

# UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI



## FACULTAD DE COMERCIO INTERNACIONAL, INTEGRACIÓN, ADMINISTRACIÓN Y ECONOMÍA EMPRESARIAL

### CARRERA DE LOGÍSTICA Y TRANSPORTE

**Tema: “Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial”**

Trabajo de Integración Curricular previo a la obtención del  
título de Ingenieras en Logística y Transporte

AUTORAS: Ortiz Benítez Lesly Belén

Urbano Portilla Karen Pamela

TUTOR: MSc. Pozo Burgos Eduardo Javier

Tulcán, 2025

## **CERTIFICADO DEL TUTOR**

Certifico que las estudiantes Ortiz Benítez Lesly Belén y Urbano Portilla Karen Pamela con el número de cédula 0401540000 y 0450082557 respectivamente han desarrollado el Trabajo de Integración Curricular: "Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial"

Este trabajo se sujeta a las normas y metodología dispuesta en el Reglamento de la Unidad de Integración Curricular, Titulación e Incorporación de la UPEC, por lo tanto, autorizo la presentación de la sustentación para la calificación respectiva

---

MSc. Pozo Burgos Eduardo Javier

**TUTOR**

Tulcán, enero de 2025

## AUTORÍA DE TRABAJO

El presente Trabajo de Integración Curricular constituye un requisito previo para la obtención del título de Ingenieras en la Carrera de logística y transporte de la Facultad de Comercio Internacional, Integración, Administración y Economía Empresarial

Nosotras, Ortiz Benítez Lesly Belén y Urbano Portilla Karen Pamela con cédula de identidad número 0401540000 y 0450082557 respectivamente declaramos que la investigación es absolutamente original, auténtica, personal y los resultados y conclusiones a los que hemos llegado son de nuestra absoluta responsabilidad.



---

Ortiz Benítez Lesly Belén

**AUTORA**



---

Urbano Portilla Karen Pamela

**AUTORA**

Tulcán, enero de 2025

## ACTA DE CESIÓN DE DERECHOS DEL TRABAJO DE INTEGRACIÓN CURRICULAR


Nosotras Ortiz Benítez Lesly Belén y Urbano Portilla Karen Pamela declaramos ser autoras de los criterios emitidos en el Trabajo de Integración Curricular: "Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial" y se exime expresamente a la Universidad Politécnica Estatal del Carchi y a sus representantes de posibles reclamos o acciones legales.



---

Ortiz Benítez Lesly Belén

**AUTORA**



---

Urbano Portilla Karen Pamela

**AUTORA**

Tulcán, enero de 2025

## AGRADECIMIENTO

Quiero expresar mi más sincero agradecimiento al MSc. Iván Mafla por su invaluable apoyo y guía a lo largo de este proyecto. Su profundo conocimiento, paciencia y constante disposición para brindar asistencia han sido cruciales para el desarrollo y culminación de esta tesis. Gracias por compartir su experiencia y por inspirarme a alcanzar altos estándares de excelencia académica y profesional. Su influencia y dedicación han dejado una huella imborrable en mi formación.

También deseo agradecer a mi amiga y compañera de tesis, Pamela Urbano, por su colaboración, compañerismo y apoyo incondicional. Su entusiasmo y compromiso han sido esenciales para superar los desafíos que encontramos en este camino. Gracias por compartir esta experiencia conmigo y ser una persona incondicional.

*Lesly Belén Ortiz Benítez*

En primer lugar, quisiera expresar mi más sincero agradecimiento a mi tutor de tesis, el MSc. Iván Mafla por su invaluable guía y apoyo incondicional a lo largo de este proceso. Su experticia, paciencia y disposición para compartir sus conocimientos han sido fundamentales para el desarrollo y enriquecimiento de esta investigación. Sus comentarios y sugerencias oportunas me han permitido alcanzar un nivel de profundidad y rigor académico que no habría sido posible sin su asesoría.

De igual manera expreso mi agradecimiento a mi amiga y compañera de tesis, Lesly Ortiz, por su dedicación, disposición para compartir ideas, y trabajar juntas para superar los desafíos que se presentaron en el camino. Gracias por ser una amiga tan especial, por creer en mí. Agradezco la oportunidad de haber compartido este proceso contigo.

*Karen Pamela Urbano Portilla*

## DEDICATORIA

Dedico esta tesis a Dios que es el pilar fundamental de mi vida, a mi querido hijo Nikolas, quien ha soportado mi ausencia durante los largos períodos que he dedicado a estudiar. Su paciencia y comprensión han sido una fuente de fortaleza para mí. A mi familia, especialmente a mi madre Sandra Benítez por su amor incondicional, apoyo constante y paciencia infinita durante este arduo camino. Y a mí misma, por la determinación y perseverancia para superar los desafíos y alcanzar este logro. Esta tesis es un reflejo del sacrificio, esfuerzo y dedicación de todos nosotros.

*Lesly Belén Ortiz Benítez*

Dedico esta tesis con todo mi corazón a mi querida familia, quienes han sido una fuente constante de amor, apoyo y fortaleza en mi vida. En primer lugar, a mis padres, cuyo sacrificio, orientación y cariño incondicional me han permitido llegar hasta aquí. Su confianza en mí y sus sabios consejos han sido la base sobre la cual he construido mis sueños y logros.

A mi hermano, quien ha sido fuente de inspiración y me ha brindado su apoyo inquebrantable en este camino. Tu presencia en mi vida ha sido un pilar de fortaleza y amistad, tus palabras de ánimo siempre me han dado el impulso necesario para seguir adelante. A mi hermana, cuyo recuerdo imborrable me acompaña en cada paso que doy, le brindo este logro como un homenaje a su memoria. Aunque su ausencia física se siente en cada latido de mi corazón, su presencia en mi alma me impulsa a perseguir mis sueños con aún más determinación y fortaleza.

*Karen Pamela Urbano Portilla*

## ÍNDICE

<b>RESUMEN.....</b>	<b>10</b>
<b>ABSTRACT .....</b>	<b>11</b>
<b>INTRODUCCIÓN .....</b>	<b>12</b>
<b>I. EL PROBLEMA.....</b>	<b>13</b>
<b>1.1. PLANTEAMIENTO DEL PROBLEMA .....</b>	<b>13</b>
<b>1.2. FORMULACIÓN DEL PROBLEMA.....</b>	<b>13</b>
<b>1.3. JUSTIFICACIÓN.....</b>	<b>13</b>
<b>1.4. OBJETIVOS Y PREGUNTAS DE INVESTIGACIÓN .....</b>	<b>14</b>
1.4.1. Objetivo General .....	14
1.4.2. Objetivos Específicos .....	15
1.4.3. Preguntas de Investigación .....	15
<b>II. FUNDAMENTACIÓN TEÓRICA .....</b>	<b>16</b>
<b>2.1. ANTECEDENTES DE LA INVESTIGACIÓN .....</b>	<b>16</b>
<b>2.2. MARCO TEÓRICO .....</b>	<b>17</b>
2.2.1. Algoritmo metaheurístico.....	17
2.2.2. Problema de ruteo de vehículos (VRP).....	18
2.2.3. Metaheurísticas para VRP .....	18
2.2.4. Tipo de operaciones.....	19
2.2.5. Proceso de distribución .....	20
2.2.6. Redes Neuronales .....	21
2.2.7. Concepto de Inteligencia artificial (IA) .....	21
<b>III. METODOLOGÍA .....</b>	<b>23</b>
<b>3.1. ENFOQUE METODOLÓGICO .....</b>	<b>23</b>
3.1.1. Enfoque .....	23
3.1.2. Tipo de Investigación.....	23
<b>3.2. HIPÓTESIS .....</b>	<b>23</b>

<b>3.3. DEFINICIÓN Y OPERACIONALIZACIÓN DE LAS VARIABLES</b> .....	<b>23</b>
3.3.1. Definición de las variables .....	23
3.3.2. Operacionalización de las variables.....	24
<b>3.4. MÉTODOS UTILIZADOS</b> .....	<b>25</b>
3.4.1. Métodos.....	25
<b>3.4.2. Técnicas</b> .....	<b>26</b>
3.4.2.1. Búsqueda bibliográfica .....	26
3.4.2.2. Estudio causal - comparativo .....	26
<b>3.1. RECURSOS</b> .....	<b>26</b>
<b>3.5. ANÁLISIS ESTADÍSTICO</b> .....	<b>27</b>
<b>IV. RESULTADOS Y DISCUSIÓN</b> .....	<b>28</b>
<b>4.1. RESULTADOS</b> .....	<b>28</b>
4.1.1. Casos de estudio de metaheurísticas aplicadas a problemas de VRP.....	28
4.1.2. Comparación y rendimiento de las metaheurísticas .....	35
4.1.3. Árbol de decisión para clasificación .....	43
4.1.4. Red neuronal de clasificación con un modelo lineal usando Tensorflow ..	51
<b>4.2. PRUEBA DE HIPOTESIS</b> .....	<b>57</b>
4.2.1. Codificación método de prueba Python.....	57
4.2.2. Resultados prueba T de Student .....	58
4.2.3. Interpretación .....	58
<b>4.3. DISCUSIÓN</b> .....	<b>59</b>
<b>V. CONCLUSIONES Y RECOMENDACIONES</b> .....	<b>64</b>
<b>5.1. CONCLUSIONES</b> .....	<b>64</b>
<b>5.2. RECOMENDACIONES</b> .....	<b>65</b>
<b>VI. REFERENCIAS BIBLIOGRÁFICAS</b> .....	<b>66</b>
<b>VII. ANEXOS</b> .....	<b>69</b>

## ÍNDICE DE TABLAS

Tabla 1. Operacionalización de variables .....	24
Tabla 2. Recursos .....	26
Tabla 3. Casos de metaheurísticas aplicadas a solución de VRP .....	29
Tabla 4. Metodología para búsqueda bibliográfica .....	35
Tabla 5. Clasificación de casos de estudio. ....	36
Tabla 6. Clasificación de casos de estudio según el método utilizado .....	39
Tabla 7. Prueba de hipótesis .....	57
Tabla 8. Comparación con Solución Metaheurística para el enrutamiento .....	60
Tabla 9. Optimización del ruteo de vehículos con drones usando algoritmos .....	61
Tabla 10. Comparación con Algoritmo de <i>Clarke and Wright</i> .....	62
Tabla 11. Comparación de metaheurísticas para resolver VRP .....	63

## ÍNDICE DE FIGURAS

Figura 1. Porcentaje de uso de algoritmo .....	42
Figura 2. Porcentaje de mejora con relación al método utilizado .....	42
Figura 3. Árbol de decisión. ....	44
Figura 4. Distribución Depósitos. ....	46
Figura 5. Distribución clientes. ....	47
Figura 6. Distribución algoritmos utilizados. ....	48
Figura 7. Distribución clasificación de casos .....	49
Figura 8. Matriz de correlación .....	50
Figura 9. Evolución del margen de error .....	56

## ÍNDICE DE ANEXOS

Anexo 1. Acta de sustentación de Predefensa del TIC .....	69
Anexo 2. Certificado del abstract por parte de idiomas .....	71
Anexo 3. Datos casos metaheurísticos .....	73
Anexo 4. Manual de uso del árbol de decisión para clasificación .....	74
Anexo 5. Manual de Uso para la Red Neuronal de Clasificación con TensorFlow .....	78

## RESUMEN

La presente tesis aborda el desarrollo de un sistema de selección de metaheurísticas para la resolución de problemas de ruteo vehicular (VRP), utilizando técnicas de inteligencia artificial como árbol de decisiones y redes neuronales. El objetivo principal es mejorar la eficiencia y efectividad en la elección de algoritmos adecuados para resolver problemas específicos de VRP. La metodología empleada incluyó una revisión exhaustiva de la literatura sobre aplicaciones de estos métodos, y la implementación de un sistema basado en aprendizaje automático que analiza características del problema para seleccionar la opción óptima entre varias alternativas. Se realizaron experimentos con datos simulados, comparando el rendimiento de diferentes algoritmos en términos de tiempo de procesamiento y calidad de las soluciones obtenidas. Los resultados muestran que el sistema propuesto mejora significativamente la elección, reduciendo los tiempos de computación y mejorando las soluciones de enrutamiento en comparación con métodos tradicionales. Se concluye que la integración de inteligencia artificial en la selección de metaheurísticas no solo optimiza el proceso de distribución, sino que también proporciona una herramienta adaptable y robusta para la gestión logística.

Palabras Claves: Metaheurísticas, Problemas de Ruteo Vehicular (VRP), Algoritmos, Sistema de selección, Inteligencia Artificial.

## **ABSTRACT**

The present thesis addresses the development of a selection system for metaheuristics solve Vehicle Routing Problems (VRP) using artificial intelligence techniques such as decision trees and neural networks. The main objective is to improve the efficiency and effectiveness in choosing suitable algorithms to resolve specific VRP issues. The employed methodology included a comprehensive review of the literature on applications of these methods, and the implementation of a machine learning-based system that analyzes problem characteristics to select the optimal option among various alternatives. Experiments were conducted with simulated data, comparing the performance of different algorithms in terms of processing time and quality of the obtained solutions. The results show that the proposed system significantly improves selection, reducing computation times and enhancing routing solutions compared to traditional methods. It is concluded that integrating artificial intelligence in the selection of metaheuristics not only optimizes the distribution process but also provides an adaptable and robust tool for logistics management.

Keywords: Metaheuristics, Vehicle Routing Problems (VRP), Algorithms, Selection System.

## INTRODUCCIÓN

La optimización de los procesos de distribución es un desafío crucial para las empresas que buscan mejorar su eficiencia, reducir costos y aumentar la satisfacción del cliente. En este contexto, el Problema de Ruteo Vehicular (VRP) se presenta como un desafío complejo de optimización combinatoria, cuyo objetivo es determinar las soluciones óptimas, considerando diversas restricciones, como la capacidad de carga, los tiempos de entrega y las ventanas horarias. Estas restricciones añaden múltiples capas de complejidad, haciendo que la resolución del VRP sea una tarea de alta demanda computacional Toth y Vigo (2022).

Abordar problemas VRP de gran escala y complejidad representa un reto significativo debido a su naturaleza combinatoria. Las técnicas tradicionales de optimización exacta, aunque garantizan soluciones óptimas, suelen ser computacionalmente prohibitivas y no escalan eficientemente para problemas de gran tamaño. Por esta razón, las metaheurísticas han surgido como alternativas prometedoras, proporcionando métodos eficientes para obtener soluciones de alta calidad en tiempos razonables Blum y Roli (2003). Metaheurísticas como algoritmos genéticos, enjambres de partículas y búsqueda tabú, entre otras, han demostrado ser efectivas en la práctica, ofreciendo un buen equilibrio entre calidad de la solución y tiempo de cómputo.

No obstante, la selección adecuada de una metaheurística para un caso específico de VRP no es trivial. Cada metaheurística tiene características y comportamientos diferentes, y la elección inadecuada puede llevar a resultados subóptimos o tiempos de computación excesivos Toth y Vigo (2022). Esta variabilidad y dependencia del contexto específico del problema plantean la necesidad de desarrollar mecanismos inteligentes que puedan analizar las características del problema y seleccionar la metaheurística más adecuada.

En este sentido, la inteligencia artificial (IA) ofrece herramientas innovadoras para enfrentar este desafío. Técnicas de aprendizaje automático, como los árboles de decisiones y las redes neuronales, pueden ser empleadas para desarrollar sistemas que, mediante el análisis de datos históricos y características específicas del problema, seleccionan de manera óptima la metaheurística más adecuada. Esto no solo mejora la eficiencia y efectividad del proceso de resolución, sino que también proporciona una solución robusta y adaptable a diversas situaciones.

## **I. EL PROBLEMA**

### **1.1. PLANTEAMIENTO DEL PROBLEMA**

El uso de metaheurísticas en el proceso de distribución ha adquirido una relevancia significativa en los últimos años debido a su capacidad para abordar problemas complejos y optimizar la eficiencia en la cadena de suministro. Estas técnicas, como algoritmos genéticos, colonias de hormigas, enjambres de partículas, entre otros, han demostrado ser eficaces en la resolución de problemas de enrutamiento de vehículos, rescate de recursos y diseño de redes logísticas. Sin embargo, existe una brecha en la comprensión de cómo aplicar adecuadamente estos métodos en diferentes contextos y sectores específicos.

El desafío de desarrollar una metaheurística para la optimización en el proceso de distribución en diferentes industrias y cadenas de suministro, implica identificar los factores críticos que influyen en la efectividad de estas técnicas, como la necesidad de la demanda, las restricciones operativas y las características del entorno. A su vez, se requiere evaluar el impacto de la implementación de estos métodos en términos de costos, tiempos de entrega, calidad del servicio y sostenibilidad, considerando las particularidades de cada sector y empresa.

Por esta razón, el problema se centra en la adaptación y configuración específica de las metaheurísticas para satisfacer las necesidades de distribución de las empresas. Esto implica comparar los diferentes algoritmos metaheurísticos eficientes, definir los parámetros relevantes, establecer criterios de evaluación para resolver dichos problemas. Asimismo, se requiere explorar enfoques de hibridación y combinación de diferentes técnicas metaheurísticas para mejorar la calidad de las soluciones y reducir los tiempos de ejecución.

### **1.2. FORMULACIÓN DEL PROBLEMA**

¿De qué manera las metaheurísticas pueden ayudar a las empresas a resolver los problemas de ruteo vehicular en el proceso de distribución?

### **1.3. JUSTIFICACIÓN**

La optimización del proceso de distribución es crucial para las empresas en la actualidad, ya que un enfoque eficiente puede marcar la diferencia en términos de

competitividad y rentabilidad. En este sentido, el uso de metaheurísticas se presenta como una opción prometedora para abordar problemas complejos y encontrar soluciones óptimas en un tiempo razonable.

Las metaheurísticas, como los algoritmos genéticos, las colonias de hormigas y los enjambres de partículas ofrecen ventajas significativas en comparación con los métodos tradicionales de optimización. Estos métodos permiten abordar problemas de distribución que involucran múltiples variables, restricciones complejas y un gran número de soluciones posibles. La tesis propuesta se enfocará en cómo estas herramientas pueden ser adaptadas y configuradas para optimizar el proceso de distribución en diferentes contextos y sectores industriales.

Uno de los aspectos fundamentales a considerar en esta investigación es la aplicabilidad de las metaheurísticas en diferentes industrias y cadenas de suministro. Cada sector presenta desafíos y restricciones específicas en términos de demanda, infraestructura logística, recursos disponibles y características del entorno. De manera que, es necesario estudiar cómo estos métodos pueden ser adaptadas y personalizadas para satisfacer las necesidades particulares de cada contexto, con el objetivo de maximizar la eficiencia y la calidad del servicio.

