



## [221011] Algoritmo genético con consideraciones de horizonte de tiempo en la solución de problemas de inventarios y ruteo

Wilson A. Castelblanco <sup>1 a,c</sup> , María C. García <sup>2 a,c</sup> , Mariana Perilla <sup>3 a,c</sup> , Nicolás Reyes <sup>4 a,c</sup> ,

PhD. Raúl F. Roldán <sup>b,c</sup>

<sup>a</sup>Estudiante de Ingeniería Industrial

<sup>b</sup>Profesor, Director del Proyecto de Grado, Departamento de Ingeniería Industrial

<sup>c</sup>Pontificia Universidad Javeriana, Bogotá, Colombia

---

### Resumen

The logistics costs of large companies in the brewing industry represent about 10% of their income, for this reason, it is a challenge arises to design a distribution plan and inventory management in Colombia. The solution for this problem is based on the development of a genetic algorithm with planning considerations in a time horizon where, based on a linear mathematical model and, comparing the use of it in a heuristic based on this mathematical model. The data used in the Martínez and Pedraza model were taken as a basis, and likewise, the results obtained by instances (small, medium and large), thus, it was possible to quantify the comparison made between models. The model presented uses a genetic algorithm, metaheuristic of continuous improvement that iterates continuously and filters the results in order to find the individual with the best objective function. It is generated from a population that contains individuals built from random data of retailers, warehouse, vehicle type and demand for a certain number of periods. Once the population is built, the objective function is calculated for each one of the individuals in order to rate them with the best fitness score, some of the best individuals pass to be part of the new population, while others must be crossed in order to create a whole new population with the best possible individuals. When the new population is fulfilled, some of the individuals have to mutate, trying to improve their fitness even better to finally give as a result the objective function of the best individual of this population. Simultaneously, Rolling Horizon is considered in a time horizon, where for each iteration the values of the current period are fixed and an adjustment is made in the demand for the remaining periods; In this way, it is guaranteed that the quantity sent to the customer, is as close as possible to the forecast demand for that period and thus, the shortages are reduced. Already, having the initial population with the adjustments made, it begins to evaluate the objective function of each of its individuals in order to build a new population with the best individuals, that is why, of the initial population, only a low percentage passes directly into the new population, while the remaining must be crossed with other chromosomes to improve their target function. Having the new population, these individuals mutate, in order to further improve their objective function. The main purpose of this model was to design a genetic algorithm in order to improve response time by the implementation of Rolling Horizon looking forward the continuous improvement in the model and develop the design of small, medium and big instances to evaluate different retailers, warehouse, type of vehicle and demands. When comparing the results of the model with those of the model of Martínez and Pedraza, we obtained that the code was optimized because an optimal response was given in a shorter time, which varies depending on the instance evaluated. In most cases there is a greater number of missing products compared to those of the model of Martínez and Pedraza, however, in some cases, these missing products are not so significant because as instances increase in size, better results are obtained in the objective function, reaching a solution where, even with the penalty cost for shortages, the value obtained is still better. Finally, the media improvement of the processing time was about 95% in each of the instances.

## 1. Justificación y planteamiento del problema

Según estudios del Departamento Nacional de Planeación (DNP, 2021), para el 2020 en Colombia, la estimación en costos logísticos para las empresas en Colombia fue de un 12,6%, realizada en la Encuesta Nacional Logística del 2020 (ENL), la cual tuvo una participación de 3.383 empresas. Los costos logísticos en las empresas colombianas disminuyeron en un 0,9% en comparación con la encuesta nacional logística realizada en el 2018. Las micro y pequeñas empresas aumentaron sus costos, destinando más del 24%. Por otro lado, las grandes y medianas empresas disminuyeron sus costos en comparación con la ENL 2018, destinando alrededor del 10% de sus ingresos a los costos logísticos, donde se encuentra categorizada la empresa de la industria cervecera la cual se utiliza en este proyecto. La posibilidad de definir un programa de distribución dentro de una empresa de la industria cervecera en Colombia es uno de los grandes retos, ya que debe permitir la correcta gestión de los recursos de su cadena de suministros, ya sean los inventarios disponibles o la distribución para suplir la demanda teniendo en cuenta la flota de transporte. Es necesario que haya una conexión entre los diferentes eslabones de la cadena para cumplir con los estándares requeridos por el mercado, garantizando la rentabilidad del negocio por medio de la minimización de costos. La posibilidad de definir un programa de distribución dentro de una empresa de la industria cervecera en Colombia es uno de los grandes retos, ya que debe permitir la correcta gestión de los recursos de su cadena de suministros, ya sean los inventarios disponibles o la distribución para suplir la demanda teniendo en cuenta la flota de transporte. Es necesario que haya una conexión entre los diferentes eslabones de la cadena para cumplir con los estándares requeridos por el mercado, garantizando la rentabilidad del negocio por medio de la minimización de costos.

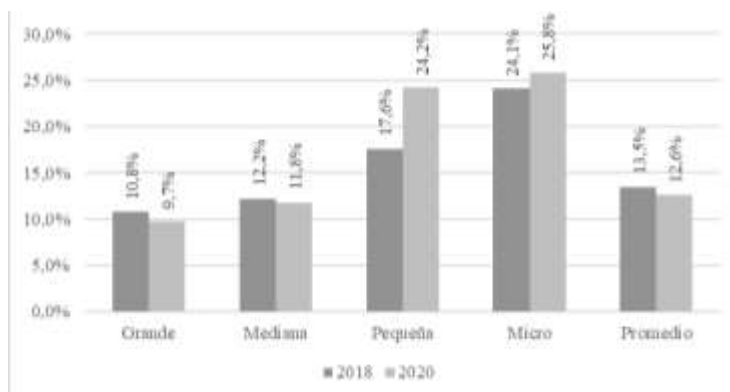


Figura 1. Costo logístico por tamaño de empresa. Tomado de: (ZonaLogística, 2020)

Teniendo en cuenta el artículo de una solución para una cadena de suministro aplicado a la industria cervecera, se presenta el modelo propuesto, el cual resuelve la gestión de una cadena de suministro que integra decisiones de la ruta de transporte, en este caso, para una empresa de la industria cervecera colombiana, con asignación de vehículos en sus diferentes puntos de distribución con decisiones de niveles de inventarios en los nodos de la red (Pedraza & Martínez, 2021). El objetivo del problema es minimizar el costo generado por la cadena de abastecimiento donde se calcula para cada periodo la cantidad necesaria teniendo en cuenta una demanda pronosticada y una demanda real ejecutada. En la figura No. 2 se presenta el esquema del problema que se quiere resolver, se identifican dos eslabones: plantas (suppliers) y mayoristas (retailers) y se busca establecer los rangos que se presentan en la demanda por parte de los mayoristas implicados para así, tener datos concretos que permitan reducir las cantidades de inventario y de transporte para satisfacer las necesidades del cliente, favoreciendo a la empresa al minimizar los costos de transporte e inventario.

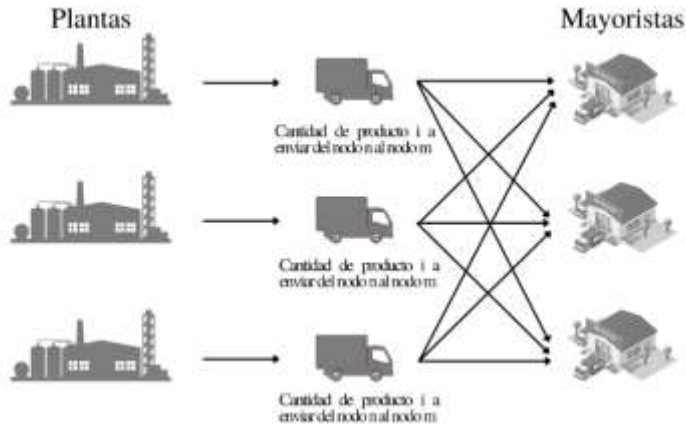


Figura 2. Modelo del problema de cadena de abastecimiento del problema propuesto. Elaboración propia.

En el mercado actual, existe una alta competencia como la fluctuación de la demanda, por esto, existen niveles de variación. Esto se ve reflejado en las decisiones de producción y logística en cada nodo de la cadena de abastecimiento. Mediante estas decisiones, se debe definir el nivel adecuado de inventarios, lo que le permite a la empresa reducir costos, generar ganancias y tener información clara sobre sus demandas. Para realiza dichas acciones, se debe tener claro las políticas de inventario, las cuales están relacionadas con las cantidades que se debe enviar a cada eslabón de la cadena de suministro en diferentes periodos de tiempo dentro de un horizonte de tiempo predefinido. Ahora bien, uno de los mayores desafíos a afrontar es la correcta toma de decisión en cuanto a la capacidad y cantidad de vehículos que serán utilizados para suplir la demanda de los clientes.

Una empresa debe contar con una planificación adecuada de los niveles de inventario para garantizar su éxito, para ello, es necesario determinar la estrategia logística donde se evalué el costo de oportunidad de la venta por demanda insatisfecha. Principalmente en la industria cervecera, esto se refiere al cumplimiento del nivel de servicio sobre la oferta de valor, donde se vela por cumplir con las políticas de venta asociadas a la distribución de un producto en el mercado altamente competido. Según la Encuesta Nacional Logística de 2020, el 56% de las empresas colombianas cuentan con flota propia, creciendo en más de 33 puntos porcentuales con respecto al 2018. Además, más del 50% de las empresas en todos los sectores a excepción del sector de la minería cuentan con flota propia. En el 2018, se logró evidenciar el porcentaje de empresas que contaba con flota propia era directamente proporcional al tamaño de la empresa, ya que el 53,3% de las empresas grandes contaban con su flota a diferencia del 21,3% de las microempresas que contaban con flota propia. En el 2020 se evidencia que esta proporcionalidad ya no se cumple, donde el 70,7% de las medianas empresas cuentan con flota propia, seguidas por las pequeñas empresas, las grandes empresas y por ultimo las microempresas, sin embargo, estas crecieron en 33,6 puntos porcentuales.

