

**MODELO ANALÍTICO CON REGULACIONES DE EMISIONES DE CARBONO EN
UNA CADENA DE SUMINISTRO CON MÚLTIPLES PERIODOS, NIVELES Y
PRODUCTOS**

Autor:

JEAMY SEBASTIAN TARAZONA JIMÉNEZ

Trabajo de investigación para optar al título de Magíster en Ingeniería Industrial

Director:

HENRY LAMOS DÍAZ, PhD. FÍSICA-MATEMÁTICA

Codirector:

DANIEL ORLANDO MARTÍNEZ QUEZADA, M.Sc. EN INGENIERÍA INDUSTRIAL

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE ESTUDIOS INDUSTRIALES Y EMPRESARIALES
MAESTRÍA EN INGENIERÍA INDUSTRIAL
BUCARAMANGA**

2024

Dedicatoria

A Dios todopoderoso, por poner el querer como el hacer.

A mi madre Elcy, a mis hermanos Santiago y Sofia, a mi compañera de vida, Karin, a mis

Abuelos Luis y Carmen, a mis tíos, a toda mi familia y mi yo interior.

A todos aquellos que contribuyeron con sus esfuerzos para lograr esto.

¡Si se pudo, lo conseguimos!

Agradecimientos

A Dios, gracias por mostrarme el camino correcto y darme la fortaleza para recorrerlo.

A mi director, Henry Lamos Díaz, y a mi codirector, Daniel Orlando Martínez, por confiar en mis capacidades, brindarme su paciencia y estar siempre dispuestos a apoyarme en cada etapa del proyecto. Su diligencia con aspectos de la convocatoria y sus valiosas consejerías han sido fundamentales, impactando positivamente mi vida personal y profesional.

Gracias, son un verdadero ejemplo para seguir.

Al parcerero Juan Diego, por medírsele al reto, las risas nunca faltaron.

A los amigos que hice durante la maestría, siempre supe que lo íbamos a lograr.

A la UIS y la EEIE y sus directivos, profesores y en especial al Auxiliar Mateo.

Al grupo OPALO y todos sus integrantes por su apoyo y contribución.

Esto es para ustedes y por ustedes. ¡Gracias por ser parte de este camino!

Tabla de Contenido

	Pág.
Generalidades del Proyecto	15
Introducción.....	16
1. Objetivos.....	18
1.1. Objetivo General	18
1.2. Objetivos Específicos	18
2. Hipótesis	18
3. Metodología.....	19
3.1. Definición del Problema.....	19
3.2. Formulación del Modelo Matemático	21
3.3. Obtención de Soluciones a partir del Modelo	21
3.4. Experimentación a través del Modelo.....	22
4. Revisión de la Literatura.....	23
4.1. Protocolo de revisión.....	23
4.2. Marco de Gestión de la Cadena de Suministro bajo Emisiones de Carbono	24
4.2.1. Impuesto sobre el Carbono	26
4.2.2. Limitación de Carbono	28
4.2.3. Tope y Comercio de Carbono.....	31
4.3. Analítica de Datos en la Cadena de Suministro	32
4.3.1. Análisis Exploratorio de los Datos (AED)	33
4.3.2. Descubrimiento y Visualización de Datos (DVD)	33
4.3.3. Análisis Predictivo de Datos (APD).....	34
4.3.4. Métodos de Reducción de Datos (MRD)	35

4.3.5.	Métodos de Deducción de Datos (MDD).....	36
4.4.	Discusión de la Revisión de Literatura.....	37
5.	Formulación del Modelo General MLSPAP-PC.....	38
5.1.	Descripción del Problema	39
5.2.	Modelo de Optimización.....	40
5.2.1.	Supuestos del Modelo de Optimización.....	40
5.2.2.	Índices del Modelo de Optimización.....	42
5.2.3.	Parámetros de Entrada.....	43
5.2.4.	Variables de Decisión.....	43
5.2.5.	Función Objetivo.....	44
5.2.6.	Restricciones.....	45
5.2.7.	Linealización del Modelo de Optimización.....	47
5.3.	Modelos de Predicción.....	47
5.3.1.	XGBRegressor.....	50
5.3.2.	CatBoostRegressor.....	52
5.3.3.	Evaluación de los Modelos de Predicción.....	54
6.	Obtención de Soluciones a partir del Modelo.....	57
6.1.	Caso 1: Regulación Impuesto al Carbono.....	59
6.2.	Caso 2: Regulaciones Impuesto y Limite al Carbono.....	62
6.3.	Caso 3: Regulaciones Impuesto y Tope - Comercio de Carbono.....	66
6.4.	Análisis de Sensibilidad de las Regulaciones de Carbono.....	70
6.4.1.	Impuesto al Carbono (<i>tic</i>).....	70
6.4.2.	Límite de Carbono (<i>cpeh</i>).....	74
7.	Experimentación a través del Modelo.....	76

7.1.	Modelo Analítico - Caso 1	79
7.2.	Modelo Analítico - Caso 2	81
7.3.	Modelo Analítico - Caso 3	83
7.4.	Análisis de los Resultados	85
8.	Conclusiones.....	87
9.	Recomendaciones	89
10.	Referencias Bibliográficas.....	91

Lista de Tablas

	Pág.
Tabla 1. Principales regulaciones de carbono	26
Tabla 2. Estudios complementarios de limitación de carbono	29
Tabla 3. Grupo de submétodos de AED.....	33
Tabla 4. Notación de índices	42
Tabla 5. Notación de parámetros	43
Tabla 6. Notación de variables	43
Tabla 7. Marco de hiperparámetros - Modelos de Predicción.....	54
Tabla 8. Comparativo de los modelos de aprendizaje automático	56
Tabla 9. Parámetros del Modelo de Optimización	58
Tabla 10. Prorrato de costos en millones de la función objetivo - Caso 1.....	59
Tabla 11. Porcentaje de costos de la función objetivo - Caso 1	59
Tabla 12. Tamaño de los lotes - Caso 1.....	60
Tabla 13. Inventario almacenado - Caso 1	61
Tabla 14. Número de vehículos - Caso 1.....	61
Tabla 15. Selección de los fabricantes - Caso 1	62
Tabla 16. Prorrato de costos en millones de la función objetivo - Caso 2.....	63
Tabla 17. Porcentaje de costos de la función objetivo - Caso 2	63
Tabla 18. Tamaño de los lotes - Caso 2.....	64
Tabla 19. Inventario almacenado - Caso 2	64
Tabla 20. Número de vehículos - Caso 2.....	65
Tabla 21. Selección de los fabricantes - Caso 2	66
Tabla 22. Prorrato de costos en millones de la función objetivo - Caso 3.....	66

Tabla 23. Porcentaje de costos de la función objetivo - Caso 3	67
Tabla 24. Tamaño de los lotes - Caso 3.....	68
Tabla 25. Inventario almacenado - Caso 3	68
Tabla 26. Número de vehículos - Caso 3.....	69
Tabla 27. Selección de los fabricantes - Caso 3	69
Tabla 28. Cantidad de carbono comprado - Caso 3.....	70
Tabla 29. Software y hardware para la implementación de los modelos	77
Tabla 30. Instancias experimentales	77
Tabla 31. Características de los modelos MILP - MLSPAP-PC.....	78
Tabla 32. Ecuaciones de búsqueda.....	106
Tabla 33. Publicaciones y citas por país	110
Tabla 34. Publicaciones y citas por fuente.....	111
Tabla 35. Publicaciones y citas por autor	111
Tabla 36. Costos de producción instancia base	112
Tabla 37. Costos de pedido instancia base	113
Tabla 38. Costos de transporte instancia base	114
Tabla 39. Costos de almacenamiento instancia base.....	114
Tabla 40. Capacidades de los fabricantes instancia base.....	115
Tabla 41. Capacidades de los vehículos instancia base.....	116
Tabla 42. Demandas de los productos instancia base.....	116
Tabla 43. Volúmenes de empaquetado instancia base	116
Tabla 44. Costo de carbono por unidad comprada instancia base.....	116
Tabla 45. Costo del carbono por unidad vendida instancia base.....	116
Tabla 46. Costo del carbono por unidad vendida instancia base.....	117

Tabla 47. Emisiones de carbono por unidad para cada pedido instancia base 117

Tabla 48. Emisiones de carbono al realizar un pedido instancia base..... 117

Tabla 49. Emisiones de carbono al almacenar inventario instancia base 117

Tabla 50. Distancias desde los fabricantes instancia base 117

Tabla 51. Factor de emisión de transporte instancia base 117

Tabla 52. Límites de emisiones de carbono instancia base 117

Tabla 53. Lista de acrónimos..... 118

Lista de Figuras

	Pág.
Figura 1. Fases metodológicas para el desarrollo de la investigación.....	19
Figura 2. Metodología aplicada en la revisión de literatura	20
Figura 3. Representación de una red de suministro del problema de asignación del tamaño de lotes multinivel y periodo con capacidades de producción (MLSPAP-PC).....	42
Figura 4. Diagrama esquemático del XGBoost.....	51
Figura 5. Diagrama esquemático del CatBoost	53
Figura 6. Sensibilidad tasa del impuesto al carbono	71
Figura 7. Sensibilidad límite de carbono.....	75
Figura 8. Costos totales por instancias e incertidumbre - Caso 1.....	80
Figura 9. Costos totales por instancias e incertidumbre - Caso 2.....	82
Figura 10. Costos totales por instancias e incertidumbre – Caso 3	84
Figura 11. Resultados del proceso de búsqueda.....	107
Figura 12. Análisis de coocurrencias de palabras claves.....	108
Figura 13. Número de documentos por año	109
Figura 14. Porcentaje de investigaciones relacionadas con los ODS.....	110
Figura 15. Configuraciones de costos – Caso 1	119
Figura 16. Configuraciones de costos - Caso 2	120
Figura 17. Configuraciones de costos - Caso 3	121

Lista de Apéndices

	Pág.
Apéndice A. Análisis Bibliométrico.....	105
Apéndice B. Parámetros de Entrada - Instancia Base [5,4,3,2].....	112
Apéndice C. Lista de Acrónimos.....	118
Apéndice D. Gráficos Complementarios.....	119

Lista Cumplimiento de Objetivos del Proyecto

Objetivo Especifico	Numeral Relacionado
1. Caracterizar la estrategia de modelado a implementar y la estructura asociada al problema objeto de estudio, a través de una revisión de literatura.	Sección 4.
2. Formular un modelo de optimización con múltiples periodos, niveles y productos para una cadena de suministro verde, basado en los hallazgos encontrados en la literatura.	Sección 5.
3. Elaborar instancias sintéticas como instrumento de validación para el problema de optimización que contenga parámetros estimados mediante un método predictivo.	Sección 7.

Resumen

Título del proyecto: Modelo analítico con regulaciones de emisiones de carbono en una cadena de suministro con múltiples periodos, niveles y productos *

Autor: Jeamy Sebastian Tarazona Jiménez **

Palabras claves: Modelo de Optimización, Modelos de Predicción, Producción, Inventario, Transporte, Regulaciones de CO₂.

Descripción:

El desarrollo económico y las actividades humanas han generado un impacto significativo en el medio ambiente. Para mitigar estos efectos, los gobiernos han implementado políticas para controlar las emisiones de carbono, lo que ha llevado a las empresas a equilibrar la rentabilidad con la responsabilidad ambiental. Esto ha obligado a los gerentes de la cadena de suministro a ajustar sus estrategias, optimizando aspectos clave como la red logística, los tamaños de lote, el inventario, la asignación de vehículos y la selección de fábricas. Estas decisiones son fundamentales para minimizar tanto los costos como las emisiones en el diseño de una cadena de suministro.

Este trabajo presenta un modelo de optimización enfocado en la regulación de emisiones de carbono, diseñado para múltiples periodos, niveles y productos, con el fin de analizar el impacto conjunto de las dimensiones económica y ambiental. El modelo se formula bajo dos escenarios: uno sin incertidumbre y otro con incertidumbre, integrando predicciones para estimar parámetros clave. Se realiza un análisis de sensibilidad para comparar tres tipos de regulaciones de emisiones: impuesto al carbono, límite de emisiones y el sistema de tope y comercio. Los resultados indican que el impuesto al carbono es la opción más económica pero también la más contaminante, mientras que el límite de emisiones es el más eficaz en la reducción de contaminación, aunque con mayores costos. El sistema de tope y comercio se sitúa entre ambos, siendo moderado tanto en costo como en impacto ambiental. Finalmente, el modelo muestra mayor sensibilidad al límite de emisiones que a la tasa del impuesto al carbono, lo que subraya la importancia de la regulación estricta en la reducción de emisiones.

* Trabajo de grado.

** Facultad de Ingenierías Fisicomecánicas. Escuela de Estudios Industriales y Empresariales (EEIE). Maestría en Ingeniería Industrial.

Director: Henry Lamos Díaz, PhD, en Física – Matemática.

Codirector: Daniel Orlando Martínez Quezada, M.Sc. en Ingeniería Industrial.

Abstract

Project Title: Analytical model with carbon emission regulations in a supply chain with multiple periods, levels and products*

Author: Jeamy Sebastian Tarazona Jiménez**

Keywords: Optimization Model, Prediction Models, Production, Inventory, Transportation, CO₂ Regulations.

Description:

Economic development and human activities have significantly impacted the environment. To mitigate these effects, governments have implemented policies to control carbon emissions, leading companies to balance profitability with environmental responsibility. This has forced supply chain managers to adjust their strategies, optimizing key aspects such as logistics networks, batch sizes, inventory, vehicle allocation, and factory selection. These decisions are critical to minimizing costs and emissions in the design of a supply chain.

This paper presents an optimization model focused on carbon emissions regulation, designed for multiple periods, levels, and products, to analyze the joint impact of the economic and environmental dimensions. The model is formulated under two scenarios: one without uncertainty and one with uncertainty, integrating predictions to estimate key parameters. A sensitivity analysis compares three types of emissions regulations: carbon tax, emissions cap and cap-and-trade system. The results indicate that the carbon tax is the most economical option but also the most polluting, while the emissions cap is the most effective in reducing pollution, although with higher costs. The cap-and-trade system is located between both, being moderate both in cost and environmental impact. Finally, the model shows greater sensitivity to the emissions cap than to the carbon tax rate, which underlines the importance of strict regulation in reducing emissions.

* Master Thesis.

** Faculty of Physical-Mechanical Engineering. School of Industrial and Business Studies (EEIE).
Master in Industrial Engineering.

First advisor: Henry Lamos Díaz, PhD, in Physics - Mathematics.

Co-advisor: Daniel Orlando Martínez Quezada, M.Sc. in Industrial Engineering.

Generalidades del Proyecto

Título

Modelo analítico con regulaciones de emisiones de carbono en una cadena de suministro con múltiples periodos, niveles y productos

Responsables

Nombre autor: Jeamy Sebastian Tarazona Jiménez

Nombre director: Henry Lamos Díaz

Nombre codirector: Daniel Orlando Martínez Quezada

Grupo de Investigación

Nombre del grupo de investigación: Grupo en Optimización y Organización de Sistemas Productivos, Administrativos y Logísticos – Grupo OPALO.

Director del grupo de investigación: Carlos Eduardo Díaz Bohórquez

Introducción

El cambio climático avanza a un ritmo sin precedentes y afecta a toda la población. La principal causa de este fenómeno es el aumento constante de las concentraciones de Gases de Efecto Invernadero (GEI), con niveles promedio anuales en 2019 de 410 ppm de dióxido de carbono (CO₂), 1866 ppm de metano (CH₄) y 332 ppm de óxido nitroso (N₂O). Estos niveles, atribuibles indiscutiblemente a la actividad humana, tienen efectos significativos sobre la población, el medio ambiente y los recursos naturales. En respuesta, muchos países han implementado mecanismos alineados con los Objetivos de Desarrollo Sostenible y el Acuerdo de París para reducir las emisiones de carbono, uno de los principales GEI (CREE, 2021). Dada la responsabilidad de la industria en las emisiones de CO₂, se han propuesto regulaciones y políticas para reducir la huella ambiental, especialmente en las cadenas de suministro no tradicionales.

Las cadenas de suministro deben adaptarse gradualmente a la implementación de las directrices sobre la regulación del carbono. Sin embargo, esta implementación ha generado desafíos adicionales para las empresas, principalmente relacionados con la gestión de la información y la toma de decisiones operativas. Las decisiones operacionales requieren modelos robustos que integren las regulaciones como restricciones clave. En este contexto, tanto profesionales como investigadores están explorando diversas estrategias para reducir las emisiones de carbono, revisando regulaciones estratégicas y operativas con el fin de mejorar la eficiencia ambiental de sus operaciones y productos, desde su preparación hasta la distribución de los productos terminados a lo largo de la cadena de suministro.

El crecimiento exponencial de estas y sus datos hace que sea relevante el uso de técnicas analíticas que faciliten su recolección y tratamiento. La cantidad de datos a nivel mundial está aumentando rápidamente, impulsada por la expansión del Internet de las Cosas

(IoT) y la creciente conectividad (Mousavi et al., 2020). En este contexto, la analítica de datos desempeña un papel clave al transformar la gran variedad y volumen de información generada por diversas fuentes, tanto internas como externas, en conocimiento valioso. Esto permite optimizar y ajustar con mayor precisión los parámetros utilizados en la modelización matemática de los problemas operativos en la cadena de suministro.

A partir de lo expuesto, esta investigación propone el desarrollo de un modelo de optimización para una red de suministro que abarca múltiples periodos, niveles y productos, con restricciones en las capacidades de producción y un enfoque integral en la minimización del costo total de las operaciones. Además, se incorporan elementos clave de diseño y control, como las regulaciones sobre emisiones de carbono y el uso de modelos de predicción. Este enfoque busca hacer una contribución tanto teórica como metodológica, abordando las siguientes decisiones estratégicas:

- La cantidad de lotes a producir y almacenar en cada periodo.
- La cantidad de vehículos necesarios para cubrir las demandas logísticas.
- La cantidad de carbono a comprar o vender según las regulaciones ambientales y las necesidades operativas de la cadena de suministro.
- La selección de los fabricantes en función de su capacidad y costos.

Asimismo, desde una perspectiva práctica, el modelo propuesto podrá implementarse como una herramienta valiosa para experimentar con diferentes políticas de control de emisiones, facilitando la toma de decisiones en entornos industriales reales. Esto permitirá a las empresas ajustar y optimizar sus estrategias, logrando un equilibrio entre la reducción de costos y la mitigación del impacto ambiental en sus cadenas de suministro.

Finalmente, la estructura del documento es la siguiente: las secciones 1 y 2 presentan los objetivos y la hipótesis; la sección 3 aborda la metodología propuesta; la sección 4 ofrece una revisión de la literatura sobre el tema de investigación; la sección 5 describe la formulación del modelo general propuesto; y la sección 6 detalla la obtención de soluciones a partir del modelo. Las secciones 7 y 8 tratan la experimentación y las conclusiones; mientras que, la sección 9 y 10 presentan, en ese orden, las recomendaciones y referencias bibliográficas del documento.

1. Objetivos

1.1. Objetivo General

Desarrollar un modelo analítico con regulaciones de emisiones de carbono para una cadena de suministro con múltiples periodos, niveles y productos.

1.2. Objetivos Específicos

- Caracterizar la estrategia de modelado a implementar y la estructura asociada al problema objeto de estudio, a través de una revisión de literatura.
- Formular un modelo de optimización con múltiples periodos, niveles y productos para una cadena de suministro verde, basado en los hallazgos encontrados en la literatura.
- Elaborar instancias sintéticas como instrumento de validación para el problema de optimización que contenga parámetros estimados mediante un método predictivo.

2. Hipótesis

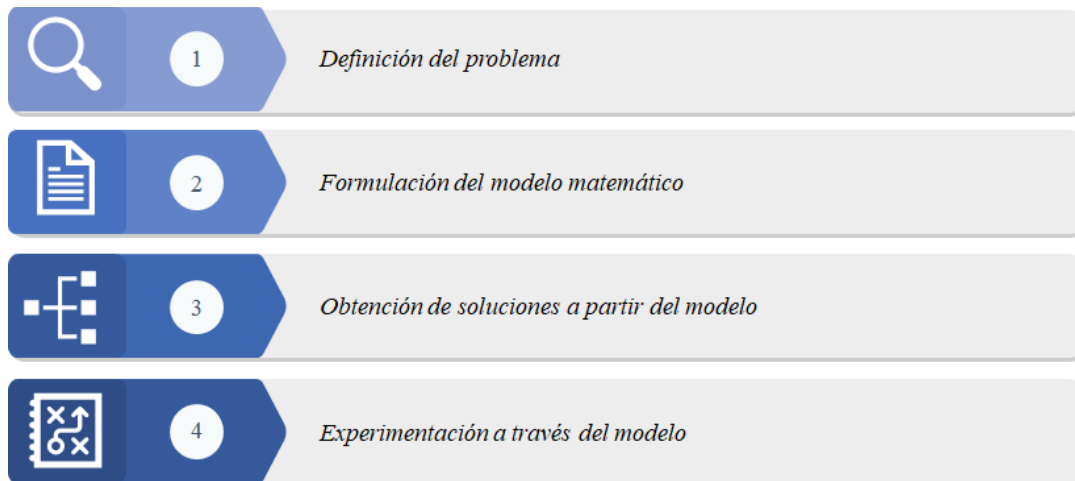
El uso de la analítica de datos mejora la toma de decisiones en los modelos de optimización del problema MLSPAP-PC en una cadena de suministro con regulaciones de emisiones de carbono, en comparación con enfoques tradicionales.

3. Metodología

La investigación presentada en este trabajo se basa en un estudio teórico que requiere el uso de una metodología cuantitativa para alcanzar los objetivos establecidos en la sección 1. Para ello, se ha adoptado una metodología estructurada en torno a un marco de trabajo de cuatro etapas de investigación operativa, adaptado del método científico propuesto por Hillier y Lieberman (2010) para abordar problemas complejos. La Figura 1 presenta las fases metodológicas consideradas, las cuales se explicarán en detalle a continuación.

Figura 1.

Fases metodológicas para el desarrollo de la investigación



3.1. Definición del Problema

Esta primera fase consta de dos etapas. La primera se centra en comprender en profundidad el problema de estudio, así como los modelos de optimización, las técnicas de analítica de datos (AD) integradas en dichos modelos y los métodos de solución aplicados. Para alcanzar este objetivo, se llevan a cabo las siguientes actividades clave:

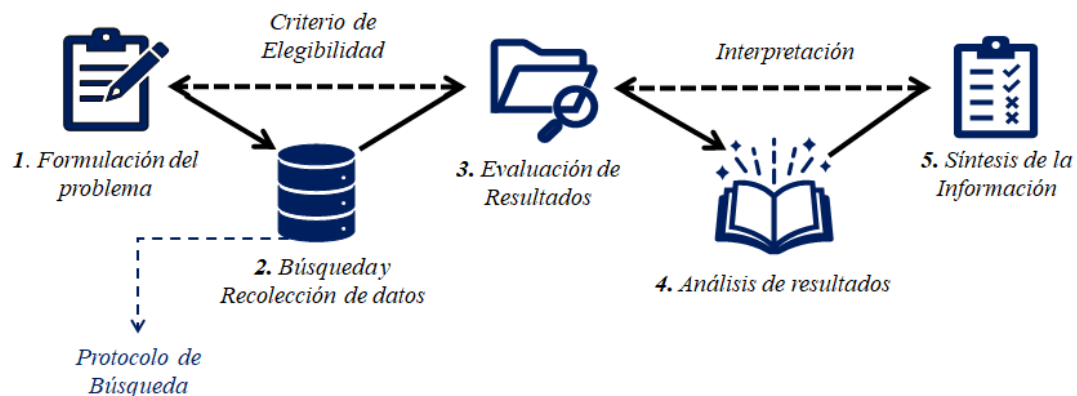
- Realización de una revisión de la literatura, seleccionando bibliografía en bases de datos y otras fuentes relevantes sobre los modelos de optimización aplicados al problema PIT en una cadena de suministro con regulaciones de carbono.

- Identificación de la literatura las técnicas de analítica de datos (AD) utilizadas en los modelos de optimización (MO) y de los métodos de solución aplicados.

Tras completar la primera etapa, se procede a la segunda, en la que se establecen los insumos necesarios para su desarrollo, siguiendo la siguiente estructura:

- Definir, a partir de la revisión, los elementos que componen el problema PIT y su estructura bajo las regulaciones de CO₂.
- Identificar los atributos y las estrategias de modelamiento a implementar en la construcción del modelo matemático.
- Revisar las posibles políticas de regulación de carbono que permitan evaluar el impacto de los costos en las operaciones de producción, inventario o transporte mediante el modelo de optimización.

Figura 2.
Metodología aplicada en la revisión de literatura



Para lograr este objetivo, la revisión seguirá una adaptación de la metodología propuesta por Randolph (2009) (ver Figura 2), que consta de cinco etapas. Estas etapas permitirán formular el problema y recopilar información relevante mediante un protocolo de búsqueda, así como evaluar, analizar, interpretar y sintetizar los hallazgos obtenidos.

3.2. Formulación del Modelo Matemático

Una vez finalizada la fase anterior y considerando los hallazgos obtenidos, se procede a la construcción del modelo matemático que representa el núcleo del problema de investigación. Para ello, es fundamental definir una serie de parámetros de entrada que incluyan la toma de múltiples decisiones y las políticas regulatorias sobre emisiones de carbono (EC) involucradas. A partir de esto, se deben seguir los siguientes pasos:

- Comprender los fundamentos teóricos de los modelos analíticos aplicados a las cadenas de suministro con regulaciones de emisiones de carbono, lo que permitirá definir los parámetros de entrada relacionados con la integración de la analítica de datos y las regulaciones de emisiones de carbono (REC) a considerar.
- Definir los criterios de asignación y evaluación del modelo matemático.
- Determinar el número de fabricantes, productos, vehículos y periodos necesarios para la construcción de la red PIT.
- Construcción del modelo matemático para el problema PIT bajo regulaciones de carbono, definiendo la función objetivo, las variables de decisión y las familias de restricciones.

3.3. Obtención de Soluciones a partir del Modelo

Para abordar el problema planteado en esta investigación, es necesario codificar las distintas etapas del modelo de decisión y seleccionar un software que permita integrar los criterios establecidos para resolver el modelo matemático. El software elegido es Python¹ como el

¹ Lenguaje de programación ampliamente utilizado en las aplicaciones web, el desarrollo de software, la ciencia de datos y el Machine Learning (ML).

entorno de solución. A continuación, se detallan los pasos a seguir para resolver el problema de estudio:

- Analizar el entorno de solución y las bases teóricas de los métodos disponibles, seleccionando el que mejor se ajuste al modelo propuesto.
- Implementar la técnica de solución seleccionada en el modelo de optimización utilizando el lenguaje de programación Python.

Finalmente, además de la codificación del modelo propuesto, esta fase incluye la calibración y ajuste de los parámetros de entrada, los cuales se obtienen de un conjunto de datos previamente identificados en la literatura. Una vez definidos, se codifican y prueban todos los pasos del método de solución para verificar su correcto funcionamiento. Los resultados se evalúan con base en la función objetivo, las variables de decisión y las familias de restricciones, garantizando así la operatividad del modelo.

