

**UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES**

TEMA:

**Aplicación de redes neuronales para la optimización de la
cadena de suministro de la empresa Logex S.A.**

AUTOR:

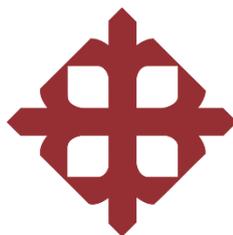
**Ansaldo Espinoza, Alejandro Vladimir
Veloz Contreras, Mario Andrés**

**Trabajo de titulación previo a la obtención del título de
LICENCIADA EN NEGOCIOS INTERNACIONALES**

TUTOR:

Ing. Carrera Buri, Félix Miguel, Mgs.

**Guayaquil, Ecuador
25 de agosto del 2025**



**UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES**

CERTIFICACIÓN

Certificamos que el presente trabajo de titulación fue realizado en su totalidad por **Ansaldo Espinoza, Alejandro Vladimir y Veloz Contreras, Mario Andrés**, como requerimiento para la obtención del título de **Licenciada Negocios Internacionales**.

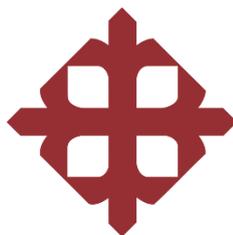
TUTOR:

f. _____
Ing. Carrera Buri, Félix Miguel Mgs.

DIRECTOR DE LA CARRERA:

f. _____
Hurtado Cevallos, Gabriela Elizabeth

Guayaquil, a los 25 del mes de agosto del año 2025



**UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES**

DECLARACIÓN DE RESPONSABILIDAD

**Yo, Ansaldo Espinoza, Alejandro Vladimir
Veloz Contreras, Mario Andrés**

DECLARO QUE:

El Trabajo de Titulación, **Aplicación de redes neuronales para la optimización de la cadena de suministro de la empresa LOGEX S.A.**, previo a la obtención del título de **Licenciada en Negocios Internacionales**, ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría.

En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

Guayaquil, a los 25 del mes de agosto del año 2025

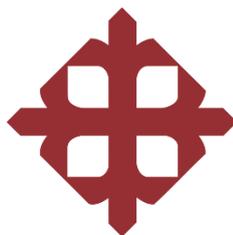
LOS AUTORES

f.

Ansaldo Espinoza, Alejandro Vladimir

f.

Veloz Contreras, Mario Andrés



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES

AUTORIZACIÓN

Yo, **Ansaldo Espinoza, Alejandro Vladimir
Veloz Contreras, Mario Andrés**

Autorizo a la Universidad Católica de Santiago de Guayaquil a la **publicación** en la biblioteca de la institución del Trabajo de Titulación, **Aplicación de redes neuronales para la optimización de la cadena de suministro de la empresa LOGEX S.A.**, cuyo contenido, ideas y criterios son de mi exclusiva responsabilidad y total autoría.

Guayaquil, a los 25 del mes de agosto del año 2025

LOS AUTORES

f. 

Ansaldo Espinoza, Alejandro Vladimir

f. 

Veloz Contreras, Mario Andrés



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES

Reporte Compilatio

INFORME DE ANÁLISIS
magister

Ansaldo Espinoza & Veloz Contreras

6%
Textos sospechosos

- 6% Similitudes
 - = No eliminados entre similitudes
 - = No entre las fuentes más detectadas
- 10% Máximas no reconocidas (guardado)
- 11% Textos potencialmente generados por IA (guardado)

Nombre del documento: Ansaldo Espinoza & Veloz Contreras.docx
ID del documento: 712f05511b483c0b92d8e67a3a0781a289723
Tamaño del documento original: 2.29 MB

Depositante: Félix Miguel Carrera Buri
Fecha de depósito: 4/9/2025
Tipo de carga: Interfaz
Fecha de fin de análisis: 4/9/2025

Número de páginas: 21/189
Número de caracteres: 141.638

Ubicación de las similitudes en el documento:

Fuentes de similitudes

Fuentes principales detectadas

N°	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	Nativity Fraine Juan Vega, P73.docx Nativity Fraine Juan Vega, P73 <small>archivo</small> 25 Fuentes al rolarse	2%		Palabras idénticas: 26 (125 palabras)
2	TUTORIA #2.pdf TUTORIA #2 <small>archivo</small> 1 Fuente de identificación	1%		Palabras idénticas: 16 (221 palabras)
3	Escalhost implementación de Machine Learning en el área de ventas de la empresa <small>archivo</small> 7 Fuentes similares	<1%		Palabras idénticas: 4 (190 palabras)
4	Teofo Final Aguirre Sánchez, Daniela Alejandra y Maldonado Ariza, AJ... <small>archivo</small> 1 Fuente de rol grupo	<1%		Palabras idénticas: 4 (190 palabras)
5	Asamblea.docx <small>archivo</small> 17 Fuentes al rolarse	<1%		Palabras idénticas: 4 (190 palabras)

Ing. Hurtado Cevallos, Gabriela Elizabet
DIRECTORA DE CARRERA

TUTOR: Ing. Carrera Buri, Félix Miguel Mgs.

AGRADECIMIENTO DE ALEJANDRO ANSALDO

A la vida, por darme la oportunidad, la salud y la fortaleza necesarias para
alcanzar este objetivo académico.

A mi padre, Vladimir Ansaldo, por su apoyo y respaldo en mi formación, A mi madre, Guisela Espinoza, por su esfuerzo incansable y por enseñarme, con su ejemplo, que el trabajo constante abre caminos hacia un futuro mejor, A mi padrastro, Mauro Escalante, por brindarme un amor incondicional y estar siempre presente en mi desarrollo personal y académico, A mis hermanos, por su interés y motivación constante hacia mis estudios, A mi abuelo, Alfredo Ansaldo, quien desde siempre me inculcó el valor de la educación como la clave para el progreso.

Al Ing. Félix Carrera, por su orientación y compromiso, así como por transmitirme el cariño hacia su disciplina, lo que se convirtió en una inspiración durante todo este proceso.

Finalmente, a todas las personas que de una u otra manera contribuyeron a la culminación de este trabajo.

DEDICATORIA DE ALEJANDRO ANSALDO

Dedico este logro a mi madre, Guisela Espinoza, por su esfuerzo inquebrantable; a mi padre, Vladimir Ansaldo, por su apoyo; a mi padrastro, Mauro Escalante, por su cariño constante; a mis hermanos Matthew, Andrew y Luca, por su compañía; y a mi abuelo, Alfredo Ansaldo, por sembrar en mí la convicción de que la educación es el mejor legado.

AGRADECIMIENTO DE MARIO VELOZ

Quiero agradecer primero a Dios, por haberme proporcionado la fuerza de cumplir todas mis metas, porque nunca perdí la fe de cumplir todo lo que me he propuesto gracias a él, a mis padres, especialmente a mi padre que mientras luchaba contra una terrible enfermedad, él hizo todo lo posible por darme la mejor educación en esta universidad, gracias a ti padre porque sé que desde el cielo has seguido todos mis pasos y me has seguido ayudando en mi camino, no me has dejado solo, te agradezco siempre por tu esfuerzo y sacrificio. A mi madre le agradezco todo lo que sigue haciendo por mí, porque no me ha fallado ningún día, por su apoyo, esfuerzo y dedicación por ver a su hijo convertirse en un gran profesional, que gran trabajo haz hecho madre. A mi hermana porque he compartido con ella buenos y malos momentos, pero siempre juntos, y porque es un ejemplo constante de superación.

A Sayenka Fuentes Elizalde, porque es mi motor de arranque para poder lograr mis metas y siempre ser una mejor persona, y un gran profesional. A mis abuelas que pudieron acompañar durante toda mi carrera universitaria brindándome siempre apoyo incondicional y aliento para poder superar cualquier adversidad.

A mi tío Kiko, que ha sido como un padre para mí, porque siempre ha estado pendiente de cualquier cosa que necesite y que siempre me ha brindado un cariño invaluable.

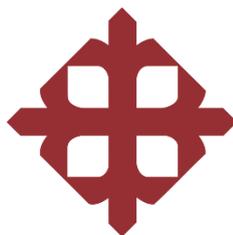
A mi compañero de titulación Alejandro Ansaldo que fue siempre un gran amigo y compañero, que estuvo pendiente de todo lo que se necesitaba para poder realizar un trabajo de este calibre.

Al Ing. Félix Carrera por haber sido un excelente tutor, quien nos brindó un soporte y valiosos conocimientos para poder guiarnos en este proyecto de investigación

A todas las personas que formaron parte de todo este proceso, acompañándome en mis caídas y logros, sinceramente sin su apoyo todo este camino hubiera sido más difícil.

DEDICATORIA DE MARIO VELOZ

Dedico este trabajo de titulación, que está lleno de esfuerzo, de sacrificio y dedicación a mis padres, a mi hermana, a Sayenka Fuentes Elizalde, a mis abuelas, a mi tío Kiko y a toda mi familia por haber estado presente durante toda mi vida y mi etapa universitaria brindándome apoyo y comprensión total. Pero principalmente, quiero dedicar este trabajo de titulación a mí y a mi padre porque esto es un proyecto donde él puso las bases y yo terminé de construir con toda mi dedicación todo esto. Porque con gran valentía logré superar todas las adversidades del camino y por eso me lo dedico, porque es el mejor reflejo de que puedo con cualquier cosa que me proponga.



**UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES**

TRIBUNAL DE SUSTENTACIÓN

f. _____

Ing. Carrera Buri, Félix Miguel Mgs.

TUTOR

f. _____

Ing. Hurtado Cevallos, Gabriela Elizabeth Mgs.

DIRECTORA DE CARRERA

f. _____

(NOMBRES Y APELLIDOS)

COORDINADOR DEL ÁREA O DOCENTE DE LA CARRERA

ÍNDICE

INTRODUCCIÓN.....	2
PROBLEMÁTICA	12
JUSTIFICACIÓN	18
OBJETIVOS	23
Objetivo General:	23
Objetivos Específicos:.....	23
Capítulo I: Fundamentación Teórica.....	23
MARCO TEÓRICO	23
Externalización de logística y cadena de suministros	23
Optimización de la cadena de suministro.....	25
Tecnologías Aplicadas a la Logística	26
Inteligencia Artificial	27
Machine Learning.....	28
Redes neuronales Artificiales.....	29
Input Layer:	30
Hidden Layer:.....	30
Propagación hacia adelante	31
Las neuronas y sus relaciones:	31
Función sigmoide:	31
Función tangente hiperbólica:	32
ReLU (Rectified Linear Unit):	32
Output Layer:	32

Función Softmax:	33
Propagación hacia adelante en Machine Learning:.....	33
Error y retro propagación:	34
Modelo de Autorregresivo (AR).....	34
Modelo de Media Móvil (MA)	34
Error Absoluto Medio (MAE)	35
Error Cuadrático Medio de la Raíz (RMSE)	35
MARCO CONCEPTUAL.....	36
Fundamentos de Inteligencia Artificial y Aprendizaje Automático	36
Clasificación Fundamental: IA Débil vs. IA Fuerte	37
Inteligencia Artificial Débil (Narrow AI)	37
Inteligencia Artificial Fuerte (General AI - AGI).....	38
Machine Learning (Aprendizaje Automático)	38
Tipos de Aprendizaje en Machine Learning	39
Aprendizaje Supervisado	40
Ejemplos de algoritmos supervisados:	40
Regresión lineal	40
Regresión logística	40
k-vecinos más cercanos (k-NN)	41
Aprendizaje No Supervisado	41
Ejemplos de algoritmos no supervisados:	42
k-means	42

Algoritmos de asociación	42
Aprendizaje por Refuerzo	43
Ejemplos de algoritmos de aprendizaje por refuerzo:	43
Q-learning	43
SARSA	44
Deep Q-Networks (DQN	45
Aprendizaje Profundo (Deep Learning)	45
Big Data:	46
Calidad de Datos (Data Quality):	47
Datos de Series Temporales (Time Series Data):	47
Normalización de Datos (Data Normalization):	47
Recopilación de Datos (Data Collection)	47
Entrenamiento (Training):	47
Evaluación (Evaluation):	47
Despliegue (Deployment):	47
Evaluación de Modelos	48
Métricas comunes:	48
Accuracy (Exactitud):	48
Redes Neuronales Artificiales (RNA)	48
Capa de entrada:	48
Capas ocultas:	48
Capa de salida:	49
Neurona Artificial	49

Pesos sinápticos:	49
Función de activación:	49
Algoritmo de Retropropagación	49
Funciones de Activación	50
ReLU:	50
Sigmoide:	50
TanH:	50
Función de Pérdida y Optimización	50
Funciones de pérdida:	50
MSE:	50
Entropía cruzada:	50
Optimización:	51
Overfitting y Técnicas de Regularización	51
Overfitting:	51
Perceptrón Multicapa (MLP):	51
Redes Neuronales Convolucionales (CNN):	51
Predicción de la Demanda	51
Cadena de Suministro:	52
Medidas Clave del Desempeño Logístico:	52
Grado de Atención (Service Level)	52
Puntos Clave:	52
Tiempo Total (Tiempo de Ciclo Total)	52
Inventario al Alcance	53