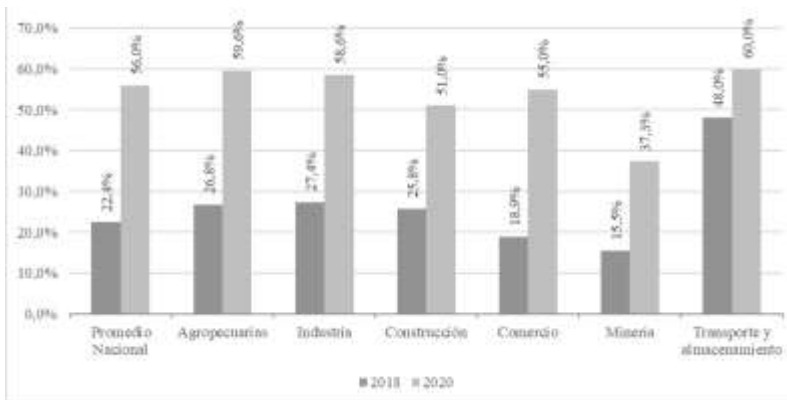


Figura 3. Empresas que cuentan con flota logística por actividades económicas. Tomado de (Zona Logística, 2020)

En síntesis, el problema que se va a abordar en este proyecto consiste en la optimización de un problema de inventario y ruteo aplicado a la industria cervecera en Colombia, con el fin de minimizar los costos relacionados con el transporte de productos y el almacenamiento de estos a partir de la solución obtenida por medio del algoritmo genético, del cual se espera obtener tiempos de ejecución razonables. Lo anterior debido a que las empresas suelen invertir gran parte de sus ingresos a los costos relacionados con la logística de gestión de inventarios y distribución. Se definirá la cantidad total de producto a suministrar desde cada planta a cada mayorista teniendo en cuenta la capacidad de inventario de cada uno de ellos, además la cantidad de producto a enviar en cada vehículo de la flota teniendo en cuenta la capacidad de cada uno de ellos.

En este proyecto se abordará la siguiente pregunta de investigación: mediante la solución planteada en el documento *“Modelo de solución para una cadena de suministro con flota heterogénea aplicado a la industria cervecera utilizando Rolling Horizon”* (Pedraza & Martínez, 2021) para garantizar la minimización de los costos logísticos, la eficiencia de traslados y las capacidades de los centros de distribución ¿se puede encontrar una solución factible en un tiempo razonable para la planeación de inventario y de ruteo en el contexto de la industria cervecera por medio del uso de la metaheurística. Para dar respuesta a la pregunta planteada se tiene acceso al modelo de optimización lineal desarrollado por Martínez y Pedraza. Luego, se realizará una metaheurística y se compararan los resultados obtenidos con el modelo de optimización lineal.

## **2. Antecedentes**

Por medio de la revisión de los antecedentes se identificaron 6 temas principales: problemas de inventario y ruteo (IRP), problemas de ruteo de vehículos (VRP), sistemas de inventario administrado por proveedores (VIM), algoritmo genético (GA), Rolling Horizon y cantidad económica de pedido (EOQ). Dado que el principal problema logístico a resolver consiste en la gestión inventario, para esto, se inspecciona los temas de IRP y VRP. Las políticas de inventario nos permiten identificar las cantidades que deben ser abastecidas, por esto se revisaran las políticas EOQ y VIM. Después, se continua con la forma en que se va a programar el ruteo por medio del VRP y, por último, abordaremos los diferentes elementos para solucionar el problema de inventario y de ruteo utilizando la metaheurística de algoritmo genético con Rolling horizon.

Para la selección y entendimiento de la metaheurística que se va a implementar para resolver el modelo de inventario y de ruteo, se realiza la revisión bibliográfica permitiente, con el fin de ampliar los conceptos que van a ser implementados a lo largo del proyecto. Se tendrá en cuenta la tesis de maestría de Ingeniería Industrial *“Modelo de solución para una cadena de suministro con flota heterogénea aplicado a la industria cervecera utilizando Rolling horizon”* (Pedraza & Martínez, 2021) y la tesis de doctorado *“A hybrid genetic algorithm for a dynamic and stochastic multi-depot inventory-routing problem”* (Roldan, Basagoiti, & Cohelo, 2016). La primera corresponde a una solución de “problemas de ruteo de la industria cervecera colombiana, sometidos a restricciones temporales de servicio y de un conjunto de técnicas aplicadas a un modelo matemático y a Rolling Horizon” (Pedraza & Martínez, 2021). Por otra parte, el tema de la tesis de doctorado corresponde al análisis de sistemas de distribución en los cuales las plantas disponen de diferentes depósitos y flotas heterogéneas y los clientes presentan una demanda dinámica.

Los problemas de inventario y ruteo (IRP) se basan en conocer la demanda de los consumidores y distribuir los recursos con una planeación geográfica que muestra la ruta que mejor se adapta al problema (Campbell, Clarke, & Savelsbergh, 2002). Este tipo de problemas de ruteo surgen cuando las decisiones de inventario y ruteo se deben tomar en simultaneo, por lo que deben ser modelados como un problema de optimización muy complejo (Siswanto, Essam, & Sarker, 2011). Se pretende simular una problemática real que tiene lugar en la industria cervecera en Colombia, donde las decisiones de inventario y rutas de vehículos se toman en simultaneo teniendo en cuenta el periodo de tiempo requerido. El problema del inventario se vuelve complejo al manejar productos que requieren rotación en el inventario (Azadeh & et al., 2016). El IRP surge como una estrategia de distribución rentable ya que antes de que surgiera este modelo de enrutamiento para inventarios, no había cohesión en el óptimo ya que este se evaluaba entre áreas, es decir, el óptimo de cada área se utilizaba como

dato de entrada y salida para poder calcular el del área continua ( (Jianxiang, Feng, & Haoxun, 2010); (Avici & Topaloglu, 2009)).

Los problemas de ruteo de vehículos (VRP), junto con los problemas de inventario y ruteo (IRP) son utilizados para reflejar cierta calidad en el servicio prestado al entregar los productos, ya que ofrecen la minimización de sus costos al entregar la mercancía siguiendo la mejor ruta posible, en el tiempo adecuado, cumpliendo con todos los requisitos necesarios (Avici & Topaloglu, 2009). En la industria militar, el enrutamiento de vehículos ha sido analizado ya que este utiliza un enfoque de programación dinámica mediante la re-optimización del sistema a través de las actualizaciones de información (Margolis, Song, & Mason, 2022). En una investigación sobre una metaheurística híbrida para enrutamiento de carretera en redes, se menciona la importancia de los problemas de ruteo de vehículos, ya que muchos de los métodos de ruteo ya existentes como lo son vecino más cercano, Dijkstra, etc., no logran garantizar el correcto funcionamiento del modelo cuando éste se vuelve más robusto, por lo cual surge la necesidad de realizar una metaheurística que logre recopilar las mejores características de cada método y así, obtener el óptimo del sistema (Dib, Manier, & Caminada, 2015).

El sistema de inventario administrado por el proveedor (VIM) es aquel en el que el proveedor supervisa los niveles de inventario de los minoristas y toma decisiones de reposición. Esto, trae muchos beneficios tanto para el proveedor como para el minorista ( (Cohelo & Laporte, 2012) ; (Avici & Topaloglu, 2009)). En un entorno de VIM, es fundamental la correcta implementación de IRP, la idea de esta idea de administración centralizada por el proveedor es que estos obtengan acceso directo a las posiciones de inventario de los clientes y tomen las decisiones de reposición necesarias (Tamer & et al., 2006). En un artículo sobre la optimización del costo total de la cadena de suministro en el problema de enrutamiento de ubicación de inventario, se utilizan el VIM, el cual se adapta e integra a el problema de enrutamiento de ubicación de inventario (LIRP), de este modo se desarrolla una heurística para determinar las cantidades de entrega a cada cliente y la frecuencia de entrega (Safi-Eddine, El-Beheiry, & El-Kharbotly, 2018).

Se ha desarrollado algoritmos exactos y aproximados para resolver un problema. Comúnmente un algoritmo exacto encuentra la solución óptima para un problema, pero tiene la desventaja de que los tiempos de cálculo son muy largos para ser usados. Se han desarrollado los algoritmos aproximados los cuales pueden encontrar una solución cercana a la óptima rápidamente, a estos se les clasifica en heurística y metaheurística. La heurística sigue las características del problema para construir el algoritmo, pero se vuelven menos eficaces y en algunos casos inaplicable cuando se agregan las restricciones adiciones al algoritmo. Para mitigar esto se crea la metaheurística, las cuales se basan en diferentes características de las heurísticas, creando algoritmos genéticos para encontrar soluciones casi optimas en un tiempo de cálculo aceptable a diferencia de las heurísticas y los algoritmos exactos. En un artículo sobre unas metaheurísticas híbridas para resolver un problema de enrutamiento y programación de atención médica domiciliaria con ventanas de tiempo, se plantean una metaheurística de ruteo basada en una combinación de un algoritmo genético (GA) y la heurística Búsqueda de Vecindad Variable (VNS) para calcular el camino más corto en un camino de carreteras encontrando una solución cercana a la óptima en milisegundos (Dib, Manier, & Caminada, 2015). El artículo de una metaheurística para resolver problemas de ruteo y simultáneamente servicio puerta a puerta de correspondencia, se propone una metaheurística de dos pasos para resolver VRP con recogidas y entregas simultaneas usando en el primer paso se usa Colonia de Abejas Artificiales (ABC) y en una segunda instancia se aplica Optimización de Colonias de Abejas (BCO) encontrando mejores valores de la función objetivo que el GA en menos iteraciones (Marinelli & et al., 2019).

*Rolling Horizon* se basa en dividir el horizonte de programación del problema principal con un horizonte de largo plazo en una secuencia de subproblemas con horizontes de tiempo más cortos donde en cada uno de estos subproblemas solo se resuelve en detalle una parte del problema (Hanczar & Kaleta, 2016) Pedraza y Martínez plantean un modelo basado en *Rolling Horizon* para la planificación de la distribución de vehículos con un plan de entrega el cual se actualiza cada periodo y se modifica de manera dinámica en el tiempo (Pedraza & Martínez, 2021). Se plantea un modelo para solucionar el problema de enrutar dinámicamente una flota de vehículos

encargados de vigilar un conjunto de objetivos sobre una colección de puntos de referencia usando programación estocástica basada en Rolling horizon ( (Margolis, Song, & Mason, 2022); (AIMMS, 2021)). Se plantea un método heurístico de la ruta más larga basado en horizonte de tiempo para maximizar la utilización de una aeronave antes de las intervenciones de mantenimiento después de una cantidad de horas de vuelo logrando planificar los vuelos de una semana entre 2 y 7 minutos (Afsar, Espinouse, & Penz, 2006).