3.4. Experimentación a través del Modelo

Una vez completadas las fases anteriores, se evalúa el impacto en el costo total de las operaciones al considerar las políticas de regulación de carbono propuestas en la literatura, las cuales constituyen el criterio de optimización del modelo. Esto permite identificar las mejores configuraciones para las operaciones de producción, inventario y transporte (PIT), así como en los eslabones de la cadena de suministro objeto de estudio. Las conclusiones se derivan de la hipótesis planteada en la sección 2. Para llevar a cabo este análisis, se propone lo siguiente:

- Evaluar los parámetros del modelo mediante un análisis de sensibilidad de los resultados obtenidos a partir del modelo propuesto.
- Comparar el rendimiento de las soluciones para el problema PIT a través de diferentes escenarios y tamaños, manteniendo las mismas condiciones.

4. Revisión de la Literatura

Las regulaciones de carbono han surgido como respuesta a la necesidad de implementar políticas que promuevan la conservación del medio ambiente. Al mismo tiempo, las organizaciones enfrentan diversos desafíos, como la excesiva dependencia de energías no renovables, que liberan grandes cantidades de dióxido de carbono (CO₂) y contribuyen directamente al calentamiento global y al cambio climático. Para reducir esta dependencia y mitigar las emisiones de carbono (EC), la gestión de emisiones en las cadenas de suministro se ha convertido en una estrategia clave para enfrentar los desafíos relacionados con la toma de decisiones estratégicas y tácticas, enfocadas en la eficiencia y sostenibilidad de las operaciones. En este contexto, la aplicación de modelos de optimización se ha vuelto esencial para tomar decisiones informadas, respaldadas por la analítica de datos en las cadenas de suministro.

Este apartado introduce los principales conceptos relacionados con el diseño de redes de suministro, con un enfoque en las regulaciones de carbono. Además, se analizan algunos modelos aplicados a las operaciones de Producción, Inventario y Transporte (PIT) que incorporan políticas de carbono y analítica de datos, los cuales constituyen los problemas centrales de esta investigación. Finalmente, se presenta un análisis bibliométrico de la literatura asociada, disponible en el Apéndice A, que confirma el interés de la comunidad científica en este tema e identifica a los principales autores, países y fuentes de información, evaluados mediante dos métricas clave: publicaciones y citas recibidas.

4.1. Protocolo de revisión

El protocolo de la revisión preliminar de la literatura se estructura en tres etapas principales: búsqueda, criterios de inclusión y exclusión, y el análisis y presentación de los artículos.

Protocolo de búsqueda: La búsqueda de información se realizó identificando términos clave asociados al proyecto de investigación. Los términos utilizados fueron: “Supply Chain”, “Carbon Emission”, “CO₂”, “Data Analytics” y “Big Data”, así como palabras relacionadas o sinónimos. Las ecuaciones de búsqueda se construyeron utilizando operadores booleanos y truncadores (ver Apéndice B) y se implementaron en las bases de datos Web of Science (WOS) y Scopus. Además, se incluyeron documentos relevantes mediante la metodología de bola de nieve, aplicando los criterios de inclusión y exclusión definidos.

Criterios de inclusión y exclusión: Se incluyeron artículos y capítulos de libros registrados en la plataforma virtual de WOS y otras bases de datos consultadas, dentro del periodo 2013-2023, y que estuvieran redactados en inglés y español. Se excluyeron aquellos documentos que no estuvieran relacionados con enfoques matemáticos en ingeniería, la toma de decisiones, o que no fueran relevantes para el proyecto.

Análisis y presentación de artículos: Se realizó una revisión manual de los títulos y resúmenes de los documentos obtenidos en cada base de datos. Tras este proceso, se revisaron los documentos no excluidos según el criterio del investigador, para identificar y eliminar posibles duplicados entre ambas bases de datos. Esto permitió generar un conjunto de documentos sin repeticiones y proceder con la revisión de la literatura.

4.2. Marco de Gestión de la Cadena de Suministro bajo Emisiones de Carbono

Es vital hacer hincapié en la Gestión de la Cadena de Suministro (GCS) para comprender el interés en las mismas. El CSCMP² la define como “un esfuerzo global de colaboración entre

² Council of Supply Chain Management Professionals: Consejo de Profesionales de Gestión de la Cadena de Suministro (CSCMP) ha sido la asociación profesional mundial preeminente dedicada al avance y la difusión de la investigación y el conocimiento sobre la gestión de la cadena de suministro (“Council of Supply Chain Management Professionals (CSCMP),” 2019).

proveedores, productores, almacenes, centros de distribución, mayoristas y minoristas, cuyo objetivo es reducir costos y mejorar el rendimiento operativo” (CSCMP, 2022). La GCS requiere una amplia variedad de métodos y principios. Una manera efectiva de descomponer su análisis es dividirla en dos subáreas principales: el diseño de la cadena de suministro (DCS) y la ejecución u operaciones de la cadena de suministro (ECS). El DCS se centra en definir la estructura de la cadena de suministro, abarcando elementos como instalaciones de producción, centros de distribución, modos y rutas de transporte, y procesos de fabricación, necesarios para satisfacer la demanda de los clientes. Estos análisis tienen un enfoque estratégico, cubren un horizonte temporal de meses o años, y generalmente se basan en datos con poca incertidumbre (Harrison, 2001).

Dada la importancia del diseño de la cadena de suministro (DCS) en las compañías, existe una amplia variedad de modelos que se enfocan en distintas partes de la cadena de suministro. Estos modelos matemáticos se utilizan principalmente para determinar variables como la cantidad de material específico requerido por cada fábrica según el número de proveedores, la cantidad de productos que se envían de la fábrica al centro de distribución y del centro de distribución al cliente, la capacidad de producción por fábrica, los costos asociados a las fábricas y centros de distribución, la cantidad de inventario a almacenar y la cantidad de productos a transportar, entre otros. Sin embargo, debido a la creciente preocupación ambiental derivada de la industrialización, se ha vuelto necesario incorporar otros aspectos, como las normativas sobre el impacto del cambio climático (Robles-Obando, 2017). En su investigación, Abbasi y Ahmadi Choukolaei (2023) presentan las principales políticas sobre emisiones de carbono, que han recibido considerable atención en los últimos años. Estas políticas se resumen en la Tabla 1.

Tabla 1.*Principales regulaciones de carbono*

Tipo de regulación	Descripción
Impuesto sobre el carbono	Es un impuesto ambiental que se aplica a las emisiones de CO ₂ , obligando a los contaminadores a pagar en proporción a sus emisiones.
Limitación de carbono	Establece un límite a la cantidad de CO ₂ que las empresas pueden emitir a la atmósfera.
Tope y comercio de carbono	Impone un límite máximo de emisiones para las empresas, permitiendo la compra y venta de derechos de emisión. Las empresas pueden ser compensadas por reducir sus emisiones o penalizadas por excederlas.

4.2.1. Impuesto sobre el Carbono

Los impuestos sobre el carbono en las cadenas de suministro son una herramienta de política pública destinada a reducir las emisiones. Por ejemplo, Fahimnia et al., (2014) proponen un modelo Programación Lineal Entera Mixta (MILP) que considera diversos factores, como los precios del combustible y del carbono, las emisiones asociadas con la producción y el transporte, así como las restricciones operativas y ambientales. Analizan el aumento en el costo total de la cadena de suministro y descubren que este permanece constante cuando el impuesto sobre el carbono varía entre 30 y 40 dólares por tonelada.

Asimismo, Marufuzzaman et al. (2014) presentan un modelo de optimización biobjetivo, que minimiza tanto los costos como las emisiones de carbono (EC), resuelto mediante el método de suma ponderada. Concluyen que un impuesto de entre 0 y 2,5 dólares por tonelada afecta la producción de biodiésel, y sugieren que incluir las EC en la planificación y diseño de la cadena de suministro puede beneficiar tanto al medio ambiente como a los costos operativos. También examinan la viabilidad de utilizar tecnologías bajas en emisiones, destacando que los beneficios son significativos cuando el impuesto sobre el carbono alcanza los 5000 \$/ton. De manera similar, Zakeri et al. (2015) presentan un modelo analítico basado en datos reales que inicialmente muestra una relación lineal entre el aumento de los costos de la cadena de

suministro y la reducción de emisiones. Sin embargo, concluyen que el comportamiento de las emisiones es errático y no lineal. El estudio revela una mejora significativa antes de alcanzar los 5 dólares australianos (AUD) por tonelada de emisiones, pero esta mejora no se manifiesta nuevamente hasta que el impuesto sobre el carbono alcanza los 50 AUD/ton.

Además, Peng et al. (2016) abordan un modelo matemático para minimizar las emisiones de carbono en el diseño de la red de distribución, considerando tanto la rentabilidad económica como el problema de las emisiones de carbono. Concluyen que, a partir de un impuesto de 0,6 ¥ por kilogramo de carbono, las emisiones comienzan a disminuir. Sin embargo, identifican un punto crítico, cercano a los 2,5 ¥/kg, en el que las emisiones se estabilizan y dejan de reducirse significativamente, a pesar del aumento en los costos totales.

De manera complementaria, Cao et al. (2019) proponen un modelo matemático no lineal para evaluar el beneficio global de la cadena de suministro, maximizando las ganancias de las empresas y considerando los efectos de los subsidios de remanufactura y los impuestos sobre el carbono. Los autores destacan que el impuesto sobre el carbono es más efectivo para reducir emisiones y mejorar el impacto ambiental general. Por su parte, los autores Zou et al. (2020) aplican la teoría de juegos de Stackelberg, lo que permite formular un modelo no lineal como un juego de decisiones bajo competencia. Este enfoque busca maximizar los beneficios tanto para minoristas como para fabricantes, mientras se promueve la reducción de emisiones dentro de la cadena de suministro. Mediante gráficos y análisis numérico, encuentran que, cuando el costo de reducción de emisiones es bajo para los fabricantes, estos están dispuestos a reducir sus emisiones. Además, un aumento en el impuesto sobre el carbono y en el precio de los permisos de emisión promueve una mayor reducción de emisiones, beneficiando tanto a los fabricantes como a los minoristas; Cadavid-Giraldo et al. (2020) proponen una formulación lineal entera mixta para una cadena de suministro en la industria cementera; sus resultados

indican que la tasa de impuesto sobre el carbono debería estar entre 15 y 150 dólares estadounidenses por tonelada. Finalmente, Guo y Xi en 2022 examinan una cadena de suministro verde de tres niveles, utilizando un modelo de juego de decisión secuencial bajo la regulación del impuesto sobre el carbono. A través de simulaciones numéricas y un análisis de inducción hacia atrás, realizan un análisis de sensibilidad de los parámetros que influyen en el rendimiento del sistema, apoyándose en los equilibrios de Nash.

4.2.2. Limitación de Carbono

Un límite de carbono es un presupuesto de emisiones asignado a las empresas por las autoridades reguladoras (Ruggieri et al., 2023). Diversos investigadores afirman que esta política es comparable en términos de eficiencia a otras políticas relacionadas con el carbono y, además, ofrece resultados superiores (Marufuzzaman et al., 2014; Mohammed et al., 2017). La primera referencia a las limitaciones de carbono se hizo en la Ley de Aire Limpio de EE. UU. de 1970, la cual restringía las emisiones tanto a nivel federal como estatal (Z. G. Tao et al., 2015). Aunque la elección de un límite de carbono puede ser compleja debido a la imprevisibilidad futura, suele basarse en las emisiones actuales o históricas. Algunas empresas deciden establecer un tope interno como un símbolo de cumplimiento ambiental. La modelización de este enfoque implica imponer un límite superior a las emisiones (Kumar et al., 2014).

Dado que esta estrategia se basa en la imposición de un límite a las emisiones de carbono (EC), es fundamental que dicha restricción se mantenga para que sea efectiva en la reducción de las EC. Varios autores han establecido un máximo de emisiones de CO₂ tanto para los bienes fabricados como para los reciclados, fijando un límite que permita realizar actividades industriales como la producción, almacenamiento y transporte. Las investigaciones relacionadas

con estas operaciones en el diseño de redes de cadenas de suministro se resumen en la Tabla 2, que proporciona información adicional sobre estudios relevantes en este campo. No obstante, es importante destacar que los límites de emisiones varían según la industria estudiada.

Tabla 2.

Estudios complementarios de limitación de carbono

Investigación	Operaciones en la CS	Límites de Emisiones
(Choudhary et al., 2015)	Producción, Inventario y Transporte	Entre 700 y 2100 [ton]
(Peng et al., 2016)	Almacenamiento y Transporte	Entre 0 y 3 [ton]
(Mohammed et al., 2017)	Producción, Almacenamiento, Reciclaje y Transporte	Entre 50 y 53 [ton]
(Sinha y Chaturvedi, 2019)	Producción, Distribución y Logística, y Uso final del producto	Entre 0 y 3371.8 [ton]
(Cadavid-Giraldo et al., 2020)	Producción y Transporte	Inferior a 500 [kg por ton]

Para este tipo de política de carbono, Martí et al. (2015) proponen un modelo MILP para el diseño de redes de cadena de suministro que abarca operaciones asociadas con materias primas, producción, almacenamiento y transporte, considerando la incertidumbre en la demanda y las decisiones sobre la capacidad de respuesta bajo diferentes políticas con o sin límites de huella de carbono. El estudio también realiza un análisis comparativo entre diferentes tipos de productos (funcionales e innovadores). Otros investigadores han abordado las cadenas de suministro con limitaciones de carbono, proporcionando reflexiones significativas. Por ejemplo, Benjaafar et al., (2013); Z. G. Tao et al., 2015; Zhao et al., (2017) han explorado la noción de límites globales o secuenciales de emisiones. Zhao y su equipo, a través de un modelo de equilibrio en una red de cadena de suministro de ciclo cerrado, concluyen que un límite global de carbono, que abarque toda la cadena de suministro, genera mejores resultados. Su análisis numérico revela que esta opción tiene un impacto más positivo en el equilibrio del sistema. Tao et al. también destacan que un límite global es ideal cuando las emisiones de carbono son excesivamente altas.

Por otro lado, Benjaafar et al. (2013) sugieren que un límite periódico de emisiones, más estricto, conduce a menores emisiones sin un aumento considerable en los costos, gracias a los ingresos adicionales generados por la venta de créditos de carbono bajo la política de tope y comercio. La política de limitación de carbono ha sido ampliamente estudiada y se reconoce que los límites máximos asociados a las emisiones de CO₂ contribuyen significativamente a la reducción de la contaminación ambiental en las cadenas de suministro. Wang et al. (2018) modelan límites de carbono en servicios logísticos refrigerados, mientras que Kushwaha et al., (2020) los aplican en la recolección de productos usados dentro de una cadena de suministro inversa en varias regiones geográficas. Astanti et al. (2022), por su parte, integran el límite de carbono en un modelo de inventario para mejorar el rendimiento ecológico, considerando factores como el deterioro del producto y los problemas de calidad.

A su vez, Peng et al. (2016) establecen límites a las emisiones del transporte en función de los niveles de inventario, el peso y la distancia recorrida de los productos. De manera similar, Zhou et al. (2017) consideraron las emisiones de CO₂ durante las operaciones de transporte y montaje de materiales en una fábrica internacional de computadoras. Otros investigadores, como S. Zhang et al. (2019), analizaron el impacto de las estructuras de poder en una cadena de suministro de dos niveles (Manufacturer Stackelberg - MS, Retail Stackelberg - RS y Vertical Nash - VN) que emplea dos estrategias de fabricación: adopción de tecnología verde (TV) y compra de créditos de carbono (CCC). Encontraron que el límite de emisiones de carbono impuesto por el gobierno tiene un impacto significativo en las decisiones del fabricante en cuanto a producción, abastecimiento y emisiones. En particular, cuando el límite de emisiones es más estricto, los fabricantes están más incentivados a adoptar tecnología verde y reducir las emisiones de carbono. Cadavid-Giraldo et al. (2020) también destacan la importancia de implementar prácticas sostenibles de producción a través de un enfoque matemático. En su

estudio, evaluaron el impacto de estas prácticas en una cadena de suministro del sector cementero. Sus hallazgos indican que un sistema basado en un límite y una tasa puede ser eficaz para reducir las emisiones de carbono en la industria. Sin embargo, subrayan la necesidad de realizar más investigaciones a nivel sectorial y regional para ajustar una política de precios capaz de inducir reducciones de emisiones dentro de un marco financiero viable.

4.2.3. *Tope y Comercio de Carbono*

El sistema de tope y comercio se basa en la compra y venta de créditos de carbono en mercados regulados externamente. En esencia, cada participante recibe un número de créditos gratuitos que representan su límite de emisiones para un periodo específico. Si una empresa emite menos de su tope, los créditos restantes pueden venderse en el mercado. Los programas de comercio de derechos de emisión están más motivados por los ingresos o compensaciones que otras regulaciones sobre el carbono, y se centran en las emisiones cuantificables de la industria y el transporte. Algunas investigaciones relevantes sobre tope y comercio incluyen: la programación lineal entera, Xu et al. (2016), para producción; Diabat et al. (2013) en distribución; Kannan et al. (2012) con un modelo lineal entero mixto; X. Li et al. (2017); y Rezaee et al. (2017), quienes proponen un modelo estocástico que incluye las emisiones del transporte.

El sistema de tope y comercio no solo motiva ingresos, sino que también impulsa objetivos medioambientales y sociales, influyendo en decisiones estratégicas. Li et al. (2017), proponen un modelo MILP para una cadena de suministro de dos niveles en la construcción, que considera costos operativos, de transporte y de emisiones bajo una política de tope y comercio. Además, Qi et al. (2017) presentan un modelo que integra inventario y enrutamiento, minimizando emisiones de CO₂ y costos operativos a lo largo de la cadena de suministro.

Otros autores que utilizan la regulación de tope y comercio incluyen a X. Xu et al. (2017), quienes coordinan una cadena de suministro MTO (Make-to-Order) compuesta por un fabricante y un minorista, utilizando tecnología verde para reducir las emisiones de carbono. Asimismo, X. Xu y Choi. (2021) investigaron el impacto del uso de la tecnología *Blockchain* en las operaciones de una cadena de suministro con plataformas en línea, bajo la regulación de tope y comercio de carbono. Por su parte, X. Wang et al. (2022) analizaron una cadena de suministro de dos períodos, también compuesta por un fabricante y un minorista. Su estudio, basado en un modelo no lineal centrado en maximizar las ganancias y las decisiones estratégicas de los actores de la cadena, considerando la compra y venta de permisos de emisión dentro del esquema de tope y comercio. Como resultado, encontraron que la coordinación entre los miembros de la cadena de suministro es clave para mejorar la eficiencia y el bienestar social.

4.3. Analítica de Datos en la Cadena de Suministro

El campo del Análisis de Datos (AD) o Análisis de Big Data (ABD) se enfoca en la aplicación de técnicas avanzadas para evaluar grandes volúmenes de datos no estructurados. Estas técnicas incluyen métodos predictivos, estadísticas, minería de datos (MD), inteligencia artificial (IA), optimización matemática y modelado por simulación, entre otros. La analítica de datos se ha convertido en una herramienta clave para empresas y organizaciones, permitiéndoles comprender mejor a sus consumidores y operaciones. A través de ella, pueden identificar patrones y tendencias en grandes conjuntos de datos y utilizar esos conocimientos para optimizar sus procesos comerciales (Werneck Barbosa et al., 2017).

Al revisar la literatura disponible para este trabajo académico, se identifican varias maneras de clasificar los enfoques de ABD (Análisis de Big Data). Las tres categorías principales, basadas en la naturaleza y el objetivo de su uso, son: análisis descriptivo, predictivo

y prescriptivo (Wang, 2015). Sin embargo, los tipos de análisis son variados y pueden dividirse en numerosos métodos y submétodos, los cuales pueden aplicarse de manera independiente o combinada. Según Chehbi-Gamoura et al. (2019), existe una jerarquía integral y completa de técnicas de análisis de datos, la cual se detalla a continuación y sigue un modelo estructurado y exhaustivo.

4.3.1. *Análisis Exploratorio de los Datos (AED)*

El Análisis Exploratorio de Datos (AED) se encarga de determinar cómo manejar y estructurar los datos, para luego seleccionar el método más adecuado para comunicarlos y adaptarlos desde una perspectiva comercial (Zhao et al., 2017). Este proceso implica la implementación de una serie de submétodos, que se dividen en cuatro grandes grupos, como se observa en la Tabla 3.

Tabla 3.
Grupo de submétodos de AED

Categoría	Finalidad	¿Como?
Descubrimiento y Visualización de Datos (DVD)	Revelación de Información Oculta	Consultar, filtrar, Simplificar y Detectar
Análisis Predictivo de Datos (APD)	Gestión Predictiva	Extrapolar, Pronosticar y Predecir
Métodos de Reducción de Datos (DRM)	Formas de Transformación y Simplificación	Evaluar, Tender y Transformar
Método de Deducción de Datos (MDD)	Toma de Decisiones	Analizar, Regular y Seleccionar

4.3.2. *Descubrimiento y Visualización de Datos (DVD)*

Según el investigador Bendoly (2016), el Descubrimiento y Visualización de Datos (DVD) es crucial para el avance del análisis de datos moderno, ya que permite identificar relaciones ocultas que no se detectan fácilmente mediante suposiciones o métodos tradicionales. El DVD proporciona marcos que facilitan el ajuste y la interpretación continua de las operaciones, especialmente en la Gestión de la Cadena de Suministro (GCS). Además, se

emplean algoritmos de Regresión (REG) en el aprendizaje automático y la estadística, como lo muestra el estudio de Zhao et al. (2017), que utiliza un modelo de optimización multiobjetivo en la GCS Verde para reducir riesgos, emisiones de carbono y costos económicos. Otros trabajos, como los de Zhong et al. (2016), emplean el modelo RFID-Cuboid para reconstruir datos RFID basados en series temporales y la producción en la nube, mientras que Brito et al. (2015) utilizan técnicas de Minería de Datos (MD), como 1-K-Medoids y CN2-SD, en la segmentación de clientes, optimizando la respuesta a las preferencias de los consumidores y ganando ventaja competitiva, especialmente en la producción personalizada.

4.3.3. *Análisis Predictivo de Datos (APD)*

El estudio de Gunasekaran et al. (2017) subraya la importancia de integrar la asimilación de Big Data (BD), el análisis predictivo (AP) y el análisis de datos avanzados (ADA) para pronosticar el rendimiento organizacional y de la cadena de suministro (PCS). Esta investigación destaca cómo la analítica de datos puede coordinar recursos y generar una ventaja competitiva en las empresas. Entre los métodos representativos del APD se encuentran la regresión, los árboles de decisión, las estadísticas bayesianas, las redes neuronales, las máquinas de vectores de soporte (MVS) y el vecino más cercano (Duan y Xiong, 2015).

Por otro lado, Schildbach y Morari (2016) proponen un esquema de control predictivo de modelos basado en escenarios (ECPMBE) para la gestión de la cadena de suministro (GCS) con múltiples niveles. Este enfoque es capaz de gestionar la incertidumbre en la planificación estocástica, asegurando un nivel de servicio al cliente predefinido y proporcionando una solución eficiente desde el punto de vista computacional, comparable a la optimización determinística. Finalmente, Jeble et al. (2018) destacan que el uso de Big Data y análisis predictivo puede mejorar la sostenibilidad en la gestión de la cadena de suministro al facilitar

una mejor planificación y toma de decisiones. En su estudio, demostraron que este tipo de análisis puede predecir la demanda futura, optimizar las rutas de transporte y reducir los residuos. El modelo, desarrollado con la lógica basada en recursos (LBR) y la teoría de contingencia (TC), fue probado utilizando MCP-MEE (Mínimos Cuadrados Parciales - Modelado de Ecuaciones Estructurales).

4.3.4. *Métodos de Reducción de Datos (MRD)*

Las técnicas de reducción de datos (DRM, por sus siglas en inglés) constituyen un área clave dentro del análisis exploratorio de datos (EDA). Estas técnicas consisten en una serie de procedimientos que transforman los datos brutos en formas más simples, categorizadas y reformateadas para facilitar la extracción de información útil (J. Li et al., 2015). En el contexto de la gestión de la cadena de suministro (GCS), el DRM utiliza metodologías especializadas para alcanzar varios objetivos, como reducir costos de servicio, mejorar la confianza entre clientes y empresas, preservar la privacidad, permitir el intercambio seguro de datos y delegar a los clientes el control de dicho intercambio.

Asimismo, Rehman et al. (2016), proponen tres capas para la reducción de datos: local, colaborativa y remota. La reducción local se lleva a cabo en dispositivos móviles, donde las aplicaciones recopilan, procesan y almacenan patrones de conocimiento. La reducción colaborativa implica la interacción entre dispositivos móviles y servidores en la nube para un análisis más profundo. Finalmente, la reducción remota se refiere a la transferencia de datos a servidores en la nube para su almacenamiento y análisis, facilitada por sistemas de localización en tiempo real, como la identificación por radiofrecuencia (IRF) para la gestión de activos (D. Zhang et al., 2016).

También los investigadores F. Tao et al., 2018 analizan el uso de tecnologías de análisis de Big Data para gestionar grandes volúmenes de datos, implementando una producción inteligente basada en el modelo autorregresivo ARIMA³ para predecir el consumo de energía en la fabricación. Este modelo apoya el marco conceptual de la fabricación inteligente impulsada por datos, que incluye cuatro módulos: el de fabricación, el de datos, el de monitorización en tiempo real y el de procesamiento de problemas.

4.3.5. Métodos de Deducción de Datos (MDD)

El MDD es una técnica utilizada en el análisis de datos que se basa en formular hipótesis y aplicar reglas de razonamiento inductivo para extraer conclusiones a partir de datos existentes (Alles, 2015; Baars et al., 2014). La calidad de los datos desempeña un papel crucial, ya que datos de baja calidad pueden llevar a decisiones empresariales erróneas, ocasionando pérdidas tanto tangibles como intangibles. Los autores Hazen et al. (2014) proponen métodos de control de calidad de datos, como los gráficos de control estadístico (GCE), que permiten monitorear la calidad de los datos en tiempo real, detectando desviaciones o errores y mejorando así la calidad de los productos basados en estos datos. Además, los autores promueven la colaboración interdisciplinaria para desarrollar métodos efectivos de control de calidad y estudiar el impacto de los datos en los resultados empresariales.

En cuanto a otras estrategias relacionadas con el MDD, destacan las reglas de asociación (RA). Kache y Seuring (2017) examinaron su aplicación en la logística de plantas,

³ Modelo estadístico utilizado para analizar y predecir series de tiempo. Este se compone de tres partes: la parte autorregresiva (AR), la parte integrada (I) y la parte de media móvil (MA). El modelo ARIMA es muy sensible a la precisión con que se determinen sus coeficientes. Se suele expresar como ARIMA(p,d,q) donde los parámetros p, d y q son números enteros no negativos que indican el orden de las distintas componentes del modelo (IBM, 2021).

subrayando la transición de un entorno corporativo analógico a uno digital. En su estudio, identificaron 43 oportunidades y desafíos empresariales relacionados con la implementación de Big Data Analytics en la cadena de suministro.

