



UNIVERSIDAD AUTONOMA DEL ESTADO DE HIDALGO

INSTITUTO DE CIENCIAS BASICAS E INGENIERIA

ÁREA ACADÉMICA DE INGENIERÍA Y ARQUITECTURA

T E S I S

DISEÑO DE REDES LOGISTICAS DE DOS NIVELES CONSIDERANDO INCERTIDUMBRE EN LA DEMANDA Y CALIDAD EN LA PRODUCCIÓN

Para obtener el grado de
MAESTRO EN CIENCIAS EN INGENIERÍA INDUSTRIAL

P R E S E N T A

Liliana Hinojosa Olvera

Director

Dr. Héctor Rivera Gómez

Comité tutorial

Dr. Jaime Garnica González

Dr. Joselito Medina Marín

Dra. Nadia Samantha Zúñiga Peña

Cd. Del Conocimiento, Mineral de la Reforma, Hgo., México a 15 de marzo 2026



Universidad Autónoma del Estado de Hidalgo
Instituto de Ciencias Básicas e Ingeniería
School of Engineering and Basic Sciences
Área Académica de Ingeniería y Arquitectura

13/Marzo/2026

Asunto: Autorización de impresión

Mtra. Ojuky del Rocío Islas Maldonado
Directora de Administración Escolar
Presente

El Comité Tutorial de la tesis de posgrado titulada **"Diseño de redes logísticas de dos niveles considerando incertidumbre en la demanda y calidad en la producción"**, realizada por la sustentante **Liliana Hinojosa Olvera** con número de cuenta **197259**, perteneciente al programa de **Maestría en Ciencias en Ingeniería Industrial**, una vez que ha revisado, analizado y evaluado el documento recepcional de acuerdo a lo estipulado en el Artículo 110 del Reglamento de Estudios de Posgrado, tiene a bien extender la presente:


AUTORIZACIÓN DE IMPRESIÓN

Por lo que la sustentante deberá cumplir los requisitos del Reglamento de Estudios de Posgrado y con lo establecido en el proceso de grado vigente.


Atentamente
"Amor, Orden y Progreso"

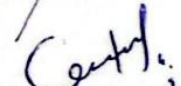
El Comité Tutorial


Dr. Héctor Rivera Gómez
Director


Dr. Josefina Medina Marín
Miembro del comité




Jaime Garnica González
Miembro del comité


Dra. Samantha Nadia Zúñiga Peña
Miembro del comité

"Amor, Orden y Progreso"



Ciudad del Conocimiento, Carretera Pachuca-Tulancingo
Km. 4.5 Colonia Carboneras, Mineral de la Reforma, Hidalgo,
México. C.P 42184
Teléfono: 52 (771) 71 720 00 Ext. 40031, 40030
aai_icbi@uaeh.edu.mx

uaeh.edu.mx

ÍNDICE

| | |
|---|-------------|
| Resumen | vi |
| Abstract | vii |
| Agradecimientos | viii |
| Dedicatorias | ix |
| Tabla de simbología | x |
| 1. CAPITULO 1. PROPÓSITO Y ORGANIZACIÓN..... | 1 |
| 1.1. Introducción..... | 1 |
| 1.2. Planteamiento del problema | 2 |
| 1.3. Importancia del tema..... | 2 |
| 1.4. Motivación | 3 |
| 1.5. Problemática | 6 |
| 1.6. Pregunta de investigación | 6 |
| 1.7. Importancia de la investigación | 7 |
| 1.8. Propósito de la investigación | 7 |
| 1.9. Objetivo General..... | 8 |
| 1.10. Objetivos específicos..... | 8 |
| 1.11. Justificación..... | 9 |
| 1.12. Alcances y limitaciones | 10 |
| 1.12.1 Alcances..... | 10 |
| 1.12.2 Limitaciones..... | 11 |
| 1.13. Contribución de la tesis..... | 11 |
| 1.14. Organización del estudio..... | 12 |
| 2. CAPÍTULO 2. MACO TEÓRICO Y REVISIÓN DE LA LITERATURA | 13 |
| 2.1. Conceptos básicos sobre la modelación de redes logísticas bajo incertidumbre | 14 |
| 2.1.1 Planeación logística y sus implicaciones operativas | 14 |
| 2.1.2 Complejidad computacional en la modelación de redes logísticas de dos niveles | 15 |
| 2.1.3 Optimización matemática..... | 16 |
| 2.1.4 Programación estocástica de dos etapas..... | 16 |
| 2.1.5 Software LINGO | 16 |
| 2.2. Cadena de suministro | 17 |

| | |
|---|-----------|
| 2.2.1 Antecedentes | 17 |
| 2.2.2 Definiciones importantes de Cadena de Suministro | 19 |
| 2.2.3 Estudios de investigación | 19 |
| 2.3. Calidad aleatoria | 22 |
| 2.3.1 Antecedentes de calidad aleatoria | 22 |
| 2.3.2 Definiciones importantes sobre Calidad | 23 |
| 2.3.3 Estudios de investigación: | 24 |
| 2.4. Demanda aleatoria..... | 27 |
| 2.4.1 Antecedentes de Demanda aleatoria | 27 |
| 2.4.2 Definiciones importantes de demanda..... | 28 |
| 2.4.3 Estudios de investigación | 29 |
| 2.5. Programación estocástica | 32 |
| 2.5.1 Antecedentes de programación estocástica..... | 32 |
| 2.5.2 Definiciones importantes de programación estocástica..... | 34 |
| 2.5.3 Estudios de investigación de programación estocástica | 35 |
| 2.6. Single Commodity Two Echelon (SCTE) | 38 |
| 2.6.1 Antecedentes de SCTE | 38 |
| 2.6.2 Definiciones importantes sobre SCTE | 39 |
| 2.6.3 Estudios de investigación | 39 |
| 2.7. Comparación metodológica del enfoque propuesto frente a métodos alternativos | 42 |
| 3. CAPITULO 3. METODOLOGIA..... | 46 |
| 3.1. Tipo | 46 |
| 3.2. Nivel | 47 |
| 3.3. Diseño | 47 |
| 3.4. Preparación de los datos de entrada | 47 |
| 3.5. Desarrollo del modelo..... | 49 |
| 3.6. Verificación y validación..... | 49 |
| 3.7. Análisis de sensibilidad e interpretación | 50 |
| 4. CAPITULO 4. DISEÑO DE REDES LOGISTICAS DE DOS NIVELES, CONSIDERANDO INCERTIDUMBRE EN LA DEMANDA Y CALIDAD EN LA PRODUCCIÓN..... | 51 |
| 4.1. Contexto | 51 |
| 4.2. Modelo determinista para redes logísticas de dos escalones | 53 |

| | |
|---|-----------|
| 4.3. Modelo determinista | 53 |
| 4.4. Modelo Estocástico | 56 |
| 4.5. Materiales y métodos | 59 |
| 4.6. Resultados Numéricos | 62 |
| 4.7. Análisis de sensibilidad | 66 |
| 4.8. Conclusiones del capítulo..... | 72 |
| 5. CAPITULO 5. DISEÑO DE REDES LOGISTICAS DE DOS NIVELES CONSIDERANDO DEMANDA Y CALIDAD ALEATORIA EN UN ENTORNO MULTERIODO | 74 |
| 5.1. Contexto | 74 |
| 5.2. Modelo multietapa con reconfiguración dinámica de centros de distribución..... | 75 |
| 5.3. Materiales y métodos | 78 |
| 5.4. Resultados numéricos | 81 |
| 5.5. Análisis de sensibilidad | 84 |
| 5.6. Conclusiones del capítulo..... | 91 |
| 6. Conclusiones generales | 93 |
| 7. Bibliografía..... | 95 |

Resumen

La presente investigación aborda el diseño, evaluación y análisis de una red logística de dos niveles considerando la demanda de los clientes y calidad del producto como variables aleatorias dentro de una cadena de suministro, compuesta por plantas de manufactura, centros de distribución y clientes, a través de la cual, mediante la aplicación de un modelo de optimización estocástico, se busca encontrar configuraciones eficientes que permitan minimizar el costo total del sistema a la vez de medir la capacidad de respuesta ante condiciones cambiantes.

El estudio inicia con la formulación de un modelo determinista el cual sirve de punto de partida para comprender el comportamiento de la red propuesta, posteriormente, se incorpora los parámetros de incertidumbre mediante la programación estocástica de dos etapas que permite modelar parámetros inciertos, respetando una secuencia de decisiones: primero se definen las decisiones de apertura de instalaciones y después se ajustan las asignaciones, una vez revelada la incertidumbre, la demanda se formula bajo una distribución normal y la calidad del producto mediante una distribución beta, lo que permite representar con mayor fidelidad el desempeño real del sistema.

El objetivo principal de este estudio es formular y analizar como el modelo de optimización propuesto integra de manera adecuada las fuentes de incertidumbre y costos asociados a la operación de la red, y que a su vez minimicen el costo total esperado del sistema, por lo cual se utilizan técnicas de programación estocástica y el software de optimización LINGO, que permite una evaluación integral de los múltiples posibles escenarios implicados en un entorno volátil.

Los resultados obtenidos se evaluaron comparando el tamaño de los modelos, así como del desempeño del modelo estocástico frente al determinista, y mediante un extenso análisis de sensibilidad que estudia el impacto de la variación de diversos costos y parámetros, evidenciando que la inclusión de incertidumbre en demanda y calidad refuerza la capacidad del sistema para operar bajo escenarios inciertos lo que permite decisiones más informadas y asertivas, para fortalecer la planificación estratégica y robustas para el diseño de redes logísticas bajo condiciones reales.

Abstract

This research addresses the design, evaluation, and analysis of a two-level logistics network considering customer demand and product quality as random variables within a supply chain, composed of manufacturing plants, distribution centers, and customers, through which, by applying a stochastic optimization model, the aim is to find efficient configurations that minimize the total cost of the system while measuring its responsiveness to changing conditions.

The study begins with the formulation of a deterministic model, which serves as a starting point for understanding the behavior of the proposed network. Subsequently, uncertainty parameters are incorporated through two-stage stochastic programming, which allows uncertain parameters to be modeled, respecting a sequence of decisions: first, decisions on opening facilities are defined, and then allocations are adjusted. Once the uncertainty is revealed, demand is formulated under a normal distribution and product quality under a beta distribution, which allows for a more accurate representation of the system's actual performance.

The main objective of this study is to formulate and analyze how the proposed optimization model adequately integrates the sources of uncertainty and costs associated with network operation, while minimizing the total expected cost of the system. To this end, stochastic programming techniques and LINGO optimization software are used, allowing for a comprehensive evaluation of the multiple possible scenarios involved in a volatile environment.

The results obtained were evaluated by comparing the size of the models, as well as the performance of the stochastic model versus the deterministic model, and through an extensive sensitivity analysis that studies the impact of the variation of various costs and parameters, showing that the inclusion of uncertainty in demand and quality reinforces the system's ability to operate under uncertain scenarios, which allows for more informed and assertive decisions to strengthen strategic and robust planning for the design of logistics networks under real conditions.

Agradecimientos

Expreso mi más sincero agradecimiento a cada uno de los catedráticos que formaron parte de mi formación durante este camino, ya que sus valiosos conocimientos, orientación y consejos contribuyeron de manera significativa a mi desarrollo académico y profesional durante este importante proceso, ya que no solo fortalecieron mis competencias, sino que también despertaron en mí el interés por seguir aprendiendo y superándome.

De manera especial, agradezco a mi director de tesis, el Dr. Héctor Rivera Gómez, por su constante apoyo, orientación y disposición durante el desarrollo de este trabajo. Su guía y paciencia fueron fundamentales para la correcta elaboración de esta investigación, así como a su entusiasmo y conocimiento que me permitieron no solo comprender, sino también disfrutar este fascinante campo de estudio.

Asimismo, agradezco a todas aquellas personas que de manera directa o indirecta aportaron al logro de este trabajo, ya sea brindando orientación, apoyo moral o facilitando los recursos necesarios para su desarrollo. Cada contribución fue valiosa y significativa para alcanzar este objetivo

Por último, agradezco a la Universidad Autónoma del Estado de Hidalgo mi casa de estudios que ha estado conmigo desde mi formación media superior y que hoy me brinda la oportunidad de continuar desarrollándome académica y profesionalmente, consolidando así este importante logro en mi vida.

Dedicatorias

Dedico este trabajo primeramente a Dios, por darme la vida y fortaleza necesaria para continuar y no rendirme.

A mi familia, quienes me brindaron su paciencia, comprensión y apoyo incondicional durante las largas horas de trabajo, por nunca soltarme, y acompañarme en cada etapa de este proceso.

De manera muy especial a mi esposo, quien me motivo a no dejar este sueño de lado, por sus constantes recordatorios de no postergar mis metas y sobre todo por su acompañamiento, consejos y confianza que me permitieron vislumbrar la culminación de este logro

A mis hijas Carla y Julieta que con su amor constante me dieron la fortaleza necesaria para seguir adelante. Ellas son la razón por la que busco superarme cada día y dejarles la enseñanza de que el mundo es suyo y que pueden lograr todo lo que se propongan.

A mis padres, por el tiempo brindado en todo mi proceso académico ya que nunca han dejado de creer en mí y han sido un pilar fundamental en cada etapa de mi vida.

Tabla de simbología

| | |
|------|---|
| r | Nodos finales (representa a los clientes con cierta demanda) |
| j | Nodos intermedios que almacenan y distribuyen los productos (silos) |
| i | Plantas productoras |
| D | Demanda |
| f | Costos fijos |
| g | Costos marginales |
| q | Capacidad |
| y | Decisión binaria para los silos |
| O | Capacidad máxima de las plantas |
| p | Proporción de defectos |
| cd | Costo por defecto |
| a | Costo unitario de transporte |
| s | Cantidad enviada por ruta |

Variables de decisión

| | |
|------------|--|
| f_1 | Costo fijo de instalación de cada silo |
| g_j | Costo marginal por unidad de tiempo de instalación |
| C_{tra} | Costo de transporte |
| C_{d1} | Costo de defectos de la planta 1 |
| C_{d2} | Costo de defectos de planta 2 |
| O_1 | Cantidad máxima disponible de la planta 1 |
| O_2 | Cantidad máxima disponible de la planta 2 |
| q_j | Capacidad máxima de instalación |
| PD_1 | Porcentaje de participación de la planta 1 |
| PD_2 | Porcentaje de participación de la planta 2 |
| QCP_1 | Costo que genera la planta 1 por producto conforme |
| QCP_2 | Costo que genera la planta 2 por producto conforme |
| TDP_1 | Tasa de defectos promedio de la planta 1 |
| TDP_2 | Tasa de defectos promedio de la planta 2 |
| μ | Media (demanda) |
| σ | Desviación estándar (demanda) |
| α_1 | Parámetro alpha de la distribución Beta para la planta 1 |
| α_2 | Parámetro alpha de la distribución Beta para la planta 2 |
| β_1 | Parámetro beta de distribución Beta a la planta 1 (que modelan la calidad) |
| β_2 | Parámetro beta de distribución Beta a la planta 2 |

1. CAPITULO 1. PROPÓSITO Y ORGANIZACIÓN

1.1. Introducción

El desarrollo de esta tesis tiene como propósito ampliar las estrategias tradicionales utilizadas en el diseño de redes logísticas, incorporando la incertidumbre inherente de un sistema real y opciones de flexibilidad operativa que brinden una toma de decisiones más realista. El trabajo se fundamenta en estudios previos de la literatura de optimización de sistemas logísticos, los cuales han mostrado la necesidad de incluir parámetros críticos altamente variables que representen de mejor manera la realidad de las cadenas de suministro.

En el ámbito logístico, rara vez se presentan condiciones ideales, ya que este entorno se caracteriza por variaciones y fluctuaciones constantes en parámetros como la demanda, la capacidad y la calidad. En general, el elevado número de variables y condiciones operativas dificultan la resolución de estos sistemas mediante métodos de optimización tradicionales; por ello el uso de modelos estocásticos han demostrado ser un enfoque adecuado para integrar y analizar comportamientos aleatorios de manera más reales.

A pesar de la relevancia de este tipo de estudios, la revisión de la literatura evidencia que su aplicación en el contexto mexicano es aún limitada, particularmente en estudios empíricos y de aplicación, lo cual abre un campo de oportunidad para el desarrollo de enfoques que permitan brindar estrategias robustas orientadas a mitigar los efectos de la incertidumbre y fortalezcan la toma de decisiones en la gestión de cadenas de suministro. En este sentido la presente investigación contribuye al proponer un marco teórico metodológico robusto para el diseño y planificación de redes logísticas en contextos inciertos.

1.2. Planteamiento del problema

Sin duda vivimos en una era de constantes transformaciones, en donde impera un entorno competitivo, donde factores como la globalización, la dinámica de mercados y la digitalización han cambiado la forma en que las empresas tanto grandes como pequeñas, gestionan la logística y las cadenas de suministro, al requerir una gestión eficiente y flexible que garantice su competitividad (Milovanovic et al., 2017).

En el entorno actual las organizaciones están expuestas a un alto nivel de variabilidad, en este contexto la adopción de modelos estocásticos, que permitan integrar la incertidumbre en la toma de decisiones logísticas, es fundamental para asegurar la capacidad de respuesta de las empresas ante cambios inesperados(Zhao et al., 2023).

Ante esta situación, surge la necesidad de desarrollar modelos de optimización que incorporen explícitamente la incertidumbre, permitiendo evaluar su impacto en decisiones estratégicas y operativas dentro de la red logística, es por ello que este trabajo se basa en estudios previos que han desarrollado modelos estocásticos y metodologías de simulación para analizar la optimización de redes logísticas, basadas en el problema SCTE (Single-Commodity Two-Echelon), modelo de dos niveles para un solo tipo de producto.

1.3. Importancia del tema

Es crucial destacar que la correcta implementación de sistemas logísticos eficientes tiene un impacto directo en la competitividad de las empresas, ya que la ausencia de herramientas que integren correctamente variables bajo incertidumbre puede llevar a decisiones subóptimas, las cuales reduzcan la capacidad de producción o generen producción innecesaria al no tener parámetros correctos de la capacidad efectiva de las plantas.

En el caso de Hidalgo, un estado en crecimiento industrial(*Indicador Trimestral de la Actividad Económica Estatal*, 2025), la optimización logística es una herramienta esencial que muestra un enfoque que permita modelar problemas logísticos

considerando a la demanda y calidad simultáneamente como variables estocásticas, y con ello mejorar su competitividad, es así que la investigación sobre el diseño óptimo de centros logísticos en redes de dos niveles bajo incertidumbre representa una excelente oportunidad para ayudar a las empresas a adaptarse a las demandas del mercado global.

Este estudio permitirá analizar y optimizar la localización de centros logísticos, así como las rutas de distribución, considerando y estudiando la variabilidad en los flujos de la demanda y analizar su nivel de calidad en producto conforme, con el objetivo de poder minimizar los costos asociados al almacenamiento, apertura de silos, nivel de aceptación de producto, capacidad de almacenamiento y transporte ofreciendo un grado de flexibilidad en la toma de decisiones logísticas.

1.4. Motivación

La gestión logística y la optimización de redes de distribución ha experimentado avances significativos en los últimos años, marcando un notorio avance en el tema de la cadena de suministros el cual ha evolucionado significativamente en las últimas décadas, pasando de enfoques tradicionales basados en modelos deterministas a enfoques más avanzados que integran la incertidumbre y la variabilidad inherente a los mercados actuales. En este sentido, el diseño de centros logísticos y el enrutamiento de vehículos han sido objeto de diversas investigaciones que buscan optimizar la eficiencia operativa y reducir los costos asociados al transporte y almacenamiento de productos.

El campo de la optimización estocástica es la base técnica en la cual se sustentan los modelos desarrollados en esta tesis, la cual se caracteriza por su capacidad de manejar la incertidumbre en los sistemas logísticos y de distribución, lo cual es esencial en la gestión de cadenas de suministro y planificación de redes logísticas.

Uno de los principales pioneros, y quien aportó las primeras contribuciones a esta área, fue el trabajo de Birge & Louveaux (2011), quienes fundamentaron la incertidumbre estocástica en la optimización logística, sentando las bases para el desarrollo de modelos

robustos que pueden adaptarse a variaciones en la demanda y otros factores inciertos, la cual es clave para manejar la variabilidad que afectan las cadenas de suministro

De acuerdo a Ghiani et al. (2013), el término estocástico se refiere a la incorporación de la incertidumbre en los modelos de decisión, como lo es la demanda de los clientes, los tiempos de viaje o los costos de transporte.

Es así como la programación estocástica, permite incorporar la incertidumbre en los modelos logísticos para tomar decisiones más robustas, al permitir integrar la variabilidad y el riesgo en los modelos logísticos, proporcionando soluciones más robustas frente a cambios inesperados en la demanda o tiempos de entrega. De acuerdo con Rivera Gómez et al. (2023), los modelos estocásticos permiten integrar la incertidumbre en la planeación logística, ayudando a las empresas a optimizar sus decisiones frente a condiciones fluctuantes del mercado.

Uno de los problemas relevantes en este campo es el problema de ubicación discreta de dos niveles para una sola mercancía (SCTE) es un enfoque relevante en la optimización logística, ya que se enfoca en la localización de un nodo de origen hasta el cliente final. Este tipo de problema permite a las empresas maximizar la eficiencia en la distribución de productos minimizando los costos de transporte entre los distintos niveles de la red logística. Estudios recientes han demostrado que el SCTE es particularmente útil para optimizar la distribución de redes de múltiples niveles, donde se debe considerar tanto el flujo entre las instalaciones como el flujo hacia los clientes (Ghiani et al., 2013).

Otra teoría relevante es el Problema de Localización-Inventario (LIP), desarrollado por Miranda & Garrido (2004), que combina las decisiones de localización de centros de distribución con la gestión de inventarios, permitiendo optimizar los costos de almacenamiento y transporte, asegurando que los productos estén disponibles en el lugar y momento adecuados para satisfacer la demanda. Según Farahani et al. (2017), el LIP es particularmente útil en entornos donde se tiene una demanda incierta, al permitir tomar decisiones estratégicas sobre la ubicación de almacenes y la cantidad de inventario a mantener en cada uno de ellos. En la práctica, este modelo es ideal para PYMES que

requieran optimizar sus operaciones logísticas bajo restricciones presupuestarias y demandas fluctuantes.

Asimismo, el problema de ruteo de vehículos de dos niveles (2E-VRP), propuesto por Eitzen et al. (2018), se centra en la asignación óptima de rutas de transporte para la distribución de productos desde centros logísticos intermedios hasta los clientes finales, considerando tanto la variabilidad en la demanda como las restricciones de capacidad de los vehículos. Este modelo ha ganado gran relevancia en los últimos años para la resolución de problemas de distribución en redes logísticas con múltiples niveles de centros de distribución, haciendo con esto una reducción significativa en costos operativos y mejorando la eficiencia de transporte. Un estudio actual de Zhang, L., Ding, P., & Thompson, R. G. (2023) destaca que el 2E-VRP es aplicable en contextos de distribución urbana y en áreas geográficamente dispersas, lo que lo convierte en una herramienta poderosa para PYMES que necesitan optimizar sus rutas de entrega y mejorar su capacidad de respuesta en mercados de alta incertidumbre.

Por último, la optimización mixta-entera (MIP) en cadenas de suministro, es un enfoque ampliamente utilizado en problemas logísticos complejos, como lo es la ubicación de centros logísticos y la asignación de rutas de transporte bajo restricciones de capacidad y costos, como lo dice Charaf et al. (2024), señala que los modelos MIP son efectivos para optimizar redes logísticas en entornos inciertos, al poder considerar múltiples variables y restricciones simultáneamente, lo que aporta puntos importantes para poder optimizar las decisiones logísticas en redes de dos niveles, considerando dos variables, como lo es la variabilidad en la demanda y la capacidad de los centros de distribución.

En los últimos años, la integración de estas teorías en modelos logísticos más complejos ha permitido el desarrollo de soluciones más efectivas para la gestión de redes de distribución. Lam et al. (2024) utilizó de algoritmos metaheurísticos, como los algoritmos genéticos híbridos, ha demostrado ser una herramienta poderosa para resolver problemas logísticos bajo condiciones de incertidumbre. Estos algoritmos combinan técnicas de optimización evolutiva con métodos de simulación estocástica para encontrar soluciones óptimas en escenarios complejos.

1.5. Problemática

Las empresas enfrentan dificultades significativas para gestionar de manera eficiente la distribución de sus productos, no por la falta de herramientas avanzadas de planificación logística, sino por las limitaciones asociadas a su implementación efectiva. Esto genera sobrecostos en transporte, largos tiempos de entrega y una disminución en la satisfacción de los clientes. Estas empresas necesitan implementar sistemas de planificación más flexibles y eficientes que les permitan mejorar su capacidad de respuesta ante las fluctuaciones del mercado y demandas inciertas.

En este contexto, al abordar a un nivel operativo, los entornos inciertos complican la planificación logística, ya que el ignorar la aleatoriedad de calidad del producto y considerar la demanda como un factor fijo limita la capacidad de generar soluciones óptimas y de anticipar escenarios críticos resultando en costos operativos elevados, tiempos de entregas más largos y una disminución en la eficiencia operativa.

A pesar de ello en varios modelos logísticos tradicionales no se toman en cuenta fuentes clave de incertidumbre de forma conjunta, es así como el uso de modelos estocásticos, apoyados en softwares especializados de optimización, permiten incorporar simultáneamente la incertidumbre en la demanda y calidad para mejorar la eficiencia operativa, minimizar costos y aumentar la capacidad de respuesta frente a cambios inesperados en las variables estocásticas.

Este enfoque no solo contribuye en la reducción de costos, sino que también proporciona un marco teórico y práctico para mejorar la eficiencia logística en redes de distribución complejas.

1.6. Pregunta de investigación

¿Cómo influye la incorporación conjunta de incertidumbre en la demanda y en la calidad del producto en las decisiones estratégicas de diseño y operación de una red logística de dos niveles, bajo el enfoque SCTE, formulado como un modelo estocástico?

1.7. Importancia de la investigación

Esta investigación es relevante ya que aportará un estudio teórico que responda a la necesidad real de desarrollar un modelo estocástico de optimización logística bajo condiciones de incertidumbre, con el objetivo de mejorar la eficiencia en la distribución de productos y minimizar los costos operativos.

Este modelo basado en el enfoque Single-Commodity Two-Echelon (SCTE) en conjunto con el uso de software de optimización, como plataforma de resolución contribuye a generar una evaluación computacional precisa, medible y escalable, así como a diseñar redes logísticas resilientes y capaces de adaptarse a entornos inciertos con soluciones robustas y eficientes.

En conjunto, esta investigación no solo aporta valor teórico al modelado bajo incertidumbre si no también un marco teórico y práctico que pueda aplicarse en otros entornos logísticos, contribuyendo así a la optimización de la planificación y distribución de productos en redes de dos niveles. Además, se espera que los hallazgos de esta investigación contribuyan al desarrollo de enfoques más robustos para la gestión logística de entornos con alta variabilidad, de redes complejas y volátiles.

1.8. Propósito de la investigación

La presente investigación tiene como objetivo principal desarrollar, formular y evaluar un modelo basado en el problema Single-Commodity Two-Echelon (SCTE) el cual se enfoca en incorporar cambios en la demanda y la calidad del producto, con el objetivo de mejorar y sustentar una correcta toma de decisiones, respondiendo así la necesidad de gestionar la logística de manera eficiente, adaptándose a un entorno donde los comportamientos de los consumidores y la demanda son inestables y difíciles de predecir, y proponer una herramienta de apoyo en la toma de decisiones para mejorar la operación logística.

