la población genética. En el mundo de los Algoritmos Genéticos se empleará esta

medición para controlar la aplicación de los operadores genéticos, es decir, permitirá controlar el número de selecciones, cruces, copias y mutaciones llevadas a cabo (Gestal, Rivero, Rabuñal, Dorado y Pazos, 2010).

7. Modelo para el 2E-LRP

7.1. Descripción del modelo

El modelo propuesto en el presente trabajo aborda el problema conjunto de localización y ruteo de vehículos para dos escalones, teniendo en cuenta limitaciones de capacidad en los depósitos centrales (depósitos primarios y centros regionales) y en la flota de vehículos. Además, el problema es formulado como un modelo de programación lineal entera mixta (PLEM), con el objetivo de minimizar los costos en los que se incurren durante el diseño de la red logística, es decir, los costos asociados a la apertura de depósitos primarios y centros regionales, los costos por utilización de vehículos y los costos generados por el ruteo, teniendo en cuenta que dichos costos están presentes en el primer y segundo escalón.

7.2. Suposiciones de estudio

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

- Se conoce la demanda de cada cliente y se consideran limitaciones deterministas.
- La capacidad de los vehículos es limitada y heterogénea en el mismo escalón.
- Un vehículo puede realizar más de una ruta en la instalación (depósito primario o centro regional) a la que fue asignada.

- La carga no puede gestionarse mediante el envío directo desde los depósitos primarios a los clientes, sino que debe ser entregada por los centros regionales. En particular: las primeras rutas escalonadas comienzan desde los depósitos primarios, sirven a uno o más centros regionales y terminan en el mismo centro regional; las rutas del segundo escalón comienzan desde un centro regional, prestan su servicio a uno o más clientes y termina en el mismo centro regional.
- Para el primer escalón (relación depósitos primarios y centros regionales) no se tiene en cuenta las conexiones (arcos) entre depósitos y para el segundo escalón (relación centros regionales y clientes) no se consideran conexiones entre centros regionales.
- Las capacidades de los depósitos primarios y los centros regionales son limitadas. La capacidad de los depósitos primarios es más alta que la capacidad de los centros regionales, y a su vez, la capacidad de los centros regionales es más alta que la demanda de los clientes.
- Cada instalación utiliza un solo vehículo.
- Las instalaciones que pertenecen al mismo escalón tienen diferentes capacidades.
- Cada centro regional debe ser atendido por un solo depósito primario y por un solo vehículo, asimismo, cada cliente debe ser atendido por un único centro regional y por un solo vehículo.
- La capacidad de cada vehículo para el primer escalón es más alta que la capacidad de cada vehículo para el segundo escalón, y la capacidad de cada vehículo para el segundo escalón es más alta que la demanda del cliente.
- El flujo no presenta pérdidas durante su tránsito por las diferentes instalaciones, pues no existe inventario.

7.3. Formulación matemática

De acuerdo con las especificaciones propuestas por *Cuda et al. (2015)*, el problema en estudio puede ser representado como un grafo completo $G = (N, A)$, en el que N representa el conjunto de nodos y A el conjunto de aristas dirigidas, más aun, $N = D \cup R \cup C$, donde D hace referencia al conjunto de depósitos primarios, R está asociado con el conjunto de centros regionales y C representa el conjunto de clientes, por otro lado, $A = E_1 \cup E_2$, en el que E_1 representa el conjunto de aristas dirigidas que conectan a un depósito primario $d \in D$ con un centro regional $r \in R$ (primer escalón), excluyendo cualquier conexión entre depósitos primarios, es decir, $E_1 = \{(i, j): i, j \in D \cup R \wedge (i, j) \notin DUD\}$, y de igual forma, E_2 es el conjunto de aristas dirigidas que conectan a un centro regional $r \in R$ con un cliente $c \in C$ (segundo escalón), excluyendo las conexiones posibles entre centros regionales, es decir, $E_2 = \{(i, j): i, j \in R \cup C \wedge (i, j) \notin RUR\}$.

Tomando como base la formulación presentada por *Dai et al. (2018)* en su investigación titulada 'Un método de dos fases para el problema de localización-ruteo multiescalón en la cadena de suministro' y teniendo en cuenta las especificaciones del investigador, el modelo matemático es desarrollado como se presenta a continuación:

7.3.1. Conjuntos

D = Conjunto de posibles depósitos primarios.

R = Conjunto de posibles centros regionales.

C = Conjunto de clientes.

V = Conjunto de vehículos para las rutas de primer nivel.

W = Conjunto de vehículos para las rutas de segundo nivel.

7.3.2. Índices

d = Índice para los posibles depósitos primarios.

r = Índice para los posibles centros regionales.

c = Índice para los clientes.

v = Índice para los vehículos de primer nivel.

w = Índice para los vehículos de segundo nivel.

7.3.3. Parámetros

K_i = Capacidad de la instalación i , $i \in D \cup R$.

H_i = Capacidad del vehículo i , $i \in W \cup V$.

F_i = Costo de abrir la instalación i , $i \in D \cup R$.

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

D_c = Demanda del cliente c , $c \in C$.

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

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

7.3.4. Variables de decisión

y_i = 1 si la instalación es abierta en el nodo i , con $i \in D \cup R$ y 0 de lo contrario.

m_{ij}^v = 1 si el vehículo $v \in V$ viaja desde el nodo i hasta el nodo j en la ruta de primer nivel, con $i \in D \cup R \wedge j \in D \cup R$ y 0 de lo contrario.

n_{ij}^w = 1 si el vehículo $w \in W$ viaja desde el nodo i hasta el nodo j en la ruta de segundo nivel, con $i \in R \cup C \wedge j \in R \cup C$ y 0 de lo contrario.

$L_{dr} = 1$ si el centro regional $r \in R$ es asignado al depósito primario $d \in D$ y 0 en caso contrario.

$P_{rc} = 1$ si el cliente $c \in C$ es asignado al centro regional $r \in R$ y 0 en caso contrario.

$q_i = 1$ si el vehículo i es usado en una ruta, con $i \in W \cup V$.

F_{dr}^v = Flujo desde el depósito primario $d \in D$ al centro regional $r \in R$ en el vehículo $v \in V$.

Z = Costo total.

7.3.5. Función objetivo

$$\begin{aligned} \text{Minimizar } Z = & \sum_{r \in R} F_r * y_r + \sum_{d \in D} F_d * y_d + \sum_{w \in W} G_w * q_w + \sum_{v \in V} G_v * q_v + \sum_{w \in W} \sum_{i \in RUC} \sum_{j \in RUC} T_{ij} * n_{ij}^w + \\ & + \sum_{v \in V} \sum_{i \in DUR} \sum_{j \in DUR} S_{ij} * m_{ij}^v \quad (1) \end{aligned}$$

7.3.6. Restricciones. Sujeto a:

$$\sum_{r \in R} P_{rc} = 1 \quad \forall c \in C \quad (2)$$

$$\sum_{c \in C} D_c * P_{rc} \leq K_r * y_r \quad \forall r \in R \quad (3)$$

$$\sum_{w \in W} \sum_{i \in RUC} n_{ic}^w = 1 \quad \forall c \in C, i \neq c \quad (4)$$

$$\sum_{i \in RUC} n_{ij}^w - \sum_{i \in RUC} n_{ji}^w = 0 \quad \forall w \in W, \forall j \in RUC, i \neq j \quad (5)$$

$$\sum_{i \in S'} \sum_{j \in S'} n_{ij}^w \leq |S'| - 1 \quad \forall w \in W, S' \subseteq S, |S'| \geq 2, i \neq j \quad (6)$$

$$\sum_{i \in R} \sum_{j \in C} n_{ij}^w \leq 1 \quad \forall w \in W \quad (7)$$

$$\sum_{w \in W} \sum_{j \in C} n_{rj}^w \leq 1 \quad \forall r \in R \quad (8)$$

$$\sum_{j \in RUC} n_{rj}^w + \sum_{j \in RUC} n_{cj}^w - P_{rc} \leq 1 \quad \forall r \in R, \forall c \in C, \forall w \in W, r \neq j, c \neq j \quad (9)$$

$$\sum_{c \in C} \sum_{i \in RUC} D_c * n_{ic}^w \leq H_w * q_w \quad \forall w \in W, i \neq c \quad (10)$$

$$\sum_{d \in D} L_{dr} = 1 \quad \forall r \in R \quad (11)$$

$$K_d * y_d \geq \sum_r K_r * L_{dr} \quad \forall d \in D \quad (12)$$

$$\sum_{i \in DUR} m_{ij}^v - \sum_{i \in DUR} m_{ji}^v = 0 \quad \forall v \in V, \forall j \in DUR, i \neq j \quad (13)$$

$$\sum_{i \in R'} \sum_{j \in R'} m_{ij}^v \leq |R'| - 1 \quad \forall v \in V, R' \subseteq R, |R'| \geq 2, i \neq j \quad (14)$$

$$\sum_{i \in D} \sum_{j \in R} m_{ij}^v \leq 1 \quad \forall v \in V \quad (15)$$

$$\sum_{v \in V} \sum_{j \in R} m_{dj}^v \leq 1 \quad \forall d \in D \quad (16)$$

$$\sum_{j \in DUR} m_{dj}^v + \sum_{j \in DUR} m_{rj}^v - L_{dr} \leq 1 \quad \forall d \in D, \forall r \in R, \forall v \in V, d \neq j, r \neq j \quad (17)$$

$$\sum_{v \in V} \sum_{d \in D} F_{dr}^v = \sum_{c \in C} D_c * P_{rc} \quad \forall r \in R \quad (18)$$

$$H_v * \sum_{j \in DUR} m_{dj}^v - F_{dr}^v \geq 0 \quad \forall v \in V, \forall d \in D, \forall r \in R, d \neq j \quad (19)$$

$$H_v * \sum_{j \in DUR} m_{rj}^v - F_{dr}^v \geq 0 \quad \forall v \in V, \forall d \in D, \forall r \in R, r \neq j \quad (20)$$

$$\sum_{d \in D} \sum_{r \in R} F_{dr}^v \leq H_v * q_v \quad \forall v \in V \quad (21)$$

$$n_{ij}^w \in \{0,1\}, i \in RUC, j \in RUC \wedge w \in W \quad (22)$$

$$m_{ij}^v \in \{0,1\}, i \in DUR, j \in DUR \wedge v \in V \quad (23)$$

$$y_r \in \{0,1\}, r \in R \quad (24)$$

$$y_d \in \{0,1\}, d \in D \quad (25)$$

$$P_{rc} \in \{0,1\}, r \in R \wedge c \in C \quad (26)$$

$$L_{dr} \in \{0,1\}, d \in D \wedge r \in R \quad (27)$$

$$q_w \in \{0,1\}, w \in W \quad (28)$$

$$q_v \in \{0,1\}, v \in V \quad (29)$$

$$F_{dr}^v \in \mathbb{Z}^+, v \in V, d \in D \wedge r \in R \quad (30)$$

7.3.7. Interpretación del modelo matemático. La ecuación (1) está asociada con la función objetivo, la cual tiene como finalidad minimizar los costos relacionados con la apertura de centros regionales (primer término) y depósitos primarios (segundo término), costos por utilizar los vehículos de segundo y primer nivel (tercer y cuarto término) y los costos generados por el ruteo en el segundo y primer escalón (quinto y sexto término). Por otro lado, la ecuación (2) garantiza la asignación de cada cliente a un único centro regional; la ecuación (3) asegura que la demanda de los clientes asignados a un centro regional, no excedan la capacidad de dicha instalación; la ecuación (4) impone que cada cliente debe ser servido por exactamente un vehículo

de segundo nivel; la ecuación (5) permite que cada vehículo regrese al mismo centro regional del cual partió. Además, la ecuación (6) evita la formación de sub-tours o rutas ilegales en el segundo escalón; la ecuación (7) asegura la asignación única de un vehículo a un centro regional específico, si este es abierto; la ecuación (8) está asociada con la utilización de un solo vehículo para cada centro regional habilitado; también, la ecuación (9) asegura que el centro regional r sirve al cliente c , si allí existe un vehículo w abandonando r y arribando a c ; la ecuación (10) permite que la demanda satisfecha por un vehículo no exceda su capacidad, si este es usado. Por otro lado, la ecuación (11) impone la asignación de cada centro regional habilitado un solo depósito primario; la ecuación (12) hace referencia a la restricción de capacidad en los depósitos primarios, pues como lo indica dicha restricción, la capacidad de un depósito primario habilitado debe ser mayor o igual a la capacidad del centro regional que le fue asignado; la ecuación (13) garantiza el retorno al mismo depósito primario del vehículo v que le fue asignado. La ecuación (14) evita la formación de sub-tours o rutas ilegales en el primer escalón; la ecuación (15) permite que un vehículo sea asignado como máximo a un depósito primario, si este es usado; la ecuación (16) restringe la utilización de un solo vehículo por cada depósito primario habilitado; la ecuación (17) asegura que el depósito primario d sirve al centro regional r , si allí existe un vehículo v abandonando d y arribando a r ; la ecuación (18) está asociada con la conservación del flujo en el centro regional r , teniendo en cuenta que la cantidad ingresada en el centro regional debe ser igual a la demanda total de los clientes asignados. Las ecuaciones (19) y (20) garantizan que la cantidad de flujo en un vehículo v , desde un depósito primario d a un centro regional r es positiva, si y solo si, tanto el depósito primario como el centro regional son visitados por el mismo vehículo v y la ecuación (21) está relacionada con la limitación de capacidad para un vehículo v (el flujo transportado en un vehículo v desde un depósito primario d a un centro regional r , debe ser menor o igual a la

capacidad de dicho vehículo). Finalmente, las ecuaciones (22)-(30) establecen la naturaleza de las variables de decisión consideradas en el modelo.

7.3.8. Representación del modelo matemático. Con el objetivo de lograr una mejor interpretación del modelo matemático formulado anteriormente, se presenta en la *Figura 9* una representación esquemática, en la cual es posible resumir y apreciar la esencia del problema en estudio.

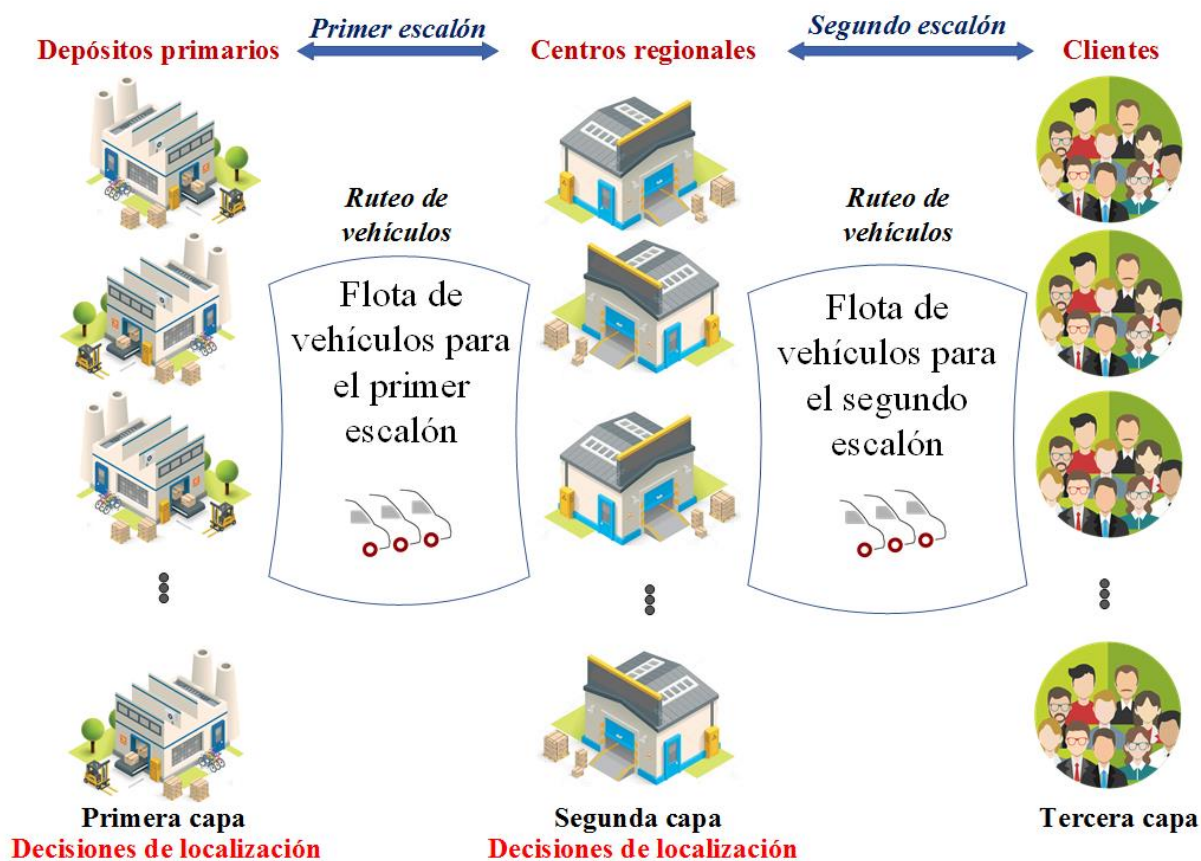


Figura 9. Representación del modelo matemático para el 2E-LRP. Adaptado de Dai, Aqlan, Gao y Zhou (2018).

Al observar la *Figura 9*, se identifican dos tipos de decisiones muy importantes que conforman el problema, la primera relacionada con la localización de instalaciones (decisión de tipo estratégica), en otras palabras, se debe hallar la cantidad y la ubicación de centros regionales

(segundo escalón) y depósitos primarios (primer escalón); mientras que la segunda, está asociada con el ruteo (decisión de tipo operacional), es decir, cómo utilizar la flota de vehículos en cada escalón, para satisfacer la demanda de los clientes (regiones afectadas) y la carga vinculada a los centros regionales; cumpliendo con el objetivo de minimizar el costo total (apertura de instalaciones, uso de vehículos y recorridos) requerido para el diseño de la red logística.

7.4. Análisis de complejidad

Como se mencionó en el marco teórico, el 2E-LRP pertenece al conjunto de problemas combinatorios, debido a esto, resulta interesante comprender la complejidad que demanda este tipo de problema, pues su dimensión (número de variables y restricciones) incrementa considerablemente ante pequeñas variaciones en los parámetros o datos de entrada más importantes; por ejemplo, el número de centros regionales, depósitos primarios, clientes o la cantidad de vehículos disponibles en el escalón, lo cual afecta en última instancia el tiempo computacional requerido para solucionarlo. Dado lo anterior, se presenta a continuación un análisis relacionado con la expansión y comportamiento del modelo matemático propuesto, al variar características claves; para lograr esto, se inicia con un estudio del LRP y luego se ajusta a la consideración de dos escalones o niveles.