4.4. Discusión de la Revisión de Literatura

Con base en la revisión de la literatura realizada, esta investigación se fundamenta en los siguientes elementos:

- **Decisiones de diseño:** La literatura destaca investigaciones sobre cadenas de suministro no tradicionales que incorporan políticas como el impuesto sobre el carbono, el límite de emisiones de carbono, y el esquema de tope y comercio. Estas políticas se han modelado utilizando Programación Lineal Entera Mixta (MILP) con uno o dos objetivos. No obstante, la mayoría de los estudios han abordado una o dos de estas políticas simultáneamente y han utilizado enfoques matemáticos o analíticos, sin aprovechar la abundancia de datos generados en los procesos de gestión de la cadena de suministro, como la predicción de la demanda.

Por ello, resulta esencial desarrollar modelos matemáticos basados en analítica de datos que integren las tres políticas de emisiones de carbono, proporcionando un análisis más exhaustivo. La presente investigación surge de esta necesidad, subrayando la importancia teórica de proponer un modelo de optimización respaldado por análisis de datos que incorpore tanto los costos ambientales (como las emisiones de carbono) como la gestión de la cadena de suministro en múltiples periodos.

- **Decisiones de control:** Las áreas más investigadas en la cadena de suministro incluyen operaciones de producción/fabricación, transporte y, en menor medida, almacenamiento/inventario, destacando el rendimiento ecológico de esta última y su papel

crucial en la planificación de la cadena de suministro. Con base en ello, se propone desarrollar un modelo matemático que integre las operaciones de producción, inventario y transporte, considerando también otras decisiones de control identificadas en la literatura. Este enfoque, que combina analítica de datos y regulaciones de CO₂ de manera simultánea, hace que el proyecto sea innovador, ya que ha sido poco explorado en investigaciones anteriores.

- **Medidas de desempeño:** Según los estudios revisados, la métrica más comúnmente empleada para evaluar las cadenas de suministro es el costo total. No obstante, otras métricas también pueden ser relevantes, como la utilidad, los gastos operativos, los costos asociados a la producción, los relacionados con los centros de distribución, el volumen de inventario a almacenar, la cantidad de productos a transportar y los impactos financieros derivados de las emisiones de CO₂.

5. Formulación del Modelo Analítico General MLSPAP-PC

El modelo analítico propuesto en esta investigación se compone de dos partes integradas que trabajan en conjunto: la primera define el problema central y desarrolla el modelo de optimización, mientras que la segunda incorpora modelos de predicción para gestionar la incertidumbre en las entradas clave del sistema. Estas dos partes se combinan para formar un modelo general que implementa las tres regulaciones de carbono y abarca las operaciones de producción, inventario y transporte en una cadena de suministro de dos eslabones con múltiples periodos, niveles y productos.

Para asegurar que los datos empleados en el modelo de optimización sean precisos y representen la realidad de manera confiable, los modelos de predicción fueron calibrados y evaluados mediante métricas como el coeficiente de determinación R^2 , la raíz del error

cuadrático medio (RMSE), el error cuadrático medio (MSE) y el error absoluto porcentual medio (MAPE). Estas métricas permiten evaluar la calidad de las predicciones y, en consecuencia, reducir la incertidumbre en los parámetros del modelo de optimización. La integración de modelos de predicción en el modelo de optimización es crucial, ya que proporciona una base de datos más confiable y precisa, lo cual resulta en decisiones óptimas más realistas y efectivas en la práctica. Este enfoque permite que el modelo responda mejor a la variabilidad del sistema y a las regulaciones de carbono, fortaleciendo la solidez y relevancia de las soluciones. Las siguientes secciones describen el problema, la formulación del modelo de optimización y los modelos de predicción empleados en la construcción del modelo analítico general.

5.1. Descripción del Problema

El problema planteado se enfoca en la Gestión de la Cadena de Suministro (GCS), abordando su diseño desde una perspectiva integral que considera múltiples fabricantes, productos, tipos de vehículos y periodos. Este enfoque cubre los eslabones de procesamiento/fabricación y distribución, abarcando la toma de decisiones tanto estratégicas como tácticas (ver Figura 3). Además, tiene en cuenta las emisiones generadas por los procesos de producción, pedido, mantenimiento de inventarios y transporte. El estudio considera el impuesto sobre el carbono (1^a), la limitación estricta de las emisiones (2^a), y el comercio de carbono (3^a), las cuales son las tres principales políticas de regulación de las emisiones de carbono que se toman en consideración en la literatura (Astanti et al., 2022; Guo y Xi, 2022; Wang et al., 2022). La primera política impone un impuesto por cada unidad de carbono emitida, mientras que la segunda establece un límite estricto a las emisiones de carbono en las distintas operaciones de la cadena de suministro (producción, inventarios, transporte, etc.). La

tercera política, de comercialización de emisiones, también fija un tope a las emisiones totales, pero permite intercambiar los excesos o ahorros de carbono a lo largo del tiempo.

5.2. Modelo de Optimización

El objetivo principal del estudio es optimizar la asignación de pedidos a los fabricantes en cada periodo, considerando diversas opciones de transportistas. La optimización busca minimizar los costes totales de la cadena de suministro, incluyendo tanto los costes tradicionales (producción, almacenamiento, transporte) como los costes ambientales asociados a las emisiones de carbono generados a partir de estas operaciones.

5.2.1. Supuestos del Modelo de Optimización

Con el fin de describir el problema con mayor claridad, el modelo matemático planteado se soporta bajo los siguientes supuestos:

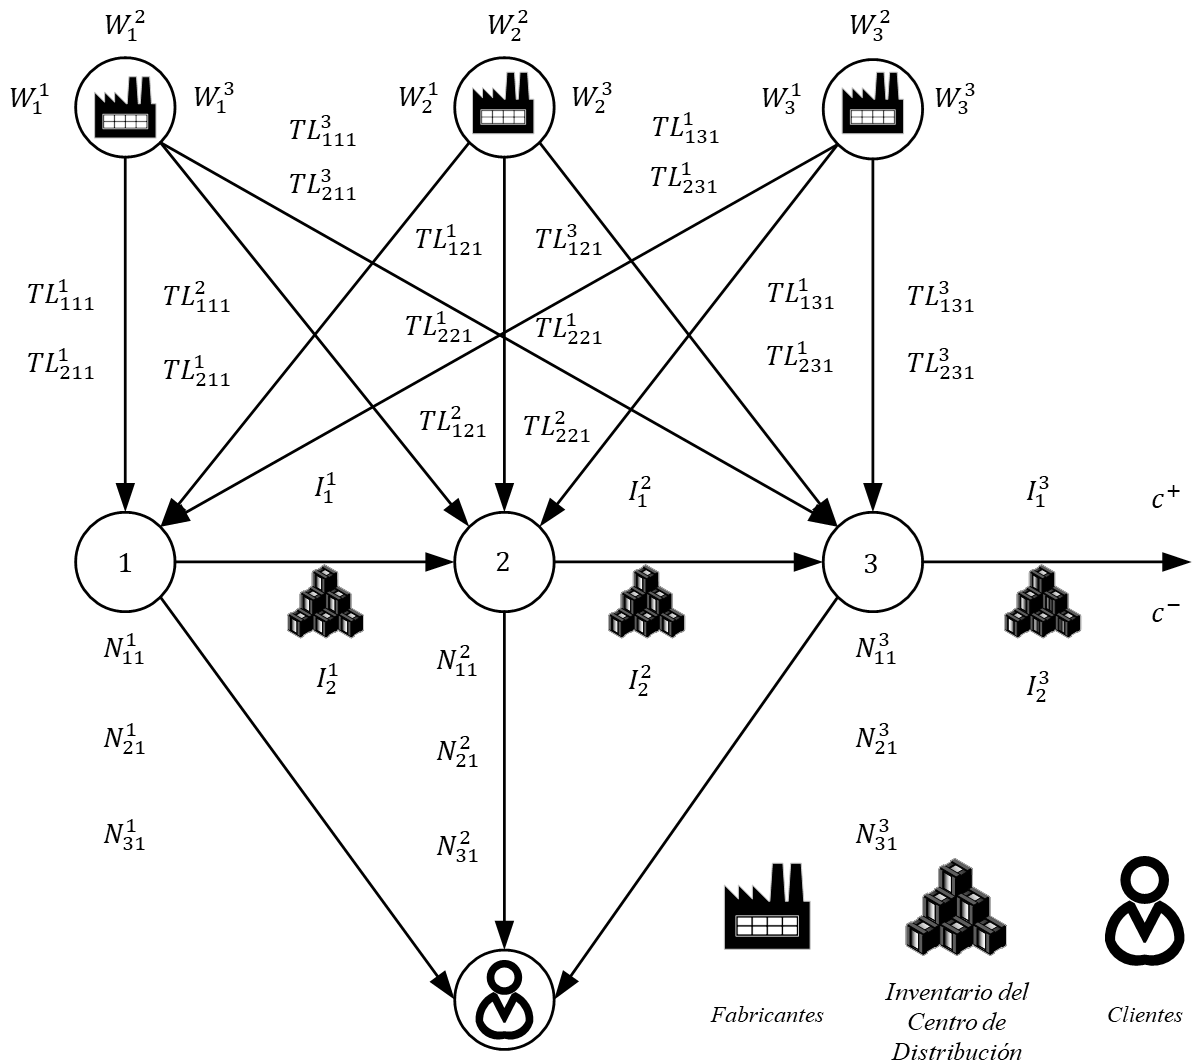
- **S1.** Los costos para cada producto comprado a cada fabricante durante todo el horizonte de planificación son conocidos.
- **S2.** Si un producto se transporta al siguiente período dentro del horizonte de planificación, el costo de mantenerlo en inventario debe ser razonable y justificable en relación con los beneficios que se esperan al venderlo en el futuro. Esto implica que el costo de almacenamiento, financiamiento, y posibles pérdidas de valor (por deterioro o desactualización) no se contemplan (Goodarzian et al., 2021a).
- **S3.** El costo del transporte se calcula en función de la distancia total recorrida por el vehículo, independientemente de la cantidad de mercancías transportadas o del número de entregas realizadas (Zgonc et al., 2019).
- **S4.** Cada artículo específico es suministrado exclusivamente por un único proveedor y distribuido a múltiples compradores (Castellano et al., 2019).

- **S5.** Solo se puede acceder a un tipo de vehículo con un volumen determinado. Además, se parte de la hipótesis de que los distintos productos están empaquetados de tal forma que pueden utilizarse todos los volúmenes del contenedor (Goodarzian et al., 2021a).
- **S6.** Se supone que el nivel de inventario inicial de todos los productos en cada fabricante es cero (Mousavi et al., 2013).
- **S7.** No se permiten entregas tardías, ni faltantes ni excedentes (Chern et al., 2013).
- **S8.** La demanda de los compradores de todos los productos es independiente entre sí y variable en los diferentes períodos. Significa que cada periodo de tiempo tiene su propia demanda (Mousavi et al., 2017).
- **S9.** Se considera un horizonte de planificación finito y conocido. En el horizonte de planificación, hay t períodos de duración iguales (Mousavi et al., 2017).
- **S10.** Los procesos de fabricación, pedidos, almacenamiento e inventario y transporte generan emisiones de carbono de forma lineal, lo que permite predecir y gestionar con precisión las emisiones en cada eslabón de la cadena de suministro según el nivel de actividad (Ma et al., 2020; Rout et al., 2021).
- **S11.** Todos los fabricantes tienen la capacidad de producir los mismos tipos de productos.
- **S12.** El gobierno es el que cobra el impuesto al carbono. Se podrá comprar o vender cualquier cantidad de permisos de emisión de carbono en el mercado de comercio de carbono (Shinkuma y Sugeta, 2016; Lai, 2023).

Basado en los supuestos y estudios previos, se han incluido diversos índices, parámetros y variables de decisión (Goodarzian et al., 2021b; Huang et al., 2020; Kumari et al., 2023). A continuación, se presenta la terminología clave que facilitará la formulación del modelo de optimización.

Figura 3.

Representación de una red de suministro del problema de asignación del tamaño de lotes multinivel y periodo con capacidades de producción (MLSPAP-PC).



Nota. La red de suministro está compuesta por dos tipos de productos, tres fabricantes, un único tipo de vehículo, un horizonte temporal de tres períodos y un conjunto de clientes.

5.2.2. Índices del Modelo de Optimización

Tabla 4.
Notación de índices

Notación	Descripción
p	Productos
m	Fabricantes
v	Tipos de Vehículos
t	Periodos de Tiempo

5.2.3. Parámetros de Entrada

Tabla 5.

Notación de parámetros

Notación	Descripción	Unidades
c_{fpm}^t	Costo de producción del producto p por parte del fabricante m en el período t	$\frac{\$}{u}$
cp_{pm}^t	Costo de pedido del producto p producido por el fabricante m en el período t	[\$]
ct_{mv}^t	Costo de transporte desde el fabricante m utilizando el vehículo v en el periodo t	$\frac{\$}{\text{km (vehículo)}}$
cm_p^t	Costo de almacenamiento del inventario del producto terminado p en el período t	$\frac{\$}{u}$
cpf_{mp}^t	Capacidad del fabricante m para el producto p en el período t	[u]
cpv_v	Capacidad del vehículo v	$\frac{m^3}{\text{vehículo}}$
d_p^t	Demanda del producto p en el período t	[u]
ve_p	Volumen de empaquetado del producto p	$\frac{m^3}{u}$
ccc	Costo del carbono por unidad comprada	$\frac{\$}{\text{ton}}$
ccv	Costo del carbono por unidad vendida	$\frac{\$}{\text{ton}}$
tic	Tasa del impuesto al carbono	$\frac{\$}{\text{ton}}$
eco^t	Emisión de carbono por unidad en cada pedido durante el período t	$\frac{\text{ton}}{u}$
ecp^t	Emisión de carbono al realizar un pedido en el período t	[ton]
ecm^t	Emisión de carbono al almacenar inventario en el período t	$\frac{\text{ton}}{u}$
ft	Factor de emisión de carbono para el transporte	$\frac{\text{ton}}{\text{km (vehículos)}}$
r_m	Distancia entre el fabricante m y el comprador	[km]
$cpeh_t$	Límite de emisiones de carbono en el periodo t	[ton]

5.2.4. Variables de Decisión

Tabla 6.

Notación de variables

Notación	Descripción
TL_{pmv}^t	Tamaño del lote del producto terminado p fabricado por el fabricante m transportado por el vehículo v en el período t
I_p^t	Inventario del producto terminado p desde el período t hasta $t + 1$
N_{mv}^t	Cantidad de vehículos tipo v que necesita el fabricante m en el periodo t
C_t^+	Cantidad de carbono comprado durante el periodo t
C_t^-	Cantidad de carbono vendido durante el periodo t
W_m^t	Selección del fabricante. 1 si se elige el fabricante m en el período t 0 en caso contrario

5.2.5. Función Objetivo

Minimización del costo total de la cadena de suministro

$$\begin{aligned}
 \mathbf{Min} \mathbf{C} = & \sum_p \sum_m \sum_v \sum_t c_{f_{pm}}^t TL_{pmv}^t + \sum_m \sum_t \left(\sum_p c_{p_{pm}}^t W_m^t + \sum_v c_{t_{mv}}^t r_m N_{mv}^t W_m^t \right) + \sum_p \sum_t c_{m_p}^t I_p^t \\
 & + ccc \left(\sum_t C_t^+ \right) + ccv \left(\sum_t C_t^- \right) + tic \left(\sum_p \sum_m \sum_v \sum_t eco^t TL_{pmv}^t + \sum_m \sum_t ecp^t W_m^t \right. \\
 & \left. + \sum_p \sum_t ecm^t I_p^t + ft \left(\sum_m \sum_v \sum_t N_{mv}^t r_m \right) \right) \quad (1)
 \end{aligned}$$

La función objetivo (1) del modelo busca minimizar el costo total a lo largo del horizonte de planificación de la cadena de suministro, integrando tanto los costos operativos tradicionales como los costos ambientales derivados de las emisiones generadas por dichas operaciones. Estos costos se estructuran de la siguiente manera: el primer término representa el costo de producción de los productos para los diferentes fabricantes y periodos. El segundo término corresponde a los costos logísticos, que incluyen tanto los costos de pedido como los de transporte, influenciados por la distancia, el número de vehículos y la elección de los fabricantes. En los términos tercero, cuarto y quinto se consideran los costos de almacenamiento de inventarios de productos terminados y los asociados con la compra o venta de créditos de carbono en cada periodo t , en donde este último es menor que el costo de compra, algo que suele ser común en los mercados de carbono (Baudry et al., 2021). Esta diferencia, conocida como “spread” o margen, se debe a varios factores, incluyendo costos de transacción, intermediación y la dinámica de oferta y demanda (3ª regulación). Finalmente, los últimos cuatro términos buscan minimizar el costo ambiental relacionado con las operaciones de producción, pedido, almacenamiento de inventario y transporte, considerando el impuesto aplicable por cada unidad de emisión generada (1ª regulación).

5.2.6. Restricciones

$$I_p^{t-1} + \sum_m \sum_v TL_{pmv}^t = d_p^t + I_p^t, \quad \forall p, t \quad (2)$$

La restricción (2) muestra el equilibrio del inventario. Establece que el inventario transportado del período anterior ($t - 1$), más el total de lotes producidos por los fabricantes en el período actual (TL_{pmv}^t), debe ser igual a la suma del inventario del período actual (I_p^t) y la demanda del producto p en el periodo t (D_p^t).

$$W_m^t d_p^t - \sum_v TL_{pmv}^t \geq 0, \quad \forall p, m, t \quad (3)$$

La restricción (3) asegura que, si un fabricante m es seleccionado para producir en el período t (es decir, $W_m^t = 1$), la producción total del producto p transportada por todos los vehículos debe ser, al menos, igual a la demanda de ese producto en dicho período. Dando lugar a que solo los fabricantes seleccionados realicen producción y que la cantidad total del producto p fabricada y transportada desde el fabricante m sea suficiente para satisfacer la demanda del período actual.

$$\sum_v TL_{pmv}^t \leq cpf_{mp}^t, \quad \forall p, m, t \quad (4)$$

La restricción (4) muestra que el tamaño del lote se rige por la capacidad del fabricante, es decir, debe ser como máximo su capacidad.

$$N_{mv}^t = \frac{\sum_p (TL_{pmv}^t ve_p)}{cpv_v}, \quad \forall m, v, t \quad (5)$$

La restricción (5) muestra el número de vehículos que necesita el fabricante m para el transporte de los lotes en el periodo t . Este valor es un número lógico que muestra el uso de la capacidad del vehículo. Para calcular el coste del transporte, este valor se ha redondeado al siguiente valor entero, manteniendo el mismo para el cálculo de la emisión de carbono a causa del transporte.

$$\sum_p \sum_m \sum_v eco^t TL_{pmv}^t + \sum_m ecp^t W_m^t + \sum_p ecm^t I_p^t + ft \left(\sum_m \sum_v N_{mv}^t r_m \right) \leq cpeh_t \quad (6)$$

La restricción (6) garantiza que las emisiones de carbono generadas por las operaciones de producción, pedido, inventario y transporte no superen un límite de emisiones determinado (2ª regulación).

$$\sum_p \sum_m \sum_v eco^t TL_{pmv}^t + \sum_m ecp^t W_m^t + \sum_p ecm^t I_p^t + ft \sum_m \sum_v N_{mv}^t r_m = cpeh_t + C_t^+ - C_t^- \quad (7)$$

La restricción (7) indica el equilibrio de toda la emisión de carbono relacionada con la producción, el mantenimiento de inventarios, los pedidos y la manipulación de los productos y el transporte durante todo el horizonte de planificación t frente a la capacidad máxima permitida de carbono y el excedente de carbono comprado o vendido.

$$C_t^+ \times C_t^- = 0, \quad \forall t \quad (8)$$

La ecuación (8) asegura que, cuando una de las dos variables (compra o venta de emisiones de carbono) esté activa, la otra permanezca inactiva, evitando así la compra y venta simultánea de emisiones de carbono.

$$TL_{pmv}^t \geq 0, \quad \forall p, m, v, t \quad (9)$$

$$N_{mv}^t \geq 0, \quad \forall m, v, t \quad (10)$$

$$I_p^t \geq 0, \quad \forall p, t \quad (11)$$

$$W_m^t \in [0,1], \quad \forall m, t \quad (12)$$

$$C_t^+, C_t^- \geq 0, \quad \forall t \quad (13)$$

Finalmente, las ecuaciones (9-11) corresponden al dominio de las variables enteras positivas, como el tamaño del lote, el número de vehículos y el inventario. La ecuación (12) establece la asignación del fabricante, permitiendo únicamente valores binarios. La ecuación (13) garantiza que los valores del excedente de carbono, ya sea comprado o vendido, sean positivos.

5.2.7. Linealización del Modelo de Optimización

El modelo de optimización anterior corresponde a un problema de Programación No Lineal Entera Mixta (MINLP, por sus siglas en inglés). Para mejorar la eficiencia de la solución en un tiempo más corto (Gondal y Sahir, 2013; Sherali y Adams, 2013), se linealizó el modelo siguiendo la metodología propuesta por Asghari et al. (2022), que consiste en transformar las variables (N_{mv}^t) (W_m^t) en A_{mv}^t añadiendo las siguientes restricciones al modelo:

$$A_{mv}^t \leq N_{mv}^t, \quad \forall m, v, t \quad (14)$$

$$A_{mv}^t \leq (M) (W_m^t), \quad \forall m, v, t \quad (15)$$

$$A_{mv}^t \geq N_{mv}^t + M (W_m^t - 1), \quad \forall m, v, t \quad (16)$$

$$A_{mv}^t \geq 0, \quad \forall m, v, t \quad (17)$$

La inclusión de las restricciones 14 a 17, permiten sustituir los términos que generan la no linealidad en la función objetivo, la cual se modifica de la siguiente manera.

$$\begin{aligned} \text{Min } C = & \sum_p \sum_m \sum_v \sum_t c_{f_{pm}}^t TL_{pmv}^t + \sum_m \sum_t \left(\sum_p c_{p_{pm}}^t W_m^t + \sum_v c_{t_{mv}}^t r_m A_{mv}^t \right) + \sum_p \sum_t c_{m_p}^t I_p^t \\ & + ccc \left(\sum_t C_t^+ \right) + ccv \left(\sum_t C_t^- \right) + tic \left(\sum_p \sum_m \sum_v \sum_t eco^t TL_{pmv}^t + \sum_m \sum_t ec_{p^t} W_m^t \right. \\ & \left. + \sum_p \sum_t ec_{m^t} I_p^t + ft \left(\sum_m \sum_v \sum_t N_{mv}^t r_m \right) \right) \end{aligned} \quad (18)$$

5.3. Modelos de Predicción

El enfoque predominante en el diseño de cadenas de suministro es la optimización determinista, donde las decisiones estratégicas y tácticas se tratan como variables deterministas. Estudios previos, como el de S. Kumar et al., (2022), también modelan la demanda del cliente en función de variables específicas, como el tiempo. Sin embargo, en la práctica, el diseño de las cadenas de suministro enfrenta una considerable incertidumbre en varios aspectos, como la demanda de los clientes, los costos, la contaminación y, a veces, factores sociales. Los parámetros inciertos suelen representarse mediante distribuciones de probabilidad, pero esta

aproximación no siempre es adecuada debido a la falta de datos fiables o de buena calidad (Gholamian et al., 2021). En la realidad, muchas cadenas de suministro enfrentan incertidumbres en múltiples parámetros, lo que subraya la necesidad de desarrollar modelos y estrategias robustas que gestionen y mitiguen efectivamente estas incertidumbres.

Considerando que las decisiones estratégicas y tácticas abordadas en esta investigación están profundamente influenciadas por la incertidumbre y que estas difieren en horizontes de tiempo muy largos, encontrar soluciones sólidas que respondan a estos desafíos se vuelve esencial. En consecuencia, se propone enfocar el análisis de la incertidumbre en las fluctuaciones de la demanda, ya que esta puede verse afectada por una variedad de factores, tales como la estacionalidad, promociones, tendencias del mercado, competencia, condiciones climáticas, entre otros. Comprender y anticipar estas fluctuaciones es fundamental para garantizar la resiliencia y el rendimiento óptimo de las cadenas de suministro en escenarios de incertidumbre.

Para abordar este desafío, dado que los datos necesarios para analizar la incertidumbre epistemológica asociada a la demanda del modelo no están disponibles en la literatura, ya sea por su alta especificidad o el nivel de granularidad requerido, y teniendo en cuenta el gran volumen de información que maneja el modelo, se seleccionó un conjunto de datos relevante de Kaggle. Este conjunto cumple con las 5V del Big Data, fundamentales para el modelo presentado en la sección 5.2. En particular, se utilizó el conjunto de datos [Grupo Bimbo Inventory Demand | Kaggle](#), el cual proporciona información detallada sobre la demanda de diversos productos en múltiples fábricas a lo largo de varios periodos de tiempo. Estos datos se alinean con la estructura necesaria del principal *input* del modelo de optimización, que es la demanda (d_p^t), es decir, las cantidades solicitadas por los clientes para cada tipo de producto y en cada periodo.

En particular, el conjunto de datos incluye transacciones históricas de ventas durante 9 semanas en Bimbo – México e información relacionada con el ID del canal de venta, producto, y depósito de ventas, entre otros. La demanda de un producto en una semana determinada se calcula como las ventas de esa semana menos las devoluciones de la semana siguiente. Estas características hacen que el conjunto de datos se ajuste a los requisitos del modelo y permita un análisis adecuado de las predicciones de la demanda mediante métricas de precisión, lo que a su vez facilita la evaluación de la incertidumbre en el modelo de optimización. Además, al ser de carácter abierto y público, este conjunto de datos está disponible en la plataforma, lo que lo convierte en una opción accesible y adecuada para este análisis.

A partir de esta base de datos, se importaron las bibliotecas, funciones necesarias y los datos, configurando los modelos para su análisis posterior. Siguiendo el enfoque propuesto por Agarwal, (2024), se realizaron los siguientes pasos: primero, se llevó a cabo un análisis exploratorio de los datos que incluyó la ingeniería de características, el manejo de datos faltantes, el tratamiento de valores atípicos y la selección de las características más relevantes. Luego, se construyó una canalización de datos para automatizar el procesamiento. Finalmente, se entrenaron los modelos XGBRegressor y CatBoostRegressor, los cuales fueron evaluados mediante cuatro métricas de desempeño, con el objetivo de estimar las predicciones de demanda y la incertidumbre en la cadena de suministro. Esta incertidumbre se incorporará dentro del intervalo de la distribución de demanda, tal como se describe en la sección 6. A continuación, se presentan la configuración, el funcionamiento y los resultados de los modelos de predicción propuestos.