Esta investigación incorpora simultáneamente la incertidumbre en la demanda de los clientes y en la calidad del producto conforme generado por cada planta, estos dos

elementos, aunque críticos en la operación logística, se han abordado de manera conjunta en menor medida en estudios previos. Es por ello que la finalidad es generar un modelo que permita la integración de estas dos variables estocásticas, y analizar el impacto bajo un extenso análisis de sensibilidad de la variación de diversos costos y parámetros de distribución de probabilidad. Que generen conclusiones de cómo influye la variabilidad bajo este enfoque y obtener escenarios reales de variabilidad, y permita analizar con mayor precisión la interacción de la fluctuación de parámetros que cambien las decisiones de diseño, y operación dentro de una red logística de dos niveles, así como su implementación en el software de optimización. El cual brinda diferentes soluciones en distintos escenarios y de esta manera comparar su comportamiento frente a un modelo determinista y poder brindar soluciones con una mejor planificación operativa en contextos logísticos complejos.

Para finalizar el estudio se busca aportar conocimiento en el desarrollo de soluciones que promuevan la flexibilidad y resiliencia de empresas en entornos de alta incertidumbre. Además de aportar bases teóricas en el ámbito estocástico, y promover alternativas de desarrollo que puedan mejorar la sostenibilidad y competitividad de las empresas en un mercado cada vez más dinámico.

1.9. Objetivo General

Desarrollar un modelo estocástico basado en el enfoque SCTE, que incorpore la incertidumbre en la demanda y calidad del producto, con el fin de evaluar el impacto de su variabilidad, dentro de la red logística de dos niveles de un solo tipo de producto y generar soluciones robustas frente a escenarios inciertos, utilizando el software LINGO como herramienta de resolución.

1.10. Objetivos específicos

1. Desarrollar un modelo de programación estocástica de dos etapas, que permita representar de manera adecuada la red logística bajo estudio, incorporando

incertidumbre en la demanda de los clientes y en la calidad del producto, con el fin de apoyar la toma de decisiones en contextos operativos variables.

2. Implementar y resolver el problema propuesto con el propósito de comparar resultados de su versión determinista y estocástica con el fin de evaluar y comparar el impacto de la incertidumbre en las decisiones de localización, asignación y flujo.
3. Evaluar los costos y beneficios asociados a la implementación de un diseño de centros logísticos en redes de dos niveles, considerando escenarios de alta y baja demanda.
4. Incorporar restricciones de nivel de servicio que permita controlar el porcentaje de demanda insatisfecha, así como costos de producto no conforme y comparar el efecto de distintos porcentajes sobre el desempeño del sistema y el costo total.

1.11. Justificación

La presente investigación es de gran importancia, ya que busca abordar las complejidades y desafíos de los entornos logísticos actuales, considerando la incertidumbre inherente a la demanda y a la calidad de los productos. Este enfoque resulta esencial en el contexto actual (Dolgui et al., 2020), donde las condiciones de mercado son cada vez más volátiles y variables. Para este contexto, el uso de modelos deterministas tradicionales resulta insuficiente para reflejar de manera adecuada el entorno operativo, ya que no permite garantizar la toma de decisiones correctas ante la presencia de incertidumbre. En consecuencia, se requiere la adopción de enfoques más robustos, capaces de minimizar los riesgos operativos y maximizar los beneficios en la gestión logística.

Además, la revisión de la literatura e información disponible evidencia una limitada información en el ámbito académico y empresarial sobre la aplicación de modelos de programación estocástica en este tipo de entornos.(Birge & Louveaux, 2011) La programación estocástica permite incluir la variabilidad de la demanda en el proceso de optimización, lo que resulta fundamental para una adecuada toma de decisiones en la

gestión de inventarios, transporte y asignación de recursos. Lo cual proporcionará un modelo práctico que podrá ser implementado para mejorar la eficiencia logística, reducir costos y aumentar la capacidad de respuesta ante fluctuaciones.

A nivel teórico, este estudio busca ampliar el conocimiento sobre la integración de métodos estocásticos en la planificación logística, creando una base para futuras investigaciones en áreas como la gestión de la cadena de suministros bajo condiciones de incertidumbre. Este enfoque es particularmente relevante en México, donde el desarrollo y la aplicación de modelos estocásticos es limitado, debido a la complejidad y a la escasez de especialistas dedicados a esta área. Según estudios, la programación estocástica no es tan difundida en el país, lo que sugiere una brecha significativa en la formación de especialistas en esta disciplina a niveles avanzados y en sectores aplicados como la logística.

A nivel social, este proyecto tiene el potencial de impactar positivamente al promover la estabilidad económica en la región, al mejorar la capacidad de las empresas locales para adaptarse eficientemente a demandas fluctuantes, fortaleciendo su competitividad y fomentando un crecimiento económico estable.

Desde un enfoque práctico, el modelo que se desarrollará, permitirá a los gestores logísticos contar con una herramienta valiosa para enfrentar los desafíos de la demanda variable, ya que ofrece la posibilidad de simular y analizar diferentes escenarios con variables estocásticas, lo que facilita una toma de decisiones más robusta, contribuyendo a la sustentabilidad y resiliencia.

1.12. Alcances y limitaciones

1.12.1 Alcances

El presente estudio aborda un modelo de optimización estocástica enfocándose en los factores de incertidumbre, basado en el problema SCTE, aplicable a redes logísticas de dos niveles. La investigación abarca únicamente el desarrollo y análisis de un modelo de simulación estocástica que integre la variabilidad de elementos inciertos, con el fin de mejorar la toma de decisiones logísticas en escenarios específicos

Se considera explícitamente la incertidumbre en la demanda de los clientes y la proporción de productos conformes (calidad), mediante distribuciones de probabilidad (normal y beta).

Además, se explorarán diferentes configuraciones logísticas mediante análisis de sensibilidad en el software de optimización, para identificar las configuraciones más eficientes y flexibles ante fluctuaciones en el mercado generando un modelo determinista equivalente para cada tamaño de muestra. Así como un análisis comparativo del desempeño y complejidad computacional entre el modelo estocástico y determinista, y por último un análisis de sensibilidad en parámetros clave como lo es la calidad, capacidades, costos etc. Lo cual permite evaluar el comportamiento del modelo propuesto.

1.12.2 Limitaciones

1. Este estudio considera solamente un tipo de producto, por lo cual no existe diferentes líneas de producción o un análisis sobre la interacción entre cada producto.
2. Evaluación restringida a redes logísticas de dos niveles, dejando fuera a redes logísticas multinivel, que podrían ser relevantes para empresas de mayor escala o con operaciones en múltiples regiones.

1.13. Contribución de la tesis

La principal contribución es el desarrollo y validación de un modelo de optimización estocástica para el diseño de redes logísticas de dos niveles, que incorpore de manera conjunta la incertidumbre en la demanda y calidad del producto para analizar el comportamiento frente a entornos variables.

Como contribución adicional, se integra la toma de decisiones dinámicas de apertura y cierre de silos a lo largo del horizonte de planeación, superando en enfoque tradicional de localización estática y aportando mayor flexibilidad al modelo. En ambos

casos se incluye un análisis comparativo para evaluar el impacto de la incertidumbre en los costos y en la complejidad computacional del problema y generando análisis de sensibilidad que permiten identificar los parámetros más influyentes en la toma de decisiones. Generando de esta manera información útil para apoyar la planeación logística en contextos más apegados a la realidad.

La contribución académica del presente trabajo de investigación está reflejada en la presentación del modelo “Diseño de redes logísticas de dos niveles, considerando incertidumbre en la demanda y calidad en la producción”, en el XIII congreso de la Sociedad Mexicana de Investigación de Operaciones, llevado a cabo en León, Guanajuato el 10 de octubre del 2025.

1.14. Organización del estudio

Esta investigación está dividida en cinco capítulos, los cuales se explican a continuación:

En el capítulo 1 se presenta el planteamiento del problema, los objetivos generales, objetivos específicos, la justificación y los límites del estudio, En el capítulo 2, se muestra el marco teórico y la revisión de la literatura que fundamentan este trabajo, al presentar a diversos autores con temas claves de redes logísticas, modelos deterministas, programación estocástica, demanda aleatoria, calidad aleatoria y cadenas de suministro. En el capítulo 3 se aborda la metodología, niveles y técnicas aplicadas al diseño de esta tesis.

A partir del capítulo 4, se muestra el primer modelo matemático, en el cual se desarrolla la solución de una red logística de dos niveles con demanda y calidad aleatoria, formulada con un enfoque SCTE. Con la finalidad de brindar un análisis de sensibilidad que ayude a mostrar el efecto de incorporar de la variabilidad y fluctuación de los parámetros principales del modelo. Finalizando con el segundo modelo donde se desarrolla una extensión del modelo del capítulo 4 incorporando decisiones dinámicas de apertura y cierre de centros de distribución en un horizonte multi-periodo, lo que permite analizar el impacto de la flexibilidad operativa y finalmente en el último capítulo se exponen las conclusiones generales de la investigación.

2. CAPÍTULO 2. MACO TEÓRICO Y REVISIÓN DE LA LITERATURA

Dentro del área de investigación de operaciones y diseño de cadena de suministro, el diseño de problemas de localización de instalaciones ocupa un rol importante ya que en general este tipo de problemas busca determinar la ubicación óptima de uno o varios centros de distribución, que cumplan de forma eficiente una cierta demanda bajo ciertos criterios que influyen en generar costos de manera directa o indirecta (capacidad, infraestructura, calidad, distancias).

Generalmente, los problemas de localización pueden abordarse mediante tres enfoques principales, de acuerdo con (Birge & Louveaux, 2011):

- **Cualitativo:** el cual es aplicable a problemas de localización discretos y relativamente pequeños donde la toma de decisiones se evalúa a través de una puntuación ponderada por medio de criterios como la proximidad, infraestructura, servicios y accesibilidad, considerando un análisis multicriterio y herramientas como matrices de evaluación, listas de chequeo con un enfoque de juicio experto.
- **Cuantitativos:** Tiene sus bases en formular el problema de localización como un modelo de optimización, el cual sirve de parteaguas para la evaluación de esta tesis, ya que entre los más destacados se encuentra el problema de localización continua de una sola mercancía y una sola empresa, problemas de localización discreta de una sola hélice de una sola mercancía (SCSE) y problemas de localización discreta de dos niveles de una sola mercancía (SCTE).
- **Método híbrido:** el cual combina el método cuantitativo y cualitativo

Dentro de este capítulo se establecen los conceptos y herramientas clave que sustentan el modelo propuesto de esta investigación, con énfasis en programación estocástica.

2.1. Conceptos básicos sobre la modelación de redes logísticas bajo incertidumbre

La modelación de sistemas logísticos permite representar de manera estructurada el comportamiento de los dos procesos de suministro, producción, almacenamiento y distribución. Dentro de esta dinámica se presenta variaciones en parámetros como la demanda, fluctuaciones en la calidad del producto, decisiones operativas y restricciones de capacidad (Kogler & Maxera, 2026).

En este contexto, la simulación y optimización matemática es una herramienta clave que permite representar de manera adecuada el desempeño del sistema real, especialmente con modelos complejos, ya que brinda una respuesta ante diferentes escenarios posibles al reproducir de manera aproximada el comportamiento del sistema a través del tiempo.

Los modelos deterministas en donde las condiciones son ideales no representan adecuadamente la variabilidad inherente de los sistemas reales, por su parte la programación estocástica incorpora esta variabilidad al generar un conjunto de escenarios. Cada uno con una probabilidad de ocurrencia, de esta forma permite capturar la incertidumbre y ofrecer soluciones más robustas para la planeación operativa, ya que representa matemáticamente la reacción del sistema ante diferentes variables inciertas, minimizando el costo total esperado y garantizando niveles adecuados de servicio.

2.1.1 Planeación logística y sus implicaciones operativas

La planeación logística (Birge & Louveaux, 2011) determina que enviar, desde dónde enviarlo y a través de qué rutas o instalaciones, considerando costos implicados en las operaciones, inventario, capacidad, almacenamiento y distintas restricciones, las cuales generan y siguen un flujo de materiales e información y cualquier incremento, desfase o alteración puede generar desviaciones importantes en el sistema. Afectando así su eficiencia y nivel de servicio, dentro de este entorno el nivel de servicio se refiere al porcentaje de demanda satisfecha en tiempo y forma. Una red logística con un alto nivel de servicio responde de manera más confiable, pero al añadir incertidumbre se

requiere estrategias adicionales, como mayor capacidad, rutas flexibles y operaciones adecuadas.

2.1.2 Complejidad computacional en la modelación de redes logísticas de dos niveles

Las decisiones de asignación, transporte, apertura o cierre de centros, así como cumplir con el nivel de demanda necesaria, que implica la planificación y operación de redes logísticas de dos niveles, integra un problema complejo desde la perspectiva matemática y computacional conformada por relaciones no lineales y un crecimiento exponencial de escenarios. Por ello este tipo de problemas se puede clasificar dentro de la categoría de problemas NP-hard, ya que no se pueden resolver mediante métodos tradicionales, ya que el tamaño del problema crece de manera exponencial y debido a ello, se requieren técnicas avanzadas y complejas para su solución (Biro Tamara J. & Horvath Adrian, 2024).

Dentro de la literatura se puede clasificar la complejidad relevante para las redes logísticas, alguna de ellas incluye a problemas P (Polynomial time) que incluye problemas que pueden resolverse en tiempo polinomial, es decir problemas logísticos simples, NP (Nondeterministic Polynomial Time), el cual abarca problemas que donde es difícil encontrar una solución, pero es sencillo verificar si una solución dada es correcta. NP-Complete que son problemas que están tanto en NP como en NP-hard, ya que son extremadamente complejos y por último los NP-hard que incluye decisiones binarias, múltiples periodos, escenarios estocásticos.

2.1.3 Optimización matemática

Dentro del contexto de las matemáticas, la optimización es el proceso de encontrar la mejor solución posible a un problema bajo ciertas restricciones, lo cual se aplica en la asignación óptima de recursos, rutas de transporte o niveles de producción, los cuales son factores clave en la cadena de suministro. Dentro de esta investigación se hace el uso de la optimización estocástica, ya que incorpora incertidumbre mediante variables aleatoria y escenarios probabilísticos.

2.1.4 Programación estocástica de dos etapas

Este modelo se caracteriza por una toma decisiones de dos etapas, como su nombre lo dice, cada una en un momento distinto, la primera es una decisión anticipada antes de conocer el valor de variables aleatorias y una etapa de ajuste en donde se revela la incertidumbre, lo que lo hace adecuada para problemas en donde se presenta información incierta en donde se requiera una toma de decisiones adecuada que deba adaptarse a diferentes escenarios(Ruszczynski & Shapiro, s/f).

2.1.5 Software LINGO

Debido a la necesidad de representar escenarios que reflejen de la manera más fiel posible el comportamiento de un sistema o proceso real, en este trabajo se emplea el software LINGO desarrollado por LINDO Systems, diseñado para formular y resolver modelos matemáticos lineales, no lineales (convexos y no convexos/globales), cuadráticos, cónicos de segundo orden, semidefinidos, estocásticos y enteros ya que se incluye un potente lenguaje y un entorno complejo que permite la creación y edición de problemas complejos con formato algebraico.

El entorno del programa permite integrar hojas de cálculo, lo que facilita la exportación de datos directamente desde Excel. Esta funcionalidad se aprovecha en el presente trabajo para implementar un modelo estocástico de dos etapas aplicado a una

red logística de dos niveles, permitiendo representar variables estocásticas en la demanda requerida por cada cliente y la calidad mediante distribuciones normal y beta, así como la comparación de diferentes escenarios y el rendimiento asociado de cada uno.

2.2. Cadena de suministro

La cadena de suministro es un concepto central en el ámbito logístico ya que representa un eje de los procesos, partes, decisiones recursos e información involucrados durante toda la cadena desde el origen hasta el consumidor final, es así que su estudio resulta fundamental para entender el funcionamiento de las organizaciones en entornos dinámicos y competitivos. En este apartado se muestra un panorama general del concepto iniciando desde sus antecedentes, así como sus principales definiciones y una revisión de estudios de investigación relevantes que permitan comprender su evolución y aplicación.

2.2.1 Antecedentes

La cadena de suministro se puede definir como una red de interacciones, que involucran organizaciones, empresas y etapas interdependientes cuyo propósito es satisfacer las necesidades del cliente, generalmente sus actores principales suelen ser los proveedores, fabricantes o productores, distribuidores (mayoristas o minoristas) y los consumidores finales (Ruszczynski & Shapiro, s/f).

A lo largo de las distintas etapas de la cadena de suministro, estos actores interactúan a través del flujo de información, recursos y bienes, teniendo como objetivo que los productos o servicios lleguen al consumidor final, de manera eficiente y ágil, para que esto se logre es fundamental optimizar procesos, reducir tiempo de entrega y mejorar la coordinación entre los eslabones de la cadena.

El concepto de cadena de suministro ha experimentado una evolución significativa a lo largo del tiempo, su origen se puede remontar a el ámbito militar, en donde se dio un

gran auge a la innovación de estrategias logísticas avanzadas, centrándose en el suministro de alimento y armas de manera ágil y coordinada. Tener estos recursos a tiempo no solo garantizaba la operatividad de las tropas, si no que podía marcar una diferencia estratégica importante frente al enemigo.

Entre los siglos XVIII Y XIX, la producción en masa y expansión mercantil que genero la revolución industrial, contribuyo a la adaptación de sistemas más complejos de distribución y transporte, sentando las bases para la gestión de la cadena de suministro, ya que años más tarde se acuño el termino Supply Chain Management (Gestión de la cadena de suministro), es así como el termino y sus implicaciones se fueron desarrollando a través de los años(Hosseini Shekarabi et al., 2025).

El avance de las tecnologías de la información permitió brindar una mayor coordinación entre las etapas de la cadena de suministro, surgieron sistemas para facilitar la planificación y gestión de recursos como el MRP (Material Requirements Planning) y el ERP (Enterprise Resource Planning).

En los últimos años con la era de la digitalización, automatización, la inteligencia artificial, el uso de sistemas de simulación y análisis de datos han propiciado un entorno más competitivo y dinámico, ya que ha permitido optimizar procesos, y tener mayor ventaja en la toma de decisiones. Sin embargo, existen problemas que afectan su desempeño, como lo son: las interrupciones de abastecimiento, fluctuación en costos de almacenamiento y transporte, además de la globalización que ha generado una mayor complejidad en la gestión de la cadena de suministro, demandando un índice de respuesta con mayor flexibilidad y adaptabilidad a cambios inesperados.

En esta línea, un factor clave que las organizaciones deben considerar en sus estrategias de optimización y planificación, es la incertidumbre en distintos escenarios, que pueden afectar diferentes variables como lo es la demanda, calidad, logística, integrando enfoques estocásticos y técnicas de predicción avanzada La combinación de estas tendencias han generado nuevas estrategias, como la implementación de cadena de suministro resilientes y desarrollo de modelos de optimización robustos que consideren múltiples fuentes de variabilidad.

2.2.2 Definiciones importantes de Cadena de Suministro

De acuerdo con Chopra & Meindl (2013), define a la cadena de suministro como “toda red involucrada en la entrega de un producto o servicio, desde los proveedores de materias primas hasta el cliente final, incluyendo fabricantes, centros de distribución, transportistas, almacenes, minoristas y hasta el cliente mismo”, así como generar que la mejor forma de visualizar la cadena no es como una serie continua de información y procesos, si no como una red cuyo objetivo el maximizar el valor total generado del eslabón total.

Al visualizar a la cadena de suministro como una red y enfatizar en los desafíos que se enfrentan al incluir la incertidumbre en la demanda y suministro, (Lee, s/f) plantea que la gestión de la CS es un proceso estratégico para lograr ventaja competitiva, es por ello que se debe tomar en cuenta el comportamiento de esta de acuerdo a la creciente variedad de productos, los ciclos de vida cortos y el manejo efectivo de compartir información en tiempo real.

2.2.3 Estudios de investigación

Chen et al. (2024), utilizan la optimización robusta para proponer un modelo multiproducto y multiperiodo para la cadena de suministro en la industria de la construcción, incorporando incertidumbre en la demanda de materiales y capacidad de los proveedores Sin necesidad de distribuciones de probabilidad, aplicando mediante el uso de una formulación matemática que integro variable inciertas en la demanda y suministro mediante intervalos logrando así analizar la sensibilidad de decisiones clave del uso de proveedores de respaldo y gestión de pedidos pendientes (backorders) y de esta manera evaluar el impacto operativo y económico obtenidos de diferentes escenarios bajo incertidumbre.

Calle García et al. (2024), demuestran con su estudio la relevancia e importancia que actualmente tiene la aplicación de la IA (Inteligencia Artificial) en la gestión de la

cadena de suministro empresarial. Al examinar como genera un nivel alto de precisión en la toma de decisiones de la previsión de demanda y eficiencia operativa, es por ello que se aplicaron métodos deductivos, inductivos y analíticos para evaluar el impacto de la IA en procesos logísticos. Se encontraron hallazgos clave como lo es el caso de Walmart al reducir su nivel de inventario de un 20% al 15% con sistemas de predicción basados en IA.

Palafox-Palafox et al. (2023), generaron un modelo de pronóstico de cadena de suministro mediante redes neuronales, al analizar cómo las redes neuronales artificiales (RNAs) generan un rendimiento mayor en la precisión de gestión en el contexto de inventarios dentro de la cadena de suministro. Consideraron cuatro eslabones principales: proveedor, distribución, detallista y producción, a partir de estos eslabones y con la recopilación de datos históricos del inventario, se desarrolla un modelo de simulación con los datos de los niveles de inventario a través del tiempo, para entrenar 110 diferentes configuraciones de redes neuronales. Con los resultados se puede demostrar que su eficiencia es superior comparado con métodos como el promedio móvil y la regresión lineal.

Gupta et al. (2021) analizaron como el uso de las tecnologías de digitalización, contribuyen a mejorar la eficiencia y desempeño de la cadena de suministro, el cual se basa en un enfoque de toma de decisiones multicriterio DEMATEL (Decision Making Trial and Evaluation Laboratory). El cual ayudo a evaluar la relación de causalidad entre el desempeño de la cadena de suministro y diferentes factores de digitalización, destacando el uso de herramientas como big data analytics, blockchain, Internet de las cosas (IoT) e Inteligencia Artificial (IA).

Gastélum Valdez & Espitia Moreno (2022), abordaron distintas teorías relacionadas con la incorporación de la cadena de suministro, una de ellas basada en los recursos (Resource-Based View, RBV), la cual analiza como ciertos recursos que se consideran únicos o difíciles de imitar dentro de la cadena de suministro, logran generar ventajas competitivas sostenibles. De igual manera analizaron costos operativos, y como minimizarlos al decidir subcontratar actividades o integrarlas internamente dentro de la cadena de suministros. (teoría de los costos de transacción, TCT), así como el alcance

del papel de los líderes empresariales y la integración efectiva de los actores de la CS, y como cada uno es esencial para mejorar la competitividad en un entorno globalizado, y generar mejores ventajas en términos de rentabilidad y eficiencia.

Dumitrascu et al. (2020), reportaron y evaluaron el desempeño de un sistema de gestión de la cadena de suministro sostenible en la industria automotriz mediante inteligencia artificial (IA), en donde se identificaron los cinco KPIs (indicadores claves de desempeño) más relevantes de cada subsistema de la CS, estableciendo de esta manera una conexión adecuada con problemas específicos dentro de la cadena. Para obtener un monitoreo adecuado y eficaz. De igual manera se implementó un modelo basado en redes neuronales artificiales (MLP-Multilayer Perceptron) para predecir y evaluar el impacto de los KPIs en el desempeño de la CS, dando como resultado el diseño de una herramienta gráfica (GUI), la cual permite monitorear los KPIs más adecuados para afrontar problemas operativos específicos, mejorando la sostenibilidad, eficiencia y resiliencia operativa en la industria automotriz.

Abbaspour et al. (2022), abordaron un problema estocástico integrado de gestión de colas y programación matemática no lineal de enteros mixtos (MINLP), este modelo toma decisiones para abordar la interacción ente las rutas de entrega y la gestión de inventarios, basados en una cadena de suministro verde. A través de un canal en línea con problemas de ruteo de vehículos (VRP) y un canal tradicional con sistema M/M/C de colas para un proveedor de materiales de construcción, considerando la incertidumbre en la demanda, tiempos de servicio y de entrega, implementando la cadena de markov en tiempo continuo (CTMC) para modelar la probabilidad de los niveles de inventario, permitiendo reducir costos, optimizar la sostenibilidad y mejorar tiempos de una cadena de suministro dual.

Belhadi et al. (2024), consideraron como la incertidumbre y el dinamismo del entorno impacta en la resiliencia y el desempeño de la cadena de suministro (SCP), aplicando inteligencia artificial (IA). Para crear SCRes (resistencia y rendimiento de la CS), mediante un modelo de ecuaciones estructurales (SEM) y una base de datos de encuestas realizada a 79 empresas diversos sectores y tamaños, arrojando mejora en el desempeño a corto plazo, y fortaleciendo la resiliencia de la CS.

Lv & Shang (2023), evaluaron cómo la transformación digital y la sostenibilidad de la cadena de suministro mejora la eficiencia operativa, aplicando el uso de un modelo de ecuaciones estructurales (SEM), en donde la transformación digital facilita el seguimiento de rutas de transporté. Optimizando la administración de inventarios mediante algoritmos avanzados y como la industria 4.0 actúa como mediador de la CS a través de tecnología como la inteligencia artificial (IA), computación en la nube y el internet de las cosas (IoT), facilitando la automatización de procesos para su integración en la cadena de suministro, así como su conexión con la gestión sostenible (SSCM) y la economía circular.

Varriale et al. (2021), en su estudio analizan dos escenarios de la cadena de suministro de queso italiano, el primero enfocando en un entorno tradicional y el segundo implementando tecnologías emergentes como el blockchain, IoT y RFID. Demostrando cómo el segundo escenario mejoran la transparencia y trazabilidad de la CS, reducción en tiempos de gestión de pedidos, mejor impacto ambiental, automatización de procesos y mejores predicciones en la detección de fallas.

2.3. Calidad aleatoria

Un aspecto relevante dentro del análisis del sistema logístico son los factores aleatorios como la calidad ya que genera un impacto en la toma de decisiones operativas y estratégicas, es por ello que a continuación se presentan antecedentes, principales definiciones y una revisión de estudios de investigación que permitan contextualizar su aplicación en entornos logísticos.

2.3.1 Antecedentes de calidad aleatoria

Anteriormente la calidad era tratada como una variable determinista, la cual se asumía que cumplía con ciertos estándares establecidos de manera predecible y constante, mediante parámetros fijos dentro de los cuales el producto era considerado conforme. Asumiendo estos límites como tolerancias definidas para definir el porcentaje de productos defectuosos y de buena calidad, su medición de basaban principalmente

en herramientas estadísticas clásicas desarrolladas en los inicios de la mitad del siglo XX.

El muestreo estadístico de aceptación es una herramienta importante para evaluar la calidad de lotes completos a partir de un muestreo, asumiendo que las características de calidad seguían distribuciones normales o binomiales ya que su objetivo se centra en reducir la variabilidad al mínimo. Surgiendo así enfoques como el Six sigma el cual incorpora técnicas estadísticas más avanzadas, compartiendo la idea de una mejora continua mediante la reducción de defectos y con esto de la variación, ya que la incertidumbre es vista como un desvío el cual se debe corregir.