7.4.1. Problema de localización y ruteo de vehículos. De acuerdo con el modelo desarrollado, el LRP está representado por las ecuaciones o restricciones (2)-(10) junto con los términos 1, 3 y 4 de la función objetivo, por lo tanto, el procedimiento para calcular el tamaño del problema se describe de la siguiente manera:

Restricciones

$$\# \text{ Restricciones en (2)} = |C|$$

$$\# \text{ Restricciones en (3)} = |R|$$

$$\# \text{ Restricciones en (4)} = |C|$$

$$\# \text{ Restricciones en (5)} = |W| * (|R| + |C|)$$

Restricciones en (6) = No se tiene en cuenta inicialmente pues su cardinalidad es igual a $2^{|S|} - 1$, donde S corresponde al conjunto de subtours, por lo tanto agregarla implicaría una gran rigurosidad en el modelo matemático.

$$\# \text{ Restricciones en (7)} = |W|$$

$$\# \text{ Restricciones en (8)} = |R|$$

$$\# \text{ Restricciones en (9)} = |R| * |C| * |W|$$

$$\# \text{ Restricciones en (10)} = |W|$$

$$\# \text{ Total de restricciones} \approx 2 * (|C| + |R| + |W|) + |W| * [|R| + |C| * (|W| + 1)]$$

Variables

$$\# \text{ Variables en (2)} = |R| * |C|$$

$$\# \text{ Variables en (3)} = |R| * |C| + |R|$$

$$\# \text{ Variables en (4)} = (|R| + |C| - 1) * |C| * |W|$$

$$\# \text{ Variables en (5)} = 2 * [(|R| * |C| * |W|) + |C| * |W| * (|R| + |C| - 1)]$$

Variables en (6) = Por el argumento presentando anteriormente no se calcula

$$\# \text{ Variables en (7)} = |R| * |C| * |W|$$

$$\# \text{ Variables en (8)} = |R| * |C| * |W|$$

$$\# \text{ Variables en (9)} = 3 * [|R| * |C| * |W| + |C| * |W| * (|R| + |C| - 1) + |R| * |C|]$$

$$\# \text{ Variables en (10)} = |R| * |C| * |W| + |C| * |W| * (|C| - 1) + |W|$$

$$\# \text{ Total de variables} \approx |R| * |C| * (14 * |W| + 5) + 7 * |C| * |W| * (|C| - 1) + |R| + |W|$$

Tomando como punto de partida los resultados obtenidos anteriormente, se realiza el siguiente análisis de sensibilidad:

7.4.1.1. Escenario 1. Asumiendo 3 posibles centros regionales (R), 3 vehículos (W) a utilizar y un conjunto compuesto de 3 clientes(C), tendremos la siguiente dimensión:

$$|R| = 3, |C| = 3 \text{ y } |W| = 3$$

$$\# \text{ Total de restricciones} \approx 2 * (3 + 3 + 3) + 3 * [3 + 3 * (3 + 1)] \approx 63$$

$$\# \text{ Total de variables de decisión} \approx 3 * 3 * (14 * 3 + 5) + 7 * 3 * 3 * (3 - 1) + 3 + 3$$

$$\# \text{ Total de variables de decisión} \approx 555$$

7.4.1.2. Escenario 2. Ahora si aumentamos bajo una relación 1-1 el número de centros regionales (R), número de vehículos disponibles (W) y el número de clientes propuestos en la configuración del escenario 1, la dimensión del problema sería la siguiente:

$$|R| = 4, |C| = 4 \text{ y } |W| = 4$$

$$\# \text{ Total de restricciones} \approx 2 * (4 + 4 + 4) + 4 * [4 + 4 * (4 + 1)] \approx 144$$

$$\# \text{ Total de variables} \approx 4 * 4 * (14 * 4 + 5) + 7 * 4 * 4 * (4 - 1) + 4 + 4 \approx 1320$$

Observación: Como se puede evidenciar en los escenarios propuestos, que representan instancias muy pequeñas o insignificantes del problema en estudio, el número de restricciones cambia drásticamente, ante pequeños incrementos en la cardinalidad de los conjuntos R, W y C (parámetros de entrada más importantes), pues al aumentarla en una unidad, el número de restricciones pasaron de 63 a 144, lo cual representa un aumento equivalente al 128.57% ; de igual forma sucede con el total de variables de decisión, las cuales pasaron de 555 a 1320, cuando se aumentó la cardinalidad de los conjunto en una unidad, representando así un cambio porcentual del 137.84%. Con los resultados obtenidos anteriormente, es posible inferir una gran elasticidad en la dimensión del LRP, lo que incrementa a su vez la complejidad para poder solucionarlo, es decir, considerar escenarios más grandes hará que el tiempo computacional se convierta en un factor crítico.

7.4.1.3. Escenarios 3. Si consideramos ahora una instancia un poco más ajustada a la realidad, por ejemplo, 30 centros regionales (R), 40 vehículos (W) disponibles y 2000 clientes, el problema tomaría la siguiente dimensión:

$$|R| = 30, |C| = 2000 \text{ y } |W| = 40$$

$$\# \text{ Total de restricciones} \approx 2 * (2000 + 30 + 40) + 40 * [30 + 2000 * (40 + 1)]$$

$$\# \text{ Total de restricciones} \approx 3'285.340$$

$$\# \text{ Total de variables de decisión} \approx 30 * 2000 * (14 * 40 + 5) + 7 * 2000 * 40 *$$

$$* (2000 - 1) + 40 + 30$$

$$\# \text{ Total de variables de decisión} \approx 1.153'.340.070$$

Observación: Los resultados obtenidos en el escenario 3, permiten afirmar con mayor seguridad la gran complejidad presente en el problema del LRP, justificados en el número de restricciones y variables de decisión que se deben considerar cuando se plantea una instancia aproximada a la realidad, como ejemplo se tiene el caso desarrollado anteriormente, donde la configuración del problema se torna mucho más robusta, dado que está compuesta por millones de restricciones y variables, sin embargo, se debe hacer énfasis, en la existencia de muchas otras instancias que demandan una mayor complejidad y requieren por lo tanto mayor esfuerzo computacional.

7.4.2. Problema de localización y ruteo de vehículos para dos escalones. El modelo matemático propuesto representa a cabalidad el 2E-LRP, por lo tanto, el procedimiento para calcular el tamaño del problema estará compuesto por dos partes, debido a que son dos escalones. La primera parte hace referencia al número de restricciones y variables obtenidas con la relación centros regionales (R)-clientes (C) (calculada anteriormente), y la segunda parte tiene que ver con la relación depósitos primarios (D)-centros regionales (R); una vez obtenida estas relaciones, se sumarán con la finalidad de totalizar los componentes que describen la complejidad del problema en estudio.

7.4.2.1. Relación centros regionales-clientes

$$\# \text{ Restricciones } R - C \approx 2 * (|C| + |R| + |W|) + |W| * [|R| + |C| * (|W| + 1)]$$

$$\# \text{ Variables } R - C \approx |R| * |C| * (14 * |W| + 5) + 7 * |C| * |W| * (|C| - 1) + |W| + |R|$$

7.4.2.2. Relación depósitos primarios-centros regionales

Restricciones

$$\# \text{ Restricciones en (11)} = |R|$$

$$\# \text{ Restricciones en (12)} = |D|$$

Restricciones en (13) = $|V| * (|D| + |R|)$

Restricciones en (14) = *No se tiene en cuenta inicialmente debido a la rigurosidad*

que agrega al modelo matemático los subtours o rutas ilegales.

Restricciones en (15) = $|V|$

Restricciones en (16) = $|D|$

Restricciones en (17) = $|D| * |R| * |V|$

Restricciones en (18) = $|R|$

Restricciones en (19) = $|D| * |R| * |V|$

Restricciones en (20) = $|D| * |R| * |V|$

Restricciones en (21) = $|V|$

Restricciones $D - R = 2 * (|D| + |R| + |V|) + 3 * |D| * |R| * |V| + |V| * (|D| + |R|)$

Variables

Variables en (11) = $|D| * |R|$

Variables en (12) = $|D| + |D| * |R|$

Variables en (13) = $2 * [(|D| * |R| * |V|) + |R| * |V| * (|D| + |R| - 1)]$

Variables en (14) = *Se desprecia justificándose en el argumento anterior (los subtours o rutas ilegales agregan mayor rigurosidad al modelo matemático)*

Variables en (15) = $|V| * |D| * |R|$

Variables en (16) = $|V| * |D| * |R|$

$$\# \text{ Variables en (17)} = 3 * [|D| * |R| * |V| + |R| * |V| * (|D| + |R| - 1) + |D| * |R|]$$

$$\# \text{ Variables en (18)} = |V| * |D| * |R| + |R| * |C|$$

$$\# \text{ Variables en (19)} = 3 * [|V| * |D| * |R| + |V| * |D| * |R|]$$

$$\# \text{ Variables en (20)} = 3 * [|V| * |R| * (|D| + |R| - 1) + |V| * |D| * |R|]$$

$$\# \text{ Variables en (21)} = |V| * |D| * |R| + |V|$$

$$\# \text{ Variables } D - R = |D| * |R| * (26 * |V| + 5) + 8 * |V| * |R| * (|R| - 1) + |R| * |C| + |D| + |V|$$

$$\# \text{ Total de restricciones } 2E - LRP \approx 2 * (|C| + |R| + |W|) + |W| * [|R| + |C| * (|W| + 1)] + 2 * (|D| + |R| + |V|) + 3 * |D| * |R| * |V| + |V| * (|D| + |R|)$$

$$\# \text{ Total de variables de decisión } 2E - LRP \approx |R| * |C| * (14 * |W| + 5) + 7 * |C| * |W| * (|C| - 1) + |W| + |R| + |D| * |R| * (26 * |V| + 5) + 8 * |V| * |R| * (|R| - 1) + |R| * |C| + |D| + |V|$$

Con las expresiones deducidas anteriormente, se procede a realizar un análisis de sensibilidad para el problema objeto de la presente investigación, esto con la finalidad de reiterar la gran complejidad presente en el tema estudiado y el porqué es necesario acudir a método aproximados, específicamente metaheurísticas como el algoritmo genético, con el objetivo de obtener buenas soluciones factibles en un tiempo computacional razonable, dado que los método exactos (Simplex o Branch and cut) no son una buena opción, pues crean un gran brecha entre las soluciones óptimas (lo ideal) y el rendimiento de la máquina, debido a que los tiempos para solucionar dichos problemas crecen abruptamente y obtener soluciones se convierte en algo muy costoso, teniendo

en cuenta que estas pueden tardar días, semanas o tal vez meses, lo cual no es tolerable si se requiere tomar una decisión en un lapso de tiempo reducido.

7.4.2.3. Escenario 1. Tomando una configuración de 3 depósitos primarios (D), 3 centros regionales (R), 3 clientes (C) y una flota de vehículos para el primer escalón (V) y segundo escalón (W) igual a 3, la dimensión del problema sería la siguiente:

$$|D| = 3, |R| = 3, |C| = 3, |V| = 3 \text{ y } |W| = 3$$

$$\begin{aligned} \# \text{ Total de restricciones } 2E - LRP &\approx 2 * (3 + 3 + 3) + 3 * [3 + 3 * (3 + 1)] + 2 * (3 + 3 \\ &+ 3) + 3 * 3 * 3 * 3 + 3 * (3 + 3) \approx 216 \end{aligned}$$

$$\begin{aligned} \# \text{ Total de variables de decisión } 2E - LRP &\approx 3 * 3 * (14 * 3 + 5) + 7 * 3 * 3 * (3 - 1) + 3 \\ &+ 3 + 3 * 3 * (26 * 3 + 5) + 8 * 3 * 3 * (3 - 1) + 3 * 3 + 3 + 3 \approx 1461 \end{aligned}$$

7.4.2.4. Escenario 2. Si incrementamos el número de depósitos primarios, centros regionales, clientes y las flotas de vehículos bajo una relación 1-1, la configuración del problema sería:

$$|D| = 4, |R| = 4, |C| = 4, |V| = 4 \text{ y } |W| = 4$$

$$\begin{aligned} \# \text{ Total de restricciones } 2E - LRP &\approx 2 * (4 + 4 + 4) + 4 * [4 + 4 * (4 + 1)] + 2 * (4 + 4 \\ &+ 4) + 3 * 4 * 4 * 4 + 4 * (4 + 4) \approx 368 \end{aligned}$$

$$\begin{aligned} \# \text{ Total de variables de decisión } 2E - LRP &\approx 4 * 4 * (14 * 4 + 5) + 7 * 4 * 4 * (4 - 1) + 4 \\ &+ 4 + 4 * 4 * (26 * 4 + 5) + 8 * 4 * 4 * (4 - 1) + 4 * 4 + 4 + 4 \approx 3472 \end{aligned}$$

Observación: La finalidad de presentar el escenario 1 y 2, que corresponden a instancias muy pequeñas o insignificantes del problema abordado, es poder apreciar la gran variabilidad involucrada en este, porque como se puede evidenciar, con tan solo aumentar la cardinalidad de los conjuntos D, R, C, V, y W en una unidad, provoca un gran efecto o incidencia en la dimensión del problema, por ejemplo, el total de restricciones cambia de 216 a 368, lo cual equivale a una diferencia positiva de 152 restricciones o un aumento porcentual del 70.37%, y de la igual forma sucede con el número de variables de decisión, que pasan de 1461 a 3472, representando una diferencia equivalente a 2011 variables más o un cambio porcentual del 137.65%. Por lo tanto, es posible inferir que la complejidad inmersa en el 2E-LRP es muy significativa, pues si se dan estos cambios en tan pequeñas instancias, el considerarlas con un mayor ajuste a la realidad, implicaría una complejidad mucho más seria, lo cual se convierte en un factor crítico, debido a que la dimensión del problema aumenta en proporciones casi indescriptibles el tiempo computacional requerido para obtener soluciones óptimas.

7.4.2.5. Escenario 3. Ahora si suponemos una instancia que se aproxima a la realidad del problema, por ejemplo, 25 depósitos primarios (D), 30 vehículos (V) disponibles para el primer escalón, 30 centros regionales (R), 35 vehículos (W) posibles para el segundo escalón y 2000 clientes (C), la configuración del 2E-LRP tomaría las siguientes dimensiones:

$$|D| = 25, |V| = 40, |R| = 30, |C| = 2000 \text{ y } |W| = 60$$

$$\begin{aligned} \# \text{ Total de restricciones } 2E - LRP &\approx 2 * (2000 + 30 + 60) + 60 * [30 + 2000 * (60 + 1)] \\ &+ 2 * (25 + 30 + 40) + 3 * 25 * 30 * 40 + 40 * (25 + 30) \approx 7'418.370 \end{aligned}$$

$$\# \text{ Total de variables de decisión } 2E - LRP \approx 30 * 2000 * (14 * 60 + 5) + 7 * 2000 * 60 *$$

$$\begin{aligned} & * (2000 - 1) + 60 + 30 + 25 * 30 * (26 * 40 + 5) + 8 * 40 * 30 * (30 - 1) + 30 * 2000 + \\ & + 25 + 40 \approx 1.730'982.305 \end{aligned}$$

Observación final: Como es posible apreciar, si tomamos en consideración un escenario aproximado a la vida real, los resultados demuestran que la dimensión del problema toma un valor considerable, el cual puede afectar en gran medida la capacidad y rendimiento de la máquina utilizada para darle solución, dado el espacio solución tan grande. Finalmente, es posible concluir por qué resulta tan importante usar métodos de solución aproximados o alternativos en este tipo de problemas combinatorios, ya que, por sus características cuantitativas, como expansión, comportamiento y alta sensibilidad ante el más pequeño cambio introducido, utilizar métodos exactos se convierte en una mala decisión debido a su alto costo computacional en función del tiempo requerido, el cual crece en proporciones arbitrarias o desconocidas, convirtiéndose así en una situación desfavorable para el responsable de diseñar la red logística (tomador de decisiones) en una ventana de tiempo reducida.

8. Diseño del algoritmo genético

Teniendo en cuenta la complejidad computacional, el 2E-LRP pertenece al conjunto de problemas tipo NP-Hard, por lo tanto, resulta necesario utilizar métodos aproximados con el objetivo de obtener buenas soluciones factibles en un tiempo computacional razonable. En la presente investigación se hará uso de la metaheurística conocida como “Algoritmo genético” y su procedimiento lógico será descrito a continuación.

8.1. Caracterización del algoritmo

La metodología propuesta para dar solución al problema abordado, se compone de tres etapas generales, las cuales resumen la esencia del algoritmo propuesto:

8.1.1. Etapa 1. Creación de la población inicial.

Etapa 1.1. Método de ahorro (corresponde al 30% de los individuos creados).

Etapa 1.2. Heurística del vecino más cercano (corresponde al 30% de los individuos creados).

Etapa 1.3. Método aleatorio (corresponde al 40% de los individuos creados).

8.1.2. Etapa 2. Aplicación de los operadores genético.

Etapa 2.1. Operador de selección (selección por torneo determinístico + aleatorio).

Etapa 2.2. Operador de cruce (cruce uniforme).

Etapa 2.3. Operador de mutación (mutación puntual).

8.1.3. Etapa 3. Presentación de la mejor solución. Una vez se cumpla con el criterio de parada, que en este caso consiste en un número I de iteraciones definidas por el investigador o usuario, el algoritmo deberá mostrar la mejor solución encontrada, compuesta por lo siguiente: un vector que muestra las instalaciones (depósitos primarios y centros regionales) habilitadas en el primer y segundo escalón, la matriz de rutas para cada nivel, el vector de vehículos a utilizar en el primer y segundo escalón, junto con el costo total de la red logística (fitness del individuo).

8.2. Representación de la solución

Los individuos o miembros que conforman la población, están representados por una codificación no binaria propuesta por el investigador y desarrollada con el objetivo de facilitar los diferentes

procesos algorítmicos que se deben llevar a cabo en cada sub-etapa; para lograr esto, se tomó como referencia el trabajo investigativo que presenta *Nakhjirkan et al.* (2017) y las recomendaciones hechas por *Samani et al.* (2017). Es importante mencionar que cada miembro se compone de tres sub-cadenas por escalón, totalizando así 6 sub-cadenas/individuo, las cuales representan una solución al problema en estudio y están definidas con las siguientes etiquetas:

8.2.1. Primer escalón

1. Asignación de centros regionales a los depósitos primarios habilitados

Interpretación: Cada dupla genética (columna) representa la relación centro regional-depósito primario, por ejemplo, la primera dupla hace referencia a que el centro regional 3 es asignado al depósito primario número 4 (*ver Figura 10*).

2. Asignación de vehículos a los depósitos primarios abiertos

Interpretación: La dupla genética (columna) define la relación depósitos primarios-vehículos, por lo tanto, la matriz presentada puede interpretarse en su primera columna como la asignación del vehículo 1 al depósito primario 4 (*ver Figura 11*).

3. Matriz de rutas (primer escalón)

Interpretación: Como se puede observar, la matriz propuesta define las rutas para cada depósito primario habilitado, donde el número *ceros* (0) indica el inicio de una ruta haciendo uso del vehículo asignado, el cual visita uno o más centros regionales y debe terminar su recorrido en la misma instalación (origen); por otro lado, el *menos uno* (-1) es utilizado para representar un cambio de ruta en una instalación específica. Tomando como ejemplo la primera columna (*ver Figura 12*), es posible evidenciar que el depósito primario 4 está formado por dos rutas y tiene asociado el vehículo tipo 1 según la *Figura 11*; así la *ruta 1*

inicia en el depósito primario 4 con el vehículo 1, visita el centro regional 1, luego sirve al centro regional 3 y regresa al depósito inicial. La *ruta 2* empieza en el mismo depósito primario y utilizando nuevamente el vehículo tipo 1 sirve al centro regional 2, luego atiende el centro regional 4 y termina su recorrido en la instalación origen.

8.2.2. Segundo escalón

1. Asignación de clientes a los centros regionales habilitados

Interpretación: Cada dupla genética (columna) representa la relación cliente-centro regional, por ejemplo, la primera dupla significa que el cliente 1 es asignado al centro regional 5 (ver *Figura 13*).

2. Asignación de vehículos a los centros regionales abiertos

Interpretación: La dupla genética (columna) define la relación centro regionales-vehículos, por lo tanto, la matriz presentada puede interpretarse en su primera columna como la asignación del vehículo 9 al centro regional 5 (ver *Figura 14*).