5.3.1. *XGBRegressor*


El algoritmo XGBoost o *eXtreme Gradient Boosting* es una técnica de aprendizaje automático supervisado basada en árboles de decisión, desarrollada por Chen y Guestrin, (2016), como una versión optimizada del algoritmo tradicional de Gradient Boosting Decision Trees (GBDT). XGBoost se construye mediante la adición continua de árboles de decisión, en los que cada nuevo árbol intenta corregir los errores residuales generados por el árbol anterior. El proceso de predicción se logra al combinar los resultados de varios árboles a través de un voto ponderado, mejorando así la precisión general. Una de las principales innovaciones de XGBoost en comparación con GBDT es el uso de la expansión de Taylor de segundo orden para optimizar la función de pérdida, lo que permite un ajuste más preciso de los datos. Además, el algoritmo incluye mecanismos de regularización L1 (lazo) y L2 (cresta) que ayudan a controlar la complejidad del modelo y evitan el sobreajuste, mejorando así su capacidad de generalización a nuevos datos.

Como se muestra en la Figura 4, los residuos, las diferencias entre los datos estimados y observados, se utilizan para refinar los predictores anteriores (es decir, los árboles) durante cada iteración. Para la regresión, el valor predictivo está determinado por la puntuación media de cada árbol (Han et al., 2019). XGBoost ofrece un procesamiento rápido y eficiente de grandes conjuntos de datos, respaldado por su tecnología de bloques. Además, XGBoost aprovecha el multithreading de la CPU para el paralelismo y mejora continuamente su algoritmo para mejorar la precisión, lo que lo convierte en una característica muy distintiva (Lu y Ma, 2020; Wu et al., 2022).

El principio de XGBoost se describe a continuación: Sea $C = \{x_i, y_i\}$, los datos iniciales con m ejemplos y n características, donde $|C| = n$, $x_i \in \mathbb{R}^n$ y $y_i \in \mathbb{R}$, \mathcal{F} indica el espacio de regresión. XGBoost predice añadiendo K funciones:

$$\begin{cases} \hat{y}_i = \varphi(x_i) = \sum_{k=1}^K f_k(x_i), f_k \in \mathcal{F}, \\ \mathcal{F} = \{f_k(x_i) = \omega_{q(x)}\}, q: \mathbb{R} \rightarrow T, \omega \in \mathbb{R}^T \end{cases} \quad (19)$$

Figura 4.
Diagrama esquemático del XGBoost



Nota. Adaptado de K. Xu et al. (2023)

En la ecuación 19, q se define como la estructura de cada árbol, T significa el total de hojas dentro del árbol. ω indica el peso de las hojas y $f_k(x_i)$ representa el resultado de k -ésimo árbol. En XGBoost, para las tareas de regresión, cada árbol se agrega al modelo de forma secuencial, mejorando así su rendimiento. El árbol recién generado debe coincidir con los residuales de la predicción anterior, y el proceso de iteración del j -ésimo árbol se muestra de la siguiente manera:

$$\hat{y}_i^j = \hat{y}_i^{j-1} + f_j(x_i), \hat{y}_i^0 = 0 \quad (20)$$

5.3.2. *CatBoostRegressor*

CatBoost es una técnica de aprendizaje automático derivada de la combinación de las palabras “Categórico” y “Boosting” propuesto por Prokhorenkova et al. (2017). Este algoritmo, basado en los Árboles de Decisión Impulsados por Gradientes (GBDT), utiliza árboles de decisión simétricos como modelos base. La estructura simétrica de estos árboles reduce el número de parámetros requeridos, lo que le permite procesar de manera eficiente las variables categóricas con alta precisión, optimizando así su rendimiento en escenarios complejos y con grandes volúmenes de datos.

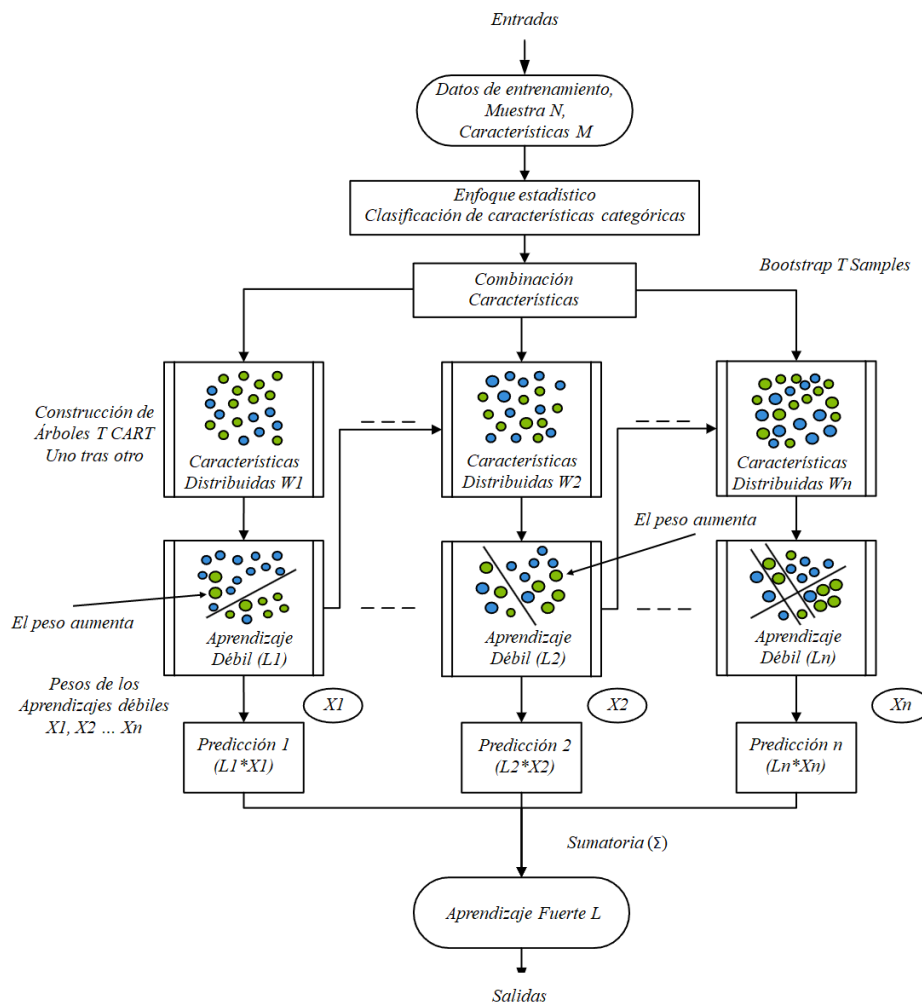
CatBoost es uno de los algoritmos de aumento de gradientes más utilizados en la actualidad (Dorogush et al., 2018), por su habilidad para gestionar eficientemente datos categóricos y mejorar el rendimiento de los modelos. El proceso comienza estimando la media de la variable objetivo y construyendo un conjunto de árboles de decisión de manera gradual, donde cada árbol se ajusta para corregir los errores del anterior. Destaca en el manejo de características categóricas mediante un método innovador llamado impulso ordenado, lo que le permite procesar estos datos sin la necesidad de preprocesamiento adicional, acelerando el entrenamiento y mejorando la precisión. Además, CatBoost resuelve problemas comunes como el sesgo de gradiente y el desplazamiento en las predicciones, mitigando el riesgo de sobreajuste. Otra ventaja es su uso de permutaciones para gestionar las variables categóricas, lo que lo diferencia de otros métodos clásicos de boosting (Hancock y Khoshgoftaar, 2020; Hao et al., 2020). Este algoritmo de aumento se distingue de otros algoritmos de gradiente por varias razones: (I) implementa el aumento ordenado, una modificación eficiente del enfoque tradicional de aumento de gradiente; (II) es efectivo tanto para conjuntos de datos pequeños como grandes; y (III) maneja con precisión una amplia variedad de características categóricas y se puede aplicar con éxito a diversos tipos y formatos de datos. Gracias a su esquema de

impulso dinámico, CatBoost también es capaz de gestionar sesgos de manera eficaz, lo que resulta en una mejor calidad de predicciones (Sapkota et al., 2024). La estructura detallada de este, que muestra cómo se integran estas mejoras, se presenta en la Figura 5.

El modelo CatBoost produce n modelos base para cada iteración de N boosting. Para cada variable de x_i $F(x_i)$. Se crea la función de árbol de decisión. P_k pertenece a las hojas del árbol. El resultado final descrito se puede expresar como la ecuación 21.

$$Z = F(x_i) = \sum_{k=1}^N C_j 1_{\{x \in P_k\}} \tag{21}$$

Figura 5.
Diagrama esquemático del CatBoost



Nota. Adaptado de Sapkota et al. (2024)

Donde $F(x_i)$ es una función de árbol de decisión de las variables explicativas x_i y P_k es la región disjunta correspondiente a las hojas del árbol.

5.3.3. Evaluación de los Modelos de Predicción

XGBRegressor y CatBoostRegressor son modelos de aprendizaje automático altamente efectivos, pero su rendimiento depende en gran medida de un ajuste cuidadoso de los hiperparámetros⁴, lo que puede hacer que su optimización sea un proceso complejo y que requiera mucho tiempo (Shi et al., 2022); la capacidad de entrenamiento de estos modelos está determinada por su marco de hiperparámetros (ver Tabla 7). Con el fin de evaluar su desempeño, se propone someter los modelos a nueve escenarios diferentes. En cada escenario, se medirán cuatro métricas clave: el Coeficiente de Determinación (R^2), el Error Cuadrático Medio (RMSE), el Error Absoluto Medio (MAE) y el Error Porcentual Absoluto Medio (MAPE), las cuales se describen en las ecuaciones (20-23). Estas métricas complementarias permitirán evaluar no solo la precisión de las predicciones, sino también su consistencia y la capacidad de cada modelo para ajustarse a diferentes tipos de datos y escenarios, proporcionando una visión más detallada del rendimiento general.

Tabla 7.

Marco de hiperparámetros - Modelos de Predicción

Parámetro	XGBoost	CatBoost
Número de arboles	n_estimators	iterations
Profundidad del árbol	max_depth	depth
Tasa de aprendizaje	learning_rate	learning_rate
Fracción de muestras	subsample	bagging_temperature

⁴ Los hiperparámetros de un modelo son los valores de configuración empleados durante el proceso de entrenamiento. A diferencia de los parámetros, que se derivan de los datos, los hiperparámetros son generalmente establecidos por el científico de datos. No es posible determinar de antemano el valor óptimo de un hiperparámetro para un problema específico, por lo que se suelen utilizar valores estándar, reglas generales o aquellos que han demostrado ser efectivos en problemas similares. Alternativamente, se puede optar por buscar la mejor opción mediante un proceso de prueba y error.

Fracción de características	colsample_bytree	N/A
Regularización	alpha, lambda	L2_leaf_reg
Variables categóricas	No especializado	Especializado

- I. R cuadrado (R^2): es el coeficiente de determinación. Es una medida de la fuerza asociada a las variables. Muestra la correlación lineal entre los valores reales probados y los predichos:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (20)$$

- II. Raíz del Error Cuadrático Medio (RMSE): La raíz del error cuadrático medio indica la desviación entre los valores reales probados y los predichos:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (21)$$

- III. Error Cuadrático Medio (MSE): Es un tipo de error medido por la diferencia cuadrática media entre los valores probados y los predichos:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (22)$$

- IV. Error Absoluto Porcentual Medio (MAPE): Se expresa como el promedio de los errores absolutos porcentuales entre los valores probados y los valores predichos:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100 \quad (23)$$

La configuración de los hiperparámetros se realizó para optimizar el rendimiento y garantizar la replicabilidad de los experimentos. Se evaluaron diferentes valores para estos: el número de árboles (n_estimators/iterations) con 50, 100 y 200; la profundidad de los árboles (max_depth/depth) en 6, 8 y 10, lo que permitió capturar más información sin sobreajustar el modelo. Además, se probó la tasa de aprendizaje (learning_rate) con valores de 0.01, 0.1 y 0.2

para equilibrar la precisión y el tiempo de entrenamiento. Ambos modelos se evaluaron usando `random_state` fijado en 42 para asegurar la replicabilidad (Rizwan et al., 2024), como se muestra en la Tabla 8.

Tabla 8.
Comparativo de los modelos de aprendizaje automático

Hiperparámetros	Modelo	R ²	RMSE	MSE	MAPE
n_estimators: 50 max_depth: 6 learning_rate: 0.01	XGBoost	0.4231	16.636	276.743	175.662
Subsample: 0.6 colsample_bytree: 0.6	CatBoost	0.4128	16.783	281.680	176.558
n_estimators: 100 max_depth: 8 learning_rate: 0.1	XGBoost	0.7487	10.980	120.553	72.224
Subsample: 0.8 colsample_bytree: 0.8	CatBoost	0.7509	10.9304	119.476	83.686
n_estimators: 200 max_depth: 10 learning_rate: 0.2	XGBoost	0.731	11.348	128.775	*69.005
Subsample: 1.0 colsample_bytree: 1.0	CatBoost	0.561	14.496	210.125	71.634
n_estimators: 50 max_depth: 6 learning_rate: 0.2	XGBoost	0.740	11.173	124.835	80.352
Subsample: 0.6 colsample_bytree: 0.6	CatBoost	0.742	11.127	123.819	88.894
n_estimators: 200 max_depth: 10 learning_rate: 0.01	XGBoost	0.714	11.705	137.016	99.758
Subsample: 1.0 colsample_bytree: 1.0	CatBoost	0.716	11.671	136.214	115.246
n_estimators: 50 max_depth: 6 learning_rate: 0.2	XGBoost	0.739	11.197	125.371	77.553
Subsample: 0.8 colsample_bytree: 0.8	CatBoost	0.741	11.136	124.003	89.377
n_estimators: 200 max_depth: 10 learning_rate: 0.01	XGBoost	0.727	11.442	130.930	99.887
Subsample: 0.8 colsample_bytree: 0.8	CatBoost	0.716	11.671	136.216	115.851

n_estimators: 50 max_depth: 6 learning_rate: 0.01 Subsample: 0.8 colsample_bytree: 0.8	XGBoost	0.439	16.401	268.988	174.648
n_estimators: 200 max_depth: 10 learning_rate: 0.2 Subsample: 0.8 colsample_bytree: 0.8	CatBoost	0.413	16.783	281.680	176.558
n_estimators: 200 max_depth: 10 learning_rate: 0.2 Subsample: 0.8 colsample_bytree: 0.8	XGBoost	0.737	11.223	125.964	70.271
n_estimators: 200 max_depth: 10 learning_rate: 0.2 Subsample: 0.8 colsample_bytree: 0.8	CatBoost	*0.758	*10.780	*116.208	72.903

*: Representa los mejores valores en cada conjunto de modelos, métricas y hiperparámetros.

El análisis de la Tabla 8 revela que la mejor configuración para este conjunto de datos es CatBoost con n_estimators: 200, max_depth: 10, learning_rate: 0.2 y subsample: 0.8. Este modelo obtuvo el mayor R² (0.758), lo que indica que explica mejor la variabilidad de los datos, y los valores más bajos de RMSE (10.780) y MSE (116.208), lo que refleja una menor dispersión de los errores. Esto sugiere que dicha configuración ofrece un rendimiento más preciso y robusto en comparación con las otras opciones.

Si bien XGBoost con la misma configuración (n_estimators: 200, max_depth: 10, learning_rate: 0.2) presenta un MAPE ligeramente mejor (70.271 frente a 72.903 en CatBoost), lo que indica un menor error porcentual, este modelo no logra superar a CatBoost en las métricas de precisión y error absoluto.

6. Obtención de Soluciones a partir del Modelo

Dado que no se dispone completamente de las instancias de referencia necesarias en la literatura para esta investigación, se utilizaron datos accesibles y supuestos realistas para los parámetros faltantes. Con base en la sección 5.2, se diseñó una instancia base específica para una empresa, que incluye una cadena de suministro con cinco productos, cuatro fabricantes, tres tipos de vehículos y dos periodos de tiempo. Los parámetros de entrada y sus distribuciones se implementaron según la Tabla 9, y los valores específicos se detallan en el Apéndice B.

Tabla 9.*Parámetros del Modelo de Optimización*

Parámetro	Valor
cf_{pm}^t	$U \sim (\text{low}=30, \text{high}=300)$
cp_{pm}^t	$U \sim (\text{low}=25, \text{high}=250)$
cm_{mv}^t	$U \sim (\text{low}=15, \text{high}=150)$
cm_p^t	$U \sim (\text{low}=10, \text{high}=100)$
cpf_{mp}^t	$U \sim (\text{low}=2.000, \text{high}=8.000)$
cpv_v	$U \sim (\text{low}=5, \text{high}=100)$
d_p^t	$U \sim (\text{low}=100, \text{high}=7500)$
ve_p	$U \sim (\text{low}=0.1, \text{high}=10)$
ccc	$U \sim (\text{low}=30, \text{high}=35)$
ccv	$U \sim (\text{low}=24, \text{high}=28)$
tic	$U \sim (\text{low}=4.24, \text{high}=6.67)$
ecp^t	$U \sim (\text{low}=0.000015, \text{high}=0.000065)$
ecm^t	$U \sim (\text{low}=0.0001, \text{high}=0.00085)$
eco^t	$U \sim (\text{low}=0.00005, \text{high}=0.00085)$
ft	$U \sim (\text{low}=0.25, \text{high}=0.95)$
r_m	$U \sim (\text{low}=10, \text{high}=400)$
$cpeh_t$	$U \sim (\text{low}=107000, \text{high}=212000)$

Nota. Adaptados de Alavidoost et al. (2018)

Para analizar la instancia base, se proponen tres casos que combinan las distintas regulaciones de emisiones de carbono abordadas en esta investigación.

- **Caso 1:** Incluye únicamente la 1ª regulación de Impuesto al Carbono, aplicando el modelo de optimización descrito en la sección 5.2, pero sin considerar las restricciones 6 y 7.
- **Caso 2:** Considera tanto la 1ª como la 2ª regulación (Impuesto y Límite de Carbono), utilizando el modelo de optimización sin la restricción número 7.
- **Caso 3:** Incluye las regulaciones 1ª y 3ª (Impuesto y Tope-Comercio de Carbono), aplicando el modelo sin la restricción número 6.

Las siguientes secciones, describen los resultados encontrados para cada uno de estos casos desarrollados, al igual que un análisis de sensibilidad de estos.

6.1. Caso 1: Regulación Impuesto al Carbono

En esta sección se analiza el caso base 1 del modelo matemático, en el cual se considera únicamente la 1ª regulación: tasa de impuesto al carbono (*tic*). Esta regulación se centra en la función objetivo, que cuantifica las emisiones generadas por las operaciones en la cadena de suministro y a través de la cual se generan los costos ambientales. A continuación, se presentan los resultados de la función objetivo, un desglose de los costos, las variables de decisión con valores distintos de cero y otros resultados relevantes.

De acuerdo con las Tablas 10 y 11, se observa que el periodo 1 es el más representativo de los dos. Esto se debe principalmente a que presenta una mayor demanda y costos más elevados en comparación con el periodo 2.

Tabla 10.

Prorrates de costos en millones de la función objetivo - Caso 1

Periodo	Producción	Logístico	Inventario	Ambiental	Total
1	4.74	11.29	0.42	1.81	18.26
2	1.17	6.97	0.00	1.74	9.87
Total	5.91	18.26	0.42	3.55	28.13

De igual manera, en la Tabla 11, el costo logístico es el más alto, ya que incluye los costos de pedido y transporte, que, en promedio, son mayores para cada producto, fabricante y vehículo en comparación con los costos de producción y ambientales.

Tabla 11.

Porcentaje de costos de la función objetivo - Caso 1

Periodo	Producción	Logístico	Inventario	Ambiental	Total
1	16.85%	40.14%	1.49%	6.43%	64.91%
2	4.16%	24.78%	0.00%	6.19%	35.09%
Total	21.01%	64.88%	0.00%	12.62%	100,00%

Las decisiones que generan estos costos en la cadena de suministro, como se detallan en las Tablas 12, 13 y 14, evidencian que las fábricas 1 y 3 no están programadas para operar en el periodo 1, mientras que los fabricantes 2 y 4 no lo están en el periodo 2. Este comportamiento

puede explicarse por los costos de pedido, que resultan más elevados durante el primer periodo en comparación con el periodo subsecuente, junto con los incrementos en los costos de fabricación que también se observan durante estos lapsos.

Los tamaños de los lotes en la Tabla 12 indican que no son uniformes ni similares entre sí, ya que presentan una amplia variación, con tamaños que van desde un mínimo de 121 unidades hasta un máximo de 7112. Esto indica que los lotes son heterogéneos y diferentes. Esta variabilidad se debe a que el modelo optimiza la producción y el pedido de grandes lotes cuando los costos logísticos y de producción son más bajos, buscando utilizar la mayor capacidad disponible en las fábricas. Una vez que estas alcanzan su límite, el modelo asigna cantidades menores a otras fábricas, que, aunque no necesariamente tienen los costos más bajos, cumplen con la capacidad y continúan siendo competitivas en términos de costos de producción, pedido y transporte.

Tabla 12.

Tamaño de los lotes - Caso 1

TL_{pmv}^t	p	m	v	t
1776	1	2	1	1
7112	1	4	1	1
3269	2	3	1	2
4498	2	4	1	1
5754	3	2	1	1
121	3	4	1	1
2744	4	2	1	1
4087	4	3	1	2
2744	4	4	1	1
4789	5	1	3	2
2576	5	2	1	1
3474	5	4	1	1

Además, como se muestra en la Tabla 13, las decisiones sobre la cantidad de inventario a almacenar indican que solo se almacena en el periodo 1, ya que este modelo no permite sobrantes de inventario, por lo tanto, dado que el periodo 2 es el último, no es posible almacenar

inventario en ese momento. Asimismo, se opta por almacenar productos en el primer periodo debido a que el costo de fabricación en el segundo es más alto. Por lo tanto, es más eficiente producir en el periodo 1 y asumir un costo de almacenamiento menor, en lugar de fabricar en el periodo 2.

Tabla 13.
Inventario almacenado - Caso 1

I_p^t	p	t
1776	1	1
121	3	1
2744	4	1
2576	5	1

La Tabla 14 indica que solo se asignan vehículos de tipo 1 y 3 para el transporte de productos, ya que ambos tienen la mayor capacidad entre los tres tipos disponibles (tipo 1, 2 y 3). El vehículo de tipo 1 tiene más del triple de capacidad que el tipo 2 y casi el doble que el tipo 3, lo que lo convierte en la opción más eficiente para transportar la mayor cantidad de lotes. Además, se observa que la cantidad de vehículos asignados al fabricante 4 es mayor en comparación con los demás fabricantes, debido a que este tiene el mayor volumen de producción.

Tabla 14.
Número de vehículos - Caso 1

N_{mv}^t	m	v	t
602	1	3	2
873	2	1	1
267	3	1	2
1234	4	1	1

Por último, la selección de los fabricantes en cada período se realiza conforme a lo especificado en la Tabla 15. Tal como se indicó previamente, los costos asociados a la producción, los pedidos y el transporte para estas fábricas y periodos son más bajos en

comparación con los escenarios alternativos a los considerados. Esta es la razón por la cual se eligen estos fabricantes en los periodos correspondientes.

Tabla 15.

Selección de los fabricantes - Caso 1

W_m^t	m	t
1	1	2
1	2	1
1	3	2
1	4	1

6.2. Caso 2: Regulaciones Impuesto y Limite al Carbono

El caso base 2 consta de un modelo matemático que considera la 1ª y 2ª regulación: la tasa de impuesto (*tic*) al carbono y el límite de carbono (*cpeh*). Este modelo aplica los costos ambientales y activa la restricción 6 para cada operación en la cadena de suministro en cada periodo del horizonte de planificación. A continuación, se presentan los resultados de la función objetivo, el desglose detallado de los costos, las variables de decisión activas y otros aspectos relevantes.

Los costos de la función objetivo, presentados en las Tablas 16 y 17, muestran, al igual que en el Caso 1, que el periodo 1 es el más representativo de los dos. Esto se debe a que tiene una mayor demanda y costos más altos en comparación con el periodo 2. No obstante, se observa un incremento en el costo total de 2.73 millones, aunque el costo ambiental disminuye aproximadamente un 37.7% respecto al Caso 1. Esta reducción se puede atribuir a la incorporación de nuevas restricciones sobre las emisiones de carbono, que impactan directamente la función objetivo y permiten un mejor control de las emisiones en la cadena de suministro.

Tabla 16.*Prorrates de costos en millones de la función objetivo - Caso 2*

Periodo	Producción	Logístico	Inventario	Ambiental	Total
1	4.26	11.48	0.29	1.35	17.37
2	1.97	10.66	0.00	0.86	13.49
Total	6.23	22.14	0.29	2.21	30.86

Asimismo, la Tabla 17 refleja un mejor equilibrio en los costos de la función objetivo por período, resultado no solo de las variaciones en la demanda entre los períodos, sino también en función de las emisiones de carbono disponibles en estos dos momentos del tiempo.

Tabla 17.*Porcentaje de costos de la función objetivo - Caso 2*

Periodo	Producción	Logístico	Inventario	Ambiental	Total
1	13.8%	37.20%	0.94%	4.37%	56.29%
2	6.38%	34.54%	0.00%	2.79%	43.71%
Total	20.18%	71.74%	0.94%	7.16%	100%

Las decisiones tomadas para el Caso 2, presentadas en las Tablas 18, 19 y 20, se modifican con respecto al Caso 1. En particular, se observa que el fabricante 2 debe estar operativo tanto en el periodo 1 como en el 2 para los productos 1 y 2, a diferencia del Caso 1, donde solo se habilitaba en el primer periodo. Además, los tamaños de los lotes se ven afectados (Tabla 18), especialmente en los productos 1, 4 y 5. Esto se debe a que, además de cumplir con las restricciones de capacidad de fabricación (cpf_{mp}^t), ahora también se debe respetar los límites de capacidad de emisiones disponibles por periodo ($cpeh$). Por esta razón, es necesario utilizar el límite de emisiones del segundo periodo dado que este no basta para satisfacer todas las cantidades demandadas, a pesar de que el límite para el primer periodo es aproximadamente un 40% mayor que para el segundo.

Tabla 18.*Tamaño de los lotes - Caso 2*

TL_{pmv}^t	p	m	v	t
7112	1	2	1	1
153	1	2	1	2
1623	1	4	1	1
4498	2	2	1	1
3269	2	3	1	2
121	3	1	3	2
5754	3	2	1	1
2744	4	2	1	1
989	4	2	1	2
5842	4	3	1	2
2576	5	2	1	1
3777	5	2	1	2
1012	5	3	1	2
3474	5	4	1	1

En cuanto a las decisiones sobre el almacenamiento de inventario, tal como en el Caso 1 y según se detalla en la Tabla 19, se observa que solo se almacena en el periodo 1, ya que el modelo no permite mantener excedentes de inventario en periodos posteriores o en el último. Además, hay una reducción en el inventario almacenado en comparación con el Caso 1. Esto se debe principalmente a que las emisiones de carbono asociadas al almacenamiento (ecm^t) no solo son incluidas en el costo de la función objetivo, sino también en las restricciones que limitan las emisiones permitidas por periodo ($cpeh_t$). A pesar de que las emisiones unitarias generadas por almacenar inventario en el primer periodo son más del doble que en las del segundo, el modelo decide almacenar inventario en el primer periodo, debido a que el límite de emisiones en este periodo es más alto.