MARCO LEGAL.....	54
METODOLOGÍA.....	56
Tipo de Investigación.....	56
Investigación Cuantitativa.....	56
Técnicas e instrumentos de recolección de datos.....	57
Dinadec (Cervecería Nacional)	57
Prebam S.A. (LOGEX)	58
Redes Neuronales Artificiales	58
Librerías Implementadas.....	59
Preparación de los datos.....	62
Transformación de la línea temporal de los datos.....	63
Evaluación del modelo predictivo	63
Predicciones.....	64
Visualización de los resultados del proyecto.....	64
Script de los descriptivos del proyecto:.....	64
RESULTADOS	72
Resultados de la investigación	72
Línea: Tendencia mensual total de solicitudes.....	73
Comparativo de solicitudes de requerimientos por Gerencia de ventas	74
Capacidad en pies promedio por Gerencia de ventas.....	75
Tendencia mensual por tipo de requerimiento y gerencia de ventas	76
Resultados de la red neuronal artificial.	77
Serie de tiempo: Capacidad promedio por mes.	77

Desempeño del modelo	79
Pronóstico a 24 meses	79
DISCUSIÓN.....	80
CONCLUSIONES.....	83
RECOMENDACIONES.....	84

ÍNDICE DE ILUSTRACIONES

<i>Ilustración 1. Como funciona la externalización logística.</i>	<i>24</i>
<i>Ilustración 2. Optimización de la cadena de suministro.</i>	<i>26</i>
<i>Ilustración 3. Estructura de la inteligencia artificial y sus subcampos.</i>	<i>27</i>
<i>Ilustración 4. Estructura de una Red Neuronal Artificial Multicapa.</i>	<i>30</i>
<i>Ilustración 5. Distribución de capacidades de equipos de frío.</i>	<i>72</i>
<i>Ilustración 6. Capacidad de equipos de frío según el tipo de requerimiento.</i>	<i>73</i>
<i>Ilustración 7. Tendencia mensual de solicitudes.</i>	<i>73</i>
<i>Ilustración 8. Cantidad de requerimientos por Gerencia de Ventas.</i>	<i>74</i>
<i>Ilustración 9. Capacidad de equipos de frío por capacidad promedio de Gerencia de Ventas.</i>	<i>75</i>
<i>Ilustración 10. Tendencia mensual por requerimiento y Gerencia de Ventas.</i>	<i>76</i>
<i>Ilustración 11. Capacidad de equipos de frío promedio por mes.</i>	<i>77</i>
<i>Ilustración 12. Modelo de Red Neuronal Artificial Monocapa.</i>	<i>78</i>
<i>Ilustración 13. Relación entre valores Reales vs los resultados predichos.</i>	<i>79</i>
<i>Ilustración 14. Pronóstico de la demanda de capacidades a 24 meses.</i>	<i>80</i>

RESUMEN

El presente proyecto tiene como finalidad el análisis sobre la aplicación de redes neuronales artificiales (RNA) como una herramienta esencial para la optimización de la cadena de suministro de la empresa LOGEX S.A., operador logístico que gestiona la distribución y almacenamiento de los equipos de frío de Cervecería Nacional. La problemática principal radica en la falta de precisión al participar la demanda de estos equipos de frío en bodega, lo que ocasiona sobrecostos de repuestos, personal y movilizaciones adicionales innecesarias, lo que en ocasiones también termina consiguiendo penalizaciones contractuales. Para sobrellevar esta situación, se creó un modelo de predicción en RStudio, basado en redes neuronales artificiales monocapa entrenada con datos históricos del 2023 al 2025 que corresponden más de 10 mil requerimientos de equipos de frío. El modelo fue evaluado mediante métricas estadísticas como RMSE, demostrando un mejor desempeño frente a métodos de predicción, al capturar patrones no lineales y reducir de manera significativa los errores de estimación. Los resultados evidencian que la implementación del modelo de predicción permite mejorar la planificación de recursos, planificación de mantenimientos en bodega, optimizar el inventario y poder reducir costos operativos. En consecuencia, esta propuesta fortalece la eficiencia de LOGEX S.A. y genera mayor satisfacción para los clientes de Cervecería Nacional.

Palabras Claves: Redes neuronales artificiales, predicción de la demanda, cadena de suministro, logística, optimización, Inteligencia artificial, Machine learning.

ABSTRACT

The purpose of this project is to analyze the application of artificial neural networks (ANNs) as an essential tool for optimizing the supply chain of LOGEX S.A., a logistics operator responsible for the distribution and storage of Cervecería Nacional's cooling equipment. The main issue lies in the lack of accuracy when forecasting the demand for these cooling units in storage, which generates additional costs in spare parts, labor, and unnecessary mobilizations, and in some cases also results in contractual penalties. To address this challenge, a predictive model was developed in RStudio, based on a single-layer artificial neural network trained with historical data from 2023 to 2025, covering more than 10,000 requests for cooling equipment. The model was evaluated using statistical metrics such as RMSE, demonstrating superior performance compared to traditional forecasting methods by capturing non-linear patterns and significantly reducing estimation errors. The results show that implementing this predictive model improves resource planning, maintenance scheduling in storage, inventory optimization, and reduces operational costs. Consequently, this proposal enhances the efficiency of LOGEX S.A. and increases customer satisfaction for Cervecería Nacional.

Keywords: Artificial neural networks, demand forecasting, supply chain, logistics, optimization, artificial intelligence, machine learning.

RÉSUMÉ

Le présent projet a pour objectif d'analyser l'application des réseaux neuronaux artificiels (RNA) en tant qu'outil essentiel pour l'optimisation de la chaîne d'approvisionnement de l'entreprise LOGEX S.A., opérateur logistique chargé de la distribution et du stockage des équipements de réfrigération de la Cervecería Nacional. La problématique principale réside dans le manque de précision lors de la prévision de la demande de ces équipements en entrepôt, ce qui entraîne des surcoûts liés aux pièces de rechange, à la main-d'œuvre et à des mobilisations supplémentaires inutiles, générant parfois également des pénalités contractuelles. Afin de surmonter cette situation, un modèle de prévision a été développé dans RStudio, basé sur un réseau neuronal artificiel monocouche entraîné avec des données historiques de 2023 à 2025, correspondant à plus de 10 000 demandes d'équipements de réfrigération. Le modèle a été évalué à l'aide de métriques statistiques telles que le RMSE, démontrant de meilleures performances par rapport aux méthodes de prévision traditionnelles, en capturant des schémas non linéaires et en réduisant de manière significative les erreurs d'estimation. Les résultats montrent que la mise en œuvre de ce modèle de prévision permet d'améliorer la planification des ressources, la gestion des maintenances en entrepôt, d'optimiser les stocks et de réduire les coûts opérationnels. En conséquence, cette proposition renforce l'efficacité de LOGEX S.A. et accroît la satisfaction des clients de la Cervecería Nacional.

Mots-clés : Réseaux neuronaux artificiels, prévision de la demande, chaîne d'approvisionnement, logistique, optimisation, intelligence artificielle, apprentissage automatique.

INTRODUCCIÓN

Una Red Neuronal Artificial (RNA) es un modelo matemático, que se inspira en una red neuronal biológica. Su unidad base es un procesador llamado neurona, que mantiene la propiedad de contar una suma ponderada de sus entradas, y el siguiente paso es aplicar una función para obtener una señal que es transmitida a otra neurona. A través de un algoritmo de aprendizaje, estas redes neuronales artificiales ajustan su estructura y parámetros que permiten minimizar alguna función de error que indique el grado de ajuste a los datos (Mayén, Serna, Flores, López Martínez y Campillo, 2014).

En las dos últimas décadas, las redes neuronales artificiales han sido protagonistas en la predicción de series de tiempo en un gran número de áreas de la gestión empresarial, como en la parte financiera, generación de energía, la medicina, las ciencias ambientales y las ciencias de los materiales (Zhang, X., Wang, Y., & Huang, G. Q., 2023). El sector logístico siempre está expuesto a sufrir adversidades por factores externos sociales o políticos, así como puede suceder por avances tecnológicos que van a exigir que siempre dichas empresas estén actualizadas y en constante renovación de sus tecnologías en la cadena de suministro para poder afrontar las adversidades que se puedan presentar en el diario vivir. Dentro del competitivo mercado actual, contratar un operador logístico que se caracteriza por su eficiencia y confianza puede llegar a marcar una gran diferencia en comparación a otras empresas que ofrezcan dichos servicios, ya que estos van a desempeñar un papel muy importante en la gestión de la cadena de suministro, y como beneficio las empresas que contratan estos servicios van a recibir soluciones

integrales que van a permitir que las empresas se mantengan centradas en sus actividades principales como la parte de comercialización.

Un operador logístico es una empresa especializada en diseñar, implementar, y supervisar todos los procesos que se encuentran en la cadena de suministro de sus clientes. Estas empresas de logística van a ofrecer una amplia gama de servicios como el almacenamiento de productos o activos fijos hasta la distribución hasta la gestión de inventario y la logística inversa. Esto viene sujeto a beneficios como la optimización de costos, ya que, al tener una gran experiencia y economías de escala, esto les da la oportunidad de optimizar las rutas de transporte y negociar tarifas preferenciales con transportistas, y esto se ve reflejado en ahorros directos para sus clientes, y al tener dicha reducción de costos las empresas pueden invertir ese presupuesto en otras áreas críticas del negocio.

La eficiencia operativa es un factor clave y es la principal característica que buscan las empresas para contratar proveedores logísticos, ya que, al contar con experiencia y recursos necesarios para comenzar a mejorar la eficiencia de las operaciones logísticas de sus clientes. Al ser un mercado tan cambiante, la necesidad de adaptarse de forma rápida a los cambios de la demanda es alta y se necesita que los operadores logísticos ofrezcan flexibilidad, y así las empresas puedan escalar sus operaciones según lo que se requiera, sin la necesidad de tener una inversión muy alta.

Tener una gestión eficiente de la cadena de suministro y generar optimización de rutas y transporte realmente genera una competitividad en el mercado, porque una gestión impecable de la cadena de suministro es clave para generar éxito en cualquier empresa, y por lo tanto el operador logístico tiene

un papel importante en este aspecto, ya que, ofrecen soluciones integrales que van a poder cubrir toda etapa del proceso logístico de la empresa. Adicional, la planificación de rutas es esencial para poder reducir costos de transporte, en algunos casos los operadores logísticos manejan plataformas o programas de software para la optimización de las rutas y así poder planificar los trayectos de manera más efectiva, ya que el objetivo es minimizar las distancias que se van a recorrer y el tiempo de su entrega. La incertidumbre de la demanda genera cuellos de botella logísticos que pueden prevenirse mediante modelos predictivos avanzados (Asadi & Bektas, 2022).

Actualmente, en el Ecuador existen algunas empresas de logística que transportan activos fijos de otras empresas, conocidas como operadores logísticos y trabajan como proveedores de dichos servicios. En este caso, se aborda exclusivamente de LOGEX o también conocido por su nombre legal "PREBAM S.A.", la cual es una empresa de logística con una trayectoria de más de 25 años, la cual ha ido creciendo a lo largo de los años con su número de flotas para los servicios logísticos contando actualmente con más de 60 flotas terrestres distribuidas en el país. Dicha empresa, brinda servicios logísticos a grandes multinacionales como AB INBEV (CERVECERÍA NACIONAL), UNILEVER, NATURA, ARCA CONTINENTAL, CONDOR, SIKA, EDESA, TERPEL, BAKELS S.A., AZZORTI, JABONERÍA WILSON y HOLCIM. Existen situaciones en las que los mismos clientes solicitan servicios logísticos de diferentes áreas, tal como es el caso de CERVECERÍA NACIONAL, el cual LOGEX comenzó a brindar sus servicios para la

movilización y entrega de cervezas en diferentes provincias del país hace más de 15 años.

LOGEX dispone de una amplia gama de servicios logísticos como preparación de pedidos, gestión de stocks, logística inversa, servicios complementarios de manipulación de mercancías y la creación de sitios web. Todas estas características permiten adaptarse a las necesidades específicas de cada cliente, ofreciendo soluciones logísticas especializadas que optimizan la cadena de suministro para mejorar la experiencia de servicios. Siempre con el compromiso de innovar para mantenerse a la vanguardia del sector logístico, ofreciendo las soluciones logísticas de última tecnología para mejorar la eficiencia, reducir costos y mejorar la satisfacción del cliente. El servicio más demandado es la logística inversa con las devoluciones, especialmente con el sector electrónico como con las mercaderías de MABE y los activos fijos de Cervecería Nacional. En cada operación logística, siempre surgen obstáculos o adversidades inesperadas. La diferencia en cada operador logístico es la rapidez y eficiencia con la que resuelven dichos problemas. LOGEX cuenta con los recursos y una gran experiencia para solucionar estos imprevistos con un mínimo impacto sobre las operaciones de cada proyecto.

LOGEX al tener un excelente y limpio desempeño con Cervecería Nacional en los servicios logísticos de cervezas, en enero del 2024 entró en proceso de licitación para la operación logística de los activos fijos de CERVECERÍA NACIONAL, exclusivamente hablando de equipos de frío, y al término de la licitación se escogió a LOGEX como único operador logístico de los equipos

de frío de Cervecería Nacional en la ciudad de Guayaquil, en la cual iniciaron operaciones el 1 de mayo del 2024. Las actividades incluyeron no solo en movilización de equipos de frío, sino también en almacenaje del parque completo de equipos de frío de Guayaquil, reparación de equipos de frío en bodega y reparaciones de equipos de frío instalados en los clientes de Cervecería Nacional de la ciudad de Guayaquil. Para LOGEX, la incorporación de reparaciones técnicas representó un gran desafío, la ampliación de alcance incluyó servicios técnicos y estructurales de las URC, ámbito en el que LOGEX incorporará know-how especializado. Ya que al ser una empresa que brinda servicios integrales de gestión de la cadena de suministro, su fin es optimizar las operaciones logísticas de sus clientes. Al tener una amplia red de socios que brindan soluciones personalizadas, y un equipo de trabajo altamente capacitado fue preciso para encargarse de esta nueva actividad que solicitó Cervecería Nacional.