3. Matriz de rutas (segundo escalón)

Interpretación: Como se puede observar, la matriz presentada define las rutas para cada centro regional habilitado, donde el número *ceros* (0) indica el inicio de una ruta haciendo uso del vehículo asignado, el cual visita uno o más clientes y termina su recorrido en el mismo centro regional (origen); por otro lado, *el menos uno* (-1) es utilizado para representar un cambio de ruta en una instalación específica. Tomando como referencia la primera columna (ver *Figura 15*), es posible observar que el centro regional 5 está formado por dos rutas y tiene vinculado el vehículo tipo 9 como lo indica la *Figura 14*; por lo tanto, la *ruta 1* inicia en la instalación mencionada anteriormente y haciendo uso del vehículo 9,

visita al cliente 10, luego sirve al cliente 1, posteriormente atiende el cliente 4 y regresa al centro regional del cual partió. La *ruta 2* empieza en el mismo centro regional, utiliza nuevamente el vehículo 9 para servir al cliente 7 y luego finaliza su recorrido volviendo a la instalación origen.

SUB-CADENA DE ASIGNACIÓN DE CR A DP HABILITADOS	3	9	.	.	.	R	CR
	4	6	.	.	.	D	DP

Figura 10. Sub-cadena de asignación de CR a DP habilitados.

SUBCADENA DE ASIGNACIÓN DE VEHÍCULOS A LOS DP HABILITADOS	4	6	.	.	.	D	DP
	1	5	.	.	.	V	VEHÍCULOS

Figura 11. Sub-cadena para la asignación de vehículos a los DP abiertos.

SUB-CADENA DE RUTAS (PRIMER ESCALÓN)					
DP4	DP6	.	.	.	DPi
0	0				0
1	5				6
3	15				0
0	8				-1
-1	9				0
0	0				11
2	-1				14
4	0				0
0	7				-1
	0				0
					13
					0

Figura 13. Sub-cadena de rutas (Primer escalón).

SUB-CADENA DE ASIGNACIÓN DE CLIENTES A CR HABILITADOS	1	2	.	.	.	C	CLIENTES
	5	8	.	.	.	R	CR

Figura 12. Sub-cadena de asignación de clientes a los CR habilitados.

SUB-CADENA DE ASIGNACIÓN DE VEHÍCULOS A LOS CR HABILITADOS	5	8	.	.	.	R	CR
	9	2	.	.	.	W	VEHÍCULOS

Figura 14. Sub-cadena para la asignación de vehículos a los CR abiertos.

SUB-CADENA DE RUTAS (SEGUNDO ESCALÓN)					
CR5	CR8	.	.	.	CRκ
0	0				0
10	3				15
1	5				18
4	11				20
0	2				12
-1	7				17
0	0				0
7	-1				-1
0	0				0
	6				16
	0				0

Figura 15. Sub-cadena de rutas (Segundo escalón).

8.3. Decodificación

Una vez finalice el proceso algorítmico, el marco de trabajo o framework deberá mostrar el miembro mejor adaptado (mejor fitness) al entorno (restricciones del problema), quien presentará la siguiente información:

1. Asignación de clientes a los centros regionales habilitados (*Figura 13*).
2. Tipo de vehículo asignado a cada centro regional abierto (*Figura 14*).
3. Conjunto de rutas que satisfacen la demanda de los clientes, teniendo en cuenta el centro regional al que fueron vinculados (*Figura 15*).
4. Asignación de centros regionales a los depósitos primarios habilitados (*Figura 10*).
5. Tipo de vehículo asignado a cada depósito primario abierto (*Figura 11*).
6. Conjunto de rutas que satisfacen la demanda de los centros regionales, tomando como referencia el depósito al que fueron asignados (*Figura 12*).

8.4. Función objetivo (Fitness)

La función objetivo o medida de ajuste que caracteriza a cada miembro de la población, está compuesta por la suma de seis elementos de costo, los cuales son: costo asociado a la apertura de centros regionales y depósitos primarios, costo por utilización de vehículos en el primer y segundo escalón, y el costo por ruteo para cada nivel (escalón). Así mismo, resulta importante mencionar que el mejor miembro estará asociado al menor fitness, pues el objetivo del problema consiste en minimizar el costo total requerido para diseñar la red logística.

8.5. Parámetros

Los datos de entrada requeridos para la inicialización de la población en el algoritmo propuesto se muestran en la *Tabla 3*.

Tabla 3.
Parámetros de inicialización en el algoritmo.

Parámetros	Descripción
Tamaño de la población	Se define un tamaño equivalente a 30 individuos, creados bajo tres enfoques de inicialización y verificando en cada uno de ellos el cumplimiento de las restricciones establecidas*.
Tasa de cruce	La tasa establecida (P_C) es del 90%, por lo tanto, una vez seleccionados los padres, se genera un número aleatorio (N_A), y se verifica la siguiente sentencia: ¿ $N_A < T_C$? SI: El cruce se realiza. NO: Los padres se agregan directamente a la población temporal*.

Continuación Tabla 3.

Descripción	Parámetros
Tasa de mutación	La tasa de mutación (P_M) definida para este tipo de problema es igual a 2.5%. Por lo tanto, se asocia a cada miembro con un número aleatorio (N_A), y el algoritmo debe verificar la siguiente sentencia: ¿ $N_A < T_M$? SI: Aplicar la mutación. NO: Despreciar al individuo y seleccionar otro*.
Corridas por instancia	El número de iteraciones o generaciones (I) propuestas para cada escenario es igual a 35, esto con la finalidad de permitir al algoritmo explorar el espacio de búsqueda*.

* Existe la posibilidad de modificar las dimensiones establecidas para cada uno de los parámetros, pues estos pertenecen al conjunto definido como *parámetros globales* en el algoritmo construido.

8.6. Pasos lógicos del procedimiento algorítmico

Con el propósito de comprender el funcionamiento general del algoritmo construido, se presenta en la *Figura 16* un diagrama de flujo que hace referencia a su ejecución global, en el cual es posible evidenciar los siguientes sub-procesos:

S1. Creación de la población inicial (se utilizan tres técnicas, la primera relacionada con un *método de ahorro*, la segunda es conocida con el nombre de *vecino más cercano* y la tercera, un *método aleatorio*). Una vez construida la población inicial, se da paso al desarrollo de la población temporal, utilizando para esto los operadores genéticos.

S2. Operador de selección: *Torneo determinístico + Aleatorio* (elegir aleatoriamente dos miembros de la población, comparar sus fitness y seleccionar al que tenga el mejor fitness, es decir, el que tenga la menor medida de ajuste, obteniendo así al padre 1, luego de esto, se elige nuevamente de forma aleatoria un individuo de la población y se define como padre 2).

S3. Operador de cruce: *Cruce Uniforme*, con $P_C = 0.9$ (crear una máscara de tamaño equivalente a la sub-cadena *asignación de clientes a los CR habilitados* y aplicar la operación lógica que da origen al *hijo 1* e *hijo 2*).

S4. Operador de mutación: *Mutación puntual*, con $P_M = 0.025$ (Una vez se cumple con el tamaño de la población, el algoritmo etiqueta a cada miembro creado con un número aleatorio N_A y procede a verificar si se realiza o no la mutación, la cual consiste en intercambiar aleatoriamente dos genes de la sub-cadena *asignación de clientes a CR habilitados*).

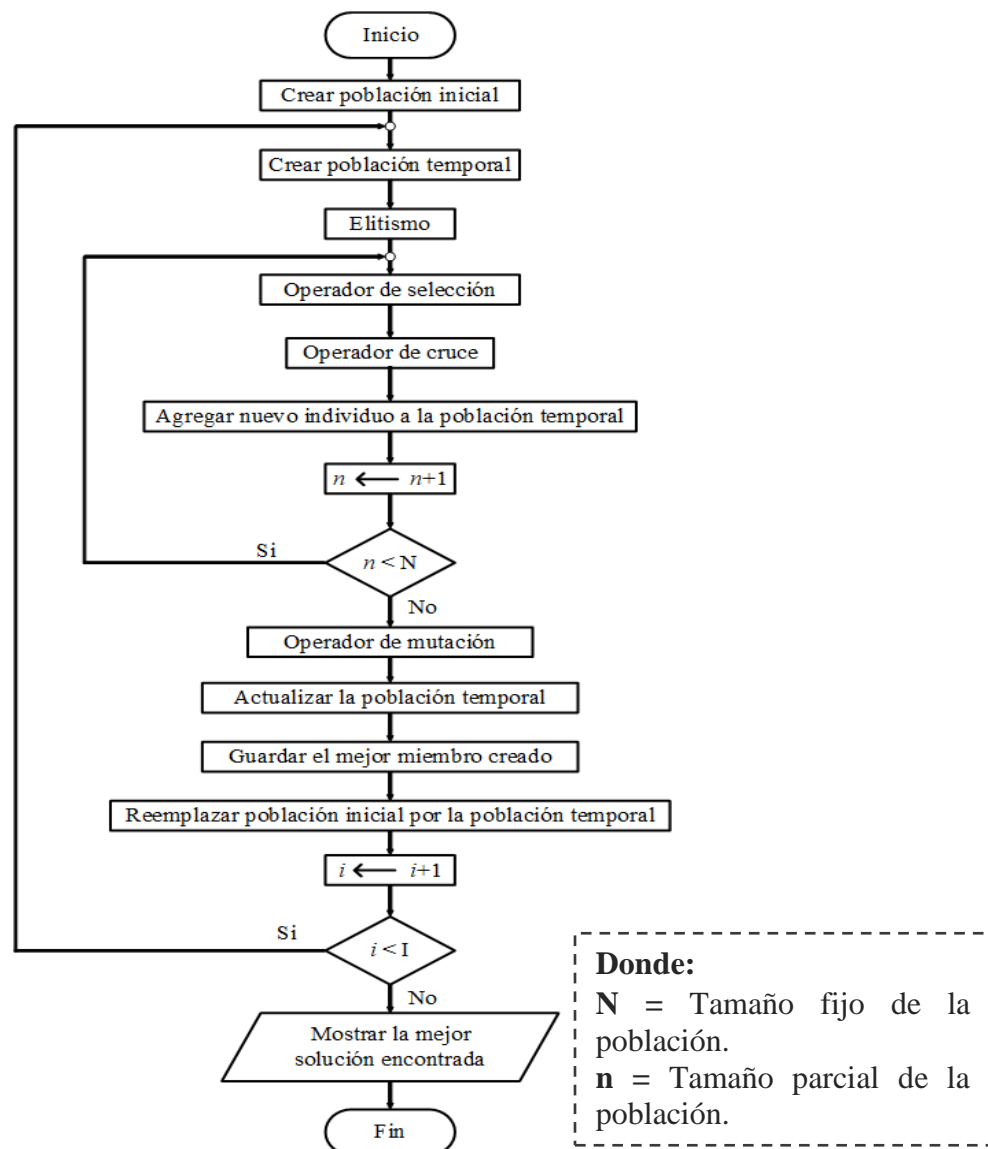


Figura 16. Procedimiento general del algoritmo genético.

8.6.1. S1. Generación de la población inicial. Como se evidencia en el *Apéndice B*, los pasos que se deben efectuar en este sub-proceso son los siguientes:

Paso 1. Definir el tamaño de la población (N).

Paso 2. Ingresar los datos del problema (número de clientes, número de centros regionales, número de depósitos primarios, número de vehículos para cada escalón, costo de abrir una instalación, ya sea centro regional o depósito primario, costo de utilizar los vehículos tanto del primer como segundo escalón, capacidad de las instalaciones y la matriz de costos para el primer y segundo escalón).

Paso 3. Calcular la porción de miembros que serán creados de acuerdo a cada método establecido. Se define que del total (N), el 30% es creado con el método de ahorro (n_1), otro 30% se obtiene utilizando la heurística del vecino más cercano (n_2) y finalmente, un 40% de la población inicial es creada aleatoriamente (n_3).

Método de ahorro: Consiste básicamente en ordenar de menor a mayor, las distancias o el costo de viajar a un conjunto de puntos P_k , tomando como referencia un nodo origen N_i , para luego formar de acuerdo a este orden secuencial la ruta R que debe visitar dichos puntos.

Método del vecino más cercano: Trata de construir un ciclo Hamiltoniano o recorrido de bajo costo, identificando el vértice más cercano a uno dado. Esta heurística se basa en la idea de moverse de una ciudad a la siguiente, de tal forma que, de todas las opciones, la ciudad elegida sea la más cercana a donde se encuentra el viajero, es decir, seleccionando aristas de bajo costo.

Método aleatorio: Este método consiste en el diseño arbitrario de recorridos que permitan visitar un conjunto de nodos N_i partiendo de un punto P_0 . Por lo tanto, con la adición de este componente estocástico, se esperan obtener configuraciones que cumplan con el objetivo de bajo costo o mínima distancia en la ruta.

Paso 4. Generar el porcentaje de miembros que corresponde a cada técnica descrita anteriormente y verificar las restricciones.

Con la finalidad de comprender mejor este sub-proceso tan importante, se presenta a continuación un ejemplo que ilustra cada uno de estos métodos descritos para la inicialización de la población, tomando como referencia la construcción del segundo escalón (CR-Clientes).

Datos de entrada

DEM(CLIENTES)	1	2	3	4	5	6	7	8	9	10
	26	20	43	29	31	24	20	39	24	39
CA(CR)	1	2	3	4	5	6				
	114	108	100	116	117	106				

Figura 17. Parámetros del modelo (Segundo escalón).

Método de ahorro

Se genera un número aleatorio como se muestra en la *Figura 18*.

Número Aleatorio (NA)	<p>Nota: El número aleatorio generado corresponde al centro regional (CR) abierto (en este caso, el N_A debe estar entre 1 y 6).</p>
4	

Figura 18. Apertura del CR (Método de ahorro).

Se ordenan los nodos (clientes) tomando como punto de partida el CR4 y se inicia la asignación de los clientes (ver *Figura 19*).

	CR4
CR1	0
CR2	0
CR3	0
CR4	0
CR5	0
CR6	0
C10	10,97
C2	17,37
C4	49,30
C5	60,64
C7	61,42
C1	74,62
C3	80,02
C8	85,37
C9	90,83
C6	102,29

Nota: Cada cliente (C) se va agregando al centro regional (CR) habilitado siempre y cuando no se haya agregado a otro centro regional previamente (CR) y no exceda la capacidad de éste.

Matriz de asignación de clientes a los CR abiertos		
CR4		
10		
2		
4		
7		

Figura 19. Procedimiento lógico del método de ahorro.

Luego de llevar a cabo este procedimiento varias veces (hasta que todos los clientes sean asignados a un centro regional habilitado), se obtiene finalmente la matriz de asignación de clientes que se presenta en la *Figura 20*.

Matriz de asignación de clientes a los CR abiertos		
CR4	CR6	CR3
10	3	9
2	5	6
4		8
7		1

Figura 20. Matriz de asignación de clientes (Método de ahorro).

Vecino más cercano

Se genera un número aleatorio (ver Figura 21).

Número Aleatorio (NA)	Nota: El número aleatorio generado corresponde al centro regional (CR) abierto (en este caso, el N_A debe estar entre 1 y 6).
4	

Figura 21. Apertura del CR (Vecino más cercano).

Una vez se habilita el CR4, el algoritmo debe ir a la matriz de costos ingresada previamente e identificar dicha instalación, con la finalidad de iniciar la búsqueda de los clientes (vecinos) más cercanos para asignarlos. Como se puede evidenciar en la Figura 22, el cliente con menor costo respecto al CR4 es el número 10, ahora con respecto al cliente 10, el vecino con menor costo es el número 2; tomando como referencia el cliente 2, el vecino más cercano corresponde al número 7 y finalmente con respecto a este, el cliente de menor costo es el número 1 (no se asignan más clientes porque la capacidad de la instalación lo impide).

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
CR1	37,03	49,75	47,18	67,05	72,87	10,67	92,16	17,58	67,50	93,07
CR2	35,52	63,93	12,35	66,39	33,58	74,81	9,02	63,95	92,99	101,71
CR3	118,38	49,10	26,75	14,79	14,86	88,15	105,50	104,79	30,94	37,66
CR4	74,62	17,37	80,02	49,30	60,64	102,29	61,42	85,37	90,83	10,97
CR5	86,51	13,26	100,14	115,39	43,50	87,70	2,87	115,71	28,16	75,19
CR6	75,17	44,84	11,27	107,16	48,98	76,17	90,30	40,27	77,81	57,01
C1	0	78,15	20,99	60,23	85,62	20,39	11,68	13,91	98,22	29,93
C2	78,15	0	69,01	38,12	108,99	48,27	8,35	68,36	45,76	28,58
C3	20,99	69,01	0	32,02	78,56	115,76	89,83	65,92	66,09	59,02
C4	60,23	38,12	32,02	0	9,77	94,71	12,68	27,90	69,59	102,09
C5	85,62	108,99	78,56	9,77	0	70,44	29,34	28,06	84,00	61,48
C6	20,39	48,27	115,76	94,71	70,44	0	119,03	59,10	66,69	58,06
C7	11,68	8,35	89,83	12,68	29,34	119,03	0	21,33	72,81	64,30
C8	13,91	68,36	65,92	27,90	28,06	59,10	21,33	0	44,03	110,88
C9	98,22	45,76	66,09	69,59	84,00	66,69	72,81	44,03	0	78,68
C10	29,93	28,58	59,02	102,09	61,48	58,06	64,30	110,88	78,68	0

Figura 22. Procedimiento lógico del método vecino más cercano.

Después de esto, inicia la asignación respectiva de clientes (*ver Figura 23*).

Nota: Cada cliente (C) se va agregando al centro regional (CR) habilitado siempre y cuando no se haya agregado a otro centro regional previamente (CR) y no exceda la capacidad de este.

CR4		
10		
2		
7		
1		

Figura 23. Sub-proceso intermedio para la asignación de clientes (Vecino más cercano).

Al repetir este procedimiento (hasta que todos los clientes sean asignados a un CR habilitado), se obtiene finalmente la configuración mostrada en la *Figura 24*.

CR4	CR1	CR6
10	6	3
2	8	9
7	4	
1	5	

Figura 24. Sub-proceso intermedio para la asignación de clientes (Vecino más cercano).

Método aleatorio

Se genera un número aleatorio (*ver Figura 25*).

Número Aleatorio (NA)
5

Nota: El número aleatorio generado corresponde al centro regional (CR) abierto (en este caso, el N_A debe estar entre 1 y 6).

Figura 25. Apertura del CR (Método aleatorio).

Una vez se habilita el CR, se inicia el proceso de asignación de clientes (*ver Figura 26*).

Matriz de asignación de clientes a los CR abiertos		
CR5		
6		
10		

Nota: Cada cliente se va agregando al centro regional habilitado aleatoriamente, siempre y cuando no se haya agregado a otro centro regional (CR) previamente y no se viole la capacidad de dicha instalación.

Figura 26. Sub-proceso intermedio para la asignación de clientes (Método aleatorio).

Al lograr la asignación de todos los clientes (diez en total para el escenario propuesto) a un CR habilitado usando el concepto de aleatoriedad, se obtiene la matriz presentada en la *Figura 27*.

Matriz de asignación de clientes a los CR abiertos			
CR5	CR4	CR2	CR1
6	3	4	5
10	9	7	8
	1		
	2		

Figura 27. Matriz de asignación de clientes (Método aleatorio).

Restricciones que se deben cumplir en los dos escalones

1. La carga asociada a una instalación (CR y DP) no puede exceder su capacidad.
2. Un cliente (segundo escalón) o un centro regional (primer escalón) no puede estar vinculado a dos instalaciones diferentes.
3. El número de instalaciones habilitadas, deben ser menor o igual al número de vehículos disponibles.