Tabla 19.*Inventario almacenado - Caso 2*

I_p^t	p	t
1623	1	1
2576	5	1

Por otro lado, las decisiones sobre el número de vehículos, Tabla 20, están influenciadas por múltiples factores: los volúmenes de empaquetado ve_p , las capacidades vehiculares cpv_v y, especialmente, los tamaños de los lotes TL_{pmv}^t . Al variar los tamaños de los lotes, se modifican las necesidades de transporte. Por ejemplo, la fábrica 1, con menor producción y lotes más pequeños, requiere menos vehículos. En contraste, la fábrica 2, con mayor producción y lotes más grandes, demanda una mayor cantidad de vehículos. Sin embargo, la distancia desde los clientes a las fábricas también influye significativamente en estas decisiones: dado que las emisiones de transporte $ft(\sum_m \sum_v \sum_t (N_{mv}^t r_m))$ aumentan en relación con la distancia, se busca minimizar el uso de la fábrica 1 (la más lejana) y la cantidad transportada a la misma, mientras que la fábrica 2, al estar más cerca, maximiza su producción y utiliza la mayor cantidad de vehículos tipo 1.

Tabla 20.

Número de vehículos - Caso 2

N_{mv}^t	m	v	t
12	1	3	2
1516	2	1	1
365	2	1	2
429	3	1	2
442	4	1	1

Finalmente, las decisiones sobre la apertura o selección de fabricantes, como se muestra en la Tabla 21, también experimentan cambios en comparación con el Caso 1. En donde no solo se debe tener en cuenta los aspectos anteriores, sino también la cantidad de emisiones generadas en las operaciones de producción (eco^t), pedido (ecp^t) e inventario (ecm^t). Dado que las emisiones en el segundo periodo son más bajas para todas estas operaciones, la fábrica 2, que además tiene la menor distancia, se activa en dicho periodo. Esto se debe fundamentalmente a la existencia del límite de emisiones ($cpeh_t$) asignado por cada periodo de tiempo, el cual no se contempla para el Caso 1.

Tabla 21.*Selección de los fabricantes - Caso 2*

W_m^t	m	t
1	1	2
1	2	1
1	2	2
1	3	2
1	4	1

6.3. Caso 3: Regulaciones Impuesto y Tope - Comercio de Carbono

El caso base 3 aborda un modelo matemático que incluye dos regulaciones estudiadas en esta investigación, la 1ª, y 3ª regulación: tasa de impuesto al carbono (*tic*), el sistema de comercialización de emisiones de carbono (*cpeh*, C_t^+ y C_t^-), teniendo en cuenta no solo los costos ambientales sino también el equilibrio de toda la emisión de carbono relacionada con la producción, el mantenimiento de inventarios, los pedidos y la manipulación de los productos y el transporte durante todo el horizonte de planificación t . Los resultados de la función objetivo, un desglose detallado de los costos de esta, las variables de decisión activas y otros aspectos relevantes del modelo se presentan a continuación.

Los costos de la función objetivo, presentados en las Tablas 22 y 23, revelan que el Caso 3 se diferencia de los anteriores, por situarse en un punto intermedio en términos de costos, tanto operativos como en valores porcentuales y absolutos. Esta particularidad responde a la naturaleza de la regulación de tope y comercio, que busca equilibrar de manera eficiente el impacto económico y ambiental de las operaciones dentro de la cadena de suministro, lo que facilita alcanzar un mejor equilibrio.

Tabla 22.*Prorrato de costos en millones de la función objetivo - Caso 3*

Periodo	Producción	Logístico	Inventario	Ambiental	Total
1	4.60	11.80	0.35	1.80	18.55
2	1.61	9.77	0.00	0.86	12.24
Total	6.21	21.57	0.35	2.71	30.79

Tabla 23.*Porcentaje de costos de la función objetivo - Caso 3*

Periodo	Producción	Logístico	Inventario	Ambiental	Total
1	14.94%	38.34%	1.14%	5.85%	60.27%
2	5.23%	31.74%	0.00%	2.79%	39.77%
Total	20.17%	70.08%	1.14%	8.64%	100%

Las decisiones en este caso, tal como se detallan en las Tablas 24, 25 y 26, muestran tanto similitudes como diferencias con respecto a los casos 1 y 2. En este escenario, se produce un lote adicional y se asigna un vehículo más en comparación con el Caso 1. En contraste, frente al Caso 2, se produce un lote menos y se asigna un vehículo menos. Al igual que en el Caso 1, los tamaños de los lotes para los productos 1, 2 y 3 no presentan cambios significativos, mientras que a diferencia de los casos anteriores, la fábrica 1 no se abre en ningún periodo. No obstante, en el Caso 3, algunos productos de tipo 5, que en el Caso 1 se trataban como un solo lote, se manejan en dos lotes. Esta misma situación se observa en el Caso 2, donde, para algunos productos tipo 1, dos lotes se combinan en uno, además de realizarse ajustes en las configuraciones de los demás elementos (índices) en ciertos lotes correspondientes a los productos tipo 5.

Los tamaños de los lotes en el Caso 3, tal como se muestran en la Tabla 26, experimentan cambios, inclinándose hacia la producción durante el periodo 1. Esto se debe, principalmente, a que el límite de emisiones permitidas en el primer periodo es mayor que en el segundo. Además, se tiene la posibilidad de evaluar si, dentro de estos límites de emisiones y mediante la comercialización de nuevas emisiones, es factible satisfacer la demanda a un costo más bajo y con el menor impacto ambiental posible.

Tabla 24.*Tamaño de los lotes - Caso 3*

TL_{pmv}^t	p	m	v	t
7112	1	2	1	1
1776	1	4	1	1
4498	2	2	1	1
3269	2	3	1	2
5754	3	2	1	1
121	3	4	1	1
2744	4	2	1	1
5842	4	3	1	2
989	4	4	1	1
2576	5	2	1	1
2874	5	2	1	2
1915	5	3	1	2
3474	5	4	1	1

Por su parte, las decisiones referentes al almacenamiento se alinean con el supuesto de no mantener sobrantes al final del último periodo, como se detalla en la Tabla 25, siguiendo la misma lógica observada en los casos 1 y 2. No obstante, en el contexto específico del inventario almacenado del producto 4 en el periodo 1, se logra un punto de equilibrio entre almacenar grandes volúmenes (como en el Caso 1) y no hacerlo (como en el Caso 2). Esto es posible gracias a la implementación de la regulación de tope y comercio, que permite gestionar las emisiones por periodo sin comprometer la viabilidad económica de las decisiones operativas.

Tabla 25.*Inventario almacenado - Caso 3*

I_p^t	p	t
1776	1	1
121	3	1
989	4	1
2576	5	1

De forma análoga a los ajustes realizados en los tamaños de los lotes, el número de vehículos utilizados también experimenta variaciones (Tabla 26), aplicándose en este caso las mismas configuraciones observadas en los casos 1 y 2. Sin embargo, se observa que la

asignación de vehículos es más equilibrada en el Caso 3 en comparación con el Caso 1, aunque ligeramente menos que en el Caso 2. Cabe destacar que, en el primer período, se utiliza más del 73% de la flota disponible, lo cual responde a la elevada demanda, los volúmenes de producción y a que las restricciones impuestas para este periodo permiten límites de emisiones más amplios, lo que lleva a una mayor operación logística de los vehículos.

Tabla 26.

Número de vehículos - Caso 3

N_{mv}^t	m	v	t
1516	2	1	1
232	2	1	2
502	3	1	2
510	4	1	1

En este mismo contexto, las restricciones de carbono, que afectan las decisiones operativas de la cadena de suministro, junto con la posibilidad de comercializar emisiones, explican a lo largo del horizonte de planificación, porqué el fabricante 1 no es seleccionado, como se muestra en la Tabla 27. Esto se debe a que dicho fabricante no ofrece los costos más bajos, está ubicado a mayor distancia de los clientes en comparación con las demás fábricas, y tiene la menor capacidad operativa. Además, el periodo 1 genera las emisiones más altas en todas las operaciones, independientemente del fabricante, en comparación con el periodo 2.

Tabla 27.

Selección de los fabricantes - Caso 3

W_m^t	m	t
1	2	1
1	2	2
1	3	2
1	4	1

Por último, en este Caso 3, la Tabla 28 indica que el límite de emisiones de carbono para el periodo 1 es insuficiente, a pesar de que este límite (*cpeh*) es casi un 39% superior al del periodo 2. Sin embargo, la demanda en el periodo 1 no solo es más de un 10% mayor que en el

periodo 2, sino que, al igual que en el Caso 2, este periodo concentra las emisiones más altas en las todas operaciones. Por esta razón, es necesario adquirir derechos adicionales de emisiones para el periodo 1. No obstante, la cantidad requerida representa menos del 3% del total de emisiones en el horizonte de planificación, logrando un equilibrio entre los costos y el impacto ambiental gracias a la política de tope y comercio.

Tabla 28.

Cantidad de carbono comprado - Caso 3

C_t^+	t
10967	1

6.4. Análisis de Sensibilidad de las Regulaciones de Carbono

Basado en lo descrito en las Secciones 6.1 - 6.3 y con el objetivo de comprender mejor el impacto de las decisiones presentadas en la sección 5.2.4, se realiza un análisis del proceso de toma de decisiones. En este análisis, se observa cómo los parámetros de entrada iniciales, comunes y representativos en los tres casos propuestos influyen de manera directa en el costo total de la cadena de suministro de la instancia base. Se ajustaron los valores de la tasa del impuesto al carbono (tic) y el límite de emisiones de carbono ($cpeh_t$), modificando uno de estos parámetros mientras los demás permanecen constantes. Los resultados de este análisis se describen en las subsecciones siguientes. Esta información permite tomar decisiones más estratégicas y fundamentadas en un entorno de mercado dinámico.

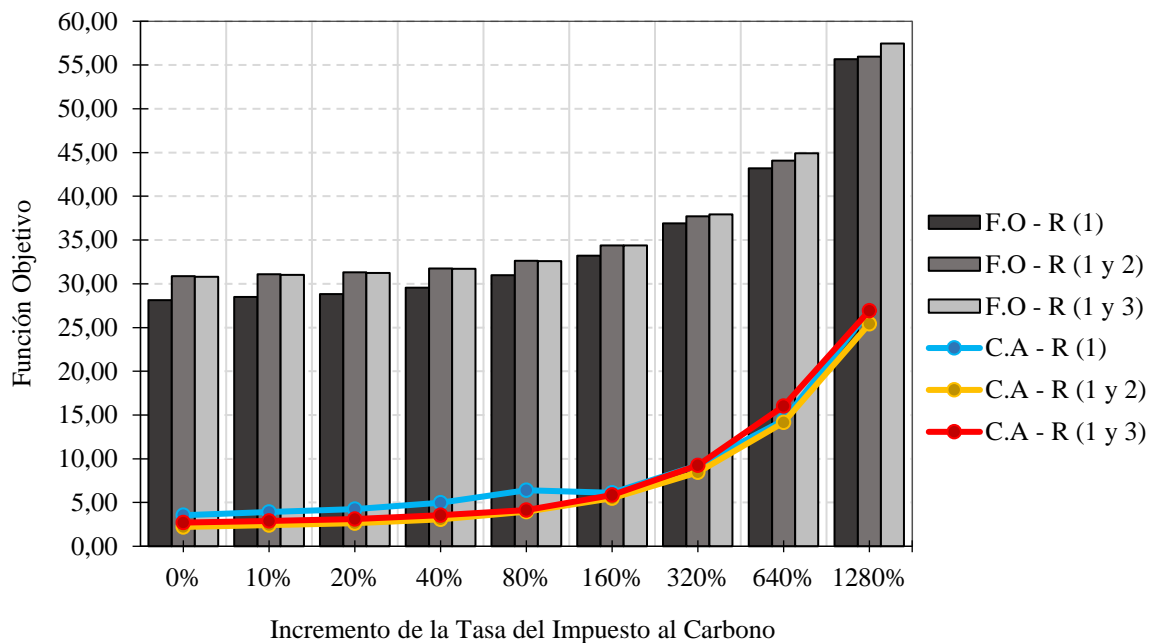
6.4.1. Impuesto al Carbono (tic)

Tasa de impuesto al carbono: Es un valor que el gobierno impone sobre cada unidad de emisiones de carbono generada durante las actividades de producción, logística e inventario. Este impuesto puede variar según la industria (Huang et al., 2020). El propósito de esta sección es analizar cómo dicho impuesto afecta las soluciones óptimas y el costo total de la cadena de

suministro, el cual se refleja en la función objetivo (ver Figura 6). Dado que las tasas de impuesto al carbono pueden fluctuar, se realizó un análisis de sensibilidad para evaluar el impacto de los costos ambientales en el costo total de la cadena de suministro.

La tasa inicial del impuesto es de 6,54 \$/tCO₂, un valor base coherente con los reportes de Colombia en los últimos cinco años (fuente: [Price|Carbon Pricing Dashboard \(worldbank.org\)](https://www.worldbank.org/)). Además, se seleccionaron 8 tasas adicionales que oscilan entre 7,194 \$/tCO₂ (+10%) y 83,712 \$/tCO₂ (+1280%), alineadas con los impuestos promedio de carbono en países de la Unión Europea. Estos valores se incluyeron para considerar escenarios futuros en los que se deben cumplir con los objetivos establecidos por el Acuerdo de París (Gomilšek et al., 2020).

Figura 6.
Sensibilidad tasa del impuesto al carbono



Nota. F.O. representa la función objetivo y C.A. el costo ambiental. R (1) hace referencia al Caso 1, R (1 y 2) al Caso 2, y R (1 y 3) al Caso 3.

La Figura 6 muestra que la tasa del impuesto al carbono y el costo total mantienen una relación directamente proporcional, evidenciada por un comportamiento ascendente. Esto refleja que, a medida que la tasa del impuesto al carbono (*tic*) aumenta, los costos totales

(barras) y los costos ambientales (líneas) de la cadena de suministro también lo hacen en todos los casos y escenarios, con excepción del Caso 1 [C.A-R (1)], el porcentaje del costo ambiental sobre el total, al pasar de un incremento del 80% al 160% en la tasa del impuesto al carbono no se refleja cambios ascendentes, pero posteriormente vuelve a incrementarse o tener una tendencia positiva. Esto sugiere que, en general, existe una correlación directa entre el impuesto y los costos, salvo en este caso particular. Este comportamiento ascendente inicialmente, para el Caso 1 es el más pronunciado en términos del costo ambiental, pero resulta menos costoso que en los casos 2 y 3 en términos totales. Esto se debe a que en el Caso 1 solo se emplea un mecanismo para moderar las emisiones de carbono, sin restricciones adicionales que penalicen los costos totales en la función objetivo ni el impacto ambiental. No obstante, este caso eventualmente converge al Caso 2, donde la regulación del impuesto, aplicada a través de la función objetivo, se complementa con límites de emisiones de carbono mediante una serie de restricciones por periodo. El Caso 2, [C.A-R (1 y 2)], genera un crecimiento en el impacto ambiental, pero de manera más controlada que en los casos 1 y 3, aunque a un costo mayor, ya que la producción se desplaza a periodos con mayores límites de emisiones, donde los costos no siempre son los más bajos, ya que no cuenta con valores de compra o venta de emisiones, siguiendo las lógicas mencionadas en las Secciones 6.2 y 6.3. Con respecto al Caso 3 [C.A-R (1 y 3)], este comienza situándose entre los casos 1 y 2 en cuanto a impacto ambiental y costos totales, más cercanos al Caso 2 que al 1. Sin embargo, a medida que aumenta la tasa del impuesto al carbono, el Caso 3 se convierte en la opción más costosa y con mayor costo ambiental, debido a que se vuelve ineficiente si se tiene un impuesto alto para sus correspondientes, límites de emisiones y costos de compra o venta de emisiones. Esto lo convierte en una alternativa desfavorable cuando no existe un equilibrio entre estos factores,

aunque se vuelve eficiente cuando dicho equilibrio está presente, como se evidencia entre el segundo y quinto escenario de incremento del impuesto.

Lo anterior confirma que el Caso 1 es más flexible en términos de costos; sin embargo, permite mayores costos ambientales en comparación con los casos 2 y 3. Por otro lado, el Caso 2 genera menores consecuencias ambientales que los Casos 1 y 3, pero implica costos económicos más altos. En contraste, el Caso 3 ofrece un equilibrio entre los impactos económicos y ambientales si se moderan los diferentes aspectos, evitando la sobrecarga en uno u otro. Además de los análisis previos, se evaluó el punto en que las decisiones previamente encontradas en la Secciones 6.1 a 6.3, comienzan a cambiar en los tres casos, identificándose que este cambio se produce a partir de un incremento del 80% en la tasa del impuesto al carbono (*tic*). Las decisiones más afectadas corresponden a los productos 5, 4 y 1, los cuales presentan las mayores demandas. Esto se debe a que el incremento en el impuesto hace menos atractiva la elección de las fábricas que inicialmente se habían seleccionado para la producción de estos productos. Este comportamiento ocurre porque los cambios en los coeficientes de la función objetivo pueden alterar la solución, al modificar las variables básicas del modelo (Rardin, 2017). Como resultado, algunas de estas variables pueden salir de la base de optimalidad, es decir, dejan de ser parte de la solución óptima. Este efecto se produce porque un aumento o disminución significativa en uno de los coeficientes de la función objetivo cambia la prioridad de la variable correspondiente.

En general, aunque se observan cambios en las decisiones a lo largo del análisis de sensibilidad, estos no son drásticos entre escenarios consecutivos, como los incrementos del 10%, 20% o 40% al inicio del análisis. Sin embargo, hacia el final, a partir del 80% de la *tic*, se registra una estabilidad en las decisiones, en cada uno de los casos con respecto al escenario anterior.

6.4.2. *Límite de Carbono (cpeh)*


Límite de emisiones de carbono: se refiere a la suma de las emisiones generadas a lo largo de las operaciones y eslabones de la cadena de suministro, desde el proveedor hasta el cliente final. Esta cantidad no debe exceder un límite establecido, denominado $cpeh_t$, el cual varía según la industria y la normativa de cada país. Es el gobierno quien asigna esta cuota de carbono al fabricante. Si las emisiones de carbono superan el límite permitido, el fabricante deberá comprar créditos de carbono en el mercado de comercio de carbono. Por el contrario, si las emisiones reales son inferiores al límite, el fabricante puede vender los créditos sobrantes para obtener beneficios (Shuang et al., 2019). Esta regulación promueve la sostenibilidad y afecta la competitividad de las empresas, ya que algunos países imponen políticas más estrictas que otros (Huang et al., 2020).

En esta subsección se examina la variación de estos límites y su impacto en el comportamiento del modelo de la cadena de suministro formulado. Además, se analiza cómo la imposición de restricciones a las emisiones de CO₂ influye en las decisiones de diseño de la red. El análisis de sensibilidad de las emisiones se realiza para un rango de -30% a 30% (Figura 7).

El análisis de la Figura 7 reveló tres hallazgos principales sobre el impacto de los límites de emisiones de carbono en los costos totales y ambientales. El primer hallazgo muestra una relación inversamente proporcional entre el límite de emisiones de carbono y los costos totales. A medida que el límite de emisiones aumenta, los costos disminuyen, con la excepción del Caso 1, donde este límite no tiene efecto al no ser considerado en la modelación. Debido a esto se observa una tendencia decreciente a lo largo del gráfico, que muestra que las variaciones entre -30% y -5%, generan cambios mayores en la función objetivo. Esto se traduce en un aumento notable de los costos cuando los límites de emisiones de carbono son más estrictos (Caso 2 y Caso 3), reflejando mayor presión sobre las operaciones a medida que se endurecen las

regulaciones. Sin embargo, después del 0%, el aumento en el límite de emisiones genera una estabilización de los costos en los casos 2 y 3. En contraste, cuando los cambios en la función objetivo varían entre un 5% y un 30%, el impacto es menor. Esto sugiere que, una vez alcanzado un cierto nivel de flexibilidad en las emisiones, los incrementos en el límite de emisiones tienen un efecto menos significativo sobre los costos.

Figura 7.
Sensibilidad límite de carbono



Nota. F.O. representa la función objetivo y C.A. el costo ambiental. R (1) hace referencia al Caso 1, R (1 y 2) al Caso 2, y R (1 y 3) al Caso 3.

El segundo hallazgo señala que en el Caso 2, cuando el límite de emisiones de carbono supera el 100% del inicial, las restricciones se vuelven lo suficientemente holgadas como para dejar de ser activas y por lo tanto, relevantes para el modelo. En consecuencia, las decisiones del Caso 2 tienden a alinearse con las del Caso 1 (donde únicamente se incluye el impuesto al carbono), resultando en costos similares. En los casos 2 y 3, se observan cambios más notables en las decisiones a medida que las variaciones en el límite de carbono aumentan. En particular, el Caso 3 converge con el Caso 2 cuando el límite de emisiones aumenta entre el 5% y el 37.5%,

esto se debe a que si el límite de emisiones aumenta tanto pero no lo suficiente, no es necesario comprar o vender emisiones de carbono, y si esto no ocurre, el Caso 3 se comporta como el caso 2, excluyendo el comercio de carbono, y las decisiones son las mismas para ambos casos.

El tercer hallazgo destaca que bajo los cambios considerados en el límite de emisiones, el Caso 2 es el más estricto en términos de impacto ambiental, pero también el más costoso. Aunque presenta los menores costos ambientales, también muestra los mayores costos totales en todos los escenarios analizados. Cuando el límite de emisiones se reduce a una quinta parte por debajo de su valor inicial, el modelo no puede encontrar una solución óptima que cumpla con las restricciones de demanda, capacidad y emisiones, como se observa en la Figura 7 para disminuciones iguales o superiores al 22%. Adicionalmente, el Caso 3 sigue las mismas dinámicas mencionadas previamente, mostrando un equilibrio entre las dimensiones económica y ambiental cuando se dan condiciones favorables. Esto es particularmente evidente en el rango comprendido entre el -10% y el 5%.

7. Experimentación a través del Modelo

Tras definir y validar el modelo general con el caso base, la siguiente fase metodológica se centra en generar soluciones generales y realizar experimentaciones. En esta sección se presentan los resultados del Diseño de la Cadena de Suministro (DCS), evaluando tanto el modelo de optimización sin incertidumbre (sin predicciones, sección 5.2) como el modelo de optimización con incertidumbre, que incorpora los resultados del mejor modelo predictivo (secciones 5.2 y 5.3).

Para la ejecución de los modelos propuestos, se utilizó Python como entorno de desarrollo, empleando la licencia Academic Named-User License de *Gurobi Optimization*, accesible a través de la red de la Universidad Industrial de Santander. A continuación, se

detallan la versión de Python utilizada y las características técnicas del software y hardware empleados en la ejecución de los modelos (ver Tabla 29).

Tabla 29.

Software y hardware para la implementación de los modelos

Categoría	Especificaciones
Versión de Python	Python 3.12.3
Procesador	AMD Ryzen™ 7 7730U con gráficos Radeon, 8 núcleos Frecuencia: 2.00 GHz - 4.50 GHz
Memoria RAM	16 GB
Almacenamiento	1 TB
Sistema Operativo	Sistema operativo de 64 bits

Dado que el modelo MILP presentado incluye tres casos, cada uno evaluado en dos escenarios (con y sin incertidumbre), es necesario realizar un análisis de su comportamiento basado en el tamaño de las instancias para comprender mejor su desempeño. Estas instancias se dividen en 15 conjuntos, organizados según tres tipos de tamaños: pequeño, mediano y grande. Este enfoque permite evaluar cómo varía el rendimiento del modelo en función de la complejidad y la dimensión de las instancias. Las instancias de prueba fueron adaptadas a partir de las propuestas por Goodarzian et al., (2021), considerando un rango de productos (p) que oscila entre 4 y 100, fabricantes (m) que van de 3 a 75, tipos de vehículos (v) de 2 a 50 y periodos de tiempo (t) de 1 a 26. La Tabla 30 muestra los índices y la cantidad de variables que surgen a partir de la combinación de todos estos elementos.

Tabla 30.

Instancias experimentales

Clasificación	#	p	m	v	t	$p * m * v * t$
<i>Pequeñas</i>	S1	4	3	2	1	24
	S2	8	6	4	2	384
	S3	12	9	6	3	1.944
	S4	16	12	8	4	6.144

	S5	20	15	10	5	15.000
	M6	24	18	12	6	31.104
	M7	28	21	14	7	57.624
<i>Medianas</i>	M8	32	24	16	8	98.304
	M9	36	27	18	9	157.464
	M10	40	30	20	10	240.000
	L11	44	33	22	12	383.328
	L12	52	39	26	14	738.192
<i>Grandes</i>	L13	64	48	32	17	1.671.168
	L14	80	60	40	21	4.032.000
	L15	100	75	50	26	9.750.000

Es importante destacar que la complejidad de los modelos depende en gran medida de la cantidad de índices que se contemplan en la red de suministro. La Tabla 31 muestra las características de los modelos MLSPAP-PC⁵ para la instancia de mayor tamaño en los tres tipos de casos (1, 2 y 3) y los tres tamaños (pequeño, mediano y grande).

Tabla 31.

Características de los modelos MILP - MLSPAP-PC.

Casos de prueba	Número de variables	Restricciones	Tiempo computacional [s]
1.1	16665	6100	3,5
1.2	252680	48400	23,5
1.3	9949502	782600	1515,6
2.1	16665	6105	5,8
2.2	252680	48410	38,9
2.3	9949502	782626	6565
3.1	16675	6120	4,4
3.2	252700	48440	40,6
3.3	9949554	782704	162000

⁵ Problema de Asignación de Tamaño de Lotes Multinivel y Periodo con Capacidades de Producción

Finalmente, con el objetivo de presentar los resultados generales de los tres casos con regulaciones de carbono descritos en la sección 6, se realizan experimentos para los tres tamaños de instancias, considerando la incertidumbre analizada en la sección 5.3. Estos experimentos integran el mejor modelo de predicción, CatBoost⁶, que incorpora un Error Absoluto Porcentual Medio (MAPE) del 72.903 %. Este error se ha sumado a los parámetros de demanda, aplicando este enfoque al modelo de optimización detallado en las secciones 5.1 y 5.2, lo que convierte al modelo en un enfoque analítico general para la toma de decisiones. Las secciones siguientes profundizan en el análisis detallado de estos resultados.