Existen distintas políticas de inventario las cuales son necesarias para diseñar una estrategia que permita el buen manejo de los recursos y la calidad de ellos, donde a su vez logre minimizar costos de mantenimiento, es por esto que es necesario contar con un modelo matemático o probabilístico al momento de administrar dichos inventarios ya que permiten conocer cuándo y cuánto hay que pedir de acuerdo al comportamiento de la demanda en un período de tiempo (Pulido & et al., 2020) como lo es la cantidad económica de pedido (EOQ), el cual es un modelo matemático para el control de inventarios en los sistemas de producción (Lui, Hendalianpour, & Hamzehlou, 2021) ya sea para diferentes nodos o eslabones de la cadena de suministro, y así mismo busca bajar el costo de ordenar y de mantenimiento del mismo. Otra política implementada es el POQ quien promueve una mejora en términos de colocación de órdenes, reducción de inventarios y reducción de ajustes sobre los pronósticos (D'Avino, Marco, Bregni, Alfredo, & Schitaldi Massimiliano, 2013).

Se busca minimizar los gastos de la cadena de suministro de la industria cervecera, a través de decisiones y planes estratégicos. Los costos de inventario pueden tener un impacto significativo en la configuración óptima de la cadena de suministro y en la expansión o contracción de los sistemas de distribución (Bolaños & Vidal, 2020), el inventario permite a la industria cumplir con la demanda total en los tiempos establecidos, los cuales representa una oportunidad para controlar costos y tomar decisiones estratégicas. El exceso de inventarios ya que aumentan considerablemente los costos de almacenamiento y mantenimiento (Pulido & et al., 2020). Es necesario realizar pronósticos sobre la demanda en un periodo de tiempo. Una de las estrategias utilizadas en las políticas de inventario es tener una reserva, al final de cada período de tiempo, un porcentaje específico de la demanda esperada del próximo período de tiempo y así minimizar costos (Bolaños & Vidal, 2020). Dichas decisiones deben ser tomadas con el objetivo de implementar estrategias que permitan la correcta gestión de inventarios y distribución a menor costo posible.

La gestión de la cadena de suministro es un conjunto de enfoques utilizados para integrar de manera eficiente a los proveedores, fabricantes, almacenes, y tiendas para que la mercancía se produzca y se distribuyan correctamente, minimizando los costos del todo sistema y brindarle un excelente servicio al cliente. Durante dicha gestión se genera un flujo de información, bienes y servicios (Hosseini, Taghi, & Hamid, 2014). El principal impacto que genera la cadena de suministros es en el desempeño financiero de las organizaciones (Fahimnia, Luong, & Marian, 2011). La planificación agregada tanto de producción como de distribución genera un plan agregado para tiempo regular, horas extras, contratación y despido, teniendo en cuenta el óptimo funcionamiento del proceso.

### **3. Objetivos**

*Diseñar una metaheurística para obtener una solución factible de la minimización de costos de inventario y de ruteo para una industria cervecera.*

- Formular el modelo matemático para el problema de inventario y de ruteo con multi depósito y flota heterogénea, generando diferentes instancias de prueba (pequeñas, medianas y grandes) que reúnan las características del problema.
- Diseñar un algoritmo genético que permita obtener una solución factible para cada una de las instancias de prueba.
- Contrastar los resultados del modelo matemático de cada una de las instancias con los resultados de la metaheurística, mediante el tiempo límite para obtener soluciones factibles.

#### 4. Metodología

Con el fin de llevar a cabo el proyecto, se hizo una revisión general de cada una de las instancias suministradas por Martínez y Pedraza como resultado de su documento “*Modelo de solución para una cadena de suministro con flota heterogénea aplicado a la industria cervecera utilizando Rolling Horizon*” (Pedraza & Martínez, 2021) en estos archivos fue posible encontrar los datos de entrada utilizados y de igual manera, los datos de salida o resultados obtenidos después del procesamiento de información. Los datos fueron clave para el desarrollo del proyecto, ya que la misma información de entrada fue utilizada en este proyecto y, los resultados fueron utilizados para llevar a cabo el análisis y poder tener la certeza de definir el rendimiento del algoritmo al compararlos.

##### 4.1. Modelo matemático lineal

<b>Conjuntos</b>	
$V_d$	Warehouse
$V_c$	Clientes
P	Horizonte de planeación t
H	Tipo de transporte
<b>Parámetros</b>	
$C_{ij}$	Costo de transporte de acuerdo a matriz de distancias
$Q_h$	Capacidad del vehículo h
$v_{ih}$	Número de vehículos del tipo h disponibles para el warehouse i
$F_{ij}$	Costo fijo por uso del vehículo
$I_i^t$	Inventario del warehouse i en el periodo t
$d_i^t$	Demanda del cliente i en el periodo t
$r_i^t$	Cantidad producida por el warehouse i en el periodo t
$U_i$	Capacidad máxima de inventario en el warehouse i
$u_{ij}$	Carga del camión
$h_i$	Costo de mantener inventario
$z_i$	Penalización por desabastecimiento en los clientes
$l_i^t$	Demanda pedida por el cliente i
<b>VARIABLES DE DECISIÓN</b>	
$x_{ijh}^{dt}$	Variable binaria para identificar si se utilizó un vehículo h para despachar producto desde el warehouse d en el periodo t
$y_{ih}^{dt}$	Variable binaria para identificar si el cliente i fue visitado por el vehículo h perteneciente al warehouse d en el periodo t

$q_i^t$	Cantidad de producto entregado al cliente $i$ en el periodo de tiempo $t$
---------	---

**Tabla 1. Conjuntos, parámetros y variables de decisión**

Función objetivo:

*Minimize* ( $\iota CO + \tau CO + \nu CO$ )

Que se compone de la suma del costo de mantener inventario, costos de trayecto y costo de vehículos respectivamente, donde:

$$\iota CO = \sum_{t \in P} \sum_{i \in V} h_i I_i^t + \sum_{t \in P} \sum_{i \in V_c} z_i l_i^t$$

Donde se representa el costo de mantener el inventario y el costo de penalización por el desabastecimiento de los proveedores, calculada a partir de la demanda pedida por el cliente.

$$\tau CO = \sum_{t \in P} \sum_{i \in V} \sum_{j \in V} \sum_{h \in H} \sum_{d \in V_d} c_{ij} x_{ijh}^{dt}$$

Se encuentra el costo de trayecto, basado en una matriz de distancias, dependiendo si éste es utilizado o no.

$$\nu CO = \sum_{t \in P} \sum_{i \in V_c} \sum_{h \in H} \sum_{d \in V_d} F_{dh} x_{dih}^{dt}$$

Por último, el costo de utilización de vehículo dependiendo del tipo si éste fue utilizado.

Ecuaciones de niveles de inventario y carga de transporte:

$$I_i^0 = S_i \quad i \in V$$

El nivel de inventario para los clientes y warehouse en el periodo 0 deben ser iguales al stock de seguridad.

$$I_i^t = I_i^{t-1} + r_i^t - \sum_{j \in V_c} u_{ji}^{t-1} \quad i \in V_d, j \in V_c, t \in P$$

El nivel de inventario se define con la cantidad de inventario del periodo final más la cantidad de producto disponible menos la capacidad de carga del vehículo del periodo anterior.

$$I_i^t \geq \sum_{j \in V_c} u_{ji}^{t-1} \quad i \in V_d, j \in V_c, t \in P$$

El nivel de inventario debe ser mayor que la carga del vehículo del periodo anterior.

$$I_i^t = I_i^{t-1} + q_i^t - d_i^t + l_i^t \quad i \in V_c, t \in P$$

El nivel de inventario es actualizado al evaluar el nivel de inventario del periodo anterior más la cantidad de producto entregada al cliente menos la demanda real más las unidades de demanda no atendida que hay para el periodo en curso.

$$\begin{aligned} I_i^t &\geq 0 & i \in V, t \in P \\ L_i^t &\geq 0 & i \in V_c, t \in P \end{aligned}$$



Las restricciones para el nivel de inventario y carga de transporte garantizan la no negatividad.

Restricciones de ruteo y vehículos:

$$\sum_{h \in H} \sum_{d \in V_d} y_{ih}^{dt} \leq 1 \quad i \in V_c, t \in P$$

Cada cliente puede ser visitado máximo una vez en el mismo periodo.

$$y_{ih}^{dt} \leq y_{dh}^{dt} \quad i \in V_c, h \in H, d \in V_d, t \in P$$

Y ese cliente debe ser visitado por el vehículo h perteneciente al warehouse d.

$$y_{dh}^{dt} \leq \sum_{i \in V} \sum_{j \in V} x_{ijh}^{dt} \quad h \in H, d \in V_d, t \in P$$

$$2y_{dh}^{dt} \leq \sum_{i \in V_c} x_{jdh}^{dt} + \sum_{j \in V_c} x_{jdh}^{dt} \quad h \in H, d \in V_d, t \in P$$

Cada cliente debe ser atendido por un vehículo, por lo que no es posible utilizar un vehículo si no atiende por lo menos a un cliente y, además, el vehículo debe salir y retornar al mismo warehouse.

$$\sum_{d \in V_d} \sum_{h \in H} \sum_{j \in V_c} x_{ijh}^{dt} \leq 1 \quad i \in V_c, t \in P, i \neq j$$

$$\sum_{d \in V_d} \sum_{h \in H} \sum_{j \in V_c} x_{jih}^{dt} \leq 1 \quad i \in V_c, t \in P, i \neq j$$

Cada cliente puede ser visitado solo una vez en cada periodo.

$$\sum_{j \in V} x_{ijh}^{dt} + \sum_{j \in V} x_{jih}^{dt} = 2y_{ih}^{dt} \quad j \in V, h \in H, d \in V_d, t \in P$$

$$\sum_{i \in V} x_{ijh}^{dt} = \sum_{i \in V} x_{jih}^{dt} \quad j \in V, h \in H, d \in V_d, t \in P$$

Se garantiza que haya continuamente un flujo en donde constantemente hay cantidades de producto despachadas.

$$\sum_{i \in V_c} \sum_{d \in D} x_{ijh}^{dt} \leq v_{jh} \quad h \in H, j \in V_d, t \in P$$

$$\sum_{i \in V_c} \sum_{d \in D} x_{jih}^{dt} \leq v_{jh} \quad h \in H, j \in V_d, t \in P$$

Se debe respetar la cantidad de vehículos de cada tipo que hay disponibles para cada warehouse.

$$x_{ijh}^{dt} = 0 \quad i \in V_c, j \in V_d, j \neq d, h \in H, d \in V_d, t \in P$$

$$x_{jih}^{dt} = 0 \quad i \in V_d, j \in V_c, i \neq d, h \in H, d \in V_d, t \in P$$

$$x_{ijh}^{dt} = 0 \quad i \in V_d, j \in V_d, h \in H, d \in V_d, t \in P$$

Cada vehículo que sale de un depósito d, debe regresar al mismo depósito d.

$$x_{ijh}^{dt} \in 0,1 \quad i, j \in V, h \in H, d \in V_d, t \in P$$

$$y_{ih}^{dt} \in 0,1 \quad i \in V, h \in H, d \in V_d, t \in P$$

El dominio de las variables binaria se establece en estas dos restricciones.