A partir de la *matriz de asignación de clientes a los CR abiertos* construida por el *método aleatorio* (*ver Figura 27*), se obtienen la sub-cadena relacionada con la asignación de clientes a los centros regionales abiertos (*ver Figura 28*).

SUB-CADENA DE ASIGNACIÓN DE CLIENTES A LOS CR ABIERTOS	1	2	3	4	5	6	7	8	9	10	CLIENTES
	4	4	4	2	1	5	2	1	4	5	CR

Figura 28. Matriz de asignación de clientes (Método aleatorio).

Luego, el algoritmo inicia la vinculación de los vehículos a la matriz “Asignación de clientes a los CR abiertos”; como resultado de este proceso se obtiene la “Sub-cadena de asignación de vehículos a los CR habilitados” y la “Sub-cadena de rutas” (ver Figura 29 y Figura 30).

SUB-CADENA DE ASIGNACIÓN DE VEHÍCULOS A LOS CR HABILITADOS	5	4	2	1	CR
	1	4	3	2	VEHÍCULOS

Figura 29. Componentes del miembro, segundo escalón (2).

SUB-CADENA DE RUTAS (SEGUNDO ESCALÓN)			
CR5	CR4	CR2	CR1
0	0	0	0
6	3	4	5
10	9	7	8
0	0	0	0
	-1		
	0		
	1		
	2		
	0		

Figura 30. Componentes del miembro, segundo escalón (3).

Aplicando ahora el *método aleatorio* al *primer escalón* y tomando como referencia el procedimiento realizado anteriormente, se obtienen las otras tres sub-cadenas del miembro, pues recordando lo expuesto hasta el momento, cada miembro está formado por 6 sub-cadenas*.

***NOTA:** Se asume para el primer escalón la información mostrada en la *Figura 31*.

Capacidad de los depósitos primarios y demanda de los centros regionales (CR)

CA(DP)	1	2	3	4	5	
	135	98	124	85	150	
DEM(CR)	1	2	3	4	5	6
	70	49	0	113	63	0

Figura 31. Parámetros del modelo (Primer escalón).

Con base a los datos de entrada (capacidad y demanda) se construyen las sub-cadenas presentadas en las *Figura 32*, *Figura 33* y *Figura 34*.

Matriz de asignación de CR a los DP abiertos			
DP4	DP2	DP1	DP5
1	2	4	5

Figura 32. Sub-cadena de asignación de CR a DP habilitados.

SUB-CADENA DE ASIGNACIÓN DE CR A DP HABILITADOS	1	2	4	5	CR
	4	2	1	5	DP
SUBCADENA DE ASIGNACIÓN DE VEHÍCULO A LOS DP HABILITADOS	4	2	1	5	DP
	4	5	1	2	VEHÍCULOS

Figura 33. Componentes del miembro primer escalón (1).

SUB-CADENA DE RUTAS (PRIMER ESCALÓN)			
DP4	DP2	DP1	DP5
0	0	0	0
1	2	4	5
0	0	0	0

Figura 34. Componentes del miembro primer escalón (2).

8.6.2. S2. Operador de selección. De acuerdo con el *Apéndice C*, los pasos que se deben ejecutar en este sub-proceso son descritos de la siguiente manera:

Paso 1. Seleccionar aleatoriamente dos miembros de la población.

Paso 2. Comparar el fitness de los individuos; como el objetivo es minimizar los costos, se debe elegir a quien tenga el menor fitness, el cual recibirá la etiqueta de *padre 1*, luego se elige

nuevamente de forma aleatoria un miembro de la población, el cual recibirá directamente la etiqueta de *padre 2*.

Paso 3. Verificar que el miembro etiquetado como *padre 2* no sea el mismo individuo etiquetado con *Padre 1*, ya que no tiene sentido realizar el siguiente sub-proceso (cruce) si los dos padres son el mismo individuo.

8.6.3. S3. Operador de cruce. Una vez construida la población inicial y ejecutado el sub-proceso de selección, el siguiente paso del algoritmo está relacionado con llevar a cabo el cruce de los individuos etiquetados como padre 1 y padre 2, por lo cual se presenta en el *Apéndice D* una descripción detallada que corresponde al sub-proceso de cruce uniforme (siempre se lleva a cabo en el segundo escalón) y los pasos se presentan a continuación:

Paso 1. Generar un número aleatorio (N_A) en el intervalo $[0,1]$.

Paso 2. Verificar si el número aleatorio $N_A < P_C$, si se cumple esta desigualdad, entonces se realiza el cruce, de lo contrario los miembros son agregados directamente a la población temporal. Es importante mencionar que cada pareja (padre 1 y padre 2) dará origen a dos hijos, por lo tanto, se deben crear dos máscaras.

Paso 3. Si se lleva a cabo el cruce, entonces se debe crear la *máscara 1* de tamaño equivalente a la sub-cadena *asignación de clientes a los CR habilitados* y posteriormente llenarla con números aleatorios de 1 y 2, los cuales representan a los padres respectivamente.

Paso 4. Una vez creada la *máscara 1* se lleva a cabo la operación de cruce respectiva para obtener el *hijo 1*, que consiste en lo siguiente: si en la máscara aparece el número 1, entonces el hijo hereda el gen del padre 1 en esa posición, pero si aparece un 2, entonces el hijo hereda el gen del padre 2 que se encuentra en dicha posición.

Paso 5. Validar que el hijo 1 cumple las restricciones R_1 , R_2 y R_3 .

Paso 6. Crear la *máscara 2* y cambiar el rol de los padres, es decir, nombrar al padre 1 como padre 2, al padre 2 como padre 1 y ejecutar los *pasos 4-5* para obtener el *hijo 2*. Con el objetivo de ilustrar este sub-proceso, se presenta un ejemplo en la *Figura 35*.

Restricciones que se deben cumplir para cada hijo creado:

R1. El número de centros regionales abiertos (CR) no puede exceder al número de vehículos disponibles.

R2. La capacidad total de los CR abiertos debe ser \geq Demanda total de los clientes.

R3. La demanda de los clientes asignados a cada CR abierto, no puede exceder la capacidad de dicho CR.

PADRE 1	VECTOR DE ASIGNACIÓN DE CLIENTES A CR	1	2	3	4	5	6	7	8	9	10	CLIENTES
		3	4	6	4	6	3	4	3	3	4	CR
MÁSCARA 1		2	1	1	1	1	1	2	2	2	1	
MÁSCARA 2	<i>PADRE 1 = PADRE 2</i> <i>PADRE 2 = PADRE 1</i>	2	2	1	2	1	1	1	2	2	2	
PADRE 2	VECTOR DE APERTURA DE CR Y ASIGNACIÓN DE	1	2	3	4	5	6	7	8	9	10	CLIENTES
		4	4	6	1	1	1	4	1	6	4	CR
HIJO 1	VECTOR DE ASIGNACIÓN DE CLIENTES A CR	1	2	3	4	5	6	7	8	9	10	CLIENTES
		4	4	6	4	6	3	4	1	6	4	CR
HIJO 2	VECTOR DE ASIGNACIÓN DE CLIENTES A CR	1	2	3	4	5	6	7	8	9	10	CLIENTES
		3	4	6	4	1	1	4	3	3	4	CR

Figura 35. Proceso lógico del cruce uniforme.

8.6.3.1. ¿Cómo manejar las infactibilidades en el proceso de cruce? Para R1 y R2: Estas dos restricciones se deben cumplir simultáneamente, de no cumplirse alguna, el algoritmo debe volver a crear la máscara respectiva (si es el hijo 1 o hijo 2 el que incumple con alguna de las restricciones) y aplicar nuevamente el proceso de cruce, esto se realizará hasta cuatro veces por cada hijo, si después de los cuatro intentos el hijo no cumple con las dos restricciones, entonces se aborta.

Para R3: Como esta restricción es sumamente importante en el logro de un individuo coherente con el entorno (modelo matemático), se presenta el siguiente procedimiento que permite solucionar los problemas de infactibilidad.

Paso 1. Calcular la carga (sumar la demanda total de todos los clientes asignados) de cada CR abierto.

Paso 1.1. Calcular la diferencia entre la capacidad y la carga para cada centro regional; si dicha diferencia da un valor negativo, significa que en ese CR la capacidad es violada (si ninguna de las diferencias da un valor negativo, entonces se procede a la asignación de los vehículos disponibles).

Paso 1.2. Una vez identificado el CR que viola su capacidad, entonces el algoritmo debe identificar el CR con la mayor diferencia positiva.

Paso 2. Identificar el cliente con menor demanda del CR que excede su capacidad.

Paso 3. Sentencia: *¿La demanda del cliente a trasladar es menor o igual a la diferencia del CR al que se pretende enviar?*

Si: Trasladar el cliente.

No: Sentencia: *¿El número de CR habilitados es menor al número de vehículos disponibles y existen más CR que pueden ser habilitados?*

Si: Identificar un CR con capacidad mayor o igual a la demanda del cliente que se desea trasladar, habilitarlo, proceder al traslado e ir al *paso 3.1*.

No: Abortar el hijo.

Paso 3.1. Calcular nuevamente la diferencia entre la capacidad y la carga para cada CR abierto, si alguna de las diferencias sigue siendo negativa, entonces se debe volver a aplicar el procedimiento descrito anteriormente, hasta que ninguna diferencia sea negativa. Luego de que todas las diferencias sean ≥ 0 , se debe primero, actualizar la sub-cadena de asignación de clientes a los CR habilitados, y luego, el algoritmo debe ir al proceso de asignar vehículos y definir las rutas.

8.6.4. S4. Operador de mutación. Este sub-proceso corresponde a la última etapa realizada por el algoritmo genético antes de reemplazar la población inicial por la población temporal, la cual fue construida a partir de los operadores genéticos descritos hasta el momento (operador de selección y cruce). De acuerdo con el *Apéndice E*, los pasos a ejecutar son los siguientes:

Paso 1. Etiquetar a cada miembro de la población temporal con un número aleatorio (N_A), el cual debe pertenecer al intervalo $[0,1]$.

Paso 2. Iniciar la selección de miembros en la población temporal y verificar si el N_A (miembro elegido) es menor a P_m (con $P_m = 0.025$), de cumplirse la desigualdad, se ejecuta el proceso de mutación, si no, el algoritmo elige un nuevo individuo y repite la validación (esta validación se

realiza N -veces, porque el tamaño de la población temporal al igual que el de la población inicial es N).

Paso 3. En caso de mutación, se elige aleatoriamente dos genes o columnas de la *sub-cadena* de *asignación de clientes a los CR abiertos* y se intercambian entre sí (dicho procedimiento se realiza dos veces).

Paso 3.1. Verificar si el algoritmo cumple con la restricción R_1 (La demanda total de los clientes asignados a cada CR abierto, no puede exceder la capacidad de dicho CR), de no cumplirse, la mutación no se tiene en cuenta y el algoritmo vuelve al *paso 2*.

Paso 4. Si el individuo mutado cumple con R_1 , entonces se procede a construir los componentes o sub-cadenas del primer y segundo escalón, haciendo uso del método aleatorio; una vez construidas se calcula el fitness y se realiza la siguiente sentencia:

¿Fitness total (inicial del individuo) < Fitness total (individuo mutado)?

SI: Entonces se guardan las seis sub-cadenas del individuo mutado.

NO: La mutación sobre el individuo no se tiene en cuenta.

8.6.5. Cálculo del fitness durante el proceso de cruce y mutación. Como cada miembro está compuesto de seis sub-cadenas, es decir, tres por escalón, entonces el algoritmo calcula dos fitness parciales (fitness #1 y fitness #2) para cualquier operación (cruce o mutación) realizada sobre el individuo. Una vez calculado estos fitness parciales (uno por escalón), se suman y el resultado de esta operación corresponde al fitness total o global del individuo.

8.6.6. Pseudocódigo del algoritmo genético. En el *Apéndice F* es presentado el funcionamiento global del algoritmo metaheurístico haciendo uso de un pseudocódigo, el cual permite comprender de una mejor forma las operaciones principales, es decir, los procesos de inicialización, selección, cruce y mutación.

9. Experimentación

Una vez desarrollado el marco de trabajo (framework) para la metaheurística “*Algoritmo genético*” en el software *Matlab R2018a*, se da paso a la siguiente fase, *la validación*. Como el modelo formulado presenta unas suposiciones de estudio particulares, por ejemplo:

- Limitaciones de capacidad en los depósitos primarios (DP).
- Limitaciones de capacidad en los centros regionales (CR).
- Flota heterogénea capacitada en el primer escalón.
- Flota heterogénea capacitada en el segundo escalón.
- Asignación de un único vehículo a cada instalación habilitada (depósito primario o centro regional).
- Restricción de transbordo en las instalaciones del mismo escalón.

Se procede a comprobar su funcionalidad y consistencia haciendo uso de experimentos numéricos. Con la finalidad de crear escenarios coherentes que permitan una adecuada evaluación del algoritmo, se toma como referencia tres instancias del 2E-LRP obtenidas de *Prodhon* (s.f.) para desarrollar las configuraciones mostradas en la *Tabla 4*.

Tabla 4.

Instancias de prueba para el 2E-LRP.

Número	Tipo de instancia	Clientes	CR	DP	W	V
1	Pequeña	50	10	7	16	10
2	Mediana	240	25	15	30	20
3	Robusta	600	30	20	35	25

La solución que se presenta en cada instancia propuesta (*ver Apéndice H*), se encuentra estructurada de la siguiente manera:

1. Sub-cadena de asignación de clientes a CR (Centros Regionales) habilitados.
2. Sub-cadena para la asignación de vehículos a CR abiertos.
3. Sub-cadena de rutas CR-CLI (Segundo escalón).
4. Sub-cadena de asignación de CR a DP (Depósitos Primarios) habilitados.
5. Sub-cadena para la asignación de vehículos a DP abiertos.
6. Sub-cadena de rutas DP-CR (Primer escalón).
7. Fitness del individuo (Costo total para diseñar la red logística)

Por último, es importante mencionar que los resultados mostrados a continuación, fueron obtenidos haciendo uso de un computador iMac con procesador Intel Core i5-5200 de 2.7 GHZ.

9.1. Resultados instancia 1

Tabla 5.

Sub-cadena de asignación de Clientes a CR habilitados.

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
1	2	14	8	27	2	40	8
2	8	15	8	28	2	41	2
3	8	16	2	29	2	42	2
4	8	17	2	30	8	43	2
5	8	18	8	31	8	44	8
6	8	19	2	32	2	45	8

Continuación Tabla 5.

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
7	8	20	2	33	8	46	2
8	8	21	8	34	2	47	2
9	2	22	2	35	2	48	8
10	8	23	2	36	8	49	2
11	2	24	2	37	8	50	2
12	8	25	8	38	2		
13	8	26	8	39	8		

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 6.

Sub-cadena para la asignación de vehículos a CR abiertos.

CR	Vehículo
8	8
2	7

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 7.

Sub-cadena de rutas CR-CLI (Segundo escalón).

CR8	CR2
0	0
3	1
13	9
45	19
12	28
0	11
-1	0
0	-1
33	0
44	27
10	20
2	32
0	34
-1	24
0	0
6	-1
15	0

Continuación Tabla 7.

CR8	CR2
7	35
4	38
0	46
-1	16
0	17
5	50
40	0
8	-1
31	0
0	43
-1	29
0	49
14	23
48	41
25	0
36	-1
0	0
-1	47
0	42
26	22
39	0
30	0
21	0
0	0
-1	0
0	0
37	0
18	0
0	0

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 8.

Sub-cadena de asignación de CR a DP habilitados.

CR	Depósito
2	5
8	5

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 9.

Sub-cadena para la asignación de vehículos a DP abiertos.

Depósito	Vehículo
5	8

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 10.

Sub-cadena de rutas DP-CR (Primer escalón).

DP5
0
8
0
-1
0
2
0

Nota: Adaptado del software matemático Matlab R2018a.

Fitness:

\$ 156.081

Elapsed time is 65.449951 seconds.

Interpretación: Como se puede observar, la *Tabla 5* presenta la asignación de cada cliente a un CR habilitado; por lo tanto, el cliente 1 es asignado al CR 2, mientras que los clientes 2 al 8 fueron asignados al CR 8, el cliente 9 es vinculado al CR 2 y de igual forma sucede con la asignación de los clientes 10 al 50. Por otro lado, la *Tabla 6* suministra la información de los CR habilitados y el vehículo de segundo nivel que se le asigna a cada uno; por ejemplo, el CR 8 está asociado con el vehículo tipo 8 y el CR 2 al vehículo 7 (en este caso solo fueron habilitados dos centros regionales para atender a todos los clientes). En la *Tabla 7* es mostrada la matriz de rutas para el segundo

escalón (relación CR-CLIENTES), por ejemplo, el CR 8 está compuesto por 7 rutas (el -1 indica el inicio de una nueva ruta en una misma instalación); la primera ruta del CR 8 visita a los clientes 3, 13, 45 y 12 con el vehículo 8; luego de servir a este último cliente, el vehículo vuelve a la misma instalación (representado por el número 0) e inicia su segundo recorrido con el mismo vehículo, el cual atiende a los clientes 33, 44, 10 y 2; una vez visitado el cliente 2, el vehículo emprende su regreso a la instalación vinculada (CR8), con el objetivo de abastecerse nuevamente y empezar el siguiente recorrido. La *Tabla 8* muestra la asignación de los CR habilitados a un DP; para este caso los CR 2 y 8 se asignan al mismo DP (número 5), quien se encargará de suplir la carga vinculada a cada uno. La *Tabla 9* presenta la asignación de un vehículo de primer nivel a los DP abiertos; por lo tanto, el DP 5 es vinculado al vehículo tipo 8. La *Tabla 10* muestra la sub-cadena o matriz de rutas para el primer escalón (relación DP-CR), en la que es posible evidenciar dos recorridos hechos con el vehículo 8, para satisfacer la carga de los CR habilitados (CR8 y CR2). Finalmente, el costo total (localización, utilización de vehículos y ruteo en los dos escalones) de la configuración obtenida es igual a \$ 156.081.

9.2. Resultados Instancia 2

Tabla 11.

Sub-cadena de asignación de Clientes a CR habilitados.

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
1	5	14	19	27	10	40	5
2	4	15	15	28	25	41	21
3	2	16	15	29	11	42	14
4	4	17	19	30	19	43	11
5	15	18	24	31	5	44	21
6	19	19	5	32	4	45	4
7	25	20	25	33	5	46	1
8	14	21	14	34	4	47	1
9	3	22	24	35	21	48	10
10	1	23	24	36	24	49	15
11	2	24	5	37	15	50	15
12	21	25	12	38	4	51	15
13	2	26	24	39	25	52	25

Continuación Tabla 11.