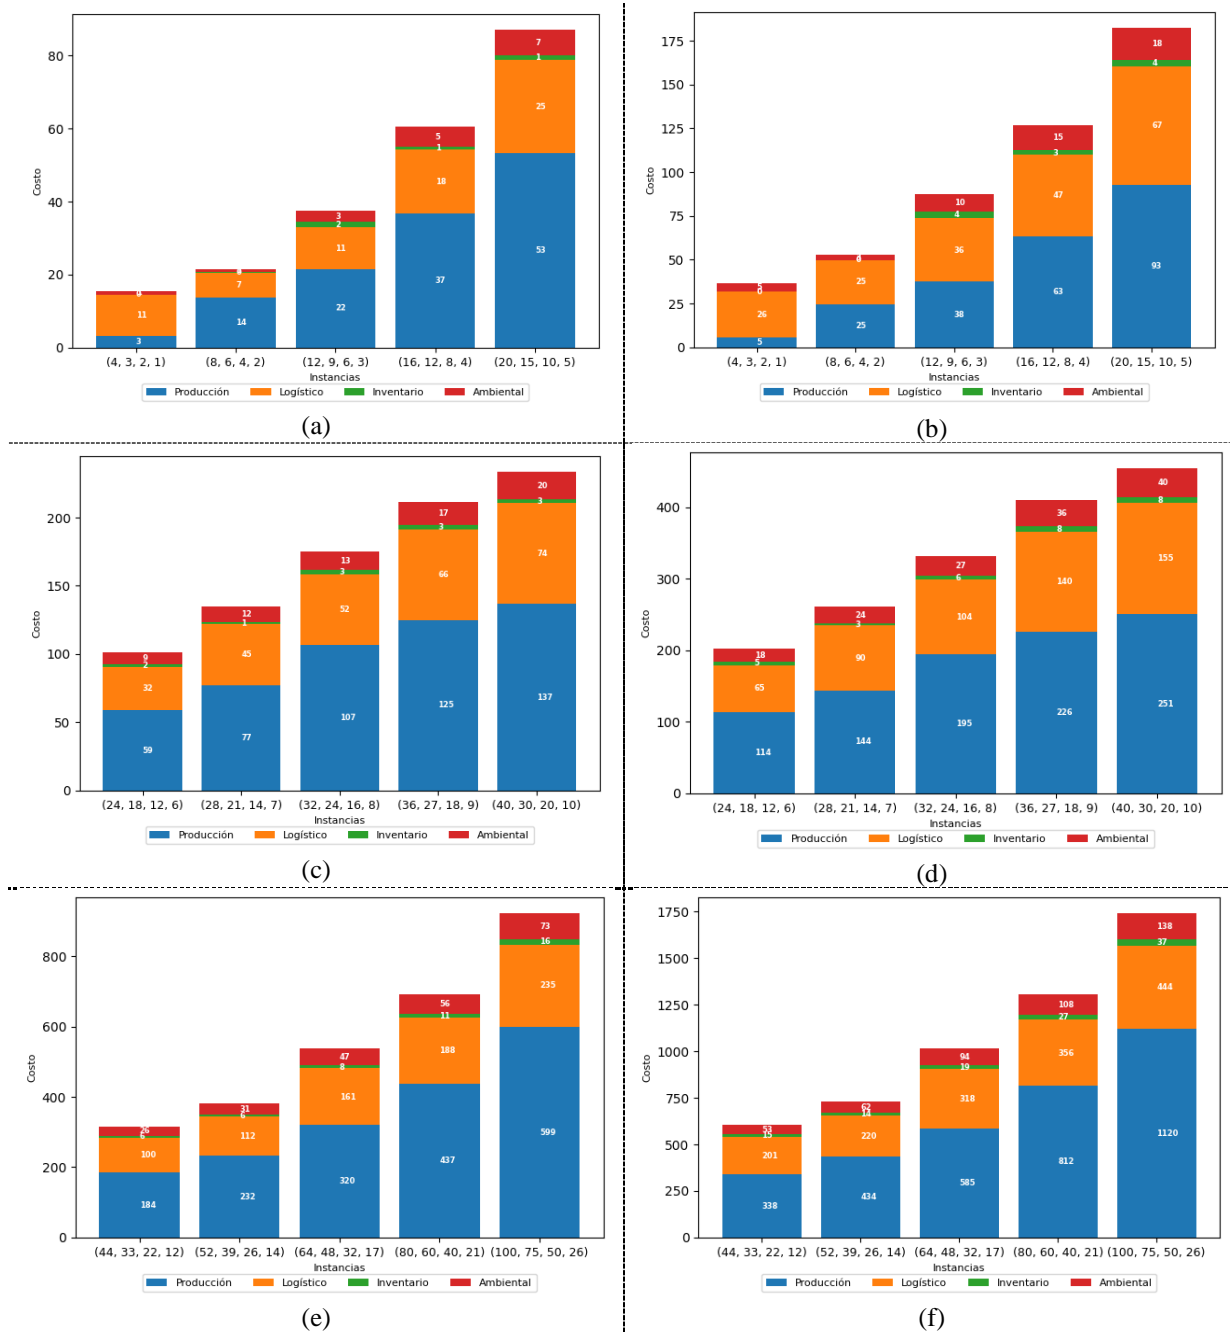
7.1. Modelo Analítico - Caso 1

Para llevar a cabo este análisis macro del modelo analítico en el Caso 1, se utilizaron las entradas del modelo, considerando las regulaciones de carbono, los parámetros asociados y el nivel de incertidumbre presente en el sistema.

Los resultados presentados en la Figura 8 destacan tres patrones claros. En primer lugar, tanto en los escenarios sin y con incertidumbre, los costos de Producción y Logística (Pedido y Transporte) son consistentemente los más altos en todas las instancias, debido a que sus valores unitarios son considerablemente mayores en comparación con los otros costos. También que, aunque los costos Ambientales y de Inventario representan una menor proporción, tienden a estabilizarse ligeramente en las instancias medianas y grandes.

⁶ CatBoost con los hiperparámetros `N_estimators: 200`, `Max_depth: 10`, `Learning_rate: 0.2`, `Subsample: 0.8` y `Colsample_bytree: 0.8`.

Figura 8.
Costos totales por instancias e incertidumbre - Caso 1



Nota. Los gráficos (a), (c) y (e) representan los modelos sin incertidumbre, mientras que los demás muestran los resultados con una incertidumbre del 72.903%.

En segundo lugar, al introducir la incertidumbre, el costo total se incrementa de forma significativa: más del doble en las instancias pequeñas y casi el doble en las medianas y grandes.

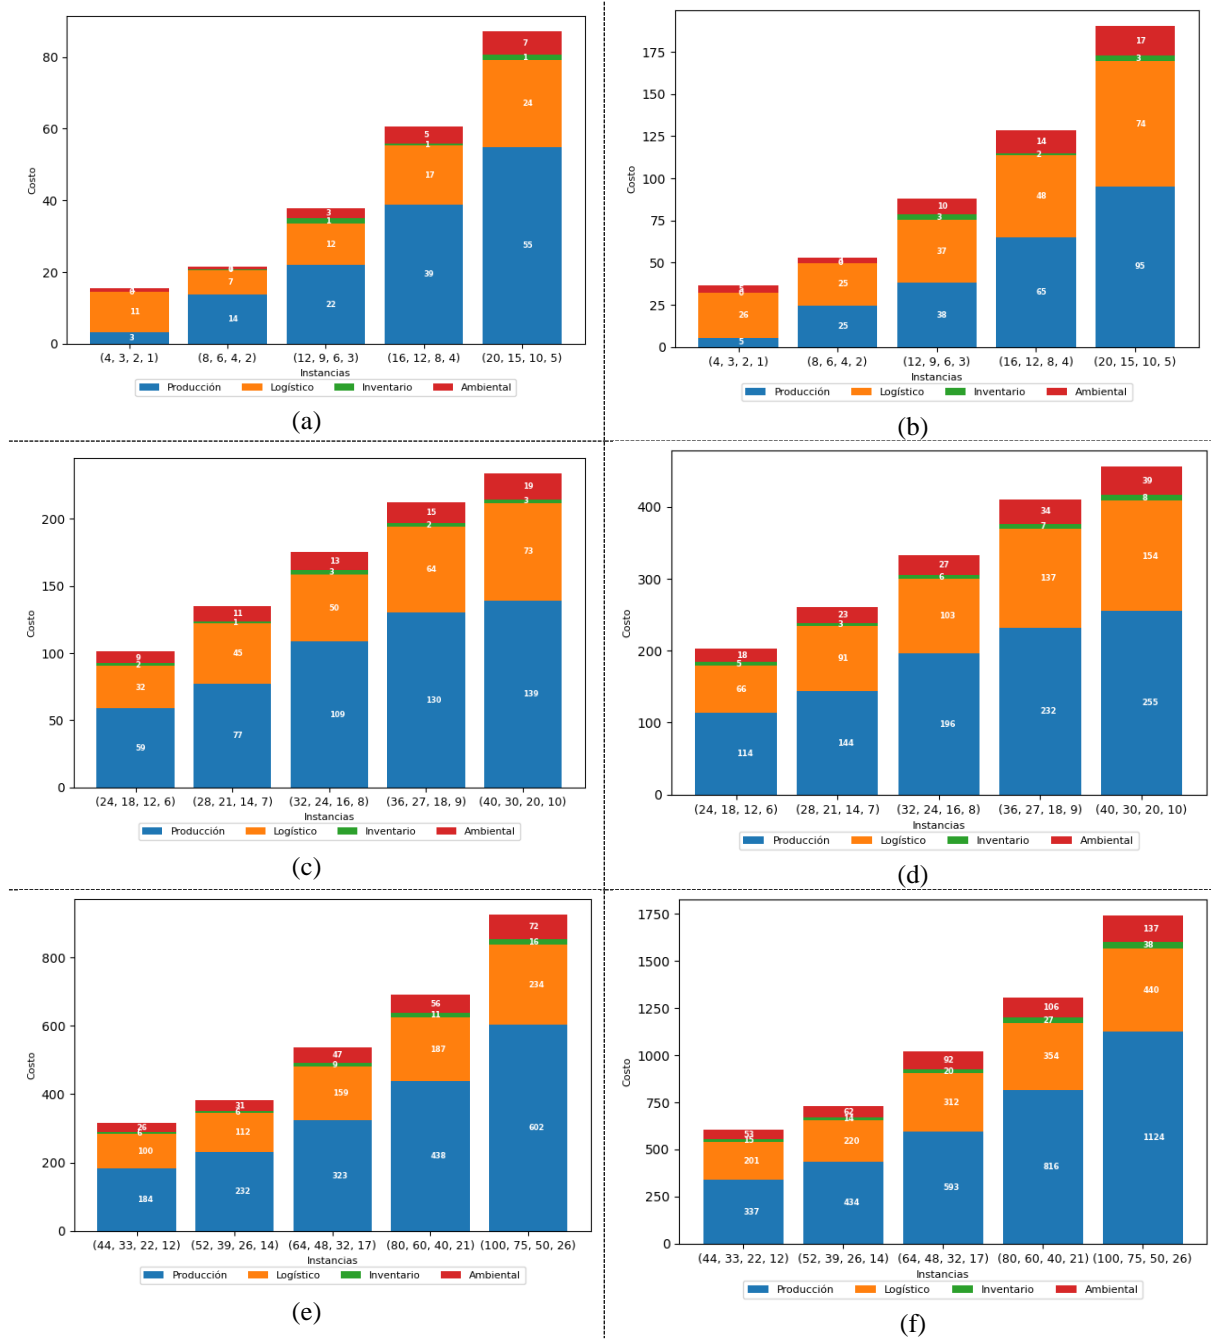
Esto sugiere que la incertidumbre afecta más a las instancias pequeñas, donde la demanda es más difícil de suplir debido a una menor flexibilidad en las combinaciones posibles del modelo. Finalmente, aunque los costos totales son más bajos en los escenarios sin incertidumbre, las proporciones de los distintos tipos de costos se mantienen relativamente constantes al introducirla (ver Apéndice D). Esto indica que la incertidumbre no modifica sustancialmente la estructura de los costos, ya que las decisiones no experimentan cambios significativos. Sin embargo, la incertidumbre sí genera un notable aumento en el costo total, particularmente en los costos Ambientales, relacionados con las emisiones de carbono y la Tasa del Impuesto al Carbono (1^{ra} regulación).

7.2. Modelo Analítico - Caso 2

El análisis de este segundo caso se fundamenta en los mismos factores establecidos en la sección 7.1. Sin embargo, incorpora la regulación de límites de carbono, lo que introduce una dimensión adicional al estudio del impacto de los costos y las emisiones en la cadena de suministro.

Los resultados observados en la Figura 9 para el Caso 2 siguen una lógica similar al Caso 1, con un incremento considerable en los costos debido a la incertidumbre, casi duplicándose. Sin embargo, se identifican tres diferencias claves. En primer lugar, las proporciones de los costos cambian ligeramente en comparación con el Caso 1 (ver Apéndice D para mayor claridad), lo que refleja pequeñas variaciones en las decisiones relacionadas con la configuración de la cadena de suministro. En segundo lugar, la implementación de la regulación del límite de carbono muestra un impacto positivo, reduciendo los costos ambientales y, por ende, las emisiones de carbono en todas las instancias, lo cual está en concordancia con lo analizado en la sección 6.2, y no se observa para el Caso 1.

Figura 9.
Costos totales por instancias e incertidumbre - Caso 2



Nota. Los gráficos (a), (c) y (e) representan los modelos sin incertidumbre, mientras que los demás muestran los resultados con una incertidumbre del 72.903%.

Por último, aunque los costos logísticos siguen siendo relevantes en las primeras instancias en ambos casos, en el Caso 2 se percibe una leve disminución, derivada de la reducción de las emisiones y los costos ambientales que se genera por la imposición de una cantidad emisiones por periodo (*cpeh*), lo que refleja un efecto más equilibrado en las decisiones y un mayor control de emisiones bajo la 1^{ra} y 2^{da} regulación de carbono.

7.3. Modelo Analítico - Caso 3

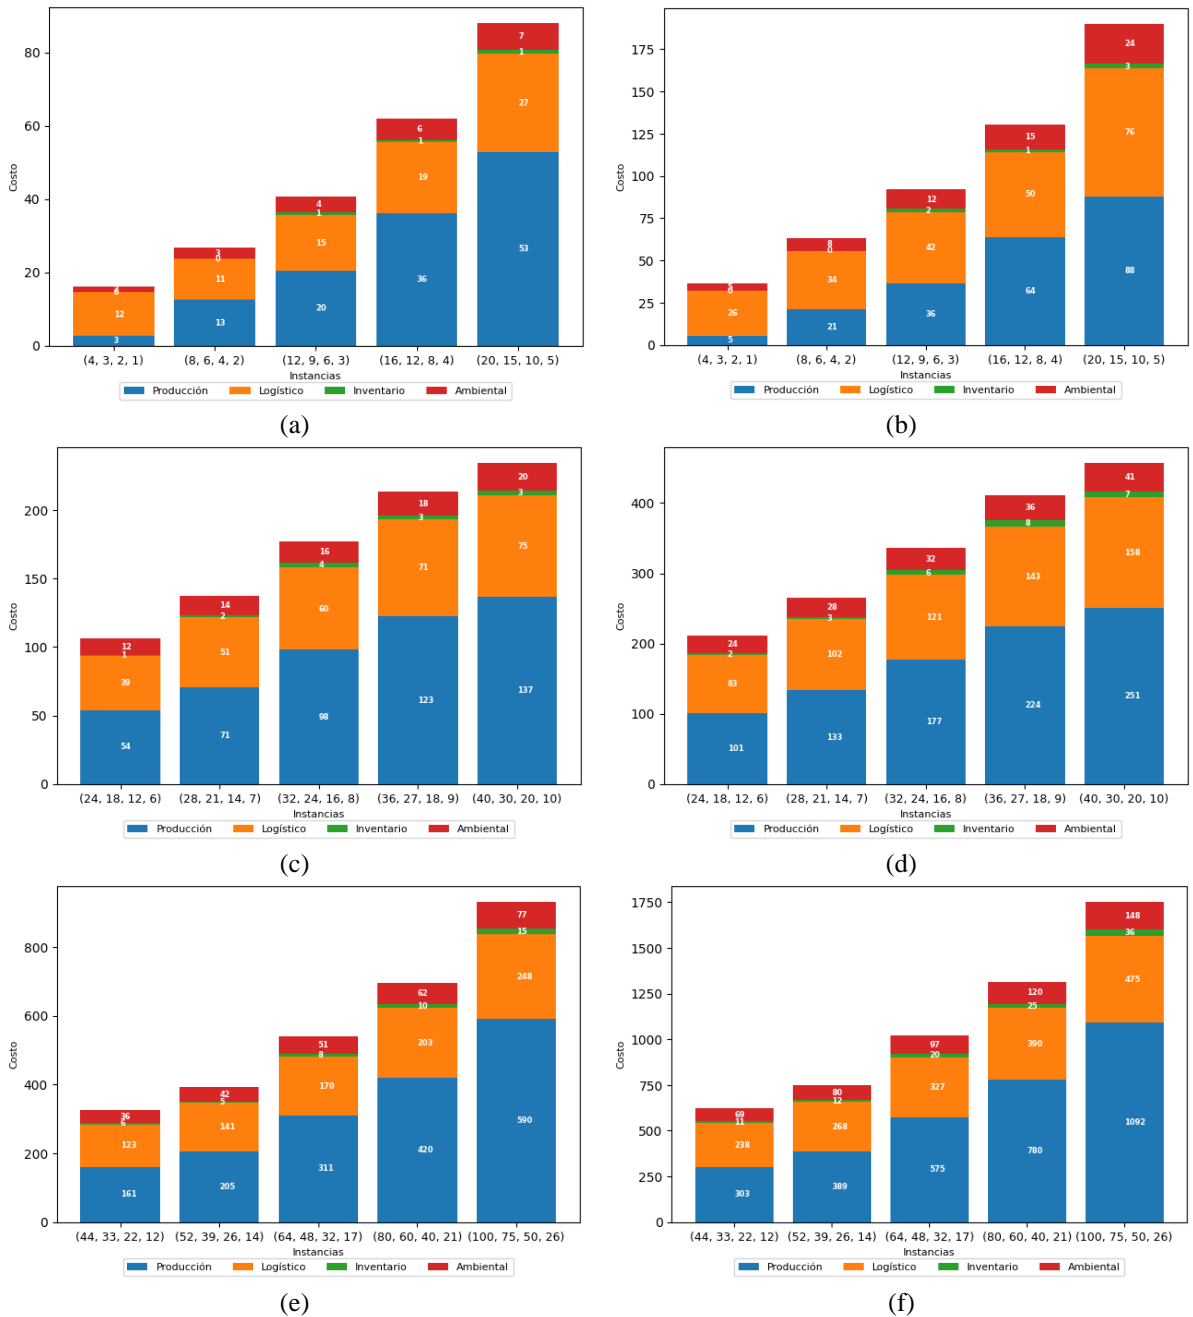
El análisis de este tercer caso se fundamenta en los mismos factores establecidos en las secciones 7.1 y 7.2. Sin embargo, la incorporación de la regulación de Tope y Comercio introduce una capa adicional de complejidad, lo que impacta no solo en los costos totales, sino también en la proporción de cada tipo de costo y las emisiones de carbono en la cadena de suministro.

El Caso 3 comparte las mismas dinámicas observadas en los casos 1 y 2, donde el aumento de la escala del modelo y la introducción de incertidumbre generan un incremento en los costos totales y en donde la proporción entre los diferentes tipos de costos se mantiene relativamente constante, cuando se incrementa la incertidumbre de la cadena de suministro. Lo cual sugiere que la incertidumbre incrementa el costo general sin alterar significativamente la estructura de los costos en ninguna de las tres regulaciones de carbono. Igualmente, los costos de Producción y Logística siguen siendo los más altos, mientras que los costos Ambientales y de Inventario se mantienen en niveles más bajos a lo largo de todas las instancias (Figura 10).

A pesar de esto, la principal diferencia en el Caso 3 radica en la implementación de la regulación de Tope y Comercio, que estabiliza los costos a medida que crecen los tamaños de las instancias. Esta regulación facilita una gestión más eficiente de las emisiones, tanto las

utilizadas como las compradas o vendidas en el mercado de derechos de emisión, lo que permite un balance más efectivo sobre los aspecto económicos y ambientales.

Figura 10.
Costos totales por instancias e incertidumbre – Caso 3



Nota. Los gráficos (a), (c) y (e) representan los modelos sin incertidumbre, mientras que los demás muestran los resultados con una incertidumbre del 72.903%.

Finalmente, también se observa que a medida que las instancias crecen, los costos de Inventario y Logística presentan incrementos más pronunciado en comparación con instancias más pequeñas. No obstante, en las instancias de mayor tamaño, estos costos comienzan a reducir su participación en el costo total de manera paulatina, mientras que los costos de Producción tienden a un comportamiento opuesto, estabilizándose en torno al 50-60% del costo total, Esto refleja una distribución menos equilibrada conforme aumenta la escala del modelo, tal como se confirma en el Apéndice D.

7.4. Análisis de los Resultados

La incertidumbre en los modelos de optimización es fundamental, ya que refleja de manera más precisa las condiciones reales de una cadena de suministro, donde parámetros como la demanda, los costos, capacidades, entre otros pueden variar inesperadamente. Como se ha discutido en las secciones anteriores (7.1-7.3), la incorporación de incertidumbre conduce a un incremento significativo en los costos totales, lo que evidencia que los modelos que no la consideran tienden a subestimar los riesgos y desafíos operativos. En un escenario sin incertidumbre, se asume que los parámetros se conocen con certeza en cada período, lo cual no refleja la realidad. Por ello, es crucial incorporar un modelo de predicción que utilice estimaciones más cercanas a la realidad, permitiendo una toma de decisiones informadas en términos de producción, logística y almacenamiento. Esto ayuda a obtener resultados más precisos, incluso en periodos futuros, cuyos parámetros solo serán conocidos a medida que se desarrollen.

La precisión del modelo predictivo, medida por un bajo MAPE, es clave para una gestión eficiente de la incertidumbre, ya que ajusta mejor los resultados a la realidad operativa. Las variaciones observadas en las Figuras 8, 9 y 10 muestran que, sin una predicción precisa, los

errores se amplifican en las decisiones estratégicas, lo que resulta en un incremento de costos, especialmente en las fases iniciales donde la variabilidad en la estructura de costos es mayor (Apéndice D). Asimismo, la falta de precisión en los modelos de predicción puede derivar en un sobre costo total en el diseño de la cadena de suministro.

Desde la perspectiva organizativa, la capacidad de una empresa para gestionar y reducir la incertidumbre depende en gran medida de su inversión en tecnología y del uso eficiente de análisis de datos. Una empresa con una sólida base financiera puede asignar recursos a investigación y desarrollo (I+D), lo que le permite desarrollar modelos predictivos más avanzados, evaluados a partir de métricas como el MAPE u otras medidas de precisión. Estos modelos mejorados no solo reducen la incertidumbre, sino que también aumentan la capacidad de la empresa para adaptarse a cambios inesperados, como fluctuaciones en la demanda o ajustes en las regulaciones ambientales, optimizando así la toma de decisiones y mejorando el rendimiento operativo.

Finalmente, una gestión adecuada de la incertidumbre no solo optimiza la toma de decisiones estratégicas, sino que también alinea estrechamente los resultados del modelo con condiciones reales del entorno operativo. Esto refuerza la resiliencia del sistema, reduciendo la variabilidad en los costos totales y proporcionando estabilidad a lo largo del tiempo. En cuanto a las regulaciones de carbono, una predicción precisa permite a las empresas cumplir eficazmente con las normativas, ajustando sus operaciones de manera proactiva para mitigar los costos asociados con las emisiones, como los impuestos, los límites y el comercio de derechos de carbono, y permitiendo así una gestión ambiental más eficiente.

8. Conclusiones

A partir de los resultados obtenidos en esta investigación, se concluye que la literatura identifica al transporte, la producción y el almacenamiento de inventarios como las principales fuentes de emisiones de carbono en la cadena de suministro, en ese orden. Las regulaciones con mayor impacto en la reducción de las emisiones y más relevantes son el impuesto sobre el carbono, el límite de carbono y el sistema de tope y comercio. Además, se ha observado que la mayoría de los modelos existentes tratan las emisiones de carbono de manera independiente, utilizando enfoques de modelación basados en Programación Lineal Entera Mixta - MILP, con uno o dos objetivos de optimización. Por último, se destaca que la naturaleza o el sentido de optimización más común en los estudios sobre sostenibilidad ambiental es la minimización, principalmente enfocada en la reducción de costos o emisiones totales.

Adicionalmente, este estudio concluye que analizar el control ambiental en la cadena de suministro mediante diferentes modelos MLSPAP-PC con regulaciones de emisiones de carbono son una herramienta clave para mejorar la toma de decisiones estratégicas. Dada la complejidad y particularidades de cada sistema, así como las diferencias entre las empresas y países, es esencial que estas estrategias estén alineadas con los objetivos organizacionales. En este contexto, los resultados también indican que la política de Impuesto al Carbono es más flexible en términos de costos, pero tienen un mayor impacto ambiental en comparación con el límite de carbono y el sistema de tope y comercio. En cambio, la política de Límite de Carbono ofrece mejores resultados en la reducción de emisiones, aunque con costos económicos más elevados. Por último, la política de Tope y Comercio demuestra un balance

entre los impactos económicos y ambientales, siempre que se moderen adecuadamente los distintos parámetros, evitando sobrecargar uno u otro aspecto en las operaciones.

Finalmente, desde la perspectiva del tamaño de las instancias y la incorporación de incertidumbre en el sistema, se observa que, a medida que crecen tanto la escala del problema como la incertidumbre, los costos totales de la cadena de suministro se incrementan de manera notable. No obstante, aunque la incertidumbre eleva el costo total (llegando a duplicarse o más), el aumento relativo en los distintos tipos de costos se mantiene entre los tres casos evaluados. En promedio, los costos de producción aumentan un 80%, los ambientales un 120%, los logísticos un 130% y los de inventario un 140%, todos en proporción directa con el grado de incertidumbre. Por otro lado, los cambios en la magnitud del sistema no solo incrementan los costos totales, sino que también alteran la distribución entre las diferentes categorías de costos. Esto sugiere que, mientras la incertidumbre provoca un aumento global de los costos, es la escala del sistema la que impacta tanto la estructura como el valor total de estos.

9. Recomendaciones

La regulación de las emisiones o huella de carbono es una herramienta clave para evaluar y mitigar el impacto ambiental generado por las actividades comerciales y productivas dentro de una cadena de suministro. Las empresas deben organizar sus redes de manera integral, considerando tanto las actividades hacia adelante como hacia atrás en la cadena. Esta visión holística es esencial para identificar y gestionar los impactos ambientales en toda la cadena, especialmente cuando se contemplan distintos niveles de emisiones. Esto incluye las emisiones directas provenientes de las actividades operativas, como el consumo de combustibles fósiles, emisiones de Alcance 1, las emisiones indirectas generadas por el consumo de energía adquirida (Alcance 2), y aquellas relacionadas con las cadenas de suministro extendidas, como las emisiones de los proveedores y el uso de productos por parte de los consumidores (Alcance 3). Este enfoque integral, que considera diversas fuentes de emisiones, permite a las empresas una visión general sobre el verdadero impacto ambiental.