Restricciones de inventario:

$$q_i^t \leq U_i \sum_{h \in H} x_{ijh}^{dt} - I_i^t \quad i \in V_c, h \in H, t \in P$$

$$q_i^t \leq (U_i - I_i^{t-1}) \quad i \in V_c, t \in P$$

$$q_i^t \leq U_i \quad i \in V_c, t \in P$$

Se asegura que la cantidad entregada por el vehículo de un depósito al cliente i en el periodo t suplirá el requerimiento, sin embargo, si no se cumple, este será 0.

$$I_i^t \leq U_i \quad i \in V_c, t \in P$$

El nivel de inventario no debe sobrepasar la capacidad de carga del vehículo.

Restricciones de carga y capacidad de transporte:

$$u_{ij}^t \leq \sum_{h \in H} \sum_{d \in V_d} Q_h x_{ijh}^{dt} \quad i \in V, j \in V_c, t \in P$$

Según el tipo de vehículo que se utiliza, se debe restringir la capacidad de carga.

$$\sum_{i \in V} u_{ij}^t - \sum_{i \in V} u_{ij}^t = q_j^t \quad t \in P$$

$$\sum_{i \in V_d} \sum_{j \in V_c} u_{ij}^t = \sum_{j \in V_c} q_j^t \quad t \in P$$

Se debe garantizar que se realice una única ruta en donde la carga total que sale del warehouse se debe ser igual a los despachos totales a los clientes.

$$u_{ij}^t \geq 0 \quad i \in R, j \in V, t \in P$$

Se garantiza la no negatividad para la carga de los vehículos.

## 4.2. Rolling Horizon

Es un método iterativo que permite buscar una mejora continua dentro del modelo mediante la fijación de los datos de instancias anteriores. En la figura 4, se encuentra de manera gráfica cómo se implementa este método. Previamente se ha pronosticado una demanda para los clientes en cada uno de los periodos, además se conoce el inventario inicial del primer periodo, gracias a ello, es posible calcular la cantidad de estibas a enviar a cada cliente cada periodo durante el horizonte de tiempo planeado, luego, se envía el pedido calculado para cada cliente en el primer periodo. Al finalizar el primer periodo se conoce la demanda real de cada cliente en este mismo, por lo que es posible actualizar el inventario de cada uno de ellos. En el siguiente periodo se actualizan las estibas a enviar a cada cliente durante ese periodo y posteriores, gracias a la actualización del inventario final conociendo la demanda real del periodo anterior. El pedido a enviar a cada cliente en cada periodo se actualiza al inicio de un nuevo periodo teniendo en cuenta la demanda real conocida del periodo anterior.

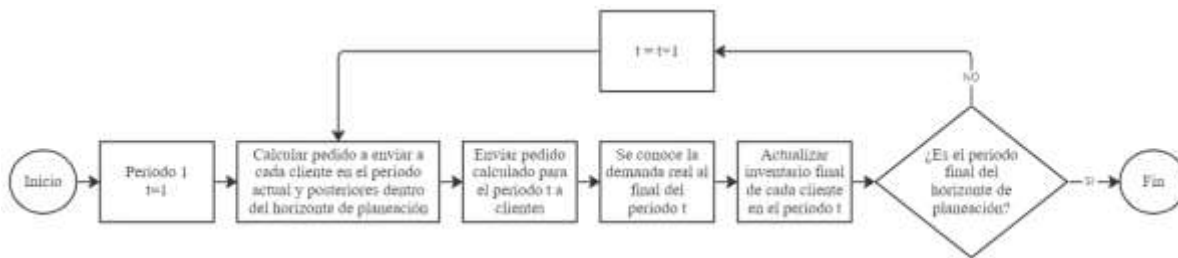


Figura 4. Diagrama de flujo del Rolling Horizon. Elaboración propia

Para realizar la actualización de inventario se utilizan las ecuaciones planteadas en el modelo matemático:

$$I_i^t = I_i^{t-1} + q_i^t - d_i^t + l_i^t \quad i \in V, t \in P$$

$$I_i^t \geq 0 \quad i \in V, t \in P$$

El inventario final de un cliente en el periodo actual es el inventario inicial del cliente en el periodo más la cantidad de estibas enviadas (el valor mínimo entre la demanda pronosticada más el inventario mínimo permitido menos el inventario inicial de ese periodo y, la capacidad del camión) y restarle la demanda real que se presenta en ese periodo. En caso de presentarse algún tipo de faltantes, esto afecta la función objetivo, ya que existe una penalización por el no abastecimiento. Sin embargo, los faltantes no serán tenidos en cuenta para la demanda del periodo siguiente ya que se manejan ventas perdidas. Al inventario final se le suma la demanda no atendida con el fin de que la función no presente resultados negativos, ya que existe una restricción de no negatividad.

Con el fin de entender de manera detallada cómo fue implementado el Rollin Horizon dentro del algoritmo genético para la solución de problemas de ruteo e inventario, se presenta en la Figura No. 5 la explicación gráfica. Primero, es necesario tener en cuenta la estructura de cromosoma que se maneja, en donde cada gen del cromosoma contiene: cliente, warehouse, tipo de transporte y demanda. De este modo, el número de iteraciones corresponde al número de periodos con los que se cuenta; en la primera iteración, de manera aleatoria, se asigna el warehouse y el tipo de vehículo que se usara para atender cada cliente en cada periodo, después en la segunda iteración, se fijan los valores calculados en el primer periodo y se actualiza el inventario de los periodos siguientes, con el fin de minimizar los costos y evitar en lo posible las penalizaciones por desabastecimiento. Este paso se repite en cada iteración fijando los datos del periodo anterior a la iteración y actualizando los valores consecutivos.




Figura 5. Diagrama de Rolling Horizon. Elaboración propia

### 4.3. Algoritmo genético

Al iniciar el algoritmo genético se crea una población inicial de 100 individuos de manera aleatoria con consideraciones de rolling horizon. Cada individuo está compuesto por el cliente a visitar en cada periodo, el warehouse desde el cual se visita, el tipo de carro usado y el pedido a enviar al cliente como se muestra a continuación.

Variable	Descripción
C	Cliente que atiende
Wh	Warehouse que atiende
Tc	Tipo de carro usado
P	Pedido a enviar al cliente

Tabla 2. Variables del algoritmo genético. Elaboración propia.

El periodo 1 del individuo 1 de una instancia de 5 clientes está representado en la tabla 3, donde el cliente 1 es visitado desde el warehouse 1 con el tipo de carro 2 y se envían 20 estibas de cerveza, y de esta manera para todos los 5 clientes que son visitados en el periodo 1, así mismo, para los periodos siguientes como se representa en la tabla 4.

	Periodo 1																			
	C	Wh	Tc	P	C	Wh	Tc	P	C	Wh	Tc	P	C	Wh	Tc	P	C	Wh	Tc	P
Individuo 1	1	1	2	20	2	2	1	30	3	1	1	28	4	2	1	16	5	2	2	27


Tabla 3. Información del periodo 1 del Individuo 1. Elaboración propia.

Individuo 1	Periodo 1	Periodo 2	Periodo 3	Periodo 4	Periodo 5
-------------	-----------	-----------	-----------	-----------	-----------

Tabla 4. Información de los periodos del individuo 1. Elaboración propia.

La palabra ruteo es utilizada con el fin de hacer referencia al trayecto definido por los cromosomas, en donde se realiza una ruta de uno a uno, identificada por el número de warehouse que abastece y el cliente por el que es visitado, como se observa en la Tabla 3, es decir, se realiza la asignación de los vehículos para cumplir con el pedido del cliente. Cabe recalcar que la flota es heterogénea, diferenciada por la capacidad de los vehículos, este parámetro está ligado a la capacidad que poseen los camiones en la actualidad en Colombia.

Para cada uno de los individuos se calculan los costos correspondientes a la función objetivo (costos de mantener inventario, costos de trayecto, costos de transporte y costos de penalización) para cada uno de los cromosomas de la población inicial. Por medio de un operador de torneo, se selecciona el 10% de los individuos con mejor fitness y estos pasan a la siguiente población. Luego, en el proceso de cruce se seleccionan aleatoriamente de la población actual 2 individuos de los cuales quien tenga el mejor fitness será el padre, este proceso se repite para seleccionar la madre, y con una probabilidad del 75%, el padre y madre se cruzan de manera aleatoria (se encuentra un punto de corte en el cromosoma de manera aleatoria y, se intercambian las partes cortadas), generando dos individuos hijo, los cuales pasan a formar parte de la nueva población, si los padres no se cruzan, pasaran a la siguiente población. Como se observa en la Figura No. 6, se presenta un ejemplo en el que hay dos cromosomas que se comparan para ser padre y dos cromosomas que se comparan para ser madre. Se seleccionan aquellos que tienen un valor fitness menor, en este caso el padre 1 y la madre 2 y de manera aleatoria se cruzan. Del cruce salen dos cromosomas hijos de los cuales se espera que se obtenga un mejor fitness. Antes de agregar los cromosomas hijos a la nueva generación, se debe garantizar que no se usen más de los vehículos disponibles en cada warehouse, dado el caso en que algún cliente sea visitado por un vehículo que no esté disponible en el warehouse, se asigna otro tipo de vehículo, y si todos los vehículos del warehouse ya fueron usados, este cliente será visitado desde otro warehouse que tenga vehículos disponibles. En síntesis, si un cliente tiene asignado un tipo de vehículo que ya no tenga vehículos disponibles, se debe buscar un tipo de vehículo de este warehouse que tenga disponibilidad para atender a este cliente, dado el caso en que no se tenga disponibilidad de vehículos, se busca un warehouse que tenga algún tipo de vehículo con disponibilidad para atender a este cliente. Este proceso de cruce se repite hasta que la nueva población tenga en mismo tamaño de la población actual.