La investigación también se centra en la evaluación del impacto de la aplicación de metaheurísticas en el proceso de distribución. Esto implica analizar tanto los resultados cuantitativos, como la reducción de costos y los tiempos de entrega, como los resultados cualitativos, como la mejora en la satisfacción del cliente y la sostenibilidad. Se requiere realizar un estudio exhaustivo para comprender cómo estos métodos generan valor agregado en términos de competitividad y rentabilidad en las empresas.

Otro aspecto importante por considerar en esta tesis es la exploración de enfoques de hibridación y combinación de diferentes técnicas metaheurísticas. La combinación de múltiples algoritmos puede potenciar la capacidad de búsqueda y ayudar a encontrar soluciones óptimas en un menor tiempo. Se pueden investigar estrategias de adaptación dinámica de parámetros y de búsqueda inteligente para mejorar la calidad de las soluciones y la eficiencia del proceso de distribución.

## **1.4. OBJETIVOS Y PREGUNTAS DE INVESTIGACIÓN**

### **1.4.1. Objetivo General**

Crear un sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial.

#### 1.4.2. Objetivos Específicos

- Estudiar del estado del arte en la optimización de procesos de logística de distribución.
- Comparar los diferentes algoritmos metaheurísticos para la solución de VRP en distribución.
- Diseñar un sistema de selección de metaheurísticas con base en las dimensiones de un VRP y redes neuronales.
- Determinar el mejor algoritmo metaheurístico de VRP, en función de los parámetros de los problemas de distribución.

#### 1.4.3. Preguntas de Investigación

¿Cuál es el estado del arte en la optimización de procesos logísticos de distribución?

¿Cuáles son los tipos de algoritmos metaheurísticos para soluciones de VRP en distribución?

¿Cuál es el rendimiento del mejor algoritmo metaheurístico de VRP en comparación a los demás?

¿Cuál es el proceso óptimo para seleccionar la metaheurística adecuada para la solución de problemas de distribución?

## II. FUNDAMENTACIÓN TEÓRICA

### 2.1. ANTECEDENTES DE LA INVESTIGACIÓN

El proceso de distribución en la logística empresarial es un desafío complejo que requiere una planificación eficiente para garantizar la entrega de productos de manera oportuna y rentable. El VRP es una de las áreas más estudiadas en este contexto, ya que implica la optimización de rutas de vehículos para satisfacer la demanda de múltiples clientes. A medida que las empresas enfrentan la necesidad de mejorar continuamente sus operaciones de distribución, se han propuesto y desarrollado diversas técnicas y metodologías para resolver dichos problemas.

Las metaheurísticas han surgido como herramientas flexibles y eficaces para ofrecer soluciones aproximadas de alta calidad en diversos problemas. El trabajo de Colin, (2024), destaca por su uso innovador del algoritmo de Recocido Simulado para resolver el desafío del ruteo de vehículos multi-depósitos. Mediante experimentos con 23 instancias reconocidas, el algoritmo logró soluciones óptimas en más del 50% de los casos, respaldando su efectividad. Además, la creación de nuevas instancias de prueba amplía el conjunto de problemas disponibles para evaluar algoritmos, proporcionando una sólida base para futuras investigaciones en la selección de metaheurísticas para problemas de VRP.

El trabajo de Frutos (2023), sobre la optimización del ruteo de vehículos con drones usando algoritmos genéticos aborda el desafío del ruteo de vehículos con drones (VRPD), una extensión del clásico problema de ruteo de vehículos (VRP). La investigación emplea programación matemática y algoritmos genéticos para modelar y resolver el problema, destacando la importancia de la adecuada representación de soluciones y parametrización del algoritmo para obtener eficiencia en la resolución. Se demuestra que la integración de camiones y drones puede mejorar el nivel de servicio y la eficiencia energética en la distribución, ofreciendo una base sólida para futuras investigaciones en el desarrollo de sistemas de selección de metaheurísticas para problemas de VRP en un entorno digitalizado y exigente.

En el año 2020 Li et al (2020), publicó un artículo en la revista IEEE Access, en el que se presenta un algoritmo híbrido que combina una heurística constructiva con un

algoritmo de búsqueda local para resolver el problema de ruteo vehicular con ventanas de tiempo, entregas y recolecciones simultáneas. Los resultados experimentales muestran que el algoritmo propuesto proporciona soluciones de alta calidad en un tiempo razonable.

Fuat y Dursun (2019), presenta una solución para el VRPSDP utilizando el algoritmo de Colonia de abejas artificiales (ABC) y la aplicación se prueba con los conjuntos de datos de problemas de referencia comúnmente utilizados para VRPSDP en la literatura, al comparar los resultados con las soluciones de ruta de menor costo en la literatura, se observa que a pesar de los pocos parámetros, el método propuesto puede producir soluciones de bajo costo muy cercanas a las soluciones más exitosas en la literatura.

El siguiente estudio realizado por Montes et al (2019), contribuye al avance del campo de la optimización combinatoria y la logística, proporcionando nuevas herramientas metaheurísticas eficientes para la resolución del VRP-TW, con potenciales aplicaciones en la mejora de la planificación y la gestión de operaciones de transporte y distribución, de manera que propone dos nuevas técnicas metaheurísticas, denominadas DS-AS-PDA y DS-MMC-AS, basadas en la combinación de las técnicas heurísticas AS y MMC con los métodos exactos PDA y DSA, respectivamente. Estas técnicas están diseñadas para aprovechar la estructura y las características del modelo matemático del VRP-TW, con el objetivo de mejorar la eficiencia computacional y la calidad de las soluciones obtenidas.

## **2.2. MARCO TEÓRICO**

### **2.2.1. Algoritmo metaheurístico.**

Un algoritmo metaheurístico es un método de optimización que se utiliza para encontrar soluciones de alta calidad a problemas complejos, a menudo en situaciones en las que se desconoce la estructura exacta del problema. Los algoritmos metaheurísticos son procedimientos generales de búsqueda que utilizan estrategias de exploración y explotación para encontrar soluciones óptimas o cercanas a la óptima de un problema de optimización. Estos algoritmos son ampliamente utilizados en la resolución de problemas de optimización en diversos campos, como la ingeniería, la informática, la economía, entre otros Blum y Roli (2003).

### 2.2.2. Problema de ruteo de vehículos (VRP)

El problema de ruteo de vehículos (VRP, por sus siglas en inglés) es un problema de optimización combinatoria que consiste en determinar la mejor ruta para un conjunto de vehículos que deben visitar un conjunto de clientes, minimizando el costo total del viaje y cumpliendo con ciertas restricciones, como la capacidad máxima de los vehículos y las ventanas de tiempo para visitar los clientes. Según Toth y Vigo (2014), el VRP es uno de los problemas de optimización más estudiados y aplicados en la logística y el transporte, ya que tiene implicaciones importantes en la eficiencia de los procesos logísticos y la reducción de costos.

El VRP es un problema NP-duro, lo que significa que no hay algoritmos eficientes conocidos que puedan resolverlo para instancias grandes en tiempos razonables. Por esta razón, se han desarrollado numerosos algoritmos metaheurísticos para resolver el VRP de manera aproximada y obtener soluciones de alta calidad. Estos algoritmos incluyen el algoritmo de recocido simulado, la búsqueda tabú, el algoritmo genético, la colonia de hormigas, entre otros Toth y Vigo (2014).

### 2.2.3. Metaheurísticas para VRP

Según Loiseau (2015), el problema básico de ruteo de vehículos (VRP) consiste en determinar un conjunto de rutas para que una flota de vehículos atienda a un conjunto de clientes a un costo mínimo. Estos problemas se encuentran dentro de los problemas de optimización combinatoria económicamente más importantes y estudiados. Para una revisión general completa y bastante actualizada de los diferentes problemas de ruteo, modelos y métodos de resolución Entre las aplicaciones más comunes se encontró problemas como la distribución de productos entre un depósito central y clientes, recolección de basura, entrega de correspondencia, servicios de reparación y mantenimiento, el transporte escolar, etc. que tienen diferentes características particulares.

El VRP puede tener varios tipos de restricciones adicionales, como limitación en las capacidades de los camiones, en la cantidad y tipo de vehículos disponibles, en la longitud de los recorridos, en los horarios de trabajo de los choferes, variaciones de las características de los vehículos, horarios en que los clientes deben ser servidos, etc. Los vehículos realizan sus movimientos a través de una red de calles o rutas partiendo de uno o varios depósitos. Cada tramo de esta red, que puede ser de una sola mano o de ambas, tiene asociado un costo y/o tiempo de viaje, que puede depender de muchos factores, como por ejemplo del tipo de vehículo o del período durante el

cual el tramo es recorrido. ("Problemas de ruteo de vehículos") Entre los objetivos a minimizar pueden estar los costos, el tiempo total de transporte, la suma de los tiempos de espera de los clientes, el número de vehículos utilizados o una combinación de diversos objetivos. El conocido y muy estudiado Problema del Viajante de Comercio (*TSP*) es un caso particular de *VRP* Loiseau (2015).

#### 2.2.4. Tipo de operaciones

Anbuudayasankar et al. (2014), describe diferentes tipos de operaciones en el contexto de la logística. Algunos de ellos son:

- Operaciones de recolección y entrega (*Pickup and Delivery, PyD*): en este tipo de operaciones, se deben recoger y entregar bienes o mercancías en diferentes ubicaciones utilizando un conjunto limitado de vehículos.
- Operaciones de recolección: en estas operaciones, los vehículos deben recoger los bienes o mercancías de diferentes ubicaciones y llevarlos a una ubicación centralizada.
- Operaciones de entrega: en estas operaciones, los vehículos deben entregar los bienes o mercancías desde una ubicación centralizada a diferentes destinos.
- Operaciones de transferencia: en estas operaciones, los vehículos deben transferir los bienes o mercancías de una ubicación a otra sin recoger ni entregar nada.
- Operaciones de servicio: en estas operaciones, los vehículos deben realizar servicios en una o varias ubicaciones, como la limpieza, el mantenimiento o la instalación.
- Operaciones de carga y descarga: en estas operaciones, los vehículos deben cargar y descargar bienes o mercancías en una ubicación específica, como un puerto o un aeropuerto.

Es importante destacar que estos tipos de operaciones pueden combinarse entre sí y con otras restricciones y objetivos para formar diferentes problemas de ruteo de vehículos, como el problema de recolección y entrega con ventanas de tiempo, el problema de ruteo de vehículos con carga mixta y el problema de ruteo de vehículos con múltiples depósitos.

Las operaciones básicas en los sitios de los clientes de la mayoría de los entornos de distribución comercial caen en una de las siguientes cuatro categorías:

- *Pure pick-up or pure delivery*
- *Delivery preceding pick-up*
- *Pick-up preceding delivery*
- *Combined pick-up and delivery*

#### 2.2.5. Proceso de distribución

Los procesos de distribución juegan un papel fundamental en la cadena de suministro, ya que se encargan de llevar a cabo los productos desde los centros de producción o almacenamiento hasta los puntos de venta o los clientes finales. Estos procesos involucran una serie de actividades como la planificación de rutas, la eliminación de recursos y la gestión eficiente de los flujos de mercancías.

La optimización de la distribución en logística y cadenas de suministro es un reto complejo por la multiplicidad de variables, restricciones y objetivos involucrados Zhang, et al. (2018). Se deben considerar aspectos como la naturaleza de los productos, rutas de entrega, capacidad de vehículos, restricciones horarias y preferencias de los clientes. Además, existen restricciones de capacidad de carga, regulaciones de tránsito y ventanas horarias de entrega. La optimización busca minimizar costos, maximizar la satisfacción del cliente y cumplir con las entregas a tiempo, requiriendo un enfoque holístico que equilibre estos aspectos. La investigación se centra en desarrollar estrategias y herramientas para optimizar integralmente los procesos de distribución.

En la literatura académica, se han propuesto diversas técnicas y enfoques para abordar los problemas de distribución, y las herramientas metaheurísticas han ganado reconocimiento por su capacidad para encontrar soluciones óptimas o cercanas a la óptima en problemas complejos. Las metaheurísticas, como los algoritmos genéticos, las colonias de hormigas y los enjambres de partículas se basan en la búsqueda y optimización iterativa para encontrar soluciones de alta calidad.

Como indican Cordeau y Laporte (2003), las metaheurísticas se han convertido en herramientas valiosas para abordar el Problema de Ruteo de Vehículos (VRP), un desafío común en la distribución de mercancías. Estas técnicas permiten encontrar soluciones aceptables en tiempos razonables, incluso para problemas de gran escala con múltiples restricciones. El VRP busca determinar la secuencia óptima de rutas para un conjunto de vehículos que realizan entregas a un conjunto de clientes, con el objetivo de minimizar los costos de transporte. La aplicación de metaheurísticas en

este contexto permite obtener soluciones eficientes y prácticas en un tiempo computacional razonable.

#### 2.2.6. Redes Neuronales

Las redes neuronales artificiales son modelos inspirados en el cerebro humano, destacando la capacidad de las neuronas para procesar información. Se menciona que las redes neuronales buscan replicar la capacidad humana de aprender a través de la experiencia y resolver problemas que no pueden expresarse mediante algoritmos convencionales. La neurona biológica se describe como la unidad básica de procesamiento que se activa mediante eventos electroquímicos al alcanzar un umbral de excitación. Se destaca la importancia de la interconexión de miles de neuronas en el cerebro humano para el pensamiento y la inteligencia. Además, se enfatiza que las redes neuronales artificiales consisten en unidades de procesamiento que intercambian datos, se utilizan para reconocer patrones y tienen la capacidad de aprender y mejorar su rendimiento. Se menciona una clasificación de modelos de redes neuronales según su similitud con la realidad biológica, dividiéndolos en modelos de tipo biológico y modelos dirigidos a aplicaciones específicas Matich (2001).

#### 2.2.7. Concepto de Inteligencia artificial (IA)

La inteligencia artificial (IA) es un campo de la informática que busca emular la inteligencia humana en máquinas. Esto implica la creación de sistemas que puedan razonar, aprender, resolver problemas y tomar decisiones de forma autónoma. La IA tiene un amplio espectro de aplicaciones, desde el reconocimiento de imágenes y el procesamiento del lenguaje natural hasta la robótica y la toma de decisiones médicas Russell y Norvig (2020).

##### 2.2.7.1. Historia de la IA

La historia de la IA comienza en la antigua Grecia con los primeros filósofos que se interesaron en la naturaleza del pensamiento y la mente. Sin embargo, no fue hasta el siglo XX que la IA se convirtió en un campo de estudio formal con la aparición de la informática. Desde entonces, la IA ha experimentado un rápido desarrollo, con avances en áreas como el aprendizaje automático, las redes neuronales artificiales y la computación en la nube Russell y Norvig (2020).

### 2.2.7.2. Enfoques de la IA

Existen diferentes enfoques para la investigación y desarrollo de la IA. Algunos de los enfoques más comunes incluyen:

- Enfoque simbólico: Este enfoque se basa en la representación de símbolos y reglas para representar el conocimiento y el razonamiento.
- Redes neuronales artificiales: Este enfoque se basa en la estructura del cerebro humano para crear sistemas que puedan aprender y adaptarse.
- Computación evolutiva: Este enfoque se basa en la evolución natural para crear sistemas que puedan mejorar su rendimiento con el tiempo

### **III. METODOLOGÍA**

#### **3.1. ENFOQUE METODOLÓGICO**

##### 3.1.1. Enfoque

La presente investigación tiene un enfoque cuantitativo ya que se enfoca en la recopilación y el análisis de datos numéricos relacionados con el desempeño y los resultados de las metaheurísticas aplicadas al VRP. Este enfoque implica la utilización de métricas y medidas cuantitativas para evaluar y comparar el rendimiento de las metaheurísticas.

##### 3.1.2. Tipo de Investigación

La presente investigación es de tipo aplicada y descriptiva. Puesto que tiene por objetivo aplicar los conocimientos y herramientas teóricas a problemas o situaciones prácticas en el mundo real, como la optimización de procesos logísticos en las empresas con problemas de VRP. De la misma manera busca describir los diferentes tipos de metaheurísticas y su comportamiento con relación a las características y entornos que presentan las empresas.

#### **3.2. HIPÓTESIS**

H0: Un sistema de selección de metaheurísticas para VRP no mejora los procesos de distribución.

H1: Un sistema de selección de metaheurísticas para VRP mejora los procesos de distribución.

#### **3.3. DEFINICIÓN Y OPERACIONALIZACIÓN DE LAS VARIABLES**

##### 3.3.1. Definición de las variables

Variable Independiente: Sistema de Metaheurística

Este sistema resulta ser innovador para la resolución de problemas de VRP. Se basa en la integración de técnicas avanzadas de inteligencia artificial con una amplia gama de metaheurísticas, con el objetivo de ofrecer una herramienta poderosa y eficaz para la optimización de rutas de vehículos en entornos logísticos complejos.

Variable dependiente: Procesos logísticos de distribución

La variable dependiente de esta investigación no solo se enfoca en los procesos logísticos de distribución, sino que también busca transformarlos y optimizarlos mediante el uso de tecnologías avanzadas, mejorando la competitividad y la capacidad de adaptación de las empresas en un entorno logístico cada vez más dinámico y exigente.

### 3.3.2. Operacionalización de las variables

En la Tabla 1, se detalla los parámetros de la variable dependiente e independiente, que abarca una serie de dimensiones y restricciones relacionadas con la operación de vehículos, la planificación y la recolección de datos, y la variable dependiente, que se centra en el proceso logístico de distribución.