Cervecería Nacional que nace en 1887 en el barrio Las Peñas, es una de las principales empresas y la primera empresa dedicada a la preparación y comercialización de bebidas alcohólicas y refrescos como “Pony Malta” en Ecuador. Son elaborados únicamente en sus plantas de producción ubicadas en Guayaquil y Quito, y actualmente pertenecen al grupo Ab Inbev. En 1913, lanzaron su marca más histórica “Pilsener”, que llegó a ser la cerveza de mayor venta en Ecuador, hasta que en el 1966 se creó la marca CLUB PREMIUM con el objetivo de tener una marca exclusiva en el grupo de Cervecería Nacional. En 2005, SABMILLER plc se convirtió en el accionista más importante de la empresa, donde se proclamaron con el nombre

Cervecería Nacional. Por último, en el 2016 el grupo Ab Inbev pasó a ser el mayor accionista de Cervecería Nacional CN S.A. Actualmente, manejan un amplio portafolio de cervezas nacionales como Cerveza Pilsener, Club Premium, Pilsener Light y Nuestra Siembra. Y las patentes de cervezas globales como Stella Artois, Corona, Beck's y Budweiser, adicional del refresco Pony Malta.

Al firmar el contrato se estableció que en la gestión de inventario se almacenaría un aproximado de más de 900 equipos de frío, y existía el compromiso de atender un parque de clientes con equipos de frío de aproximadamente 38 mil en la ciudad de Guayaquil. El lead manager del proyecto de equipos de frío Héctor Rivas, junto con el departamento de compras de la empresa crearon una amplia línea de proveedores para conseguir los mejores repuestos, choferes, camiones y auxiliares para este nuevo proyecto también llamado en LOGEX como "CNEF". Después de la completa transición del anterior operador logístico, que se concretó el 15 de mayo del 2024 y oficialmente comenzaron a realizar las entregas y cambios de equipos de frío de Cervecería Nacional.

Cervecería Nacional para mayor control de la gestión de los proveedores logísticos implementaron en el año 2022 una serie de indicadores KPI para poder medir y supervisar los tiempos de atención de los operadores logísticos, los tiempos de entrega y cambios de equipos de frío, los días de reparación de los equipos de frío en taller y la medición de inventario para garantizar que siempre los activos fijos de la empresa se encuentren almacenados de forma

correcta y evitar que existan pérdidas o fraudes de los activos fijos. Estos indicadores KPI se implementaron junto con diferentes actividades y reuniones de seguimiento, revisiones semanales junto con los supervisores técnicos de Cervecería Nacional, adicional dentro del contrato se establecieron penalizaciones económicas por la falta de cada uno de los indicadores KPI, ya que, cada uno de ellos tiene un límite permitido de fallo. El contrato incluye indicadores KPI y penalizaciones; ello subraya la importancia de una gestión basado en datos. Al ser un operador logístico con una gran trayectoria y completa experiencia en servicios logísticos optaron por implementaron sus propios indicadores para supervisar de forma diaria su propia gestión y comenzar a dar un mejor servicio a sus clientes. Sin embargo, LOGEX busca soluciones adicionales basadas en analítica avanzada para fortalecer el control operativo.

En el actual mundo con grandes empresas que manejan muchos activos fijos, una gestión eficiente dentro de la cadena de suministro es clave para obtener el éxito que espera toda compañía. Uno de los métodos más efectivos para conseguir logros en la cadena de suministro es la externalización de la logística, o también se la conoce como “Outsourcing logístico”. Esta estrategia empresarial se basa en delegar las tareas logísticas de la empresa, como es el almacenamiento, distribución y transporte, a un operador logístico especializado, o también conocido “Logístico de terceros”. Esto se basa prácticamente cuando una empresa contrata como proveedor a un tercero especializado para que se encargue de una parte o su totalidad de las funciones logísticas, y el objetivo de esta estrategia es que al delegar estas funciones a terceros estas empresas se pueden concentrar en sus tareas

principales, como la producción y el desarrollo de productos. Esto al ser uno de los mayores desafíos de Cervecería Nacional, ya que buscan concentrarse en sus competencias principales como las marcas Heineken, Amstel, Biela y la producción de cervezas artesanales que están tomando una gran posición en el mercado. Les beneficia tener un operador logístico especializado para encargarse de la cadena de suministro en este caso de los equipos de frío, ya que este también es una estrategia de apalancamiento o también conocido como “Vendedor silencioso”.

Claramente, al manejar una logística eficiente esto se ve reflejado en un alto nivel de experiencia para los clientes, ya que, al confiar en un operador logístico para manejar la cadena de suministro, las empresas aseguran que las entregas sean más rápidas y con una mayor precisión sin tener casos que sean fallidos, claro está que esto puede pasar en algunos casos, pero por factores externos como preferencias del mismo cliente. Esto se puede medir también como una mayor satisfacción del cliente, que siempre estas grandes empresas van a supervisar, por lo que siempre garantiza una gran lealtad de los clientes y el crecimiento del mismo negocio.

De cada \$100 de ventas para las empresas, \$17,9 corresponden al costo logístico aproximadamente en Ecuador, hablando de empresas grandes, porque cuando son empresas pequeñas normalmente les llega a costar el triple (\$26,4) de lo destina una empresa grande. Esta parte del costo lo dividimos en transporte que es el 40% y en almacenamiento que es el 23%. Pero no siempre estos recursos son eficientes, ya que, un camión llega a ocupar un aproximado de 11 horas adicionales en actividades que no tienen nada que ver con el tráfico, aquí podemos incluir 4 horas que pierden los

transportistas con tiempos de espera, desde que llega el vehículo hasta que descarga y carga nuevamente. También podemos hablar sobre los casos en los que los requerimientos han sido fallidos, diversos estudios indican que, en promedio, hasta el 40% de las entregas presentan desviaciones en LATAM.

En el sector logístico, se suma al avance tecnológico, actualmente la automatización de los procesos y casos muy importantes sobre la sostenibilidad. Es uno de los puntos claves para prosperar dentro de una competencia tan feroz como la es la logística en Ecuador. La empresa LOGEX se encarga de adaptarse rápidamente a las tecnologías más recientes y eficientes, a los procesos pioneros y los enfoques estratégicos, lo que se ha podido reflejar en el éxito de los proyectos que ha llevado a cabo.

Las empresas cada vez más se desarrollan debido al constante despliegue de avances tecnológicos y en la evolución en la cadena de suministro. Este proceso siempre de ser de forma ágil para poder seguir siendo competitivo en el mercado y dentro del entorno digital actual. La automatización es una característica que se ha convertido en un objetivo clave para las empresas modernas, aumentando eficiencia, reducir los costos y para aumentar la productividad de las actividades. Los operadores logísticos pueden aprovechar la automatización mediante la implementación de plataformas o formas completas entre sistemas WMS/TMS y brindar soluciones de e-commerce. Para esto se debe cumplir con términos exactos y precisos sobre los flujos de datos, para que la integración sea de forma más rápida para la información crítica.

Tener conocimiento sobre la predicción de la demanda futura de un producto o servicio es clave para optimizar recursos y brindar mayor satisfacción a los

clientes, ya que, están preparados para cualquier escenario posible. Los operadores logísticos logran analizar factores como en casos de historial de ventas, la economía de un país, las tendencias del mercado, la competencia y un factor muy importante el cual es el precio para poder determinar la predicción de la demanda. De esta manera, los operadores logísticos están siempre preparados y con mayor facilidad para planificar de mejor manera los recursos como empleados, materiales y horarios, de esa manera se realiza una operación más eficiente. Al momento de realizar una predicción de la demanda es necesario considerar que se puede realizar en diferentes fases de la cadena de suministro. Esto va a incluir la carga, descarga y entrega de la mercadería. Cuanto sea más precisa sea la predicción en cada uno de los procesos de la cadena de suministro, mayor será la optimización de la empresa en sus operaciones y poder ajustarse de manera precisa a los niveles de la demanda.

La predicción de la demanda puede llegar a reducir las regulares interrupciones en la cadena de suministro, como puede ser en el caso de una empresa que tiene conocimiento sobre cuánto va a producir según el aumento de la demanda, con esto dicha empresa se va a preparar de manera eficiente ya que tendrá en cuenta los recursos que va a necesitar para poder brindar la mayor satisfacción posible a sus clientes, y de igual manera, el resultado va a ser positivo ya que satisface los pedidos inminentes. Sin embargo, la incertidumbre de la demanda genera cuellos de botella logísticos que pueden prevenirse mediante modelos predictivos avanzados (Asadi & Bektas, 2022), y no tendrá ni los recursos ni las estrategias para poder cumplir con todos los procesos y pedidos de sus clientes.

Los modelos de predicción de la demanda son herramientas claves en la cadena de suministro, ya que estas permiten conocer de forma precisa y anticipada la cantidad de productos o servicios que los clientes van a solicitar en el futuro. Claramente, para poder hacer uso de estas herramientas deben existir datos históricos, variables estacionales o tendencias del mercado al que va enfocado para tener una predicción estimada con el objetivo de optimizar la gestión de inventarios, los recursos logísticos y las diferentes rutas de distribución. La importancia de los modelos de predicción de la demanda se plantea por su capacidad de reducir costos, aumentar la productividad, mejorar la satisfacción del cliente y optimizar la eficiencia en la cadena de suministro en los operadores logísticos.

Casos de éxito como Amazon, ya que al ser conocida por su enfoque de innovación en la predicción de la demanda y su óptima gestión de inventario. Esta compañía utiliza herramientas avanzadas enfocadas en la inteligencia artificial y redes neuronales artificiales para poder analizar grandes volúmenes de datos, y por tal razón siempre logran anticiparse a las demandas del cliente con base en patrones históricos de consumo (Murad & Samuel, 2023). Esta estrategia ha logrado conseguir por lo que esa característica que todos conocemos, la entrega de paquetes inminentes de manera puntual y una excelente experiencia para los consumidores.

PROBLEMÁTICA

Para comenzar, Es importante para las empresas de logística poder hacer más con menos, es pertinente recordar el entorno operativo en que se desempeña la empresa LOGEX S.A. es de brindar servicios logísticos a varias empresas, los cuales son transporte, mantenimiento y reparación de

unidades de refrigeración comercial (URC); sus operaciones son trabajar con activos de alto costo de otras empresas lo cual obliga mantener controles rigurosos de inventario, en la gestión de cadenas de suministro, la predictibilidad de la demanda se define en función de su variabilidad, lo cual influye directamente en la estrategia logística a aplicar, como “lean”, “agile” o un enfoque híbrido (Rushton, Croucher & Baker, 2014)

Por otro lado, Cervecería Nacional (CN) es una de las empresas de bebidas más grande que tiene el país, con más de 137 años de existencia, esto la convierte en un cliente relevante, debido a que una buena relación con ellos aseguraría una posición fuerte en el entorno del negocio.

Asimismo, Cervecería Nacional, al ser tan demandada, tiene que poder asegurar que sus productos estén disponibles, los refrigeradores comerciales funcionan como estrategia de apalancamiento del cliente, los equipos se prestan a los clientes dependiendo de la cantidad de hectolitro que el cliente compre, hay muchos equipos, se mide por pies y los categoriza según el tamaño.

Por lo tanto, estos equipos prestados aseguran a Cervecería Nacional la compra de hectolitros recurrente, por eso se vuelve clave que cada cliente tenga un equipo de frío disponible.

Un SLA efectivo debe definir claramente los KPIs, el método de seguimiento y las consecuencias por incumplimiento, incluyendo incentivos por desempeño (Barkborka, 2020)

Puesto que tener un equipo de frío siempre disponible se vuelve una necesidad para Cervecería Nacional, LOGEX S.A. entra como un el operador logístico para gestionar los refrigeradores comerciales, esto obliga a que

siempre se cumpla con las entregas, debido que el KPI 3 descuenta 3,6% del fee variable cuando la efectividad se ve reducida por debajo del 95%.

Por esta razón, dependen directamente de la capacidad que tenga en cumplir con los tiempos y niveles de servicios, LOGEX S.A. cuenta con taller de reparación, relevante debido a que permite tener siempre equipos disponibles, la capacidad de almacenamiento (m²) para tener los refrigeradores comerciales, un inventario centralizado, flota de transporte propia.

Teniendo el modelo de negocio se desarrollan varios problemas, se mencionó que Cervecería Nacional tiene varias “categorías” de refrigeradores comerciales, esto demanda un terreno en donde tenerlos y el trabajo de simplemente tenerlos se ve magnificado por la gran cantidad de equipos y la cantidad de “categorías”, esto demanda infraestructura la cual tiene un valor.

Dado que la organización actúa como operador logístico es importante no tener sobre inventario debido a que ocuparía capacidad de almacenamiento (m²) útil para otros equipos, tampoco es buena idea andar con quiebre de inventario ya que se produciría un retraso y existieran penalizaciones.

Por otra parte, Existe un proceso de reparación y rotación de los equipos, los refrigeradores comerciales cuando son recogidos de los clientes siempre pasan por una revisión, en el caso de que lo necesite de que tenga algo dañado se lo repara para que quede listo para la rotación, pero hay en ocasiones que se deben reparar equipos y terminan siendo un gasto innecesario en repuestos, tiempo y capacidad de almacenamiento (m²) debido a que no se lo necesitaba. Es importante darles prioridad a los refrigeradores

comerciales necesarios, pero esta tarea se ve complicada debido a la incertidumbre del mañana.