**Figura 6. Ejemplo de cruce. Elaboración propia.**

Todos aquellos individuos que hacen parte de la nueva población mutan de manera aleatoria con el 5% de probabilidad, en donde los valores del individuo son modificados buscando una mejora en la función objetivo. Una vez se haya terminado el proceso de mutación, se calcula el fitness de cada individuo de la nueva población y se selecciona aquel con el costo más bajo, donde este es la mejor solución factible de esa población. Si la mejor solución factible es la misma durante 100 iteraciones consecutivas, el algoritmo genético se detiene, de esta manera es posible obtener tiempos de respuesta efectivos. En la figura 7 se presenta el diagrama de flujo del algoritmo genético implementado.

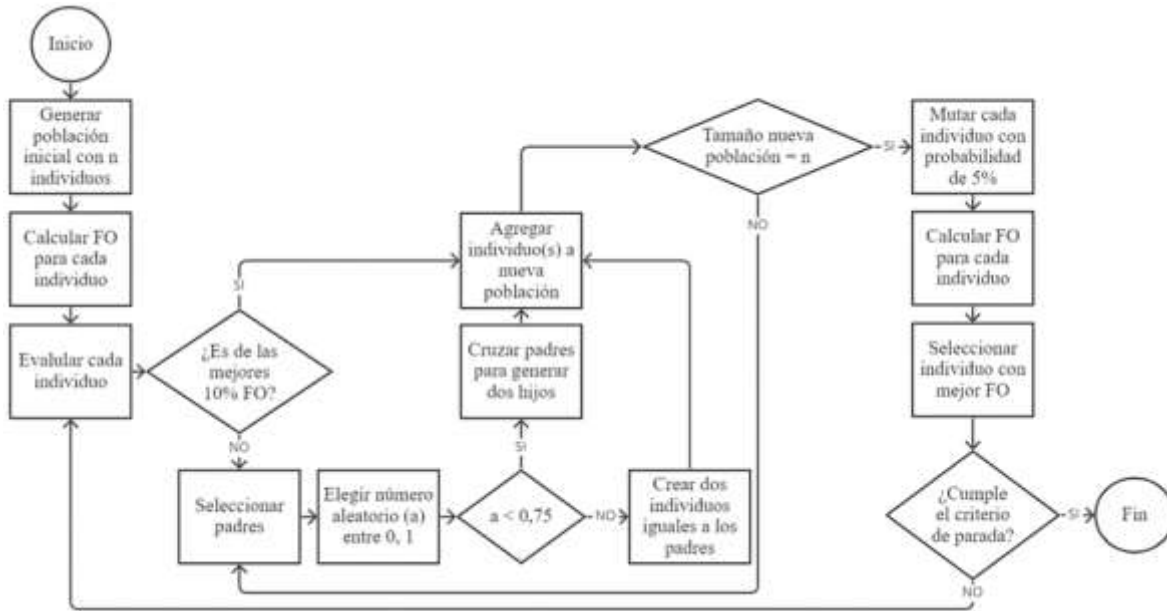


Figura 7. Diagrama de flujo algoritmo genético. Elaboración propia.

Este algoritmo genético se realiza en el lenguaje de programación Python, ejecutado en el servicio en la nube de Google Colaborate en donde se utilizaron las librerías de pandas, numpy, random, openpyxl y heapq con el fin de utilizar sus funciones para la construcción del algoritmo genético. Estas librerías tienen diferentes funciones en donde, cuando se llaman en el código, internamente realizan funciones complejas. Por ejemplo, pandas, es una librería especializada en el análisis de datos, donde permite acceder a filas y columnas de una hoja de Excel (Aprende con Alf, 2022). Por otra parte, numpy permite generar objetos de matriz multidimensional en donde permite generar arreglos y una variedad de operaciones rápidas entre matrices (Numpy, 2022). Adicionalmente, la librería de openpyxl permite leer y guardar la información generada en diversos archivos de Excel (xlsx, xlsxm, xlsx, xlsxm), permite escribir en las hojas de cálculo en el mismo lenguaje (Clark, 2022). Random, es una librería que ayuda a implementar generadores de números pseudoaleatorios según sea necesario, son muy útiles al realizar simulaciones (Pitón, s.f.). Finalmente, la librería de heapq permite realizar un torneo elite, en donde se organizan los datos de una matriz de menor a mayor (Pitón, s.f.).

## 5. Resultados

Para llevar a cabo la obtención de los resultados de manera confiable, se realizan pruebas en el algoritmo genético con diferentes números de interacciones y cantidades de individuos en la población, buscando mejorar la solución factible que minimice la función objetivo. Cada una de las 30 instancias (10 pequeñas, 10 medianas y 10 grandes) es ejecutada 30 veces, con un intervalo de confianza del 95%, en donde se calcula; en donde  $s$  la media de la función objetivo y cada uno de los costos (costo de penalización, de mantener inventario, de trayecto y de vehículo). De este modo, se comparan las instancias pequeñas, medianas y grandes con un tamaño de la población ( $n$ ) de 10, 30, 50, 70, 100 y 200 individuos para decidir la cantidad de individuos de la población; luego se modifica el criterio de parada ( $m$ ), para cada una de las internaciones anteriores, con 10, 30, 50, 70 y 100 iteraciones consecutivas con la misma mejor solución factible, identificando la estabilización de la función objetivo.

Debido a los resultados obtenidos en las pruebas con diferentes cantidades de individuos, es posible identificar que a medida que la población cuenta con más individuos, la función objetivo mejora, sin embargo, esta mejoría se va reduciendo progresivamente y a su vez aumentan los tiempos de procesamiento, ya que como se observa en la tabla 5, a partir de la población con 70 individuos se empieza a estabilizar el resultado, donde

se presenta una variación inferior al 1% en la función objetivo en los casos de 70, 100 y 200 individuos en la población. Como se evidencia en la tabla 5, la variación en la función objetivo, para las instancias de 100 individuos a 200 individuos, es de tan solo el 0,2%, en cambio, los tiempos de procesamiento aumentan significativamente, ya que se presentan tiempos de procesamiento para n=100 de 14, 28 y 69 segundos y para n=200 de 51, 124 y 317 segundos, aumentando en 264%, 323% y 359% para las instancias pequeñas, medianas y grandes respectivamente, generando retrasos en la toma de decisión. Debido a lo anterior, se decide usar en el algoritmo genético, con una población de 100 individuos, la cual permite obtener resultados factibles en un buen tiempo de procesamiento.

Función Objetivo Promedio						
	10 individuos	30 individuos	50 individuos	70 individuos	100 individuos	200 individuos
Instancias 5	\$294,956,799	\$281,820,950	\$279,369,450	\$277,143,634	\$275,644,468	\$275,178,353
Instancias 10	\$440,234,904	\$404,791,147	\$392,775,452	\$388,455,841	\$386,644,038	\$385,810,953
Instancias 15	\$857,002,836	\$737,755,428	\$718,877,756	\$709,963,735	\$701,955,688	\$699,683,063

**Tabla 5. Función objetivo promedio según la cantidad de individuos de la población. Elaboración propia.**

Al probar los diferentes criterios de parada, es posible evidenciar que la mejora entre las distintas pruebas no es significativa, a excepción de casos puntuales, y aunque no se presenta una mejora cada vez que el criterio de parada es mayor, los mejores resultados se dan con un criterio de parada de 100 iteraciones consecutivas con la misma mejor solución factible. Es por esto, que se toma la decisión de usar los resultados del algoritmo genético con una población de 100 individuos y un criterio de parada de 100 iteraciones consecutivas con la misma mejor solución factible del problema.

Función Objetivo Promedio					
	CP 10	CP 30	CP 50	CP 70	CP 100
Instancias 5	\$274,845,979	\$275,644,468	\$274,779,744	\$274,816,543	\$274,765,956
Instancias 10	\$391,958,136	\$386,644,038	\$385,007,385	\$385,076,750	\$384,863,053
Instancias 15	\$698,541,054	\$701,955,688	\$697,201,040	\$693,674,148	\$690,519,381

**Tabla 6. Función objetivo promedio según el criterio de parada. Elaboración propia.**

De este modo, es posible comparar el resultado promedio de cada instancia con el valor del mejor individuo de la población obtenida en el modelo de Martínez y Pedraza, para evaluar si se obtiene una mejora en la función objetivo.

Intervalos de confianza (mejor FO)								
Instancia	Media	Desviación	Int Inf	Int Sup	Ancho	Error	Maestría	¿Mejora?
1-5-1	\$ 231.681.566	\$ 170.086	231.630.488	231.732.644	\$ 102.156	\$ 51.078	\$ 294,539,641	SI
1-5-2	\$ 242.500.000	\$ 924.104	242.222.484	242.777.516	\$ 555.031	\$ 277.516	\$ 62,852,800	NO
1-5-3	\$ 306.499.700	\$ 155.027	306.453.144	306.546.256	\$ 93.111	\$ 46.556	\$ 222,531,458	NO
1-5-4	\$ 280.072.091	\$ 207.964	280.009.638	280.134.544	\$ 124.906	\$ 62.453	\$ 314,131,358	SI
1-5-5	\$ 336.978.875	\$ 233.866	336.908.643	337.049.107	\$ 140.464	\$ 70.232	\$ 229,264,183	NO
2-5-1	\$ 201.328.650	\$ 12.362	201.324.938	201.332.362	\$ 7.425	\$ 3.712	\$ 317,717,525	SI
2-5-2	\$ 196.899.316	\$ 194.723	196.840.839	196.957.793	\$ 116.954	\$ 58.477	\$ 65,626,233	NO
2-5-3	\$ 325.406.833	\$ 242.166	325.334.109	325.479.557	\$ 145.449	\$ 72.724	\$ 159,300,483	NO
2-5-4	\$ 311.453.691	\$ 178.937	311.399.955	311.507.427	\$ 107.473	\$ 53.736	\$ 116,792,866	NO
2-5-5	\$ 282.086.250	\$ 301.752	281.995.632	282.176.868	\$ 181.237	\$ 90.618	\$ 176,775,208	NO