**Tabla 1.** Operacionalización de variables

Variable	Dimensión	Indicadores	Técnica	Instrumento		
<b>Variable independiente</b> <b>Sistema de Metaheurística</b>	Restricciones con relación a vehículos	Tipo de flota	Estudio causal – comparativo	Bases de datos		
		Número de vehículos				
		Capacidad de vehículos				
	Restricciones operacionales	Distancia máxima				
		Tiempo máximo				
		Ventana de tiempo				
	Condiciones estáticas	Número de centros de distribución.			Modelación	
		Solo <i>Pick-up</i>				
	Tipos de operaciones	Solo <i>Delivery</i>			Programación de algoritmos	Ficha bibliográfica
		<i>Pick-up</i> y <i>Delivery</i>				
Requerimiento de personal	Simultáneo	Programación de aplicaciones	Ficha de observación			
	Secuencial					
	Número de conductores					
Requerimiento de planificación	Hora de inicio y fin de ruta	Entrevista				
	Tiempo de descanso					
	Número de nodos de carga					
Requerimiento de datos	Número de nodos de descarga					
	Red vial					
		Información geográfica				

Variable	Dimensión	Indicadores	Técnica	Instrumento
<b>Variable dependiente Proceso logístico de distribución</b>	Costos	Ubicación de nodos	Búsqueda bibliográfica	Registros históricos Ficha bibliográfica
		Ubicación de vehículos		
		Estructura de pago		
	Tiempos	Costo de rutas de distribución		
		Tiempos de rutas de distribución		
	Distancia	Distancia de rutas de distribución		
	Planificación	Eficiencia en la distribución		
Análisis y Diseño	Tiempo de Análisis Tiempo de Diseño Tiempo de Selección			

### 3.4. MÉTODOS UTILIZADOS

#### 3.4.1. Métodos

##### 3.4.1.1. Teórico

Para el desarrollo de la investigación es necesario la utilización de fundamentos teóricos como punto de partida que servirán para la descripción de las empresas con relación a los procesos logísticos de distribución. El método mencionado permitirá analizar los datos históricos y actuales de las empresas sobre las diferentes rutas de distribución y la inclinación que esta tenga a futuro.

##### 3.4.1.2. Experimental

El método experimental ayuda a la manipulación y registro de las variables con el propósito de poder verificar una hipótesis, a través del planteamiento de función objetivo y explicación de las variables con relación al comportamiento.

##### 3.4.1.3. VRP

La comparación de metaheurísticas de VRP enfocadas en el *delivery*, busca optimizar recursos con relación a los procesos de distribución con características propias de cada empresa.

### 3.4.2. Técnicas

#### 3.4.2.1. Búsqueda bibliográfica

La técnica utilizada es fundamental en el desarrollo de una investigación sobre metaheurísticas para VRP en procesos de distribución, puesto permite recopilar y analizar de manera sistemática la información existente en fuentes bibliográficas relevantes, como libros, revistas científicas, conferencias, tesis, informes técnicos, entre otros.

Al revisar las publicaciones existentes, se pueden identificar las técnicas, enfoques y resultados más recientes en el campo. Esto ayuda a comprender la evolución de las metaheurísticas y proporciona una base sólida para el desarrollo de la investigación.

#### 3.4.2.2. Estudio causal - comparativo

Esta técnica utilizada permite conocer la relación causa – efecto por el tiempo computacional en que los datos trabajan. Dicha investigación es tanto retrospectiva puesto que se centra en analizar el problema luego de los efectos, como prospectiva debido a la evaluación de este antes de que los hechos sucedan.

## 3.1. RECURSOS

A continuación, se detallarán los recursos necesarios que se va a tomar en cuenta para el desarrollo de la presente investigación:

**Tabla 2.** Recursos

<b>RECURSOS</b>	
<b>INSTITUCIONALES</b>	Repositorio Digital UPEC Libros UPEC Libreta de apuntes
<b>MATERIALES</b>	Esferos Libros
<b>ECONÓMICOS</b>	Viáticos
<b>TECNOLÓGICOS</b>	Computador
<b>RECURSOS</b>	
	Celular Internet Microsoft 365 <i>Google Colab</i>

### **3.5. ANÁLISIS ESTADÍSTICO**

El procesamiento y análisis de datos se realizó en dos etapas. En la primera etapa, se recopiló la información extraída de la revisión bibliográfica de casos de estudio sobre metaheurísticas aplicadas a soluciones de problemas VRP, tomando en cuenta los parámetros y restricciones utilizadas para la solución. Esta información se organizó en una base de datos de Excel.

En la segunda etapa, se cargó la base de datos en un cuaderno de *Google Colab* donde se realizó la programación del algoritmo con *Python*. En este cuaderno, se utilizaron códigos de aprendizaje automático para crear un árbol de decisión y una red neuronal. Estos modelos se utilizaron para seleccionar el algoritmo más adecuado para solucionar problemas de ruteo vehicular (VRP) en las empresas según las características propias de cada uno.

## IV. RESULTADOS Y DISCUSIÓN

### 4.1. RESULTADOS

4.1.1. Casos de estudio de metaheurísticas aplicadas a problemas de VRP.

Los estudios revisados ofrecen una perspectiva clara sobre la eficacia de diversas metaheurísticas al enfrentar desafíos específicos en el ruteo vehicular, logrando mejoras sustanciales en eficiencia operativa y gestión de costos. Cada método aborda con éxito problemas particulares relacionados con la logística de transporte, empleando una variedad de enfoques metaheurísticos. Los resultados obtenidos revelan avances notables en la optimización de rutas y la eficiente asignación de recursos en diversos entornos y escenarios.

Es notable la orientación de la investigación hacia la resolución de problemas del mundo real, como el ruteo de vehículos con ventanas de tiempo, demanda estocástica y distribución de productos perecederos, entre otros escenarios logísticos. La aplicabilidad práctica de los métodos propuestos se refleja en los resultados obtenidos, evidenciando su utilidad en la gestión eficiente de flotas de vehículos en contextos complejos y dinámicos.

Las metaheurísticas empleadas en estos estudios abarcan una amplia gama de técnicas, incluyendo búsqueda tabú, recocido simulado, algoritmos genéticos, heurística de *Clarke and Wright*, metaheurísticas híbridas, optimización espiral y búsqueda armónica. Esta diversidad de enfoques resalta la amplitud de herramientas disponibles para abordar los desafíos específicos del ruteo vehicular, proporcionando a los profesionales de la logística una variedad de opciones eficaces y adaptativas para mejorar la eficiencia operativa y reducir los costos asociados al transporte.

**Tabla 3.** Casos de metaheurísticas aplicadas a solución de VRP

Método Utilizado	Características generales	Referencias bibliográficas
<p><b>Búsqueda de Tabú</b></p>	<ul style="list-style-type: none"> <li>• Se centran en el Problema de Ruteo de Vehículos (VRP), teniendo en cuenta restricciones como capacidades de los vehículos, ventanas de tiempo y visitas sincronizadas.</li> <li>• La flexibilidad del algoritmo se demuestra al abordar casos con clientes dispersos, ventanas de tiempo y visitas sincronizadas.</li> <li>• La validación del modelo muestra mejoras significativas en los costos de transporte, la utilización de la capacidad de los camiones y la distancia total recorrida.</li> <li>• Introduce una memoria a corto plazo llamada "lista tabú" que registra movimientos recientes y evita que el algoritmo repita soluciones previas.</li> <li>• Se destaca la importancia de ajustar parámetros y estrategias de búsqueda según el escenario del problema.</li> <li>• Versatilidad para adaptarse a cualquier problema del ámbito empresarial.</li> </ul>	<ul style="list-style-type: none"> <li>• Gómez, J. Zamudio, B (2023)</li> <li>• Boza, O. Lecca, E. Acevedo, A. (2012)</li> </ul>
<p><b>Algoritmo genético</b></p>	<ul style="list-style-type: none"> <li>• Consideran aspectos importantes como ventanas de tiempo, tiempos de servicio y restricciones de capacidad. Estos elementos son fundamentales en problemas de ruteo de vehículos del mundo real.</li> <li>• En uno de los casos, se destaca que el algoritmo genético logra una disminución del 54 % en los kilómetros recorridos en comparación con una herramienta de optimización existente. Esto subraya la eficiencia del algoritmo genético en la mejora de la eficacia logística.</li> </ul>	<ul style="list-style-type: none"> <li>• Gómez, D. (2022)</li> <li>• Martínez, J. Vega, F. (2020)</li> </ul>

Método Utilizado	Características generales	Referencias bibliográficas
<b>Búsqueda Armónica</b>	<ul style="list-style-type: none"> <li>• En uno de los casos, se destaca que el algoritmo genético logra una disminución del 54% en los kilómetros recorridos en comparación con una herramienta de optimización existente. Esto subraya la eficiencia del algoritmo genético en la mejora de la eficacia logística.</li> <li>• <i>Harmony Search</i> se inspira en el proceso de improvisación musical y se utiliza para encontrar soluciones de alta calidad en problemas de optimización.</li> <li>• Las soluciones potenciales se representan como armonías musicales. Cada variable en la solución se asocia con una nota musical y se organiza en un vector.</li> <li>• Se realizan comparaciones con modelos matemáticos, la eficacia y flexibilidad de la metaheurística se destacan en estas comparaciones, sugiriendo que <i>Harmony Search</i> puede proporcionar soluciones competitivas y prácticas en comparación con enfoques más teóricos.</li> <li>• La generación de nuevas soluciones se realiza mediante la combinación de las mejores soluciones actuales, emulando el proceso de ajuste gradual en la música. Esto se logra mediante operadores como improvisación, memoria y exploración.</li> <li>• La metaheurística puede ser particularmente efectiva para abordar el desafío de organizar y ubicar las cajas de manera eficiente en el espacio tridimensional</li> </ul>	<ul style="list-style-type: none"> <li>• Barros, M. (2020)</li> </ul>
<b>Heurística de Clarke y Wright</b>	<ul style="list-style-type: none"> <li>• Es una heurística de construcción utilizada para encontrar soluciones aproximadas al VRP. Se basa en el concepto de</li> </ul>	<ul style="list-style-type: none"> <li>• Maguiña, L. (2016)</li> <li>• Prato, Suero y Guzmán. (2015)</li> </ul>

Método Utilizado	Características generales	Referencias bibliográficas
<b>Metaheurísticas híbridas</b>	<p>“ahorros” al combinar rutas y reducir los costos totales de transporte.</p> <ul style="list-style-type: none"> <li>• En los casos mencionados, se informa un ahorro del 17.55 % y 18.75 %, respectivamente, utilizando esta técnica en comparación con otros enfoques.</li> <li>• Se logra aprovechar espacios y reducir la subutilización, lo que conduce a una disminución en el número de despachos de vehículos a la semana sin comprometer la satisfacción de la demanda de los clientes.</li> <li>• La heurística sigue un procedimiento de construcción secuencial. Se evalúan y combinan rutas de manera iterativa para mejorar la eficiencia del ruteo y reducir los costos.</li> <li>• <i>Clarke-Wright Savings</i> sigue un enfoque "Greedy" (ávido), tomando decisiones localmente óptimas en cada paso sin considerar la optimización global.</li> </ul> <p>La heurística <i>Clarke-Wright</i> puede adaptarse y modificarse para abordar variaciones específicas del problema, lo que la hace versátil y aplicable a diferentes contextos de ruteo de vehículos. exhaustiva del espacio de búsqueda. Cada decisión se toma de manera rápida y local.</p> <ul style="list-style-type: none"> <li>• Se centra específicamente en la resolución de problemas de rutas de vehículos, en este caso, el <i>Capacitated Vehicle Routing Problem (CVRP)</i>.</li> <li>• Combinan elementos de al menos dos algoritmos diferentes para aprovechar sus fortalezas individuales.</li> </ul>	<ul style="list-style-type: none"> <li>• Soto, et al. (2008)</li> </ul>

Método Utilizado	Características generales	Referencias bibliográficas
<b>Optimización espiral SOA</b>	<ul style="list-style-type: none"> <li>• Los resultados experimentales demuestran la eficacia de las metaheurísticas híbridas propuestas en la resolución de los problemas específicos. Esto destaca la capacidad de estas combinaciones para proporcionar soluciones competitivas y eficientes.</li> <li>• Las metaheurísticas híbridas son adaptables a diversas variantes de VRP, como VRP con capacidad limitada (CVRP), VRP con ventanas de tiempo (VRPTW), VRP con múltiples depósitos, etc.</li> <li>• La implementación exitosa de metaheurísticas híbridas para VRP a menudo involucra experimentación y ajuste de parámetros.</li> <li>• Se ha adaptado específicamente para abordar el VRPSD. Esta adaptación implica considerar la demanda estocástica de los clientes en lugar de valores determinísticos, lo que hace que el problema sea más complejo y desafiante.</li> <li>• La efectividad de la metaheurística SOA se evalúa comparándola con investigaciones anteriores que utilizaron otras metaheurísticas para abordar el VRPSD. Esta comparación proporciona una medida de la mejora relativa y la eficacia del enfoque propuesto.</li> <li>• Se reportan resultados significativos en términos de mejoras en la distancia total de viaje, alcanzando hasta un 15.74 % en tres instancias específicas.</li> </ul>	<ul style="list-style-type: none"> <li>• Laban, M. (2022)</li> </ul>

Método Utilizado	Características generales	Referencias bibliográficas
<b>Recocido Simulado</b>	<ul style="list-style-type: none"> <li>• Se aplican a problemas de optimización combinatoria, donde el objetivo es encontrar la mejor combinación de elementos discretos.</li> <li>• Estas técnicas son versátiles y se aplican en diversos campos logísticos. Pueden abordar problemas donde sea necesario encontrar la mejor solución entre múltiples combinaciones posibles.</li> <li>• Se utilizan para minimizar costos o maximizar la eficiencia en problemas como el CVRP.</li> <li>• Simula el proceso de recocido en metalurgia. Utiliza probabilidades para aceptar soluciones subóptimas con el objetivo de escapar de lugares óptimos y explorar de manera más amplia el espacio de soluciones.</li> <li>• Algunos trabajos proporcionan una revisión cronológica y teórica del trasfondo de las técnicas de Recocido Simulado, destacando los resultados recientes y la evolución de la investigación en este campo.</li> </ul>	<ul style="list-style-type: none"> <li>• Tello, J. (2011)</li> </ul>
<b>Colonia de Hormigas</b>	<ul style="list-style-type: none"> <li>• La aplicación del algoritmo de Sistema de Colonia de Hormigas con Búsqueda Local queda demostrada para obtener resultados cercanos a los valores óptimos en el diseño de experimentos.</li> <li>• Esta metaheurística demostró su eficacia al producir soluciones satisfactorias en la mayoría de las instancias evaluadas. Esto destaca la robustez y aplicabilidad del algoritmo a una variedad de casos.</li> </ul>	<ul style="list-style-type: none"> <li>• Toro, et al. (2013)</li> </ul>

Método Utilizado	Características generales	Referencias bibliográficas
	<ul style="list-style-type: none"><li data-bbox="607 276 1379 480">• Los mejores resultados se obtienen asignando igual importancia a la feromona y la distancia (<math>\beta = 1</math>). Este equilibrio es esencial para el buen funcionamiento del algoritmo, ya que la feromona guía la exploración global, mientras que la distancia influye en la búsqueda local.</li><li data-bbox="607 499 1379 665">• Se identifican parámetros específicos que tienen una influencia significativa en el rendimiento del algoritmo. Esto incluye la importancia de <math>\beta</math> y <math>\rho</math> en problemas más restringidos y la relevancia de <math>a</math> y <math>\rho</math> en problemas menos restringidos.</li></ul>	

La Tabla 4 presenta un esquema metodológico detallado que guía el proceso de estudio del estado del arte en el campo de las metaheurísticas aplicadas al *Vehicle Routing Problem* (VRP). Este enfoque sistemático es fundamental para comprender cómo estas técnicas se han implementado en la resolución de problemas logísticos, así como para identificar las tendencias emergentes y evaluar la efectividad de cada metaheurística.

Establece el contexto de la investigación, se realiza una investigación exhaustiva utilizando bases de datos académicas, la información recopilada se organiza según el tipo de metaheurística lo que facilita la comprensión de las contribuciones existentes y permite comparaciones futuras, se lleva a cabo una selección rigurosa de los artículos más relevantes, aplicando criterios de impacto y novedad. Se utilizan métricas cuantitativas para asignar puntuaciones que priorizan los estudios más significativos. Los artículos seleccionados son analizados y comparados en términos de calidad de solución, adaptabilidad y tiempos de ejecución, lo que proporciona una base sólida para evaluar la efectividad de cada metaheurística y como paso final se realiza un resumen de los hallazgos clave, destacando las metaheurísticas más aplicadas y aquellas con mayor promesa en calidad de solución.

**Tabla 4.** Metodología para búsqueda bibliográfica

<b>Fase</b>	<b>Descripción</b>	<b>Técnicas o herramientas</b>
<b>Definir el problema</b>	Descripción del problema planteado en el tema de estudio y sus variantes	Artículos de revisión, libros sobre metaheurísticas, libros sobre problemas de VRP y logística de distribución.
<b>Búsqueda de fuentes</b>	Búsqueda exhaustiva en base de datos académicos para identificar trabajos relevantes sobre metaheurísticas aplicadas a problemas de VRP	Google académico, Scopus, SCIELO, IEEE Xplore.
<b>Clasificación de la literatura</b>	Organizar los estudios según el tipo de metaheurística utilizada (AG, ACO, SA, etc.) y sus aplicaciones.	Según el tipo de referencia, tipo de metaheurística, tipo de VRP, y aplicación específica
<b>Filtrado de resultados</b>	Selección de artículos más relevantes en función de criterios como impacto y novedad del enfoque	Métricas: Criterio de Impacto (1-5)

Fase	Descripción	Técnicas o herramientas
		Criterio de Novedad (1-5)
		Puntuación Total
<b>Evaluación de resultados</b>	Evaluación y comparación del desempeño de metaheurísticas aplicadas a VRP en termino de calidad de solución, adaptabilidad, tiempos de ejecución	Comparación basados en porcentajes de mejora
<b>Redacción de resultados</b>	Resumen de hallazgos claves, indicando las metaheurísticas más aplicadas, y más prometedoras en la calidad de solución	Métricas: Número de Aplicaciones Calidad de Solución (1-10)

#### 4.1.2. Comparación y rendimiento de las metaheurísticas

Para la comparación del rendimiento de las metaheurísticas aplicadas a problemas de ruteo vehicular (VRP), se consideran un conjunto de casos de estudio mencionados en la Tabla 5, que presentan diferentes tipos de problemas, y se toman en cuenta diferentes criterios, como la eficiencia en porcentaje, el método utilizado, el área a la que pertenece el caso.