Al asumir que en muchas situaciones o casos la variabilidad no puede eliminarse o controlarse al 100%, se incorpora a la calidad como una variable aleatoria dentro de modelos estocásticos. Los cuales suelen ser entornos productivo más complejo y globales, demostrando que incorporar la variabilidad de la calidad, permite generar toma de decisiones con mejor robustez, reducir riesgos y optimizar en mayor porcentaje costos.

El enfoque estocástico de la calidad durante los últimos años ha incrementado su aplicación en industrias con altos estándares, como lo es la industria automotriz, agroalimentaria y farmacéutica dando lugar a modelos de toma de decisiones, asignación de rutas, pedidos, selección de proveedores y sistemas de devolución o penalización por incumplimiento. Siguiendo el modelo general de programación estocástica (Birge & Louveaux, 2011) se puede representar de la siguiente manera:

$$\text{Min } c^T x + E_{\xi} Q(x, \xi)$$

2.3.2 Definiciones importantes sobre Calidad

Al hablar de calidad, se debe tomar en cuenta a Edwards Deming quien fue uno de los principales pioneros en este ámbito, ya que fue considerado el padre del control estadístico de calidad, además definió los 14 principios de gestión y el ciclo PDCA, y define al termino calidad como la capacidad de satisfacer los requerimientos del consumidor de forma continua, con el menor costo posible y con la ayuda de todos los miembros involucrados en la organización. De igual manera Juran lo define como una

“adecuación al uso”, e introdujo la trilogía de la calidad: planificación, control y mejora, la cual es fundamental en el enfoque del Control Total de la Calidad en donde todas las áreas son responsables de una buena calidad, y no se limita solo a que el producto esté libre de defectos si no que cumpla con las expectativas del usuario final. Dentro de esta línea se puede observar como el concepto de Calidad tiene un impacto considerable y repercute en las ganancias y éxito de una empresa, es por ello que considerar diferentes fuentes de variación y un clima más apegado a la realidad repercute en brindar predicciones y cálculos más certeros en procesos de toma de decisiones.

2.3.3 Estudios de investigación:

Yang et al. (2022), introducen el aprendizaje automático como herramienta de diagnóstico en fallas de autopartes, optimización de procesos de manufactura, recolección y análisis de datos de calidad, así como apoyo a la remanufactura de partes no conformes, e incorporar en la problemática de la calidad en la manufactura. Donde cada fabricante produce las partes de acuerdo a sus capacidades, generando una variabilidad significativa en la calidad de las piezas, es así como los autores proponen el uso de modelos de aprendizaje automático (machine learning) y el uso de la impresión 3D para la producción de partes con requisitos de alta precisión y refinar un modelo de predicción para generar una oportunidad al controlar la calidad aleatoria.

Angioloni & Cerroni. (2025), a través de un enfoque de teoría de las perspectivas modelan la calidad aleatoria del agua como una variable estocástica, en la industria agrícola generando una forma de aleatoriedad ambiental, en donde se impacta sobre la perspectiva y resultado de sus acciones, a través de múltiples escenarios inciertos ambientales, donde se demuestra que la cooperación y la percepción de riesgo son factores clave para mejorar la calidad del agua

Wang et al. (2023), exploraron como impacta la variabilidad del tiempo basado en la teoría de la confiabilidad de sistemas, para lo cual proponen un modelo de optimización multiobjetivo estocástico en el área de la construcción del equilibrio-costo-calidad, como

variables aleatorias independientes. Teniendo como singularidad de que la calidad sea una variable estocástica, utilizan un modelo de calidad-tiempo, para cuantificar la probabilidad, basado en conjunto difuso trapezoidales que ofrecen datos más realistas de la calidad, así como la implementación de un algoritmo de optimización de enjambre de partículas (PSO), para lograr el balance de los tres objetivos con las mejores soluciones óptimas.

Feng et al. (2024), propusieron un nuevo enfoque para pronosticar la salud funcional de sistemas de manufactura multietapa incorporando la calidad funcional del producto, considerando factores como el desgaste de maquinaria, errores humanos y condiciones ambientales, los cuales son los principales causantes de la variabilidad aleatoria en la calidad en los procesos, Aplicaron una red de fabricación de flujo estocástico de calidad (QSFMN), el cual integra errores de inspección (α, β) , un cardo variable, el estado de degradación de la maquinaria e incorporando un flujo de calidad, representada como una distribución probabilística, la cual fluctúa con el tiempo y el status de cada estación de trabajo, generando un ajuste más preciso de ritmos de producción y mantenimiento de control de calidad de forma anticipada.

Chen et al. (2023), rastrearon y predijeron el estado de calidad de los productos, por medio de un modelo innovador llamado stochastic deep koopman (SDK), para abordar el modelado de sistemas de fabricación multietapa (MMS), el cual localiza y predice el estado de calidad de productos, tomando en cuenta calidades inciertas debido a perturbaciones externas o internas del proceso productivo que identifica el comportamiento complejo de los MMS, la cual incluye su variabilidad y permite analizar la propagación de la incertidumbre a lo largo del sistema.

Graber et al, (2020), estudiaron el desarrollo de estaciones de carga para vehículos eléctricos (BEV) en áreas urbanas con una metodología estocástica de dos etapas, incorporando restricciones de calidad de servicio (QoS) a sus usuarios, y minimizando costos a los gerentes. Utilizaron distribuciones probabilísticas por medio de simulaciones de variables aleatorias, como el tiempo de llegada, estado inicial de la carga, duración en el estacionamiento, los cuales se caracterizan por su aleatoriedad y como impacta en la calidad del servicio.

Ragnitz et al. (2025), desarrollaron un modelo que incorpora datos de incertidumbre aleatoria y epistemológica, basado en la identificación de daños estructurales por medio de una base de datos de medidas de una estructura (torre metálica) experimental, por medio de un enfoque estocástico de optimización multiobjetivo. Optimizando las diferencias entre los resultados de medición y los resultados de simulación, es decir buscar la brecha más corta entre estas diferencias, lo cual permite identificar resultados bajo condiciones reales como el viento, vibraciones y temperatura, estos datos de entrada son considerados variables aleatorias y se evalúan con técnica como la Bayoma (Bayesian Operational Modal Analysis), simulación monte Carlo y representar lo datos de calidad del sistema estructural.

Yilmazlar et al. (2024), abordaron el problema de capacidad de las líneas de producción de la industria automotriz, con una demanda incierta, esta debido a factores de calidad de los vehículos que no pueden producirse por diferentes temas de calidad, estos deben de retirarse de la línea y ceder su lugar a vehículos que cumplan con las características adecuadas. Combinando la programación estocástica con restricciones de penalización de faltantes (backlog), considerando múltiples niveles de demanda, con fallas estocásticas de producto, lo cual genera un número exponencial de escenarios por medio del enfoque de aproximación del promedio de la muestra y un algoritmo basado en la descomposición en forma de L.

Rivera Gómez et al. (2023b), analizaron la planificación agregada de la producción (APP) considerando tanto la demanda como la calidad como variables aleatorias, a través de un modelo estocástico multietapa. La calidad se modela como la proporción de productos sin defectos, representada mediante una distribución beta, lo cual permite capturar la variabilidad inherente al proceso productivo. Asimismo, se contempla la generación de una cantidad aleatoria de productos defectuosos, que se incorpora al modelo mediante programación estocástica multietapa. Este enfoque incluye parámetros de nivel de servicio y penalizaciones asociadas a los productos defectuosos, considerando explícitamente los costos derivados de la calidad no conforme. A través de una simulación de escenarios bajo condiciones de incertidumbre, se realiza un análisis

de sensibilidad que permite evaluar cómo los costos por defectos impactan la cantidad de unidades producidas, los niveles de inventario y la contratación de personal.

Shi et al. (2024), este estudio aborda el análisis de una base de datos de cerca de 2000 datos de cementación y entubado de pozos petroleros y de gas entre los años de 2016 y 2021 en el este de china, para lo cual proponen un modelo predictivo de calidad de cementación, así como técnicas de bosques aleatorios (random forest) de aprendizaje automático y Shapley Additive Explanations (SHAP). Que permiten interpretar el impacto de cada variable, incorporando optimización bayesiana, la cual ayudo a evaluar el desempeño bajo la alta incertidumbre, incluyendo múltiple variable estocásticas de entrada, valores atípicos, datos faltantes tratada mediante técnicas estadísticas, buscando modelar la calidad aleatoria por medio de anticipar e identificar factores clave que impactan la variabilidad en los resultados.

2.4. Demanda aleatoria

La demanda juega un papel importante al representar factores de incertidumbre ya que de esta influye directamente en la planificación de la distribución, producción e inventarios, así que, con el fin de conceptualizar este término, se presentan a continuación sus antecedentes, principales definiciones de la literatura y una revisión de estudios de investigación que permita comprender su aplicación y rol dentro de los modelos de planeación y optimización logística.

2.4.1 Antecedentes de Demanda aleatoria

En los primeros estudios en distintas áreas como la administración de operaciones, se consideraba a la demanda como una variable conocida, predecible y constante en distintos modelos matemáticos, conocidos comúnmente como modelos deterministas. Por ejemplo, una expresión típica tiene por objetivo minimizar el costo total de asignación:

$$\text{Minimizar } \sum c_{ij} x_{ij} \text{ sujeto a: } \sum x_{ij} \geq d_j$$

La restricción representada como: $\sum x_{ij} \geq d_j$, donde d_j tiene un valor conocido, y el modelo este sujeto a cumplir con esta demanda sin considerar fluctuaciones o situaciones inciertas, y es la base primaria para los enfoques de modelos pioneros. Principalmente para gestión en el área de manufactura con el MRP (planificación de requerimiento de material), cuyo objetivo es calcular la cantidad y el momento en que deben producirse componentes o solicitar material, basado en la programación maestra de producción, con tiempo fijo de entrega. A partir del desarrollo de estos modelos fueron evolucionando a partir de los años 80 y 90, incorporando enfoques probabilísticos que pudieran adaptar la incertidumbre de mejor manera y a principios del siglo XXI surgieron técnicas como:

- Simulación monte Carlo
- Programación estocástica
- Modelos robustos
- Pronósticos con aprendizaje automático

Los cuales permiten una toma de decisiones más realistas con un nivel de riesgo menor, cuya aplicación ha dados resultados en campos como la manufactura avanzada, la logística, educación, energía y servicios. Ya que en ámbitos de producción real es muy complicado predecir con exactitud la demanda de un producto y por ello la simulación es una herramienta muy practica en este contexto, como lo es Arena, flexSim, ProModel y AnyLogic, que analizan varias variables estocásticas y restricciones que permiten resultados con mayor precisión y optimizando beneficios y ganancia.

2.4.2 Definiciones importantes de demanda

En el ámbito de la logística y cadena de suministro Chopra & Meindl (2013), también incursiono en estos temas define a la demanda como la necesidad del cliente por productos o servicios, la cual se expresa en términos de calidad, tiempo y lugar de entrega requeridos, es aplicable en temas de la planificación de la demanda, diseño de redes logísticas y el control de inventarios. Dentro de esta línea podemos observar que

el termino demanda aplica en varios contextos y en el área de la gestión de operaciones es considerado como una representación del volumen proyectado de productos o servicios requerido por el cliente y debe ser atendida por la organización (Heizer & Render, 2010), el cual aborda estudios con gran relevancia para analizar y simular escenarios de cumplimiento de demanda, en temas de planificación de capacidad y producción.

2.4.3 Estudios de investigación

Sawant et al. (2024), diseñaron un modelo con demanda incierta en el sector de la salud, aplicado a una red de cadena de suministro de oxígeno bajo el escenario de una situación crítica, como lo es una pandemia, en donde la demanda tiene un grado alto de incertidumbre. Utilizan un enfoque de programación estocástica de dos etapas con múltiples escenarios, los cuales consideran múltiples restricciones, como el número limitado de vehículos, escases de producto, capacidad de producción limitada y una demanda incierta, generando resultados certeros sobre el número de instalaciones de almacenamiento y producción, así como rutas eficientes para su distribución.

Alikhani et al. (2023), estudiaron el diseño colaborativo de redes de distribución bajo un enfoque de colaboración horizontal, donde diferentes empresas comparten centros de distribución para formar coaliciones. Considerando múltiples escenarios con aumentos inciertos y repentinos de la demanda, así como interrupciones en los centros, teniendo como objetivo la optimización del uso de recursos y aumentar la resiliencia frente a la incertidumbre.

Liu et al. (2023), propusieron un modelo para la localización de instalaciones de centro de COVID-19, por medio de un marco de optimización de dos fases bajo escenario de demanda variable e incierta a gran escala, bajo predicciones con un muy corto plazo. Durante la primera fase se usa el método de la programación estocástica con aproximación de promedio de muestras (SAA), desarrollan un enfoque de relajación lagrangiana con optimización convexa en línea y durante la segunda fase se modifican los niveles de capacidad en tiempo real conforme fluctúa la demanda e introducen el

concepto de resiliencia operativa con información imperfecta, la cual cubre la necesidad de que la demanda sea aleatoria para escenarios que cambian constantemente.

Tighirt et al. (2025), incorporaron un modelo de cadenas de Markov de tiempo continuo, para un sistema autónoma de conversión eólica (WECS), bajo un consumo de carga aleatorio, para el cual cada nivel de carga corresponde a un estado específico, para predecir las variaciones estocásticas de la demanda. Es decir, de la carga, sin recurrir a bases de datos históricos, ni métodos como el monte Carlo, ya que el sistema estima las probabilidades de transición entre estados de la demanda, adquiriendo la capacidad de anticiparse a cambio imprevistos, integrándolo con el control del sistema, generando con ello un nivel de robustez que permite ajustar dinámicamente la diferencia entre el uso de la batería, la generación eólica y la demanda.

Malik & Kim, (2020), analizaron una demanda incierta tipo difusa estocástica, bajo un modelo integrado de una cadena de suministro para la producción de productos complejos con múltiples restricciones: limitante de espacio, presupuesto, producción flexible con tasa variable y calidad que depende del ritmo de producción. En comparación con modelos tradicionales, ellos consideran la interdependencia entre la tasa de producción y la calidad del producto, así como un enfoque de inversión discreta para abordar el tema de minimizar los costos de preparación, demostrando un aumento en la flexibilidad de sistemas productivos reales.

Wang et al. (2025), definieron el problema de enrutamiento camión-dron con demanda estocástica (TDRP-SD), al crear un módulo extra del modelo clásicos de ruteo bajo incertidumbre, incorporando seguimiento por medio de drones, los cuales abarcan extensiones mayores. Así como mejor adaptabilidad y mayor velocidad en el contexto de logística de emergencia, y sustentando una política de reabastecimiento sincronizado camión-dron (TDS), los cuales tienen la función de abastecer faltantes con las cualidades de ser autónomos mientras los camiones siguen en ruta, manejando de esta forma una toma de decisiones de reabastecimiento en tiempo real y flexibilidad en el ruteo al poder modelar la demanda como una variable aleatoria.

Ma et al. (2025), plantearon la implementación de dos enfoques para abordar un modelo de despacho económico de energía basado en la segmentación estocástica (SS) la cual genera escenarios de generación de energía eólica con alta incertidumbre por medio de la correlación espacio-temporal usando técnicas como la transformada de Karhunen-Loève (KL), Copulas R-vine el cual permite acortar la brecha de variabilidad. Mejorando de esta manera un despacho más preciso y con mejor adaptabilidad. Y el IBDR, el cual genera respuestas a la demanda basada en incentivos, modelándola en torno a paquetes de reducción de carga escalonados, con compensación económica, por medio de algoritmos de agrupamiento K-means que se activan según la necesidad de equilibrio.

Z. Liu et al. (2023), abordaron el concepto de protección ambiental ecológica, resaltando a los lineamientos y regulaciones de responsabilidad social corporativa, por medio de un modelo de diseño de red de cadena de suministro cerrada (CLSCND) con ayuda de la programación estocástica de dos etapas con aversión al riesgo (RATSSP). Considerando la toma de decisiones de capacidad de las instalaciones bajo el factor de demanda incierta y considerando restricciones con incertidumbre operativa en cuanto a demoras en entrega y Conditional Value at Risk (CVar) el cual modela el riesgo de beneficio. El objetivo es equilibrar el riesgo de ganancia con la ganancia total, integrando algoritmos metaheurísticos como SSO (optimización de enjambre simplificada), AG (algoritmos genéticos) Y PSO (optimización de enjambre de partículas) para abordar el enfoque del problema NP-hard.

Gao & Cai. (2025), investigaron una solución general para la asignación de recursos por medio de una programación escalable y moldeable ya que tiene la capacidad de operar en sistemas de borde sin limitaciones de una estructura fija de niveles jerárquicos, bajo un enfoque de modelos de demanda estocástica. El cual tiene como fin obtener una mayor precisión de la carga de trabajo y su variabilidad, es así como proponen un algoritmo de ubicación de recursos en cualquier capa de arquitectura de borde (PRAE), que aborda programación dinámica a subsistemas con una red isomórfica de subproblemas, teniendo como objetivo optimizar los ingresos esperados mediante una distribución ágil de los recursos bajo demandas estocásticas.

Diglio et al. (2020), desarrollaron un modelo de programación estocástica de dos etapas para resolver un problema de diseño de territorio bajo ciertas condiciones de demanda incierta, se contextualiza bajo un modelo de programación estocástica entera mixta de dos etapas, bajo restricciones de acciones de recursos: la externalización (outourcing) y reasignación de unidades territoriales que pueden cambiar de un distrito a otro y reducir la brecha de un ajuste de demanda. Permitiendo con cualquiera opción que el modelo corrija la asignación inicial de territorios, manejando así las dos etapas, en la primera etapa de decisiones correctivos o de ajuste sin conocer aún la demanda real y en la segunda etapa puede ajustar o corregir la solución inicial y se usa un modelado de prueba computacional probado con datos geográficos reales.

2.5. Programación estocástica

Para implementar un análisis del sistema logístico, la programación estocástica permite incorporar incertidumbre dentro de los parámetros del sistema y el proceso de toma de decisiones, lo cual resulta ser una herramienta relevante en el análisis de sistemas logísticos y para contextualizar este enfoque se presentan sus antecedentes, principales definiciones y una revisión de estudios de investigación que permitan comprender su evolución y aplicación dentro del diseño de redes logísticas bajo incertidumbre.

2.5.1 Antecedentes de programación estocástica

La optimización matemática aplicada o también conocida como la investigación de operaciones es una disciplina que se encarga de analizar, modelar y resolver problemas de toma de decisiones complejos, por medio de métodos matemáticos, esta disciplina abarca dos principales modelos:

- Modelos deterministas: Los cuales asumen que los datos de un sistema son conocidos con certeza y no se considera la incertidumbre.

- Modelos estocásticos: Estos modelos incorporan incertidumbre en al menos una variable, dando hincapié al uso de escenarios aleatorios, los cuales crean una representación de eventos futuros inciertos.

Sus orígenes se pueden encontrar en la década de los años 50, y a la necesidad de mejorar la toma de decisiones informadas, ya que muchos modelos realistas compartían cierto grado de incertidumbre, surgiendo así modelos que tuvieran la capacidad de manejar variables aleatorias.

La programación estocástica, generalmente se plantea en dos etapas (estas etapas dependen de cuando se revelen las variables inciertas), en la primer etapa o decisión anticipada, son las decisiones, datos o valores que se conocen antes de saber el valor real de las variables inciertas, y la segunda etapa o decisión de ajuste, es cuando se revela cierta información del entorno. El objetivo de este enfoque busca encontrar o acercar a la solución que minimice el mayor riesgo posible o se ajuste en mayor medida a una solución óptima, tomando criterio fluctuante como los tiempos de entrega, demanda de producto y los costos operativos, haciendo especialmente útil en áreas como la gestión de inventarios, la ubicación de instalaciones, planificación de recursos y la logística.

Cuando se incorpora variabilidad y riesgo, uno de los modelos matemáticos más utilizados integra herramientas matemáticas robustas, como lo es la programación estocástica de dos etapas, según Birge & Louveaux (2011) la formulación general se puede definir bajo la siguiente estructura:

$$\text{Min } c^T x + E_{\xi} Q(x, \xi)$$

$$\text{s. t. } Ax = b,$$

$$x \geq 0$$

Donde:

x : Representa las decisiones de la primera etapa o estratégicas, como la asignación inicial de recursos o la ubicación de instalaciones.

$Q(x, \xi)$: Es la función que define el costo esperado de la segunda etapa bajo un escenario ξ

E_{ξ} : Es la esperanza matemática que representa los escenarios posibles, permitiendo incorporar la incertidumbre en variables clave.

Es así como la programación estocástica de dos etapas permite representar modelos de problemas en los que algunas decisiones deben tomarse antes de conocer completamente el estado del entorno, mientras que otras se ajustan posteriormente una vez que la incertidumbre se ha revelado y así representar cadenas de trabajo complejas bajo condiciones dinámicas y no deterministas

2.5.2 Definiciones importantes de programación estocástica

Como se vio en la parte anterior de antecedentes, la programación estocástica es ideal para una toma de decisiones óptimas bajo condiciones de incertidumbre, ya que este tipo de modelo matemático es principalmente utilizado en variables aleatorias y escenarios probables. Es así que al presentar este tema no se puede dejar de lado el término incertidumbre el cual se refiere a los parámetros del modelo cuyo valor no es conocido con certeza, pero puede describirse mediante una distribución de probabilidad, como la demanda, calidad, tiempos, costos etc.

Escenarios: dentro de la programación estocástica el uso del término escenarios define una realización posible de las variables, las cuales capturan diferentes futuros posibles asociados a una cierta probabilidad y parámetros específicos, por lo cual (Birge & Louveaux, 2011) lo definen como una metodología de optimización que incorpora incertidumbre por medio de variables aleatorias y escenarios probabilísticos con el objetivo de minimizar el costo total esperado.

2.5.3 Estudios de investigación de programación estocástica

Grass. (2020), utilizaron un método computacional acelerado en forma de L (descomposición de Benders estocástica), el cual es eficiente para resolver problemas estocásticos de dos etapas en contextos de incertidumbre severa, considerando un lapso de tiempo aceptable ante situaciones de peligro, ocasionados por desastres naturales. Se presenta un método acelerado con la ayuda de un algoritmo especializado de punto interiores (SPIM), para el problema de la ubicación y preposicionamiento de artículos de ayuda humanitaria en desastres como huracanes, manejando distintos escenarios (posibles afectaciones) y reduciendo significativamente los tiempos de solución en comparación con algoritmos estándar.

Geng et al. (2021), explican la incertidumbre en el suministro de biodiesel utilizando aceite de cocina usado (WCO), como un factor clave, por medio del desarrollo de un modelo de programación estocástica de dos etapas, que determine la ubicación óptima de los centros de pretratamiento del aceite residual, considerando distintos escenarios bajo la variable estocástica de suministro, integrando la sostenibilidad ambiental y económica, logrando así una cadena de suministro sostenible y resiliente a la par de optimizar costos.

Correia et al. (2018) abordaron la problemática de ubicación de centros de asignación múltiple con capacidad multiperiodo y estocásticos para desarrollar un modelo avanzado de centros logísticos (hubs), considerando a la demanda como una variable estocástica a lo largo del tiempo. Con capacidad limitada y de asignación múltiple de flujos, su propuesta se centra en un marco de programación de dos etapas, con un conjunto de desigualdades válidas para mejorar la solución computacional usando programación lineal entera mixta.

Correia & Melo (2021), propusieron dos modelos de programación estocástica de dos etapas para un problema de localización de instalaciones con planificación dinámica de capacidades, en múltiples periodos de tiempo para distintos segmentos de clientes considerando incertidumbre en la demanda, se plantean dos marcos diferentes para la toma de decisiones de capacidad. Asignando en el primer modelo decisiones

relacionadas con la escalabilidad de la capacidad como de primera etapa y en el segundo modelo estas capacidades se asignan a la segunda etapa, demostrando mediante simulaciones que la segunda etapa es más eficiente y flexible bajo incertidumbre.

Askarifard et al. (2021), analizaron la integración de aspectos de sostenibilidad para la programación de proyectos, para el cual se propone un modelo matemático de optimización robusta multiobjetivo, con el método de restricción ϵ , considerando factores sociales, ambientales, de riesgo y económicos bajo incertidumbre. Generando varios escenarios para determinar con mayor precisión los parámetros de sensibilidad y la generación de soluciones basadas en Pareto y un diseño de experimentos que brinda resultados de acuerdo a parámetros de niveles óptimos logrando generar soluciones con mayor variedad.

Salari et al. (2022), evaluaron la efectividad de la programación estocástica (SP) para abordar problemas de toma de decisiones en logística humanitaria bajo incertidumbre, en donde las condiciones climatológicas, desastres o accidentes afectan la red logística, la demanda y magnitud. Propusieron un modelo matemático bi-nivel y estocástico enfocado a problemas de reabastecimiento multi-comodidad (multi-commodity rebalancing) priorizando la equidad en la distribución de bienes mediante escenarios discretos estocásticos.

Koutsokosta & Katsavounis (2020), desarrollaron un modelo dinámico de programación lineal entera mixta (MILP), utilizando herramientas como el premium solver y Gurobi, para gestionar los costos operativos totales de una cadena de suministro de tres niveles en el área de la construcción. Considerando a los centros de suministro (proveedores), centros de procesamiento (plantas) y sitios de construcción, manejando múltiples ubicaciones y múltiples productos en variados periodos de tiempo, con lo cual se genera una fluctuante complejidad que lo asemeja de mejor forma a un entorno real y típico de la construcción.

Dowson (2020), extendieron el algoritmo tradicional SDDP (Stochastic Dual Dynamic Programming), el cual es útil para resolver problemas estocásticos multietapa con horizonte finito e introduce el uso de "policy graph" (estructuras gráficas), la cual

genera una representación de cómo se originan las decisiones y estados a través del tiempo bajo incertidumbre. Lo aplican en un problema de ganadería lechera demostrando que logra superar los efectos negativos del horizonte finito, al modelar sistemas complejos de redes logísticas.

Lagzaie & Hamzehee (2022), presentaron un modelo matemático de programación lineal entera mixta (MILP) para gestionar una cadena de suministro verde de ciclo cerrado (closed-loop green supply chain) con un entorno de incertidumbre, aplicándolo en una industria multiobjetivo, multiproducto y multiperíodo, combinando el método de Torabi y Hassini (TH) que convierte variables inciertas en formas deterministas, para encontrar la solución óptima que reditué en aumentar la rentabilidad y al mismo tiempo causar un menor impacto ambiental.

Mohammed & Ali (2024), centraron su investigación en proponer un modelo de programación estocástica de dos etapas, para asignar las dimensiones óptimas de sistemas híbridos de energía renovable, que enfrente eficazmente los retos derivados de la incertidumbre y variabilidad que las caracterizan. Para lo cual se utilizan escenarios estocásticos que modelen esta variabilidad con un ahorro del 8.16% de costos y ahorro de tiempo en comparación con la cobertura progresiva, superando así métodos como el monte Carlo.

Krenek. (2022) abordaron un enfoque de bandas de resguardo (guard bands) para modelar un proceso de manufactura bajo incertidumbre, con un programa estocástico de dos etapas para la optimización de tolerancias, considerando la incertidumbre del mercado y los procesos de fabricación a través de un modelo no lineal con restricciones de oportunidad (chance constraints). Así como la técnica de Sample Average Approximation (SAA) que aborda la variabilidad de las condiciones usando JuMP (Julia for mathematical Programming) y CPLEX para la solución del modelo de optimización.