Los modelos propuestos en esta investigación abordan los aspectos económicos y ambientales en el Diseño de la Cadena de Suministro, cubriendo dos de las tres dimensiones fundamentales del Triple Resultado. No obstante, para alcanzar una sostenibilidad integral, resulta esencial incorporar los aspectos sociales. Integrar componentes que promuevan la responsabilidad social corporativa permitiría una gestión más holística de las operaciones, abordando aspectos como el bienestar de los trabajadores, el impacto social en las comunidades y la equidad a lo largo de toda la cadena de suministro. Esto no solo garantizaría la optimización de los recursos y emisiones, sino que también contribuiría al desarrollo social y fomentaría una mayor responsabilidad ética en todos los eslabones de la cadena de suministro.

Además, una mayor inversión en analítica de datos por parte de las empresas podría resultar clave para mitigar la incertidumbre. Con el uso de herramientas analíticas más avanzadas, las organizaciones pueden desarrollar modelos más precisos que permitan prever con mayor exactitud fluctuaciones en la demanda, costos y operaciones. Esto no solo reduciría los niveles de incertidumbre, sino que también conduciría a una disminución de los costos en la cadena de suministro. Por lo tanto, al integrar una mejor capacidad analítica, las empresas no solo optimizarían sus recursos, sino que también minimizarían riesgos y aumentarían la eficiencia operativa, mejorando su capacidad de respuesta en un entorno cada vez más dinámico y complejo.

Por último, se recomienda contar con fuentes de datos reales, completas y confiables que permitan validar y contrastar los modelos teóricos con la realidad. Esto no solo facilitará una comprensión más profunda de los desafíos ambientales, sino que también permitirá identificar patrones y tendencias específicas a las que se enfrentan distintos sectores y empresas. Dichos datos son esenciales para adaptar soluciones a las necesidades reales y evaluar la efectividad de las estrategias propuestas. Además, este enfoque contribuirá a abordar problemas ambientales en diversos niveles, desde el ámbito departamental hasta el nacional e internacional, promoviendo acciones más informadas y alineadas con las metas globales de sostenibilidad.

10. Referencias Bibliográficas

- Abbasi, S., & Ahmadi Choukolaei, H. (2023). A systematic review of green supply chain network design literature focusing on carbon policy. *Decision Analytics Journal*, 6, 100189. <https://doi.org/10.1016/J.DAJOUR.2023.100189>
- Agarwal, S. (2024). *Group Bimbo Predictive Model*. <https://www.kaggle.com/code/agshiv92/group-bimbo-predictive-model#1.2-Configuration>
- Alavidoost, M. H., Tarimoradi, M., & Zarandi, M. H. F. (2018). Bi-objective mixed-integer nonlinear programming for multi-commodity tri-echelon supply chain networks. *Journal of Intelligent Manufacturing*, 29(4), 809–826. <https://doi.org/10.1007/S10845-015-1130-9/METRICS>
- Alles, M. G. (2015). Drivers of the use and facilitators and obstacles of the evolution of big data by the audit profession. *Accounting Horizons*, 29(2), 439–449. <https://doi.org/10.2308/ACCH-51067>
- Asghari, M., Fathollahi-Fard, A. M., Mirzapour Al-E-Hashem, S. M. J., & Dulebenets, M. A. (2022). Transformation and Linearization Techniques in Optimization: A State-of-the-Art Survey. *Mathematics 2022*, Vol. 10, Page 283, 10(2), 283. <https://doi.org/10.3390/MATH10020283>
- Astanti, R. D., Daryanto, Y., & Dewa, P. K. (2022). Low-Carbon Supply Chain Model under a Vendor-Managed Inventory Partnership and Carbon Cap-and-Trade Policy. *Journal of Open Innovation: Technology, Market, and Complexity*, 8(1), 30. <https://doi.org/10.3390/JOITMC8010030>
- Baars, H., Felden, C., Gluchowski, P., Hilbert, A., Kemper, H. G., & Olbrich, S. (2014). Shaping the next incarnation of Business intelligence: Towards a flexibly governed

network of information integration and analysis capabilities. *Business and Information Systems Engineering*, 6(1), 11–16. <https://doi.org/10.1007/S12599-013-0307-Z/FIGURES/1>

Baudry, M., Faure, A., & Quemin, S. (2021). Emissions trading with transaction costs. *Journal of Environmental Economics and Management*, 108, 102468. <https://doi.org/10.1016/J.JEEM.2021.102468>

Bendoly, E. (2016). Fit, Bias, and Enacted Sensemaking in Data Visualization: Frameworks for Continuous Development in Operations and Supply Chain Management Analytics. *Journal of Business Logistics*, 37(1), 6–17. <https://doi.org/10.1111/JBL.12113>

Benjaafar, S., Li, Y., & Daskin, M. (2013). Carbon footprint and the management of supply chains: Insights from simple models. *IEEE Transactions on Automation Science and Engineering*, 10(1), 99–116. <https://doi.org/10.1109/TASE.2012.2203304>

Brito, P. Q., Soares, C., Almeida, S., Monte, A., & Byvoet, M. (2015). Customer segmentation in a large database of an online customized fashion business. *Robotics and Computer-Integrated Manufacturing*, 36, 93–100. <https://doi.org/10.1016/j.rcim.2014.12.014>

Cadavid-Giraldo, N., Velez-Gallego, M. C., & Restrepo-Boland, A. (2020). Carbon emissions reduction and financial effects of a cap and tax system on an operating supply chain in the cement sector. *Journal of Cleaner Production*, 275, 122583. <https://doi.org/10.1016/J.JCLEPRO.2020.122583>

Cao, K., He, P., & Liu, Z. (2019). Production and pricing decisions in a dual-channel supply chain under remanufacturing subsidy policy and carbon tax policy. *Https://Doi-Org.Bibliotecavirtual.Uis.Edu.Co/10.1080/01605682.2019.1605471*, 71(8), 1199–1215. <https://doi.org/10.1080/01605682.2019.1605471>

Castellano, D., Gallo, M., Grassi, A., & Santillo, L. C. (2019). The effect of GHG emissions on production, inventory replenishment and routing decisions in a single vendor–multiple buyers supply chain. *International Journal of Production Economics*, 218, 30–42. <https://doi.org/10.1016/J.IJPE.2019.04.010>

Chehbi-Gamoura, S., Derrouiche, R., Damand, D., & Barth, M. (2019). Insights from big Data Analytics in supply chain management: an all-inclusive literature review using the SCOR model. *Https://Doi.Org/10.1080/09537287.2019.1639839*, 31(5), 355–382. <https://doi.org/10.1080/09537287.2019.1639839>

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 13-17-August-2016, 785–794. https://doi.org/10.1145/2939672.2939785/SUPPL_FILE/KDD2016_CHEN_BOOSTING_SYSTEM_01-ACM.MP4

Chern, M. S., Pan, Q., Teng, J. T., Chan, Y. L., & Chen, S. C. (2013). Stackelberg solution in a vendor–buyer supply chain model with permissible delay in payments. *International Journal of Production Economics*, 144(1), 397–404. <https://doi.org/10.1016/J.IJPE.2013.03.008>

Choudhary, A., Sarkar, S., Settur, S., & Tiwari, M. K. (2015). A carbon market sensitive optimization model for integrated forward–reverse logistics. *International Journal of Production Economics*, 164, 433–444. <https://doi.org/10.1016/J.IJPE.2014.08.015>

Council of Supply Chain Management Professionals (CSCMP). (2019). *The Grants Register 2019*, 259–260. https://doi.org/10.1007/978-1-349-95810-8_371

CREE. (2021). *Puntos clave del reporte del Grupo de Trabajo I del IPCC - CREE*. <https://creenergia.org/puntos-clave-del-reporte-del-grupo-de-trabajo-i-del-ipcc/>

- Diabat, A., Abdallah, T., Al-Refaie, A., Svetinovic, D., & Govindan, K. (2013). Strategic closed-loop facility location problem with carbon market trading. *IEEE Transactions on Engineering Management*, 60(2), 398–408. <https://doi.org/10.1109/TEM.2012.2211105>
- Dorogush, A. V., Ershov, V., & Yandex, A. G. (2018). *CatBoost: gradient boosting with categorical features support*. <https://arxiv.org/abs/1810.11363v1>
- Duan, L., & Xiong, Y. (2015). Big data analytics and business analytics. *Https://Doi-Org.Bibliotecavirtual.Uis.Edu.Co/10.1080/23270012.2015.1020891*, 2(1), 1–21. <https://doi.org/10.1080/23270012.2015.1020891>
- Fahimnia, B., Sarkis, J., Boland, J., Reisi, M., & Goh, M. (2014). *International Journal of Production Research Policy insights from a green supply chain optimisation model*. *Policy insights from a green supply chain optimisation model*. <https://doi.org/10.1080/00207543.2014.958592>
- Gholamian, N., Mahdavi, I., Mahdavi-Amiri, N., & Tavakkoli-Moghaddam, R. (2021). Hybridization of an interactive fuzzy methodology with a lexicographic min-max approach for optimizing a multi-period multi-product multi-echelon sustainable closed-loop supply chain network. *Computers & Industrial Engineering*, 158, 107282. <https://doi.org/10.1016/J.CIE.2021.107282>
- Gomilšek, R., Čuček, L., Homšak, M., Tan, R. R., & Kravanja, Z. (2020). Carbon Emissions Constrained Energy Planning for Aluminum Products. *Energies 2020, Vol. 13, Page 2753*, 13(11), 2753. <https://doi.org/10.3390/EN13112753>
- Gondal, I. A., & Sahir, M. H. (2013). Model for biomass-based renewable hydrogen supply chain. *International Journal of Energy Research*, 37(10), 1151–1159. <https://doi.org/10.1002/ER.2970>

- Goodarzian, F., Kumar, V., & Abraham, A. (2021a). Hybrid meta-heuristic algorithms for a supply chain network considering different carbon emission regulations using big data characteristics. *Soft Computing*, 25(11), 7527–7557. <https://doi.org/10.1007/S00500-021-05711-7/FIGURES/16>
- Goodarzian, F., Kumar, V., & Abraham, A. (2021b). Hybrid meta-heuristic algorithms for a supply chain network considering different carbon emission regulations using big data characteristics. *Soft Computing*, 25(11), 7527–7557. <https://doi.org/10.1007/S00500-021-05711-7/TABLES/19>
- Gunasekaran, A., Papadopoulos, T., Dubey, R., Wamba, S. F., Childe, S. J., Hazen, B., & Akter, S. (2017). Big data and predictive analytics for supply chain and organizational performance. *Journal of Business Research*, 70, 308–317. <https://doi.org/10.1016/j.jbusres.2016.08.004>
- Guo, J., & Xi, M. (2022). Greening, Pricing and Marketing Coordination for a Complex Three-Level Supply Chain Under the Carbon Tax in China. *IEEE Access*, 10, 76895–76905. <https://doi.org/10.1109/ACCESS.2022.3192838>
- Han, Y., Wu, J., Zhai, B., Pan, Y., Huang, G., Wu, L., & Zeng, W. (2019). *Coupling a Bat Algorithm with XGBoost to Estimate Reference Evapotranspiration in the Arid and Semiarid Regions of China*. <https://doi.org/10.1155/2019>
- Hancock, J. T., & Khoshgoftaar, T. M. (2020). CatBoost for big data: an interdisciplinary review. *Journal of Big Data*, 7(1), 1–45. <https://doi.org/10.1186/S40537-020-00369-8/FIGURES/9>
- Hao, Z., Long, C., & Zhiqiang, W. (2020). Abnormal Traffic Detection Technology Based on Data Augmentation and Model Update. *Netinfo Security*, 20(2), 66. <https://doi.org/10.3969/J.ISSN.1671-1122.2020.02.009>

- Harrison, T. P. (2001). Global Supply Chain Design. *Information Systems Frontiers*, 3, 413–416.
- Hazen, B. T., Boone, C. A., Ezell, J. D., & Jones-Farmer, L. A. (2014). Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications. *International Journal of Production Economics*, 154, 72–80. <https://doi.org/10.1016/J.IJPE.2014.04.018>
- Hillier, F. S., & Lieberman, G. J. (2010). *Introducción a la investigación de operaciones*.
- Huang, Y. S., Fang, C. C., & Lin, Y. A. (2020). Inventory management in supply chains with consideration of Logistics, green investment and different carbon emissions policies. *Computers & Industrial Engineering*, 139, 106207. <https://doi.org/10.1016/J.CIE.2019.106207>
- IBM. (2021). *DOCUMENTACIÓN IBM*. <https://www.ibm.com/docs/es/spss-modeler/saas?topic=series-arima>
- Jeble, S., Dubey, R., Childe, S. J., Papadopoulos, T., Roubaud, D., & Prakash, A. (2018). Impact of big data and predictive analytics capability on supply chain sustainability. *International Journal of Logistics Management*, 29(2), 513–538. <https://doi.org/10.1108/IJLM-05-2017-0134/FULL/XML>
- Kache, F., & Seuring, S. (2017). Challenges and opportunities of digital information at the intersection of Big Data Analytics and supply chain management. *International Journal of Operations and Production Management*, 37(1), 10–36. <https://doi.org/10.1108/IJOPM-02-2015-0078/FULL/XML>
- Kannan, D., Diabat, A., Alrefaei, M., Govindan, K., & Yong, G. (2012). A carbon footprint based reverse logistics network design model. *Resources, Conservation and Recycling*, 67, 75–79. <https://doi.org/10.1016/J.RESCONREC.2012.03.005>

- Kumar, A., Jain, V., & Kumar, S. (2014). A comprehensive environment friendly approach for supplier selection. *Omega*, 42(1), 109–123. <https://doi.org/10.1016/J.OMEGA.2013.04.003>
- Kumar, S., Sigroha, M., Kumar, K., & Sarkar, B. (2022). Manufacturing/remanufacturing based supply chain management under advertisements and carbon emissions process. *RAIRO - Operations Research*, 56(2), 831–851. <https://doi.org/10.1051/RO/2021189>
- Kumari, M., Kanti De, P., Narang, P., & Shah, N. H. (2023). Integrated optimization of inventory, replenishment, and vehicle routing for a sustainable supply chain utilizing a novel hybrid algorithm with carbon emission regulation. *Expert Systems with Applications*, 220, 119667. <https://doi.org/10.1016/J.ESWA.2023.119667>
- Kushwaha, S., Ghosh, A., & Rao, A. K. (2020). Collection activity channels selection in a reverse supply chain under a carbon cap-and-trade regulation. *Journal of Cleaner Production*, 260, 121034. <https://doi.org/10.1016/J.JCLEPRO.2020.121034>
- Lai, Y. B. (2023). Capital mobility and environmental policy: taxes versus TEP. *International Tax and Public Finance*, 30(2), 326–350. <https://doi.org/10.1007/S10797-021-09721-X/METRICS>
- Li, J., Tao, F., Cheng, Y., & Zhao, L. (2015). Big Data in product lifecycle management. *International Journal of Advanced Manufacturing Technology*, 81(1–4), 667–684. <https://doi.org/10.1007/S00170-015-7151-X/METRICS>
- Li, X., Peng, Y., & Zhang, J. (2017). A mathematical/physics carbon emission reduction strategy for building supply chain network based on carbon tax policy. *Open Physics*, 15(1), 97–107. <https://doi.org/10.1515/PHYS-2017-0011/MACHINEREADABLECITATION/RIS>
- Lu, H., & Ma, X. (2020). Hybrid decision tree-based machine learning models for short-term

water quality prediction. *Chemosphere*, 249, 126169.

<https://doi.org/10.1016/J.CHEMOSPHERE.2020.126169>

Ma, X., Wang, J., Bai, Q., & Wang, S. (2020). Optimization of a three-echelon cold chain considering freshness-keeping efforts under cap-and-trade regulation in Industry 4.0. *International Journal of Production Economics*, 220, 107457. <https://doi.org/10.1016/J.IJPE.2019.07.030>

Martí, J. M. C., Tancrez, J. S., & Seifert, R. W. (2015). Carbon footprint and responsiveness trade-offs in supply chain network design. *International Journal of Production Economics*, 166, 129–142. <https://doi.org/10.1016/J.IJPE.2015.04.016>

Marufuzzaman, M., Ekşiođlu, S. D., & Hernandez, R. (2014). Environmentally Friendly Supply Chain Planning and Design for Biodiesel Production via Wastewater Sludge. *Https://Doi.Org/10.1287/Trsc.2013.0505*, 48(4), 555–574. <https://doi.org/10.1287/TRSC.2013.0505>

Mohammed, F., Selim, S. Z., Hassan, A., & Syed, M. N. (2017). Multi-period planning of closed-loop supply chain with carbon policies under uncertainty. *Transportation Research Part D: Transport and Environment*, 51, 146–172. <https://doi.org/10.1016/J.TRD.2016.10.033>

Mousavi, S. M., Bahreininejad, A., Musa, S. N., & Yusof, F. (2017). A modified particle swarm optimization for solving the integrated location and inventory control problems in a two-echelon supply chain network. *Journal of Intelligent Manufacturing*, 28(1), 191–206. <https://doi.org/10.1007/s10845-014-0970-z>

Mousavi, S. M., Foroozesh, N., Zavadskas, E. K., & Antucheviciene, J. (2020). A new soft computing approach for green supplier selection problem with interval type-2 trapezoidal fuzzy statistical group decision and avoidance of information loss. *Soft*

Computing, 24(16), 12313–12327. <https://doi.org/10.1007/S00500-020-04675-4/TABLES/7>

Mousavi, S. M., Hajipour, V., Niaki, S. T. A., & Alikar, N. (2013). Optimizing multi-item multi-period inventory control system with discounted cash flow and inflation: Two calibrated meta-heuristic algorithms. *Applied Mathematical Modelling*, 37(4), 2241–2256. <https://doi.org/10.1016/J.APM.2012.05.019>

Peng, Y., Ablanedo-Rosas, J. H., & Fu, P. (2016). A Multiperiod Supply Chain Network Design Considering Carbon Emissions. *Mathematical Problems in Engineering*, 2016. <https://doi.org/10.1155/2016/1581893>

Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2017). CatBoost: unbiased boosting with categorical features. *Advances in Neural Information Processing Systems, 2018-December*, 6638–6648. <https://arxiv.org/abs/1706.09516v5>

Qi, Q., Wang, J., & Bai, Q. (2017). Pricing decision of a two-echelon supply chain with one supplier and two retailers under a carbon cap regulation. *Journal of Cleaner Production*, 151, 286–302. <https://doi.org/10.1016/J.JCLEPRO.2017.03.011>

Randolph, J. (2009). A Guide to Writing the Dissertation Literature Review. *Practical Assessment, Research, and Evaluation*, 14, 13. <https://doi.org/10.7275/b0az-8t74>

Rardin, R. L. . (2017). *Optimization in operations research*. 1144. https://books.google.com/books/about/Optimization_in_Operations_Research.html?hl=es&id=P4s2zgEACAAJ

Rehman, M. H. U., Chang, V., Batool, A., & Wah, T. Y. (2016). Big data reduction framework for value creation in sustainable enterprises. *International Journal of Information Management*, 36(6), 917–928. <https://doi.org/10.1016/J.IJINFOMGT.2016.05.013>

- Rezaee, A., Dehghanian, F., Fahimnia, B., & Beamon, B. (2017). Green supply chain network design with stochastic demand and carbon price. *Annals of Operations Research*, 250(2), 463–485. <https://doi.org/10.1007/S10479-015-1936-Z/FIGURES/9>
- Ricke, K., Drouet, L., Caldeira, K., & Tavoni, M. (2018). Country-level social cost of carbon. *Nature Climate Change* 2018 8:10, 8(10), 895–900. <https://doi.org/10.1038/s41558-018-0282-y>
- Rizwan, S. A., Deneshkumar, V., & Senthamarai Kannan, K. (2024). Hyperparameter Optimization for Gradient-Boosted Tree-Based Machine Learning Models and Their Effect on Model Performance. *Springer Proceedings in Mathematics and Statistics*, 421, 447–456. https://doi.org/10.1007/978-3-031-51167-7_43
- Robles-Obando, N. (2017). Supply chain optimization model that incorporates its impact on climate change. *Revista Tecnología En Marcha*, 30(4), 118–129. <https://doi.org/10.18845/TM.V30I4.3416>
- Rout, C., Paul, A., Kumar, R. S., Chakraborty, D., & Goswami, A. (2021). Integrated optimization of inventory, replenishment and vehicle routing for a sustainable supply chain under carbon emission regulations. *Journal of Cleaner Production*, 316, 128256. <https://doi.org/10.1016/J.JCLEPRO.2021.128256>
- Ruggieri, G., Andreolli, F., & Zangheri, P. (2023). A Policy Roadmap for the Energy Renovation of the Residential and Educational Building Stock in Italy. *Energies* 2023, Vol. 16, Page 1319, 16(3), 1319. <https://doi.org/10.3390/EN16031319>
- Sapkota, S. C., Saha, P., Das, S., & Meesaraganda, L. V. P. (2024). Prediction of the compressive strength of normal concrete using ensemble machine learning approach. *Asian Journal of Civil Engineering*, 25(1), 583–596. <https://doi.org/10.1007/S42107-023-00796-X/FIGURES/8>

- Schildbach, G., & Morari, M. (2016). Scenario-based model predictive control for multi-echelon supply chain management. *European Journal of Operational Research*, 252(2), 540–549. <https://doi.org/10.1016/J.EJOR.2016.01.051>
- Sherali, H. D., & Adams, W. P. (2013). Reformulation-linearization techniques for discrete optimization problems. *Handbook of Combinatorial Optimization*, 5–5, 2849–2896. https://doi.org/10.1007/978-1-4419-7997-1_45
- Shi, F., Lu, S., Gu, J., Lin, J., Zhao, C., You, X., & Lin, X. (2022). Modeling and Evaluation of the Permeate Flux in Forward Osmosis Process with Machine Learning. *Industrial and Engineering Chemistry Research*, 61(49), 18045–18056. https://doi.org/10.1021/ACS.IECR.2C03064/SUPPL_FILE/IE2C03064_SI_002.ZIP
- Shinkuma, T., & Sugeta, H. (2016). Tax versus emissions trading scheme in the long run. *Journal of Environmental Economics and Management*, 75, 12–24. <https://doi.org/10.1016/J.JEEM.2015.09.002>
- Shuang, Y., Diabat, A., & Liao, Y. (2019). A stochastic reverse logistics production routing model with emissions control policy selection. *International Journal of Production Economics*, 213, 201–216. <https://doi.org/10.1016/J.IJPE.2019.03.006>
- Sinha, R. K., & Chaturvedi, N. D. (2019). A review on carbon emission reduction in industries and planning emission limits. *Renewable and Sustainable Energy Reviews*, 114, 109304. <https://doi.org/10.1016/J.RSER.2019.109304>
- Tao, F., Qi, Q., Liu, A., & Kusiak, A. (2018). Data-driven smart manufacturing. *Journal of Manufacturing Systems*, 48, 157–169. <https://doi.org/10.1016/J.JMSY.2018.01.006>
- Tao, Z. G., Guang, Z. Y., Hao, S., Song, H. J., & Xin, D. G. (2015). Multi-period closed-loop supply chain network equilibrium with carbon emission constraints. *Resources, Conservation and Recycling*, 104, 354–365.

<https://doi.org/10.1016/J.RESCONREC.2015.07.016>

Wang, C. H. (2015). Using quality function deployment to conduct vendor assessment and supplier recommendation for business-intelligence systems. *Computers & Industrial Engineering*, *84*, 24–31. <https://doi.org/10.1016/J.CIE.2014.10.005>

Wang, X., Sethi, S. P., & Chang, S. (2022). Pollution abatement using cap-and-trade in a dynamic supply chain and its coordination. *Transportation Research Part E: Logistics and Transportation Review*, *158*, 102592. <https://doi.org/10.1016/J.TRE.2021.102592>

Werneck Barbosa, M., De La, A., Vicente, C., Bronzo, M., Marcos, L. &, Valadares De Oliveira, P., De La Calle Vicente, A., Ladeira, M. B., Paulo, M., & De Oliveira, V. (2017). Managing supply chain resources with Big Data Analytics: a systematic review. <https://doi.org/10.1080/13675567.2017.1369501>, *21*(3), 177–200. <https://doi.org/10.1080/13675567.2017.1369501>

Wu, J., Ma, D., & Wang, W. (2022). Leakage Identification in Water Distribution Networks Based on XGBoost Algorithm. *Journal of Water Resources Planning and Management*, *148*(3), 04021107. [https://doi.org/10.1061/\(ASCE\)WR.1943-5452.0001523/ASSET/879E83A0-4BA4-4B85-8463-88C52729802D/ASSETS/IMAGES/LARGE/FIGURE13.JPG](https://doi.org/10.1061/(ASCE)WR.1943-5452.0001523/ASSET/879E83A0-4BA4-4B85-8463-88C52729802D/ASSETS/IMAGES/LARGE/FIGURE13.JPG)

Xu, K., Xia, Z., Cheng, M., & Tan, X. (2023). Carbon price prediction based on multiple decomposition and XGBoost algorithm. *Environmental Science and Pollution Research*, *30*(38), 89165–89179. <https://doi.org/10.1007/S11356-023-28563-0/TABLES/7>

Xu, W., Shao, L., Yao, B., Zhou, Z., & Pham, D. T. (2016). Perception data-driven optimization of manufacturing equipment service scheduling in sustainable manufacturing. *Journal of Manufacturing Systems*, *41*, 86–101.

<https://doi.org/10.1016/j.jmsy.2016.08.001>

Xu, X., & Choi, T. M. (2021). Supply chain operations with online platforms under the cap-and-trade regulation: Impacts of using blockchain technology. *Transportation Research Part E: Logistics and Transportation Review*, 155, 102491.