Nuestros resultados experimentales demuestran que el control de la demanda y el cumplimiento afectan el rendimiento y la calidad del servicio de los sistemas de viajes compartidos de manera muy diferente. (Zara Elby, 2017)

Igualmente, hay problemas con la flota de camiones, patrones irregulares de uso, LOGEX S.A. posee 3 camiones y vehículo de carga arrendado con un valor de \$1300 al mes, hay meses que tienen picos que exige una demanda, lo que provoca una sobrecarga en las rutas o la necesidad de otro camión, pero en los periodos de pico genera capacidad de flota ociosa o pagos de alquiler innecesarios. Esta variabilidad que provoca costos fijos en temporadas bajas logra generar gastos innecesarios.

Este cambio de paradigma hacia un enfoque más basado en datos permite que la gestión de la flota responda de forma dinámica a los problemas identificados a través de sensores y algoritmos que detectan anomalías y brindan información de pronóstico sobre la vida útil restante de los componentes. (Crespo del Castillo & Parlikad, 2024, traducción propia).

En mente, se reconoce que uno de los riesgos está en la demanda; se combina con ocasiones en que el taller de mantenimiento procesa las URC retornadas y equipos con baja demanda, lo que provoca que primero ocupen capacidad de almacenamiento importante, se usen repuestos para máquinas de menor prioridad.

Esto se evidencia por la cantidad de inventario almacenado y la ocupación de capacidad de almacenamiento reducida, lo que provocaría la necesidad de bodegas adicionales. Además, el tiempo no juega a su favor; la devaluación técnica es de tener en cuenta, compresores perdiendo gas, repuestos útiles caducándose.

Así, estos conflictos contractuales generan un ejemplo, las penalizaciones en el esquema de KPIs permite descuentos mes a mes que se acumulan hasta 30% del fee variable, el KPI 9 equipos de frío en reparación mayor a 5 días recibe una multa del 3% al registrarse 40 unidades fuera de plazo, al incumplir podrían erosionar la imagen de LOGEX S.A. frente a Cervecería Nacional.

Además, pensando en que hay meses que no hay una demanda exigente de equipos el pago de un el camión de alquiler adicional representa un gasto innecesario, el pago fijo de \$1300 al mes por el camión de alquiler se sumaría al fallar el KPI 3 o 9 los cuales penalizan por un 3%-6% del fee variable, agravando la presión de liquidez.

En la parte económica es un tema relevante, ya que se está gastando el dinero en partes del proceso que podrían ahorrarse o reinvertiendo en diferentes aspectos de la empresa. Exponiendo otra idea se podría considerarse que el capital de trabajo inmovilizado en los puntos incorrectos en vez de mejorar otras áreas como la tecnológica.

En vista del impacto del CN en los puntos de ventas es grande, en Ecuador hay muchos locales informales que compran a Cervecería Nacional y necesitan refrigeradores comerciales, si LOGEX no cumple su parte podría lograr que sus clientes migren.

Por estos problemas queda claro, las penalizaciones, los costos aumentados y la pérdida de confianza descritos antes hacen pensar que el problema es más profundo de lo que parece, la falta de anticipar la necesidad del cliente se ve en diseminada en varias ramas de la empresa, bodega talleres, recursos, transporte.

Sin embargo, se destaca que LOGEX dispone del histórico, desde la reparación del equipo de frío retirado hasta el que llegue a la puerta del cliente, y un histórico de más de 82.000 entregas.

El problema está en la incertidumbre operativa, es la incertidumbre que guarda el mañana, los reportes descriptivos, aunque hay casos importantes para preferir reportes predictivos, este tipo de reportes ayuda a prevenir fallas inesperadas evitando las malas experiencias, siendo la antes expuesta prioridad de reparación según la demanda futura.

Esto radica en un problema "Domino", si se repara un lote de 14 pies, cierta capacidad de almacenamiento se verá ocupado, al momento de traer algún equipo de 19 pies pueda que falte espacio lo que conducirá a un retraso y dependiendo del tiempo la penalización contractual, se esparce en la logística de la empresa.

De lo expuesto se desprende que, lo que no se trata de falta de recursos físicos Sino en la incapacidad de pronosticar con precisión sus actividades operativas como la cantidad y el tipo de equipo de frío que se necesita en los periodos, eso es lo que desata una cadena de sobre costos y penalizaciones que podría restar hasta 30% de la facturación variable mensual, un riesgo a la rentabilidad.

JUSTIFICACIÓN

Sin lugar a duda, las empresas de logística son la mejor opción para las empresas grandes de manufactura y comercialización, tener una cadena de suministros tan grande agrega complejidad a logística de cualquier empresa, servicios de un operador externo como Logex S.A. permite que Cervecería Nacional pueda enfocar sus esfuerzos en otras áreas y sin perder fuerzas en la cadena de suministro.

Igualmente, las empresas de logística se enfrentan a penalizaciones al no cumplir con los acuerdos establecidos para las entregas, pueden tener sobre stock haciéndolos usar espacio útil de las bodegas, el alquiler de otro camión como gasto fijo cuando pudiera ser capital útil.

De hecho, el desempeño logístico, entendido como eficiencia, eficacia y diferenciación logística, impacta directamente en el desempeño organizacional y la capacidad competitiva de las empresas (González et al., 2020).

Es un hecho que hay sectores de la empresa el cual puede verse más o menos afectado por estos problemas, pero lo que no hay duda es que son previsibles. La capacidad de reaccionar a los problemas va a ser el gran diferenciador el cual va a posicionar a la empresa más competitiva frente a las otras.

En consecuencia, las redes neuronales han sido una solución que las empresas que están en el entorno de transporte y rutas, estas han demostrado

su efectividad, DHL incluyó redes neuronales para la predicción de demanda y optimizar así sus operaciones, se demostró un aumento del 30% en su productividad.

Es importante destacar, Según McKinsey (2023), la implementación de inteligencia artificial en las operaciones de distribución puede reducir los niveles de inventario entre un 20 % y un 30 %, Logex S.A. no sería la excepción para esta sensibilidad, sabiendo que las mejoras se verían esparcidas para toda la estructura de la organización, se reduciría los tiempos exigidos por Cervecería Nacional.

Por lo tanto, las redes neuronales constituyen un aliado estratégico, esta inversión en crear para este caso una red neuronal artificial como modelo predictivo, el cual va a reducir costos fijos, “En LATAM se espera que AI recorte tiempos de entrega y combustible 10-20 %” (AmericasMI, 2024), la productividad en las operaciones diarias va a recibir un aumento de su productividad, liberando incluso el estrés de los trabajadores haciendo este un ambiente laboral más placentero.

De igual importancia, Logex S.A. verá un fortalecimiento en su imagen como empresa, abriendo puertas para nuevas negociaciones, con el claro mejoramiento de sus operaciones se demostrará que la empresa no solo entrega un trabajo bien hecho, sino que **se proyecta** como una empresa capaz de anticipar el futuro y saber que las soluciones no son momentáneas, sino que se pretende dar soluciones que penetren durante el tiempo la

actividad diaria de la empresa en al reducir la incertidumbre y mejorar los aspectos tecnológicos de la empresa.

En consecuencia, la implementación de estas herramientas abre múltiples oportunidades con las cual es posible valorar el proyecto. cómo es bien sabido por mucho tiempo, quien innova primero tiene mayores probabilidades de capturar el mercado.

Es fundamental tener en cuenta, que latino América está pasando por una fase de oportunidades sin precedentes, la adaptación de nuevas tecnologías se ha visto entre las más destacadas empresas en Latinoamericanas, Mercado libre, integro IA para anticipar la demandad de productos con el uso de datos históricos, también se logró optimización de las rutas, reduciendo costos y minimizando tiempos de entrega.

Otra pionera fue la empresa Kiki Latam, ellos usan el análisis de datos y algoritmos para optimizar la logística de “última milla”, integran seguimiento en tiempo real de las entregas para mejorar su cadena de logística y asegurar la entrega del paquete.

De ahí que, cerca del 30% de las empresas lideres que aplican los avances de la tecnología para la optimización de la cadena de suministro la ven como una ventaja competitiva, exponiendo el caso de AB InBev, ellos lograron reducir en un 50% de los productos fuera de stock, alcanzaron niveles bajos de falta de inventario y se mejoró en un 20% la precisión de la demanda, Según *The Logistics World* (2025), la implementación de inteligencia artificial

y automatización en la logística está transformando la eficiencia operativa, reduciendo errores y mejorando los tiempos de entrega.

Lograr prever la demanda en los equipos de frío significa menos quiebre de stock, saber la prioridad en reparación de equipos de frío, repuesta más rápida en la entrega de equipo de frío y más ventas para Cervecería nacional.

Hay que señalar que, en Ecuador la presencia de estudios que embarque al uso de redes neuronales artificiales para la cadena de suministro es escaso, por lo que llevar a cabo un estudio a Logex S.A. y a su cadena de demanda va a ser un gran logro a nivel empresarial y a nivel académico.

Asimismo, Logex S.A. posee un histórico de más 80 mil órdenes las cuales se encuentran estructuradas permitiendo un buen filtrado o manipulación de datos, además cada registro cuenta con variedad de variables, numéricas y texto, y gracias a la cantidad de datos se podrá captar patrones relevantes.

Agregando esta idea, se puede ayudar a contribuir al desempeño de Ecuador en la *Logistics Performance Index* del Banco Mundial, la cual es una herramienta de benchmarking que mide la calidad del sistema logístico en un país en una escala del 1 al 5, este índice global ayuda a mejorar la percepción del sector logístico del país permitiendo así atraer a la inversión extranjera.

Entonces queda evidenciado, por academia, que la idea de implementar estas tecnologías de predicción es un hecho que lleva las operaciones a una

optimación, se considera un proyecto factible para los recursos que hoy cuenta la empresa, la viabilidad del proyecto será expuesta.

Puesto que, Logex S.A. cuenta con los datos, infraestructura para poder llevar la aplicación de las redes neuronales para la optimización de la cadena de suministro, se planea poder predecir la demanda de los equipos de frío, de esa manera se busca saber, la cantidad de demanda, se pretende identificar los equipos demandados para así poder darle prioridad a los necesarios tanto para las rutas y reparaciones, se busca tener en stock solo los equipos óptimos.

A continuación, se procede a “limpiar datos”. Se analiza el significado de las etiquetas y ver cuáles van a ser de utilidad para el estudio, se verifica duplicados para evitar sesgo. Asimismo, los datos son filtrados para trabajar únicamente con la información relevante, debido a que la base de datos al descargarla se baja con datos que no son de utilidad para este proyecto, también se implementará métodos estadísticos que van a ir combinado con machine learning, lo cual permitirá manejar grandes volúmenes de datos y detectar patrones no lineales, obteniendo así respuestas más precisas y mejores predicciones.

En conclusión, esta investigación será un gran avance en la logística interna de Logex S.A., recortando gastos innecesarios, optimizando la demanda, también como se verá reflejada la imagen de la empresa con su aliado, Cervecería Nacional, sin mencionar que la buena logística aportará en

la imagen del país frente a futuros inversores, esta actividad académica va a impulsar a la empresa.

OBJETIVOS

Objetivo General:

Implementar redes neuronales artificiales como herramienta de inteligencia artificial para predecir la demanda y optimizar los procesos de la cadena de suministro en la empresa LOGEX S.A.

Objetivos Específicos:

- Analizar los procesos actuales de la cadena de suministro de la empresa LOGEX S.A. para identificar los retrasos, ineficiencias, y oportunidades de mejora de la operación que pueden ser restauradas con técnicas de Inteligencia Artificial.
- Diseñar y entrenar un modelo de red neuronal artificial con la misión de predecir la demanda de equipos de frío, niveles de almacenamiento y tiempos de entrega.
- Evaluar el impacto de la implementación del modelo de red neuronal artificial sobre los indicadores KPI logísticos establecidos por el cliente Cervecería Nacional.

Capítulo I: Fundamentación Teórica

MARCO TEÓRICO

Externalización de logística y cadena de suministros

La logística empresarial y todo lo que conlleva la de suministro se estipulan como las bases fundamentales en el actual contexto empresarial a nivel mundial. La logística, es comprendida como el proceso elemental de planificar, implementar y controlar de forma eficaz el flujo y el almacenamiento

de bienes, información o servicios desde un punto de origen hasta el punto de venta o su destino final, se establece como un componente estratégico para las organizaciones (Coyle et al., 2013). La cadena de suministros, por otro lado, asume todas las actividades que comprenden la adquisición, producción y distribución de productos, lo que a nivel mundial representa un sistema interconectado que ha ocasionado impactos positivos directamente en la competitividad de una empresa.



Ilustración 1. Como funciona la externalización logística.

La decisión estratégica de la externalización de logística radica en la capacidad de reducir costos y delegar la administración de productos de una empresa para su distribución. La sincronización efectiva de las diferentes etapas de la cadena de suministro se refleja como una gran ventaja competitiva, permitiendo a las empresas responder a tiempo a las demandas del mercado (Christopher, 2016). De igual manera, la externalización de logística no solo se limita a la distribución física de bienes, sino que también la gestión de inventarios, supervisión de indicadores de servicio al cliente y

decisiones estratégicas que impactan de manera inmediata en la rentabilidad y sostenibilidad de la empresa.