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
53	2	97	25	141	15	185	14
54	20	98	2	142	3	186	10
55	4	99	4	143	21	187	10
56	1	100	5	144	24	188	25
57	25	101	22	145	3	189	12
58	20	102	4	146	10	190	5
59	3	103	19	147	12	191	1
60	21	104	14	148	4	192	10
61	25	105	15	149	22	193	4
62	1	106	20	150	22	194	3
63	21	107	14	151	24	195	24
64	12	108	4	152	1	196	14
65	22	109	21	153	5	197	22
66	19	110	1	154	22	198	3
67	20	111	20	155	15	199	10
68	20	112	10	156	4	200	25
69	21	113	24	157	25	201	22
70	1	114	14	158	25	202	1
71	19	115	19	159	21	203	15
72	21	116	12	160	20	204	19
73	19	117	5	161	19	205	19
74	5	118	19	162	2	206	12
75	24	119	1	163	24	207	11
76	25	120	11	164	25	208	10
77	10	121	5	165	22	209	21
78	11	122	21	166	25	210	22
79	19	123	21	167	14	211	4
80	5	124	11	168	24	212	5
81	14	125	3	169	15	213	15
82	4	126	25	170	22	214	12
83	21	127	25	171	1	215	19
84	15	128	11	172	5	216	25
85	10	129	21	173	11	217	12
86	12	130	14	174	11	218	10
87	22	131	24	175	3	219	11
88	3	132	10	176	14	220	1
89	4	133	12	177	10	221	1
90	19	134	24	178	15	222	19
91	11	135	25	179	20	223	15
92	24	136	15	180	14	224	19
93	24	137	15	181	21	225	11
94	24	138	22	182	11	226	24
95	1	139	22	183	3	227	25
96	3	140	2	184	1	228	10

Continuación Tabla 11.

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
229	22	232	22	235	20	238	5
230	2	233	15	236	11	239	11
231	20	234	3	237	3	240	12

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 12.

Sub-cadena para la asignación de vehículos a CR abiertos.

CR	Vehículo
25	18
11	11
12	7
10	29
15	21
24	8
22	23
20	24
1	3
3	28
14	30
4	26
21	19
19	20
5	12

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 13.

Sub-cadena de rutas CR-CLI (Segundo escalón).

CR25	CR11	CR12	CR10	CR15	CR24	CR22	CR20	CR1	CR3	CR14	CR4	CR21	CR19	CR5	CR2
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
216	207	189	192	49	94	201	58	221	145	185	4	44	6	121	230
135	173	116	186	233	168	170	111	171	96	180	102	12	224	117	162
76	236	133	132	141	195	65	106	152	9	42	193	143	103	212	53
97	120	147	112	84	18	197	68	70	125	81	82	181	71	1	98
158	128	206	146	155	92	150	160	10	198	114	45	123	215	33	3
20	29	217	177	136	23	210	235	110	194	167	2	69	30	190	11
57	182	240	27	37	151	154	54	62	59	130	34	0	79	31	13
164	43	64	0	137	36	149	231	47	88	107	108	-1	66	24	140
39	91	86	-1	50	144	229	0	191	142	196	55	0	0	40	0
52	239	25	0	0	226	138	-1	184	237	21	32	60	-1	172	0
0	0	0	85	-1	134	165	0	220	234	8	89	35	0	80	0
-1	-1	-1	199	0	22	0	67	0	0	104	211	83	115	153	0
0	0	0	228	213	75	-1	179	-1	-1	176	0	129	222	0	0
28	124	214	218	105	113	0	0	0	0	0	-1	109	73	-1	0
188	225	0	77	15	93	87	0	95	175	0	0	72	204	0	0
166	219	0	48	203	163	232	0	56	183	0	156	0	0	19	0
157	78	0	0	223	0	139	0	119	0	0	38	-1	-1	100	0
7	174	0	-1	5	-1	101	0	202	0	0	99	0	0	74	0
127	0	0	0	16	0	0	0	46	0	0	148	41	118	238	0
126	0	0	208	178	26	0	0	0	0	0	0	63	205	0	0
61	0	0	187	51	131	0	0	0	0	0	0	122	17	0	0
200	0	0	0	169	0	0	0	0	0	0	0	209	14	0	0
227	0	0	0	0	0	0	0	0	0	0	0	159	161	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	-1	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	90	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 14.

Sub-cadena de asignación de CR a DP habilitados.

CR	Depósito	CR	Depósito
5	2	1	8
4	7	21	1
2	2	24	4
15	2	12	12
19	7	10	8
25	1	11	7
14	12	20	4
3	13	22	8

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 15.

Sub-cadena para la asignación de vehículos a DP abiertos.

Depósito	Vehículo
1	16
13	11
12	4
4	1
7	18
2	19
8	9

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 16.

Sub-cadena de rutas DP-CR (Primer escalón).

DP1	DP13	DP12	DP4	DP7	DP2	DP8
0	0	0	0	0	0	0
21	3	14	20	19	15	1
0	0	12	24	11	2	10
-1	0	0	0	0	0	0
0	0	0	0	-1	-1	-1
25	0	0	0	0	0	0
0	0	0	0	4	5	22
0	0	0	0	0	0	0

Nota: Adaptado del software matemático Matlab R2018a.**Fitness :**

$$\$ 2'734.962$$

Elapsed time is 149.713721 seconds.

Nota: La interpretación de las tablas y el fitness se realiza de igual forma que en la instancia 1.

9.3. Resultados Instancia 3

Tabla 17.

Sub-cadena de asignación de Clientes a CR habilitados

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
1	9	28	2	55	20	82	18	109	6	136	29
2	12	29	29	56	6	83	18	110	18	137	2
3	18	30	2	57	29	84	20	111	20	138	9
4	29	31	25	58	21	85	18	112	21	139	19
5	22	32	18	59	29	86	21	113	2	140	9
6	17	33	9	60	18	87	12	114	9	141	11
7	9	34	19	61	22	88	18	115	23	142	12
8	12	35	25	62	6	89	1	116	1	143	25
9	20	36	20	63	17	90	25	117	9	144	12
10	20	37	19	64	18	91	25	118	11	145	6
11	2	38	21	65	12	92	17	119	19	146	25
12	17	39	6	66	29	93	2	120	9	147	11
13	18	40	21	67	12	94	6	121	17	148	8
14	11	41	8	68	14	95	9	122	22	149	21
15	29	42	18	69	29	96	8	123	2	150	2
16	11	43	11	70	17	97	29	124	25	151	29
17	2	44	2	71	2	98	12	125	1	152	2
18	2	45	2	72	12	99	6	126	8	153	19
19	22	46	23	73	11	100	8	127	25	154	2
20	17	47	12	74	11	101	29	128	12	155	23
21	6	48	19	75	20	102	18	129	23	156	18
22	12	49	17	76	17	103	6	130	6	157	14
23	11	50	14	77	12	104	25	131	19	158	25
24	18	51	2	78	23	105	18	132	9	159	2
25	23	52	19	79	6	106	25	133	25	160	2
26	18	53	23	80	20	107	14	134	23	161	12
27	19	54	21	81	14	108	22	135	20	162	20

Continuación Tabla 17.

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
163	11	191	11	219	2	247	22	275	25	303	29
164	23	192	8	220	21	248	23	276	19	304	14
165	18	193	17	221	11	249	17	277	2	305	2
166	12	194	21	222	18	250	18	278	23	306	1
167	25	195	6	223	18	251	2	279	21	307	11
168	2	196	18	224	23	252	12	280	14	308	2
169	20	197	20	225	29	253	25	281	12	309	17
170	22	198	12	226	22	254	18	282	21	310	6
171	14	199	6	227	2	255	2	283	2	311	6
172	9	200	19	228	20	256	19	284	23	312	8
173	14	201	2	229	2	257	21	285	11	313	25
174	17	202	11	230	18	258	19	286	8	314	23
175	23	203	17	231	18	259	17	287	18	315	14
176	6	204	8	232	17	260	1	288	23	316	23
177	18	205	14	233	23	261	18	289	19	317	25
178	2	206	14	234	1	262	19	290	23	318	2
179	1	207	6	235	23	263	2	291	21	319	9
180	1	208	20	236	9	264	19	292	18	320	25
181	11	209	11	237	14	265	12	293	11	321	11
182	2	210	20	238	12	266	2	294	18	322	20
183	18	211	29	239	14	267	23	295	18	323	17
184	6	212	18	240	23	268	8	296	23	324	18
185	25	213	25	241	23	269	12	297	2	325	21
186	9	214	22	242	19	270	22	298	21	326	14
187	22	215	2	243	11	271	8	299	19	327	21
188	11	216	17	244	2	272	23	300	20	328	25
189	22	217	6	245	8	273	14	301	21	329	6
190	20	218	8	246	8	274	11	302	11	330	17

Continuación Tabla 17.

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
331	21	359	23	387	20	415	23	443	17	471	18
332	21	360	23	388	17	416	21	444	19	472	8
333	9	361	11	389	19	417	19	445	29	473	9
334	23	362	12	390	25	418	1	446	25	474	21
335	9	363	21	391	14	419	8	447	19	475	2
336	18	364	17	392	21	420	12	448	2	476	6
337	25	365	21	393	14	421	21	449	23	477	18
338	14	366	11	394	21	422	11	450	23	478	29
339	2	367	18	395	21	423	2	451	25	479	21
340	11	368	23	396	14	424	11	452	11	480	23
341	29	369	14	397	17	425	1	453	14	481	21
342	2	370	21	398	23	426	8	454	23	482	14
343	21	371	25	399	20	427	21	455	12	483	25
344	1	372	22	400	1	428	21	456	23	484	12
345	18	373	17	401	20	429	21	457	2	485	11
346	25	374	23	402	19	430	23	458	11	486	23
347	19	375	9	403	22	431	11	459	9	487	9
348	2	376	12	404	25	432	8	460	21	488	12
349	12	377	11	405	22	433	1	461	21	489	29
350	19	378	19	406	18	434	12	462	11	490	21
351	21	379	2	407	14	435	6	463	25	491	18
352	1	380	17	408	23	436	20	464	23	492	22
353	18	381	29	409	21	437	20	465	21	493	1
354	14	382	20	410	11	438	8	466	21	494	22
355	18	383	2	411	29	439	21	467	20	495	2
356	14	384	20	412	17	440	21	468	1	496	19
357	17	385	25	413	19	441	2	469	19	497	18
358	29	386	18	414	6	442	18	470	9	498	19

Continuación Tabla 17.

Cliente	CR	Cliente	CR	Cliente	CR	Cliente	CR
499	8	527	18	555	19	583	23
500	8	528	9	556	23	584	21
501	2	529	17	557	21	585	12
502	8	530	25	558	21	586	17
503	20	531	20	559	6	587	9
504	11	532	23	560	18	588	25
505	17	533	8	561	25	589	21
506	20	534	29	562	6	590	12
507	21	535	6	563	2	591	19
508	2	536	18	564	21	592	19
509	19	537	19	565	6	593	20
510	25	538	6	566	23	594	2
511	6	539	25	567	23	595	17
512	1	540	1	568	19	596	19
513	19	541	18	569	18	597	2
514	1	542	11	570	14	598	18
515	9	543	6	571	21	599	2
516	19	544	23	572	18	600	29
517	22	545	21	573	9		
518	18	546	1	574	20		
519	19	547	17	575	17		
520	2	548	22	576	18		
521	21	549	21	577	25		
522	29	550	8	578	19		
523	12	551	8	579	11		
524	19	552	19	580	21		
525	8	553	23	581	9		
526	17	554	12	582	11		

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 18.

Sub-cadena para la asignación de vehículos a CR abiertos.

CR	Vehículo
29	3
18	9
2	31
8	26
11	19
25	23
1	32
6	14
20	20
22	7
14	11
17	8
9	16
23	27
21	30
12	33
19	25

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 19.

Matriz de rutas CR-CLI (Segundo escalón).

CR29	CR18	CR2	CR8	CR11	CR25	CR1	CR6	CR20	CR22	CR14	CR17	CR9	CR23	CR21	CR12	CR19
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
225	477	441	148	181	158	125	511	197	517	315	443	459	456	479	434	555
600	183	251	533	274	146	540	195	36	19	391	575	581	544	429	362	200
303	345	318	126	424	446	514	535	9	405	304	174	319	288	86	455	378
478	295	520	41	452	530	418	103	467	187	157	412	7	449	409	72	153
534	177	348	426	285	337	234	145	437	226	482	20	470	314	428	590	262
341	491	255	500	16	346	433	217	593	214	171	388	528	316	521	98	413
4	324	308	100	542	124	468	21	75	494	107	193	1	0	557	67	552
59	527	137	271	188	0	344	130	10	170	356	373	515	-1	325	488	591
151	497	227	499	23	-1	180	207	436	372	68	92	0	0	370	161	389
489	560	113	96	302	0	352	0	169	270	206	364	-1	290	38	420	242
57	110	563	312	366	313	400	-1	190	492	407	203	0	164	545	484	513
136	32	594	204	377	577	306	0	0	189	393	232	573	430	558	523	592
445	222	508	218	0	91	425	311	-1	5	453	595	138	415	440	198	299
211	442	150	286	-1	104	116	562	0	108	354	70	186	553	584	0	289
29	598	383	192	0	463	546	435	574	403	173	547	587	53	40	-1	509
15	82	160	246	14	106	179	310	399	247	205	49	120	408	220	0	519
101	336	17	432	462	213	89	94	208	548	81	6	172	241	507	47	0
411	102	501	525	43	0	493	62	80	122	50	121	0	0	0	87	-1
358	165	448	502	361	-1	260	329	401	61	273	330	-1	-1	-1	77	0
522	3	342	551	321	0	0	176	210	0	0	0	0	0	0	269	516
0	230	0	438	191	127	-1	184	135	0	-1	-1	114	267	466	2	347
-1	0	-1	245	74	451	0	0	531	0	0	0	487	454	564	281	119
0	-1	0	0	422	185	512	-1	55	0	570	249	95	224	481	252	139
66	0	495	-1	221	253	0	0	0	0	239	259	335	46	392	554	402
97	42	44	0	458	35	0	56	-1	0	237	63	132	272	589	349	256
381	471	423	419	209	167	0	543	0	0	280	309	236	278	490	22	417

Continuación Tabla 19.

69	83	28	550	0	404	0	559	384	0	338	357	33	248	149	128	469
0	60	379	472	-1	0	0	109	162	0	326	12	0	0	58	0	37
0	386	18	268	0	-1	0	476	503	0	369	323	-1	-1	416	-1	350
0	250	71	0	147	0	0	414	387	0	396	586	0	0	331	0	48
0	292	305	0	582	510	0	79	84	0	0	505	140	25	282	238	258
0	355	283	0	431	320	0	538	111	0	0	529	333	450	461	8	568
0	406	597	0	504	275	0	199	300	0	0	526	473	464	571	585	537
0	212	30	0	141	133	0	39	322	0	0	76	375	115	54	144	0
0	26	51	0	118	588	0	0	382	0	0	380	117	532	427	166	-1
0	13	159	0	485	371	0	-1	0	0	0	397	0	486	474	376	0
0	367	475	0	293	561	0	0	-1	0	0	216	0	368	327	265	52
0	518	266	0	579	483	0	565	0	0	0	0	0	334	343	142	34
0	287	219	0	307	539	0	99	228	0	0	0	0	296	0	65	444
0	85	339	0	340	0	0	0	506	0	0	0	0	0	-1	0	596
0	576	244	0	410	-1	0	0	0	0	0	0	0	-1	0	0	496
0	88	297	0	73	0	0	0	0	0	0	0	0	0	301	0	131
0	0	168	0	0	390	0	0	0	0	0	0	0	583	465	0	578
0	-1	152	0	-1	317	0	0	0	0	0	0	0	360	395	0	276
0	0	229	0	0	90	0	0	0	0	0	0	0	134	291	0	498
0	231	178	0	163	31	0	0	0	0	0	0	0	155	421	0	447
0	223	182	0	243	328	0	0	0	0	0	0	0	284	257	0	524
0	196	11	0	202	385	0	0	0	0	0	0	0	566	112	0	264
0	541	215	0	0	143	0	0	0	0	0	0	0	0	279	0	27
0	572	0	0	0	0	0	0	0	0	0	0	0	-1	332	0	0
0	569	-1	0	0	0	0	0	0	0	0	0	0	0	351	0	0
0	254	0	0	0	0	0	0	0	0	0	0	0	240	365	0	0
0	261	201	0	0	0	0	0	0	0	0	0	0	398	549	0	0
0	353	263	0	0	0	0	0	0	0	0	0	0	567	460	0	0

Continuación Tabla 19.

0	156	599	0	0	0	0	0	0	0	0	0	0	556	298	0	0
0	24	45	0	0	0	0	0	0	0	0	0	0	374	0	0	0
0	105	93	0	0	0	0	0	0	0	0	0	0	235	-1	0	0
0	294	277	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	64	457	0	0	0	0	0	0	0	0	0	0	-1	580	0	0
0	536	123	0	0	0	0	0	0	0	0	0	0	0	363	0	0
0	0	154	0	0	0	0	0	0	0	0	0	0	78	439	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	129	394	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	480	194	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	175	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	359	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	233	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 20.

Sub-cadena de asignación de CR a DP habilitados.

CR	Depósito
9	11
12	15
18	6
29	9
22	15
17	11
20	6
2	9
11	15
6	15
23	6
19	11
25	10
21	11
8	11
14	9
1	9

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 21.

Sub-cadena para la asignación de vehículos a DP abiertos.

Depósito	Vehículo
9	21
6	20
15	23
11	17
10	12

Nota: Adaptado del software matemático Matlab R2018a.

Tabla 22.

Sub-cadena de rutas DP-CR (Primer escalón).

DP9	DP6	DP15	DP11	DP10
0	0	0	0	0
29	20	22	9	25
14	23	12	19	0
1	0	11	8	0
0	-1	0	0	0
-1	0	-1	-1	0
0	18	0	0	0
2	0	6	17	0
0	0	0	21	0
0	0	0	0	0

Nota: Adaptado del software matemático Matlab R2018a.

Fitness :

\$ 2'335.319

Elapsed time is 195.417824 seconds.

Nota: La interpretación de las tablas y el fitness se realiza de igual forma que en la instancia 1.

Con base a los resultados obtenidos anteriormente para cada instancia (pequeña, mediana y robusta), es posible afirmar que el marco de trabajo propuesto para el algoritmo genético, cumple con los criterios de funcionalidad (genera datos de salida) y consistencia (las restricciones y especificaciones planteadas son ejecutadas correctamente), los cuales son muy importantes en la solución del problema abordado.

10. Análisis estadístico

Una vez superada la etapa de validación, resulta interesante identificar el conjunto de factores que intervienen significativamente en el desempeño del algoritmo propuesto. Por lo tanto, se realiza a continuación un diseño factorial 2^k , con el propósito de lograr una comprensión formal de aquellos factores que influyen considerablemente en las variables: *función objetivo (F.O)* y *tiempo computacional (TCO)*, quienes se encargan de establecer la calidad y el rendimiento del algoritmo. Después de analizar la estructura conceptual que presenta el marco de trabajo, se definieron como principales factores a analizar: Tamaño de la población (TP), número de generaciones (NG), probabilidad de cruce (PC) y probabilidad de mutación (PM), obteniendo así un diseño factorial de la forma 2^4 . Por último, es importante aclarar que el valor de la función objetivo está dado pesos (\$) y el tiempo computacional en segundos (s).

La configuración del diseño factorial para las instancias propuestas anteriormente, se muestra en la *Tabla 23*.

Tabla 23.

Diseño factorial para el algoritmo genético.

Factores	Nivel	
	Bajo (-1)	Alto (+1)
TP	10	30
NG	15	35
PC	0,9	1
PM	0,025	0,1

10.1. Instancia 1. Con base en los factores y niveles definidos anteriormente, se desarrolla el diseño de experimentos como se muestra en la *Tabla 24*, la cual está compuesta por dos réplicas para cada variable de estudio.

Tabla 24.

Estructura del diseño de experimentos (Pequeña instancia).

TP	NG	PC	PM	RÉPLICAS			
				F.O (R1)	F.O (R2)	TCO (R1)	TCO (R2)
-1	-1	-1	-1	186081	191593	65,45	64,43
1	-1	-1	-1	166732	169614	224,53	214,70
-1	1	-1	-1	182070	193828	148,74	149,08
1	1	-1	-1	124529	143830	538,70	527,3
-1	-1	1	-1	182752	175022	67,13	62,38
1	-1	1	-1	169643	158368	221,98	216,27
-1	1	1	-1	184739	183657	147,63	151,85
1	1	1	-1	122028	113126	527,89	518,10

Continuación Tabla 24.