**Tabla 7. Resultados de instancias de prueba para 5 retailers. Elaboración propia**

Intervalos de confianza (mejor FO)								
Instancia	Media	Desviación	Int Inf	Int Sup	Ancho	Error	Maestría	¿Mejora?
1-10-1	\$ 394.683.675	\$ 367.120	394.573.426	394.793.924	\$ 220.498	\$ 110.249	\$ 294,539,641	NO
1-10-2	\$ 679.916.183	\$ 700.052	679.705.952	680.126.414	\$ 420.462	\$ 210.231	\$ 62,852,800	NO
1-10-3	\$ 537.746.458	\$ 386.354	537.630.433	537.862.483	\$ 232.050	\$ 116.025	\$ 222,531,458	NO
1-10-4	\$ 223.253.842	\$ 782.089	223.018.974	223.488.709	\$ 469.735	\$ 234.868	\$ 314,131,358	SI
1-10-5	\$ 174.112.017	\$ 143.569	174.068.902	174.155.132	\$ 86.230	\$ 43.115	\$ 229,264,183	SI
2-10-1	\$ 244.421.475	\$ 791.458	244.183.794	244.659.156	\$ 475.362	\$ 237.681	\$ 317,717,525	NO
2-10-2	\$ 655.785.192	\$ 847.860	655.530.573	656.039.811	\$ 509.238	\$ 254.619	\$ 65,626,233	NO
2-10-3	\$ 543.705.317	\$ 492.813	543.557.321	543.853.312	\$ 295.991	\$ 147.996	\$ 159,300,483	NO
2-10-4	\$ 253.839.775	\$ 247.849	253.765.344	253.914.206	\$ 148.862	\$ 74.431	\$ 116,792,866	SI
2-10-5	\$ 141.166.600	\$ 146.637	141.122.564	141.210.636	\$ 88.072	\$ 44.036	\$ 176,775,208	SI

**Tabla 8. Resultados de instancias de prueba para 10 retailers. Elaboración propia.**

Intervalos de confianza (mejor FO)								
Instancia	Media	Desviación	Int Inf	Int Sup	Ancho	Error	Maestría	¿Mejora?
1-15-1	\$ 658.498.892	\$ 1.124.977	658.161.052	658.836.731	\$ 675.679	\$ 337.840	\$ 621.476.242	NO
1-15-2	\$ 879.537.300	\$ 6.507.418	877.583.072	881.491.528	\$ 3.908.457	\$ 1.954.228	\$ 884.778.208	SI
1-15-3	\$ 351.446.108	\$ 390.502	351.328.837	351.563.379	\$ 234.542	\$ 117.271	\$ 469.023.058	SI
1-15-4	\$ 629.793.508	\$ 1.333.775	629.392.965	630.194.051	\$ 801.086	\$ 400.543	\$ 727.444.325	SI
1-15-5	\$ 979.986.833	\$ 4.446.270	978.651.584	981.322.083	\$ 2.670.499	\$ 1.335.249	\$ 754.299.350	NO
2-15-1	\$ 767.680.233	\$ 1.636.099	767.188.900	768.171.567	\$ 982.667	\$ 491.333	\$ 673.447.467	NO
2-15-2	\$ 861.140.525	\$ 1.142.531	860.797.414	861.483.636	\$ 686.222	\$ 343.111	\$ 820.496.733	NO
2-15-3	\$ 379.334.217	\$ 730.096	379.114.963	379.553.470	\$ 438.507	\$ 219.254	\$ 567.816.775	SI
2-15-4	\$ 577.236.475	\$ 1.167.760	576.885.788	577.587.162	\$ 701.375	\$ 350.687	\$ 529.655.592	NO
2-15-5	\$ 820.539.717	\$ 3.729.386	819.419.753	821.659.681	\$ 2.239.928	\$ 1.119.964	\$ 599.454.867	NO

**Tabla 9. Resultados de instancias de prueba para 15 retailers. Elaboración propia.**

Como se evidencia en las tablas 7, 8 y 9, en las instancias de 5 clientes, la solución factible del algoritmo genético mejora en el 30% de los casos, y en las instancias de 10 y 15 clientes mejoran en el 40% de los casos en comparación con la solución propuesta por Martínez y Pedraza.

Objetivos específicos	Cumplimiento	Resultados
Formular el modelo matemático para el problema de inventario y de ruteo con multi depósito y flota heterogénea, generando diferentes instancias de prueba (pequeñas, medianas y grandes) que reúnan las características del problema.	Se plantearon diferentes instancias con 5, 10 y 15 clientes con el fin de evaluar su función objetivo de acuerdo con la variación de sus datos y de la cantidad de depósitos que la atienden. Teniendo en cuenta que los datos suministrados consideran la demanda en estibas, el ruteo que se hace en cada una de las instancias es depósito-cliente-depósito, por lo que no se tiene en consideración el diseño de ruteo.	Como se observan en las tablas No. 5, 6 y 7, se diseñó alrededor de 10 instancias diferentes por cada tamaño de instancia pequeño (5), mediano (10) y grande (15). En donde, como se observa en la sección de metodología, cada cromosoma está conformado por un cliente, una cantidad de depósitos, un tipo de vehículo y la demanda del respectivo cliente.



Diseñar un algoritmo genético que permita obtener una solución factible para cada una de las instancias de prueba.	Se obtienen soluciones factibles en cada una de las instancias y, en algunos casos mejores soluciones respecto a los resultados del modelo de Martínez y Pedraza.	Como se muestra en las tablas de resultados, en cada una de ellas se encuentra una función objetivo factible y, en algunas de las instancias se mejora con respecto a la del modelo de Martínez y Pedraza.
Contrastar los resultados del modelo matemático de cada una de las instancias con los resultados de la metaheurística, mediante el tiempo límite para obtener soluciones factibles.	Por medio del algoritmo genético fue posible optimizar el tiempo de respuesta que, para instancias de 5 clientes tarda alrededor de 10 segundos; para instancias de 10 clientes alrededor de 15 segundos y para 15 clientes alrededor de 30 segundos.	$Mejora = \left  \frac{T_{AG} - T_m}{T_m} \right  \cdot 100\%$ <ul style="list-style-type: none"> <li>• Instancias de 5 clientes: 73,58%</li> <li>• Instancias de 10 clientes: 88,09%</li> <li>• Instancias de 15 clientes: 90,85%</li> </ul>

Tabla 10. Resumen de resultados

Como resultado del modelo se obtienen dos tipos de solución para cada una de las instancias. En la figura No. 8, se presenta un ejemplo de lo que sería una solución factible del modelo para un periodo del horizonte de tiempo. Se presentan dos situaciones: en la primera, el abastecimiento se realiza desde un solo warehouse y visita, en este caso, a los cinco clientes del modelo, en la segunda situación, el abastecimiento se realiza desde dos warehouse, los cuales, de manera aleatoria abastecen a la totalidad de los clientes. En cada caso debido a la demanda realizada por cada cliente mayorista, los camiones solo logran tener la capacidad para abastecer a uno de los clientes, razón por la que la ruta que se realiza es warehouse – retailer - warehouse.

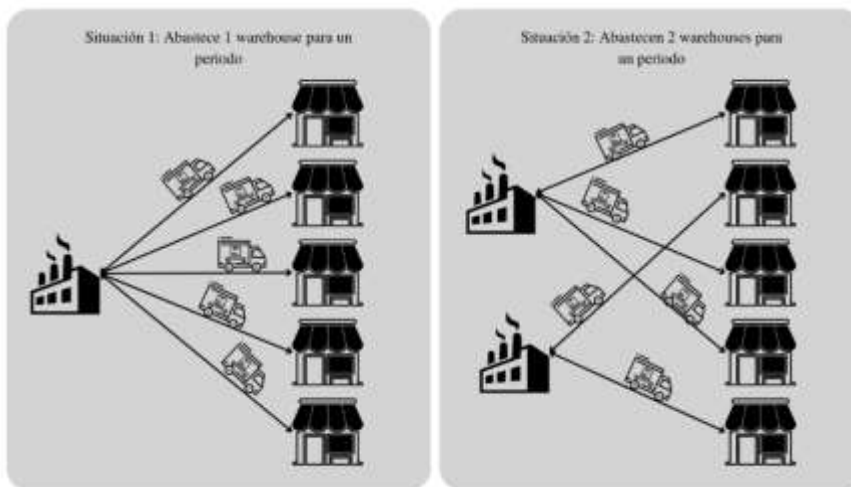


Figura 8. Ejemplo de solución del modelo. Elaboración propia

### 5.1. Medición del impacto

Por medio de este modelo de algoritmo genético se logra tener un impacto operacional, debido a que se optimizan los tiempos de respuesta, minimizando los tiempos para dar una oportuna solución a un problema de inventario y ruteo. Este impacto resulta importante para la industria teniendo en cuenta que en las empresas que deben garantizar el abastecimiento de sus proveedores, bajo el modelo de VMI, el tiempo en la toma de decisiones es un factor importante ya que puede representarse en pérdida de dinero. Por otra parte, también se logró obtener un impacto financiero ya que, como se aborda en la justificación del problema, en Colombia las empresas grandes suelen invertir alrededor del 10% de sus ingresos en temas logísticos. Considerando que el modelo diseñado tiene gran flexibilidad con los datos de entrada

## 6. Análisis de resultados

Teniendo en cuenta los resultados obtenidos a partir del modelo planteado por Martínez y Pedraza fue posible comparar la eficacia del algoritmo genético realizado. Los valores que se tuvieron en cuenta para realizar las comparaciones fueron, en primera instancia, los tiempos de respuesta por parte del código, en donde se ve un ahorro de tiempo de procesamiento bastante significativo que varía dependiendo del tamaño de las instancias evaluadas. También se tuvo en cuenta valores como mejor individuo, es decir, el individuo en la instancia que obtuvo una mejor función objetivo. De igual manera se tuvo en cuenta los costos de penalización, de mantener en inventario, trayecto y de uso de vehículo.