En el entorno empresarial actual todo se vuelve más complejo, la interconexión entre la externalización de logística y la cadena de suministros se vuelve imprescindible para conseguir un éxito a largo plazo. La capacidad de un operador logístico para gestionar de manera eficiente su cadena de suministro no solo se refleja en la entrega de productos, sino también en la capacidad de adaptarse a cambios o solicitudes urgentes cuidando la expectativa del cliente, las fluctuaciones del mercado y las innovaciones tecnológicas (Chopra & Meindl, 2016).

Optimización de la cadena de suministro

En el sector de la gestión de la cadena de suministros, la aplicación de tecnologías para la optimización se ejecuta como un enfoque fundamental para poder mejorar la eficiencia y una competitividad en el mercado. Diferentes modelos teóricos logran ofrecer marcos conceptuales que permiten a las organizaciones implementar estrategias efectivas para poder optimizar sus procesos elementales. La optimización, en este escenario logístico, se refiere a la búsqueda de mejores soluciones que puedan aumentar la productividad en las rutas y maximizar el rendimiento de la cadena de suministro.



Ilustración 2. Optimización de la cadena de suministro.

La aplicación de estrategias de optimización no se determina únicamente para la gestión de inventario, sino que abre paso a la planificación del transporte y la gestión de la demanda. Diferentes métodos, como el modelo de programación lineal, se utilizan para maximizar el impacto positivo en la asignación de recursos y una planificación de producción efectiva (Coyle et al., 2013). Estos sistemas de optimización brindan herramientas analíticas eficientes para poder afrontar desafíos específicos en diferentes etapas de la cadena de suministro.

Al implementar estrategias que se basan en la optimización de la cadena de suministro se hace referencia a un enfoque eficaz con una continua mejora.

Tecnologías Aplicadas a la Logística

En el panorama empresarial actual, la implementación de tecnologías desempeña un papel clave en la mejora de la gestión de la cadena de suministro.

Inteligencia Artificial

Según Team (2023), es una tecnología que brinda la oportunidad de crear máquinas que pueden ejecutar tareas que normalmente dependen de la inteligencia y el trabajo humano. Por ejemplo, Alan Turing hizo un experimento llamado el “Test de Turing” que consistía en poder saber si la inteligencia artificial puede imitar el trabajo humano, lo que logró que se establezcan las bases de la inteligencia artificial.

A partir de esta información, se puede identificar que el real objetivo de la inteligencia artificial es simular la inteligencia humana a través de diferentes capacidades en la máquina como por ejemplo el reconocimiento de voz, la toma de decisiones y los diferentes modelos sobre técnicas de aprendizaje automático como el Machine Learning o el Deep Learning (Haleem et al., 2022).

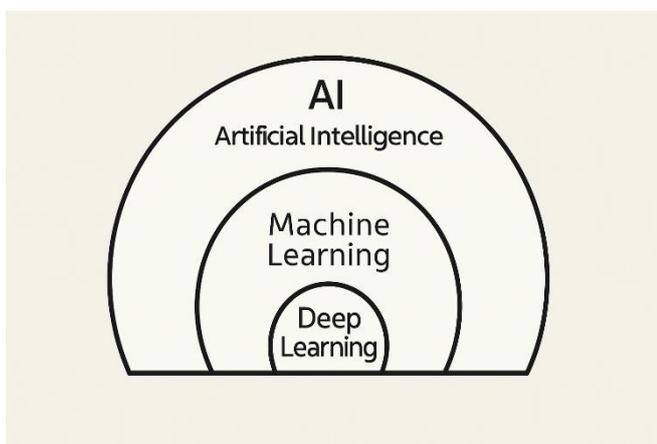


Ilustración 3. Estructura de la inteligencia artificial y sus subcampos.

Actualmente, la adopción de la inteligencia artificial se acelerará en la frontera digital reduciendo la brecha que existe entre los consumidores y la tecnología, de tal manera que cada vez se logren invertir más recursos para los diferentes sectores de la industria. Por otro lado, se sabe que en el mundo actual se vive

a diario descubrimientos tecnológicos como el reconocimiento facial y modulación inteligente de sonido, hasta automóviles con la capacidad de manejarse sin piloto; mucho de esto se puede realizar por la inteligencia artificial, también se la puede determinar por su capacidad de interpretar de manera muy acertada los datos externos y poder aprender de ellos para poder utilizarlos con el objetivo de poder lograr los objetivos específicos (Haenlein y Kaplan, 2019).

En el sector logístico la Inteligencia Artificial se puede convertir en una muy buena herramienta para poder predecir la demanda, mejorar la gestión para las rutas de distribución y optimización de inventario lo que podría hacer que los clientes que optan por externalizar su proceso logístico de forma segura, apostar más por la innovación en tecnología nueva para que su nivel competitivo en el mercado impulse a la empresa a crecer y generar ventajas competitivas frente a los demás operadores logísticos.

Machine Learning

Como menciona Ramírez (2018) el machine learning o también conocido como aprendizaje automático es un subconjunto de las ciencias computacionales, como es también una rama de la inteligencia artificial, que logra facilitar los sistemas para aprender sobre los datos, en ocasiones logra manejar grandes cantidades de datos para crear sistemas automáticos que de forma automática aprenden y tienen las tareas de clasificar, resolver y predecir escenarios críticos o eventos, y comportamientos sin que sea necesario la práctica de un ser humano, todo esto se logra por la creación y entrenamiento de algoritmos con extensas bases de datos, pudiendo identificar patrones y como resultado el análisis completo de los datos.

Como indica Alpaydin (2020), el aprendizaje automático por medio de la utilización de algoritmos lo que permite a las computadoras mejorar su capacidad de aprender, analizar y poder relacionar los patrones de una gran base de datos que pueda llegar a predecir escenarios con estos datos que puedan permitir a las personas un mejor control en su toma de decisiones, por lo que la Inteligencia Artificial, dota a las máquinas la capacidad de ejecutar tareas autónomas sin la necesidad de tener una previa programación ni una supervisión.

Es conocido por ser un método de análisis de datos que logra automatizar la construcción de los modelos analíticos gracias a la utilización de los datos que logran abarcar diferentes formas de información digital como, por ejemplo: palabras, números, e inclusive imágenes (Date, 2020).

Los algoritmos empleados cuando se aplican en el Machine Learning se crean en base a los datos recopilados, en donde se analizan y se calculan dentro de sus capas, y mientras tenga más datos que procesar almacenados en el sistema, estos serán más complejos, pero a la vez tendrán un mayor porcentaje de efectividad. Entonces cuando se llegan a los resultados esperados, serán mucho más exactos e irán mejorando con el tiempo (Aprende IA, 2021).

Redes neuronales Artificiales

Las redes neuronales artificiales, también conocidas como RNA, son modelos informáticos diseñados para poder replicar la funcionalidad del cerebro humano a partir de un conjunto de datos. Diversas fórmulas y expresiones

matemáticas son necesarias para su funcionalidad y la estructura de los procesamientos.

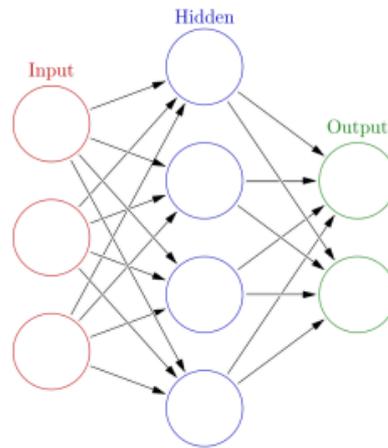


Ilustración 4. Estructura de una Red Neuronal Artificial Multicapa.

La estructura fundamental de la red neuronal es la siguiente:

Input Layer:

Para su estructura, se sabe que se comienza en el input layer; esta capa de nuestra red va a ser la que recepta los datos, pixeles de imagen, peso, altura, edad, etc. Un punto clave sobre esta capa es que en esta primera fase solo se van a recibir los datos y los va a enviar a la capa siguiente; esta primera capa la vamos a tratarla como capa 0.

El número de nodos en esta fase o capa es similar a las características de la base de datos que se use en los modelos de redes neuronales. MNIST es una base de datos donde contiene imágenes del 0 al 9 y cada imagen es de 28x28 pixeles, lo que nos da un total de 784. Entonces el input layer va a dar como resultado 784 nodos.

Hidden Layer:

Esta capa es la parte fundamental de la red neuronal y las hidden layer, en esta capa puede variar su cantidad dependiendo de la complejidad de la red neuronal. Se puede encontrar hasta el escenario más sencillo que llega a tener 1 o casos más complicados que pueden llegar a tener 96 capas. Se debe tomar en cuenta, que capas y nodos no cumplen la misma función ni tienen similitud, pueden existir casos de confusión ya que al hablar de nodos puede crecer el número de manera exponencial. Las Deep Learning normalmente contienen más capas ocultas.

Propagación hacia adelante

Las neuronas y sus relaciones:

Las entradas (x_i) de cada neurona son ponderadas por sus propios pesos (w_i) respectivos. La forma en la que se calcula la salida de cada neurona:

$$z = \sum_{i=1}^n w_i \cdot x_i + b$$

La función de activación es la parte del proceso donde se produce su complejidad; sin esta parte se obtiene una red limitada a problemas lineales; gracias a esta parte, una red neuronal puede hacer tareas complejas, no lineales y comienza a aprender patrones complejos.

Las capas ocultas sirven en este proceso para calcular; se aplica una función de activación $f(z)$.

Función sigmoide:

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

Esta función mapea los valores entre 0 y 1, lo que es útil para problemas de clasificación.

Función tangente hiperbólica:

Esta función mapea los valores entre -1 y 1 , ofreciendo una salida más centrada.

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

ReLU (Rectified Linear Unit):

Esta función es popular en redes neuronales profundas debido a su simplicidad y eficiencia computacional.

$$\text{ReLU}(z) = \max(0, z)$$

$$\text{ReLU}(z) = \begin{cases} 1 & \text{si } z > 0 \\ 0 & \text{si } z \leq 0 \end{cases}$$

Output Layer:

Esta capa es la de salida de una red neuronal; en esta capa se presencian los resultados del modelo; para eso se debe plantear varias fórmulas. Se debe comprender que las respuestas son probabilidades, es decir que siempre puede existir un margen de error.

Las funciones más usadas son la función de activación sigmoide y Softmax.

- Función sigmoide:

$$\sigma(Z) = \frac{1}{1 + e^{-z}}$$

Esta función tiene como objetivo ayudar a observar valores más cercanos a 0 y los valores más cercanos a 1. Se sabe que mientras esté más cerca del 1 se encuentre, las probabilidades de las respuestas van a ser más efectivas. Es aplicable para buscar una sola respuesta, es decir, en actividades de clasificación binaria. El ejemplo más claro es, si se desea determinar si un correo electrónico es spam o no lo es, la red neuronal va a proporcionar un valor de salida cercano a 1 para los casos positivos, que en este caso es el spam, y cercanos a 0 para los valores negativos o correos de no spam.

Función Softmax:

A diferencia de la sigmoide, esta función permite clasificar de forma multiclase. Con esta función la red neuronal artificial puede dar probabilidades, pero a múltiples clases; bajo la misma premisa, daría una respuesta cercana a 0 y 1, pero en esta ocasión podrá dar varias respuestas. Por ejemplo, en un escenario de clasificación multiclase, como lo es la categorización de imágenes médicas en distintas patologías como por ejemplo la fibrosis pulmonar, neumonía o una condición normal, la función softmax va a transformar la salida del modelo en un grupo de probabilidades. Cada clase va a recibir un valor en 0 y 1, y la suma total de las probabilidades va a ser igual a 1, lo que va a permitir determinar la clase más probable para una entrada determinada.

Propagación hacia adelante en Machine Learning:

Esta función de propagación sucede en cada capa de la red neuronal; entra la información, se ejecuta la suma ponderada, se suma el sesgo (en caso de que sea necesario), se aplica la función de activación y se pasa a la parte de

propagación y así sucesivamente a cada neurona hasta que se logra llegar a la salida con el resultado.

Error y retro propagación:

Durante el proceso de entrenamiento, lo que se busca hacer es comparar el resultado de la salida con la respuesta real, la salida pronosticada con la salida real y dependiendo de los repuestos se le ajustarán los pesos.

$$w_i^{(new)} = w_i^{(old)} - \eta \frac{\partial E}{\partial w_i}$$

Modelo de Autorregresivo (AR)

En las series de tiempo temporales se encuentra AR como un modelo que capturar relaciones temporales en las series de datos, son necesarias para las predicciones de variables, es decir donde el valor existente de una serie temporal se aclara para combinar sus propios datos pasados y un término de error aleatorio.

x_t : Valor de la serie temporal.

ϕ_1, ϕ_2, ϕ_p : Estos valores representan el coeficiente autorregresivo, permite cuantificar que impacta en los datos pasados sobre los presentes.

$x_{t-1}, x_{t-2}, x_{t-p}$: Los datos anteriores de la serie.

ϵ_t : El Error o ruido blanco.

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \epsilon_t$$

Modelo de Media Móvil (MA)

A diferencia del concepto anterior podemos decir que el MA trabaja con los errores del pasado, modelo estadístico el cual usa los errores de una serie de

datos para poder hacer una predicción, nos permite suavizar las fluctuaciones aleatorias usando los errores previos.

x_t : Valor de la serie temporal.

μ : Media constante de la serie.

$\epsilon_{t-1}, \epsilon_{t-2}, \dots, \epsilon_{t-q}$: Son los términos para el error repartidos con media cero y varianza constante.