**Tabla 5.** Clasificación de casos de estudio.

Clasificación	Caso	Método Utilizado	Porcentaje de mejora (%)
	Empresa manufacturera	Búsqueda de Tabú y Algoritmo genético	23
	Empresa de Rendering	Heurística de Greedy	9.6
<b>Manufactura</b>	Industria alimentaria	Heurística de Clarke y Wright	10
	Industria pastelera	Algoritmo genético	15.4
	Industria Colombiana	Recocido Simulado	4
	Packing con ruteo	Búsqueda Armónica	14.3
<b>Distribución</b>	Distribución OLDR	Búsqueda de Tabú	20

<b>Clasificación</b>	<b>Caso</b>	<b>Método Utilizado</b>	<b>Porcentaje de mejora (%)</b>
	Distribución de productos en polvo para construcción	<i>Heurística de Clarke y Wright</i>	15.3
	Distribución de bebidas	Algoritmo genético	37.24
	Distribución de papa	Colonia de Hormigas	18
	Distribución de comida	Vecino más cercano	13.2
	Distribución de productos perecederos	Algoritmo genético	10.2
	Entrega de periódico	Heurística de Greedy	37
	Demandas estocásticas	Optimización espiral SOA	15.74
	Distribución a una línea de supermercados	Heurística de <i>Clark and Wright</i>	41
	Distribución secundaria	Recocido Simulado	13.2
	Distribución laboratorios	Búsqueda de Tabú	3
	Empresa alimenticia Cali	Búsqueda de Tabú	17.58
	Ventanas de tiempo y visita sincronizada	Búsqueda de Tabú	15.34
	Transporte de pacientes	Búsqueda de Tabú	20
<b>Logística y Transporte</b>	Rutas de autobuses escolares	Vecino más cercano	33.2
	Transporte de combustible	Heurística de <i>Clarke y Wright</i>	11.6
	Transporte de acopio de leche	Heurística de <i>Clarke Wright</i>	10.6
	Recolección y custodia de documentos	Algoritmo genético	54
<b>Recolección</b>	Recolección por contenedores	Metaheurísticas híbridas	12.5
	Recolección de residuos municipio San Miguel noche	Colonia de Hormigas	6.33
	Recolección de residuos	Colonia de Hormigas	23.5

<b>Clasificación</b>	<b>Caso</b>	<b>Método Utilizado</b>	<b>Porcentaje de mejora (%)</b>
	Recolección y distribución de leche	Colonia de Hormigas	27.6
	Recolección de nieve	Recocido Simulado	17.3
	Recolección de basura	Vecino más cercano	20.12

La Tabla 5 presenta una amplia variedad de casos de estudio véase en Anexo 3, en áreas como manufactura, distribución, logística y transporte, y recolección. Cada caso incluye información relevante sobre el método utilizado, la eficiencia alcanzada y las características específicas del caso.

Los resultados muestran que no existe un método único que sea eficiente en todas las áreas. La elección del método adecuado depende de las características y restricciones de cada caso. La diversidad de métodos y resultados demuestra la complejidad de los desafíos logísticos y de optimización.

La Tabla 6 presentada ofrece un análisis de la eficiencia de los métodos utilizados para la distribución y recolección en diversos escenarios prácticos. Este análisis se basa en dos criterios principales: la clasificación del caso, el método empleado para optimizar el proceso y los porcentajes de eficiencia obtenidos tras la aplicación de dichos métodos.

**Tabla 6.** Clasificación de casos de estudio según el método utilizado

Clasificación	Caso	Método Utilizado	% uso método	Porcentaje de mejora (%)	de	Porcentaje promedio de mejora del método (%)
DISTRIBUCIÓN	Distribución OLDR			20		
DISTRIBUCIÓN	Distribución laboratorios			3		
DISTRIBUCIÓN	Empresa alimenticia Cali			17.58		
LOGÍSTICA Y TRANSPORTE	Ventanas de tiempo y visita sincronizada	Búsqueda de Tabú	20 %	15.34		17 %
LOGÍSTICA Y TRANSPORTE	Empresa manufacturera			23		
LOGÍSTICA Y TRANSPORTE	Transporte de pacientes			20		
MANUFACTURA	Industria pastelera			15.4		
DISTRIBUCIÓN	Distribución de bebidas			37.24		
DISTRIBUCIÓN	Distribución de productos perecederos	Algoritmo genético	13 %	10.2		21 %
RECOLECCIÓN	Recolección y custodia de documentos			54		
	<i>Packing</i> con ruteo	Búsqueda Armónica	3 %	14.3		3 %
MANUFACTURA	Industria alimentaria		17 %	10		16 %
DISTRIBUCIÓN	Distribución de productos en polvo para construcción	Heurística de Clarke <i>Wright</i>		15.3		
DISTRIBUCIÓN	Distribución a una línea de supermercados			41		
LOGÍSTICA Y TRANSPORTE	Transporte de combustible			11.6		

Clasificación	Caso	Método Utilizado	% uso método	Porcentaje de mejora (%)	Porcentaje promedio de mejora del método (%)
LOGÍSTICA Y TRANSPORTE	Transporte de acopio de leche			10.6	
MANUFACTURA	Empresa de Rendering	Heurística de Greedy	7 %	9.6	8 %
DISTRIBUCIÓN	Entrega de periódico			37	
RECOLECCIÓN	Recolección por contenedores	Metaheurísticas híbridas	3 %	12.5	2 %
DISTRIBUCIÓN	Demandas estocásticas	Optimización espiral SOA	3 %	15.74	3 %
MANUFACTURA	Industria Colombiana			4	
DISTRIBUCIÓN	Distribución secundaria	Recocido Simulado	10 %	13.2	6 %
RECOLECCIÓN	Recolección de nieve			17.3	
DISTRIBUCIÓN	Distribución de comida			13.2	
LOGÍSTICA Y TRANSPORTE	Rutas de autobuses escolares	Vecino más cercano	10 %	33.2	12 %
RECOLECCIÓN	Recolección de basura			20.12	
DISTRIBUCIÓN	Distribución de papa			18	
RECOLECCIÓN	Recolección de residuos municipio San Miguel noche	Colonia de Hormigas	13 %	6.33	13 %
RECOLECCIÓN	Recolección de residuos			23.5	
RECOLECCIÓN	Recolección y distribución de leche			27.6	
			<b>100 %</b>		<b>100 %</b>

En la Tabla 6, se observa que los métodos de distribución más eficientes son aquellos que implementan algoritmos genéticos, como se evidencia en la industria pastelera, donde se logró una eficiencia del 21 %. Otras metodologías eficaces incluyen la búsqueda de tabú, como se aprecia en la distribución de la empresa OLDR, con un rendimiento del 17 %, y la optimización espiral SOA, empleada en la distribución de demandas estocásticas, logrando una eficiencia del 15.74 %.

En cuanto a la recolección, se destaca que los métodos más eficientes son aquellos que incorporan metaheurísticas híbridas, como se evidencia en la recolección por contenedores, con un rendimiento del 12.5 %. Otros métodos eficaces incluyen la búsqueda armónica, como en el caso del *packing* con ruteo, con una eficiencia del 14.3 %, y la colonia de hormigas, utilizada en la distribución de papa, con una eficiencia del 18 %.

Cabe destacar que los métodos más utilizados son la búsqueda tabú, con un 20 % de adopción, y la búsqueda armónica, con un 3 % de utilización. Estas metodologías resultan relativamente simples de implementar y pueden ofrecer resultados aceptables en la mayoría de los casos.

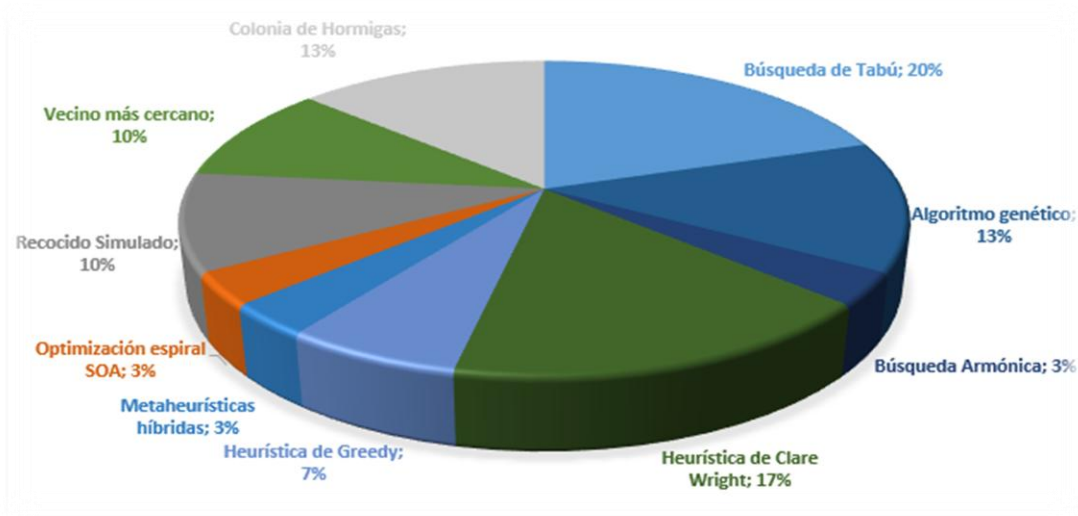
Desde una perspectiva de clasificación, se evidencia que los métodos de distribución superan en eficiencia a los métodos de recolección. Esto se atribuye a la naturaleza más estructurada y predecible de los procesos de distribución en comparación con los de recolección.

En términos de distribución, los métodos más eficientes se aplican en situaciones donde la demanda es variable o impredecible. Esto se debe a su capacidad para adaptarse a cambios en la demanda y ofrecer soluciones eficientes en todo momento.

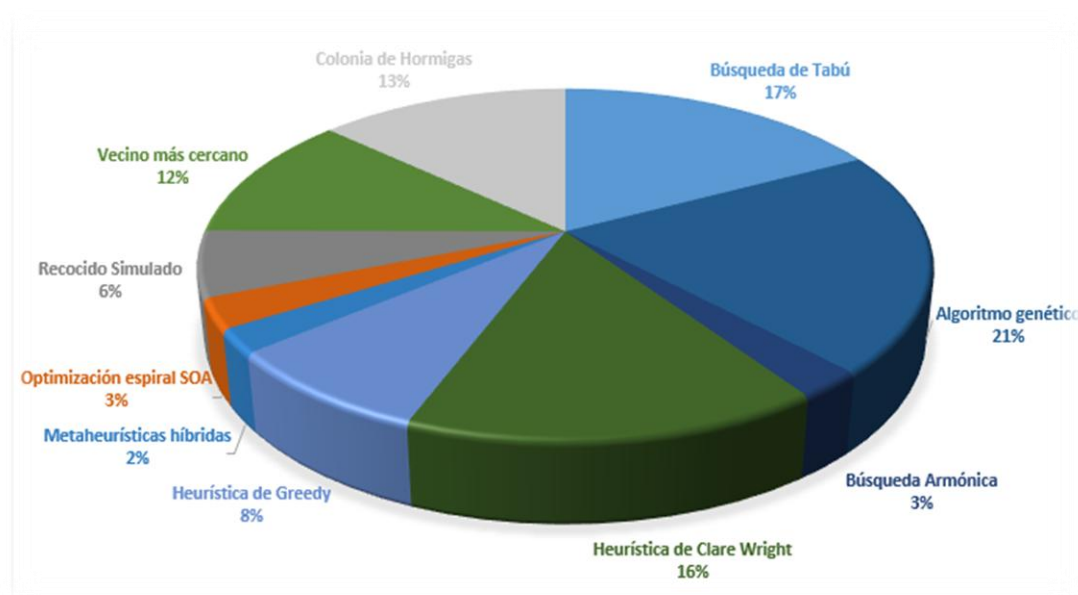
Por otro lado, en el ámbito de la recolección, los métodos más eficientes se emplean en casos donde los puntos de recolección están dispersos, permitiendo minimizar la distancia recorrida por los vehículos de recolección.

En ese sentido, los resultados de la Tabla 5 muestran que existen una serie de métodos eficientes para optimizar los procesos de distribución y recolección. La selección del método más adecuado dependerá de las características específicas del caso en cuestión.

En la Figura 1 y la Figura 2, se muestra los porcentajes de uso de algoritmo y de mejora con relación al método utilizado, lo que conlleva una estrecha relación en donde la mejora varía considerablemente entre los métodos.



**Figura 1.** Porcentaje de uso de algoritmo



**Figura 2.** Porcentaje de mejora con relación al método utilizado.

En la Figura 1 y la Figura 2, el algoritmo genético (21 %) y la colonia de hormigas (18 %) son los métodos más eficientes y el recocido simulado (6 %) y la optimización espiral SOA (15.74 %) los menos eficientes. La elección del método adecuado dependerá de las características y restricciones de cada caso, considerando factores como la complejidad del problema, la disponibilidad de datos, el tiempo de ejecución y el costo.

Este análisis se basa en un número limitado de casos de estudio y los resultados pueden variar en diferentes situaciones. Se recomienda consultar la fuente original de la información para obtener detalles adicionales sobre los casos analizados.

#### 4.1.3. Árbol de decisión para clasificación

El diagrama de flujo proporciona una estructura lógica y condicional para determinar el valor de la variable  $x$  basándose en una serie de preguntas sobre las variables  $x_{10}$ ,  $x_{18}$ ,  $x_{15}$  y  $x_4$ . Cada ruta en el diagrama conduce a una hoja terminal que asigna un valor específico a  $x$  dependiendo de las condiciones evaluadas. La inclusión de medidas como el índice Gini, el número de muestras y los valores finales de  $x$  para cada conjunto de datos, refleja la naturaleza predictiva del modelo representado por el diagrama.

A continuación, se detalla el pseudocódigo del árbol de decisión en *Python*:

```
import numpy as np
import pandas as pd
from matplotlib import pyplot as plt
%matplotlib inline
datos = pd.read_excel("/content/MyDrive/DATOS_MET.xlsx")
datos
from google.colab import drive
drive.mount('/content/drive')
datos
datos.describe()
datos.corr()
import seaborn as sns
plt.style.use("default")
plt.figure(figsize=(15,15))
sns.heatmap(datos.corr(),annot = True)
plt.title("Correlation Matrix")
plt.show()
features =
np.asarray(datos[["CLIENTES", "DEP", "VEN_TIEMPO", "DEP", "DEL", "PICK", "SE
C", "VEHICULOS", "T_FLOTA", "DIST_MAX", "COND", "CLI_CARGA", "CLI_DESCARGA",
"COSTO/KM", "DISTANCIA", "UND_CARGA", "CAPACIDAD", "TIM_SERVICIO", "EFICIEN
CIA"]])
targets = np.asarray(datos[["ALG"]])
print(targets)
features.shape, targets.shape
from sklearn.model_selection import train_test_split
train_features, test_features, train_targets, test_targets =
train_test_split(features, targets, random_state = 60)
train_features.shape, train_targets.shape
from sklearn.preprocessing import StandardScaler
from sklearn.tree import DecisionTreeClassifier
```

```

from sklearn.metrics import accuracy_score, classification_report,
confusion_matrix

d_tree = DecisionTreeClassifier(max_depth=5)

d_tree
sc = StandardScaler()
train_features = sc.fit_transform(train_features)
test_features = sc.fit_transform(test_features)

d_tree.fit(test_features, test_targets)
predictions = d_tree.predict(test_features)
print(test_targets)
print(predictions)
print(classification_report(test_targets, predictions))
np.median(np.abs(predictions-test_targets))
plt.figure(figsize=(5,5))
sns.heatmap(confusion_matrix(test_targets, predictions), annot = True)
plt.title("Confusion matrix")
plt.show()
from sklearn import tree
fig = plt.figure
_ = tree.plot_tree(d_tree, filled = True)

```

La Figura 3 muestra un diagrama de flujo para el cálculo del valor de una variable  $x$ . El diagrama comienza con la pregunta ¿ $x_{10} < -0.219$ ? Si la respuesta es sí, el valor de  $x$  se establece en 0. Si la respuesta es no, el diagrama continúa con la siguiente pregunta: ¿ $x_{18} < -0.479$ ?

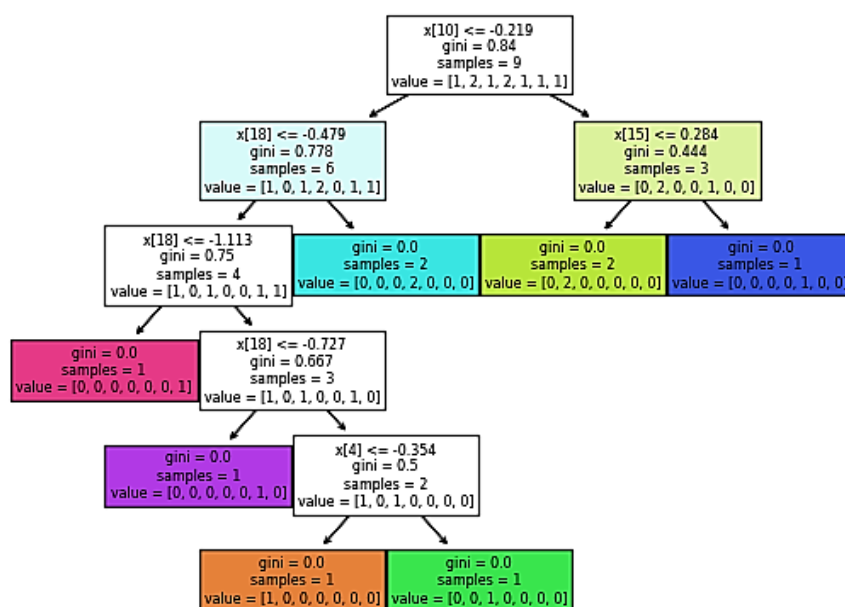


Figura 3. Árbol de decisión.

Este proceso continúa hasta que se llega a una hoja terminal, que asigna un valor a  $x$ . En total, hay 10 hojas terminales, cada una con un valor diferente para  $x$ .

Las siguientes son las posibles rutas que se pueden tomar a través del diagrama de flujo:

- Si  $x_{10}$  es menor que  $-0.219$ , entonces  $x$  se establece en  $0$ .
- Si  $x_{10}$  no es menor que  $-0.219$ , entonces se comprueba si  $x_{18}$  es menor que  $-0.479$ .
- Si  $x_{18}$  es menor que  $-0.479$ , entonces se comprueba si  $x_{15}$  es menor o igual que  $0$ .
- Si  $x_{15}$  es menor o igual que  $0$ , entonces  $x$  se establece en  $1$ .
- Si  $x_{15}$  no es menor o igual que  $0$ , entonces  $x$  se establece en  $2$ .
- Si  $x_{18}$  no es menor que  $-0.479$ , entonces se comprueba si  $x_4$  es menor o igual que  $-0.354$ .
- Si  $x_4$  es menor o igual que  $-0.354$ , entonces  $x$  se establece en  $0$ .
- Si  $x_4$  no es menor o igual que  $-0.354$ , entonces  $x$  se establece en  $1$ .
- El valor final de  $x$  dependerá de los valores de las variables  $x_{10}$ ,  $x_{18}$ ,  $x_{15}$  y  $x_4$ .