2.6. Single Commodity Two Echelon (SCTE)

El modelo Single Commodity Two Echelon constituye un enfoque para el análisis y optimización de redes logísticas, al poder representar sistemas de distribución de dos niveles con un solo tipo de producto, y poder entenderlo por medio de sus antecedentes, así como sus principales características y conocer algunos estudios relevantes para comprender su estructura y aplicación.

2.6.1 Antecedentes de SCTE

El termino SCTE (Single Commodity Two Echelon), surge debido a la falta de complejidad real en los enfoques tradicionales, principalmente modelos matemáticos clásicos, los cuales en su mayoría asumen entornos estáticos e ideales, delimitando la capacidad de respuesta, lo que restringe su aplicabilidad en contextos caracterizados por alta variabilidad, recursos limitados e incertidumbre.

Dentro de este enfoque se estudia la distribución de un producto, donde los primeros estudios formales de la literatura de localización de instalaciones y distribución se busca minimizar los costos logísticos por medio de la decisión de apertura, operación, manejo y transporte. Evolucionando de esta manera entre los años 80 y 90 hacia una formulación de dos escalones, permitiendo así analizar con mayor precisión los efectos de la capacidad, demanda, calidad, tiempos y costos, para posteriormente agregar la variabilidad dentro de parámetros claves del sistema.

Estas características lo convierten en una herramienta útil para resolver problemas complejos, como lo es diseñar una red logística bajo incertidumbre, mejorar procesos y optimizar problemas con varias variables al mismo tiempo, es así como este enfoque considera diversas herramientas computacionales y analíticas que permiten representar con mayor precisión la complejidad. Como lo es la programación matemática que permite optimizar decisiones bajo restricciones; los modelos estocásticos, que integran la incertidumbre en variables clave como la demanda, el tiempo o los costos; la simulación, utilizada para modelar el comportamiento dinámico de los sistemas y en los últimos años

la Inteligencia artificial (IA) ha crecido de manera exponencial, ofreciendo nuevas posibilidades para el análisis predictivo y una toma de decisiones adaptativa

Gracias a esta integración de herramientas, esta metodología es aplicable en una amplia gama de sectores desde el ámbito educativo, donde ha servido para rediseñar procesos de enseñanza-aprendizaje y gestión académica, así como la mejora de redes de producción, distribución y asignación de recursos en sectores industriales, logísticos y de salud.

2.6.2 Definiciones importantes sobre SCTE

Se define a SCTE como a un sistema logístico de dos escalones de un solo producto, el primer nivel formado por plantas y el segundo nivel por almacenes, centros de distribución o cliente final, con la finalidad de minimizar los costos totales por medio de determinar capacidades, aperturas o cantidades a enviar de la cadena de suministro.

Dentro de este contexto el termino diseño de redes logísticas toma gran relevancia para entender el concepto principal, ya que se refiere al proceso de optimización que determina la estructura física (ubicación de instalaciones) y operativa (rutas, flujos y capacidades) de una cadena de suministro.

2.6.3 Estudios de investigación

Dellaert et al. (2021) propusieron un modelo matemático exacto, manejando múltiples productos únicos y ventanas de tiempo para la entrega, en un problema de ruteo de vehículos con capacidad limitada en una red de dos escalones (ejes logísticos), denominado MC-2E-VRPTW (Multi-Commodity Two-Echelon Vehicle Routing Problem with Time Windows). Para el cual evalúan diferentes formulaciones matemáticas, modelo basado en arcos (MC2E-2^a), modelo de tres caminos o rutas (MC2E-3P), modelo

combinado de arcos y caminos (MC2E-A-P) y un modelo de dos caminos optimizado (MC2E-2P), considerando la eficiencia y rendimiento de cada uno.

Zehtabian (2024), abordaron restricciones de equidad en una cadena de suministro cortas de productos agroalimentarios frescos basado en un modelo de enteros mixto (MIP) para un problema de distribución de múltiples productos en una red de dos niveles (dos escalones). Desarrollando una combinación de heurística y programación matemática (matheurística), así como el coeficiente de Gini y el índice de rango relativo para implementar las medidas de equidad, dada la complejidad del problema planteado, ofreciendo una estrategia efectiva para equilibrar los costos y la justicia en las operaciones de una red logística.

Petris et al. (2024), analizaron un enfoque innovador sustentado en un algoritmo Branch-Price-and-Cut (BPC) para un problema de distribución y asignación de múltiples productos en redes de dos niveles conocido como Multi-Commodity Two-Echelon Distribution Problem (MC2DP). Asignando restricciones de capacidad y costos apoyándose en el set covering problema (SCP), para elegir las rutas que cubran el mayor número de demandas y técnicas de generación de columnas y para reducir la complejidad del problema se usaron relajaciones ng-path y un enfoque heurístico para agilizar el rendimiento en situaciones reales, demostrando una eficacia de resolver 439 de 736 instancias de manera óptima y un desfase del 2.1% en casos no óptimos.

Escobar-Vargas et al. (s/f), desarrollaron una metaheurística basada en el método de hedging progresivo (Progressive Hedging) para resolver un problema de localización-ruteo multicommodity de dos niveles (2E-MLRPSCD) considerando a la demanda como variable aleatoria y correlacionadas con decisiones de asignación de origen-destino (OD), implementada con estrategia de selección de escenarios y asignación de reinicio para evitar óptimos locales, demostrando su capacidad para resolver y modelar de manera efectiva problemas reales

Zhou et al. (2024), plantearon un modelo de optimización del problema de localización y ruteo (LRP) en la industria agrícola en la cual se maneja producto perecedero, el cual incluye restricciones como ventanas de tiempo para servicio,

capacidad de almacenamiento en congeladores y cuidado de estado de producto en cuestión de frescura. Diseñan un modelo matemático con la ayuda de un algoritmo híbrido de optimización basado en ballenas (Hybrid Whale Optimization Algorithm-HWOA) anexando la mutación genética y el cruce para optimizar la eficiencia de búsqueda, en un entorno de demanda dispersa e incertidumbre logística.

Fontem & Price. (2021), modelaron el problema de seleccionar clientes sobre el diseño de contratos de opciones de una cadena de suministro de dos niveles, por medio de programación bi-nivel no lineal entera mixta (MINLP), considerando a un intermediario (bróker) el cual es la entidad entre fabricantes y proveedores y crear un escudo ante fluctuaciones inesperados del cambio del precio, creando un activador de precio (trigger Price) el cual funge como techo de costo, con datos reales del mercado del petróleo (WTI) por medio de la simulación.

Tirkolaei et al. (2023), abordaron un problema jerárquico de localización-asignación-ruteo (2EH-LARP) NP-hard, en sistemas logísticos jerárquicos, considerando criterios de sostenibilidad y interrupciones en almacenes, en una red de dos niveles con múltiples productos por medio de GWO (Algoritmos de optimización de lobo Gris y PSO (Optimización de Enjambre de Partículas), integrando un diseño de cadenas de suministro bajo incertidumbre.

Li et al. (2025), analizaron el problema de enrutamiento furgoneta-robot de dos niveles con SS (2ERP-SS), definiendo espacios temporales llamados satélite compartidos en la acera (SS) en donde se transbordan cargas entre vans y robots en zonas urbanas densas para abordar el uso de espacio limitado. Por medio de un modelo MILP (Mixed Integer Linear Programming) y proponen los siguientes algoritmos: búsqueda adaptativa en vecindario amplio (ALNS) y beam search con búsqueda en vecindario amplio (b-LNS), para resolver el problema que aborde de manera eficaz la gestión de operaciones logísticas en la cadena de suministro.

Parichehreh & Javadian (2020), ofrecen un modelo matemático para el diseño de una red de cadena de suministro postal de 4 niveles, aplicando la programación entera mixta (MIP), el enfoque que se aborda es determinista, ya que la demanda es sumida

como conocida y no fluctuante. La red propuesta busca la ubicación óptima de los centros de distribución y el número de paquetes que se envíen entre nodos, el cual se resuelve con el uso del software LINGO 17, y se presenta un análisis de sensibilidad de las capacidades de los centros de distribución y el cambio en las cantidades iniciales de los paquetes.

Rahbari et al. (2025), Analizan la incertidumbre en la demanda en una cadena de suministro agroalimentaria de ciclo cerrado (closed-loop), con un modelo multiobjetivo de programación estocástica robusta, por medio de escenarios, incluyendo restricciones de tipo chance-constrained, la cual sirve para moldear variables estocásticas que influyen en la producción, la logística inversa y el retorno. Generando múltiples escenarios y resultados con mayor confianza ante fluctuaciones inciertas. Incorporan el mecanismo cap and trade y un ciclo completo que incluye estaciones como la logística inversa, generando una visión integral del flujo de trabajo y generando un análisis de sensibilidad que permite medir la estabilidad de resultados clave ante diferentes cambios.

2.7. Comparación metodológica del enfoque propuesto frente a métodos alternativos

Existen diversas metodologías en la literatura para abordar problemas de localización y asignación sobre el diseño de redes logísticas bajo incertidumbre, cada una difiere de la forma en que se representa la incertidumbre, el nivel de rigor matemático y el tipo de solución que genera.

En relación a la incertidumbre, se pueden distinguir enfoques con probabilidades (estocásticos), enfoques sin probabilidades (robustos), optimización distribucionalmente robusta (DRO) y enfoques alternativos (modelos difusos y basados en intervalos). Los enfoques estocásticos usan información histórica o estimaciones estadísticas confiables y modelan la incertidumbre mediante distribuciones de probabilidad y escenarios, en esta categoría se encuentra la programación estocástica, la cual puede formularse en múltiples variantes, como los modelos multi-etapa, restricciones probabilísticas (chance constraints) y aproximaciones mediante muestreo (Sample Average Approximation, SAA). Es así que la programación estocástica en dos etapas, permite distinguir entre

decisiones estratégicas de diseño de la red logística (como lo es la ubicación y capacidad de instalaciones), tomadas en la primer etapa y decisiones operativas de asignación de flujos que se ajustan en la segunda etapa (al revelar la incertidumbre), lo que genera una forma realista del proceso de toma de decisiones en sistemas logísticos y a la vez permite optimizar el costo esperado del sistema.

De igual manera, en los enfoques con probabilidad se encuentra la simulación-optimización, cuyo principal objetivo es la evaluación del desempeño de configuraciones predefinidas del sistema, pero no garantiza soluciones óptimas ni una formulación matemática explícita, haciéndola menos efectiva cuando se busca analizar formalmente el impacto de la incertidumbre en decisiones estratégicas y operativas.

Por otro lado los enfoques sin probabilidad, modelan la incertidumbre mediante conjuntos de variación y buscan soluciones factibles ante el peor de los casos posibles, lo que genera un aumento en la confiabilidad del sistema, por lo que tiende a generar soluciones conservadoras con mayores costos totales, es así que la programación robusta no es una opción eficiente desde el punto de vista económico, ya que se tiene la información suficiente para representar la incertidumbre mediante escenarios probabilísticos.

Un enfoque intermedio entre la programación estocástica y la robusta es la optimización distribucionalmente robusta (DRO), ya que considera conjuntos de distribuciones posibles en lugar de una distribución única, lo que ofrece una protección adicional frente a errores de estimación de probabilidad, pero genera una complejidad computacional mayor lo que lo hace menos apropiado para el alcance del presente estudio.

A si mismo enfoques alternativos, como los modelos basados en lógica difusa (Fuzzy) o intervalos, representan a la incertidumbre de manera subjetiva o cualitativa, por lo que son útiles cuando no se dispone de información cuantificable.

Por otro lado, la metaheurística tiene capacidad para resolver problemas de localización logística de gran escala, tales como la búsqueda tabú, el recocido simulado y los algoritmos genéticos, los cuales tienen la característica de explorar un espacio de

soluciones mediante reglas heurísticas, con el objetivo de encontrar soluciones de buena calidad en un tiempo computacional razonable.

Este tipo de enfoque es útil en métodos computacionalmente inviables, dichos métodos corresponden principalmente a técnicas de solución empleadas en modelos deterministas de gran escala y cuyos resultados no tienen una garantía de optimalidad, ya que depende de parámetros de calibración y diseño del algoritmo, dificultando una comparación objetiva entre diferentes soluciones, lo que representa un problema ya que se busca evaluar de manera formal el impacto de la incertidumbre en la demanda y calidad del producto, por lo que se centra en enfoques de optimización bajo incertidumbre, descartando el uso exclusivo de modelos deterministas clásicos.

Finalmente, dentro de esta área se encuentran métodos de solución tales como los solvers exactos para modelos MILP, métodos de descomposición (Benders o L-shaped), metaheurísticas que constituyen herramientas computacionales para resolver los problemas formulados. Dentro de este trabajo se formula un problema de tamaño tratable y cuyo objetivo es localizar una solución óptima a diferencia de la metaheurística que generalmente se emplea en modelos deterministas a gran escala.

Tabla 1. Comparación metodológica del enfoque propuesto frente a métodos alternativos

| Enfoque metodológico | Forma de modelar la incertidumbre | Tipo de decisiones que manejan | Solución óptima | Principal ventaja | Limitaciones clave | Adecuación al problema SCTE |
|---|---|---------------------------------------|------------------------|------------------------------------|---|------------------------------------|
| Modelo determinista (MILP clásico) | No considera incertidumbre | Operativa y estratégica | sí | Formulación simple y exacta | Soluciones poco realistas ante variabilidad | Baja |
| Simulación-optimización | Escenarios simulados sin optimización explícita | Principalmente operativas | No | Permite evaluar sistemas complejos | No optimiza ni formula explícitamente el problema | Baja |
| Metaheurísticas (GA, PSO, GWO, WOA, etc.) | Implícita o no considera | Estratégicas y operativas | No | Maneja problemas de gran escala | No garantiza optimalidad ni rigor matemático | Media |
| Programación robusta | Conjuntos de incertidumbre | Estratégicas y operativas | Si | Alta confiabilidad | Soluciones conservadoras y costosas | Media |

| | | | | | | |
|--|--|--|---------------------|--|--|-------|
| Optimización distribucionalmente robusta (DRO) | e (peor caso) Conjunto de distribuciones plausibles | Estratégicas y operativas | Si | Protección ante errores de distribución | Alta complejidad computacional | Media |
| Fuzzy / intervalos | Incertidumbre cualitativa o subjetiva | Estratégicas y operativas | No necesariamente | Útil sin datos cuantificables | Difícil comparación con modelos clásicos | Baja |
| Programación estocástica de dos etapas | Escenarios probabilísticos | Estratégicas (1° etapa), y operativas (2° etapa) | Si (valor esperado) | Representación realista de la incertidumbre, formulación rigurosa y comparación con SCTE clásico | Mayor esfuerzo computacional | alta |

Por lo tanto, aunque la literatura reporta un uso predominante de algoritmos híbridos y metaheurísticas para resolver problemas de localización y ruteo de dos niveles, gran mayoría de ellos corresponden principalmente a técnicas de solución empleadas en modelos deterministas de gran escala y el presente trabajo adopta un enfoque de programación estocástica de dos etapas ya que se cuenta con una formulación matemática explícita que facilita el análisis, así como la presencia de incertidumbre cuantificable en la demanda y calidad del producto lo que permite modelar explícitamente la incertidumbre mediante escenarios probabilísticos y obtener soluciones óptimas; que ayuden a la comparación y justificación de resultados.

3. CAPITULO 3. METODOLOGIA

Dentro de este capítulo se explica la metodología usada para la presente investigación, el cual se basa en el desarrollo de un modelo de optimización estocástica aplicada a una red logística de dos niveles bajo incertidumbre: se asigna a la demanda de los clientes una distribución normal con media μ y desviación estándar σ y en la calidad de la producción se utiliza una distribución beta con parámetros a y b . Se desarrolla en dos escalones logísticos el primero es de plantas de producción a centros de distribución y el segundo de los centros de distribución a los clientes. Se aborda en dos etapas bajo incertidumbre, donde la primera etapa se toma la decisión de que centros de distribución instalar (antes de conocer la demanda y calidad) y en la segunda etapa, se determina cuánto enviar desde cada planta al centro de distribución y al cliente. Se aborda el proceso de investigación de acuerdo a las siguientes etapas:

3.1. Tipo

La presente tesis pertenece al enfoque cuantitativo, ya que, dentro de los enfoques de investigación existente, este trabajo aborda técnicas matemáticas y computacionales que sirven de herramienta para analizar los datos simulados que buscan generar soluciones óptimas.

Se aborda el uso de un modelo matemático y análisis computacional con ayuda del software LINGO, permitiendo evaluar la incertidumbre dentro del problema por medio de técnicas de programación estocástica, ya que a través del muestreo de escenarios se obtienen soluciones robustas, que permite analizar las relaciones entre las variables independientes y lograr mayor efectividad y optimización de los parámetros requeridos.

3.2. Nivel

Esta investigación se puede clasificar dentro de distintos niveles, el primero siendo un estudio de nivel exploratorio, ya que se analiza a las variables de demanda y calidad dentro de un contexto de incertidumbre lo cual es considerado como un enfoque poco abordado, dentro de una estructura de dos escalones para un producto.

De igual manera posee un nivel descriptivo, ya que cuantifica la variación y comportamiento de los principales elementos del sistema (plantas, centros de distribución y clientes), bajo condiciones de diferentes escenarios.

Finalmente entraría en un estudio de tipo correlacional, por el hecho de que evalúa y analiza el impacto que tienen ciertas variables, como la calidad de los productos bajo cierta probabilidad y restricciones, así como la capacidad de producción, y como esto afecta y se relaciona con el cumplimiento de la demanda y el costo total del sistema.

3.3. Diseño

El diseño de esta investigación de acuerdo a su temporalidad, es de origen retrospectiva, ya que la información en la cual se basa es de origen hipotético, y de datos de diferentes modelos que se han estudiado al pasar de los años ya que debido a la complejidad de estos temas se dificulta la obtención de datos e información. Respecto a su evolución, se puede manejar un diseño transversal ya que se evalúa bajo solo un momento de incertidumbre del presente modelo. Y por último se considera un diseño observacional ya que no presenta una interacción directa del investigador con el fenómeno, ya que no se manipulan de forma directa las variables dentro del entorno físico. este análisis se sustenta por medio de la evaluación de diferentes escenarios.

3.4. Preparación de los datos de entrada

De acuerdo al modelo propuesto, se formuló un conjunto de datos que representen de una forma realista una red logística de distribución de dos niveles en base a una red logística de prueba, se asignaron datos iniciales para alimentar el modelo, los cuales

están compuestos por 3 entidades, las cuales se plantean en plantas de producción, centros de distribución y clientes. Los datos utilizados para alimentar el modelo se dividieron en dos categorías ya que se consideran datos aleatorios y deterministas, explicados en la tabla 1:

Tabla 2. Principales datos aleatorios y deterministas

| Datos deterministas | | Datos aleatorios | |
|---|-----------|-----------------------------------|------------------------|
| Capacidad máxima de producción por planta | o_i | Demanda de los clientes | $D(\alpha_i, \beta_i)$ |
| Capacidad máxima de almacenamiento de cada centro de distribución | q_j | Proporción de productos conformes | p_i^ω |
| Costos fijos asociados a la instalación y operación de silos | f_j | | |
| Costos unitarios de transporte en cada ruta desde el vector planta-centro de distribución-cliente | a_{ijr} | | |
| Costos de productos defectuosos | cd_i | | |

Los datos deterministas son considerados valores que se conocen y estos son en cierto punto constantes y fijos a lo largo del tiempo, ya que no presentan incertidumbre ni variabilidad, en cada escenario el valor será el mismo, generalmente estos datos son obtenidos por medio de base de datos o toma de medidas, estándares técnicos o supuestos por medio de experiencia. Los datos aleatorios o también llamados estocásticos son datos los cuales están sujetos a una variación o incertidumbre ya que su valor puede variar dependiendo factores que no se pueden controlar, las cuales son asignadas por medio de distribuciones de probabilidad.

3.5. Desarrollo del modelo

El modelo representa un problema de Single-Commodity Two-Echelon Network (SCTE), el cual tiene como objetivo minimizar el costo total del sistema logístico, en este caso maneja costos de transporte, del vector planta-centro de distribución-cliente, costos de defectos por productos no conformes, el cual aborda proporciones aleatorias que representan la incertidumbre y costos de operación de silos. De igual manera se manejan variables de decisión las cuales se representan por la cantidad enviada desde cada planta al vector cliente y una variable binaria que deduce si se abre o no un silo, todo el modelo se rige bajo restricciones de disponibilidad de producción de cada planta. Ya que no se puede enviar más de lo que se produce, y una demanda de clientes, la cual se requiere satisfacer al 100% la demanda de cada cliente, propiciando de esta manera un entorno más apegado a la realidad logística de empresas actuales, brindando una herramienta útil en diversas áreas de este sector y a la literatura actual que incluya variables con incertidumbre.

3.6. Verificación y validación

Los datos del modelo se verificaron de acuerdo a una coherencia dimensional, e decir se aseguró que las cantidades y límites de capacidad sean consistentes, esto se logró durante varias pruebas con un número de nodos y escenarios que pudieran reflejar coherencia del correcto funcionamiento y de la factibilidad del modelo. Así como depurar errores lógicos o de sintaxis dándole seguimiento a los reportes de LINGO, y asegurando el cumplimiento de demandas flujos entre los distintos niveles de la cadena logística.

La validación se calificó de acuerdo a que el modelo emule adecuadamente la lógica de una red logística de dos niveles bajo incertidumbre, ya que una gran ayuda es que anteriormente se trabajó con modelos deterministas. Lo cual ofreció una versión estática permitiendo comparar los resultados obtenidos con la fluctuación contra un modelo estocástico, así como un análisis del comportamiento ante distintos tamaños de muestra en distintas variables clave

3.7. Análisis de sensibilidad e interpretación

El análisis del modelo se evalúa con base en los resultados del modelo estocástico de dos etapas, el cual se analiza bajo diferentes escenarios y valores comparando el costo total de cada uno bajo ciertos parámetros y como impacta en las decisiones logísticas y su eficiencia. La información se presenta por medio de tablas comparativas que simplifiquen la información para poder observar el comportamiento desde una perspectiva global y simplificada.

Dentro de las tablas propuestas se incluye una comparación entre el modelo determinista, el modelo estocástico y su equivalente modelo determinista expandido por escenarios, así como indicadores que miden el desempeño del modelo en cuanto a su eficiencia con indicadores como el número de iteraciones, tipo de solución alcanzada y el tiempo de cómputo. Además de mostrar un análisis de resultados en donde se muestran distintos escenarios y como analizan la selección de apertura de cada silo, así como la cantidad asignada de demanda de las granjas y como impacta la variación de las variables estocásticas, lo cual permite ver cómo se distribuye la carga y determinar el rendimiento del sistema, e identificar como afectan las variaciones propuestas, en que grado impactan.

4. CAPITULO 4. DISEÑO DE REDES LOGISTICAS DE DOS NIVELES, CONSIDERANDO INCERTIDUMBRE EN LA DEMANDA Y CALIDAD EN LA PRODUCCIÓN

4.1. Contexto

Los cambios constantes que se presentan en el mercado actualmente requieren de agilidad y eficiencia de los distintos sistemas logísticos para afrontar la incertidumbre inherente de los procesos, ya que si no se consideran adecuadamente pueden provocar ineficiencias operativas, sobrecapacidad o falta de capacidad, costos elevados, pérdida de ventas o saturación de líneas, provocando pérdida de rentabilidad y competitividad. Sin embargo, muchos modelos de optimización logística aún se construyen bajo supuestos deterministas que no reflejan las condiciones cambiantes del entorno real.

Es por ello que las empresas requieren herramientas que permitan brindarles panoramas reales y medibles en cuanto a diferentes parámetros de análisis, por lo cual abordamos uno de los principales enfoques del diseño redes logísticas con el modelo Single-Commodity-Two-Echelon (SCTE), que estructura la cadena en dos niveles: plantas de producción, centros de distribución (silos) y clientes. El cual incorpora simultáneamente la incertidumbre en la demanda de los clientes y en la proporción de productos conformes (calidad), lo cual incrementa la complejidad en la optimización del diseño de redes y una mejor toma de decisiones estratégicas. De igual manera se propone aportar a la literatura estocástica la cual con frecuencia es abordada con modelos deterministas, bajo este contexto el modelo se evaluará con el software de optimización el cual permite analizar distintos escenarios generados a partir de distribuciones de probabilidad de la demanda y calidad. Mostrando de manera cuantitativa la precisión de las decisiones sobre asignación de flujos y activación de centros de distribución y de esta manera ofrecer herramientas robustas y adaptativas al entorno actual.




Figura 1. Estructura de la red logística bajo estudio

La Figura 1 representa la red logística de dos escalones analizada en este estudio, correspondiente al modelo SCTE, integrada por 2 plantas, 6 centros de distribución y 7 clientes, las conexiones entre los nodos representan las posibles rutas de transporte dentro de la red; estas conexiones únicamente están indicadas para mostrar la existencia de comunicación entre los elementos de cada nivel jerárquico. Sin definir de manera previa una ruta específica, ya que el modelo es el encargado de asignar la ruta idónea, considerando las restricciones operativas establecidas.

Asimismo, la red incorpora la incertidumbre asociada a la demanda de los clientes y a la calidad del producto, las cuales se modelan mediante distribuciones probabilísticas, que permiten evaluar las decisiones de localización, asignación y flujo bajo distintos escenarios posibles, reflejando de manera más realista el comportamiento de un sistema logístico.

4.2. Modelo determinista para redes logísticas de dos escalones

El punto de partida para el análisis y formulación del modelo bajo incertidumbre desarrollado, se basa en un modelo determinista el cual representa una red de distribución de dos escalones para un solo producto, considerando los tres niveles siguientes: 7 clientes, 6 centros de distribución y 2 plantas, para el cual se lleva una lógica similar al definir conjuntos de variables de decisión, así como restricciones de apertura de centros de distribución por medio de variables binarias. Se consideran costos de transporte, costos fijos de instalación de los centros de distribución y costos variables de operación, bajo restricciones de demanda determinada de cada cliente, capacidad máxima de almacenamiento de los centros de distribución y respetar límite de capacidad de cada planta, el objetivo es minimizar el costo total de la red logística

En la siguiente etapa del estudio se incorporan 2 variables estocásticas, ya que en el modelo determinista la demanda de los clientes, la capacidad de los centros de distribución y los costos logísticos son conocidos y no fluctúan, lo cual no refleja adecuadamente un entorno real, es por ello que se considera en este estudio como afecta los factores inciertos

4.3. Modelo determinista

La formulación del modelo determinista para redes logísticas de dos escalones se define con la siguiente notación:

Parámetros

A) Conjuntos

I : conjunto de plantas de manufactura, indexado por $i \in I$

J : Conjunto de centros de distribución, indexado por $j \in J$.

R : Conjunto de clientes, indexado por r , donde $r \in R$

B) Parámetros

Demanda y capacidad

d_r : Demanda determinada en el cliente r .

o_i : Capacidad máxima de la planta i .

q_j : Capacidad máxima del centro de distribución j .

C) Costos

a_{ijr} : costo unitario de transporte desde la planta i , pasando por el centro de distribución j , hasta el cliente r .

f_j : Costo fijo de instalación y operación del centro de distribución j .

g_j : Costo marginal de almacenamiento por unidad en el centro de distribución j .