Instancias	1 WAREHOUSE				2 WAREHOUSE			
	CP	CMI	CT	CV	CP	CMI	CT	CV
5	-13,8%	21,4%	4,3%	3,1%	-24,8%	26,9%	33,2%	4,1%
10	-8,7%	13,5%	1,5%	2,0%	-8,7%	18,8%	24,9%	1,7%
15	-0,5%	10,6%	1,8%	1,9%	-12,9%	13,3%	19,1%	0,7%

Tabla 11. Mejora de los costos según instancias de prueba de retailers. Elaboración propia.

CP	Costo penalización
CMI	Costo mantener inventario
CT	Costo trayecto
CV	Costo vehículo

Tabla 12. Abreviación de los costos de la función objetivo

En las instancias de cinco clientes en donde solo se atiende desde un warehouse, se obtiene que, al implementar el algoritmo genético, en promedio mejora la función objetivo, respecto a los resultados de Martínez y Pedraza, en el 40% de los casos, donde en promedio aumentan los costos de penalización por faltantes en un 13.8%, a su vez, se puede evidenciar que existe una reducción de costos de: mantener inventario del 21,4%, de costos de trayecto del 4.3% y de los costos de vehículo del 3.1%. Igualmente sucede con los costos de las instancias en donde se presentan dos warehouse, donde mejora la función objetivo del algoritmo genético en el 20% de los casos, con disminución de 26.9%, 33.2% y 4.1% en los costos de mantener inventario, costos de trayecto y costos de vehículo respectivamente, sin embargo, se encuentra un incremento en los costos de penalización del 24,8% debido al aumento de faltantes.

En las instancias de diez clientes en donde solo se atiende desde un warehouse, se obtiene que, al implementar el algoritmo genético, en promedio mejora la función objetivo, respecto a los resultados de Martínez y Pedraza, en el 40% de los casos, donde en promedio aumentan los costos de penalización por faltantes en un 8,7 %, a su vez, se puede evidenciar que existe una reducción de costos de: mantener inventario del 13,5%, de costos de trayecto del 1,5% y de los costos de vehículo del 2%. Igualmente sucede con los costos de las instancias en donde se presentan dos warehouse, donde mejora la función objetivo del algoritmo genético en el 40% de los casos, con disminución de 18,8%, 24,9% y 1,7% en los costos de mantener inventario, costos de trayecto y costos de vehículo respectivamente, sin embargo, se encuentra un incremento en los costos de penalización del 8,7% debido al aumento de faltantes.

En las instancias de quince clientes que son atendidas por un solo warehouse se obtiene una mejor solución factible en el algoritmo genético en el 60% de los casos comparado con la solución propuesta por el modelo de Martínez y Pedraza, por lo que es posible afirmar que en estas instancias el algoritmo genético encuentra en promedio mejores resultados. Esto se da principalmente a que los faltantes encontrados en las soluciones del algoritmo genético son similares a las del modelo de Martínez y Pedraza, causando así, que los costos de penalización aumenten en tan solo un 0,5% y se logran reducir los costos de mantener inventario en un 10,6%, los costos de trayecto en 1,8% y los costos de vehículo en 1,9%. Para las instancias de 15 clientes que son

visitados por dos warehouse las soluciones del algoritmo genético mejoran en tan solo el 20% de los casos, esto principalmente porque se presenta un aumento del 12,9% en los costos de penalización, y aunque se mejoran los costos de mantener inventario en un 13,3%, los costos de trayecto en un 19,1% y los costos de vehículo en un 0,7%, no es suficiente para mejorar la función objetivo a los valores alcanzados por Martínez y Pedraza en su solución.

Los costos de penalización por los faltantes son muy altos debido a que la empresa cervecera busca garantizar que se cubra toda la demanda de sus clientes, ya que desabastecer a un cliente tiene consecuencias negativas como la mala reputación, mala imagen, disminución en las ventas, entre otras. Al presentarse faltantes se corre el riesgo de pérdida del cliente, quien tuvo un costo de adquisición previamente y quien representa unas ventas determinadas en cada periodo, además, la competencia que presenta productos similares se puede fortalecer a causa de los faltantes presentados en los clientes a quienes no fue posible suplir toda su demanda, ya que estos recurrirán a otras empresas para poder satisfacer sus necesidades y no verse perjudicados, lo cual puede generar que no tan solo se pierda un cliente sino que la competencia adquiere un nuevo cliente, ganando participación de mercado. Por otro lado, la reputación de la empresa se ve afectada, presentando una mala imagen y disminuyendo su presencia, lo que puede generar que el consumidor prefiera decantarse por otras marcas.

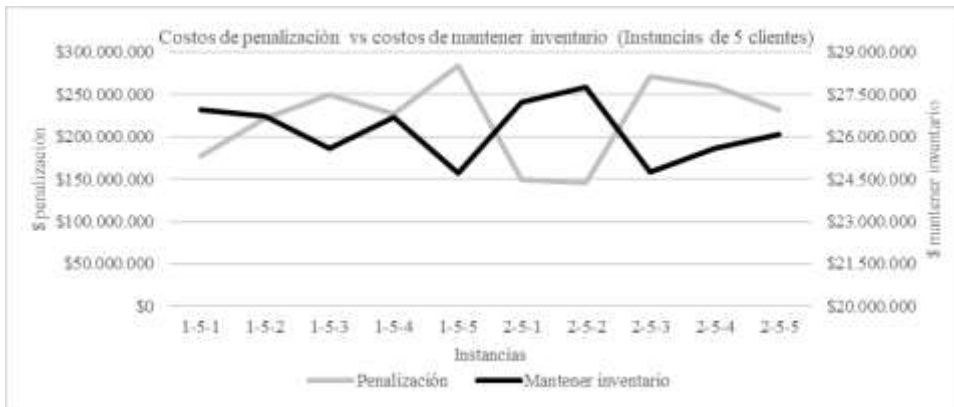


Figura 9. Costos de penalización vs costos de mantener inventario (Instancias de 5 clientes)

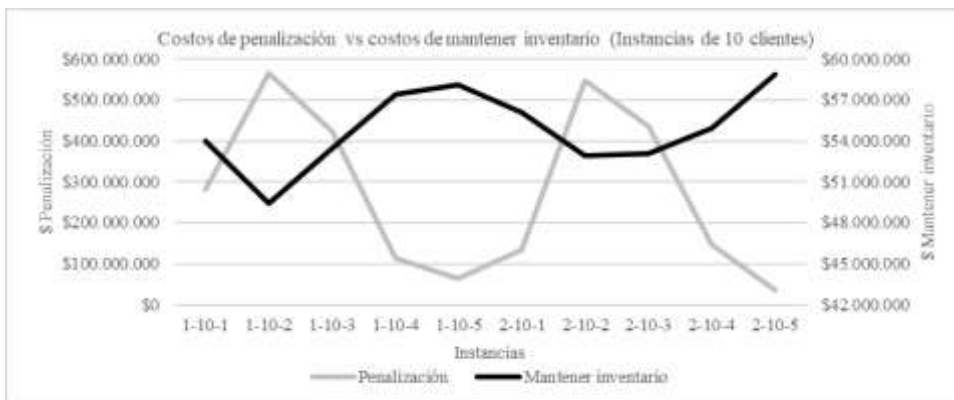


Figura 10. Costos de penalización vs costos de mantener inventario (Instancias de 10 clientes)




Figura 11. Costos de penalización vs costos de mantener inventario (Instancias de 15 clientes)

En nuestro modelo es posible identificar que a medida que el costo de mantener inventario disminuye, el costo por penalizaciones crece, es decir, son inversamente proporcionales como se evidencia en las figuras 9, 10 y 11. Este costo de penalización no crece linealmente debido a que cada cliente tiene un diferente costo de penalización, pero se evidencia una clara tendencia, donde debemos garantizar minimizar la cantidad de faltantes dado al alto costo de las penalizaciones. Los costos de mantener inventario disminuyen a medida que aumentan los costos de penalización debido a que al tener más faltantes se debe almacenar menos estibas de cerveza, pero, este ahorro es muy pequeño a diferencia del sobre costo generado por el desabastecimiento de los clientes en cada una de las instancias. Es por esto, que se debe buscar la menor cantidad de faltantes en cada cliente de cada periodo, para que, de esta forma, los costos totales disminuyan.

En términos generales, a medida que el problema se vuelve más robusto (debe procesar más información), el algoritmo genético presenta mejores resultados, a pesar de que los tiempos de respuesta, sin ser significativos, aumentan. Además, para la mayoría de las instancias se encuentra que los costos de mantener inventario, trayecto y vehículo que hacen parte de la función objetivo, se mejoran. Sin embargo, debido a la penalización por no abastecimiento, el costo de la función objetivo se eleva, ya que este costo es el más influyente por su elevado valor en la función objetivo, generando como resultado que se obtenga en algunas instancias al mejor individuo de la población con una función objetivo mayor que la del modelo de Martínez y Pedraza. Por último, los tiempos de procesamiento se presentan en la siguiente tabla:

Tiempo de procesamiento (s)				
Instancia	Modelo de Martínez y Pedraza	Tesis	Mejoría %	Promedio
5	53	14	73,58%	84,17%
10	235	28	88,09%	
15	754	69	90,85%	

Tabla 13. Tiempo de procesamiento

## 7. Conclusiones y recomendaciones.

Se hizo el análisis y formulación del modelo matemático teniendo en cuenta las características del problema presentado, para las diferentes instancias. A partir de esta formulación, se pudo desarrollar el algoritmo genético obteniendo tantas soluciones factibles e incluso, en algunas de las instancias, mejores que las obtenidas por el modelo matemático Martínez y Pedraza, como tiempos de procesamiento menores, generando de este modo un menor tiempo de respuesta en la toma de decisiones. El problema solucionado se hizo con base en una industria cervecera, sin embargo, tiene funcionalidad para cadena de suministro con flota heterogénea, debido a que para el desarrollo de este se tuvo en cuenta la versatilidad de los datos y variables de entrada, razón por la que es

posible variar la cantidad de clientes, depósitos, tipo y cantidad de camiones disponibles para la distribución y la demanda solicitada por los clientes mayoristas.