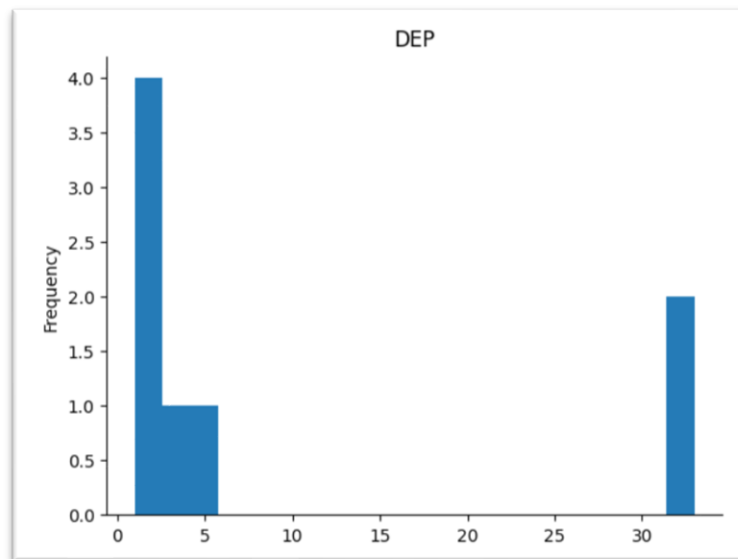
En la imagen también se incluye la siguiente información:

- Gini: Esta es una medida de la impureza de un conjunto de datos. Un valor de  $0$  indica que el conjunto de datos es completamente puro, mientras que un valor de  $1$  indica que el conjunto de datos es completamente impuro.
- Muestras: Este es el número de datos en un conjunto de datos.
- Valor: Este es el valor final de  $x$  para un conjunto de datos.

#### 4.1.3.1. Distribuciones

A continuación, se presenta los códigos correspondientes que muestran la distribución de las variables 'DEP', 'CLIENTES', 'ALG', 'CLASE\_PROCESO', mediante un histograma en la Figura 4. Este tipo de gráfico ayuda a visualizar la frecuencia de los valores y la forma de la distribución. Utilizando la biblioteca *Matplotlib* en *Python*, se generará un histograma con 20 intervalos (*bins*) para una mejor comprensión de los datos.

```
from matplotlib import pyplot as plt
_df_3['DEP'].plot(kind='hist', bins=20, title='DEP')
plt.gca().spines[['top', 'right']].set_visible(False)
```

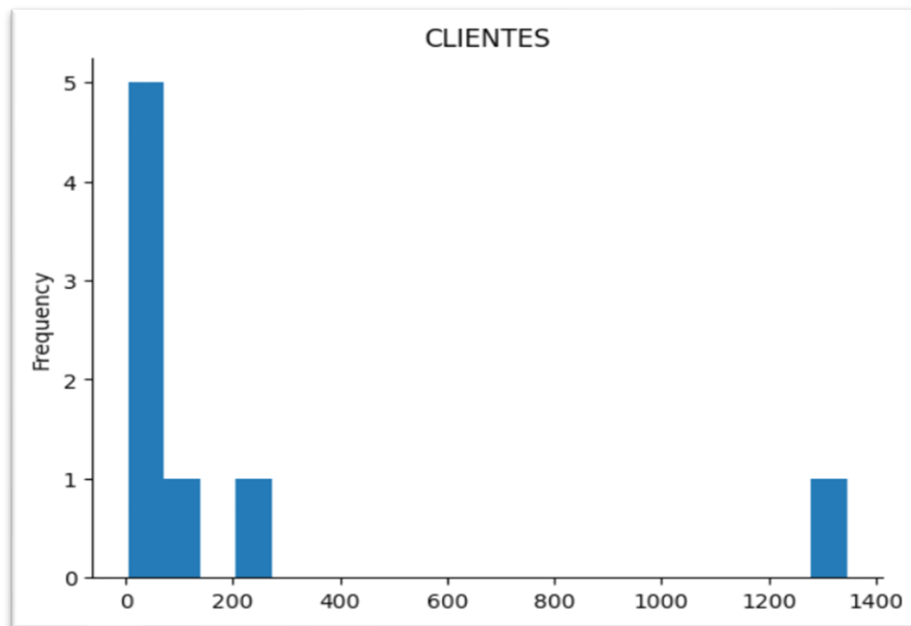


**Figura 4.** Distribución Depósitos.

En la Figura 4 se muestra una La distribución presenta una forma bimodal, con dos picos de frecuencia, uno alrededor de 0 y otro alrededor de 200. Esto sugiere que puede haber dos grupos distintos de depósitos, según la clasificación. El pico más alto se encuentra en el rango de 0 a 50, lo que indica que la mayoría de los depósitos se encuentran en este rango. El segundo pico, aunque más pequeño, se encuentra en el rango de 150 a 200. Es decir que representa cuatro tipos de depósitos diferentes, con características y patrones de distribución distintos.

En la Figura 5 La distribución se aproxima a una forma normal, con un pico central y colas que se extienden hacia ambos lados. Esto sugiere que la mayoría de los valores se encuentran cerca del promedio, con algunos valores atípicos en los extremos. El pico central se encuentra en el rango de 200 a 400, lo que indica que la mayoría de los clientes se encuentran en este rango. Las colas se extienden hasta el rango de 0 a 800, con una presencia menor de clientes en estos extremos. Esto indica que las empresas tienen una base de clientes diversa en términos de tamaño o actividad.

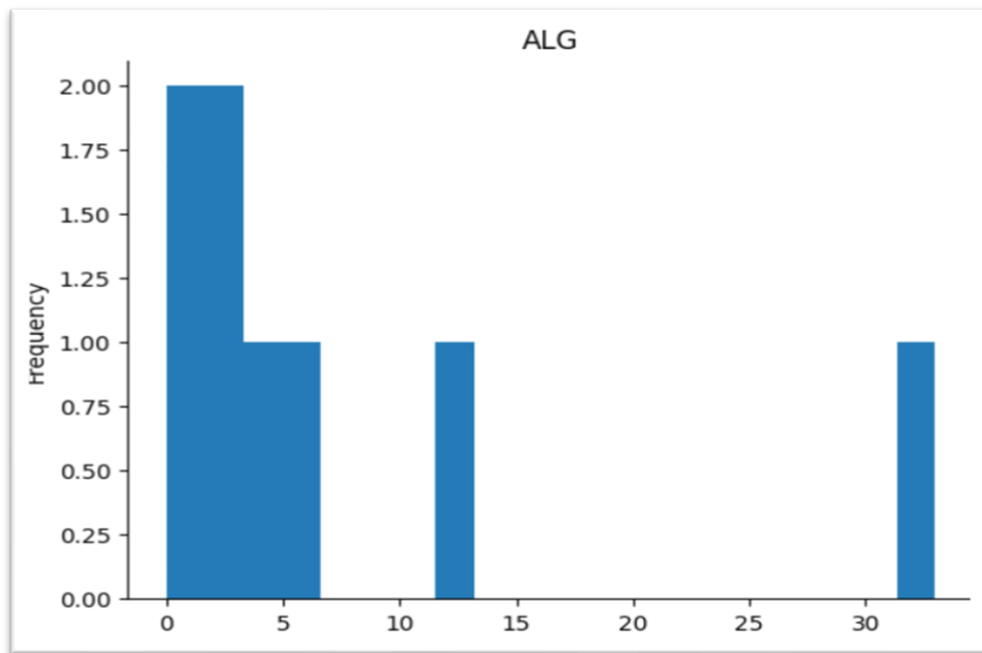
```
from matplotlib import pyplot as plt
_df_2['CLIENTES'].plot(kind='hist', bins=20, title='CLIENTES')
plt.gca().spines[['top', 'right',]].set_visible(False)
```



**Figura 5.** Distribución clientes.

En la Figura 6, la distribución presenta una asimetría positiva, con un pico en el extremo izquierdo y una cola que se extiende hacia la derecha. Esto sugiere que la mayoría de los casos se procesan utilizando un algoritmo específico, con algunos casos que se procesan con algoritmos menos comunes. El pico más alto se encuentra en el rango de 0 a 5, lo que indica que el algoritmo "0" es el más utilizado. La cola se extiende hasta el rango de 20 a 35, con una presencia menor de algoritmos en estos rangos. Es decir que se utiliza un algoritmo en principal para procesar la mayoría de los casos, con algoritmos alternativos que se utilizan en situaciones específicas o para casos más complejos.

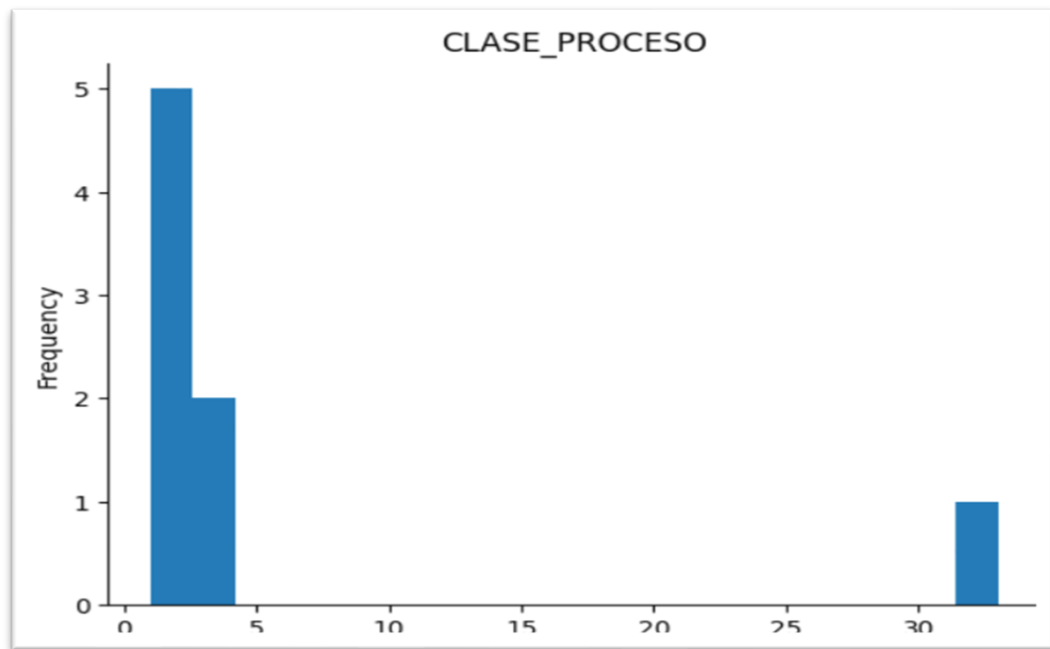
```
from matplotlib import pyplot as plt
_df_1['ALG'].plot(kind='hist', bins=20, title='ALG')
plt.gca().spines[['top', 'right',]].set_visible(False)
```



**Figura 6.** Distribución algoritmos utilizados.

En la Figura 7 la distribución presenta una asimetría negativa, con un pico en el extremo derecho y una cola que se extiende hacia la izquierda. Esto sugiere que la mayoría de los casos se clasifican en una categoría específica, con algunos casos que se clasifican en categorías menos comunes. El pico más alto se encuentra en el rango de 40 a 50, lo que indica que la categoría "40" es la más utilizada. La cola se extiende hasta el rango de 0 a 20, con una presencia menor de casos en estas categorías. Es decir que se tiene una categoría principal para clasificar la mayoría de los casos, con categorías alternativas que se utilizan para casos específicos o menos comunes.

```
from matplotlib import pyplot as plt
_df_0['CLASE_PROCESO'].plot(kind='hist', bins=20,
title='CLASE_PROCESO')
plt.gca().spines[['top', 'right',]].set_visible(False)
```




**Figura 7.** Distribución clasificación de casos.

#### 4.1.3.2 Matriz de correlación

La matriz de correlación se presenta como una herramienta valiosa para analizar las relaciones entre diversas variables, revelando coeficientes que señalan la intensidad y dirección de dichas conexiones.

```
import seaborn as sns
plt.style.use("default")
plt.figure(figsize=(15,15))
sns.heatmap(datos.corr(),annot=True)
plt.title("Correlation Matrix")
plt.show()
```

En la Figura 8, se muestra el coeficiente de correlación lineal entre cada par de variables, permitiendo determinar si existe una relación significativa y su dirección (positiva o negativa). El coeficiente puede variar entre -1 y 1, donde 0 indica ausencia de correlación, valores positivos indican correlación positiva, y valores negativos señalan correlación negativa. La matriz se emplea para identificar, evaluar la fuerza y dirección de la relación, y seleccionar variables relevantes.



**Figura 8.** Matriz de correlación.

En la Figura 8 se evidencian correlaciones positivas, con coeficientes de correlación comprendidos entre 0.69 y 0.96. Estas correlaciones indican relaciones lineales positivas entre diversas variables. Por ejemplo, se observa una correlación positiva significativa entre la distancia recorrida y las distancias máximas alcanzadas. Asimismo, se aprecia una correlación positiva entre el número de clientes de carga y la cantidad de conductores y vehículos disponibles.

En donde se identifican correlaciones negativas, con coeficientes de correlación relativamente bajos, fluctuando entre -0.64 y -0.75. Estas correlaciones están asociadas con diferentes tipos de distribución logística, tales como *delivery*, *pick up*, y secuencial. Cada uno de estos tipos de distribución posee características específicas, y no presentan correlación entre sí en el contexto observado.

#### 4.1.4. Red neuronal de clasificación con un modelo lineal usando *Tensorflow*

A continuación, se muestra el pseudocódigo para la creación de una red neuronal con un modelo lineal usando *Tensorflow*:

```
import numpy as np
import matplotlib.pyplot as plt
import tensorflow as tf
import pandas as pd

df = pd.read_excel("/content/drive/MyDrive/DATOS_MET.xlsx")
df
X =
df[["CLASE_PROCESO", "CLIENTES", "DEP", "VEN_TIEMPO", "DEL", "PICK", "SEC", "
VEHICULOS", "T_FLOTA", "DIST_MAX", "COND", "CLI_CARGA", "CLI_DESCARGA", "COS
TO/KM", "DISTANCIA", "UND_CARGA", "CAPACIDAD", "TIM_SERVICIO", "EFICIENCIA"
]].to_numpy()
X[:10]
X.shape
y = df["ALG"].to_numpy()
y[:100]
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y)
X_train.shape, X_test.shape, y_train.shape, y_test.shape
from sklearn.preprocessing import StandardScaler
sc = StandardScaler()
X_train = sc.fit_transform(X_train)
X_test = sc.fit_transform(X_test)
import tensorflow as tf

## input layer: 19 neurons
inputlyr = tf.keras.layers.Dense(units = 19)

## hidden layers with 16 neurons and relu
hdnlyr01 = tf.keras.layers.Dense(units = 16, activation = tf.nn.relu)
##hdnlyr02 = tf.keras.layers.Dropout(0.5)
hdnlyr02 = tf.keras.layers.Dense(units = 16, activation = tf.nn.relu)
## output layer
outlyr = tf.keras.layers.Dense(units = 13, activation=tf.nn.softmax)

model = tf.keras.Sequential([inputlyr, hdnlyr01, hdnlyr02, outlyr])
model.compile(
    optimizer = tf.keras.optimizers.Adam(),
    loss = tf.keras.losses.SparseCategoricalCrossentropy(),
    metrics = ["accuracy"]
)
print("training....")
history = model.fit(X_train, y_train, epochs = 100, verbose = 100)
print("Model is ready.")
```

```

#PROBAR EL MÉTODO
test_loss, test_acc = model.evaluate(X_test,y_test,verbose = 2)

print("\nTest accuracy:",test_acc)
train_loss, train_acc = model.evaluate(X_train,y_train,verbose = 2)

print("\nTrain accuracy:",train_acc)
predictions = model.predict(X_test)
predictions
## como se usa softmax la suma de probabilidades es 1
sum(predictions[5])
## cuál es el índice con la mayor probabilidad se usa np.argmax()

np.argmax(predictions[4])
plt.style.use("default")
plt.figure()
plt.xlabel("Epocas")
plt.ylabel("Loss Function")
plt.plot(history.history["loss"])
plt.show()

# se ingresa los datos de prueba
dato = [[1, 27, 1, 0, 1, 0, 0, 1, 2, 63, 1, 1, 52, 1.89, 23, 5, 3, 56,
20]]
# se transforma los datos de prueba
dato = sc.fit_transform(dato)
prediccion = model.predict(dato)
prediccion
# se encuentra el mejor algoritmo para ese caso, con esas
características
np.argmax(prediccion)

```

El código presentado comienza con la importación de bibliotecas esenciales, como *numpy* para operaciones matemáticas, *matplotlib.pyplot* para visualizaciones, *tensorflow* para construir el modelo de aprendizaje automático, y *pandas* para manipular datos en formato *DataFrame*. Luego, se aborda la carga de datos desde el archivo Excel "DATOS\_MET.xlsx" hacia un *DataFrame* de *pandas*, extrayendo características (X) y etiquetas (y), y dividiendo el conjunto en conjuntos de entrenamiento (80 %) y prueba (20 %). Se realiza un preprocesamiento aplicando escalado estándar a los datos. La construcción del modelo implica la creación de una red neuronal secuencial con capas de entrada, ocultas y salida, utilizando activaciones ReLU y *softmax*. El modelo se compila con el optimizador Adam, la función de pérdida *SparseCategoricalCrossentropy*, y la métrica de precisión. Luego, se entrena el modelo a lo largo de 100 épocas con los datos de entrenamiento y se

evalúa su precisión en ambos conjuntos. Las predicciones se realizan en los datos de prueba, utilizando *argmax* para determinar la clase con mayor probabilidad. Además, se visualiza la evolución de la función de pérdida durante el entrenamiento mediante un gráfico. Se concluye el código con la prueba de nuevos datos, escalado y predicción del algoritmo más adecuado, identificando la clase con mayor probabilidad mediante *argmax*. Este código proporciona una estructura integral para construir, entrenar y evaluar un modelo de aprendizaje automático, así como para realizar predicciones y visualizar el rendimiento del modelo.

#### 4.1.4.1. Carga de datos

- Se lee un archivo Excel "DATOS\_MET.xlsx" y se almacena en un *DataFrame* de pandas.