D) Variables de decisión

$y_j \in \{0,1\}$: variable binaria que indica si el centro de distribución j está abierto ($y_j = 1$) o no ($y_j = 0$).

$s_{ijr} \geq 0$: cantidad de producto transportada desde la planta i , pasando por el centro de distribución j , hacia el cliente r .

E) Función objetivo

La función objetivo minimiza el costo total esperado, que incluye costos de transporte, costos fijos de operación, y de instalación:

$$\text{Minimizar } Z = \sum_{i \in I} \sum_{j \in J} \sum_{r \in R} a_{ijr} \cdot s_{ijr} + \sum_{j \in J} \left(f_j \cdot y_j + g_j \cdot \sum_{i \in I} \sum_{r \in R} s_{ijr} \right) \quad (1)$$

En la ecuación 1, el objetivo del modelo determinista de la red logística de dos niveles, es minimizar el costo total del sistema logístico, el cual incluye costos de transporte que indica los gastos necesarios para trasladar el producto desde las plantas, a través de los centros de distribución hasta llegar a los clientes, así como los costos fijos de instalación y operación de los centros de distribución siempre que este se encuentre abierto para recibir el producto y costos variables de almacenamiento que repercute en cada unidad de producto almacenado.

F) Restricciones

- **Restricción de capacidad en las plantas:**

La cantidad enviada desde cada planta i no puede superar su capacidad:

$$\sum_{j \in J} \sum_{r \in R} s_{ijr} \leq o_i, \quad \forall i \in I. \quad (2)$$

- **Restricción de balance de demanda en los clientes:**

La demanda de cada cliente debe ser completamente satisfecha:

$$\sum_{i \in I} \sum_{j \in J} s_{ijr} = d_r, \quad \forall r \in R. \quad (3)$$

- **Restricción de capacidad en los centros de distribución:**

La cantidad manejada por cada centro de distribución no debe superar su capacidad si está abierto.

$$\sum_{i \in I} \sum_{r \in R} s_{ijr} \leq q_j \cdot y_j, \quad \forall j \in J. \quad (4)$$

- **Restricción de binariedad:**

Los centros de distribución deben estar abiertos o cerrados:

$$y_j \in \{0,1\}, \quad \forall j \in J. \quad (5)$$

4.4. Modelo Estocástico

El modelo determinista se modificó para incorporar demanda aleatoria, la cual es modelada por una distribución normal. Además, se consideró la calidad aleatoria, la cual emplea la distribución beta para definir la proporción de producto libre de defecto.

a) Conjunto y subconjuntos

I : conjunto de plantas de manufactura, indexado por $i \in I$

J : Conjunto de centros de distribución, indexado por $j \in J$.

R : Conjunto de clientes, indexado por r , donde $r \in R$

Ω : Espacio de escenarios posibles, indexado por w , donde $w \in \Omega$

b) Parámetros

Demanda y capacidad

D_r^ω : **Demanda aleatoria en el cliente r** bajo el escenario ω , modelada como una distribución normal con parámetros, $D_r^\omega \sim N(\mu_r, \sigma_r^2)$.

o_i : Capacidad máxima de la planta i .

q_j : capacidad máxima del centro de distribución j .

Costos

a_{ijr} : costo unitario de transporte desde la planta i al centro de distribución j y luego al cliente r .

f_j : costo fijo de operación del centro de distribución j .

g_j : costo marginal de almacenamiento por unidad en el centro de distribución j .

cd_i : costo asociado a los defectos en la planta i .

Calidad

p_i^ω : **proporción de productos conformes** en la planta i bajo el escenario ω , modelada como una distribución beta, $p_i^\omega \sim beta(\alpha_i, \beta_i)$.

α_i, β_i : parámetros de la distribución beta para la planta i .

Variables de decisión

$y_j \in \{0,1\}$: variable binaria que indica si el centro de distribución j está abierto ($y_j = 1$) o no ($y_j = 0$).

s_{ijr}^ω : cantidad transportada desde la planta i , pasando por el centro de distribución j , hacia el cliente r bajo el escenario ω .

c) Función objetivo

La función objetivo minimiza el costo total esperado, que incluye costos de transporte, costos fijos de operación, costos de almacenamiento y costos asociados a los defectos:

$$\text{Minimizar: } Z = \mathbb{E}_\omega \sum_{i \in I} \sum_{j \in J} \sum_{r \in R} a_{ijr} \cdot s_{ijr}^\omega + cd_i \cdot (1 - p_i^\omega) \cdot s_{ijr}^\omega + \sum_{j \in J} f_j \cdot y_j + g_j \cdot \sum_{i \in I} \sum_{r \in R} s_{ijr}^\omega \quad (6)$$

d) Restricciones

- **Restricción de capacidad en las plantas:**

La cantidad enviada desde cada planta no puede superar su capacidad:

$$\sum_{j \in J} \sum_{r \in R} s_{ijr}^\omega \leq o_i \cdot p_i^\omega, \forall i \in I, \forall \omega \in \Omega. \quad (7)$$

- **Restricción de balance de demanda en los clientes:**

La demanda de cada cliente debe satisfacerse en cada escenario:

$$\sum_{i \in I} \sum_{j \in J} s_{ijr}^\omega = D_r^\omega, \forall r \in R, \forall \omega \in \Omega. \quad (8)$$

- **Restricción de capacidad en los centros de distribución:**

La cantidad manejada por cada centro de distribución no debe superar su capacidad si está abierto.

$$\sum_{i \in I} \sum_{r \in R} s_{ijr}^\omega \leq q_j \cdot y_j, \forall j \in J, \forall \omega \in \Omega. \quad (9)$$

- **Restricción de binariedad:**

Los centros de distribución deben estar abiertos o cerrados:

$$y_j \in \{0,1\}, \forall_j \in J. \quad (10)$$

- **Restricciones de no anticipación:**

Las decisiones deben ser consistentes para escenarios con las mismas realizaciones de D_r y p_i :

$$s_{ijr}^{\omega_1} = s_{ijr}^{\omega_2}, \quad \forall_i \in I, \forall_j \in J, \forall_r \in R, \forall_{\omega_1, \omega_2} \in \Omega: D_r^{\omega_1} = D_r^{\omega_2}, p_i^{\omega_1} = p_i^{\omega_2} \quad (11)$$

Indicadores clave

El modelo de programación estocástica se complementa con el cálculo de los siguientes indicadores:

- **Porcentaje de demanda satisfecha:**

$$\text{Porcentaje de demanda satisfecha} = \frac{\sum_{i \in I} \sum_{j \in J} \sum_{r \in R} s_{ijr}^{\omega}}{r \in R^{\omega}} \cdot 100, \quad \forall_{\omega} \in \Omega \quad (12)$$

- **Costos por defectos:**

$$\text{Costos por defectos en planta } i = cd_i \cdot (1 - p_i^{\omega}) \cdot \sum_{j \in J} \sum_{r \in R} s_{ijr}^{\omega}, \forall_i \in I, \forall_{\omega} \in \Omega. \quad ..(13)$$

4.5. Materiales y métodos

El objetivo de esta sección es mostrar el enfoque de resolución para el problema propuesto en este trabajo. Enfatizando que el modelo estocástico se formuló considerando dos variables estocásticas: la demanda requerida por cada cliente (distribución normal) y la calidad del producto (distribución beta). Cada distribución permite al sistema incorporar la incertidumbre que posee un entorno operativo y de producción real, por ello su estructura se basa en un enfoque de programación estocástica de dos etapas; la primera contempla las decisiones estratégicas de

asignación y localización, mientras que la segunda ajusta dichas decisiones al revelarse los valores reales de la incertidumbre. Las actividades desarrolladas son las siguientes:

1. Preparación de los datos de entrada: En esta etapa se recopilaron y organizaron los datos necesarios para la construcción del modelo. Se consideraron los parámetros de la demanda aleatoria de los clientes, modelada con una distribución normal, utilizando valores de media y desviación estándar representativos. Calidad de la producción en plantas, expresada como proporción de productos conformes, capacidades de producción y almacenamiento en plantas y silos. Costos fijos, variables y de transporte entre los distintos niveles de la red. Estos datos se integraron a través de hojas de cálculo externas vinculadas al modelo mediante funciones especiales de LINGO.
2. Desarrollo del modelo: Se formuló un modelo de programación estocástica de dos etapas adaptado al problema SCTE (Single-Commodity Two-Echelon), en la primera etapa se determina la selección de centros de distribución, asignación inicial y definición de flujos. En la segunda etapa después de conocer la realización de la demanda y calidad bajo los diversos escenarios generados. Se determina el flujo de materiales de las plantas-centros de distribución-clientes. El modelo fue implementado en LINGO, considerando restricciones de capacidad, asignación y calidad, con el objetivo de minimizar el costo total del sistema logístico.
3. Verificación y validación: Se realizaron pruebas con instancias reducidas para verificar el funcionamiento del modelo y la coherencia de las restricciones. La validación conceptual se llevó a cabo mediante: Comparación de resultados entre la versión determinista y la estocástica, revisión de la consistencia en los patrones de asignación bajo escenarios y evaluación de la lógica de los resultados frente a lo esperado en un sistema logístico real.
4. Análisis de sensibilidad e interpretación: Finalmente, se aplicó un análisis de sensibilidad para examinar cómo variaciones en parámetros clave afectan las decisiones y los costos del sistema. Se modificaron los costos de defectos, capacidades de silos. Además de los parámetros de las distribuciones de demanda y calidad. Esto permitió observar el impacto de la incertidumbre y evaluar la robustez y flexibilidad del modelo, así como su potencial y aplicación práctica.

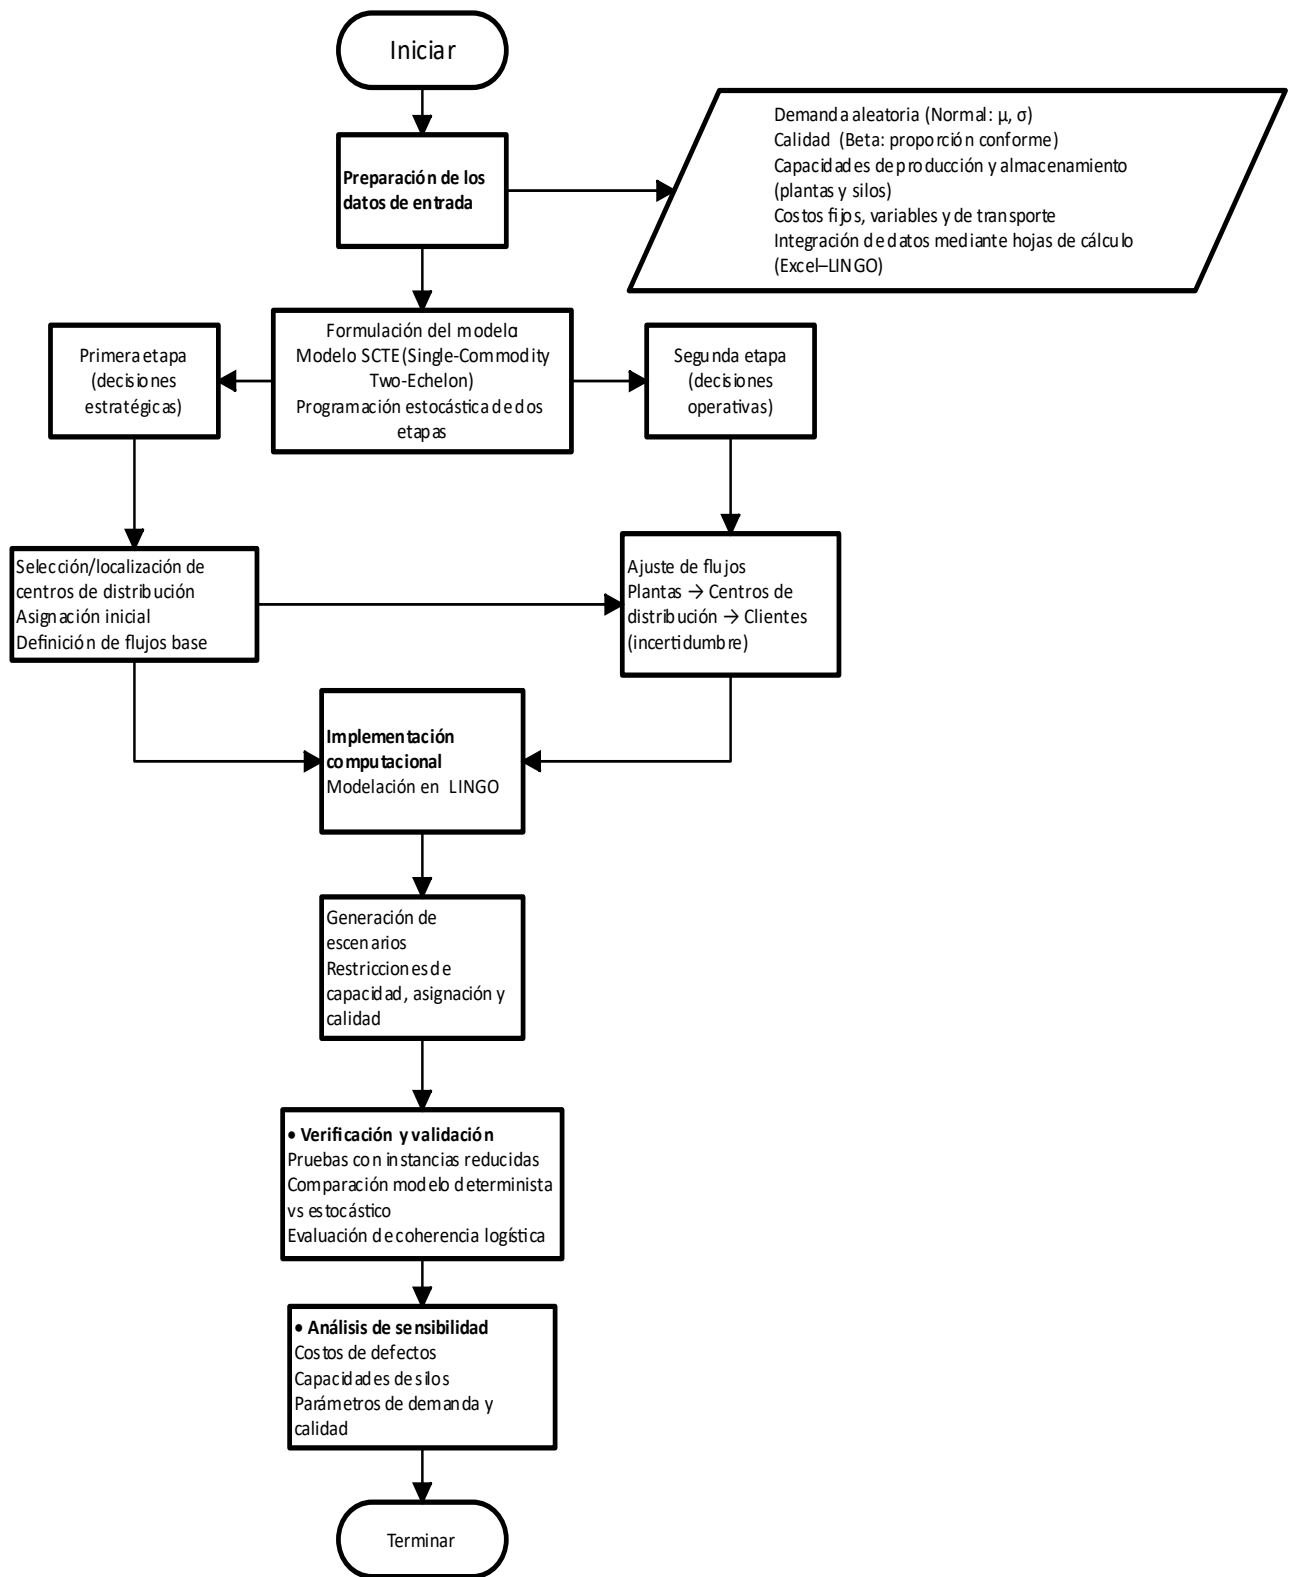


Fig. 2 Diagrama metodológico del modelo estocástico de dos etapas

4.6. Resultados Numéricos

En esta sección se presenta un ejemplo numérico que permite evaluar el comportamiento del modelo determinista frente al modelo estocástico de dos etapas, al incorporar variabilidad en dos elementos claves del sistema (la demanda y la calidad de la producción), lo cual permite visualizar como cambia la solución del modelo al abordar parámetros estocásticos y a su vez permite evaluar el incremento de la complejidad computacional.

El software de optimización desarrolla el modelo determinista equivalente para abordar la variabilidad del modelo, al crear un árbol de escenarios con la construcción de diferentes combinaciones considerando factores de capacidad, costos (transporte, almacenamiento y defectos) que permitan calcular una solución óptima y factible que minimice el costo total del sistema bajo incertidumbre.

Las instancias numéricas se ejecutaron en una computadora Dell Vostro 3400 con un procesador Intel Core i5-1135G7 de 11ª generación, 8 GB de RAM y sistema operativo de 64 bits. El cual es adecuado para resolver este tipo de problemas.

A continuación, se presenta en la Tabla 1, donde se definen los parámetros utilizados en ambos modelos como datos de entrada necesarios para abordar este tipo de problemas.

Tabla 1: Datos para las instancias numéricas

| | | | | | | | | |
|------------------|------------|------------|-----------|-----------|-------|----------|-------|--------|
| Parametro | f_1 | g_j | C_{tra} | C_{d1} | C_d | O_1 | O_2 | q_j |
| Valor | 244.16 | 0.172 | 0.06 | 2 | 2 | 170 | 170 | 103.33 |
| Parametro | σ_1 | σ_2 | β_1 | β_2 | μ | α | | |
| Valor | 50 | 50 | 5 | 5 | 37.43 | 8.04 | | |

El procedimiento descrito permite evaluar varios escenarios, como se muestra en la Tabla 2. qué a medida que aumenta el número de escenarios, también crecen el número de

variables aleatorias y restricciones del modelo determinista equivalente, lo que posibilita analizar cómo se comporta un modelo determinista frente a un modelo estocástico y como crece el tamaño de muestra y la variabilidad. Se observa de manera más clara como el sistema se ajusta a entornos complejos lo que demanda un esfuerzo computacional significativamente mayor, pero ofrece una visión más robusta y realista del desempeño del sistema bajo incertidumbre.

Tabla 2. Comparación del tamaño de los modelos

| Tamaño de muestra | Modelo determinista | | Modelo estocástico de dos etapas | | | | Modelo determinista equivalente | |
|-------------------|---------------------|---------------|----------------------------------|-----------|----------------------|---------------|---------------------------------|---------------|
| | Variables | Restricciones | Numero de escenarios | Variables | Variables aleatorias | Restricciones | Variables | Restricciones |
| 3 | 90 | 16 | 3 | 99 | 9 | 25 | 297 | 85 |
| 4 | 90 | 16 | 4 | 99 | 9 | 25 | 396 | 115 |
| 5 | 90 | 16 | 5 | 99 | 9 | 25 | 495 | 145 |
| 6 | 90 | 16 | 6 | 99 | 9 | 25 | 594 | 175 |

De acuerdo a la Tabla 2, al hacer la comparación entre el modelo determinista, el modelo estocástico de dos etapas y su correspondiente modelo determinista equivalente, al variar el tamaño de la muestra utilizado en las distribuciones de probabilidad de 3 a 6 puntos. Se observa el comportamiento de las variables y restricciones con respecto a cada número de muestra correspondiente, se puede observar como el modelo determinista se mantiene constante en cada escenario con 90 variables y 16 restricciones, no presentan cambios ni alteraciones, debido a que no se incorpora ningún elemento aleatorio, pues se asume una demanda constante para cada cliente y una proporción de defectos fija. Mientras que el modelo estocástico de dos etapas introduce la incertidumbre a través de escenarios. Este modelo estocástico presenta un incremento de 90 variables a 99 variables, ya que se implementan decisiones que dependen de la toma de decisión de las variables aleatorias, las cuales son las encargadas de representar la incertidumbre en parámetros críticos del sistema, como lo es en este caso, los valores de demanda y calidad. El software de optimización se apoya de un modelo determinista equivalente para poder resolver un modelo estocástico, ya que, en lugar de trabajar directamente con incertidumbre, el programa crea una versión extendida del

modelo determinista en la que se representan todos los escenarios posibles, es por esta razón que el número máximo de tamaño de muestra que se pudo utilizar es 6 ya que en el séptimo punto al momento de ejecutar el programa aparece una leyenda de infactibilidad. Es decir que no tiene ninguna solución posible que satisfaga todas las restricciones necesarias del modelo. El tamaño de muestra implica un crecimiento exponencial cuando el valor es 6, pues implica un modelo con 594 variables y 175 restricciones. En la Tabla 2 es claro de observar cómo aumenta el tamaño del modelo determinista equivalente conforme se utilizan más puntos en el tamaño de muestra para determinar los escenarios de las variables aleatorias.

Tabla 3. Comparación entre el modelo determinista y estocástico

| Tamaño de muestra | Tiempo de cómputo (segundos) | | Numero de iteraciones | | Tipo de solución | |
|-------------------|------------------------------|--------------------|-----------------------|--------------------|---------------------|--------------------|
| | Modelo determinista | Modelo estocástico | Modelo determinista | Modelo estocástico | Modelo determinista | Modelo estocástico |
| 3 | 0.07 | 0.39 | 1443 | 3172 | Global optimal | Global optimal |
| 4 | 0.07 | 0.69 | 1443 | 4736 | Global optimal | Global optimal |
| 5 | 0.07 | 0.61 | 1443 | 6735 | Global optimal | Global optimal |
| 6 | 0.07 | 1.27 | 1443 | 9755 | Global optimal | Global optimal |

Siguiendo con la comparación del modelo determinista con el modelo estocástico, la Tabla 3 evalúa el rendimiento computacional, en donde se consideran 3 métricas: tiempo de cómputo, número de iteraciones y el tipo de solución por cada determinado número de tamaño de muestra. Se puede notar que, en el modelo determinista, el tiempo de cómputo permanece constante en .07seg con 1443 iteraciones, en cada uno de los escenarios evaluados, ya que sigue sin afectar ninguna variabilidad en el modelo. Mientras que el modelo estocástico muestra un aumento en el tiempo de ejecución en un inicio de 0.39 seg. en el tamaño de muestra 3 con 3172 iteraciones y cuando el tamaño de muestra es 6, el tiempo aumenta a 1.27 seg, pero en esta ocasión el software realiza 9755 iteraciones en donde el número de iteraciones casi se triplica. Lo cual es lógico con la naturaleza del modelo en donde las variables y restricciones se multiplican por el

número de escenarios generados. Además, en ambos modelos se obtuvieron soluciones óptimas que validan la eficacia del enfoque utilizado, en los rangos de complejidad propuestos.

Tabla 4. Resultados óptimos para los escenarios

| Escenario | Planta de Manufactura | Centro de distribución activado | Clientes | | | | | | | |
|--|--|---------------------------------------|----------|-------|-------|-------|-------|-------|-------|-------|
| | | | 1 | 2 | 3 | 4 | 5 | 6 | 7 | |
| 1 | 1 | 1 | 2.56 | 0 | 34.83 | 0 | 0 | 0 | 0 | |
| | | 5 | 0 | 0 | 7.57 | 53.24 | 39.17 | 0 | 0 | |
| | | 6 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | |
| | 2 | 1 | 1.23 | 0 | 0 | 0 | 0 | 41.37 | 0 | |
| | | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | |
| | | 6 | 22.62 | 39.02 | 0 | 0 | 0 | 0 | 49.44 | |
| | Demanda | | | 26.42 | 39.02 | 42.40 | 53.24 | 39.17 | 41.37 | 49.44 |
| | $p_1 = 0.93$ $p_2 = 0.90$ | | | | | | | | | |
| | 2 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 5 | | | 0 | 0 | 31.31 | 31.96 | 30.57 | 6.14 | 0 | |
| 6 | | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | |
| 2 | | 1 | 48.07 | 0 | 0 | 0 | 0 | 22.20 | 9.72 | |
| | | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | |
| | | 6 | 0 | 32.18 | 0 | 0 | 0 | 0 | 27.09 | |
| Demanda | | | 48.07 | 32.18 | 31.31 | 31.96 | 30.57 | 28.34 | 36.81 | |
| $p_1 = 0.84$ $p_2 = 0.93$ | | | | | | | | | | |
| 3 | | 1 | 1 | 17.23 | 0 | 0 | 0 | 0 | 0 | 0 |
| | 5 | | 0 | 0 | 21.76 | 36.71 | 41.51 | 0 | 0 | |
| | 6 | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | |
| | 2 | 1 | 9.31 | 0 | 16.06 | 0 | 0 | 37.38 | 0 | |
| | | 5 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | |
| | | 6 | 9.69 | 49.12 | 0 | 0 | 0 | 0 | 25.48 | |
| | Demanda | | | 36.24 | 49.12 | 37.83 | 36.71 | 41.51 | 37.38 | 25.48 |
| | $p_1 = 0.90$ $p_2 = 0.86$ | | | | | | | | | |

En la Tabla 4 se presentan los resultados óptimos para 3 escenarios diferentes del modelo estocástico de dos etapas, los cuales se diferencian a partir de diferentes valores de demanda y calidad. Se analizan los siguientes escenarios

ESCENARIO 1: Demanda alta y $p_1 = 0.93$ $p_2 = 0.90$

En este escenario se observa que la planta 1 y 2 envían a través de los centros de distribución 1,5 y 6 con las siguientes asignaciones, la planta 1 tiene 93% de producto conforme y produce cantidades significativas, ya que el cliente 4 recibe 53.2 unidades y el cliente 5 recibe 39.17 de la planta 1. La planta 2 tiene el 90% de producto conforme y abastece al cliente 7 con 49.44 unidades y al cliente 6 con 41.37, cumpliendo en su totalidad las cantidades indicadas para cada cliente. A pesar que la planta 1 tiene una

mejor proporción de producto conforme, la planta 2 envía más producto a los clientes, esto se explica por los costos más bajos debido a la cercanía con los clientes.

ESCENARIO 2: Demanda baja y $p_1 = 0.84$ $p_2 = 0.93$

Las plantas utilizan los mismos centros de distribución 1,5 y 6 como en el escenario 1, pero en este caso se observa que cuando la planta 1 tiene una proporción de producto conforme más baja que la planta 1, el sistema reacciona enviando ms producto a partir de la planta 2 a los clientes, para evitar el costo de producto no conforme.

ESCENARIO 3: Demanda media y $p_1 = 0.90$ $p_2 = 0.86$

En el caso de tener una demanda media y que la planta 2 tenga una menor tasa de producto conforme. El modelo sigue utilizando los centros de distribución 1, 5 y 6 respectivamente en cada planta. En este escenario la planta 2 tiene la menor tasa de producto conforme, sin embargo, al tener una demanda media por parte de los clientes. Se sigue utilizando la planta 2, pues las dos plantas son necesarias para poder satisfacer la demanda de los clientes.

Al variar la tasa de demanda de los clientes y las tasas de producto conforme en las dos plantas se observa claramente en la Tabla 4 que el modelo reacciona de una manera lógica y las decisiones de diseño de la red logística se ajustan de forma de minimizar el costo total de la red.