$\theta_1, \theta_2, \dots, \theta_p$: Son características ponderadas en el impacto de los errores pasados en el valor actual.

$$X_t = \mu + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q}$$

Métricas para Evaluar los Modelos de Predicción

Error Absoluto Medio (MAE)

El MAE como indica es para medir la magnitud promedio de los errores entre los datos que se predijeron y los datos reales observados, esta métrica nos entrega valores absolutos y permite ver el error promedio del modelo frente a las mismas unidades de la variable original.

y_t : Valor real

y_{Δ_t} : Valor predicho en el tiempo

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - y_{\Delta_t}|$$

Error Cuadrático Medio de la Raíz (RMSE)

Al igual que concepto anterior, RMSE promedia los errores, calcula la raíz cuadrada del error promedio, pero sanciona con mayor fuerza las

inexactitudes de los valores atípicos, útil cuando deseamos dar más importancia a grandes desviaciones.

y_t : Valor real

$y\Delta_t$: Valor predicho en el tiempo

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - y\Delta_t)^2}$$

MARCO CONCEPTUAL

Fundamentos de Inteligencia Artificial y Aprendizaje Automático

- La Inteligencia Artificial (IA) es una disciplina científica y tecnológica que busca diseñar, modelar e implementar sistemas computacionales capaces de realizar tareas que, en seres humanos, requieren inteligencia. Estos sistemas procesan información, aprenden de datos, reconocen patrones, toman decisiones y adaptan su comportamiento en entornos dinámicos, imitando o superando capacidades cognitivas humanas.
- Según Nilsson (2009), la IA es "la ingeniería que construye entidades inteligentes", mientras que Russell & Norvig (2021) la definen como "el estudio de agentes racionales que perciben su entorno y ejecutan acciones para maximizar sus objetivos".
- La IA se sustenta en múltiples áreas, como:
 - Machine Learning (Aprendizaje Automático)
 - Procesamiento del Lenguaje Natural (NLP)
 - Visión por Computadora
 - Robótica Cognitiva
 - Sistemas Expertos

Clasificación Fundamental: IA Débil vs. IA Fuerte

- La distinción entre IA Débil (Narrow AI) e IA Fuerte (General AI) surge de las capacidades cognitivas y el alcance funcional de los sistemas artificiales. Esta clasificación, propuesta inicialmente por John Searle (1980) en su experimento mental del "Cuarto Chino", delimita si una máquina puede realmente "pensar" o solo simular pensamiento.

Inteligencia Artificial Débil (Narrow AI)

Definición:

La IA Débil, también llamada IA Específica, se refiere a sistemas diseñados para realizar tareas concretas con alto rendimiento, pero sin consciencia, autoconsciencia o comprensión real. Estos sistemas operan dentro de un dominio limitado y no extrapolan su conocimiento a contextos no entrenados.

- Características:
- Especializada: Excelencia en una única función (ej: reconocimiento facial, chatbots, recomendación de contenidos).
- Dependencia de datos: Requiere grandes volúmenes de datos entrenados para su funcionamiento.
- Ausencia de consciencia: No tiene entendimiento subjetivo ni intencionalidad (ej: un modelo de lenguaje como GPT-4 no "comprende" lo que dice).
- Basada en optimización: Usa algoritmos para maximizar métricas (precisión, recall, etc.) sin autonomía genuina.
- Ejemplos:
 - Siri, Alexa (asistentes virtuales).
 - AlphaGo (juego de Go).
 - Sistemas de diagnóstico médico basados en ML.

- Fundamento Teórico:
Según Searle (1980), la IA Débil solo simula inteligencia mediante manipulación sintáctica, sin semántica real ("sintaxis no equivale a semántica").

Inteligencia Artificial Fuerte (General AI - AGI)

La IA Fuerte, o Inteligencia General Artificial (AGI), postula la creación de sistemas con capacidades cognitivas equivalentes a las humanas, incluyendo:

- Autoconciencia
- Comprensión abstracta
- Razonamiento contextual
- Aprendizaje autónomo en múltiples dominios
- Características:
- Generalización: Aplica conocimiento de un ámbito a otro sin reentrenamiento (transfer learning humano).
- Intencionalidad: Posee metas propias y comprensión semántica (no solo procesamiento estadístico).
- Consciencia fenomenológica: Experiencia subjetiva (qualia), según defensores como David Chalmers (1996).
- Adaptabilidad: Resuelve problemas novedosos sin programación explícita.
- Marco computacional: La IA actual se basa en arquitecturas de redes neuronales, insuficientes para replicar cognición humana (según Penrose, 1989).
- Ejemplos teóricos/proyectos en desarrollo:
 - Blue Brain Project (simulación de cerebro humano).
 - OpenAI's GPT-n (enfoques hacia AGI).

Machine Learning (Aprendizaje Automático)

El Machine Learning (ML), o aprendizaje automático, es una subdisciplina de la inteligencia artificial (IA) que se centra en el desarrollo de algoritmos y modelos que permiten a las computadoras aprender a partir de datos, identificar patrones y tomar decisiones con mínima intervención humana. A diferencia de los sistemas tradicionales, que requieren programación explícita para cada tarea, los sistemas de ML mejoran su rendimiento automáticamente a medida que procesan más información. El proceso de ML implica alimentar al sistema con grandes volúmenes de datos, a partir de los cuales el algoritmo identifica patrones ocultos. Este conocimiento se utiliza posteriormente para hacer predicciones o tomar decisiones automáticas. El éxito del ML depende en gran medida de la calidad y cantidad de los datos disponibles, así como de la elección adecuada de algoritmos y su correcta parametrización.

Relación entre Inteligencia Artificial y Machine Learning

La inteligencia artificial es un campo amplio que busca desarrollar sistemas capaces de realizar tareas que, si fueran realizadas por humanos, requerirían inteligencia. Dentro de este campo, el Machine Learning representa un enfoque específico que permite a las máquinas aprender de los datos y mejorar su rendimiento con el tiempo sin ser programadas explícitamente para cada tarea.

En otras palabras, mientras que la IA abarca una variedad de técnicas y enfoques para emular la inteligencia humana, el ML se centra en el aprendizaje a partir de datos como medio para alcanzar ese objetivo. Esta relación se puede visualizar como un conjunto, donde el ML es una parte integral de la IA, proporcionando las herramientas necesarias para que los sistemas inteligentes puedan adaptarse y mejorar con la experiencia.

Tipos de Aprendizaje en Machine Learning

El Machine Learning se clasifica comúnmente en tres tipos principales de aprendizaje, cada uno con características y aplicaciones distintas:

Aprendizaje Supervisado

En el aprendizaje supervisado, los algoritmos se entrenan utilizando conjuntos de datos etiquetados, es decir, cada entrada de datos está asociada con una salida deseada. El objetivo es aprender una función que, a partir de nuevas entradas, pueda predecir la salida correspondiente. Este tipo de aprendizaje es ampliamente utilizado en tareas de clasificación y regresión.

Ejemplos de algoritmos supervisados:

Regresión lineal

La regresión lineal es una técnica estadística fundamental utilizada en aprendizaje automático supervisado para modelar la relación entre una variable dependiente continua y una o varias variables independientes. Esta técnica se basa en la suposición de que existe una relación lineal entre dichas variables, permitiendo predecir el valor de salida a partir de nuevas entradas. Su enfoque es determinista, y busca minimizar el error entre los valores predichos y los valores reales observados. La regresión lineal es ampliamente empleada en contextos donde se requiere interpretar el impacto de diferentes factores sobre un resultado cuantitativo, como en predicciones económicas, análisis de tendencias o proyecciones científicas. Sin embargo, su aplicabilidad se ve limitada cuando las relaciones entre las variables son no lineales o cuando existen fuertes correlaciones entre las variables predictoras. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning: With Applications in R* (Vol. 103). Springer.

Regresión logística

La regresión logística es una técnica de modelado estadístico orientada a resolver problemas de clasificación binaria, donde el objetivo es predecir la probabilidad de

que una observación pertenezca a una de dos categorías posibles. A diferencia de la regresión lineal, este método no busca estimar un valor continuo, sino una probabilidad limitada entre 0 y 1, lo que permite interpretar los resultados en términos de riesgos o probabilidades condicionales. Es particularmente útil en campos como la medicina, la mercadotecnia o la detección de fraudes. Su interpretación es relativamente intuitiva y permite evaluar la influencia de cada variable independiente sobre la probabilidad del evento de interés. No obstante, asume que existe una relación lineal entre las variables independientes y el logaritmo de las probabilidades, lo cual puede limitar su eficacia en contextos altamente no lineales. Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression* (3rd ed.). Wiley.

k-vecinos más cercanos (k-NN)

El algoritmo de los k-vecinos más cercanos es un método de aprendizaje supervisado que se basa en la proximidad entre observaciones para hacer predicciones. Es un enfoque no paramétrico, lo que significa que no asume una forma funcional específica entre las variables, sino que confía en la similitud local entre los datos. En clasificación, al recibir una nueva muestra, el algoritmo identifica las k muestras del conjunto de entrenamiento más cercanas y asigna la clase más común entre ellas. En regresión, el valor predicho se calcula a partir del promedio de los valores de salida de los vecinos. Su simplicidad lo convierte en un algoritmo fácil de implementar y entender, además de ser flexible frente a problemas no lineales. Sin embargo, su rendimiento puede degradarse con conjuntos de datos grandes o de alta dimensionalidad, y es sensible al ruido y a la escala de los datos. Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27.

Aprendizaje No Supervisado

El aprendizaje no supervisado se utiliza cuando los datos no están etiquetados. El objetivo es identificar patrones, estructuras o relaciones ocultas dentro de los datos. Este enfoque es común en tareas de agrupamiento y reducción de dimensionalidad.

Ejemplos de algoritmos no supervisados:

k-means

El algoritmo *k-means* es una técnica de agrupamiento no supervisado ampliamente utilizada en minería de datos y aprendizaje automático para particionar un conjunto de datos en k grupos distintos. Su objetivo es organizar los datos de tal manera que los elementos dentro de un mismo grupo sean lo más similares posible entre sí y lo más diferentes posible respecto a los de otros grupos. Este método inicia asignando aleatoriamente k centroides (representantes de cada grupo), y luego itera entre dos fases: asignar cada punto de datos al centroide más cercano y recalculando los centroides como la media de los puntos de cada grupo. El proceso continúa hasta que los centroides dejan de cambiar significativamente, alcanzando así una solución estable. Su simplicidad computacional, escalabilidad y velocidad de convergencia han hecho que sea utilizado en una amplia variedad de aplicaciones, como segmentación de clientes, compresión de imágenes, y agrupamiento de documentos. No obstante, el algoritmo presenta ciertas limitaciones, como su sensibilidad a la elección del número de grupos (k) y su vulnerabilidad ante datos ruidosos o con estructuras no esféricas.

MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1(14), 281–297. University of California Press.

Algoritmos de asociación

Los algoritmos de asociación son técnicas empleadas en el análisis de datos para descubrir patrones, relaciones y correlaciones frecuentes entre variables dentro de

grandes bases de datos. Estas reglas de asociación describen cómo la ocurrencia de ciertos elementos en un conjunto de datos influye en la presencia de otros, siendo ampliamente utilizadas en aplicaciones como el análisis de cesta de mercado, recomendación de productos, y diagnóstico médico. Uno de los algoritmos más representativos en esta categoría es el algoritmo *Apriori*, que trabaja generando primero los conjuntos frecuentes de ítems y luego derivando reglas de asociación a partir de ellos, utilizando métricas como soporte, confianza y lift. Estos algoritmos permiten extraer conocimiento útil de bases de datos transaccionales, facilitando la toma de decisiones comerciales o la personalización de servicios. Sin embargo, pueden generar un volumen elevado de reglas redundantes o poco relevantes, lo que obliga a aplicar técnicas de filtrado y validación para garantizar la calidad del conocimiento extraído.

Agrawal, R., Imieliński, T., & Swami, A. (1993). Mining association rules between sets of items in large databases. *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data*, 207–216.

Aprendizaje por Refuerzo

En el aprendizaje por refuerzo, un agente aprende a tomar decisiones mediante la interacción con un entorno. El agente recibe recompensas o penalizaciones en función de sus acciones, y su objetivo es maximizar la recompensa acumulada a lo largo del tiempo. Este tipo de aprendizaje es especialmente útil en situaciones donde la toma de decisiones secuenciales es crucial.

Ejemplos de algoritmos de aprendizaje por refuerzo:

Q-learning

Q-learning es un algoritmo de aprendizaje por refuerzo fuera de política (*off-policy*) que permite a un agente aprender una estrategia óptima de comportamiento en un entorno desconocido, mediante la exploración y la retroalimentación recibida por las

recompensas asociadas a cada acción tomada. Este algoritmo tiene como objetivo aprender una función de valor que indique la utilidad esperada de realizar una determinada acción en un estado específico, y seguir luego la política que maximiza esta utilidad acumulada a largo plazo. Una de sus características distintivas es que actualiza sus estimaciones en función de la mejor acción posible, independientemente de la política de exploración seguida durante el aprendizaje. Esta propiedad hace que Q-learning sea robusto y flexible, siendo útil en entornos donde se necesita aprendizaje autónomo sin conocimiento previo del modelo del entorno. Ha sido aplicado con éxito en sistemas de navegación de robots, juegos de tablero, redes de comunicaciones y problemas de control en tiempo real.

Watkins, C. J. C. H., & Dayan, P. (1992). Q-learning. *Machine Learning*, 8(3–4), 279–292.