Mediante el diseño del algoritmo genético, teniendo en cuenta los mismos datos analizados en el modelo de Martínez y Pedraza, se logró obtener una solución factible para cada una de las instancias. Se obtuvo que el 37% de las instancias se logran obtener valores de la función objetivo menores que en el modelo comparado y se observó que en 63% restante de los casos, los costos de la función objetivo se elevan debido a la penalización por faltantes, debido a que tienen una alta incidencia en el modelo a causa de la cantidad de faltantes que se representa en el costo por faltantes, por lo que se abre la posibilidad de variar las capacidades de los camiones o las demandas de los clientes con el fin de obtener mejores resultados. Respecto a los costos de inventario, de transporte y del vehículo, se obtuvo una mejoría en el 96,7% de las instancias, en comparación al modelo de Martínez y Pedraza. Teniendo en cuenta la restricción en la que un solo vehículo debe abastecer la demanda total del cliente, en varias ocasiones se observa que la demanda supera la capacidad total del vehículo, por lo que en ocasiones es imposible mitigar los costos de penalización. Se propone probar el algoritmo desarrollado para un modelo de distribución de mayorista a minorista, donde posiblemente las demandas se adecuen de mejor manera y se pueda realizar un ruteo un poco más complejo, cumpliendo con las restricciones.

Para la obtención de los resultados con los tiempos de procesamiento expuestos, se contó con computadores con características técnicas como procesadores CORE i5 y Windows 10, por tal motivo estos tiempos están sujetos a dichas características, por esto en el caso de presenta un computador con mejores características técnicas se obtendrá un menor tiempo de procesamiento. Teniendo en cuenta que el modelo matemático de Martínez y Pedraza se realizó en la distribución de Linux Ubuntu, los tiempos de respuesta de su modelo para instancias de 5 y 10 son buenos. Sin embargo, al obtener los tiempos de respuesta del algoritmo genético, se obtiene que son en promedio 84,2% mejores, a pesar de no haberse corrido en las mismas condiciones. Por esta razón, es posible decir que el tiempo de respuesta del algoritmo genético es muy bueno, además de dar respuestas factibles muy cercanas a las del modelo matemático.

Teniendo en consideración que el algoritmo genético fue realizado con base al código del modelo de solución para una cadena de suministro con flota heterogénea aplicado a la industria cervecera utilizando Rolling Horizon, a lo largo del desarrollo del trabajo se presentaron algunas limitaciones que provenían desde el desarrollo del modelo de solución, por lo que se obviaron y se continuó con el desarrollo del algoritmo genético con las mismas. Una de estas, es que la capacidad de los camiones está dada en estibas al igual que la demanda de cada uno de los clientes, por lo que, al momento de realizar la ruta para el abastecimiento de los clientes, la capacidad del camión llegaba a su límite e incluso, en algunos casos no daba abasto, con la demanda de un solo cliente. Por esta razón, se diseñó de una ruta de distribución uno a uno, ya que para todos los casos cada camión solo tiene la capacidad de visitar a un solo cliente y volver al depósito. Además, el código fue desarrollado en lenguaje de programación Python, por lo que es necesario que quién quiera adecuar o realizar implementaciones en el modelo, debe conocer el lenguaje.

Se recomienda aumentar la capacidad de los camiones y la cantidad disponible por depósito con el fin de encontrar mayor versatilidad en el modelo y lograr que un camión pueda visitar más de un cliente o, disminuir la demanda del cliente (considerando que se encuentra en estibas). Además, con el fin de obtener tiempos de respuesta similares se recomienda que el código sea corrido en un computador con una capacidad de procesamiento similar a la descrita y es indispensable tener acceso a internet, ya que estos factores pueden variar el tiempo de respuesta. También se debe tener claras las variables implementadas debido a que es de vital importancia para el desarrollo adecuado del programa. Además, se podría llegar a contemplar la idea de implementar una flota eléctrica para reducir la contaminación.

## 8. Referencias

Afsar, Espinouse, & Penz. (2006). A two-step heuristic to build flight and maintenance planning in a rolling-horizon. *IEEE Xplore*.

- AIMMS. (14 de december de 2021). *How to AIMMS*. Obtenido de Rolling Horizon: <https://how-to.aimms.com/Articles/435/435-rolling-horizon.html>
- Aprende con Alf. (14 de 07 de 2022). *La librería Pandas*. Obtenido de <https://aprendeconalf.es/docencia/python/manual/pandas/>
- Avici, & Topaloglu. (2009). A metaheuristic solution approach for the production routing problem with visit spacing policy. *European Journal of Operational Research*.
- Azadeh, & et al. (2016). A genetic algorithm-Taguchi based approach to inventory routing problem of a single perishable product with transshipment. *Computers & Industrial Engineering*.
- Bolaños, & Vidal. (2020). El impacto de los costos de mantenimiento de inventario en el diseño estratégico de las cadenas de suministro. *Universidad de Antioquia*.
- Campbell, Clarke, & Savelsbergh. (2002). Inventory routing in practice: The vehicle routing problem. *SIA Monographs on discrete mathematics and applications*, 309-330.
- Clark, E. G. (24 de 05 de 2022). *openpyxl: una biblioteca de Python para leer/escribir archivos Excel 2010 xlsx/xlsm*. Obtenido de <https://openpyxl.readthedocs.io/en/stable/>
- Cohelo, & Laporte. (2012). The exact solution of several classes of inventory-routing problems. *Computers & Operations Research*.
- D'Avino, Marco, Bregni, Alfredo, & Schitaldi Massimiliano. (2013). A revised and improved version of the MRP algorithm.
- Dib, Manier, & Caminada. (2015). A hybrid metaheuristic for routing in road networks. *International Conference in Intelligent Transportation systems*.
- DNP. (27 de julio de 2021). Obtenido de <https://www.dnp.gov.co/Paginas/A-12,6-cayeron-los-costos-logisticos-de-las-empresas-frente-a-sus-ventas.aspx>
- Dong Won, Young Hae, Tae Young, & Mitsou. (2013). An adaptive genetic algorithm for the time dependent inventory routing problem. *Springer Science+Business Media New York*.
- Fahimnia, Luong, & Marian. (2011). Optimización de algoritmos genéticos de un plan integrado de producción-distribución agregada en cadenas de suministro. *Universidad de Australia Meridional*.
- Hanczar, & Kaleta. (2016). Inventory routing problem in rolling horizon planning environment. *Evaluation of decision making under the risk*, 337-388.
- Hansen, & Maldenovic. (1999). Variable neighborhood search: Principles and applications. *European Journal of Operational Research*, 449-467.
- Hao, Congdong, Ying, Chunnan, & Yu. (2018). A nonlinear Integer Programming model for integrated location, inventory, and routing decisions in a closed-loop supply chain. *Wiley*.
- Hiassat, Diabat, & Rahwan. (2017). A genetic algorithm approach for location-inventory-routing problem with perishable products. *Journal of Manufacturing Systems*, 93-103.
- Hosseini, Taghi, & Hamid. (2014). Robust optimization approach for an aggregate production-distribution planning in a three-level supply chain. *Springer*.

- Jianxiang, Feng, & Haoxun. (2010). A solution approach to the inventory routing problem in a three-level distribution system. *European Journal of Operational Research*.
- Louly, & Dolgui. (2011). Optimal time phasing and periodicity for MRP with POQ policy. *Int. J. Production Economics*, 76-86.
- Lui, Hendalianpour, & Hamzehlou. (2021). Reducción de costos del sistema de producción de inventario en varios niveles de la cadena de suministro utilizando teoría de juegos y demanda difusa.
- Manuel Cillero. (s.f.). *Pruebas del Sistema*. Obtenido de [manuel.cillero.es](https://manuel.cillero.es/):  
<https://manuel.cillero.es/doc/metodologia/metrica-3/tecnicas/pruebas/sistema/>
- Margolis, Song, & Mason. (2022). A Markov decision process model on dynamic routing for target surveillance. *Computers and Operations Research*.
- Marinelli, & et al. (2019). A two-stage metaheuristic approach for solving the vehicle routing problem with simultaneous pickup/delivery and door-to-door service. *Polytechnic University of Bari*.
- Meng, Lu, Xi, & Zhang. (2011). Application of six Sigma method in improving the quality of box parts. *Proceedings of 2011 International Conference on Electronic and Mechanical Engineering and Information Tecnology*, 4158-4161.
- Nathan, & Gonzales. (30 de abril de 2020). *Lean Six Sigma, una metodología aplicada a procesos reales*. Obtenido de Izertis: <https://www.izertis.com/es/-/blog/lean-six-sigma-una-metodologia-aplicada-a-procesos-reales>
- Numpy. (22 de 06 de 2022). *Numpy documentación*. Obtenido de <https://numpy.org/doc/stable/>
- Pawan, Rajendra, Sharma, & Vinod. (2018). Genetic algorithm-based routing protocol for energy efficient routing in MANET's. *Advances in Intelligent Systems and Computing*.
- Pedraza, E., & Martínez, J. (2021). Modelo de solución para una cadena de suministro con flota heterogénea aplicado a la industria cervecera utilizando rolling horizon (Tesis de posgrado). *Pontificia Universidad Javeriana, Bogotá, Colombia*.
- Pitón. (s.f.). *heapq - Algoritmo de cola de pila*. Obtenido de <https://docs.python.org/3/library/heapq.html>
- Pitón. (s.f.). *random - Generar números pseudoaleatorios*. Obtenido de <https://docs.python.org/3/library/random.html>
- Pulido, & et al. (2020). An optimization approach for inventory costs in probabilistic inventory models: A case study. *Ingeniare*, 383-395.
- Roldan, R., Basagoiti, & Cohelo. (2016). A hybrid genetic algorithm for a dynamic and stochastic multi-depot inventory-routing problem (Tesis doctoral). *Université Laval, Québec, Canadá*.
- Safi-Eddine, El-Beheiry, & El-Kharbotly. (2018). An improved genetic algorithm for optimizing total supply chain cost in inventory location routing problem. *Ain Shams Engineering Journal*.
- Senoussi, Dauzere-Peres, Brahimi, Penz, & Mouss. (2018). Heuristics Based on Genetic Algorithms for the Capacitated Multi Vehicle Production Distribution Problem. *Computers and Operations Research*, 108-119.

- Siswanto, Essam, & Sarker. (2011). Solving the ship inventory routing and scheduling problem with undedicated compartments. *Computers & Industrial Engineering*, 289-299.
- Tamer, & et al. (2006). A genetic algorithm approach to the integrated inventory-distribution problem. *International Journal of Production Research*.
- ZonaLogística. (30 de julio de 2020). *Resultados de la Encuesta Nacional Logística 2020*. Obtenido de Zona Logística: <https://zonalogistica.com/resultados-de-la-encuesta-nacional-logistica-2020/>