RÉPLICAS							
TP	NG	PC	PM	F.O (R1)	F.O (R2)	TCO (R1)	TCO (R2)
-1	-1	-1	1	185349	199981	65,03	71,38
1	-1	-1	1	164532	171096	237,20	239,82
-1	1	-1	1	190879	183265	165,70	161,93
1	1	-1	1	155357	134451	573,04	567,57
1	-1	1	1	161890	162028	235,18	240,66
-1	1	1	1	188144	179719	160,18	158,62
1	1	1	1	115157	109606	569,13	572,46

Nota: Adaptado del software estadístico MINITAB 18, versión 2018.

Una vez que se organizan los datos, estos son procesados utilizando el software Minitab. Por lo tanto, al llevar a cabo el análisis estadístico, es posible evidenciar en la *Figura 36*, que el comportamiento de los datos relacionados con la función objetivo (F.O) indican que no existe un cambio significativo en la variabilidad de los residuales y tampoco siguen una aparente tendencia en el orden de corridas; sin embargo, al analizar la gráfica de normalidad e histograma, es posible inferir que los datos no se comportan como dicha distribución. Además, al observar la *Tabla 25* correspondiente al análisis de varianza (ANOVA), es posible afirmar que los efectos principales están asociados al tamaño de la población (TP), el número de generaciones (NG) junto con su interacción (TP*NG) y a la probabilidad de cruce (PC), pues como se evidencia, son estos los factores que presentan una mayor diferencia estadísticamente significativa (Valor p igual a cero).

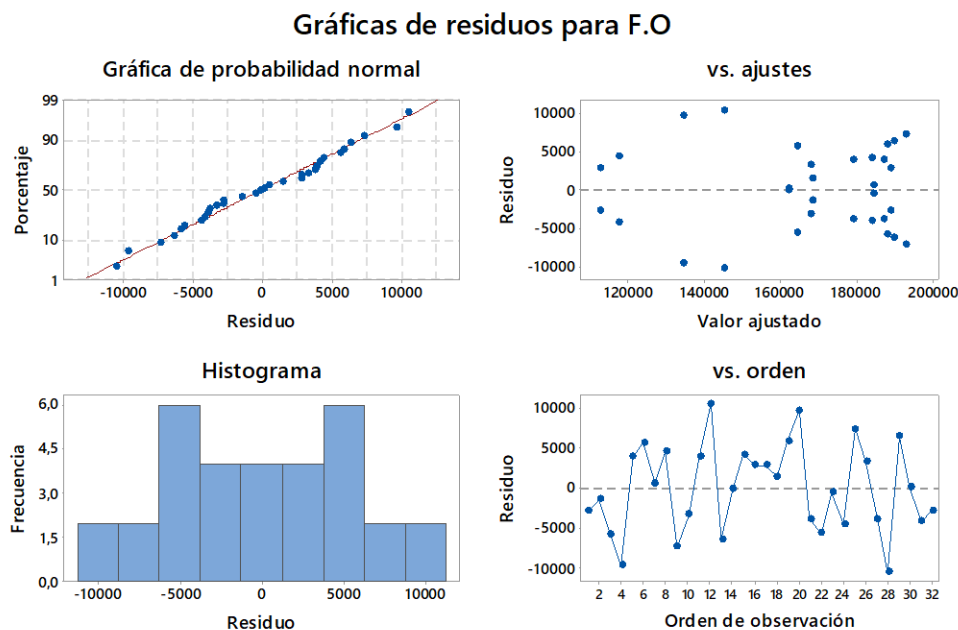


Figura 36. Gráfica de residuos para la F.O (Pequeña instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

Tabla 25.

Análisis de varianza (ANOVA) para pequeña instancia.

Fuente	GL	SC	MC	Valor F	Valor p
Modelo	15	20471070200	1364738013	23,82	0,000
Lineal	4	16977388557	4244347139	74,09	0,000
TP	1	12972175128	12972175128	226,43	0,000
NG	1	3189888001	3189888001	55,68	0,000
PC	1	781211628	781211628	13,64	0,002
PM	1	34113800	34113800	0,60	0,452
Interacciones de 2 términos	6	3029026196	504837699	8,81	0,000
TP*NG	1	2667128648	2667128648	46,56	0,000
TP*PC	1	192472200	192472200	3,36	0,085
TP*PM	1	13191816	13191816	0,23	0,638
NG*PC	1	135943560	135943560	2,37	0,143
NG*PM	1	7505875	7505875	0,13	0,722
PC*PM	1	12784096	12784096	0,22	0,643
Interacciones de 3 términos	4	456737237	114184309	1,99	0,144
TP*NG*PC	1	255685191	255685191	4,46	0,051
TP*NG*PM	1	69726240	69726240	1,22	0,286

Continuación Tabla 13.

Fuente	GL	SC	MC	Valor F	Valor p
TP*PC*PM	1	78763800	78763800	1,37	0,258
NG*PC*PM	1	52562004	52562004	0,92	0,352
Interacciones de 4 términos	1	7918210	7918210	0,14	0,715
TP*NG*PC*PM	1	7918210	7918210	0,14	0,715
Error	16	916625612	57289101		
Total	31	21387695812			

Nota: Obtenido del software estadístico MINITAB 18, versión 2018.

Teniendo en cuenta la *Figura 37* y *Figura 38*, es posible reafirmar con una confianza del 95% que los factores con mayor influencia significativa en la calidad de la función objetivo (F.O), corresponden al tamaño de la población (factor más importante), el número de generaciones, su combinación respectiva y la probabilidad de cruce.




Figura 37. Diagrama de Pareto de efectos estandarizados F.O (Pequeña instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

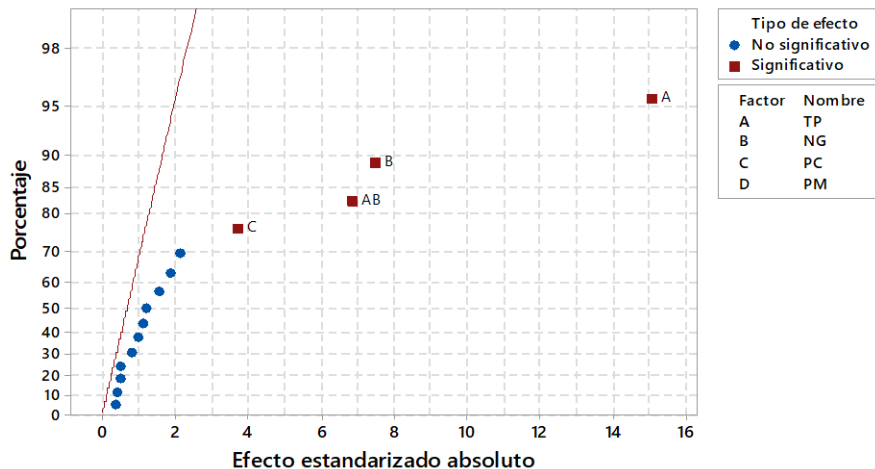


Figura 38. Gráfica de efectos normales absolutos estandarizados F.O (Pequeña instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

Analizando la Figura 39 gráfica de efectos principales para la función objetivo, se puede evidenciar que los niveles de factores que minimizan el costo total (localización y ruteo multinivel) son: Tamaño de la población igual a 30, número de generaciones 35, probabilidad de cruce 1 y probabilidad de mutación igual a 0.025 (2.5%).




Figura 39. Gráfica de efectos principales para la F.O (Pequeña instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

Al estudiar la interacción múltiple de factores para la función objetivo (F.O), específicamente la doble combinación TP*NG (pues esta presenta un efecto significativo sobre dicha variable), es posible observar que el mejor efecto (*ver Figura 40*) de esta interacción se logra cuando es seleccionado simultáneamente un tamaño de población (TP) igual a 30 y un número de generaciones (NG) equivalente a 35.




Figura 40. Gráfica de interacción para la F.O (Pequeña instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

Tomando como referencia el R-ajustado, puede observarse en la *Tabla 26* que los factores utilizados para el experimento (TP, NG, PC y PM), explican en un 91.70% a la variable función objetivo (F.O); esto resulta muy interesante, porque permite comprender con mayor claridad, el grado de influencia e interés que presenta el conjunto de factores, si se desea cumplir con el objetivo establecido para el algoritmo propuesto (minimizar el costo total).

Tabla 26.

Resumen del modelo para la F.O (Pequeña instancia).

S	R-cuad.	R-cuad. (ajustado)	R-cuad. (pred)
7568,96	95,71%	91,70%	82,86%

Nota: Obtenido del software estadístico MINITAB 18, versión 2018.

Por otro lado, al analizar el tiempo computacional (TCO) requerido para obtener una solución con el algoritmo propuesto, se encuentra que los factores con mayor incidencia en esta variable como se muestra en la *Figura 41* son: tamaño de la población (TP), número de generaciones (NG), probabilidad de mutación (PM), la interacción de dos niveles: TP*NG, TP*PM, NG*PM y la interacción de tres factores: TP*NG*PM.

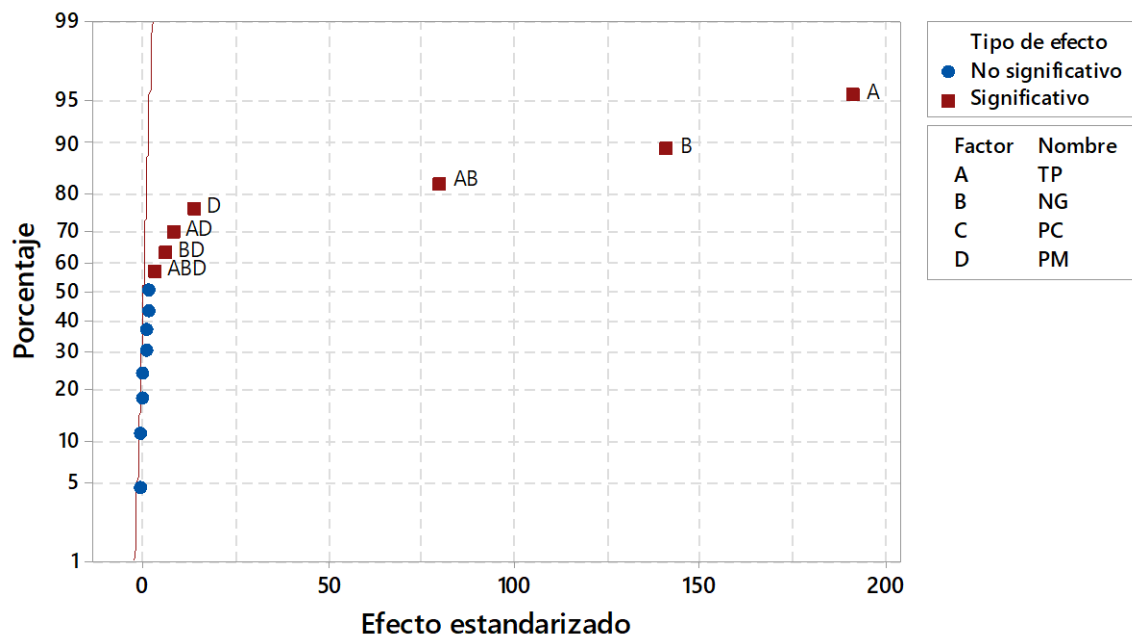


Figura 41. Gráfica normal de efectos estandarizados TCO (Pequeña instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

Teniendo en cuenta la *Figura 42*, puede inferirse (como era de suponer) que al tomar los niveles bajos de los factores TP, NG y PM, permiten obtener un menor tiempo computacional (TCO). Así mismo, resulta importante mencionar que los niveles del factor PC no tienen ninguna influencia significativa sobre la variable estudiada, por lo que es posible tomar cualquier nivel.




Figura 42. Gráfica de efectos principales para el TCO (Pequeña instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

10.2. Instancia 2. El diseño de experimentos para la instancia propuesta, es mostrado en la *Tabla 27*.

Tabla 27.

Estructura del diseño de experimentos (Mediana instancia).

TP	NG	PC	PN	RÉPLICAS			
				F.O (R1)	F.O (R2)	TCO (R1)	TCO (R2)
-1	-1	-1	-1	2902455	2977942	149,71	157,23
1	-1	-1	-1	2536301	2393743	340,48	348,65
-1	1	-1	-1	2724954	2805025	327,75	332,57
1	1	-1	-1	2319018	2299014	734,64	732,31
-1	-1	1	-1	2607917	2712731	160,70	163,88
1	-1	1	-1	2540648	2420753	354,27	353,98
-1	1	1	-1	2738487	2640617	337,74	333,17
1	1	1	-1	2371116	2222361	736,88	736,84
-1	-1	-1	1	3067738	3089372	176,98	171,48
1	-1	-1	1	2564036	2616636	372,72	364,95
-1	1	-1	1	2776616	2619955	347,48	354,58

Continuación Tabla 27.

TP	NG	PC	PN	RÉPLICAS			
				F.O (R1)	F.O (R2)	TCO (R1)	TCO (R2)
1	1	-1	1	2326521	2415372	763,96	769,68
1	-1	1	1	2578794	2469566	364,95	377,40
-1	1	1	1	2627432	2610286	341,91	357,80
1	1	1	1	2210426	2305426	765,91	759,44

Nota: Adaptado del software estadístico MINITAB 18, versión 2018.

De acuerdo con la *Tabla 28*, puede apreciarse que los factores: tamaño de la población (TP), número de generaciones (NG), probabilidad de cruce (PC) y probabilidad de mutación (PM) explican en un 92.60% a la variable función objetivo (F.O) según el R-ajustado, lo cual es muy importante, pues por un lado valida la selección de factores realizada previamente y por otro, permite comprender el grado de interacción e importancia que presentan dichos factores sobre la variable analizada. Además, con base a la *Tabla 29*, es posible identificar a los factores TP, NG, PC, PM, junto con las combinaciones NG*PM y TP*NG*PM, como los efectos estadísticamente significativos sobre la variable F.O, lo cual puede ser corroborado al apreciar la *Figura 43* y *Figura 44*, que corresponden a la gráfica de efectos normales absolutos estandarizados y al diagrama de Pareto respectivamente.

En la *Figura 45* es mostrado el comportamiento de los datos asociados nuevamente con la función objetivo (F.O), los cuales indican que no existe un cambio significativo en la variabilidad de los residuales ni siguen una aparente secuencia en el orden de las corridas; sin embargo, al observar minuciosamente la gráfica de normalidad e histograma, es posible inferir que los residuales no se comportan estadísticamente como dicha distribución.

Tabla 28.

Resumen del modelo para la F.O (Mediana instancia).

S	R-cuad.	R-cuad. (ajustado)	R-cuad. (pred)
67887,2	96,18%	92,60%	84,72%

Nota: Obtenido del software estadístico MINITAB 18, versión 2018.

Tabla 29.

Análisis de varianza (ANOVA) para mediana instancia.

Fuente	GL	SC	MC	Valor F	Valor p
Modelo	15	1,85695E+12	1,23796E+11	26,86	0,000
Lineal	4	1,70257E+12	4,25643E+11	92,36	0,000
TP	1	1,23653E+12	1,23653E+12	268,31	0,000
NG	1	3,70789E+11	3,70789E+11	80,45	0,000
PC	1	61210074807	61210074807	13,28	0,002
PM	1	34040219698	34040219698	7,39	0,015
Interacciones de 2 términos	6	90990426940	15165071157	3,29	0,026
TP*NG	1	631488020	631488020	0,14	0,716
TP*PC	1	15157179727	15157179727	3,29	0,089
TP*PM	1	2381171219	2381171219	0,52	0,483
NG*PC	1	2430716071	2430716071	0,53	0,478
NG*PM	1	70387821464	70387821464	15,27	0,001
PC*PM	1	2050439	2050439	0,00	0,983
Interacciones de 3 términos	4	59524983872	14881245968	3,23	0,040
TP*NG*PC	1	10446606827	10446606827	2,27	0,152
TP*NG*PM	1	26340810934	26340810934	5,72	0,029
TP*PC*PM	1	17039013734	17039013734	3,70	0,072
NG*PC*PM	1	5698552377	5698552377	1,24	0,283
Interacciones de 4 términos	1	3858712334	3858712334	0,84	0,374
TP*NG*PC*PM	1	3858712334	3858712334	0,84	0,374
Error	16	73738651175	4608665698		
Total	31	1,93068E+12			

Nota: Obtenido del software estadístico MINITAB 18, versión 2018.




Figura 44. Gráfica de efectos normales absolutos estandarizados F.O (Mediana instancia). Obtenido del software estadístico MINITAB 18, versión 2018.




Figura 43. Diagrama de Pareto de efectos estandarizados F.O (Mediana instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

Gráficas de residuos para F.O

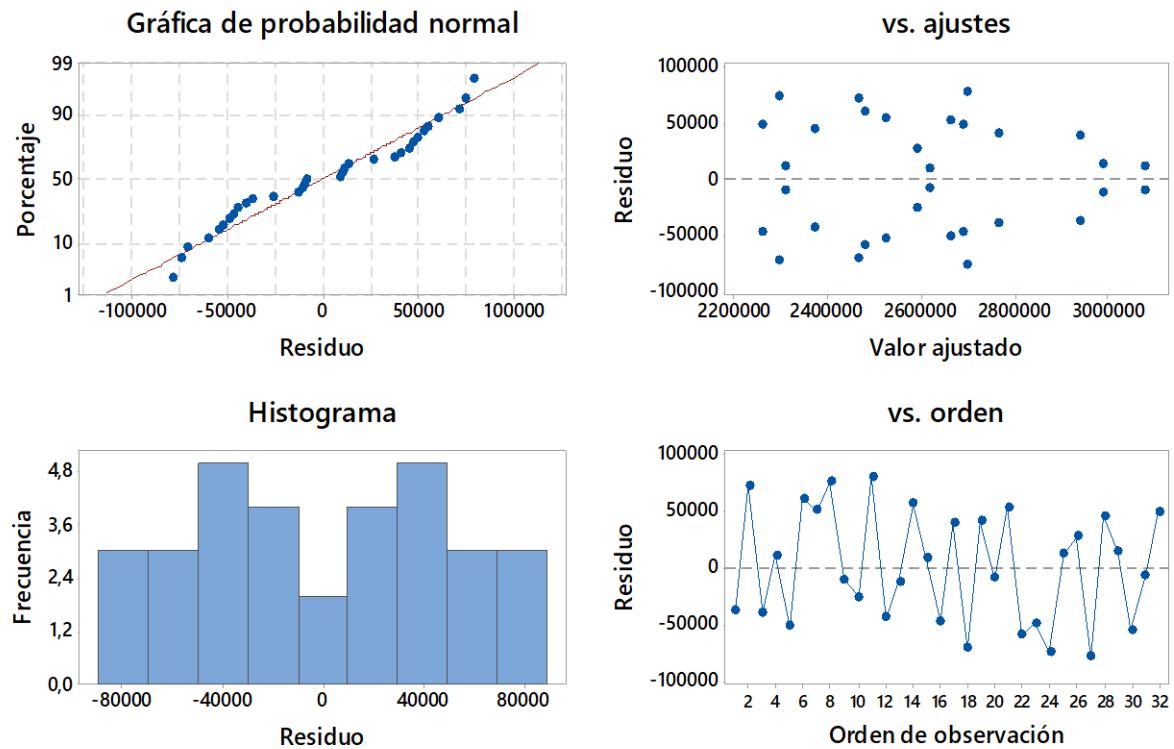


Figura 45. Gráfica de residuos para la F.O (Mediana instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

Según la *Figura 46*, es posible observar un mayor grado de significancia por parte del factor tamaño de la población (TP), ya que con dicho factor se logra el menor valor promedio de la F.O. Como el objetivo a cumplir es minimizar el fitness o medida de ajuste vinculada al individuo, se identifica la mejor combinación de niveles en los factores a la siguiente configuración: Tamaño de la población igual a 30, número de generaciones 35, probabilidad de cruce 1 y probabilidad de mutación igual a 0.025 (2.5%).