4.7. Análisis de sensibilidad

En esta sección se presenta un análisis de sensibilidad, donde se estudia la variación de costos y su impacto en parámetros clave del modelo, en la primera fila se presenta el caso base que es el valor utilizando los valores de la Tabla 1 del ejemplo numérico. Posteriormente se evalúan en cada fila el impacto de variar cada costo del modelo con una variación porcentual del más/menos 40% de su valor original. Para el

análisis se analizaron 16 casos diferentes, lo cual permite analizar a detalle el efecto de cada parámetro de costo sobre la solución del modelo. En los casos 1 y 2 se varia el costo fijo de instalación, casos 3 y 4 el costo marginal, caso 5 y 6 costos de transporte por unidad, 7 y 8 costos de defectos de la planta 1, caso 9 y 10 costos de defectos de la planta 2, del caso 11 al 14 capacidad máxima de cada planta y por último caso 15 y 16 la capacidad promedio de silo.

Tabla 5. Variación de costo ideado

| Casos | Parámetro | Variación de costo/parámetro | | | | | | | |
|--------------|-----------|------------------------------|-------|-----------|----------|----------|-------|-------|--------|
| | | f_1 | g_j | C_{tra} | C_{d1} | C_{d2} | O_1 | O_2 | q_j |
| Caso de base | - | 244.16 | 0.172 | 0.06 | 2 | 2 | 170 | 170 | 103.33 |
| Caso 1 | f_1 | 146.50 | 0.172 | 0.06 | 2 | 2 | 170 | 170 | 103.33 |
| Caso 2 | | 341.86 | 0.172 | 0.06 | 2 | 2 | 170 | 170 | 103.33 |
| Caso 3 | g_j | 244.16 | 0.103 | 0.06 | 2 | 2 | 170 | 170 | 103.33 |
| Caso 4 | | 244.16 | 0.240 | 0.06 | 2 | 2 | 170 | 170 | 103.33 |
| Caso 5 | C_{tra} | 244.16 | 0.172 | 0.036 | 2 | 2 | 170 | 170 | 103.33 |
| Caso 6 | | 244.16 | 0.172 | 0.084 | 2 | 2 | 170 | 170 | 103.33 |
| Caso 7 | C_{d1} | 244.16 | 0.172 | 0.06 | 1.20 | 2 | 170 | 170 | 103.33 |
| Caso 8 | | 244.16 | 0.172 | 0.06 | 6 | 2 | 170 | 170 | 103.33 |
| Caso 9 | C_{d2} | 244.16 | 0.172 | 0.06 | 2 | 1.2 | 170 | 170 | 103.33 |
| Caso 10 | | 244.16 | 0.172 | 0.06 | 2 | 7 | 170 | 170 | 103.33 |
| Caso 11 | O_1 | 244.16 | 0.172 | 0.06 | 2 | 2 | 153 | 170 | 103.33 |
| Caso 12 | | 244.16 | 0.172 | 0.06 | 2 | 2 | 400 | 170 | 103.33 |
| Caso 13 | O_2 | 244.16 | 0.172 | 0.06 | 2 | 2 | 170 | 150 | 103.33 |
| Caso 14 | | 244.16 | 0.172 | 0.06 | 2 | 2 | 170 | 400 | 103.33 |
| Caso 15 | q_j | 244.16 | 0.172 | 0.06 | 2 | 2 | 170 | 170 | 62 |
| Caso 16 | | 244.16 | 0.172 | 0.06 | 2 | 2 | 170 | 170 | 145 |

Los resultados del análisis de sensibilidad se presentan en la Tabla 6.

Tabla 6. Sensibilidad Variación de costo

| Casos | Parámetro | | Indicadores clave | | | | | | Activated Silos | Costo total (\$) |
|--------------|-----------|------|-------------------|------------|--------------|--------------|-------------|-------------|-----------------|------------------|
| | | | PD_1 (%) | PD_2 (%) | QCP_1 (\$) | QCP_2 (\$) | TDP_1 (%) | TDP_2 (%) | | |
| Caso de base | - | | 41.79% | 58.20% | 30.92 | 19.41 | 15.46 | 6.96% | 1,5,6 | 1852.96 |
| Caso 1 | f_1 | -40% | 60.06% | 39.93% | 44.44 | 13.31 | 15.46% | 6.96% | 3,5,6 | 1568.51 |
| Caso 2 | | +40% | 41.79% | 58.20% | 30.92 | 19.41 | 15.46% | 6.96% | 1,5,6 | 2128.96 |
| Caso 3 | g_j | -40% | 41.79% | 58.20% | 30.92 | 19.41 | 15.46% | 6.96% | 1,5,6 | 1836.38 |
| Caso 4 | | +40% | 41.79 | 58.20% | 30.92 | 19.41 | 15.46% | 6.96% | 1,5,6 | 1869.53 |
| Caso 5 | C_{tra} | -40% | 41.79 | 58.20 | 30.92 | 19.41 | 15.46% | 6.96% | 1,5,6 | 1425.09 |
| Caso 6 | | +40% | 60.06% | 39.93% | 44.44 | 13.31 | 15.46% | 6.96% | 3,5,6 | 2273.25 |
| Caso 7 | C_{d1} | -40% | 41.79 | 58.20% | 18.55 | 19.41 | 15.46% | 6.96% | 1,5,6 | 1843.17 |

| | | | | | | | | | | |
|----------------|----------|-------|--------|--------|-------|-------|--------|-------|------------|----------|
| Caso 8 | | +300% | 37.7% | 62.27% | 83.75 | 20.76 | 15.46% | 6.96% | 1,5,6 | 1899.39 |
| Caso 9 | C_{d2} | -40% | 41.79% | 58.20% | 30.92 | 11.64 | 15.46% | 6.96% | 1,5,6 | 1841.153 |
| Caso 10 | | +350% | 60.06% | 39.93% | 44.44 | 46.61 | 15.46% | 6.96% | 1,5,6 | 1915.05 |
| Caso 11 | O_1 | -10% | 41.79% | 58.20% | 30.92 | 19.41 | 15.46% | 6.96% | 1,5,6 | 1852.96 |
| Caso 12 | | +235% | 64.52% | 35.47% | 47.74 | 11.83 | 15.46% | 6.96% | 3,5,6 | 1847.76 |
| Caso 13 | O_2 | -10% | 41.79% | 58.20% | 30.92 | 19.41 | 15.46% | 6.96% | 1,5,6 | 1853.51 |
| Caso 14 | | +235% | 41.79% | 58.20% | 30.92 | 19.41 | 15.46% | 6.96% | 1,5,6 | 1852.08 |
| Caso 15 | q_j | -40% | 52.65% | 47.34% | 38.96 | 15.78 | 15.46% | 6.96% | 1, 2,3,5,6 | 2333.81 |
| Caso 16 | | +40% | 58.50% | 41.49% | 43.29 | 13.83 | 15.46% | 6.96% | 5,6 | 1625.28 |

En la Tabla 6 de la sensibilidad de la variación de los costos del modelo, se enfoca en comparar el impacto que generan las variaciones de distintos parámetros de costo sobre los principales indicadores clave como en el costo total del modelo.

La tabla parte del caso base el cual da como resultado un costo total de \$1852.96 con los valores originales de la cual se distribuye la demanda en la planta 1 con un 41.79% y en la planta 2 con un 58.20%, activando los silos 1,5 y 6, con su respectiva tasa de defectos por planta e indicadores de calidad

Se observa que cuando el costo por defectos generados en la planta 1 se incrementa significativamente (caso 8), el modelo responde reduciendo la participación de dicha planta al 37.7% y asignando mayor proporción de la demanda a la planta 2 en un 62.27%. Esto se debe a que, la planta 1 incurre en mayores costos de calidad debido a una mayor proporción de productos defectuosos. Como resultado, el costo total del sistema aumenta, reflejando la penalización por baja calidad.

En el caso 10, cuando el costo de defectos de la planta 2 aumenta 350% se observa que la planta 1 absorbe mayor cantidad de demanda en un 60.06%, mientras que la planta 2 reduce su participación a un 39.93%. Al aumentar el costo de defectos de la planta 2, el costo de calidad de esta planta también aumenta. La tasa de defectos de ambas plantas es similar al caso de base. Se observa además que el costo total de la red logística aumenta cuando se incrementa el costo de los defectos de la planta 2.

Por otro lado, al modificar la capacidad de los centros de distribución q_j , se observa que cuando esta se reduce, el modelo responde activando un mayor número de centros de distribución (por ejemplo, silos 1, 2, 3, 5 y 6). Esto se debe a que una menor capacidad de almacenamiento de los centros de distribución obliga al sistema a distribuir el flujo entre más instalaciones para poder satisfacer la demanda. En cambio,

cuando la capacidad de almacenamiento se incrementa, el modelo prefiere activar solo dos centros de distribución (5 y 6), priorizando aquellos cercanos a las plantas con menor costo de calidad, como en el caso del centro de distribución 5, que favorece la producción desde planta 1, a pesar de su mayor tasa de defectos, siempre que el balance entre calidad y distancia lo permita.

Se concluye que los parámetros con mayor sensibilidad del modelo es la capacidad de silos (q_j), en donde al disminuir su valor base activa 5 silos y el costo total se incrementa. Se observa además que cuando se aumenta su valor base, solo se requieren 2 silos, denotando como influye mucho en el costo. El costo de transporte (C_{tra}), también se observa que es una variable crítica al impactar en el costo total y los costos fijos de apertura que afecta fuertemente las decisiones y en su contraparte con parámetros como los costos marginales de almacenamiento (g_j) y capacidad de las plantas (θ_1, θ_2), que no muestran un impacto relevante en la red, la variación de los costos implica al modelo a adaptarse donde se debe enfocar la gestión de flujo de producto.

El análisis se complementa con el análisis de sensibilidad de la Tabla 7, donde se evalúa la variación de los parámetros de la demanda aleatoria, modificando la media (μ) y la desviación estándar (σ) de la distribución normal utilizada para modelar la demanda aleatoria. La tabla presenta el caso base en donde se tienen valores de $\mu=37$ y $\sigma=8.04$ basado en una demanda promedio y una variabilidad moderada, para estos valores se obtiene un costo total de \$1852.96.

Tabla 7. Sensibilidad de los parámetros aleatorios

| Casos | Parámetros de la demanda aleatoria | | Indicadores clave | | | | | | | Costo Total (\$) |
|---------------------------------------|------------------------------------|-------------|-------------------|--------------|--------------|--------------|---------------|-------------|-----------------|------------------|
| | μ | σ | PD_j (%) | PD_2 (%) | QCP_1 (\$) | QCP_2 (\$) | TDP_1 (%) | TDP_2 (%) | Activated Silos | |
| Caso base | 37 | 8.04 | 41.79 | 58.20 | 30.92 | 19.41 | 15.46% | 6.96 | 1,5,6 | 1852.96 |
| Fluctuación de la desviación estándar | | | | | | | | | | |
| Caso 17 | 37.43 | 4 | 57.32% | 42.67% | 44.44 | 14.91 | 15.46% | 6.96% | 1,3,5 | 1843.73 |
| Caso 18 | 37.43 | 8 | 41.77 | 58.22% | 30.92 | 19.42 | 15.46% | 6.96% | 1,5,6 | 1852.87 |
| Caso 19 | 37.43 | 12 | 60.61% | 39.38% | 42.75 | 12.51 | 15.46% | 6.96% | 3,5,6 | 1872.41 |
| Fluctuación de la media | | | | | | | | | | |
| Caso 20 | 20 | 8.04 | 55.33% | 42.66% | 20.79 | 6.97 | 15.46% | 6.96% | 1,5 | 1066.96 |
| Caso 21 | 30 | 8.04 | 35.92% | 64.07% | 20.80 | 16.72 | 15.46% | 6.96% | 4,6 | 1538.52 |
| Caso 22 | 40 | 8.04 | 55.86% | 44.13% | 44.44 | 15.82 | 15.46% | 6.96% | 3,5,6 | 1945.64 |

Se analizan los casos 17, 18 y 19 en donde varia la desviación estándar de la distribución normal, en el caso 17 con una de desviación estándar de 4 implica menor variabilidad de la demanda, lo que implica pocos cambios notorios en el costo total, pero cambios en los centros de distribución abiertos que en este caso son el 1,3 y 5, la tasa de defectos no se afectada al variar la desviación estándar. Sin embargo, con una menor variabilidad de la demanda la planta 1 participa más en la satisfacción de la demanda pues capta el 57.32%. Al aumentar la desviación estándar de la demanda en el caso 19 se opta por abrir otros centros de distribución (3,5 y 6) reconfigurando la asignación de la demanda entre las plantas 1 y 2.

En la segunda sección se analiza la variación de la media de la demanda, manteniendo en su valor base la desviación estándar. En este caso se observa un cambio notorio del caso 20 al caso 22. Más específicamente cuando la media es 20 en el caso 20 se tiene menor demanda, y esto implica que se necesitan solo 2 centros de distribución para satisfacer la demanda (centros 1 y 5). Cuando la demanda aumenta a 40 en el caso 22, se necesitan tres centros de distribución para poder satisfacer la demanda. El sistema define los flujos necesarios de producto entre las plantas y centros de distribución.

La Tabla 8 presenta un análisis de sensibilidad de la tasa de productos conformes de ambas plantas, lo cual se refiere al porcentaje de nivel de calidad de producto generado por planta. Recordemos que la tasa de producto conforme se modela mediante la distribución beta, con parámetros α y β .

Tabla 8. Variación del parámetro de la distribución que modela la tasa de producto conforme

| Casos | Parámetros de la demanda aleatoria | | Indicadores clave | | | | | | | Costo Total (\$) | |
|---|------------------------------------|-------------------------|-------------------|--------------|--------------|--------------|--------------|---------------|-------------|------------------|-----------------|
| | α | β | Promedio (%) | PD_j (%) | PD_2 (%) | QCP_1 (\$) | QCP_2 (\$) | TDP_1 (%) | TDP_2 (%) | | Activated Silos |
| Caso base | $\alpha_1 = \alpha_2 = 50$ | $\beta_1 = \beta_2 = 5$ | 90.90% | 41.79 | 58.20 | 30.92 | 19.41 | 15.46% | 6.96 | 1,5,6 | 1852.96 |
| Variación de lo parámetro de calidad de la planta 1, con $\alpha_2 = 50$ y $\beta_2 = 5$ | | | | | | | | | | | |
| Caso 23 | $\alpha_1 = 50$ | $\beta_1 = 12$ | 80.64% | 41.79% | 58.20% | 54.61 | 19.41 | 27.30 | 6.96% | 1,5,6 | 1877.90 |
| Caso 24 | 50 | 8 | 86.20% | 41.79% | 58.20% | 42.17 | 19.41 | 21.08 | 6.96% | 1,5,6 | 1864.46 |
| Caso 25 | 50 | 4 | 92.59% | 41.79% | 58.20% | 26.64 | 19.41 | 13.32% | 6.96% | 1,5,6 | 1848.79 |
| Caso 26 | 50 | 1 | 98.03% | 64.52% | 35.47% | 16.43 | 11.83 | 5.32% | 6.96% | 3,5,6 | 1830.84 |
| Variación de lo parámetro de calidad de la planta, con $\alpha_1 = 50$ y $\beta_1 = 5$ | | | | | | | | | | | |
| Caso 27 | $\alpha_2 = 50$ | $\beta_2 = 12$ | 80.64% | 41.79% | 58.20% | 30.92 | 46.80 | 15.46% | 16.80% | 1,5,6 | 1880.91 |
| Caso 28 | 50 | 8 | 86.20% | 41.79% | 58.20% | 30.91 | 31.78 | 15.46% | 11.41% | 1,5,6 | 1866.33 |
| Caso 29 | 50 | 4 | 92.59% | 41.79% | 58.20% | 30.92 | 15.09 | 15.46% | 5.41% | 1,5,6 | 1847.48 |
| Caso 30 | 50 | 1 | 98.03% | 41.79% | 58.20% | 30.92 | 2.16 | 15.46% | .07% | 1,5,6 | 1827.78 |

Se observa que en el caso base se asigna $\alpha_1 = \alpha_2 = 50$ y $\beta_1 = \beta_2 = 5$, esto implica que la planta 1 y 2 tienen la misma tasa de producto conforme con una media de 90.90%, del cual la planta 1 produce el 41.70% de la demanda y la planta 2 el 58.20% del total de la demanda. Posteriormente se analiza el escenario de variar la tasa de producto conforme de ambas plantas y analizar este efecto en la toma de decisiones:

En los casos 23 al 26, se analiza el caso donde varía la tasa de producto conforme de la planta 1, desde un valor de 80.64% al 98.03%. Se observa que al aumentar β_1 , la calidad promedio de la planta 1 aumenta, generando menos defectos. Esto afecta la asignación de la demanda entre plantas, pues si la planta 1 genera menos defectos capta una mayor asignación de la demanda hasta un 64.52%, observando que la tasa de defectos de la planta 1 reduce drásticamente hasta 5.32%. Si se generan menos defectos el costo total del sistema logístico reduce a un mínimo de 1830.84.

Cuando se varía la tasa de defectos de la planta 2, se observa que al aumentar el parámetro β_2 , la calidad promedio de la planta 2 aumenta, pero se observa que el porcentaje de asignación de la demanda entre las dos plantas es el mismo en todos los casos analizados (casos 27-30). La razón de observar este efecto se debe a la estructura de costos y distancias de las plantas. Donde si se observa un impacto es en el indicador de la tasa de defectos de la planta 2, la cual reduce de 16.80% a 0.07%, resultado que es lógico de observar si la planta 2 genera menos defectos.

El análisis anterior confirma que la calidad del producto genera un impacto directo en la asignación de la demanda, ya que, al mejorar la proporción de productos conformes, el modelo tiende a preferir esta planta como principal fuente de suministro. De los resultados obtenidos se puede deducir que la calidad es un parámetro crítico ya que si una planta tiene mala calidad se compensa con más uso de la otra planta disminuyendo la dependencia de configuraciones costosas de centros de distribución y si ambas plantas mejoran su calidad, entonces los costos de defectos caen y la red se vuelve más eficiente en términos económicos.

4.8. Conclusiones del capítulo

En este capítulo se presenta la formulación de un modelo de programación estocástica de dos etapas, aplicado a un problema de diseño de una red logística de dos niveles (SCTE), el cual surge de un modelo determinista para considerar aspectos estocásticos que permiten representar de forma realista las condiciones que por lo general operan las cadenas de suministro, incluyendo restricciones de asignación y capacidad que complementen las necesidades de manera ágil y robusta.

Con la ayuda de un software de optimización se determinó la solución del modelo, incorporando distribuciones de probabilidad tanto como la demanda como para la calidad. Se generaron diversos escenarios de sensibilidad que evaluaron la variación de distintos parámetros clave y cómo influyen directamente en el costo total del sistema y la toma de decisiones de acuerdo a las diferentes variaciones.

Se observó como el tamaño del modelo estocástico incrementa conforme se vuelve más complejo al incrementar el número de puntos considerados para discretizar las variables continuas ya que crece el número de variables y restricciones en comparación con su modelo determinista. Esto confirma que la incertidumbre genera un costo computacional, pero ofrece soluciones más acercadas a la realidad.

Se observó además en los resultados del análisis de sensibilidad como la variación de parámetros de capacidades y costos generan ajustes en las variables de decisión,

como la activación de silos y la asignación de la demanda, que minimizan los costos del impacto del sistema logístico. Asimismo, un factor clave es la calidad ya que muestra un efecto significativo, pues al mejorar la proporción de producto conforme se logra reducir costos de defectos y agilizar la asignación de demanda hacia las plantas con mayor eficiencia.

Por último, se puede concluir que la incertidumbre juega un papel importante que no se debe excluir de la planificación logística ya que ofrece resultados significativos en el costo total y la configuración del sistema, que ayuda a una toma de decisiones más informada que fortalece la resiliencia y la competitividad de las cadenas de suministro actuales.

5. CAPITULO 5. DISEÑO DE REDES LOGISTICAS DE DOS NIVELES CONSIDERANDO DEMANDA Y CALIDAD ALEATORIA EN UN ENTORNO MULTERIODO

5.1. Contexto

En la actualidad en donde diversas actividades logísticas se enfrentan a retos cada vez más complejos y dinámicos, se busca sistemas más flexibles y adaptativos que no solo busquen optimizar los flujos de distribución sino poder ajustar su infraestructura logística conforme evoluciona el entorno. Es por ello que a diferencia de modelos deterministas donde se asumen condiciones constantes y conocidas, o modelos estocásticos de dos etapas que considera una decisión inicial y una corrección al revelarse la incertidumbre, en este nuevo modelo se agrega la posibilidad de que las decisiones evolucionen progresivamente con el tiempo (Melo et al., 2009).

Dentro del contexto planteado en el capítulo anterior, donde se incorporó la incertidumbre en el modelo mediante parámetros clave como la demanda y la calidad para representar un entorno más cercano a la realidad. En el presente capítulo se propone la extensión de dicho modelo a un entorno multiperiodo, en esta nueva formulación, se introduce una estructura más compleja al agregar la reconfiguración dinámica de los centros de distribución, lo que permite la posibilidad de cerrar y abrir centros de distribución a lo largo de distintos periodos de tiempo, para que, de esta manera, el sistema pueda adaptarse a la evolución temporal de las condiciones logísticas.

Con esta característica el modelo se define con un enfoque estocástico multietapa, el cual introduce una estructura más flexible, el cual tiene la capacidad de enfrentar retos en mercados altamente fluctuantes y responder de una manera ágil y adaptativa a las exigencias actuales de una red logística moderna.

En vez de una única decisión binaria para abrir o cerrar un centro de distribución, se permite en el modelo que estos se puedan reconfigurar (cerrar y volver a abrir) en distintas etapas según la evolución del sistema lo requiera, lo que le permite adaptarse

mejor ante cambios o alteraciones de variables claves del modelo, con el propósito de evaluar los beneficios operativos y económicos de la reconfiguración dinámica de los centros de distribución.

En la siguiente sección se presenta la formulación del modelo propuesto, así como los resultados obtenidos con tablas de sensibilidad, tablas comparativas de rendimiento entre distintos modelos y se discute sobre cómo es que una planeación adaptable puede ofrecer soluciones más robustas y eficientes dentro de una red logística.

5.2. Modelo multietapa con reconfiguración dinámica de centros de distribución

La siguiente notación es utilizada en la formulación del modelo de reconfiguración de centros de distribución para una red logística de dos niveles multiperiodo, considerando incertidumbre en la demanda y calidad:

a) Conjuntos e índices

- I : Conjunto de plantas indexado por i .
- J : Conjunto de centros de distribución indexado por j .
- \mathcal{R} : Conjunto de clientes indexado por r .
- T : Conjunto de periodos, indexado por t .
- Ω : Conjunto de escenarios indexado por ω .

b) Parámetros aleatorios:

Demanda y calidad:

- d_{rt}^{ω} : Demanda del cliente r en el periodo t bajo el escenario ω .
- d_{it}^{ω} : Proporción de producto conforme en la planta i en el periodo t bajo el escenario ω .

Capacidades:

- o_i : Capacidad máxima de producción de la planta i .
- q_j : Capacidad máxima del centro de distribución j .

Costos:

- a_{ijr} : Costo unitario de transporte desde la planta i , pasando por el centro de distribución j , hacia el cliente r .
- f_{jon} : Costo fijo de apertura del centro de distribución j .
- f_{joff} : Costo fijo de cierre del centro de distribución j .
- f_{juse} : Costo fijo de operación del centro de distribución j si está en uso.
- g_j : Costo marginal de almacenamiento por unidad en el centro de distribución j .
- cdi : Costo unitario por producto defectuoso en la planta i .

Transiciones:

- L_j : Número máximo de cambios de estado (apertura y cierre) permitidos para el silo j .
- P_ω : Probabilidad del escenario ω .

c) Variables de Decisión

- $x_{ijrt}^\omega \geq 0$: Unidades transportadas de la planta i , pasando por el centro de distribución j , hacia el cliente r , en el periodo t , bajo el escenario ω .
- $y_{jt}^\omega \in \{0,1\}$: 1 si el centro de distribución j está abierto en el periodo t bajo el escenario ω .
- $z_{jt}^\omega \in \{0,1\}$: 1 si el centro de distribución j se abre en el periodo t (transición de cerrado a abierto).
- $w_{jt}^\omega \in \{0,1\}$: 1 si el centro de distribución j se cierra en el periodo t (transición de abierto a cerrado).

d) Función objetivo:

Minimizar el costo total esperado, el cual se compone por el costo de transporte, costos fijos de transición y operación de los centros de distribución, costos de almacenamiento y costos por defectos, expresado de la siguiente manera:

$$\begin{aligned}
\text{Minimizar } & \sum_{\omega \in \Omega} p_{\omega} \sum_{t \in T} \left[\sum_{i \in I} \sum_{j \in J} \sum_{r \in R} a_{ijr} x_{ijrt}^{\omega} \right. \\
& + \sum_{j \in J} \{f_{jon} z_{jt}^{\omega} + f_{joff} w_{jt}^{\omega} + f_{juse} y_{jt}^{\omega}\} \\
& + \sum_{j \in J} g_j \sum_{i \in I} \sum_{r \in R} x_{ijrt}^{\omega} \\
& \left. + \sum_{i \in I} \sum_{j \in J} \sum_{r \in R} c_{di} (1 - p_{it}^{\omega}) x_{ijrt}^{\omega} \right]
\end{aligned} \tag{14}$$

e) Restricciones

e.1) Capacidad de las plantas

$$\sum_{j \in J} \sum_{r \in R} x_{ijrt}^{\omega} \leq o_i \quad \forall i \in I, t \in T, \omega \in \Omega. \tag{15}$$

e.2) Satisfacción de la demanda

$$\sum_{i \in I} \sum_{j \in J} p_{it}^{\omega} x_{ijrt}^{\omega} \geq d_{rt}^{\omega} \quad \forall r \in R, t \in T, \omega \in \Omega. \tag{16}$$

e.3) Capacidad de los silos

$$\sum_{i \in I} \sum_{r \in R} x_{ijrt}^{\omega} \leq q_j \cdot y_{jt}^{\omega} \quad \forall j \in J, t \in T, \omega \in \Omega. \tag{17}$$

e.4) Dinámica del estado de los silos

Para $t > 1$:

$$y_{jt}^{\omega} = y_{j,t-1}^{\omega} + z_{jt}^{\omega} - w_{jt}^{\omega} \quad \forall j \in J, t = 2, \dots, T, \omega \in \Omega \tag{18}$$

Con estado inicial:

$$y_{j1}^{\omega} = y_{j1} \quad \forall j \in J, \omega \in \Omega \tag{19}$$

e.5) Transiciones válidas

$$z_{jt}^{\omega} \leq 1 - y_{j,t-1}^{\omega}, \quad w_{jt}^{\omega} \leq y_{j,t-1}^{\omega} \quad \forall j \in J, t > 1, \omega \in \Omega \quad (20)$$

e.5) Limite total de cambios de estado

$$\sum_{t \in T} (z_{jt}^{\omega} + w_{jt}^{\omega}) \leq L_j \quad \forall j \in J, \omega \in \Omega \quad (21)$$

e.6) Restricciones de no anticipatividad

Para cada nodo de información (definido por el conjunto Ω_t de escenarios que comparten el mismo historial hasta el periodo t), se imponen:

$$y_{jt}^{\omega} = y_{jt}^{\omega'}, \quad z_{jt}^{\omega} = z_{jt}^{\omega'}, \quad w_{jt}^{\omega} = w_{jt}^{\omega'}, \quad \forall j \in J, t \in T, \omega, \omega' \in \Omega_t \quad (22)$$

5.3. Materiales y métodos

Esta sección tiene por objetivo presentar el enfoque de resolución del presente modelo estocástico multiperiodo integrando la decisión dinámica de apertura y cierre del centro de distribución que a diferencia del capítulo anterior este incorpora explícitamente una lógica operativa temporal, al permitir que cada centro de distribución tenga la capacidad de modificar su estado de apertura en cada periodo del horizonte de planificación. En este segundo modelo de igual manera se considera a la demanda de los clientes y la proporción de producto conforme como variables aleatorias.