SARSA

SARSA (State-Action-Reward-State-Action) es un algoritmo de aprendizaje por refuerzo en línea y bajo política (*on-policy*), que busca aprender una política óptima al interactuar con el entorno, actualizando sus estimaciones basadas en la secuencia real de estados y acciones tomadas por el agente. A diferencia de Q-learning, que evalúa la mejor acción posible en el siguiente estado independientemente de la política seguida, SARSA utiliza la acción que el agente realmente ejecuta en ese estado siguiente, haciendo que su comportamiento y actualización de valores estén alineados con la política de exploración utilizada (por ejemplo, ϵ -greedy). Esto puede hacer que SARSA sea más conservador y estable en entornos donde las acciones subóptimas tienen consecuencias negativas importantes. Su aplicación ha sido explorada en tareas como control de tráfico vehicular, estrategias en videojuegos, y control adaptativo en robótica, destacando por su capacidad de aprendizaje continuo y adaptable.

Rummery, G. A., & Niranjan, M. (1994). *On-line Q-learning using connectionist*

systems (Technical Report CUED/F-INFENG/TR 166). Cambridge University Engineering Department.

Deep Q-Networks (DQN)

Deep Q-Networks (DQN) representan una evolución del algoritmo Q-learning, combinándolo con redes neuronales profundas para permitir su aplicación a problemas de alta dimensionalidad y con espacios de estado continuos o muy complejos. En lugar de mantener una tabla de valores para cada par estado-acción, como en Q-learning tradicional, DQN utiliza una red neuronal que aproxima la función de valor de acción, lo que permite generalizar el aprendizaje a partir de la experiencia previa. Esta técnica ha sido pionera en el uso del aprendizaje profundo en entornos dinámicos e inciertos, logrando resultados impresionantes en dominios como videojuegos clásicos (por ejemplo, Atari) sin necesidad de características manuales. DQN introdujo además dos innovaciones clave: el *replay memory*, que almacena experiencias pasadas para entrenar la red de forma más estable, y la *red objetivo*, que mejora la estabilidad del aprendizaje al desacoplar las actualizaciones de la red principal. Gracias a estas mejoras, DQN abrió el camino para una nueva generación de algoritmos de control inteligente basados en redes profundas.

Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... & Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533.

Aprendizaje Profundo (Deep Learning)

El *aprendizaje profundo* (*Deep Learning*) es un subcampo del aprendizaje automático que se basa en el uso de redes neuronales artificiales con múltiples capas ocultas para modelar representaciones jerárquicas de datos. Estas redes, conocidas como redes neuronales profundas, están diseñadas para aprender automáticamente

características complejas a partir de grandes volúmenes de datos sin requerir una ingeniería manual intensiva de variables. A través de capas sucesivas de procesamiento no lineal, el aprendizaje profundo permite extraer patrones de alto nivel, como el reconocimiento de rostros, el entendimiento del lenguaje natural o la identificación de objetos en imágenes.

Una de sus principales fortalezas es la capacidad de generalizar sobre datos no estructurados, como texto, audio o imágenes, lo que ha permitido avances significativos en áreas como la visión por computador, la traducción automática, los asistentes virtuales y los sistemas autónomos. El éxito del aprendizaje profundo se ha visto favorecido por el crecimiento exponencial en la disponibilidad de datos, el aumento del poder computacional (especialmente mediante GPUs y TPUs) y mejoras en técnicas de entrenamiento como la normalización por lotes, regularización y optimización estocástica.

A diferencia de los modelos de aprendizaje automático tradicionales, que a menudo dependen de características diseñadas manualmente, el aprendizaje profundo se enfoca en la representación de datos de manera automática, permitiendo una mayor capacidad de abstracción y flexibilidad. No obstante, también presenta desafíos importantes, como la necesidad de grandes cantidades de datos etiquetados, elevados costos computacionales y una menor interpretabilidad de los modelos resultantes.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.

Big Data:

Conjuntos de datos extremadamente grandes y complejos, que exceden la capacidad del software tradicional para ser capturados, gestionados y procesados en un tiempo razonable (Laney, 2001, p. 1).

Calidad de Datos (Data Quality):

La adecuación al uso de los datos, abarcando dimensiones como exactitud, integridad, consistencia, actualidad y relevancia (Redman, 1998, p. 47).

Datos de Series Temporales (Time Series Data):

Secuencia de observaciones recolectadas secuencialmente en el tiempo, esencial para pronósticos de demanda y optimización dinámica (Hyndman & Athanasopoulos, 2018, p. 3).

Normalización de Datos (Data Normalization):

Técnica para escalar características numéricas a un rango común (e.g., [0,1]), crítica para el entrenamiento eficiente de redes neuronales (Goodfellow et al., 2016, p. 299).

Recopilación de Datos (Data Collection)

Proceso sistemático de reunir y medir información de fuentes diversas para responder preguntas de investigación, garantizando calidad y relevancia (Sarker, 2021, p. 5).

Entrenamiento (Training):

Fase donde el algoritmo aprende patrones de los datos mediante ajuste iterativo de parámetros, minimizando una función de pérdida (Goodfellow et al., 2016, p. 149).

Validación (Validation):

Proceso de optimización de hiperparámetros y prevención de sobreajuste (overfitting) usando un conjunto de datos independiente durante el entrenamiento (Raschka, 2018, p. 311).

Evaluación (Evaluation):

Análisis del rendimiento del modelo final con métricas cuantitativas (ej. precisión, F1-score) en datos no vistos (*test set) (Provost & Fawcett, 2013, p. 76).

Despliegue (Deployment):

Implementación del modelo en entornos productivos para generar predicciones operativas, requiriendo monitoreo continuo y actualizaciones (Sculley, 2015).

Evaluación de Modelos

Métricas comunes:

Accuracy (Exactitud):

Proporción de predicciones correctas (tanto positivas como negativas) sobre el total de muestras (Provost & Fawcett, 2013).

- Precision
- Recall
- F1-Score
- MSE (Error cuadrático medio)
- MAE (Error absoluto medio)

Redes Neuronales Artificiales (RNA)

Las redes neuronales artificiales (RNA) son sistemas computacionales bioinspirados que emulan el procesamiento de información del cerebro humano (McCulloch & Pitts, 1943). Estas arquitecturas están compuestas por capas interconectadas de neuronas artificiales que transforman datos de entrada en salidas predictivas (Rosenblatt, 1958). La estructura típica incluye:

Capa de entrada:

Recibe datos crudos, como señales sensoriales o características preprocesadas (LeCun et al., 2015).

Capas ocultas:

Extraen características jerárquicas mediante transformaciones no lineales (Goodfellow et al., 2016).

Capa de salida:

Genera predicciones para tareas específicas, como clasificación o regresión (Bishop, 2006).

Neurona Artificial

La neurona artificial, conceptualizada inicialmente por McCulloch y Pitts (1943), es la unidad fundamental de procesamiento en las RNA. Según Schmidhuber (2015), su diseño simula la integración de estímulos biológicos mediante:

Pesos sinápticos:

Modulan la importancia de cada conexión (Hinton, 2012).

Función de activación:

Introduce no linealidades para modelar relaciones complejas (Nair & Hinton, 2010).

Algoritmo de Retropropagación

El algoritmo de retropropagación, popularizado por Rumelhart et al. (1986), es el pilar del entrenamiento de RNA. Como describen LeCun et al. (2015), este método:

Calcula errores comparando salidas predichas y reales mediante funciones de pérdida (Bishop, 2006).

Propaga gradientes hacia atrás para ajustar pesos, optimizando el rendimiento del modelo (Bengio et al., 1994).

Funciones de Activación

Las funciones de activación determinan el comportamiento no lineal de las RNA:

ReLU:

Propuesta por Nair y Hinton (2010), mitiga el problema del gradiente desaparecido en redes profundas.

Sigmoide:

Utilizada históricamente para clasificación binaria, pero con limitaciones en entrenamiento profundo (LeCun et al., 1998).

TanH:

Versión escalada de la sigmoide, preferida en redes recurrentes (Hochreiter & Schmidhuber, 1997).

Función de Pérdida y Optimización

Funciones de pérdida:

MSE:

Ampliamente usado en regresión por su interpretabilidad estadística (Hastie et al., 2009).

Entropía cruzada:

Recomendada para clasificación por su sensibilidad a probabilidades (Murphy, 2012).

Optimización:

El gradiente descendente, fundamentado en trabajos de Cauchy (1847), ajusta pesos iterativamente. Variantes como el mini-batch mejoran eficiencia (Bottou, 2010).

Overfitting y Técnicas de Regularización

Overfitting:

Fenómeno descrito por Hawkins (2004) donde el modelo memoriza ruido en lugar de aprender patrones generalizables.

Perceptrón Multicapa (MLP):

Sistemas de procesamiento de información distribuida que emplean transformaciones no lineales jerárquicas, caracterizados por su capacidad de aprendizaje representacional profundo y adaptación contextual dinámica.

Redes Neuronales Convolucionales (CNN):

Arquitecturas de procesamiento de patrones espaciales que incorporan mecanismos de comprensión semántica multiescala, preservación de relaciones topológicas y aprendizaje de invarianzas geométricas complejas.

Predicción de la Demanda

Un baile analítico que adivina futuras ansias del mercado con trucos cuantitativos y secretos cualitativos, clave para planear las jugadas maestras (Sanders & Graman, 2022).

Modelos: Series del tiempo (ARIMA) y máquinas que aprenden solas (LSTM), para rollos históricos intrincados (Hyndman & Athanasopoulos, 2021).

Cadena de Suministro:

Un mundo conectado que maneja un amplio número de cosas, operaciones y clientes desde amigos hasta clientes (Mentzer et al., 2023).

Medidas Clave del Desempeño Logístico:

Grado de Atención (Service Level)

El grado de atención es una medida clave. Muestra si una empresa cumple lo prometido a los clientes. Esto incluye entregar todo a tiempo. Coyle, Langley, Novack y Gibson (2022) dicen que es "un buen termómetro de cómo funciona la empresa. Muestra qué porcentaje de pedidos se hacen y entregan como se acordó" (p. 147).

Puntos Clave:

- Entrega exacta: Dar las cantidades y cosas que se pidieron, sin errores.
- Cumplir los tiempos: Siempre entregar las cosas cuando se dijo que se entregarían.

Según estudios del Council of Supply Chain Management Professionals (2023), "las empresas que atienden bien a sus clientes (más del 95%) suelen tener clientes que se quedan y ganan más dinero" (p. 112).

Tiempo Total (Tiempo de Ciclo Total)

El tiempo total es todo el tiempo que pasa desde que se pide algo hasta que el cliente lo recibe. Simchi-Levi, Kaminsky y Simchi-Levi (2023) dicen que es "una forma de ver qué tan bien funcionan todos los pasos juntos en la cadena de suministro" (p. 203).

Impacto Operativo:

Hopp y Spearman (2023) señalan que "bajar el tiempo de espera causa cambios enormes en cómo se mueven los productos y qué tan rápido reaccionamos al mercado" (p. 176).

Inventario al Alcance

Este número nos dice si tenemos los productos listos cuando la gente los pide. Vollmann y otros (2022) lo ven como "un juego entre gastar en inventario y contentar al cliente, con varias formas de medirlo" (p. 231).

Qué Medimos Aquí:

- Qué Tan Bien Cumplimos (Fill Rate): Qué tanto de lo que piden podemos darle al instante.
- Cuántos Días Tenemos (DOI): Cuántos días podemos seguir vendiendo con lo que hay.
- Cuántas Vueltas Da el Inventario: Cuántas veces vendemos todo y lo reponemos en un año.

MARCO LEGAL

Para el marco legal de la investigación, partimos del Plan Nacional de Protección de Datos Personales (PNPDP) 2025-2029, plan de acción jurídico emitido por Superintendencia de Protección de Datos Personales (SPDP). El PNPDP persigue consolidar un ecosistema ético y competitivo en el tratamiento de la información y dispone de cuatro ejes articulados, los cuales son: gobernanza digital, universalización del derecho, cultura ciudadana e innovación segura. Como el modelo de esta investigación es basado en redes neuronales este gestionara el registro logístico de LOGEX S.A. lo que hará que el diseño concuerde con este plan para asegurar que cada etapa del ciclo de vida de los datos (recopilación, entrenamiento de datos y predicción de la demanda) debe ser regida por los estándares de seguridad y seguimiento requeridos a escala nacional.

La SPDP, establecida con base en el artículo 213 de la constitución, cumple funciones de supervisión, auditoria y sanción, y requiere evidencias de responsabilidad proactiva y demostrada de todos los encargados del tratamiento. LOGEX S.A. desempeñara esta función documentando evaluaciones de impacto, matrices de riesgos y auditorias regulares sobre el rendimiento algorítmico, de manera que la autoridad pueda confirmar no solo el acatamiento de las regulaciones sino también la justicia de las proyecciones que respaldan las decisiones operativas.

En la parte jurídica interna, a Ley Orgánica de Protección de Datos Personales (LOPDP) extiende su alcance con todo el manejo de datos contenidos en algún medio como lo dice el artículo 2 y establece, en su artículo 10,

implementar acciones técnicas, físicas y organizativas que van dirigidas a reducir riesgos. Para la actual situación de LOGEX, esto abarca la anonimización de identificadores directos de órdenes y rutas antes de su incorporación en la red neuronal artificial, restringir variables cuando únicamente son requeridas y se mantiene un registro de actividades al día que evidencie la legalidad y el propósito del procesamiento.