	CLASE_PROCESO	ALG	CLIENTES	DEP	VEN_TIEMPO	DEL	PICK	SEC	VEHICULOS	T_FLOTA	DIST_MAX	COND	CLI_CARGA	CLI_DESCARGA	COSTO/KM	DISTANCIA	UND_CARGA	CAPACIDAD	TJM_SERVICIO	EFICIENCIA
0	1	2	27	1	0	1	0	0	1	2	63.000	1	1	52	1.89	23.000	5	3	56	20.00
1	1	2	40	3	1	1	0	0	2	2	220.000	2	1	20	0.52	180.000	2	2	10	3.00
2	1	6	1346	4	1	1	0	0	18	2	618.000	18	4	1346	0.98	510.000	1	1	3	37.00
3	1	10	25	1	1	1	0	0	4	1	210.000	4	1	25	0.52	201.000	1	2	5	10.20
4	1	3	50	1	1	1	0	0	3	2	159.000	3	1	50	1.10	154.000	4	2	10	13.20
5	1	8	16	1	1	1	0	0	1	1	109.000	1	1	60	0.98	84.000	2	2	17	15.74
6	1	2	79	1	1	1	0	0	8	2	227.000	8	1	1	0.52	236.000	1	3	25	17.58
7	1	5	26	1	0	1	0	0	26	1	181.140	26	0	26	0.36	181.140	4	2	16	41.00
8	1	6	20	1	0	1	0	0	2	1	120.300	2	0	20	0.24	64.330	1	3	12	15.30
9	1	4	44	1	0	1	0	0	3	2	1590.600	3	0	44	0.08	998.260	1	3	17	37.24
10	1	1	21	4	0	0	0	1	25	2	643.000	25	0	21	0.15	950.000	1	2	10	18.00
11	1	0	15	3	1	0	1	0	9	2	256.000	2	2	13	0.15	465.000	2	1	10	13.20
12	1	2	30	1	1	1	0	0	12	2	50.000	12	0	30	0.10	50.000	2	2	60	31.00
13	2	2	100	1	1	1	0	0	2	2	1593.000	2	1	100	0.52	1200.000	2	3	10	15.34
14	2	1	79	1	1	1	0	0	8	3	227.000	8	1	79	0.52	96.000	1	3	30	21.60
15	2	2	130	1	0	0	1	0	25	2	456.000	55	1	1	8.00	222.000	1	1	7	20.00
16	2	0	13	5	1	1	0	0	8	2	483.000	4	6	7	0.11	623.000	1	2	5	33.20
17	2	1	30	2	1	1	0	0	5	2	770.000	3	0	30	0.12	753.000	3	3	45	11.60
18	2	6	18	1	1	1	0	0	5	1	2920.000	3	0	18	0.10	3999.000	3	2	12	10.60
19	3	3	52	3	1	1	0	0	6	1	776.000	6	3	52	0.52	200.000	2	2	2	12.20
20	3	11	10	1	1	0	0	1	3	1	1302.000	3	1	10	0.52	1155.000	2	2	10	23.00
21	3	5	46	1	1	0	0	1	28	2	107.000	6	1	46	1.89	69.000	4	2	15	10.00
22	3	6	13	1	1	1	0	0	4	2	909.000	4	1	13	1.69	1090.000	4	3	29	9.60
23	3	9	5	1	1	1	1	1	1	2	3500.000	1	1	1	2.01	450.000	2	2	25	14.30
24	3	4	7	1	1	1	0	0	4	2	12.900	4	1	7	0.52	25.280	1	2	5	15.40
25	4	4	140	1	1	0	1	0	15	2	205.000	15	140	1	0.52	705.000	2	2	10	54.00
26	4	7	208	1	0	0	1	0	140	2	20.755	140	208	0	0.04	18.161	1	2	7	12.50
27	4	1	21	1	0	0	1	0	12	1	283.680	12	9	1	0.56	48.000	1	2	8	6.33
28	4	0	10	2	1	0	1	0	5	2	100.000	3	10	0	0.10	50.000	1	3	10	20.12
29	4	3	20	2	1	0	1	0	7	1	420.000	5	17	3	0.13	622.000	3	2	25	17.30

Figura 9. Base de datos

- Se extraen las columnas especificadas como características (X) y la columna "ALG" como etiquetas (y).

```
array([ 2,  2,  6, 10,  3,  8,  2,  5,  6,  4,  1,  0,  2,  2,  1,  2,  0,
        1,  6,  3, 11,  5,  6,  9,  4,  4,  7,  1,  0,  3,  1,  1, 12])
```

- Se divide el conjunto de datos en entrenamiento (80 %) y prueba (20 %).

*((24, 19), (9, 19), (24, ), (9,))*

#### 4.1.4.2. Preprocesamiento

Se aplica escalado estándar a los datos de entrenamiento y prueba para normalizar las características.

#### 4.1.4.3 Construcción del modelo

Se crea un modelo de red neuronal secuencial con las siguientes capas:

- Capa de entrada con 19 neuronas (por el número de características).
- Dos capas ocultas con 16 neuronas cada una y función de activación ReLU.
- Capa de salida con 13 neuronas (por el número de clases de algoritmos) y función de activación *softmax*.
- Se compila el modelo con el optimizador Adam, la función de pérdida *SparseCategoricalCrossentropy* y la métrica de precisión.

#### 4.1.4.4. Entrenamiento del modelo

Se entrena el modelo durante 100 épocas con los datos de entrenamiento.

Epoch 1/100.....100/100

#### 4.1.4.5. Evaluación del modelo

Se evalúa la precisión del modelo en los conjuntos de entrenamiento y prueba.

*1/1 - 0s - loss: 4.9318 - accuracy: 0.1111 - 24ms/epoch - 24ms/step*

*Test accuracy: 0.1111111119389534*

*1/1 - 0s - loss: 1.1171 - accuracy: 0.7917 - 29ms/epoch - 29ms/step*

*Train accuracy: 0.7916666865348816*

#### 4.1.4.6. Predicción

- Se realizan predicciones sobre los datos de prueba.

*1/1 [=====] - 0s 95ms/step*


- Se utiliza la función *argmax* para encontrar la clase con mayor probabilidad para cada dato.

```
array([[7.88343847e-02, 1.56818822e-01, 1.76032901e-01, 1.10619940e-01,
        1.19826002e-02, 6.39183372e-02, 1.93846095e-02, 2.10850630e-02,
        6.28043786e-02, 4.34076004e-02, 8.36433917e-02, 1.36658505e-01,
        3.48095559e-02],
       [4.35105860e-02, 2.67586678e-01, 1.40751526e-01, 1.18295096e-01,
        6.65211901e-02, 4.83044088e-02, 5.48013672e-02, 2.69453619e-02,
        5.56497127e-02, 3.38705368e-02, 4.71050479e-02, 5.37442043e-02,
        4.29142490e-02],
       [6.48885667e-02, 5.62474914e-02, 5.05034685e-01, 1.24247894e-01,
        1.91218462e-02, 2.98180748e-02, 9.29110870e-03, 1.48232644e-02,
        1.71128977e-02, 2.88078953e-02, 4.32806015e-02, 6.87851161e-02,
        1.85405221e-02],
```

```
[7.33281821e-02, 3.57217640e-01, 5.28684072e-02, 2.88098957e-02,
3.36107463e-02, 4.57574204e-02, 3.53841484e-02, 8.18825420e-03,
4.38359343e-02, 1.93465184e-02, 7.38846287e-02, 5.75702079e-02,
1.70197949e-01],
[9.41599980e-02, 8.14337283e-02, 3.74457210e-01, 1.82863697e-01,
2.06127129e-02, 1.73692200e-02, 2.06163302e-02, 1.95998959e-02,
2.31792331e-02, 2.28627622e-02, 4.79383804e-02, 6.16261661e-02,
3.32806185e-02],
[5.27172089e-02, 2.48163983e-01, 1.63775012e-01, 5.27932905e-02,
6.82818741e-02, 7.53673539e-02, 4.49651405e-02, 8.15221108e-03,
3.59340534e-02, 1.03255250e-02, 3.87837104e-02, 7.19308555e-02,
1.28809750e-01],
[5.14276810e-02, 5.94430208e-01, 1.85368303e-02, 8.97630397e-03,
1.58461966e-02, 2.43195295e-02, 1.36564812e-02, 1.32353709e-03,
2.56906562e-02, 6.94327289e-03, 4.88441549e-02, 3.11551224e-02,
1.58849955e-01],
[1.55078843e-02, 5.59883535e-01, 1.93930805e-01, 2.17422284e-02,
2.19239164e-02, 2.29448359e-02, 1.74160451e-02, 4.44449979e-04,
1.08931977e-02, 8.82870343e-04, 9.74672474e-03, 2.58449018e-02,
9.88386571e-02],
[9.51209441e-02, 5.89378215e-02, 3.61123204e-01, 1.36721328e-01,
1.40541000e-02, 4.08032425e-02, 1.55784925e-02, 1.20026972e-02,
1.97625067e-02, 1.84579790e-02, 4.70724888e-02, 1.39924020e-01,
4.04412672e-02]], dtype=float32)
```

#### 4.1.4.7. Visualización

Se crea un gráfico para visualizar la evolución de la función de pérdida durante el entrenamiento.



**Figura 10.** Evolución del margen de error

En la Figura 10 se puede observar que a medida que el modelo se va entrenando el error se va minimizando hasta quedar en 0.

#### 4.1.4.8. Prueba con nuevos datos

- Se ingresan nuevos datos de prueba y se escalan.

```
[[1, 27, 1, 0, 1, 0, 0, 1, 2, 63, 1, 1, 52, 1.89, 23, 5, 3,
56, 20]]
```

- Se realiza la predicción del algoritmo más adecuado para ese caso.

1/1 [=====] - 0s 21ms/step

```
array([[0.06964745, 0.10926056, 0.08151168, 0.07487388, 0.08816408,
0.08838683, 0.08513066, 0.05119059, 0.07014219, 0.05506855,
0.07119292, 0.074558 , 0.08087265]], dtype=float32)
```

- Se utiliza la función *argmax* para encontrar el índice del algoritmo con mayor probabilidad.

*ALGORITMO 0*

## 4.2. PRUEBA DE HIPOTESIS

Para realizar la prueba de hipótesis se toma en cuenta la información de la Tabla 6, en donde se incluye la formulación de la hipótesis nula y alternativa, las variables involucradas, el método de prueba, los criterios de decisión y resultados esperados.

**Tabla 7.** Prueba de hipótesis

Elemento	Descripción
<b>Hipótesis Nula (<math>H_0</math>)</b>	El sistema de selección de metaheurísticas para VRP no mejora los procesos de distribución.
<b>Hipótesis Alternativa (<math>H_1</math>)</b>	El sistema de selección de metaheurísticas para VRP mejora los procesos de distribución.
<b>Variable Independiente</b>	Uso de un sistema de selección de metaheurísticas basado en inteligencia artificial.
<b>Variable Dependiente</b>	Procesos logísticos de distribución
<b>Método de Prueba</b>	Comparación de resultados utilizando pruebas t para muestras independientes.
<b>Criterios de Decisión</b>	Si el valor p es menor que el nivel de significancia ( $\alpha = 0.05$ ), se rechaza la hipótesis nula a favor de la hipótesis alternativa.
<b>Nivel de Significancia (<math>\alpha</math>)</b>	0.05
<b>Tamaño de Muestra</b>	Número de instancias de VRP evaluadas con y sin el sistema de IA (30 instancias para cada grupo).
<b>Procedimiento</b>	<ol style="list-style-type: none"><li>1. Recolección de datos simulados de problemas VRP.</li><li>2. Aplicación del sistema de selección de metaheurísticas basado en IA.</li><li>3. Evaluación de mejoras obtenidas.</li><li>4. Comparación de resultados con métodos tradicionales.</li></ol>
<b>Resultados Esperados</b>	Mejoras significativas en los tiempos de procesamiento y calidad de las soluciones obtenidas utilizando el sistema basado en IA.

### 4.2.1. Codificación método de prueba *Python*

A continuación, se detalla el código en *Python* paso a paso para realizar la prueba T de *Student*:

```
# Instalar scipy (si no está instalada)
!pip install scipy

# Importar las bibliotecas necesarias
import numpy as np
from scipy import stats
```

```

# Ingresar los datos de las columnas "valores" y "mejora"
valores = np.zeros(30) # Antes de aplicar el algoritmo
mejora = np.array([20, 3, 17.58, 15.34, 23, 20, 15.4, 37.24, 10.2, 54,
14.3, 10, 15.3, 41, 11.6, 10.6, 9.6, 37, 12.5, 15.74, 4, 13.2, 17.3,
13.2, 33.2, 20.12, 18, 6.33, 23.5, 27.6]) # Después de aplicar el
algoritmo

# Realizar la prueba T de Student para muestras pareadas
t_statistic, p_value = stats.ttest_rel(mejora, valores)

# Mostrar los resultados de la prueba t
print(f'Estadístico t: {t_statistic}')
print(f'Valor p: {p_value}')

# Interpretar los resultados
if p_value < 0.05:
    print("La media de las mejoras es significativamente diferente de
los valores antes de aplicar el algoritmo (p < 0.05).")
else:
    print("No hay suficiente evidencia para afirmar que la media de
las mejoras es diferente de los valores antes de aplicar el algoritmo
(p ≥ 0.05).")

```

#### 4.2.2. Resultados prueba T de Student

*Estadístico t: 8.99155523897278*

*Valor p: 6.949340146293882e-10*

*La media de las mejoras es significativamente diferente de los valores antes de aplicar el algoritmo (p < 0.05).*

#### 4.2.3. Interpretación

- Prueba estadística: Una vez realizada la prueba T se puede observar las diferencias son estadísticamente significativas.

- ✓ **Estadístico t:** 8.99155523897278

El estadístico t obtenido es 8.99155523897278. Este valor indica cuántas desviaciones estándar están las medias de las dos muestras comparadas. Un valor t tan alto sugiere que hay una diferencia considerable entre las dos medias.

- ✓ **Valor p:** 6.949340146293882e-10

El valor p obtenido es 6.949340146293882e-10, que menor que 0.05 indica que la media de las mejoras después de aplicar el algoritmo es significativamente diferente de cero. Esto sugiere que el algoritmo tiene un impacto positivo y significativo en las mejoras observadas.

- Decisión: El valor  $p$  obtenido es menor que 0.05, se rechaza la hipótesis nula, concluyendo que el sistema basado en IA mejora la eficiencia en la solución del VRP.

### 4.3. DISCUSIÓN

Los progresos en la investigación de la optimización de procesos logísticos, especialmente en la distribución, han sido significativos gracias al uso de metaheurísticas y la incorporación de inteligencia artificial. Estas evoluciones han dado lugar al surgimiento de enfoques innovadores destinados a enfrentar los desafíos complejos en logística, destacando el *Vehicle Routing Problem* (VRP) como una de las áreas centrales de interés.

En el análisis de los casos de aplicación de metaheurísticas dentro del panorama actual, se han identificado diversos enfoques exitosos para resolver el *Vehicle Routing Problem* (VRP). Investigaciones anteriores han validado la efectividad de métodos como búsqueda tabú, recocido simulado, algoritmos genéticos, heurística de *Clarke Wright* y otras combinaciones de metaheurísticas. La evaluación detallada de estas experiencias brinda una comprensión profunda sobre cómo estas estrategias han sido aplicadas exitosamente en la optimización de problemas de ruteo vehicular, evidenciando avances significativos en términos de eficiencia operativa y gestión de costos.

La evaluación y desempeño de estas metaheurísticas proporcionan valiosas perspectivas sobre sus fortalezas y debilidades en diversos contextos logísticos. Este análisis crítico posibilita la identificación de las condiciones en las cuales ciertas metaheurísticas destacan, estableciendo así una base robusta para la concepción de un sistema de selección de metaheurísticas, capaz de elegir la metaheurística más apropiada de acuerdo con las características específicas de cada problema de VRP en los procesos de distribución.

En este marco, la discusión actual se enfoca en la creación de un sistema de selección de metaheurísticas destinado a abordar el VRP, utilizando las enseñanzas extraídas del estado del arte, el análisis exhaustivo del rendimiento y la comprensión profunda de experiencias anteriores. La meta fue desarrollar una estrategia sólida que aproveche las fortalezas de diversas metaheurísticas y la capacidad de adaptación de la inteligencia artificial, con el propósito de encontrar el camino hacia soluciones más eficientes y rentables en los procesos de distribución logística.

A continuación, se presenta la comparación con los antecedentes investigativos.

La Tabla 7 compara dos investigaciones sobre metaheurísticas en el contexto del Problema de Ruteo de Vehículos (VRP), abordando desde sistemas de selección hasta el diseño de algoritmos específicos.

**Tabla 8.** Comparación con Solución Metaheurística para el enrutamiento

	<b>Investigación 1</b>	<b>Investigación 2</b>
<b>Aspecto</b>	<b>“Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial”</b>	<b>“Diseño de un algoritmo metaheurístico para la solución del Problema de Ruteo de Vehículos MultiDepósito”</b>
<b>Problema</b>	La adaptación y configuración específica de las metaheurísticas para satisfacer las necesidades de distribución de las empresas.	La tesis realizada por Colin (2024), aborda el diseño de un algoritmo metaheurístico para resolver el Problema de Ruteo de Vehículos MultiDepósito (MDVRP). Este problema, al igual que el Problema de Ruteo de Vehículos (VRP) clásico, pertenece al campo de la optimización combinatoria y se clasifica como <i>NP-Hard</i> según Garey y Johnson (1979). Esto implica que encontrar una solución óptima mediante métodos exactos en un tiempo polinomial es extremadamente complicado.
<b>Resultados</b>	Diseño un sistema de selección de metaheurísticas para la solución a los problemas de distribución con base en las dimensiones de un VRP.	Desarrollar un algoritmo metaheurístico de Recocido Simulado que sea capaz de reducir al mínimo el costo total de los desplazamientos de los vehículos que satisfacen la demanda de cada cliente.

Resumen:

Las dos investigaciones se dedican a resolver problemas de Ruteo de Vehículos (VRP) mediante algoritmos metaheurísticos. ambas investigaciones contribuyen significativamente a la optimización de la distribución vehicular, pero desde enfoques diferentes, a primera investigación crea un sistema adaptable para seleccionar metaheurísticas según las necesidades del problema, mientras que la segunda se enfoca en desarrollar un algoritmo específico para una variante del VRP.