Figura 46. Gráfica de efectos principales para la F.O (Mediana instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

Teniendo en cuenta que la interacción de dos niveles NG*PM pertenecen a los efectos principales, resulta importante definir cuál es la mejor combinación de niveles simultáneos que permite un menor valor en la F.O, tomando como referencia la influencia de dichos factores; por lo tanto, basados en la Figura 47 se identifica como la mejor combinación a los niveles: PM= 0.1 y NG=35.




Figura 47. Gráfica de efectos principales para la F.O (Mediana instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

De igual forma, al analizar el tiempo computacional (TCO) requerido para obtener una solución con el algoritmo propuesto, se encuentra que los principales factores influyentes con una confianza del 95% son: tamaño de la población (TP), número de generaciones (NG), probabilidad de mutación (PM) y la interacción de dos niveles: TP*NG y TP*PM (ver *Figura 48* y *Figura 49*). Y como es de esperarse, la combinación que minimiza dicha variable (TCO) son los niveles bajos (-1), es decir, TP=10, NG= 15, PM= 0.025 y como la PC no tiene un efecto directo, se toma el valor de 0.9 (ver *Figura 50*).




Figura 48. Diagrama de Pareto de efectos estandarizados TCO (Mediana instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

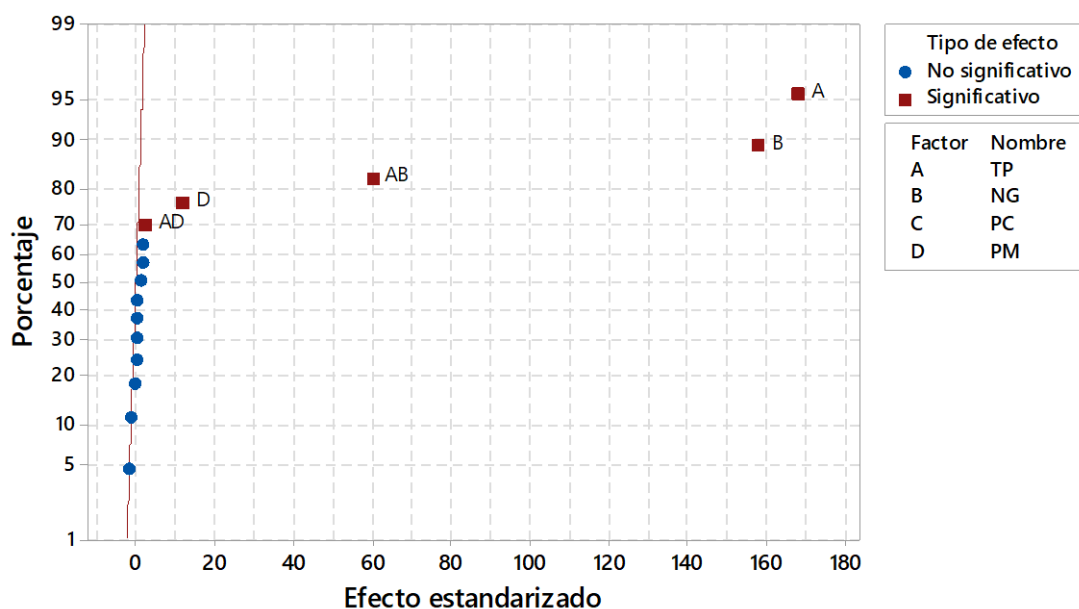


Figura 49. Gráfica normal de efectos estandarizados TCO (Mediana instancia). Obtenido del software estadístico MINITAB 18, versión 2018.




Figura 50. Gráfica de efectos principales para el TCO (Mediana instancia). Obtenido del software estadístico MINITAB 18, versión 2018.

10.3. Instancia 3. Tomando en cuenta los factores y niveles especificados anteriormente, se desarrolla el diseño de experimentos como se muestra en la *Tabla 30*.

Tabla 30.

Estructura del diseño de experimentos (Instancia robusta).

TP	NG	PC	PN	RÉPLICAS			
				F.O (R1)	F.O (R2)	TCO (R1)	TCO (R2)
-1	-1	-1	-1	2642198	2735319	197,51	195,42
1	-1	-1	-1	2308876	2198716	457,86	459,2
-1	1	-1	-1	2571646	2649972	392,29	386,3
1	1	-1	-1	2202110	2111705	958,6	977,89
-1	-1	1	-1	2465104	2519271	194,62	193,79
1	-1	1	-1	2312833	2131673	445,93	447,7
-1	1	1	-1	2492933	2333624	377,4	392,5
1	1	1	-1	2158503	2041297	956,66	922,74
-1	-1	-1	1	2792660	2837670	203,69	194,11
1	-1	-1	1	2334124	2302412	473,77	492,92
-1	1	-1	1	2527643	2406498	382,67	382,88
1	1	-1	1	2117907	2218583	995,56	1007,2
-1	-1	1	1	2618567	2757506	203,77	212,34
1	-1	1	1	2347559	2268362	502,3	465,61
-1	1	1	1	2482869	2397617	419,69	392,55
1	1	1	1	2012222	2099224	986,35	981,04

Nota: Adaptado del software estadístico MINITAB 18, versión 2018.

De acuerdo con el análisis de varianza (*ver Tabla 31*), se identifican con un nivel de significancia igual al 5%, los factores más importantes para la instancia estudiada, los cuales son: tamaño de la población (TP), número de generaciones (NG), probabilidad de cruce (PC) y la combinación de dos factores NG*PM. Así mismo, es posible verificar con base al R-ajustado (*ver Tabla 32*), que los factores propuestos (TP, NG, PC y PM) explican a la función objetivo (F.O) en un 89.59%, indicando así un buen ajuste y a su vez, la existencia de más factores influyentes que

no se tuvieron en cuenta durante el experimento, por ejemplo, la participación porcentual de los métodos de inicialización para la población (método de ahorro, vecino más cercano y aleatorios), el tipo de procesador, entre otros.

Tabla 31.
Análisis de varianza (ANOVA) para instancia robusta.

Fuente	GL	SC	MC	Valor F	Valor p
Modelo	15	1,56984E+12	1,04656E+11	18,79	0,000
Lineal	4	1,47069E+12	3,67673E+11	66,01	0,000
TP	1	1,14950E+12	1,14950E+12	206,37	0,000
NG	1	2,36070E+11	2,36070E+11	42,38	0,000
PC	1	72093164551	72093164551	12,94	0,002
PM	1	13026715108	13026715108	2,34	0,146
Interacciones de 2 términos	6	71059268486	11843211414	2,13	0,107
TP*NG	1	2153139848	2153139848	0,39	0,543
TP*PC	1	14168967376	14168967376	2,54	0,130
TP*PM	1	971115503	971115503	0,17	0,682
NG*PC	1	100376738	100376738	0,02	0,895
NG*PM	1	48368042044	48368042044	8,68	0,009
PC*PM	1	5297626978	5297626978	0,95	0,344
Interacciones de 3 términos	4	24123656793	6030914198	1,08	0,398
TP*NG*PC	1	6442288428	6442288428	1,16	0,298
TP*NG*PM	1	8192672014	8192672014	1,47	0,243
TP*PC*PM	1	9413600775	9413600775	1,69	0,212
NG*PC*PM	1	75095576	75095576	0,01	0,909
Interacciones de 4 términos	1	3960967264	3960967264	0,71	0,412
TP*NG*PC*PM	1	3960967264	3960967264	0,71	0,412
Error	16	89120583515	5570036470		
Total	31	1,65896E+12			

Nota: Obtenido del software estadístico MINITAB 18, versión 2018.

Tabla 32.

Resumen del modelo para la F.O (Instancia robusta).

S	R-cuad.	R-cuad. (ajustado)	R-cuad. (pred)
74632,7	94,63%	89,59%	78,51%

Nota: Obtenido del software estadístico MINITAB 18, versión 2018.

La identificación plena de los principales efectos en la F.O, puede ser realizada apoyándose en el diagrama de Pareto que muestra los efectos estandarizados (ver Figura 51) y la gráfica de efectos normales absolutos estandarizados (ver Figura 52), a partir de los cuales es posible validar la afirmación hecha anteriormente sobre las interacciones más importantes.




Figura 51. Diagrama de Pareto de efectos estandarizados F.O (Instancia robusta). Obtenido del software estadístico MINITAB 18, versión 2018.




Figura 52. Gráfica de efectos normales absolutos estandarizados F.O (Instancia robusta). Obtenido del software estadístico MINITAB 18, versión 2018.

Según la Figura 53 y como ha sucedido en las instancias desarrolladas anteriormente, la combinación de niveles en los factores que permiten minimizar el valor de la función objetivo (F.O) son: TP=30, NG= 35, PC=1 y PM=0.025, es decir, la mejor medida de ajuste o fitness se logra cuando en el marco de trabajo son considerados los parámetros relacionados con su nivel alto (+1), a excepción de PM, cuyo valor elegido debe corresponder al nivel bajo (-1).




Figura 53. Gráfica de efectos principales para la F.O (Instancia robusta). Obtenido del software estadístico MINITAB 18, versión 2018.

Al estudiar los factores incidentes en el tiempo computacional (TCO), puede inferirse según la *Figura 54* y *Figura 55* que dichos factores significativos están asociados con: tamaño de la población (TP), número de generaciones (NG), probabilidad de mutación (PM), junto con las interacciones de dos niveles: TP*NG, TP*PM y TP*PC. Más aún, es posible establecer de acuerdo con la *Figura 56*, que los niveles a utilizar con el objetivo de minimizar dicho TCO, están relacionados con los niveles bajos de los factores mencionados anteriormente, es decir, TP=10, NG=15, PM= 0.025 y PC es seleccionado arbitrariamente porque no presenta una influencia estadísticamente significativa sobre la variable estudiada; por lo tanto, se elige un valor igual a 0.9.




Figura 54. Diagrama de Pareto de efectos estandarizados TCO (Instancia robusta). Obtenido del software estadístico MINITAB 18, versión 2018.

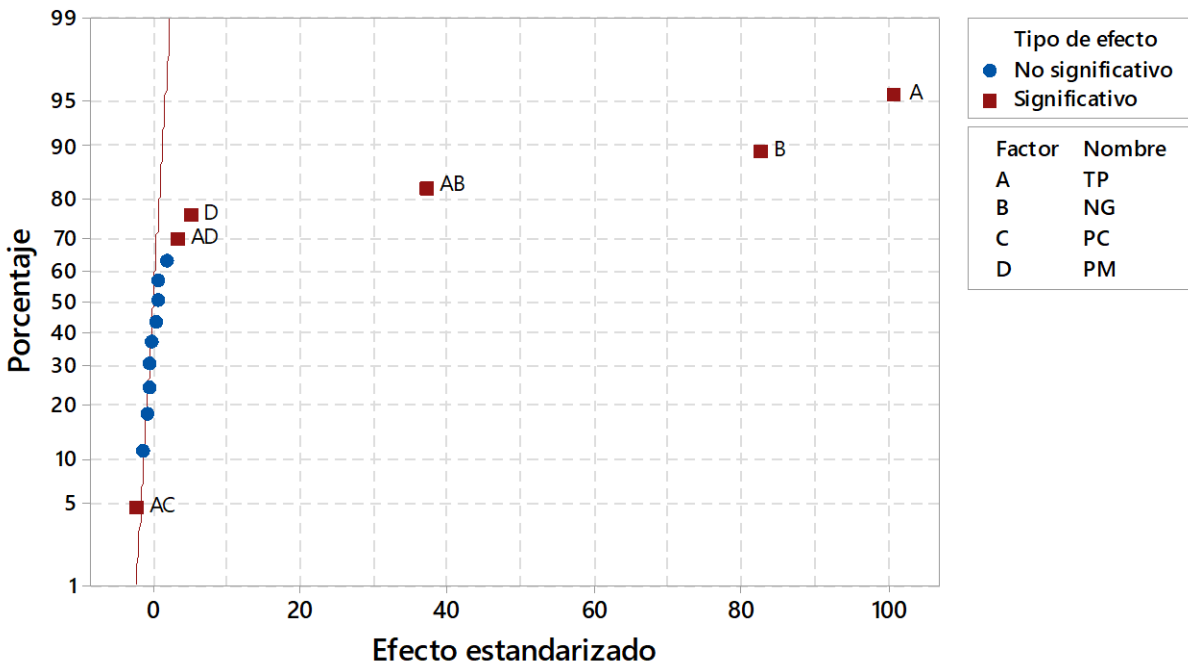


Figura 55. Gráfica normal de efectos estandarizados TCO (Instancia robusta). Obtenido del software estadístico MINITAB 18, versión 2018.




Figura 56. Gráfica de efectos principales para el TCO (Instancia robusta). Obtenido del software estadístico MINITAB 18, versión 2018.

Tomando como referencia los resultados estadísticos obtenidos anteriormente para las tres instancias estudiadas, es posible concluir de modo general que los factores con una gran influencia sobre la función objetivo o fitness (F.O) del marco de trabajo propuesto son: tamaño de la

población (TP), número de generaciones (NG) y probabilidad de cruce (PC); por otro lado, los factores que presentan un efecto estadísticamente significativo en el tiempo computacional (TCO) son: Tamaño de la población (TP), número de generaciones (NG) y probabilidad de mutación (PM). Ahora bien, si el objetivo que se desea cumplir es el obtener los menores costos posibles sin importar el tiempo computacional requerido (objetivo deseado en esta investigación), entonces hay que elegir los niveles altos (+1) de TP, NG y PC, pero si el propósito es lograr mejores soluciones factibles en el menor tiempo posible, entonces se deben tomar como datos de entrada al algoritmo, los niveles bajos (-1) correspondientes a TP, NG y PM.

11. Conclusiones

Según la revisión de literatura y el análisis bibliométrico (*ver Apéndice A*), pocos autores han abordado el problema de localización y ruteo de vehículos multinivel considerando flota heterogénea capacitada, por lo tanto, el presente estudio puede ser catalogado como un referente para futuras investigaciones en el área de logística humanitaria y logística comercial, dado que el enfoque multidisciplinario con el cual se formuló el modelo y el marco de trabajo, permiten adaptarlo sin ningún inconveniente. Además, es importante mencionar que las consideraciones presentadas en el modelo, junto con el nuevo método de solución desarrollado, aportan significativamente al trabajo realizado por Dai et al. (2018), ya que brindan una visión mucho más realista y aplicativa del problema.

El algoritmo diseñado puede ser utilizado como una herramienta computacional para apoyar la toma de decisiones en el área de logística humanitaria o comercial, la cual permite localizar depósitos primarios (DP) y centros regionales (CR), definir los vehículos a utilizar en cada nivel

y construir las rutas que permitan atender los requerimientos de los clientes o la carga asociada a cada CR habilitado, cumpliendo con el objetivo de minimizar el costo total requerido para la construcción de la red logística.

La representación de la solución y el procedimiento lógico propuesto en las diferentes fases (inicialización, selección, cruce y mutación) del algoritmo genético, facilitan en gran medida los diversos procesos algorítmicos que se deben llevar a cabo para obtener una solución factible al problema en estudio, pues como se puede apreciar en la experimentación, el tiempo computacional requerido para solucionar una instancia catalogada como robusta (600 clientes) es de aproximadamente 18 minutos, lo cual es un tiempo razonable dada la complejidad inmersa en los sistema de localización y distribución multi-escalón.

El implementar una técnica de inicialización híbrida para la construcción de la población, permitió acotar el espacio de búsqueda a las mejores áreas factibles del problema, reduciendo así la pérdida de tiempo (como se aprecia en los datos obtenidos durante la fase de validación y experimentación) por parte del algoritmo en regiones innecesarias, gracias a la naturaleza que presentan los métodos (vecino más cercano y ahorro) implementados. Sin embargo, es importante aclarar que la aplicación de dichos procedimientos heurísticos se hicieron bajo un porcentaje de participación equivalente a 30% para cada uno y un 40% para el enfoque aleatorio, pues aunque es importante evitar regiones infactibles y reducir el espacio de búsqueda a las mejores soluciones, también resulta vital mantener la diversidad en los miembros creados, por lo que el mayor porcentaje de participación en la creación de individuos se asigna al procedimiento aleatorio, evitando así una convergencia prematura del algoritmo a óptimos locales.

De acuerdo con el análisis estadístico, es posible inferir con una confianza del 95% que los principales factores incidentes en la calidad de la solución (función objetivo, F.O) obtenida con la metaheurística algoritmo genético son: tamaño de la población (TP), número de generaciones (NG) y probabilidad de cruce (PC); por otro lado, los factores que presentan un efecto estadísticamente significativo en el rendimiento (tiempo computacional, TCO) de dicho algoritmo son: Tamaño de la población (TP), número de generaciones (NG) y probabilidad de mutación (PM). Ahora bien, si el objetivo que se desea cumplir es el de obtener el menor costo posible sin importar el tiempo computacional requerido (objetivo deseado en esta investigación), entonces hay que elegir los niveles altos (+1) de TP, NG y PC, pero si el propósito es lograr buenas soluciones factibles en el menor tiempo posible, entonces se deben elegir los niveles bajos (-1) correspondientes a TP, NG y PM.

A pesar que el método de solución propuesto no fue comparado con otros algoritmos metaheurísticos o híbridos presentados en la literatura, debido a las consideraciones adicionales que se tuvieron en cuenta a la hora de construir el modelo y a una existencia básica de las instancias de prueba para el 2E-LRP encontradas hasta la fecha de la investigación, puede afirmarse, basándose en los experimentos numéricos y el diseño experimental, que el enfoque genético desarrollado en el presenta trabajo investigativo posee una gran competitividad (rendimiento) a la hora de enfrentar diversos escenarios, ya que al ejecutar dicha metodología para resolver escenarios definidos como pequeños, medianos o robustos (hasta 600 clientes) demanda un bajo esfuerzo computacional.

12. Recomendaciones

Para futuras investigaciones en el área se sugiere:

En cuanto al modelamiento matemático, relajar algunas suposiciones de estudio, por ejemplo, permitir transbordo entre instalaciones del mismo escalón, atención de un centro regional (CR) por más de un depósito primario (DP), considerar múltiples productos, dividir la demanda de un cliente o la carga de un centro regional habilitado y permitir la asignación de múltiples vehículos a una misma instalación, esto con el objetivo de minimizar los costos, lograr una mayor flexibilidad en las rutas, ampliar el alcance y aplicación que posee el 2E-LRP en la logística global (humanitaria, comercial y urbana).

Aunque la incertidumbre hará que los modelos sean más complejos, la demanda incierta es más realista, por lo tanto, resultaría interesante considerar factores estocásticos o difusos en el comportamiento que presenta la demanda de los clientes. También sería importante incluir ventanas de tiempo difíciles, ya que en muchos casos las restricciones horarias para servir a un cliente o conjunto de clientes, se convierten en un gran inconveniente a la hora de obtener soluciones coherentes que se ajusten con la realidad del problema. Por último, permitir la planeación multi-periodo junto con el control de inventario, el cual involucra decisiones sobre el ciclo de reposición y la cantidad requerida, contribuirán al desarrollo de un modelo mucho más útil y robusto para la gestión de la cadena de suministro.