La metodología se basa en la programación estocástica multietapa, resuelto por medio del software de optimización. Los pasos de la metodología empleada son los siguientes:

- 1) Preparación de los datos de entrada: en esta etapa se considera toda la información que se recopiló en el modelo estocástico de dos etapas, considerando los principales datos de parámetros de capacidad, costos de almacenamiento, además se incorpora los costos de apertura, cierre y operación de los centros de distribución. Datos históricos para estimar los parámetros de demanda con distribución normal y calidad

por cada planta, los cuales se integraron a través de hojas de cálculo externas vinculadas al modelo por medio de funciones de especiales de LINGO. De igual manera se definen las condiciones iniciales para cada silo, así como restricciones de un máximo cambio de estado de cada centro de distribución que garantice un adecuado entorno para mostrar el dinamismo del modelo.

- 2) Desarrollo del modelo estocástico multiperiodo: Se formula un modelo de optimización estocástica que incorpora la dinámica de transición de estados considerando la consistencia temporal, por medio de restricciones que considere que cada centro de distribución pueda abrirse, cerrarse o mantenerse en operación en cada periodo mediante variables binarias, permitiendo la generación de múltiples escenarios. Por medio del software de optimización la solución del modelo genera evaluaciones de decisiones por etapa y la construcción del modelo determinista equivalente cuyo objetivo es minimizar el costo total esperado.
- 3) Verificación y validación: esta etapa de pruebas sirve para verificar si el modelo cumple las restricciones necesarias de capacidad, satisfacción y transición de estado necesarias para su validez, evaluando si las decisiones son coherentes con respecto al comportamiento operativo del sistema como por ejemplo; cuando la demanda incrementa que el sistema tome la decisión correcta de abrir o cerrar un silo justificadamente, y validar que el modelo reproduce y representa adecuadamente la dinámica de un sistema logístico multiperiodo real. Así como la capacidad del software ante distintos números de periodos y cuál es su capacidad computacional para resolver este tipo de problemas np-hard.
- 4) Análisis de sensibilidad: durante esta etapa se realizó la evaluación del cambio de distintos parámetros clave, y como es que afecta la variación en cada uno de ellos. Los parámetros que se tomaron en cuenta para su evaluación fueron los siguientes:
 - Variación de la capacidad de silos.
 - Costos de apertura, cierre y uso de silos.
 - Variación en parámetros de la demanda (media y desviación estándar) y en la calidad (distribución beta).

Con este análisis se logra obtener una comprensión más profunda del comportamiento del sistema bajo diferentes condiciones de incertidumbre, e identificar que parámetros tienen mayor peso en condiciones de incertidumbre dentro de la toma de decisiones de una red logística.

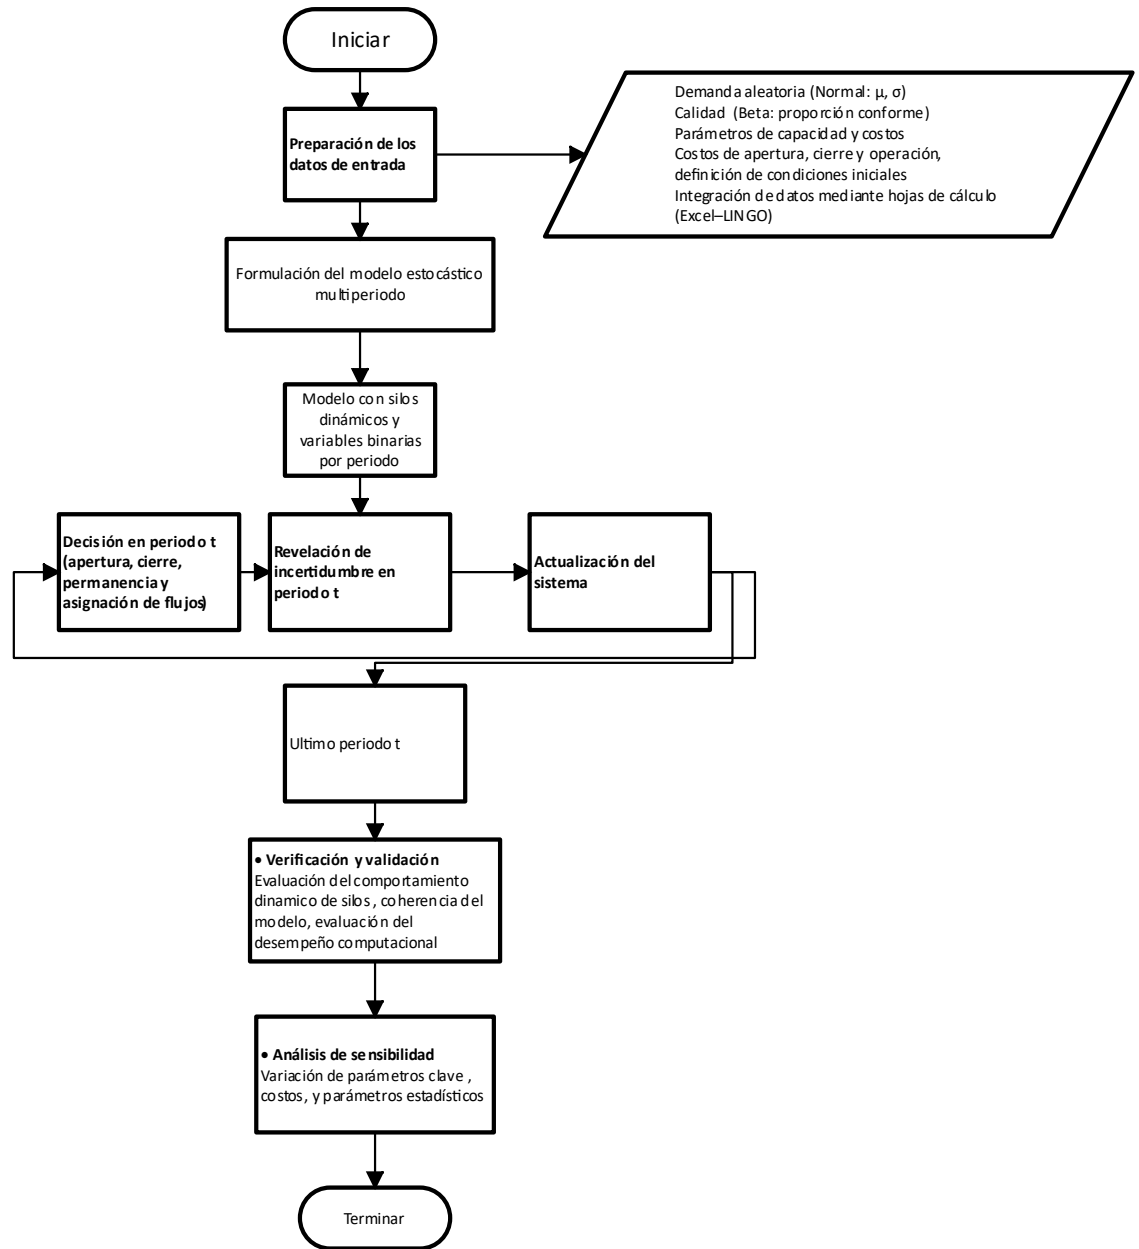


Fig. 3 Estructura metodológica del modelo de programación estocástica multietapa con decisión dinámica de centros de distribución

5.4. Resultados numéricos

La instancia numérica que se desarrolla en este capítulo abarca diversas instancias, que permiten evaluar el comportamiento del modelo estocástico multietapa con decisiones dinámicas de apertura y cierre de silos, considerando a la demanda y calidad como variables aleatorias, por lo cual incrementa potencialmente la complejidad computacional del problema debido a la presencia de múltiples periodos.

Este modelo permite examinar la generación de árboles de escenarios por periodo, en donde se observa como incrementan las restricciones y variables de decisión ligadas a la implementación de dinámica de silos. De igual manera se discute el impacto computacional del número de escenarios del horizonte multiperiodo y el tiempo de respuesta requerido por el software de optimización, el cual demuestra que a mayor número de periodos mayor es la cantidad de iteraciones necesarias para encontrar una solución óptima. Todas las iteraciones fueron realizadas en una computadora Dell Vostro 3400, equipado con un procesador Intel® Core™ i5-113G7 @ 2.40 GHz, 8 GB de memoria RAM y sistema operativo de 64 bits.

A continuación, se muestran los principales datos de entrada utilizados para las instancias numéricas para la resolución del modelo.

Tabla 1: Datos para las instancias numéricas

| | | | | | | | |
|------------------|------------|------------|-----------|-----------|-------|----------|------------|
| Parametro | g_j | C_{tra} | C_{d1} | C_d | O_1 | O_2 | q_j |
| Valor | 0.172 | 0.06 | 8 | 8 | 160 | 200 | 103.33 |
| Parametro | σ_1 | σ_2 | β_1 | β_2 | μ | α | α_1 |
| Valor | 50 | 50 | 1 | 1 | 37.43 | 10 | 9 |
| Parametro | α_1 | FON_j | $FOFF_j$ | $FUSE_j$ | L | | |
| Valor | 9 | 48.83 | 61.04 | 61.04 | 10 | | |

En el modelo de reconfiguración dinámica se incluye nuevos parámetros, que no se incluyen en el modelo anterior, empezando por eliminar el parámetro asociado a la apertura y operación de un centro de distribución (f_j), ya que en este caso representa un

costo estático en el modelo implicando que si un centro está abierto permanece abierto durante todo el horizonte de tiempo.

En el modelo actual este costo se descompone en tres componentes dinámicos por centro:

- FON_j : costo por abrir un centro de distribución.
- $FOFF_j$: Costo por cerrar el centro de distribución.
- $FUSE_j$: costo por utilizar un centro de distribución (operación).

De igual manera se incluye a una variable L para indicar el número de veces que puede cambiar de estado cada centro a lo largo del horizonte de planeación, representado con 1 para un centro abierto y 0 a un centro cerrado. Este parámetro se incluye para evitar un comportamiento no racional del modelo, al generar una apertura y cierre de forma infinita, y de esta manera mantener decisiones lógicas y realistas evitando una explosión combinatoria en el algoritmo estocástico.

Tabla 2. Comparación del tamaño de los modelos

| Número de periodos | Modelo determinista | | Modelo estocástico de multi etapas | | | Modelo determinista equivalente | | |
|--------------------|---------------------|---------------|------------------------------------|-----------|----------------------|---------------------------------|-----------|---------------|
| | Variables | Restricciones | Numero de escenarios | Variables | Variables aleatorias | Restricciones | Variables | Restricciones |
| 2 | 223 | 61 | 4 | 232 | 18 | 61 | 956 | 661 |
| 3 | 327 | 100 | 8 | 343 | 27 | 100 | 2744 | 2245 |
| 4 | 431 | 139 | 16 | 447 | 36 | 139 | 7152 | 6445 |
| 5 | 535 | 178 | 32 | 551 | 45 | 178 | 17632 | 16909 |
| 6 | 639 | 217 | 64 | 655 | 54 | 217 | 41920 | 41965 |

En la Tabla 2, se observa el análisis de tres tipos de modelos, los cuales se describen a continuación:

Modelo determinista: presenta un crecimiento lineal entre las variables y restricciones conforme aumenta el número de periodos, cada periodo agrega más decisiones (capacidad, demanda o transporte), bajo la premisa de que son valores fijos es decir no presentan incertidumbre. Este tipo de modelo solo requiere más ecuaciones y más variables para capturar la dinámica del sistema, el cual sigue siendo manejable a pesar de tener 6 periodos.

Modelo estocástico multietapas: cada periodo duplica el número de escenarios, por lo tanto, se observa un crecimiento exponencial lo que refleja las diversas ramas de incertidumbre que rodean al modelo, pasando de 232 variables en el segundo periodo a 655 en el periodo seis y de 18 variables aleatorias a 54, reflejando la dimensión del problema y como es que la incertidumbre influye en las decisiones que genera el programa.

El modelo determinista equivalente, el cual convierte cada escenario posible en un conjunto de restricciones y variables adicionales, generando un problema estocástico grande pero sin incertidumbre explícita, lo cual se aprecia en el aumento explosivo de las variables y restricciones, generando 661 restricciones en el periodo 2 y llegando a 41965 en el periodo 6, con este modelo se observa cómo crece la complejidad de la dinámica logística. Además, el costo computacional a partir del sexto periodo se dispara y es difícil de manejar a partir de este periodo, ya que en el periodo 7, no fue posible obtener una solución por el número excesivo de variables y restricciones, se llegó a esta conclusión después de dejar al software de optimización resolviendo por 30 horas sin obtener un resultado óptimo para periodos mayores a 7.

Tabla 3. Comparación entre el modelo determinista y estocástico

| Tamaño de muestra | Tiempo de cómputo (seg) | | Numero de iteraciones | | Tipo de solución | |
|-------------------|-------------------------|--------------------|-----------------------|--------------------|---------------------|--------------------|
| | Modelo determinista | Modelo estocástico | Modelo determinista | Modelo estocástico | Modelo determinista | Modelo estocástico |
| 2 | 0.27 | 0.73 | 471 | 4528 | Global optimal | Global optimal |

| | | | | | | |
|---|------|---------|------|---------|----------------|----------------|
| 3 | 0.19 | 5.04 | 767 | 15330 | Global optimal | Global optimal |
| 4 | 0.47 | 32.63 | 1207 | 56757 | Global optimal | Global optimal |
| 5 | 0.84 | 122.07 | 2295 | 197130 | Global optimal | Global optimal |
| 6 | 1.04 | 1630.19 | 2851 | 2500520 | Global optimal | Global optimal |

Para complementar el análisis en la explicación entre el modelo determinista y el modelo estocástico, se presenta la Tabla 3, la cual refleja la comparación en el tiempo de cálculo computacional, el número de iteraciones para llegar a la mejor solución y el tipo de solución obtenida, destacando un incremento considerable del tiempo de cómputo del modelo estocástico, ya que al considerar la incertidumbre genera un modelo más complejo tanto en el tiempo de cómputo como en el aumento exponencial de iteraciones.

Se observa que ambos modelos logran alcanzar en los 6 periodos una solución global óptima, donde el modelo determinista es más sencillo y rápido, sin embargo, el modelo estocástico ofrece un panorama más apegado a la realidad, pero con un costo de tiempo de cómputo considerablemente mayor.

Se puede concluir que el primer modelo sirve de base mientras que el modelo estocástico, al incorporar la incertidumbre ofrece una propuesta robusta que requiere de mayores recursos computacionales para alcanzar los resultados esperados.

5.5. Análisis de sensibilidad

En esta sección se estudiará como afectan los distintos parámetros de costos que influyen en la toma de decisiones estratégicas del modelo y el costo total que genera cada decisión al incorporar la reconfiguración dinámica de los centros de distribución. Se consideran los costos de apertura, cierre, operación, transporte, almacenamiento y defectos que intervienen en el costo total y comportamiento del sistema logístico. Este análisis permite visualizar como impacta los factores aleatorios de la demanda y calidad con la fluctuación de los costos operativos, ofreciendo evidencia sobre la importancia de

aplicar modelos estocásticos multiperiodo para generar comportamientos más apegados a la realidad.

El análisis inicia evaluando diversos parámetros, con la ayuda de la siguiente Tabla 4, se realiza un análisis de sensibilidad de costos, en el cual se varía cada parámetro clave en cada caso (sombreados), con el propósito de observar los cambios que genera dentro del modelo del sistema logístico.

Tabla 4. Variación de costos

| Casos | Parámetro | incremento | Variación de costo/parámetro | | | | | | | | | |
|---------------------|-----------------------|------------|------------------------------|--------------|--------------|-------------|--------------|----------|----------|------------|------------|------------|
| | | | a_{ijr} | f_j^{on} | f_j^{use} | f_j^{off} | g_j | C_{d1} | C_{d2} | O_1 | O_2 | q_j |
| Caso de base | - | | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 160 | 200 | 119 |
| Caso 1 | a_{ijr} | -40% | 0.036 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 160 | 200 | 119 |
| Caso 2 | | +40% | 0.084 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 160 | 200 | 119 |
| Caso 3 | f_j^{on}, f_j^{use} | -40% | 0.06 | 29.30 | 36.63 | 1.47 | 0.172 | 8 | 8 | 160 | 200 | 119 |
| Caso 4 | f_j^{off} | +40% | 0.06 | 68.37 | 85.47 | 3.42 | 0.172 | 8 | 8 | 160 | 200 | 119 |
| Caso 5 | g_j | -40% | 0.06 | 48.83 | 61.04 | 2.44 | 2 | 8 | 8 | 160 | 200 | 119 |
| Caso 6 | | +100% | 0.06 | 48.83 | 61.04 | 2.44 | 2 | 8 | 8 | 160 | 200 | 119 |
| Caso 7 | C_{d1} | -100% | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 1 | 8 | 160 | 200 | 119 |
| Caso 8 | | +200% | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 16 | 8 | 160 | 200 | 119 |
| Caso 9 | C_{d1} | -100% | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 1 | 160 | 200 | 119 |
| Caso 10 | | +200% | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 16 | 160 | 200 | 119 |
| Caso 11 | o_1 | -5% | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 151 | 200 | 119 |
| Caso 12 | | +250% | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 400 | 200 | 119 |
| Caso 13 | o_2 | -4.5 | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 160 | 191 | 119 |
| Caso 14 | | +200 | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 160 | 400 | 119 |
| Caso 15 | q_j | -1 | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 160 | 200 | 117.81 |
| Caso 16 | | 200 | 0.06 | 48.83 | 61.04 | 2.44 | 0.172 | 8 | 8 | 160 | 200 | 238 |

La variación de los parámetros es de acuerdo a los porcentajes de incremento, tomando un valor mayor y un valor menor como se indica en la columna de incremento de la Tabla 1 con referencia a su valor base. En los casos 3 y 4 referente a los costos de f_j^{on} , f_j^{use} , f_j^{off} que representan los costos asociados a la apertura, uso y cierre de los centros de

distribución, se tomó un valor promedio de los 6 centros para ejemplificarlo en la tabla, así como el valor promedio de g_j (costo marginal).

Los resultados obtenidos en el análisis de sensibilidad se presentan en la Tabla 5.

Tabla 5. Análisis de Sensibilidad de la variación de costo

| Casos | Parámetro | Incremento | Indicadores clave | | | | | | | Costo total |
|---------------------|----------------------------|------------|-------------------|---------------|---------------|---------------|---------------|-------------|------|----------------|
| | | | PSP_1 | PSP_2 | CDP_1 | CDP_2 | PDP_1 | PDP_2 | PSA | |
| | | | (%) | (%) | (\$) | (\$) | (%) | (%) | | |
| Caso de base | - | | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.9% | 3.25 | 7737.82 |
| Caso 1 | a_{ijr} | -40% | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.9% | 3.25 | 5517.80 |
| Caso 2 | | +40% | 45.26% | 54.74% | 682.13 | 511.54 | 13.61% | 8.9% | 4.5 | 93211.45 |
| Caso 3 | f_j^{on} | -40% | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.9% | 3.25 | 7413.58 |
| Caso 4 | f_j^{use} f_j^{off} | +40% | 42.22% | 57.78% | 624.23 | 545.21 | 13.31% | 8.92% | 3.00 | 9332.47 |
| Caso 5 | g_j | -40% | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.9% | 3.25 | 7648.23 |
| Caso 6 | | +100% | 44.52% | 55.48% | 668.72 | 518.53 | 13.55% | 8.89% | 3.25 | 14272.09 |
| Caso 7 | C_{d1} | -100% | 45.94% | 54.06% | 85.82 | 507.77 | 13.51% | 8.94% | 3.25 | 7167.70 |
| Caso 8 | | +200% | 39.83% | 60.17% | 2194.29 | 573.70 | 13.18% | 8.96% | 3.25 | 9368.66 |
| Caso 9 | C_{d2} | -100% | 40.67% | 59.33% | 595.35 | 70.04 | 13.16% | 8.90% | 3.25 | 7247.54 |
| Caso 10 | | +200% | 45.94% | 54.06% | 686.58 | 1015.53 | 13.51% | 8.94% | 3.25 | 8276.22 |
| Caso 11 | θ_1 | -5% | 39.93% | 60.07% | 586.40 | 571.89 | 13.18% | 8.96% | 3.25 | 7758.893 |
| Caso 12 | | +250% | 47.24% | 52.76% | 673.66 | 457.52 | 13.05% | 8.37% | 3.25 | 7628.37 |
| Caso 13 | θ_2 | -4.5% | 42.57% | 57.43% | 622.81 | 543.50 | 13.18% | 8.94% | 3.25 | 7751.49 |
| Caso 14 | | +200% | 33.27% | 66.73% | 476.64 | 629.71 | 12.78% | 8.80% | 3.25 | 7715.61 |
| Caso 15 | q_j | -1% | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.90% | 3.25 | 7739.89 |
| Caso 16 | | +200% | 41.35% | 58.65% | 599.81 | 556.48 | 13.05% | 8.94% | 2.25 | 7537.52 |

La Tabla 5 presenta un análisis de sensibilidad de costos, en la cual se evalúa el comportamiento del modelo cuando sufre modificaciones en sus principales parámetros tanto económicos como operativos y a continuación se enlistan los principales resultados:

- Variación del costo de transporte a_{ij} : al disminuir un 40% el costo de transporte (caso 1), el costo total del sistema disminuye de \$7737.82 a \$5517.80, se observa que cuando el costo de transporte aumenta, el incremento en el costo total del sistema logístico que genera es significativamente mayor (caso 2), este comportamiento evidencia un parámetro altamente sensible dentro del sistema. Ya que pequeñas variaciones generan impactos notables en la estructura de costos, modificando la forma en que el modelo distribuye la producción y selecciona rutas convenientes. El incremento en los costos se refleja en el porcentaje de demanda asignado a cada planta, donde el modelo tiende a equilibrar ligeramente la distribución de producción entre ambas (caso 2), buscando rutas más económicas ante el incremento en los costos por defecto. Esto ocurre porque al aumentar la producción en la planta 1, también crece el volumen de producto fabricado por esta planta y por ende también aumenta el costo de producto defectivo a 682.13. Finalmente, el modelo decide abrir 4.5 silos en promedio, decisión que se ejecuta como una estrategia para reducir costos de transporte, almacenar producto más cerca del cliente y compensar parcialmente el aumento en los gastos operativos.
- Variación del costo de manejo de los centros de distribución: a fin de detectar cambios significativos en la sensibilidad del modelo, en este rubro se juntan los tres costos que afectan a los centros de distribución f_j^{on} (costo de apertura del centro), f_j^{use} (costo fijo de operación del centro) y f_j^{off} (costo de cierre del centro). Notando como al reducir estos costos (caso 3), el modelo se permite la posibilidad de abrir más centros o mantenerlos, reduciendo así el costo total del sistema. Mientras que al aumentar el costo (caso 4) el sistema reduce la cantidad de silos abiertos a 3, generando un aumento en el costo total del sistema.
- Variación del costo de defecto de calidad C_{d1}, C_{d2} : en este caso se puede observar el equilibrio entre costo y calidad ya que si el costo de defecto baja (caso 7 y caso 9) el sistema tolera más defectos por el bajo coste económico que representa, asignado un mayor porcentaje de la demanda a la planta con el menor costo de defectos. La columna de costo de defectos CDP, se observa como reduce su valor si el costo de defectos de la planta se reduce. Si aumentan el costo de los defectos, (caso 8 y 10),

la producción incrementa para favorecer la planta con el menor costo de defectos, provocando en ambas plantas un aumento en el costo total.

- Variación de capacidad de producción θ_1, θ_2 : se nota ya que al reducir la capacidad de producción de las plantas (caso 11 y 13) el modelo debe compensar la falta de capacidad, asignando más porcentaje de la demanda a la planta a la que no tiene el descenso de capacidad. Además, se observa que a las plantas que se le asigna un mayor porcentaje de demanda, tienden a aumentar sus costos de calidad pues fabrican más unidades, pero también incrementan el número de defectos. El aumento de la capacidad de producción de las plantas, tiende a incrementar la producción de la planta que experimenta el incremento en su capacidad. Además, esto implica que el costo de calidad también aumenta por la generación de una mayor cantidad de defectos.
- Variación de capacidad de los centros de distribución q_j : Este factor indica el límite máximo de productos que un centro de distribución puede manejar o procesar, en el cual se percibe una sensibilidad baja a los cambios, debido a que el sistema posee la capacidad suficiente para manejar la demanda requerida siempre que la variación no sea tan grande. Se observa que el bajar el valor de este parámetro (caso 15), se necesitan abrir más centros de distribución, 3.25 en promedio. Además, cuanto la capacidad de los silos aumenta, se necesitan abrir menos centros en promedio, solo 2.25. Estos resultados son lógicos y esperados en la sensibilidad.

La Tabla 6 muestra la sensibilidad del modelo frente a cambios en los parámetros de la distribución normal que modela la demanda aleatoria, se analiza la fluctuación de la desviación estándar σ y la media μ , con 3 valores diferentes a su valor base. Esta sección tiene como objetivo entender el comportamiento del modelo ante cambios de la incertidumbre de la demanda.

Tabla 6. Variación de los parámetros de la distribución que modela la demanda aleatoria

| casos | Parámetros de la demanda aleatoria | | Indicadores clave | | | | | | | Costo Total (\$) |
|---------------------------------------|------------------------------------|-----------|-------------------|---------------|---------------|---------------|---------------|-------------|-------------|------------------|
| | μ | σ | PSP_1 (%) | PSP_2 (%) | CDP_1 (\$) | CDP_2 (\$) | PDP_1 (%) | PDP_2 (%) | PSA | |
| Caso base | 37.43 | 10 | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.9% | 3.25 | 7737.82 |
| Fluctuación de la desviación estándar | | | | | | | | | | |
| Caso 17 | 37.43 | 6 | 38.94% | 61.06% | 535.19 | 533.85 | 13.18% | 8.81% | 3.00 | 7291.538 |
| Caso 18 | 37.43 | 8 | 39.64% | 60.36% | 563.25 | 547.99 | 13.19% | 8.85% | 3.00 | 7504.241 |
| Caso 19 | 37.43 | 10 | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.9% | 3.25 | 7737.82 |
| Fluctuación de la media | | | | | | | | | | |
| Caso 20 | 22 | 10 | 45.80% | 54.20% | 396.64 | 315.47 | 12.11% | 8.48% | 2.25 | 5096.04 |
| Caso 21 | 30 | 10 | 38.9% | 61.10% | 454.72 | 470.36 | 12.59% | 8.70% | 3.0 | 6470.80 |
| Caso 22 | 38 | 10 | 41.03% | 58.07% | 608.92 | 565.36 | 13.17% | 8.93% | 3.25 | 7835.75 |

Los resultados de la sensibilidad de los parámetros de la distribución de probabilidad de la demanda son los siguientes:

- Impacto de la fluctuación de la desviación estándar: el valor base es 10, cuando disminuye la desviación estándar de la distribución normal a 6 se tiene una demanda más estable lo que influye en tener una planeación más acertada y eficiente que contribuye a una reducción de costos pues el sistema puede planificar mejor. Al incrementar σ a 10 se tiene mayor incertidumbre y variabilidad en la demanda, entonces el sistema reacciona abriendo más centros de distribución en promedio en 3.25.
- Impacto de la fluctuación de la media: cuando la media de la distribución normal reduce a 22, el sistema experimenta menor demanda, entonces solamente se abren 2.25 centros en promedio. Cuando la media aumenta a 38, se tiene una mayor demanda, entonces es necesario abrir más centros en promedio a una cantidad de 3.25. La asignación de la demanda entre plantas fluctúa sin un patrón claro a fin de reducir el costo total del sistema.