La Tabla 8 presenta un análisis comparativo entre dos investigaciones sobre la optimización del ruteo de vehículos: una centrada en la selección de metaheurísticas

para el VRP y otra en la aplicación de algoritmos genéticos y drones para mejorar la eficiencia en la distribución.

**Tabla 9.** Optimización del ruteo de vehículos con drones usando algoritmos

	<b>Investigación 1</b>	
<b>Aspecto</b>	<b>“Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial”</b>	<b>Investigación 2</b>
		<b>Optimización del ruteo de vehículos con drones usando algoritmos genéticos</b>
<b>Propuesta</b>	Comparar los diferentes algoritmos metaheurísticos para la solución de VRP en distribución	Frutos (2023) en su estudio realizado propone utilizar programación matemática y algoritmos genéticos para abordar y resolver el problema, resaltando la importancia de representar adecuadamente las soluciones y ajustar los parámetros del algoritmo para lograr una resolución eficiente.
<b>Resultados</b>	Diseño un sistema de selección de metaheurísticas para la solución a los problemas de distribución con base en las dimensiones de un VRP.	Muestra que la combinación de camiones y drones puede elevar el estándar de atención al cliente y la eficiencia en el consumo de energía durante la distribución, lo cual sienta las bases para investigaciones futuras en la creación de sistemas de selección de metaheurísticas adaptados a problemas de Ruteo de Vehículos en un entorno digitalizado y desafiante.

Resumen:

La primera investigación se centra en la comparación de algoritmos metaheurísticos en la solución de VRP, mientras que la segunda investiga la optimización del ruteo de vehículos con la integración de drones.

La investigación uno ofrece una herramienta de selección de metaheurísticas para problemas de distribución, mientras que la investigación dos propone una solución innovadora que mejora la eficiencia energética y el servicio al cliente en la distribución utilizando drones

La Tabla 9 compara dos investigaciones sobre optimización de ruteo: una enfocada en la selección de metaheurísticas para el VRP y otra en la mejora de rutas para el transporte de leche usando el Algoritmo Clarke and Wright.

**Tabla 10.** Comparación con Algoritmo de *Clarke and Wright*

Aspecto	Investigación 1 "Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial"	Investigación 2 "Algoritmo de <i>Clarke and Wright</i> para mejorar la gestión de ruta del transporte de acopio de leche"
<b>Propuesta</b>	Comparar los diferentes algoritmos metaheurísticos para la solución de VRP en distribución	El estudio realizado por Li et al (2020), propuso medir los efectos de implementar el Algoritmo <i>Clarke and Wright</i> en la gestión del transporte de acopio de leche. Se desarrollaron rutas para 5 camiones cisterna que recolectaban leche de múltiples proveedores, realizando 7 viajes diarios. Este trabajo se enmarca en una investigación aplicada con un diseño cuasi experimental.
<b>Resultados</b>	Diseño un sistema de selección de metaheurísticas para la solución a los problemas de distribución con base en las dimensiones de un VRP.	Los resultados obtenidos al aplicar el algoritmo de <i>Clarke and Wright</i> mostraron una mejora del 10.4 % en la utilización de la capacidad de carga, una reducción de 24.4 minutos en la distancia recorrida, así como una disminución de 61 minutos en el tiempo total de transporte. Además, se logró un ahorro de S/179.99 Soles en costos de flete por día de trabajo.

**Resumen:**

La Investigación uno se enfoca en diseñar un sistema automatizado de selección de metaheurísticas para VRP utilizando IA, mientras que la Investigación 2 se centra en implementar un algoritmo específico (*Clarke and Wright*) para optimizar rutas de transporte. Ambas investigaciones contribuyen al campo de la optimización en logística y transporte, pero se diferencian en enfoque y método. Mientras la primera investigación se centra en la selección automatizada de métodos de resolución, la segunda se enfoca en la implementación específica de un algoritmo clásico para mejorar operaciones específicas de transporte.

La Tabla 10 compara dos investigaciones sobre metaheurísticas aplicadas al ruteo de vehículos: una centrada en la selección del mejor algoritmo para el VRP y otra en el desarrollo de técnicas innovadoras para el VRP con ventanas de tiempo.

**Tabla 11.** Comparación de metaheurísticas para resolver VRP

Aspecto	Investigación 1	Investigación 2
	<b>“Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial”</b>	<b>“Metaheurísticas para resolver el problema de ruteo de vehículos con ventanas de tiempo”</b>
<b>Objetivo</b>	Determinar el mejor algoritmo metaheurístico de VRP, en función de los parámetros de los problemas de distribución.	Montes et al (2019) en su trabajo desarrolló y evaluó dos técnicas metaheurísticas innovadoras para resolver el Problema de Ruteo de Vehículos con Ventanas de Tiempo (VRP-TW).
<b>Resultados</b>	Determinación el mejor algoritmo metaheurístico de VRP, en función de los parámetros de los problemas de distribución.	Los resultados numéricos obtenidos muestran que tanto DS-AS-PDA como DS-MMC-AS exhiben un comportamiento robusto y son capaces de generar soluciones que, según los datos, son las mejores reportadas en la literatura hasta el momento. Además, logran estas soluciones con un número menor de evaluaciones de la función objetivo en comparación con otras técnicas conocidas.

Resumen:

Mientras que la Investigación 1 se centra en la identificación de algoritmos metaheurísticos efectivos para problemas de distribución, la Investigación 2 avanza hacia el desarrollo de nuevas técnicas para resolver específicamente el VRP-TW, alcanzando resultados significativos en términos de eficiencia y calidad de las soluciones obtenidas.

## V. CONCLUSIONES Y RECOMENDACIONES

### 5.1. CONCLUSIONES

- La prueba T de *Student* realizada muestra que la media de las mejoras obtenidas después de aplicar el algoritmo de metaheurísticas es significativamente diferente de la media antes de la aplicación del algoritmo (valor  $p < 0.05$ ). Esto indica que el algoritmo de metaheurísticas implementado en el sistema tiene un impacto positivo significativo en la resolución del problema de enrutamiento de vehículos (VRP) en procesos de distribución.
- La evidencia obtenida a través de la prueba T de *Student* respalda la robustez del algoritmo de metaheurísticas en diferentes escenarios y conjuntos de datos. Esto sugiere que el sistema desarrollado puede ser aplicado de manera efectiva en una variedad de contextos y condiciones dentro de la logística de distribución, ofreciendo resultados consistentes y mejorados.
- Los resultados estadísticos obtenidos validan la eficacia del sistema de selección de metaheurísticas desarrollado. La alta significancia del valor t (8.991) y el valor p extremadamente bajo ( $6.949e-10$ ) sugieren que las mejoras en los resultados no son producto del azar, sino del uso efectivo de la inteligencia artificial en la selección y aplicación de las metaheurísticas más adecuadas.
- El sistema propuesto contribuye significativamente a la optimización de los procesos logísticos en la distribución. Al aplicar el algoritmo de metaheurísticas, se lograron mejoras sustanciales en la solución del VRP, lo cual se traduce en rutas de distribución más eficientes y, por ende, en una reducción de costos operativos y tiempos de entrega.
- Los resultados positivos obtenidos proporcionan una base sólida para la implementación práctica del sistema en entornos reales de distribución. Además, se justifica la expansión del uso del sistema a otros dominios y su integración con otros componentes de la cadena de suministro,

potencialmente mejorando la eficiencia global de las operaciones logísticas.

## **5.2. RECOMENDACIONES**

Para trabajos futuros encaminados con la investigación, es aconsejable incrementar la variedad de metaheurísticas evaluadas. El presente trabajo se centra en un conjunto limitado de algoritmos, pero la inclusión de una gama más amplia podría proporcionar una perspectiva más integral y generalizable sobre la efectividad del sistema de selección. Esta expansión permitiría una evaluación más completa del rendimiento del sistema y aseguraría que las conclusiones sean aplicables a una mayor diversidad de problemas de ruteo vehicular (VRP). Además, comparar estas metaheurísticas adicionales en diferentes escenarios logísticos y con diversos conjuntos de datos podría identificar situaciones específicas en las que cada algoritmo destaca, contribuyendo a una selección más precisa y eficiente.

Aunque los experimentos con datos simulados son útiles para probar la viabilidad inicial del sistema, se recomienda realizar evaluaciones en entornos con datos reales para validar su aplicabilidad práctica. Utilizar datos de operaciones logísticas de empresas permitirá verificar cómo el sistema de selección de metaheurísticas se desempeña en situaciones del mundo real, con todas sus complejidades y variabilidades. Esto no solo fortalecerá la credibilidad y relevancia de los resultados obtenidos, sino que también ofrecerá información crucial sobre las posibles adaptaciones necesarias para enfrentar desafíos específicos de la industria.

## VI. REFERENCIAS BIBLIOGRÁFICAS


- Anbuudayasankar, Ganesh, Mohapatra, y Sanjay. (2014). *Models for Practical Routing Problems in Logistics*. Springer International Publishing.
- Barros, M. . (2020). *Metaheurística aplicada a un problema de packing con ruteo*. Tesis de maestría publicada. Universidad De Concepción.
- Blum, C., y Roli, A. (2003). *Metaheuristics in combinatorial optimization: Overview and conceptual comparison*. ACM Computing surveys, 35.
- Boza, O. Lecca, E. Acevedo, A. (2012). *El empleo de modelos metaheurísticos en la logística industrial. El caso del enrutamiento de vehículos*. *Industrial Data. Revista de Investigación*,15, pp. 70-79.
- Colin, J. B. (2024). *Diseño de un algoritmo metaheurístico para la solución del Problema de Ruteo de Vehículos MultiDepósito*. . Creative Commons.
- Cordeau, J. F. y Laporte, G. (2003). *Una heurística de búsqueda tabú para el problema estático de discado para múltiples vehículos*. MATEMÁTICA ESPOL - FCNM , 512 - 522.
- Frutos. (2023). *Optimización del problema de ruteo de vehículos con drones usando algoritmos genéticos*. Argentina: Portal oficial del Estado argentino.
- Fuat Simsir y Dursun Ekmekci. (2019). *A metaheuristic solution approach to capacitated vehicle routing and network optimization*. *Engineering Science and Technology, an International Journal*, 727-735.
- Gómez, D. (2022). *Ruteo de vehículos VRPTWPD para información de valor mediante el uso de algoritmos genéticos*. Politécnico Grancolombiano.
- Gómez, J. Zamudio, B. (2023). *Solución al Problema de Ruteo de Vehículos con Ventanas de Tiempo y Visita Sincronizada mediante la metaheurística Búsqueda Tabú*. Universidad Industrial de Santander.
- Laban, M. (2022). *Metaheurística optimización por espiral para disminuir la distancia total recorrida en el problema de ruteo vehicular con demanda estocástica*. Universidad Nacional Mayor de San Marcos.

- Li, H., Li, X., y Zhang, X. (2020). *A hybrid metaheuristic algorithm for the vehicle routing problem with time windows and simultaneous delivery and pickup*. IEEE Access, 8.
- Loiseau, I. (2015). *Metaheurísticas para problemas de ruteo de vehículos*. Quito : *Memorias Elavio*.
- Maguiña, L. (2016). *Implantación de VRP - Solver aplicando la heurística de Clarke Wright para el ruteo del transporte terrestre en el área de distribución caso de estudio: industrias alimentarias*. Universidad Nacional Mayor de San Marcos.
- Martínez, J. Vega, F. (2020). *Optimización del ruteo de vehículos para la distribución de una empresa fabricante de bebidas en la ciudad de Quito*.
- Matich, S. (2001). *Las redes neuronales artificiales: Modelos y aplicaciones*. .
- Montes, Mora, Obregón, Cobos, D. I., Rincón, Gutiérrez, y Lara. (2019). *Metaheurísticas para resolver el problema de ruteo de vehículos con ventanas de tiempo*. Revista de matemáticas teoría y aplicaciones, 27(2), 305-332. <https://doi.org/https://doi.org/10.15517/rmta.v27i2.37889>
- Perez, J. (2012). *Caracterización, Modelado y Determinación de las Rutas de la Flota en una Empresa de Rendering*. Universidad de Sevilla.
- Prato, R. Suero, D. Guzmán, O. (2015). *Ruteo de Vehículos desde un Centro de Distribución a una Línea de Supermercados en Barranquilla, Colombia*. Universidad del Norte.
- Russell y Norvig . (2020). *A Modern Approach (4th ed.)*. Artificial Intelligence.
- Soto, D. Soto, W. Pinzón, Y. (2008). *Una metaheurística híbrida aplicada a un problema de planificación de rutas*. Avances en Sistemas e Informática, pp. 135-144.
- Tello, J. (2011). *Una metaheurística para resolver el problema de ruteo vehicular capacitado en empresas de distribución secundaria*. Tesis publicada. Escuela Superior Politécnica Del Litoral.
- Toro, Ocampo, Santa, y Granada. (2013). *Solución del problema de ruteamiento de vehículos en la distribución de papa en Colombia*. Universidad Tecnológica de Pereira.
- Toth y Vigo. (2022). *The Vehicle Routing Problem*. Society for Industrial and Applied Mathematics.
- Toth, P., y Vigo, D. (2014). *Vehicle routing: problems, methods, and applications*. MOS-SIAM.

Zhang, Wan y Jiang. (2018). *Investigación en la optimización del sistema de distribución basado en tecnología logística*. Ciencia e ingeniería de materiales, 062103.

## VII. ANEXOS

### Anexo 1. Acta de sustentación de Predefensa del TIC



**UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI**

FACULTAD DE COMERCIO INTERNACIONAL, INTEGRACIÓN, ADMINISTRACIÓN Y ECONOMÍA EMPRESARIAL

CARRERA DE LOGÍSTICA Y TRANSPORTE

**ACTA**

DE LA SUSTENTACIÓN ORAL DE LA PREDEFENSA DEL TRABAJO DE INTEGRACIÓN CURRICULAR


<b>ESTUDIANTE:</b> Ortiz Benítez Lesly Belén		<b>CÉDULA DE IDENTIDAD:</b> 0401540000	
<b>PERIODO ACADÉMICO:</b> 2024B		<b>DOCENTE TUTOR:</b> MSc. Mafla Bolaños Iván Gabriel	
<b>PRESIDENTE TRIBUNAL:</b> MSc. Beltrán del Hierro Daniel Mauricio		<b>DOCENTE:</b> MSc. Alpala Alpala Luis Omar	
<b>TEMA DEL TIC:</b> "Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con Inteligencia artificial"			

No.	CATEGORÍA	Evaluación cuantitativa	OBSERVACIONES Y RECOMENDACIONES
1	PROBLEMA - OBJETIVOS	8,67	Revisar objetivo general
2	FUNDAMENTACIÓN TEÓRICA	10,00	
3	METODOLOGÍA	10,00	
4	RESULTADOS	8,00	Mejorar la resolución de imágenes, construcción de metodologías para búsqueda de información bibliográfica y us
5	DISCUSIÓN	10,00	
6	CONCLUSIONES Y RECOMENDACIONES	9,67	Revisar en base a la modificación del objetivo general
7	DEFENSA, ARGUMENTACIÓN Y VOCABULARIO PROFESIONAL	7,00	Mejorar presentación, argumentar técnicamente el contenido del trabajo realizado
8	FORMATO, ORGANIZACIÓN Y CALIDAD DE LA INFORMACIÓN	8,67	


Obleniendo una nota de: **8,93** Por lo tanto, **APRUEBA** ; debiendo el o los investigadores acatar el siguiente artículo:

Art. 36.- De los estudiantes que aprueban el informe final del TIC con observaciones.- Los estudiantes tendrán el plazo de 10 días para proceder a corregir su informe final del TIC de conformidad a las observaciones y recomendaciones realizadas por los miembros del Tribunal de sustentación de la pre-defensa.

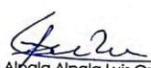
Para constancia del presente, firman en la ciudad de Tulcán el **lunes, 30 de septiembre de 2024**



MSc. Beltrán del Hierro Daniel Mauricio  
**PRESIDENTE TRIBUNAL**



MSc. Mafla Bolaños Iván Gabriel  
**DOCENTE TUTOR**



MSc. Alpala Alpala Luis Omar  
**DOCENTE**



# UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI



FACULTAD DE COMERCIO INTERNACIONAL, INTEGRACIÓN, ADMINISTRACIÓN Y ECONOMÍA EMPRESARIAL

CARRERA DE LOGÍSTICA Y TRANSPORTE

## ACTA

DE LA SUSTENTACIÓN ORAL DE LA PREDEFENSA DEL TRABAJO DE INTEGRACIÓN CURRICULAR

ESTUDIANTE:	Urbano Fortilla Karen Pamela	CÉDULA DE IDENTIDAD:	0450082557
PERIODO ACADÉMICO:	2024B		
PRESIDENTE TRIBUNAL	MSc. Beltrán del Hierro Daniel Mauricio	DOCENTE TUTOR:	MSc. Maffa Bolaños Iván Gabriel
DOCENTE:	MSc. Alpala Alpala Luis Omar		
<b>TEMA DEL TIC:</b> "Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con Inteligencia artificial"			
No.	CATEGORÍA	Evaluación cuantitativa	OBSERVACIONES Y RECOMENDACIONES
1	PROBLEMA - OBJETIVOS	8,67	Revisar objetivo general
2	FUNDAMENTACIÓN TEÓRICA	10,00	
3	METODOLOGÍA	10,00	
4	RESULTADOS	8,00	Mejorar la resolución de imágenes, construcción de metodologías para búsqueda de información bibliográfica y us
5	DISCUSIÓN	10,00	
6	CONCLUSIONES Y RECOMENDACIONES	9,67	Revisar en base a la modificación del objetivo general
7	DEFENSA, ARGUMENTACIÓN Y VOCABULARIO PROFESIONAL	7,00	Mejorar presentación, argumentar técnicamente el contenido del trabajo realizado
8	FORMATO, ORGANIZACIÓN Y CALIDAD DE LA INFORMACIÓN	8,67	

Obteniendo una nota de: **8,93** Por lo tanto, **APRUEBA** : debiendo el o los investigadores acatar el siguiente artículo:

Art. 36.- De los estudiantes que aprueban el Informe final del TIC con observaciones.- Los estudiantes tendrán el plazo de 10 días para proceder a corregir su informe final del TIC de conformidad a las observaciones y recomendaciones realizadas por los miembros del Tribunal de sustentación de la pre-defensa.