<https://doi.org/10.1016/J.TRE.2021.102491>

Xu, X., He, P., Xu, H., & Zhang, Q. (2017). Supply chain coordination with green technology under cap-and-trade regulation. *International Journal of Production Economics*, 183, 433–442. <https://doi.org/10.1016/J.IJPE.2016.08.029>

Zakeri, A., Dehghanian, F., Fahimnia, B., & Sarkis, J. (2015). Carbon pricing versus emissions trading: A supply chain planning perspective. *International Journal of Production Economics*, 164, 197–205. <https://doi.org/10.1016/J.IJPE.2014.11.012>

Zgonc, B., Tekavčič, M., & Jakšič, M. (2019). The impact of distance on mode choice in freight transport. *European Transport Research Review*, 11(1), 1–18. <https://doi.org/10.1186/S12544-019-0346-8/FIGURES/10>

Zhang, D., Yang, L. T., Chen, M., Zhao, S., Guo, M., & Zhang, Y. (2016). Real-Time Locating Systems Using Active RFID for Internet of Things. *IEEE Systems Journal*, 10(3), 1226–1235. <https://doi.org/10.1109/JSYST.2014.2346625>

Zhang, S., Wang, C., Yu, C., & Ren, Y. (2019). Governmental cap regulation and manufacturer's low carbon strategy in a supply chain with different power structures. *Computers & Industrial Engineering*, 134, 27–36. <https://doi.org/10.1016/J.CIE.2019.05.026>

Zhao, R., Liu, Y., Zhang, N., & Huang, T. (2017). An optimization model for green supply chain management by using a big data analytic approach. *Journal of Cleaner Production*, 142, 1085–1097. <https://doi.org/10.1016/J.JCLEPRO.2016.03.006>

- Zhong, R. Y., Lan, S., Xu, C., Dai, Q., & Huang, G. Q. (2016). Visualization of RFID-enabled shopfloor logistics Big Data in Cloud Manufacturing. *International Journal of Advanced Manufacturing Technology*, 84(1–4), 5–16. <https://doi.org/10.1007/S00170-015-7702-1/METRICS>
- Zhou, Y., Gong, D. C., Huang, B., & Peters, B. A. (2017). The Impacts of Carbon Tariff on Green Supply Chain Design. *IEEE Transactions on Automation Science and Engineering*, 14(3), 1542–1555. <https://doi.org/10.1109/TASE.2015.2445316>
- Zou, F., Zhou, Y., & Yuan, C. (2020). The Impact of Retailers' Low-Carbon Investment on the Supply Chain under Carbon Tax and Carbon Trading Policies. *Sustainability* 2020, Vol. 12, Page 3597, 12(9), 3597. <https://doi.org/10.3390/SU12093597>

Apéndice A. Análisis Bibliométrico

El concepto de cadenas de suministro (CS) ha existido durante mucho tiempo, pero su enfoque y relevancia han evolucionado a lo largo de los años. Las discusiones sobre las CS modernas comenzaron a ganar importancia a fines del siglo XX y principios del siglo XXI. El término "Cadena de Suministro" se popularizó en la década de 1980 y desde entonces se ha convertido en un concepto fundamental en el ámbito empresarial y logístico. Sin embargo, el enfoque en la gestión de la cadena de suministro ha ido creciendo en importancia a medida que las empresas han reconocido los beneficios de una mayor eficiencia económica y ambiental en concordancia con sus operaciones. En la actualidad, las cadenas de suministro son un tema recurrente en la gestión empresarial y se consideran fundamentales para el éxito competitivo en diversos sectores industriales. Por esta razón, desde la investigación, las propuestas realizadas se han enfocado en el desarrollo de modelos y políticas que optimicen las operaciones de las CS; luego, con el objetivo de describir el campo de conocimiento actual, se propone una búsqueda de los principales aportes y estudios realizados en torno a este tópico.

Haciendo uso de las bases de datos multidisciplinarias disponibles en la Universidad Industrial de Santander, como primer elemento se establece la ecuación de búsqueda a utilizar en cada una de las bases de datos elegidas, considerando las frases y términos que asocian el objeto de investigación. En segundo momento, la búsqueda se restringe a los campos de título, resumen o palabras clave, y mediante el uso de operadores booleanos, truncadores, comillas y paréntesis, se establece la estructura necesaria para que los trabajos encontrados pertenezcan al tópico y área de estudio. Finalmente, los resultados se delimitan por tipo de documento, capítulos de libros, y artículos científicos, aquellos documentos disponibles en inglés, y por ventana de tiempo a los publicados en el siglo XXI.

El presente análisis bibliométrico se realizó con base a la información resultante de la investigación realizada en Web of Science (WOS) y Scopus con las siguientes ecuaciones:

Tabla 32.

Ecuaciones de búsqueda

Ecuación 1.

Ecuación de búsqueda en Web of Science:

TS= ((SUPPLY CHAIN* AND NETWORK*) AND ((CARBON EMISSION* OR "CO2" OR "GREENHOUSE" OR EMISSION*) AND ((DATA ANALYTIC*) OR "BIG DATA"))) AND 2023 OR 2022 OR 2021 OR 2020 OR 2019 OR 2018 OR 2017 OR 2016 OR 2015 OR 2001 (PUBLICATION YEARS) AND ENGLISH (LANGUAGES) (1)

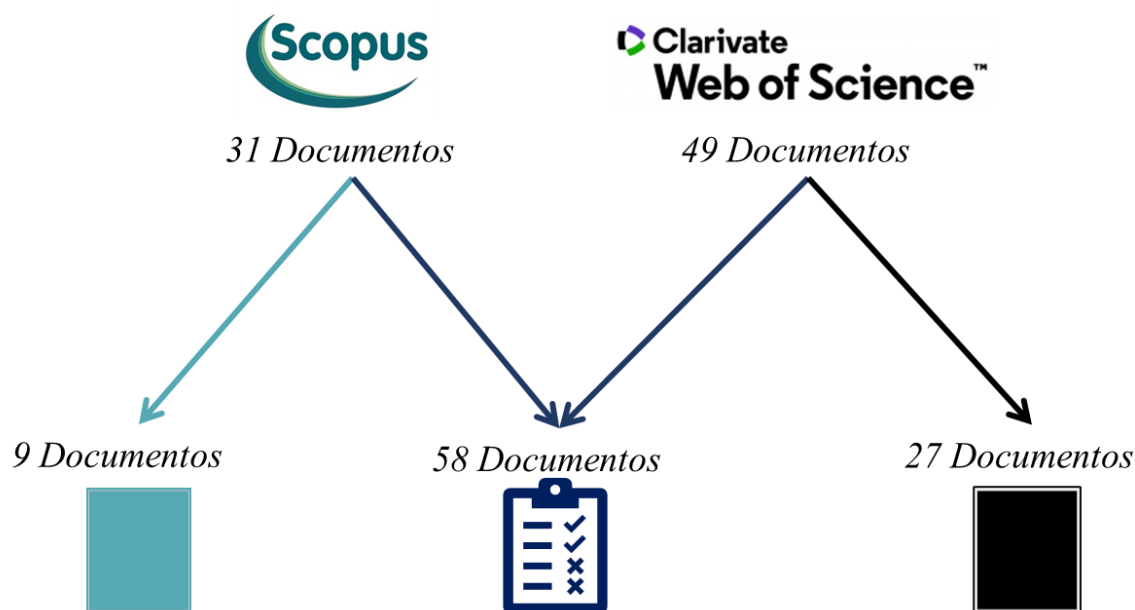
Ecuación 2.

Ecuación de búsqueda de Scopus:

TITLE-ABS-KEY ((SUPPLY CHAIN* AND NETWORK*) AND ((CARBON EMISSION* OR "CO2" OR "GREENHOUSE" OR EMISSION*) AND ((DATA ANALYTIC*) OR "BIG DATA")))AND (LIMIT-TO (PUBYEAR,2023) OR LIMIT-TO (PUBYEAR,2022) OR LIMIT-TO (PUBYEAR,2021) OR LIMIT-TO (PUBYEAR,2020) OR LIMIT-TO (PUBYEAR,2019) OR LIMIT-TO (PUBYEAR,2018) OR LIMIT-TO (PUBYEAR,2017) OR LIMIT-TO (PUBYEAR,2016) OR LIMIT-TO (PUBYEAR,2014) OR LIMIT-TO (PUBYEAR,2013) OR LIMIT-TO (PUBYEAR,2001)) AND (LIMIT-TO (LANGUAGE,"ENGLISH")) (2)

De las búsquedas realizadas se encontraron 49 resultados en Web of Science y 31 resultados en Scopus; sin embargo, algunos de los registros encontrados resultan repetidos en ambas bases de datos. Específicamente, de los 31 documentos encontrados en Scopus, 27 de ellos también se encontraron en WOS. Considerando lo anterior, a continuación, se muestra la distribución de los documentos obtenidos (ver Figura 10).

Figura 11.
Resultados del proceso de búsqueda



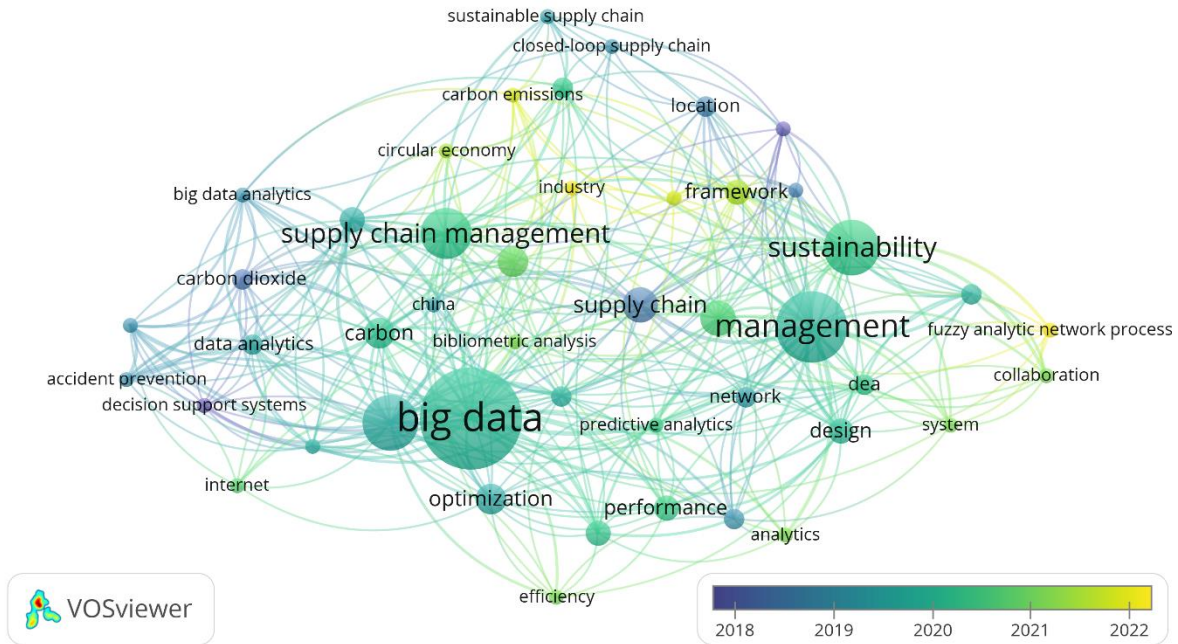
Luego de depurar los documentos repetidos, se realiza un proceso de validación de los 58 resultados disponibles mediante un análisis de coocurrencias de palabras clave (a través del software VOSviewer). Con un mínimo de 3 coocurrencias, los principales términos encontrados en este conjunto se muestran en la Figura 11.

La Figura 11 permite analizar el instante de tiempo en donde, en promedio, ocurren las coocurrencias de las palabras encontradas. Esto permite observar cómo el tópico de cadenas de suministro ha sido estudiado desde diferentes perspectivas a lo largo de los años, empezando con modelos de toma de decisiones, sistemas de apoyo a la toma de decisiones y asociados al dióxido de carbono, pasando luego por optimización y análisis de big data; posteriormente con los modelos de gestión de la cadena de suministro (GCS), sostenibilidad, emisiones de carbono y desarrollo sostenible. Así mismo, la Figura 12 muestra una relación de la analítica predictiva, el internet y la eficiencia en las GCS con la economía circular y la industria.


Por otra parte, se revisa algunas de las medidas de desempeño usadas en estos estudios: rentabilidad, impacto (económico y ambiental) y costos totales de operación.

Figura 12.

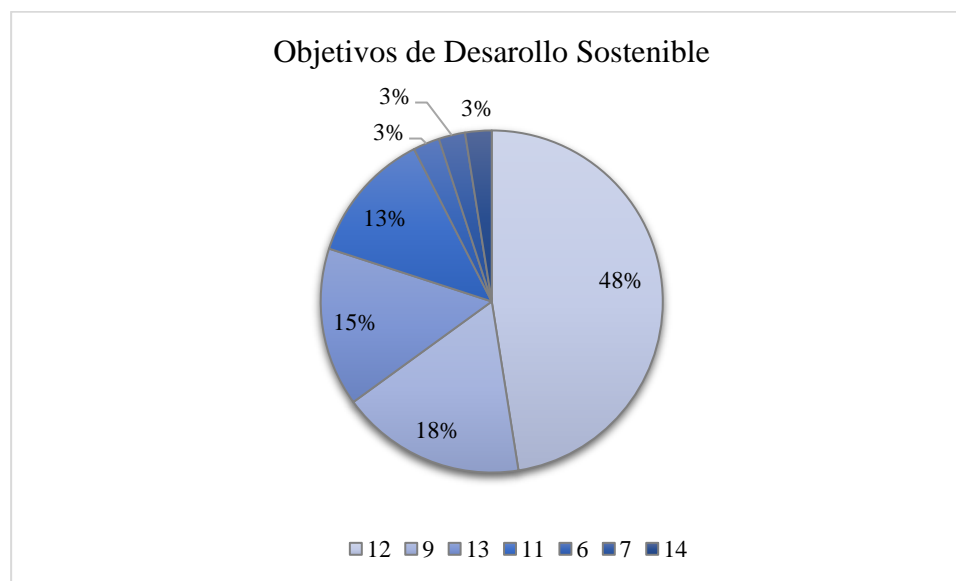
Análisis de coocurrencias de palabras claves



Considerando la información previa, resulta crucial examinar el comportamiento de los resultados presentados en función del año de publicación. Con este propósito, se ha llevado a cabo un análisis de series temporales que revela notables picos en los años 2020 y 2022 (ver Figura 13). Además, se puede observar una disminución en 2021 en comparación con 2020, posiblemente atribuible a la pandemia. Al mismo tiempo, se destaca que, hasta el momento de ejecutar la ecuación de búsqueda en 2023, se han identificado 2 registros pertinentes relacionados con el tema de investigación.

Figura 13.*Número de documentos por año*

Ahora bien, gracias al reporte de citas que ofrece WOS, resulta importante observar el comportamiento de la cantidad de artículos asociados o relacionadas con los objetivos de desarrollo sostenible (ODS). En la Figura 14, se observa una inclinación hacia el ODS 12, producción y consumo responsables; el ODS 9 (industria, innovación e infraestructura) y el ODS 13 (acción por el cambio climático). Permitiendo inferir que el tema en estudio resulta llamativo en la actualidad e impacta a varios ODS. Es importante mencionar que los documentos analizados en esta gráfica corresponden a los encontrados en la base de Web of Science. Ya que estos representan aproximadamente el 84,5% de los documentos totales y se toman como respaldo para concluir con respecto al objeto de estudio en general.

Figura 14.*Porcentaje de investigaciones relacionadas con los ODS*

Por otro lado, la Tabla 33 muestra el número de publicaciones y citas en función del país de origen. Resaltan China, Inglaterra e India como los países con más publicaciones; sin embargo, los países con mayor número de citas son India, Inglaterra y Estados Unidos; mientras que, Suecia y Finlandia encabezan la lista de los países menos citados. Es importante resaltar que únicamente se consideraron aquellos países con un mínimo de 3 documentos publicados.

Tabla 33.*Publicaciones y citas por país*

País	Cantidad de Documentos	Citaciones Totales
China	13	189
Inglaterra	8	302
India	8	358
Estados Unidos	8	238
Australia	6	89
Finlandia	3	59
Países Bajos	3	179
Noruega	3	113
España	3	81
Suecia	3	56

Analizando las fuentes de los documentos, la Tabla 34 muestra el comportamiento de las 8 mejores de acuerdo con el número de publicaciones y citas. Resulta importante destacar al Journal of Cleaner Production, Computers Operations Research y Sustainable Cities and Society como las principales fuente de citas con: Documentos: 5, Citaciones: 188, Documentos: 2, Citaciones: 168 y Documentos: 2, Citaciones: 126, respectivamente.

Tabla 34.
Publicaciones y citas por fuente

Fuente	Documentos	Citas Totales
Journal of Cleaner Production	5	188
Annals of Operations Research	4	57
Sustainability	3	30
Business Strategy and the Environment	2	20
Computers Industrial Engineering	2	77
Computers Operations Research	2	168
Science of the Total Environment	2	63
Sustainable Cities and Society	2	126

Por último, la Tabla 35 muestra los 10 investigadores con más publicaciones, así como sus citas. En ella, se resalta a Al-mallahi A y Singh SP quienes encabezan la lista desde la perspectiva de número de citas, a pesar de no ser los autores con las publicaciones más antiguas, elemento que respalda el impacto de sus investigaciones.

Tabla 35.
Publicaciones y citas por autor

Fuente	Documentos	Citas Totales
Singh SP	3	105
Kumar A	2	37
Zhang B	2	19
Abraham A	1	40
Ada N	1	3
Agrawal R	1	4
Agusti S	1	25
Ahad MA	1	104
Aikhuele DO	1	1
Al-mallahi A	1	109

Apéndice B. Parámetros de Entrada - Instancia Base [5,4,3,2]**Tabla 36.***Costos de producción instancia base*

cf_{pm}^t	p	m	t
285	1	1	1
91	1	1	2
190	1	2	1
145	1	2	2
236	1	3	1
30	1	3	2
126	1	4	1
275	1	4	2
153	2	1	1
295	2	1	2
264	2	2	1
296	2	2	2
279	2	3	1
111	2	3	2
258	2	4	1
62	2	4	2
242	3	1	1
97	3	1	2
55	3	2	1
284	3	2	2
253	3	3	1
169	3	3	2
265	3	4	1
186	3	4	2
151	4	1	1
213	4	1	2
143	4	2	1
202	4	2	2
194	4	3	1
58	4	3	2
290	4	4	1
234	4	4	2
213	5	1	1
118	5	1	2
37	5	2	1
246	5	2	2
292	5	3	1
106	5	3	2
205	5	4	1
101	5	4	2

Tabla 37.
Costos de pedido instancia base

cp_{pm}^t	p	m	t
238	1	1	1
75	1	1	2
158	1	2	1
121	1	2	2
196	1	3	1
25	1	3	2
105	1	4	1
229	1	4	2
127	2	1	1
245	2	1	2
220	2	2	1
246	2	2	2
232	2	3	1
93	2	3	2
215	2	4	1
52	2	4	2
201	3	1	1
81	3	1	2
46	3	2	1
237	3	2	2
210	3	3	1
141	3	3	2
221	3	4	1
155	3	4	2
126	4	1	1
178	4	1	2
119	4	2	1
169	4	2	2
161	4	3	1
48	4	3	2
242	4	4	1
195	4	4	2
177	5	1	1
99	5	1	2
30	5	2	1
205	5	2	2
243	5	3	1
88	5	3	2
171	5	4	1
84	5	4	2

Tabla 38.*Costos de transporte instancia base*

ct_{mv}^t	m	v	t
142	1	1	1
45	1	1	2
95	1	2	1
72	1	2	2
118	1	3	1
15	1	3	2
63	2	1	1
137	2	1	2
76	2	2	1
147	2	2	2
132	2	3	1
148	2	3	2
139	3	1	1
55	3	1	2
129	3	2	1
31	3	2	2
121	3	3	1
48	3	3	2
27	4	1	1
142	4	1	2
126	4	2	1
84	4	2	2
132	4	3	1
93	4	3	2

Tabla 39.*Costos de almacenamiento instancia base*

cm_p^t	p	t
95	1	1
30	1	2
63	2	1
48	2	2
78	3	1
10	3	2
42	4	1
91	4	2
51	5	1
98	5	2

Tabla 40.*Capacidades de los fabricantes instancia base*

cpf_{mp}^t	m	p	t
7685	1	1	1
3359	1	1	2
5566	1	2	1
4569	1	2	2
6584	1	3	1
2017	1	3	2
4144	1	4	1
7458	1	4	2
4736	1	5	1
7890	1	5	2
7204	2	1	1
7916	2	1	2
7539	2	2	1
3822	2	2	2
7076	2	3	1
2727	2	3	2
6713	2	4	1
3503	2	4	2
2576	2	5	1
7660	2	5	2
6956	3	1	1
5109	3	1	2
7241	3	2	1
5470	3	2	2
4700	3	3	1
6080	3	3	2
4516	3	4	1
5842	3	4	2
5651	3	5	1
2632	3	5	2
7796	4	1	1
6552	4	1	2
6077	4	2	1
3976	4	2	2
2158	4	3	1
6821	4	3	2
7836	4	4	1
3697	4	4	2
5894	4	5	1
3593	4	5	2

Tabla 41.*Capacidades de los vehículos instancia base*

cpv_v	v
95	1
26	2
61	3

Tabla 42.*Demandas de los productos instancia base*

d_p^t	p	t
7112	1	1
1776	1	2
4498	2	1
3269	2	2
5754	3	1
121	3	2
2744	4	1
6831	4	2
3474	5	1
7365	5	2

Tabla 43.*Volúmenes de empaquetado instancia base*

ve_p	p
9.481559342831536	1
2.342819469204058	2
5.984759429472212	3
4.340255980803978	4
7.664992796883313	5

Tabla 44.*Costo de carbono por unidad comprada instancia base*

ccc
34

Tabla 45.*Costo del carbono por unidad vendida instancia base*

ccv
27

Tabla 46.*Costo del carbono por unidad vendida instancia base*

<i>tic</i>
6.54

Tabla 47.*Emisiones de carbono por unidad para cada pedido instancia base*

<i>eco^t</i>	<i>t</i>
0.0008081058054813362	1
0.00023123793690537836	2

Tabla 48.*Emisiones de carbono al realizar un pedido instancia base*

<i>ecp^t</i>	<i>t</i>
0.00006238161284258352	1
0.00002632737105658615	2

Tabla 49.*Emisiones de carbono al almacenar inventario instancia base*

<i>ecm^t</i>	<i>t</i>
0.0008107241926387527	1
0.00026991056584879224	2

Tabla 50.*Distancias desde los fabricantes instancia base*

<i>r_m</i>	<i>m</i>
379	1
98	2
241	3
177	4

Tabla 51.*Factor de emisión de transporte instancia base*

<i>ft</i>
0.91

Tabla 52.*Límites de emisiones de carbono instancia base*

<i>cpeh_t</i>	<i>t</i>
206501	1
130787	2

Apéndice C. Lista de Acrónimos**Tabla 53.***Lista de acrónimos*

#	Nombre	Acrónimo
1	Cadenas de Suministro	CS
2	Gestión de la Cadena de Suministro	GCS
3	Emisiones de Carbono	EC
4	Gases de Efecto Invernadero	GEI
5	Modelos de Optimización	MO
6	Modelos de Optimización Matemática	MOM
7	Analítica de Datos	AD
8	Análisis de Big Data	ABD
9	Dióxido de Carbono	CO ₂
10	Producción, Inventario y Transporte	PIT
11	Modelo de Programación Lineal Mixto	MILP
12	Regulaciones de Emisiones de Carbono	REC
13	Web de la Ciencia	WOS

Apéndice D. Gráficos Complementarios

Figura 15.
Configuraciones de costos – Caso 1

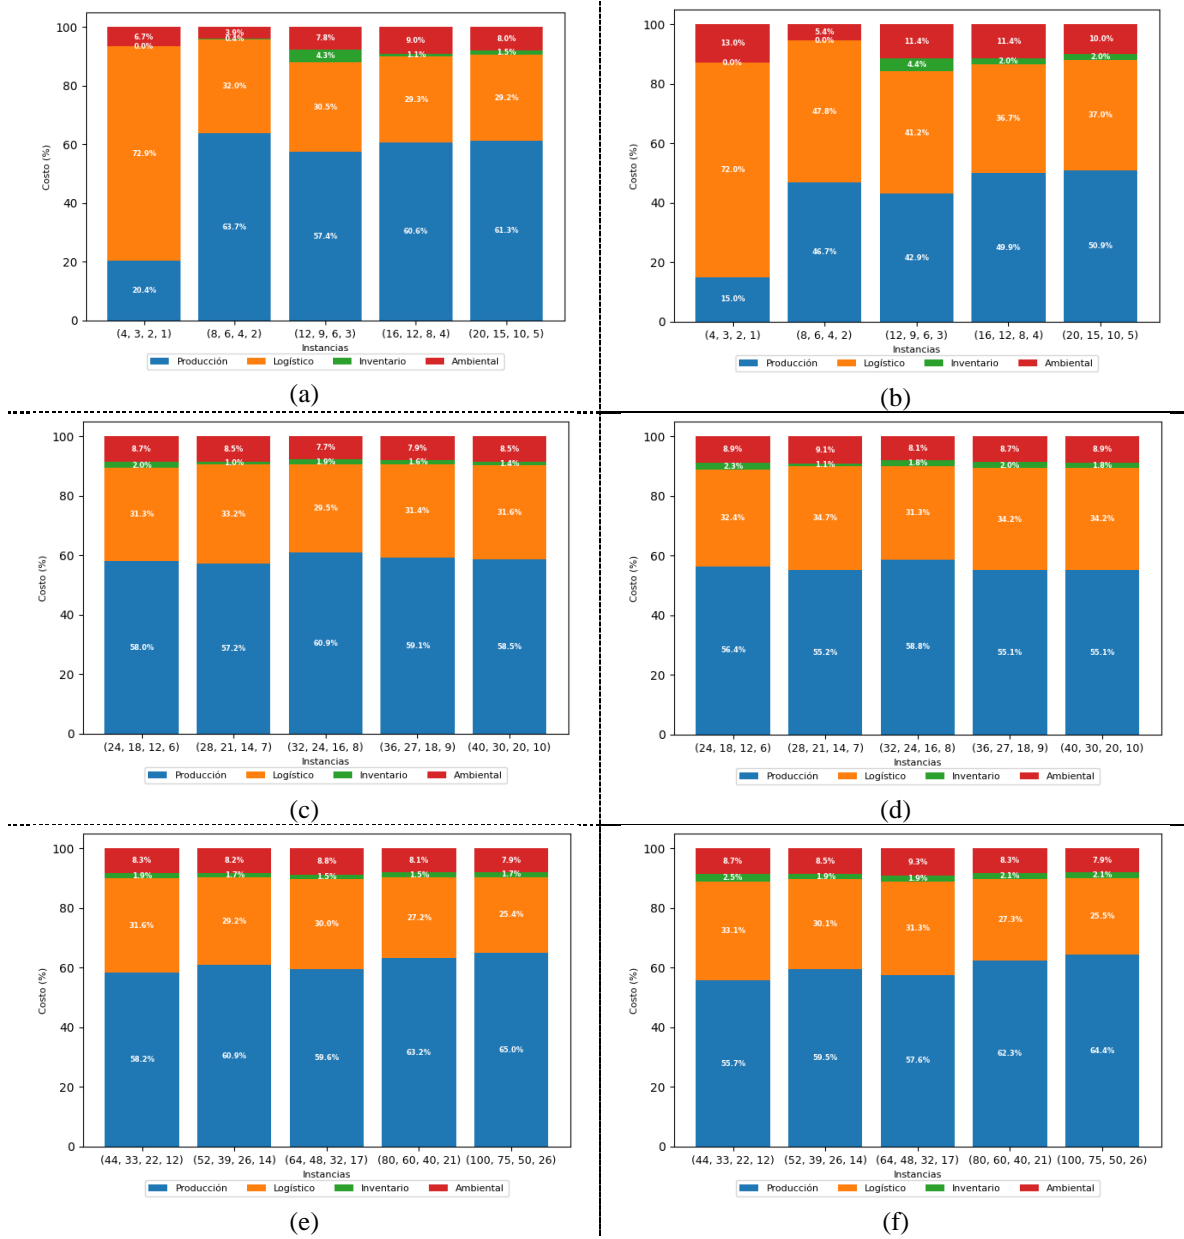


Figura 16.
Configuraciones de costos - Caso 2



Figura 17.
Configuraciones de costos - Caso 3