Implementar nuevas técnicas de solución con el propósito de mejorar la calidad en las respuestas obtenidas según el objetivo que se desea cumplir (maximizar beneficios o minimizar costos) y a su vez, lograr una reducción del esfuerzo computacional requerido; para lo cual se sugiere crear un algoritmo híbrido compuesto por el algoritmo genético (GA) y un procedimiento de búsqueda voraz adaptativa (GRASP) o un algoritmo memético (MA) formado por un algoritmo evolutivo NSGA II y un procedimiento de búsqueda local.

Abordar el problema bajo un enfoque multiobjetivo, en el cual además de minimizar el costo total asociado con la localización, ruteo y utilización de vehículos, se logre maximizar la confiabilidad de las rutas establecidas. Finalmente, se recomienda extender el problema a N-escalones, con la finalidad de construir un algoritmo general que se adapte a cualquier tipo de problema logístico multi-escalón.

Referencias bibliográficas

- Aguilar, K. J. (2017). *Un modelo multiobjetivo de localización-ruteo para la planeación logística en la fase de preparación a sismos en Bucaramanga*. (Tesis de maestría). Universidad Industrial de Santander, Colombia.
- Altay, N., y Green III, W. G. (2006). OR/MS research in disaster operations management. *European Journal of Operational Research*, 175(1), 475-493. doi:10.1016/j.ejor.2005.05.016
- Álvarez, C. (2009). *Optimización de enjambre de partículas (PSO) aplicada al problema de la P-mediana. Bucaramanga. Universidad Industrial de Santander*. (Tesis de pregrado). Universidad Industrial de Santander, Colombia.
- Ambrosino, D., y Scutellà, M. (2005). Distribution network design: New problems and related models. *European Journal of Operational Research*, 165(3), 610-624. doi:10.1016/j.ejor.2003.04.009
- Baas, S., Ramasamy, S., Pryck, J. D., y Battista, F. (octubre de 2009). *Análisis de Sistemas de Gestión del Riesgo de Desastres*. Roma: Organización de las Naciones Unidas para la Agricultura y la Alimentación [FAO]. Recuperado de <http://www.fao.org/3/a-i0304s.pdf>
- Balcik, B., Beamon, B. M., Krejci, C. C., Muramatsu, K. M., y Ramirez, M. (2010). Coordination in humanitarian relief chains: Practices, challenges and opportunities. *International Journal of Production Economics*, 126(1), 22-34. doi:10.1016/j.ijpe.2009.09.008
- Banco Mundial. (14 de abril de 2016). *Gestión del riesgo de desastres*. Banco Mundial. Recuperado de: <http://www.bancomundial.org/es/topic/disasterriskmanagement/overview>
- Barreto, M. A., y Niño, P. N. (2016). *Un algoritmo memético para el problema de localización-ruteo con ventanas de tiempo para la atención de desastres sísmicos en la ciudad de Bucaramanga*. (Pregrado). Universidad Industrial de Santander, Colombia.
- Blickle, T., y Thiele, L. (1995). *A Comparison of Selection Schemes used in Genetic Algorithms* (Segunda edición). TIK-Report.

- Blum, C., y Roli, A. (2003). Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison. *ACM Computing Surveys*, 35(3), 268–308. Recuperado de https://www.iiia.csic.es/~christian.blum/downloads/blum_rol_2003.pdf
- Boccia, M., Crainic, T. G., Sforza, A., y Sterle, C. (2010). A Metaheuristic for a Two Echelon Location-Routing Problem. En P. Festa (Ed.), *International Symposium on Experimental Algorithms* (págs. 288-301). Naples: Springer. doi:10.1007/978-3-642-13193-6_25
- Boccia, M., Crainic, T. G., Sforza, A., y Sterle, C. (enero de 2011). *Location-Routing Models for Designing a Two-Echelon Freight Distribution System*. Canada: Cirrelt. Recuperado de <https://www.cirrelt.ca/DocumentsTravail/CIRRELT-2011-06.pdf>
- Boussaid, I., Lepagnot, J., y Siarry, P. (2013). A survey on optimization metaheuristics. *Information Sciences*, 237, 82-117. doi:10.1016/j.ins.2013.02.041
- Bruns, A. D. (1998). *Zweistufige Standortplanung unter Berücksichtigung von Tourenplanungsaspekten : primale Heuristiken und lokale Suchverfahren*. (Tesis de doctorado). University of St. Gallen, San Galo.
- Cecchini, S., Sunkel, G., y Barrantes, A. (18 de abril de 2017). *Protección social de la infancia frente a los desastres*. CEPAL. Recuperado de <https://www.cepal.org/es/enfoques/proteccion-social-la-infancia-frente-desastres>
- CEPAL. (14 de diciembre de 2005). *El impacto de los desastres naturales en el desarrollo: documento metodológico básico para estudios nacionales de caso*. Recuperado de CEPAL: https://repositorio.cepal.org/bitstream/handle/11362/25766/1/LCmexL694_es.pdf
- Chong, E. K., y Zak, S. H. (2001). *An introduction to optimization* (Segunda ed.). United States of America: WILEY-INTERSCIENCE.
- Contardo, C., Hemmelmayr, V., y Crainic, T. G. (2012). Lower and upper bounds for the two-echelon capacitated location-routing problem. *Computers & Operations Research*, 39(12), 3185-3199. doi:10.1016/j.cor.2012.04.003
- Correal, J. F. (23 de abril de 2016). ¿Cuán vulnerable es Colombia ante un sismo? *El Tiempo*. Recuperado de <http://www.eltiempo.com/archivo/documento/CMS-16571309>

- Cuda, R., Guastaroba, G., y Speranza, M. (2015). A survey on two-echelon routing problems. *Computers & Operations Research*, 55, 185-199. doi:10.1016/j.cor.2014.06.008
- Dai, Z., Aqlan, F., Gao, K., y Zhou, Y. (2018). A two-phase method for multi-echelon location-routing problems in supply chains. *Expert Systems With Applications*, 115, 618-634. doi:10.1016/j.eswa.2018.06.050
- Dalfard, V. M., Kaveh, M., y Nosratián, N. E. (2013). Two meta-heuristic algorithms for two-echelon location-routing problem with vehicle fleet capacity and maximum route length constraints. *Neural Computing and Applications*, 23(8), 2341–2349. doi:10.1007/s00521-012-1190-0
- Darwin, C. (2007). *The Descent of Man*. Nuvision Publications.
- Day, J. M., Melnyk, S. A., Larson, P. D., Davis, E. W., y Whybark, D. C. (2012). Humanitarian and Disaster Relief Supply Chains: A Matter of Life and Death. *Journal of Supply Chain Management*, 48(2), 21-36. doi:10.1111/j.1745-493X.2012.03267.x
- Dorigo, M., y Stützle, T. (2004). *Ant Colony Optimization*. Estados Unidos: MIT Press.
- Dowland, K. A., y Diaz, B. (2001). Diseño de heurística y fundamento del recocido simulado. *Revista Iberoamericana de Inteligencia Artificial*(20), 34-52
- Fogel, D. B. (2000). What is evolutionary computation? *IEEE Spectrum*, 37(2), 26-32.
- Forouzanfar, F., y Tavakkoli-Moghaddam, R. (2012). Using a genetic algorithm to optimize the total cost for a location-routing-inventory problem in a supply chain with risk pooling. *Journal of Applied Operational Research*, 4(1), 2-13. Recuperado de <http://orlabanalytics.ca/jaor/archive/v4/n1/jaorv4n1p2.pdf>
- Gaytán, J., Arroyo, P. E., y Enríquez, R. (8 de octubre de 2010). *Logística humanitaria: planeación y control del producto*. Revista Énfasis. Recuperado de <http://www.logisticamx.enfasis.com/notas/17787-logistica-humanitaria-planeacion-y-control-del-producto>

- Gestal, M. (s.f.). *Introducción a los algoritmos genéticos*. Departamento de Tecnologías de la información y las comunicaciones: Universidad de Coruña, España. Recuperado de <http://sabia.tic.udc.es/mgestal/cv/aaggtutorial/tutorialalgoritmosgeneticos.pdf>
- Gestal, M., Rivero, D., Rabuñal, J. R., Dorado, J., y Pazos, A. (2010). *Introducción a los Algoritmos Genéticos y la Programación Genética*. Coruña: Universidade da Coruña.
- Giraldo, L. F., Delgado, E., Riaño, J. C., y Castellanos, G. (2006). Selección de características usando modelo híbrido basado en algoritmos genéticos. *Ingeniería e Investigación*, 26(3), 113-119. Recuperado de <http://www.scielo.org.co/pdf/iei/v26n3/v26n3a13.pdf>
- Glover, F. (1986). Future paths for integer programming and links to artificial intelligence. *Computers & Operations Research*, 13(5), 533-549. doi:10.1016/0305-0548(86)90048-1
- Goldberg, D. E. (1989). *Genetic algorithms in search, optimization, and machine learning*. Boston: Addison-Wesley.
- Goldberg, D. E. (2002). *The Design of Innovation*. Addison-Wesley.
- Gonzalez-Feliu, J. (octubre de 2009). *The multi-echelon location-routing problem : concepts and methods for tactical and operational planning*. Francia: ResearchGate. Recuperado de https://www.researchgate.net/publication/39064434_The_N-echelon_Location_routing_problem_concepts_and_methods_for_tactical_and_operationa_l_planning
- Guha-Sapir, D., Hoyois, P., y Below, R. (2016). *Annual Disaster Statistical Review 2015: The numbers and trends*. CRED. Recuperado de http://www.cred.be/sites/default/files/ADSR_2015.pdf
- Hillier, F. S., y Lieberman, G. J. (2010). *Introducción a la investigación de operaciones* (Novena ed.). México: McGraw-Hill.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems*. Ann Arbor, USA: University of Michigan Press.

- Jacobsen, S., y Madsen, O. (1980). A comparative study of heuristics for a two-level routing-location problem. *European Journal of Operational Research*, 5(6), 378-387. doi:10.1016/0377-2217(80)90124-1
- Johnson, D. S., y Garey, M. (1979). *Computers and Intractability: A Guide to the Theory of NP-Completeness*. New York: Freeman & Company.
- Kovács, G., y Spens, K. M. (2007). Humanitarian logistics in disaster relief operations. *Management Research News*, 37(2), 99-114. doi:10.1108/09600030710734820
- Lange, K. (2010). *Applied Probability*. Stanford: Springer Science & Business Media.
- Laporte, G. (1988). Location-routing problems. En B. L. Golden, y A. A. Assad (Edits.), *Vehicle Routing: Methods and Studies* (págs. 163-198). Amsterdam.
- L'Hermitte, C., Tatham, P., Bowles, M., y Brooks, B. (2016). Developing organisational capabilities to support agility in humanitarian logistics: An exploratory study. *Journal of Humanitarian Logistics and Supply Chain Management*, 6(1), 72-99. doi:10.1108/JHLSCM-02-2015-0006
- Li, H.-G., y Li, X.-G. (2009). Image segmentation with pseudo branch and bound algorithm. *International Conference on Machine Learning and Cybernetics*, 12-15. doi:10.1109/ICMLC.2009.5212215
- Macedo, R., Alves, C., Hanafi, S., Jarboui, B., Mladenović, N., Ramos, B., y de Carvalho, J. (2015). Skewed general variable neighborhood search for the location routing scheduling problem. *Computers & Operations Research*, 61, 143-152. doi:10.1016/j.cor.2015.03.011
- Madsen, O. B. (1983). Methods for solving combined two level location-routing problems of realistic dimensions. *European Journal of Operational Research*, 12(3), 295-301. doi:10.1016/0377-2217(83)90199-6
- Manopiniwes, W., y Irohara, T. (2014). A Review of Relief Supply Chain Optimization. *Industrial Engineering & Management Systems*, 13(1), 1-14. doi:10.7232/iems.2014.13.1.001

- Michalewicz, Z. (1992). *Genetic Algorithms + Data Structures = Evolution Programs*. charlotte: Springer-Verlag.
- Min, H., Jayaraman, V., y Srivastava, R. (1998). Combined location-routing problems: A synthesis and future research directions. *European Journal of Operational Research*, 108(1), 1-15. doi:10.1016/S0377-2217(97)00172-0
- Nagy, G., y Salhi, S. (2007). Location-routing: Issues, models and methods. *European Journal of Operational Research*, 177(2), 649-672. doi:10.1016/j.ejor.2006.04.004
- Nakhjirkan, S., y Rafiei, F. M. (2017). An Integrated Multi-Echelon Supply Chain Network Design Considering Stochastic Demand: A Genetic Algorithm Based Solution. *Promet - Traffic & Transportation*, 29(4), 391-400. doi:10.7307/ptt.v29i4.2193
- Nguyen, V.-P., Prins, C., y Prodhon, C. (2012). Solving the two-echelon location routing problem by a GRASP reinforced by a learning process and path relinking. *European Journal of Operational Research*, 216(1), 113-126. doi:10.1016/j.ejor.2011.07.030
- Nier, A. P., y Niño, J. A. (2015). *Desarrollo de un algoritmo híbrido para resolver el problema de localización-ruteo (LRP)*. (Pregrado). Universidad Industrial de Santander, Colombia.
- Niño, A. C., y Vargas, J. S. (2018). *Algoritmo memético para el problema de localización y ruteo de vehículos con ventanas de tiempo en el proceso de recolección de residuos sólidos en el centro de la ciudad de Bucaramanga de la empresa de aseo de Bucaramanga-EMAB*. (Tesis de pregrado). Universidad Industrial de Santander, Colombia.
- Niño, A. F. (2017). *Estudio del problema de ruteo de vehículos de dos escalones*. (Tesis de pregrado). Universidad Industrial de Santander, Colombia.
- Organización Panamericana de la Salud [OPS] y Organización Mundial de la Salud [OMS]. (2001). *Logística y gestión de suministros humanitarios en el sector de la salud*. Washington, D.C.: OPS y OMS.
- Perboli, G., Tadei, R., y Vigo, D. (2011). The two-echelon capacitated vehicle routing problem: Models and Math-Based Heuristics. *Transportation Science*, 45(3), 485-449. doi:10.1287/trsc.1110.0368

- Poli, R., Kennedy, J., y Blackwell, T. (2007). Particle swarm optimization. *Swarm Intell*, 1, 33-57. doi:10.1007/s11721-007-0002-0
- Pradhananga, R., Mutlu, F., Pokharel, S., Holguín-Veras, J., y Seth, D. (2016). An integrated resource allocation and distribution model for pre-disaster planning. *Computers & Industrial Engineering*, 91, 229-238. doi:10.1016/j.cie.2015.11.010
- Prodhon, C. (s.f.). *Instances du LRP-2E*. Obtenido de Prodhon:
http://prodhonc.free.fr/Instances/instancesLRP2E_fr.htm
- Programa de las Naciones Unidas para el Desarrollo [PNUD]. (2004). *Informe mundial. La reducción de riesgos de desastres. Un desafío para el desarrollo*. Recuperado de <http://www.bvsde.paho.org/cursodesastres/diplomado/pdf/ReduccionDeRiesgos.pdf>
- Rahmani, Y., Cherif-Khetta, W., y Oulamara, A. (2014). The Two-Echelon Multi-products Location-Routing problem with Pickup and Delivery: Formulation and heuristic approaches. *International Journal of Production Research*, 54(4), 999-1019. doi:10.1080/00207543.2015.1040127
- Rand, G. K. (1976). Methodological choices in depot location studies. *Journal of the Operational Research Society*, 27(1), 241-249.
- Rechenberg, I. (1973). *Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution*. Stuttgart: Frommann-Holzboog.
- Resende, M., y González, J. (2003). GRASP: Procedimientos de búsqueda miopes aleatorizadas y adaptativos. *Revista Iberoamericana de Inteligencia Artificial*, 7(19).
- Rocha, L. B., González, E. C., y Orjuela, J. A. (2011). Una revisión al estado del arte del problema de ruteo de vehículos: Evolución histórica y métodos de solución. *Ingeniería*, 16(2), 35-55. Recuperado de <https://revistas.udistrital.edu.co/ojs/index.php/reving/article/download/3832/5398>
- Ropke, S. (2005). *Heuristic and exact algorithms for vehicle routing problems*. (Tesis de Doctorado). University of Copenhagen, Dinamarca.

- Safeer, M., Anbuudayasankar, S. P., Balkumar, K., y Ganesh, K. (2014). Analyzing Transportation and Distribution in Emergency Humanitarian Logistics. *Procedia Engineering*, 97, 2248-2258. doi:10.1016/j.proeng.2014.12.469
- Samani, M. G., y Hosseini-Motlagh, S.-M. (2017). A Hybrid Algorithm for a Two-Echelon Location-Routing Problem with Simultaneous Pickup and Delivery under Fuzzy Demand. *International Journal of Transportation Engineering*, 5(1), 59-85. doi:10.22119/IJTE.2017.45837
- Sánchez, M. (2000). Optimización Combinatoria. En A. Martín, *Matemáticas del siglo XX: Una mirada en 101 artículos* (págs. 115-120). España: Nivola. Recuperado de <http://www.sinewton.org/numeros/numeros/43-44/Articulo22.pdf>
- Sharif, T. M., y Salari, M. (2015). A GRASP algorithm for a humanitarian relief transportation problem. *Engineering Applications of Artificial Intelligence*, 41, 259-269. doi:10.1016/j.engappai.2015.02.013
- Suarez, O. (2011). Una aproximación a las heurísticas metaheurísticas. *INGE@UAN*, 1(2), 44-51. Obtenido de <http://csifesvr.uan.edu.co/index.php/ingean/article/view/198>
- Tavakkoli-Moghaddam, R., y Raziei, Z. (2016). A New Bi-Objective Location-Routing-Inventory Problem with Fuzzy Demands. *IFAC-PapersOnLine*, 49(12), 1116-1121. doi:10.1016/j.ifacol.2016.07.646
- Tavakkoli-Moghaddam, R., Forouzanfar, F., y Ebrahimnejad, S. (2013). Incorporating location, routing, and inventory decisions in a bi-objective supply chain design problem with risk-pooling. *Journal of Industrial Engineering International*, 9(1). doi:10.1186/2251-712X-9-19
- Tavana, M., Abtahi, A.-R., Di Caprio, D., Hashemi, R., y Yousefi-Zenouz, R. (2017). An integrated location-inventory-routing humanitarian supply chain network with pre- and post-disaster management considerations. *Socio-Economic Planning Sciences*. doi:doi.org/10.1016/j.seps.2017.12.004

- Thomas, A. S., y Kopczak, L. R. (2005). From logistics to supply chain management: the Path forward in the humanitarian sector. *Fritz Institute*, 15, 1-15. Recuperado de <http://www.fritzinstitute.org/PDFs/WhitePaper/FromLogisticsto.pdf>
- Thomas, A., y Mizushima, M. (2005). Logistics training: necessity or luxury? *Forced Migration Review*, 22, 60-61.
- Tomasini, R., y Wassenhove, L. V. (2009). *Humanitarian Logistics*. Basingstoke, Hampshire: Palgrave Macmillan UK. doi:10.1057/9780230233485
- Vahdani, B., Veysmoradi, D., Noori, F., y Mansour, F. (2018). Two-stage multi-objective location-routing-inventory model for humanitarian logistics network design under uncertainty. *International Journal of Disaster Risk Reduction*, 27, 290-306. doi:10.1016/j.ijdr.2017.10.015
- Winker, P., y Gilli, M. (2007). *Heuristic Optimization Methods in Econometrics*. Université de Genève.