En la Tabla 7 se presenta la variación de los parámetros de la distribución beta que modela la tasa de producto conforme con parámetros α y β . Esta distribución describe el porcentaje de producto sin defectos producidos por cada planta.

Tabla 7. Variación de los parámetros de la distribución beta

| Casos | Parámetros de la calidad aleatoria | | Indicadores clave | | | | | | | Costo | |
|---|------------------------------------|-------------------------|-------------------|-------------|-------------|-------------|-------------|-------------|-------------|-------|------------|
| | α | β | Promedio (%) | PSP_1 (%) | PSP_2 (%) | CDP_1 (%) | CDP_2 (%) | PDP_1 (%) | PDP_2 (%) | PSA | Total (\$) |
| Caso base | $\alpha_1 = \alpha_2 = 9$ | $\beta_1 = \beta_2 = 1$ | 90% | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.9% | 3.25 | 7737.82 |
| Variación de los parámetros de calidad de la planta 1, con $\alpha_2 = 9$ y $\beta_2 = 1$ | | | | | | | | | | | |
| Caso 23 | $\alpha_1 = 9$ | $\beta_1 = 1.5$ | 85.71% | 39.90% | 60.10% | 805.67 | 564.62 | 17.40% | 8.92% | 3.25 | 8053.83 |
| Caso 24 | 9 | 1 | 90.00% | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.9% | 3.25 | 7737.82 |
| Caso 25 | 9 | 0.45 | 95.23% | 47.60% | 52.40% | 402.87 | 500.24 | 8.02% | 8.95% | 3.00 | 7369.89 |
| Variación de los parámetros de calidad de la planta 2, con $\alpha_1 = 9$ y $\beta_1 = 1$ | | | | | | | | | | | |
| Caso 27 | $\alpha_2 = 9$ | $\beta_2 = 1.25$ | 87.80% | 43.28% | 56.72% | 637.68 | 690.26 | 13.26% | 11.21 | 3.25 | 8000.52 |
| Caso 28 | 9 | 1 | 90.00% | 40.67% | 59.33% | 595.35 | 560.32 | 13.16% | 8.90% | 3.25 | 7737.82 |
| Caso 29 | 9 | 0.45 | 95.23% | 38.45% | 61.55% | 558.36 | 230.67 | 13.10% | 3.75% | 3.00 | 7141.25 |

Los resultados obtenidos son los siguientes:

- Variación del promedio de producto conforme de la planta 1: cuando se fija el valor de $\beta_1 = 1.5$, la planta 1 reduce la tasa de producto conforme a 85.71% (caso 23), lo que refleja que esta planta 1, reduce su participación en el porcentaje de demanda, pues baja a 39.90%, la planta 2 produce más para compensar esta reducción. Además, se observa que si la planta 1 genera más defectos es lógico se observar que su costo de calidad incrementa considerablemente a 805.67. También se observa que al modificar los parámetros de la distribución beta en este caso 23, la tasa de defectos de la planta 1 aumenta a 17.40% lo que incrementa el costo total del sistema. En este contexto es necesario abrir en promedio más centros de distribución con una media de 3.25 centros.
- Variación del promedio de producto conforme de la planta 2: cuando la planta 2 empeora su calidad, al reducir la tasa de producto conforme a 87.80% en el caso 27, se observa que dicha planta participa en un menor porcentaje en la satisfacción de la demanda, solamente en un 56.72%. Además, al generar más defectos, la planta 2 incrementa considerablemente su costo de calidad a 690.26. En el caso 27, la tasa de defectos de la planta 2 aumenta a 11.21% y es necesario abrir más centros de distribución a 3.25 en promedio.

En conclusión, los resultados de la Tabla 7, muestra como la calidad es una variable clave dentro de la red logística ya que no solo afecta la manufactura, sino que impacta en toda la configuración óptima de la cadena de suministro al alterar flujos, costos y decisiones de operación.

5.6. Conclusiones del capítulo

En el presente capítulo se formuló la ampliación del capítulo anterior, al introducir la posibilidad de reconfigurar dinámicamente los centros de distribución, brindando de esta manera la capacidad de adaptación del sistema dentro de un mismo horizonte de planeación, mediante decisiones de apertura y cierre, mostrando así una representación de evolución del sistema con mayor realismo.

Las condiciones en las que opera el sistema logístico consideran los principales costos asociados a su operación, entre ellos costos de almacenamiento, transporte y los costos por defecto de producto no conforme. Además, se anexan los costos generados por la apertura, cierre de centros de operación, costos de operación de silos y de transición derivados de los cambios de estado, lo que representa escenarios más realistas y por ende un incremento en las restricciones del modelo, ya que se agrega un límite de cambios de estado, así como condiciones de no anticipación que aseguran decisiones robustas, brindando de esta manera una reacción evolutiva del sistema.

Para determinar la solución del modelo mediante el software de optimización, este construye diferentes arboles de escenarios por periodo, con el fin de crear un problema multietapa, en el que se revelan las variables estocásticas en cada una de ellas. Además, define el estado abierto o cerrado de cada silo a lo largo del horizonte de planificación, permitiendo representar la evolución dinámica del sistema. De esta forma el software convierte el modelo estocástico original a un modelo determinista equivalente el cual es un modelo grande que duplica variables y restricciones formando un árbol de decisión que, a su vez, garantiza que la información generada sea coherente entre los periodos

considerados, creando así un problema equivalente resoluble que genera una solución óptima, factible y económicamente eficiente para un entorno dinámico y realista.

De acuerdo a los resultados del análisis de sensibilidad se observa como los principales parámetros de costos, capacidad y calidad influyen de manera significativa en la configuración óptima de la red logística, donde busca un equilibrio ajustando el porcentaje de utilización de los centros de distribución y distribuyendo los flujos de acuerdo al impacto de los cambios. A fin de compensar los incrementos en los costos y minimizar el impacto logístico de los ajustes de las variables de decisión, lo que representa como el modelo reacciona ante las fluctuaciones de la demanda y calidad, mostrando la robustez frente a distintos escenarios. Demostrando, así como al tener una mejor calidad en la producción, se reducen los costos de defectos impactando en plantas más eficientes y reduciendo los costos totales.

En las principales pruebas queda demostrado como el modelo se vuelve más complejo conforme aumenta el número de periodos, ya que el tamaño crece exponencialmente en complejidad, mostrando el costo computacional de un sistema más robusto y flexible.

Finalmente se puede concluir que al incorporar la función de reconfiguración dinámica de los centros de distribución fortalece su capacidad de adaptación ante los incrementos de eficiencia del sistema, el cual brinda un enfoque útil para entornos de alta variabilidad en donde los factores inciertos tienen un peso significativo. Es por ello que la incertidumbre no debe ser ignorada, ya que es la que determina las principales configuraciones de la red logística, que pueda ofrecer una visión más robusta para la toma de decisiones que ayuden a fortalecer la competitividad actual de las cadenas de suministro.

6. CONCLUSIONES GENERALES

El estudio desarrollado en este trabajo muestra la importancia de incorporar incertidumbre dentro del diseño y operación de las redes logísticas de dos niveles. El modelo con el que se partió para este estudio asume una asignación de demanda entre plantas, centros de distribución y clientes bajo un enfoque determinista, lo que facilitó comprender el funcionamiento esencial del sistema en condiciones estables. Sin embargo, dicho enfoque no representa de manera adecuada las fluctuaciones reales del entorno operativo. Con el fin de superar esta limitación, en el capítulo 4 se desarrolló un modelo de programación estocástica de dos etapas que incorporó elementos de mayor complejidad mediante la integración de incertidumbre en la demanda y calidad, representadas mediante distribuciones normal y beta. A través de esta formulación se evidenció como la variabilidad en los requerimientos de los clientes y en la proporción de producto conforme influye directamente en los costos totales del sistema, modificando la asignación óptima y obligando al modelo a redistribuir la demanda entre plantas con diferentes niveles de eficiencia. Este resultado confirma el cumplimiento del primer y segundo objetivo específico, al demostrar el impacto de la incertidumbre en decisiones de localización, asignación y flujo. Así mismo, el análisis de sensibilidad permitió identificar que variaciones en los parámetros principales pueden alterar significativamente la estructura de la red logística, mostrando así la necesidad de flexibilidad operativa para mantener niveles adecuados de servicio, la evaluación de costos y beneficios asociados a distintos escenarios de demanda aplica al cumplimiento del tercer objetivo planteado.

En el capítulo 5 se presenta la formulación extendida del modelo anterior al incorporar la dinámica temporal de los centros de distribución, permitiendo su apertura, operación y cierre a lo largo del horizonte de planeación, lo que incrementa la complejidad del sistema. Este modelo permitió representar de forma más precisa la operación real de la red logística, ya que las instalaciones no permanecen estáticas, si no que pueden activarse o desactivarse para responder a fluctuaciones en la demanda y calidad del producto. Los resultados mostraron que la red tiende a reconfigurarse en cada periodo para alcanzar el objetivo de minimizar costos, priorizando la apertura de centros de

distribución en ubicaciones estratégicas cuando la demanda aumenta o cuando la calidad mejora y cerrándolos cuando su uso deja de ser rentable.

Además, la incorporación de restricciones de nivel de servicio y costos asociados al producto no conforme permitió analizar el efecto de distintos porcentajes de cumplimiento sobre el desempeño del sistema y el análisis de sensibilidad confirmó que el modelo extendido es capaz de adaptarse a variaciones en los parámetros operativos permitiendo identificar configuraciones más robustas ante la incertidumbre. Con ello se dio cumplimiento al cuarto objetivo específico, al evaluar el impacto del nivel de servicio y la calidad sobre el costo y la configuración de la red.

En conjunto, los resultados obtenidos son satisfactorios y demuestran que la integración de la incertidumbre, complementada con las decisiones dinámicas de apertura y cierre de los centros de distribución, permiten construir un modelo más realista y robusto para el diseño de redes logísticas en entornos cambiantes. El trabajo no solo aporta evidencia cuantitativa sobre el impacto de la incertidumbre en la configuración óptima de la red para apoyar la toma de decisiones complejas, sino que también un marco teórico a futuras investigaciones que incluyan nuevas fuentes de incertidumbre o incorporen múltiples productos que fortalezcan la planeación y optimización en contexto cambiantes.

7. BIBLIOGRAFIA

- Abbaspour, S., Aghsami, A., Jolai, F., & Yazdani, M. (2022). An integrated queueing-inventory-routing problem in a green dual-channel supply chain considering pricing and delivery period: A case study of construction material supplier. *Journal of Computational Design and Engineering*, 9(5), 1917–1951. <https://doi.org/10.1093/jcde/qwac089>
- Alikhani, R., Eskandarpour, M., & Jahani, H. (2023). Collaborative distribution network design with surging demand and facility disruptions. *International Journal of Production Economics*, 262, 108912. <https://doi.org/10.1016/j.ijpe.2023.108912>
- Angioloni, S., & Cerroni, S. (2025). Farmers' cooperation to improve water quality under scientific uncertainty: A lab-in-the-field experiment. *Journal of Agricultural Economics*, 76(1), 45–73. <https://doi.org/10.1111/1477-9552.12614>
- Askarifard, M., Abbasianjahromi, H., Sepehri, M., & Zeighami, E. (2021). A robust multi-objective optimization model for project scheduling considering risk and sustainable development criteria. *Environment, Development and Sustainability*, 23(8), 11494–11524. <https://doi.org/10.1007/s10668-020-01123-z>
- Belhadi, A., Mani, V., Kamble, S. S., Khan, S. A. R., & Verma, S. (2024). Artificial intelligence-driven innovation for enhancing supply chain resilience and performance under the effect of supply chain dynamism: An empirical investigation. *Annals of Operations Research*, 333(2–3), 627–652. <https://doi.org/10.1007/s10479-021-03956-x>
- Birge, J. R., & Louveaux, F. (2011). *Introduction to Stochastic Programming*. Springer New York. <https://doi.org/10.1007/978-1-4614-0237-4>
- Biro Tamara J. & Horvath Adrian. (2024). Assigning Metaheuristics to a Logistics Problem: A Novel Classification System for Algorithms and Problems. *Chemical Engineering Transactions*, 114, 1003–1008. <https://doi.org/10.3303/CET24114168>

- Calle García, J. S., Pincay Delgado, M. A., Mendoza Pionce, B. S., & Bravo Quijije, G. S. (2024). USO ESTRATÉGICO DE LA INTELIGENCIA ARTIFICIAL EN LA GESTIÓN DE LA CADENA DE SUMINISTRO EMPRESARIAL. *Ciencia y Desarrollo*, 27(2), 267. <https://doi.org/10.21503/cyd.v27i2.2620>
- Chen, Z., Maske, H., Shui, H., Upadhyay, D., Hopka, M., Cohen, J., Lai, X., Huan, X., & Ni, J. (2023). Stochastic deep Koopman model for quality propagation analysis in multistage manufacturing systems. *Journal of Manufacturing Systems*, 71, 609–619. <https://doi.org/10.1016/j.jmsy.2023.10.012>
- Correia, I., & Melo, T. (2021). Integrated facility location and capacity planning under uncertainty. *Computational and Applied Mathematics*, 40(5), 175. <https://doi.org/10.1007/s40314-021-01560-0>
- Correia, I., Nickel, S., & Saldanha-da-Gama, F. (2018). A stochastic multi-period capacitated multiple allocation hub location problem: Formulation and inequalities. *Omega*, 74, 122–134. <https://doi.org/10.1016/j.omega.2017.01.011>
- Dellaert, N., Van Woensel, T., Crainic, T. G., & Dashty Saridarq, F. (2021). A multi-commodity two-Echelon capacitated vehicle routing problem with time windows: Model formulations and solution approach. *Computers & Operations Research*, 127, 105154. <https://doi.org/10.1016/j.cor.2020.105154>
- Diglio, A., Nickel, S., & Saldanha-da-Gama, F. (2020). Towards a stochastic programming modeling framework for districting. *Annals of Operations Research*, 292(1), 249–285. <https://doi.org/10.1007/s10479-020-03631-7>
- Dolgui, A., Ivanov, D., & Sokolov, B. (2020). Reconfigurable supply chain: The X-network. *International Journal of Production Research*, 58(13), 4138–4163. <https://doi.org/10.1080/00207543.2020.1774679>

- Dowson, O. (2020). The policy graph decomposition of multistage stochastic programming problems. *Networks*, 76(1), 3–23. <https://doi.org/10.1002/net.21932>
- Dumitrascu, O., Dumitrascu, M., & Dobrotă, D. (2020). Performance Evaluation for a Sustainable Supply Chain Management System in the Automotive Industry Using Artificial Intelligence. *Processes*, 8(11), 1384. <https://doi.org/10.3390/pr8111384>
- Escobar-Vargas, D., Crainic, T. G., Rei, W., & Wallace, S. W. (s/f). *The Two-Echelon Multicommodity Location-Routing Problem with Stochastic and Correlated Demands*.
- Feng, T., Yang, X., He, Y., Liao, R., & Cai, Y. (2024). Functional health prognosis approach for multistate manufacturing systems based on quality stochastic flow manufacturing network. *Computers & Industrial Engineering*, 188, 109913. <https://doi.org/10.1016/j.cie.2024.109913>
- Fontem, B., & Price, M. (2021). Joint client selection and contract design for a risk-averse commodity broker in a two-echelon supply chain. *Annals of Operations Research*, 307(1–2), 111–138. <https://doi.org/10.1007/s10479-021-04319-2>
- Gao, J., & Cai, C. (2025). Incorporating stochasticity in demands for optimizing resource allocation in versatile edge systems devoid of layer constraints. *Ain Shams Engineering Journal*, 16(3), 103300. <https://doi.org/10.1016/j.asej.2025.103300>
- Gastélum Valdez, J. S., & Espitia Moreno, I. C. (2022). IMPLICACIONES TEÓRICAS EN LA INTEGRACIÓN DE LA CADENA DE SUMINISTRO. *INCEPTUM*, 12(23), 29–49. <https://doi.org/10.33110/inceptum.v12i23.378>
- Geng, N., Fu, Q., & Sun, Y. (2021). Stochastic Programming of Sustainable Waste Cooking Oil for Biodiesel Supply Chain under Uncertainty. *Journal of Advanced Transportation*, 2021, 1–18. <https://doi.org/10.1155/2021/5335625>
- Ghiani, G., Laporte, G., & Musmanno, R. (2013). *Introduction to logistics systems management* (2nd edition). Wiley. <https://doi.org/10.1002/9781118492185>

- Graber, G., Calderaro, V., Mancarella, P., & Galdi, V. (2020). Two-stage stochastic sizing and packetized energy scheduling of BEV charging stations with quality of service constraints. *Applied Energy*, 260, 114262. <https://doi.org/10.1016/j.apenergy.2019.114262>
- Gupta, H., Kumar, S., Kusi-Sarpong, S., Jabbour, C. J. C., & Agyemang, M. (2021). Enablers to supply chain performance on the basis of digitization technologies. *Industrial Management & Data Systems*, 121(9), 1915–1938. <https://doi.org/10.1108/IMDS-07-2020-0421>
- Heizer, J. H., & Render, B. (2010). *Principios de administración de operaciones* (7a ed). Pearson Educación.
- Hosseini Shekarabi, S. A., Kiani Mavi, R., & Romero Macau, F. (2025). Supply Chain Resilience: A Critical Review of Risk Mitigation, Robust Optimisation, and Technological Solutions and Future Research Directions. *Global Journal of Flexible Systems Management*, 26(3), 681–735. <https://doi.org/10.1007/s40171-025-00458-8>
- Indicador Trimestral de la Actividad Económica Estatal*. (2025).
- Kogler, C., & Maxera, P. (2026). A literature review of supply chain analyses integrating discrete simulation modelling and machine learning. *Journal of Simulation*, 20(1), 110–134. <https://doi.org/10.1080/17477778.2025.2500393>
- Koutsokosta, A., & Katsavounis, S. (2020). A Dynamic Multi-Period, Mixed-Integer Linear Programming Model for Cost Minimization of a Three-Echelon, Multi-Site and Multi-Product Construction Supply Chain. *Logistics*, 4(3), 19. <https://doi.org/10.3390/logistics4030019>
- Krenek, R. (2022). Developing a two-stage stochastic programming model in tolerance optimization using a guard band approach. *Engineering Reports*, 4(2), e12461. <https://doi.org/10.1002/eng2.12461>
- Lagzaie, L., & Hamzehee, A. (2022). Providing a Multiproduct and Multiperiodic Model for Closed-Loop Green Supply Chain under Conditions of Uncertainty Based on a Fuzzy Approach for Solving Problem of Business Market. *Complexity*, 2022(1), 2780073. <https://doi.org/10.1155/2022/2780073>

- Lam, W. H., Lam, W. S., & Lee, P. F. (2024). A Bibliometric Analysis of a Genetic Algorithm for Supply Chain Agility. *Mathematics*, 12(8), 1199. <https://doi.org/10.3390/math12081199>
- Lee, H. L. (s/f). *Aligning Supply Chain Strategies with Product Uncertainties*.
- Li, H., Wang, F., Xiong, H., & Wang, Z. (2025). Two-echelon van-robot routing problem with sharing-curbside satellites. *Journal of Heuristics*, 31(1), 3. <https://doi.org/10.1007/s10732-024-09541-2>
- Liu, K., Liu, C., Xiang, X., & Tian, Z. (2023). Testing facility location and dynamic capacity planning for pandemics with demand uncertainty. *European Journal of Operational Research*, 304(1), 150–168. <https://doi.org/10.1016/j.ejor.2021.11.028>
- Liu, Z., Hu, L.-M., & Yeh, W.-C. (2023). Risk-averse two-stage stochastic programming-based closed-loop supply chain network design under uncertain demand. *Applied Soft Computing*, 147, 110743. <https://doi.org/10.1016/j.asoc.2023.110743>
- Ly, Y., & Shang, Y. (2023). Investigation of industry 4.0 technologies mediating effect on the supply chain performance and supply chain management practices. *Environmental Science and Pollution Research*, 30(48), 106129–106144. <https://doi.org/10.1007/s11356-023-29550-1>
- Ma, Y., Li, M., Shen, J., & Ji, T. (2025). Implementing demand response in day-ahead economic dispatch using stochastic segmentation. *Electric Power Systems Research*, 239, 111233. <https://doi.org/10.1016/j.epsr.2024.111233>
- Malik, A. I., & Kim, B. S. (2020). A multi-constrained supply chain model with optimal production rate in relation to quality of products under stochastic fuzzy demand. *Computers & Industrial Engineering*, 149, 106814. <https://doi.org/10.1016/j.cie.2020.106814>
- Melo, M. T., Nickel, S., & Saldanha-da-Gama, F. (2009). Facility location and supply chain management – A review. *European Journal of Operational Research*, 196(2), 401–412. <https://doi.org/10.1016/j.ejor.2008.05.007>

- Milovanovic, G., Milovanovic, S., & Radisavljevic, G. (2017). Globalization: The key challenge of modern supply chains. *Ekonomika*, 63(1), 31–40. <https://doi.org/10.5937/ekonomika1701031M>
- Mohammed, N., & Ali, M. M. (2024). Optimal Sizing of Hybrid Renewable Energy System Using Two-Stage Stochastic Programming. *International Journal of Energy Research*, 2024(1), 2361858. <https://doi.org/10.1155/2024/2361858>
- Palafox-Palafox, D., Medina-Marín, J., Seck-Tuoh-Mora, J. C., Serna-Díaz, M. G., & Hernández-Romero, N. (2023). Modelo de pronóstico de cadena de suministro mediante redes neuronales. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, 11(Especial3), 103–111. <https://doi.org/10.29057/icbi.v11iEspecial3.11482>
- Parichehreh, M., & Javadian, N. (2020). A Mixed-Integer Programming Model to Configure a Post Supply Chain Network. *Annals of Data Science*, 7(2), 281–290. <https://doi.org/10.1007/s40745-020-00268-y>
- Petris, M., Archetti, C., Cattaruzza, D., Ogier, M., & Semet, F. (2024). A Branch-Price-and-Cut algorithm for the Multi-Commodity two-echelon Distribution Problem. *EURO Journal on Transportation and Logistics*, 13, 100139. <https://doi.org/10.1016/j.ejtl.2024.100139>
- Ragnitz, J., Hofmeister, B., Jonscher, C., Hübler, C., & Rolfes, R. (2025). A stochastic multi-objective optimisation approach for damage localisation via model updating with uncertain input parameters. *Engineering Structures*, 330, 119860. <https://doi.org/10.1016/j.engstruct.2025.119860>
- Rahbari, M., Khamseh, A. A., & Mohammadi, M. (2025). A multi-objective robust scenario-based stochastic chance constrained programming model for sustainable closed-loop agri-food supply chain. *Computers & Chemical Engineering*, 194, 108914. <https://doi.org/10.1016/j.compchemeng.2024.108914>

- Rivera Gomez, H., Granillo Macias, R., Garnica Gonzalez, J., & Anaya Fuentes, G. E. (2023). A STOCHASTIC APPROACH FOR AGGREGATE PRODUCTION PLANNING CONSIDERING RANDOM DEMAND AND RANDOM QUALITY. *DYNA MANAGEMENT*, 11(1), [10P.]-[10P.]. <https://doi.org/10.6036/MN10904>
- Ruszczynski, A., & Shapiro, A. (s/f). *Stochastic Programming Models*.
- Salari, S. A.-S., Mahmoudi, H., Aghsami, A., Jolai, F., Jolai, S., & Yazdani, M. (2022). Off-Site Construction Three-Echelon Supply Chain Management with Stochastic Constraints: A Modelling Approach. *Buildings*, 12(2), 119. <https://doi.org/10.3390/buildings12020119>
- Sawant, R., Kumar, A., & Yadav, V. K. (2024). Modelling medical oxygen supply chain network under demand uncertainty using stochastic programming. *OPSEARCH*, 61(4), 2158–2190. <https://doi.org/10.1007/s12597-024-00773-1>
- Shi, Y., Sun, J., Li, Z., Yang, F., Yang, X., & Luo, Q. (2024). Predicting and analyzing the cementing quality of oil well reservoirs based on Bayesian-random forest model. *Geoenergy Science and Engineering*, 241, 213077. <https://doi.org/10.1016/j.geoen.2024.213077>
- Tighirt, A., Aatabe, M., El Guezar, F., Bouzahir, H., & Vargas, A. N. (2025). Stochastic power management strategy for an autonomous wind energy conversion system with battery storage under random load consumption using Markov process. *Journal of Energy Storage*, 114, 115812. <https://doi.org/10.1016/j.est.2025.115812>
- Tirkolaei, E. B., Goli, A., & Mardani, A. (2023). A novel two-echelon hierarchical location-allocation-routing optimization for green energy-efficient logistics systems. *Annals of Operations Research*, 324(1–2), 795–823. <https://doi.org/10.1007/s10479-021-04363-y>
- Varriale, V., Cammarano, A., Michelino, F., & Caputo, M. (2021). Sustainable Supply Chains with Blockchain, IoT and RFID: A Simulation on Order Management. *Sustainability*, 13(11), 6372. <https://doi.org/10.3390/su13116372>

- Wang, F., Li, H., & Xiong, H. (2025). Truck–drone routing problem with stochastic demand. *European Journal of Operational Research*, 322(3), 854–869. <https://doi.org/10.1016/j.ejor.2024.11.036>
- Wang, J., Wang, Z., & Liu, H. (2023). Multi-objective Stochastic Time-cost-quality Optimization for Construction Projects Based on the Reliability Theory. *KSCE Journal of Civil Engineering*, 27(11), 4545–4556. <https://doi.org/10.1007/s12205-023-1083-z>
- Yang, X., Zheng, Q., Hu, Y., Chen, R., Wang, X., & Liu, Y. (2022). Research on High-Quality Development of Auto Parts Manufacturing Industry Based on Machine Learning Model. *Scientific Programming*, 2022, 1–9. <https://doi.org/10.1155/2022/3659742>
- Yilmazlar, I. O., Kurz, M. E., & Rahimian, H. (2024). Mixed-model sequencing with stochastic failures: A case study for automobile industry. *European Journal of Operational Research*, 319(1), 206–221. <https://doi.org/10.1016/j.ejor.2024.06.019>
- Zehtabian, S. (2024). A fair multi-commodity two-echelon distribution problem. *EURO Journal on Transportation and Logistics*, 13, 100126. <https://doi.org/10.1016/j.ejtl.2024.100126>
- Zhao, N., Hong, J., & Lau, K. H. (2023). Impact of supply chain digitalization on supply chain resilience and performance: A multi-mediation model. *International Journal of Production Economics*, 259, 108817. <https://doi.org/10.1016/j.ijpe.2023.108817>
- Zhou, X., Li, J., Xie, F., & Fang, J. (2024). Research on origin-based cold storage location and routing optimization of fresh agricultural products based on hybrid whale algorithm. *Scientific Reports*, 14(1), 21078. <https://doi.org/10.1038/s41598-024-72170-z>