Para constancia del presente, firman en la ciudad de Tulcán el **lunes, 30 de septiembre de 2024**

MSc. Beltrán del Hierro Daniel Mauricio  
**PRESIDENTE TRIBUNAL**

MSc. Maffa Bolaños Iván Gabriel  
**DOCENTE TUTOR**

MSc. Alpala Alpala Luis Omar  
**DOCENTE**

## Anexo 2. Certificado del abstract por parte de idiomas



### UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI FOREIGN AND NATIVE LANGUAGE CENTER

#### Informe sobre el Abstract de Artículo Científico o Investigación.

**Autor:** Karen Pamela Urbano Portilla y Ortiz Benitez Lesly Belén

**Fecha de recepción del abstract:** 19 de noviembre de 2024

**Fecha de entrega del informe:** 29 de noviembre de 2024

El presente informe validará la traducción del idioma español al inglés si alcanza un porcentaje de: 9 – 10 Excelente.

Si la traducción no está dentro de los parámetros de 9 – 10, el autor deberá realizar las observaciones presentadas en el ABSTRACT, para su posterior presentación y aprobación.

#### Observaciones:

Después de realizar la revisión del presente abstract, éste presenta una apropiada traducción sobre el tema planteado en el idioma Inglés. Según la rúbrica de evaluación de la traducción en Inglés, ésta alcanza un valor de 9; por lo cual se valida dicho trabajo.

Atentamente



MA. Martha Viveros

Docente responsable del  
CIDEN



UNIVERSIDAD POLITÉCNICA ESTATAL DEL CARCHI FOREIGN AND  
NATIVE LANGUAGE CENTER

<b>ABSTRACT- EVALUATION SHEET</b>				
<b>NAME:</b> Karen Pamela Urbano Portilla y Ortiz Benitez Lesly Belén				
<b>DATE:</b> 29 de noviembre de 2024				
<b>Topic:</b> "Sistema de selección de metaheurísticas para solución de VRP en procesos de distribución con inteligencia artificial".				
<b>MARKS AWARDED</b>		<b>QUANTITATIVE AND QUALITATIVE</b>		
<b>VOCABULARY AND WORD USE</b>	Use new learnt vocabulary and precise words related to the topic	Use a little new vocabulary and some appropriate words related to the topic	Use basic vocabulary and simplistic words related to the topic	Limited vocabulary and inadequate words related to the topic
	EXCELLENT: 2 <input type="checkbox"/>	GOOD: 1,5 <input type="checkbox"/>	AVERAGE: 1 <input type="checkbox"/>	LIMITED: 0,5 <input type="checkbox"/>
<b>WRITING COHESION</b>	Clear and logical progression of ideas and supporting paragraphs.	Adequate progression of ideas and supporting paragraphs.	Some progression of ideas and supporting paragraphs.	Inadequate ideas and supporting paragraphs.
	EXCELLENT: 2 <input type="checkbox"/>	GOOD: 1,5 <input type="checkbox"/>	AVERAGE: 1 <input type="checkbox"/>	LIMITED: 0,5 <input type="checkbox"/>
<b>ARGUMENT</b>	The message has been communicated very well and identify the type of text	The message has been communicated appropriately and identify the type of text	Some of the message has been communicated and the type of text is little confusing	The message hasn't been communicated and the type of text is inadequate
	EXCELLENT: 2 <input type="checkbox"/>	GOOD: 1,5 <input type="checkbox"/>	AVERAGE: 1 <input type="checkbox"/>	LIMITED: 0,5 <input type="checkbox"/>
<b>CREATIVITY</b>	Outstanding flow of ideas and events	Good flow of ideas and events	Average flow of ideas and events	Poor flow of ideas and events
	EXCELLENT: 2 <input type="checkbox"/>	GOOD: 1,5 <input type="checkbox"/>	AVERAGE: 1 <input type="checkbox"/>	LIMITED: 0,5 <input type="checkbox"/>
<b>SCIENTIFIC SUSTAINABILITY</b>	Reasonable, specific and supportable opinion or thesis statement	Minor errors when supporting the thesis statement	Some errors when supporting the thesis statement	Lots of errors when supporting the thesis statement
	EXCELLENT: 2 <input type="checkbox"/>	GOOD: 1,5 <input type="checkbox"/>	AVERAGE: 1 <input type="checkbox"/>	LIMITED: 0,5 <input type="checkbox"/>
<b>TOTAL/AVERAGE</b>	9 - 10: EXCELLENT 7 - 8,9: GOOD 5 - 6,9: AVERAGE 0 - 4,9: LIMITED	<b>TOTAL 9</b>		

### Anexo 3. Datos casos metaheurísticos

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T
1	CLASE_PROCESO	ALG	CLIENTES	DEP	VEN_TIEMPO	DEL	PICK	SEC	VEHICULOS	T_FLOTA	DIST_MAX	COND	CLI_CARGA	CLI_DESCARGA	COSTO/KM	DISTANCIA	UND_CARGA	CAPACIDAD	TIM_SERVICIO	MEJORA
2	1	2	27	1	0	1	0	0	1	2	63	1	1	52	1,89	23	5	3	56	20
3	1	2	40	3	1	1	0	0	2	2	220	2	1	20	0,52	180	2	2	10	3
4	1	6	1346	4	1	1	0	0	18	2	618	18	4	1346	0,98	510	1	1	3	37
5	1	10	25	1	1	1	0	0	4	1	210	4	1	25	0,52	201	1	2	5	10,2
6	1	3	50	1	1	1	0	0	3	2	159	3	1	50	1,1	154	4	2	10	13,2
7	1	8	16	1	1	1	0	0	1	1	109	1	1	60	0,98	84	2	2	17	15,74
8	1	2	79	1	1	1	0	0	8	2	227	8	1	1	0,52	236	1	3	25	17,58
9	1	5	26	1	0	1	0	0	26	1	181,14	26	0	26	0,36	181,14	4	2	16	41
10	1	6	20	1	0	1	0	0	2	1	120,3	2	0	20	0,24	64,33	1	3	12	15,3
11	1	4	44	1	0	1	0	0	3	2	1590,6	3	0	44	0,08	998,26	1	3	17	37,24
12	1	1	21	4	0	0	0	1	25	2	643	25	0	21	0,15	950	1	2	10	18
13	1	0	15	3	1	0	1	0	9	2	256	2	2	13	0,15	465	2	1	10	13,2
14	1	2	30	1	1	1	0	0	12	2	50	12	0	30	0,1	50	2	2	60	31
15	2	2	100	1	1	1	0	0	2	2	1593	2	1	100	0,52	1200	2	3	10	15,34
16	2	1	79	1	1	1	0	0	8	3	227	8	1	79	0,52	96	1	3	30	21,6
17	2	2	130	1	0	0	1	0	25	2	456	55	1	1	8	222	1	1	7	20
18	2	0	13	5	1	1	0	0	8	2	433	4	6	7	0,11	623	1	2	5	33,2
19	2	1	30	2	1	1	0	0	5	2	770	3	0	30	0,12	753	3	3	45	11,6
20	2	6	18	1	1	1	0	0	5	1	2920	3	0	18	0,1	3999	3	2	12	10,6
21	3	3	52	3	1	1	0	0	6	1	776	6	3	52	0,52	200	2	2	2	12,2
22	3	11	10	1	1	0	0	1	3	1	1302	3	1	10	0,52	1155	2	2	10	23
23	3	5	46	1	1	0	0	1	28	2	107	6	1	46	1,89	69	4	2	15	10
24	3	6	13	1	1	1	0	0	4	2	909	4	1	13	1,69	1090	4	3	29	9,6
25	3	9	5	1	1	1	1	1	1	2	3500	1	1	1	2,01	450	2	2	25	14,3
26	3	4	7	1	1	1	0	0	4	2	12,9	4	1	7	0,52	25,28	1	2	5	15,4
27	4	4	140	1	1	0	1	0	15	2	205	15	140	1	0,52	705	2	2	10	54
28	4	7	208	1	0	0	1	0	140	2	20,755	140	208	0	0,04	18,161	1	2	7	12,5
29	4	1	21	1	0	0	1	0	12	1	283,68	12	9	1	0,56	48	1	2	8	6,33
30	4	0	10	2	1	0	1	0	5	2	100	3	10	0	0,1	50	1	3	10	20,12
31	4	3	20	2	1	0	1	0	7	1	420	5	17	3	0,13	622	3	2	25	17,3
32	4	1	25	3	1	0	1	0	6	1	200	6	25	0	0,17	620	1	2	7	23,5
33	4	1	23	2	0	0	1	0	8	1	650	3	23	0	0,12	935	3	2	12	27,6
34	4	12	32	32	1	0	1	0	3	1	111	3	31	1	0,52	43	1	2	7	4,2

## Anexo 4. Manual de uso del árbol de decisión para clasificación

### Manual de Uso del Árbol de Decisión para Clasificación

Este manual está diseñado para proporcionar una guía detallada sobre la implementación de un árbol de decisión para la clasificación de datos en empresas que busquen optimizar los procesos de distribución mediante el uso de metaheurísticas para solución de VRP.

El árbol de decisión es una herramienta poderosa en el análisis de datos, que permite tomar decisiones basadas en condiciones lógicas. A continuación, se describirán los pasos necesarios para cargar datos, entrenar el modelo y evaluar su rendimiento utilizando *Python* y bibliotecas como ``numpy``, ``pandas``, y ``sklearn``.

#### a) Estructura del Árbol de Decisión

El árbol de decisión se construye a partir de un conjunto de variables independientes (``x10``, ``x18``, ``x15``, y ``x4``), formulando preguntas que conducen a la asignación de un valor a la variable dependiente ``x``. Cada ruta en el árbol culmina en una hoja terminal, que determina el resultado final en función de las respuestas a las preguntas planteadas. Este enfoque permite una interpretación clara y visual de las decisiones tomadas por el modelo.

#### b) Metodología

##### 1. Preparación del Entorno

Asegúrese de contar con las bibliotecas necesarias instaladas en su entorno de trabajo:

```
bash
pip install numpy pandas matplotlib seaborn scikit-learn
```

##### 2. Cargar los Datos

Importe las bibliotecas requeridas y cargue los datos desde un archivo Excel:

```
python
import numpy as np
import pandas as pd
from matplotlib import pyplot as plt

python
import seaborn as sns
from sklearn.model_selection import train_test_split
```

```

from sklearn.preprocessing import StandardScaler
from sklearn.tree import DecisionTreeClassifier
from sklearn.metrics import accuracy_score, classification_report, confusion_matrix

# Cargar el conjunto de datos
datos = pd.read_excel("/content/MyDrive/DATOS_MET.xlsx")

```

### 3. Análisis Exploratorio de los Datos

Realice un análisis preliminar para comprender las características del conjunto de datos:

```

python
# Descripción básica de los datos
print(datos.describe())

# Cálculo de la matriz de correlación
print(datos.corr())

# Visualización de la matriz de correlación
plt.figure(figsize=(15, 15))
sns.heatmap(datos.corr(), annot=True)
plt.title("Matriz de Correlación")
plt.show()

```

### 4. Preparación de las Variables

Defina las características (*features*) y los objetivos (*targets*) que se utilizarán para el entrenamiento del modelo:

```

python
features = np.asarray(datos[["CLIENTES", "DEP", "VEN_TIEMPO", "DEL", "PICK", "SEC", "VEHICULOS",
"T_FLOTA", "DIST_MAX", "COND", "CLI_CARGA", "CLI_DESCARGA", "COSTO/KM", "DISTANCIA",
"UND_CARGA", "CAPACIDAD", "TIM_SERVICIO", "EFICIENCIA"]])
targets = np.asarray(datos[["ALG"]])

```

### 5. División de los Datos

Separe el conjunto de datos en conjuntos de entrenamiento y prueba para evaluar el rendimiento del modelo:

```

python
train_features, test_features, train_targets, test_targets = train_test_split(features, targets,
random_state=60)

```

## 6. Normalización de los Datos

Estandarice las características para asegurar que todos los atributos contribuyan de manera equitativa al modelo:

```
python
sc = StandardScaler()
train_features = sc.fit_transform(train_features)
test_features = sc.transform(test_features)
```

## 7. Creación y entrenamiento del Árbol de Decisión

Defina y entrene el modelo de árbol de decisión utilizando el conjunto de entrenamiento:

```
python
d_tree = DecisionTreeClassifier(max_depth=5)
d_tree.fit(train_features, train_targets)
```

## 8. Realización de Predicciones

Utilice el modelo entrenado para realizar predicciones sobre el conjunto de prueba y evalúe su desempeño:

```
python
predictions = d_tree.predict(test_features)
# Imprimir el reporte de clasificación
print(classification_report(test_targets, predictions))

# Visualización de la matriz de confusión
plt.figure(figsize=(5, 5))
sns.heatmap(confusion_matrix(test_targets, predictions), annot=True)
plt.title("Matriz de Confusión")
plt.show()
```

## 9. Visualización del Árbol de Decisión

Visualice la estructura del árbol de decisión para interpretar las decisiones tomadas por el modelo:

```
python
from sklearn import tree
fig = plt.figure(figsize=(15, 10))
```

```
_ = tree.plot_tree(d_tree, filled=True)
```

Este manual proporciona una guía integral para implementar un árbol de decisión en el contexto de una tesis. Siguiendo estos pasos, podrá clasificar datos y evaluar la efectividad de su modelo de manera clara y estructurada. Es importante adaptar las variables y la ruta del archivo a su propio conjunto de datos y contexto de investigación.

## Anexo 5. Manual de Uso para la Red Neuronal de Clasificación con TensorFlow

### Manual de Uso para la Red Neuronal de Clasificación con TensorFlow

#### 1. Introducción

Este manual proporciona una guía detallada para usar una red neuronal de clasificación con un modelo lineal utilizando TensorFlow. La red neuronal está diseñada para clasificar algoritmos con base en un conjunto de características. El flujo completo abarca la carga de datos, preprocesamiento, construcción del modelo, entrenamiento, evaluación, y predicciones.

#### 2. Requisitos Previos

Para implementar esta red neuronal, asegúrate de cumplir con los siguientes requisitos:

- Conocimientos básicos en programación Python y en aprendizaje automático.
- Bibliotecas necesarias instaladas: TensorFlow, NumPy, pandas, matplotlib y scikit-learn.

#### 3. Instalación del Entorno

a) Instalación de las bibliotecas necesarias:

```
``bash
pip install numpy pandas matplotlib tensorflow scikit-learn
``
```

b) Verificación de la instalación:

Ejecuta el siguiente comando en un archivo *Python* o en un entorno *Jupyter Notebook*:

```
``python
import tensorflow as tf
print(tf.__version__)
``
```

Deberías ver la versión instalada de TensorFlow.

#### 4. Carga de Datos

a) Cargar el archivo de datos:

La red usa un archivo Excel llamado `DATOS\_MET.xlsx` que contiene las características (X) y las etiquetas (y) para el modelo.

```
```python
import pandas as pd
df = pd.read_excel("/ruta/al/archivo/DATOS_MET.xlsx")
```
```

b) Extracción de características (X) y etiquetas (y):

```
```python
X = df[["CLASE_PROCESO", "CLIENTES", "DEP", "VEN_TIEMPO", "DEL", "PICK", "SEC",
"VEHICULOS", "T_FLOTA", "DIST_MAX", "COND", "CLI_CARGA", "CLI_DESCARGA",
"COSTO/KM", "DISTANCIA", "UND_CARGA", "CAPACIDAD", "TIM_SERVICIO",
"EFICIENCIA"]].to_numpy()
y = df["ALG"].to_numpy()
```
```

5. Preprocesamiento

a) División de los datos en conjuntos de entrenamiento y prueba (80% - 20%):

```
```python
from sklearn.model_selection import train_test_split
train_X, test_X, train_y, test_y = train_test_split(X, y, test_size=0.2, random_state=42)
```
```

b) Escalado de las características:

```
```python
from sklearn.preprocessing import StandardScaler
scaler = StandardScaler()
train_X = scaler.fit_transform(train_X)
test_X = scaler.transform(test_X)
```
```

6. Construcción del Modelo

a) Crear la arquitectura de la red neuronal:

```
```python
import tensorflow as tf
input_layer = tf.keras.layers.Dense(units=19, input_shape=(19,))
hidden_layer1 = tf.keras.layers.Dense(units=16, activation='relu')
```

```
hidden_layer2 = tf.keras.layers.Dense(units=16, activation='relu')
output_layer = tf.keras.layers.Dense(units=13, activation='softmax')
```

```
model = tf.keras.Sequential([input_layer, hidden_layer1, hidden_layer2,
output_layer])
...
```

b) Compilar el modelo:

```
``python
model.compile(optimizer=tf.keras.optimizers.Adam(),
              loss=tf.keras.losses.SparseCategoricalCrossentropy(),
              metrics=['accuracy'])
...
```

7. Entrenamiento del Modelo

a) Entrenar el modelo con los datos de entrenamiento:

```
``python
history = model.fit(train_X, train_y, epochs=100, verbose=1)
...
```

8. Evaluación del Modelo

a) Evaluar la precisión en los conjuntos de prueba y entrenamiento:

```
``python
test_loss, test_acc = model.evaluate(test_X, test_y, verbose=2)
print("\nPrecisión en prueba:", test_acc)
```

```
train_loss, train_acc = model.evaluate(train_X, train_y, verbose=2)
print("\nPrecisión en entrenamiento:", train_acc)
...
```

9. Predicción con Nuevos Datos

a) Ingresar los datos de prueba y escalar:

```
``python
nuevo_dato = [[1, 27, 1, 0, 1, 0, 0, 1, 2, 63, 1, 1, 52, 1.89, 23, 5, 3, 56, 20]]
nuevo_dato = scaler.transform(nuevo_dato)
...
```

b) Realizar la predicción:

```
```python
prediccion = model.predict(nuevo_dato)
mejor_clase = np.argmax(prediccion)
print("La clase con mayor probabilidad es:", mejor_clase)
```
```

## 10. Visualización del Proceso de Entrenamiento

a) Graficar la evolución de la función de pérdida:

```
```python
import matplotlib.pyplot as plt
plt.figure()
plt.xlabel("Épocas")
plt.ylabel("Función de pérdida")
plt.plot(history.history["loss"])
plt.show()
```
```

## 11. Pruebas con Nuevos Datos

- Ejecutar nuevas pruebas utilizando el mismo flujo de escalado y predicción.
- Analizar los resultados y ajustar el modelo si es necesario (por ejemplo, cambiando la arquitectura o los hiperparámetros).

Este manual proporciona los pasos esenciales para implementar y utilizar la red neuronal en una empresa. La red neuronal puede ser utilizada para automatizar la clasificación de algoritmos basados en diversas características, optimizando procesos y mejorando la toma de decisiones.