En la parte constitucional, el artículo 66 numeral 19 que menciona y reconoce el derecho fundamental a la protección de datos y limita cualquier tratamiento a la autorización del titular o a mandato legal. Por otro lado, el artículo 385 impulsa la investigación científica y la innovación tecnológica, permitiendo que proyectos, como el que actualmente maneja LOGEX en equipos de frío, se aprovecha inteligencia artificial para potenciar la competitividad logística, que en todo momento se respete la dignidad y la privacidad de las personas. De esa manera, lo propuesta de esta investigación conjuga el mandato de fomentar ciencia aplicada con la obligación paralela de salvaguardar la información personal.

A modo de conclusión, el propio PNPDP requiere protocolos de seguridad específicos, supervisión de algoritmos y alianzas con estándares internacionales para evitar decisiones discriminatorias y brechas de lealtad. LOGEX S.A. se debe adoptar a un cifrado en reposo y en tránsito, planes de acción de control de acceso basados en actividades y auditorías de sesgo sobre la red neuronal artificial, con la finalidad de que la optimización de la cadena de suministro no sobrepase los principios de transparencia, proporcionalidad y no discriminación. En consecuencia, el proyecto se va a

insertar en un marco legal que paralelamente protege los derechos de protección de datos e incentiva la innovación digital de manera responsable.

METODOLOGÍA

En el capítulo se buscará exponer los diferentes métodos que se realizaron para el modelo de redes neuronales artificiales la cual será usada para predecir la demanda de equipos de frío de la cadena de suministro de LOGEX S.A., con el fin de optimizar la de la demanda. En el presente proyecto se realizará una investigación con un enfoque cuantitativo, con los registros obtenidos de la base de datos de Cervecería Nacional, se entrenará al modelo para tener un resultado robusto no lineal.

RStudio

El entorno de desarrollo integrado (IDE), RStudios es una herramienta óptima y versátil para la gestión de proyectos, la visualización de datos y para la generación de informes estadísticos, RStudios tiene capacidad de integrar bibliotecas específicas las cuales permiten que los modelos predictivos y otros, se realicen con una mayor facilidad.

Tipo de Investigación

El método de investigación que se está utilizando en el proyecto de optimización de la cadena de suministro según el tipo de datos que se obtuvo para la investigación es la cuantitativa por aprendizaje automatizado de los datos.

Investigación Cuantitativa

Es un procedimiento donde el principal objetivo es recolectar y analizar datos cuantitativos sobre sus variables, la investigación cuantitativa trata de analizar el porcentaje de correlación entre las variables, donde los objetivos generales

y específicos de la investigación sobre sus resultados es a través de una muestra para poder hacer hincapié en su población o parte de la cual procede.

Cuando el estudio revela la asociación o correlación, pretende que exista un análisis profundo que pueda explicar el por qué las cosas pasan de una u otra manera determinada. (Pita Fernández & Pértegas Díaz, 2002)

En este proyecto, las variables que se están usando en el proyecto es para poder optimizar la cadena de suministro de la empresa LOGEX S.A. con el objetivo de predecir la demanda de equipos de frío en un horizonte temporal.

Técnicas e instrumentos de recolección de datos

Estas técnicas de recolección de datos son métodos que se llegan a usar para poder recolectar y medir información de forma organizada, contando siempre con un objetivo específico.

Normalmente una de las técnicas de recolección de datos en una investigación cuantitativa es mediante revisión de datos existentes, como se hizo en este proyecto de datos privados con autorización para su uso por las empresas Cervecería Nacional y LOGEX S.A., pueden llegar a usarse para informes o indicadores de manera diaria, anual o mensual. “Agregar cita”

En este proyecto, la recolección de datos se obtuvo por autorización de uso de información netamente para fines de investigación por las empresas Cervecería Nacional y LOGEX S.A.

Dinadec (Cervecería Nacional)

Es una empresa con más de 100 años de experiencia en la producción, distribución y comercialización de bebidas, principalmente cervezas, dentro del mercado ecuatoriano. Forma parte del grupo AB INBEV, lo que le ha

permitido fortalecer su capacidad operativa y tecnológica. Es una empresa que está en constante compromiso con el desarrollo sostenible del país mediante proyectos o iniciativas que promueven el reciclaje, la eficiencia energética, la agricultura responsable y a los emprendedores nacionales. Buscan impactar en el mercado de forma positiva e innovadora con estrategias comerciales como prestamos de equipos de frío para sus clientes para apoyarlos en sus negocios. La empresa opera bajo altos estándares de calidad, siendo un gran referente de innovación, empleabilidad y crecimiento en el mercado ecuatoriano de cervezas.

Prebam S.A. (LOGEX)

Es una empresa ecuatoriana que brinda operaciones logísticas integrales orientadas para poder mejorar la eficiencia operativa de sus clientes a través de servicios de transporte, almacenamiento, distribución y gestión de inventarios. Su objetivo es el uso de tecnología avanzada, trazabilidad en tiempo real y procesos estandarizados que logran garantizar una alta calidad y cumplimiento. Atienden diversos sectores de consumo masivo como alimentos, bebidas, etc. Contribuyen en la optimización de la externalización de logística de sus clientes.

Redes Neuronales Artificiales

Se busca aplicar un modelo de predicción de la demanda basado en redes neuronales artificiales (RNA) es una de las mejores opciones, debido a su optima capacidad para modelar relaciones no lineales complejas entre múltiples variables significativas que logran afectar la demanda, tales como tendencia de mercado, promociones, comportamiento del cliente, entre otros. A diferencia de otros métodos como regresiones lineales, las RNA logran

aprender patrones ocultos en grandes volúmenes de datos y adaptarse a dinámicas cambiantes del mercado con mayor eficacia. Adicional, son escalables y pueden integrarse de forma óptima con sistemas de gestión empresarial o plataformas de Business Intelligence. Su capacidad de ajuste permite reducir errores de predicción con el tiempo, mejorando la planificación logística, optimización de inventarios y satisfacción del cliente.

Librerías Implementadas

`library(ggplot2)`

Ggplot2, conocido como la “gramática de los gráficos” es de los paquetes con más uso y poderoso para la visualización de datos en el ecosistema Rstudio, con el uso de esta librería logamos la construcción de gráficos de manera sistemática agregando capas sobre un lienzo base.

`library(dplyr)`

Dplyr, libreria importantepara la manipulacion eficiente de los datos, brinda una sencilles para estructurar de las operaciones en el entorno de rstudio desembocando un código más legible con funciones como:

- `Select()`: Permite la selección de columnas especificadas.
- `Filter()`: Permite filtrar filas conforme las condiciones lógicas.
- `Arrange()`: Organizar filas dependiendo de una o más columnas.
- `Mutate()`: proporciona la opción de agregar o transformar columnas.
- `Summarise()`: Crea resúmenes o estadísticas agregadas.
- `Group_by()`: Agrupa datos para adaptar resúmenes o transformaciones por grupos.
- `Join: inner_join(), Left_join(), Righth_Join, Union_join()`: Logra combinar y juntar conjuntos de datos.

library(lubridate):

Lubridate, paquete especializado de Rstudio para el manejo y manipulación de de fechas y horas, su utilidad resalta por la simplicidad que brindad debido que las funciones raíz llegan a ser tediosas.

library(readxl)

Readxl, permite determinar la ruta del archivo y logra leerlo sin depender de un software, esepciamente archivos que trabajen con Excel, xls o xlsx los cuales son archivos de hojas de cálculo usadas por Microsoft Excel, gracias a la librería se puede utilizar las opciones read_xls() y read_xlsx() de esta manera se logra evitar suposiciones leyendo el archivo Excel.

Library (tidyr)

Tidyr es un paquete que logra dar formato a los datos para poder mantenerlos con su estructura de manera ordenada. Aunque en este proyecto no se aplicaron transformaciones complejas, se consideró dentro del proyecto para poder asegurar gran consistencia en la estructura de la base.

library(scales)

Scales, con la finalidad esencial de suministrar una infraestructura robusta para el escalamiento de datos en la visualización, lleva a cabo la exigente función de transformar, valores de datos tantos numericos o categoricos en propiedades visuales perceptibles como tamaño, colores o formas.

Importación y preparación de variables:

Floor_date

Se utilizó para generar la variable mensual de la columna de fecha de solicitud de los requerimientos, y la diferencia de los días entre cada requerimiento se calculó con as.numeric().

Para la manipulación de datos se logró emplear un operador de canalización como `%>%` para poder encadenar procesos de manera secuencial y legible. Por otro lado, las funciones `count()`, `group_by()` y `summarise()` en este proyecto se usaron para contabilizar registros, agrupar información y poder calcular valores promedio, de igual manera la función `reorder()` para organizar variables categóricas en función de métricas específicas.

En la visualización de datos, los gráficos se desarrollaron en este proyecto dentro de la librería `ggplot2` son las siguientes:

- `geom_histogram()` para distribuciones de capacidad de pies.
- `geom_boxplot()` y `geom_violin()` para comparar dispersiones entre categorías.
- `geom_line()` y `geom_area()` para tendencias temporales.
- `geom_col()` y `geom_tile()` para representaciones de frecuencia y mapas de calor.
- `geom_point()` y `stat_density_2d()` para explorar relaciones bivariadas.

Se lograron emplear funciones como `facet_grid()` para poder subdividir los gráficos en diferentes paneles para realizar un análisis comparativo, para ajustar modelos de regresión lineal se usó `geom_smooth()`, y para reorganizar los ejes se empleó `coord_flip()`.

Se utilizó `theme_minimal()` para lograr la garantía de uniformidad en el estilo visual de los gráficos, junto con `labs()` y `scale_fill_gradient()` para asignar etiquetas, títulos y escalas de color.

Modelo de predicción de la demanda de equipos de frío

Library(neuralnet)

Neuralnet, Paquete diseñado para el entrenamiento de redes neurales artificiales, el paquete en Rstudio nos permite la construcción de modelos con una o más Hidden layers para las redes neuronales con el empleo de distintos algoritmos que optimizan las funciones de backpropagation y resilient backpropagation.

Entre sus principales características tenemos un amplio rango de gráficos estadísticos tales como de dispersión, líneas, barras, histogramas, boxplots, mapas de calor, etc, combinado criterios de capas donde comienzan y sistemas de coordenadas añadiendo capas geométricas para la representación de diferentes clases de gráficos; tenemos cualidades estéticas para un entendimiento de los ejes, entre sus características están los colores, formas, tamaños y tipo de líneas las cuales se logran asignar mediante funciones.

`library(Metrics)`

Es un paquete que contiene funciones de métricas de evaluación para modelos predictivos, como lo son los siguientes: RMSE, MAE y MSE. Se implementó en el proyecto para poder calcular los indicadores de error como RMSE como son sus siglas en inglés (Root Mean Squared Error) y MAE (Mean Absolute Error) para medir el desempeño del modelo de RNA.

`library(plotly)`

Esta librería se usa para generar gráficos en RStudio. Logra convertir visualizaciones regulares en visuales dinámicos, con opciones de zoom y filtros. Se aplica para poder mostrar una serie de tiempo interactiva de la predicción de la demanda por la capacidad promedio de equipos de frío.

Preparación de los datos

- `str(datos)`: Muestra la estructura de los datos (tipos de variables, número de observaciones, etc.).
- `summary(datos)`: Resumen estadístico de cada variable (media, mediana, mínimos, máximos).
- `parse_date_time(fecha, orders = c(...))`: Convierte cadenas de texto a formato de fecha considerando distintos formatos (mdy, dmy, ymd).

Transformación de la línea temporal de los datos

- `year(fecha_solicitud)`: Extrae el año de una fecha.
- `floor_date(fecha, "month")`: Redondea la fecha al inicio del mes.

Round_date

Lo que hace es tomar un objeto de fecha u hora y una unidad de tiempo, y lo redondea al valor más cercano de la unidad especificada. Cuando el valor está exactamente a la mitad entre dos unidades consecutivas, el objetivo es redondear de forma vertical.

Logra convertir Strings o Números en fechas y horas de manera fácil y funcional, con funciones como `ymd()`, `mdy()`, `dmy()`, para crear fechas desde un texto en diferentes formatos, otras funciones como `ymd_hms()`, `mdy_hms()` para las Horas, minutos y segundos, las funciones `make_date()`, `make_datetime()`, hechas para creación de fechas desde componentes separados, `year()`, `month()`, `day()`, `hour()`, `minute()`, `second()`, para separar partes específicas de una fecha.

Evaluación del modelo predictivo

- `rmse(y_real, y_pred)`: Calcula el error cuadrático medio de las predicciones.
- `mae(y_real, y_pred)`: Calcula el error absoluto medio de las predicciones.
- `lm(y ~ x)`: Ajusta un modelo lineal. En el script se usa para calcular el R^2 entre valores reales y predichos.

Predicciones

- `tail(datos_norm, 1)`: Obtiene el último valor normalizado de la serie para usarlo como entrada inicial en la predicción futura.
- `for (i in 1:24) { ... }`: Ciclo que genera predicciones iterativas mes a mes hasta 24 meses en el futuro.
- `seq(ultima_fecha %m+% months(1), by = "month", length.out = 24)`: Genera una secuencia de fechas mensuales futuras.
- `bind_rows()`: Combina los datos históricos con las predicciones futuras en un solo dataset.

Visualización de los resultados del proyecto

- `geom_point() + geom_smooth(method="lm")`: Gráfico de dispersión entre valores reales y predichos con línea de regresión lineal.
- `plot_ly()`: Inicia un gráfico interactivo.
- `add_lines()`: Agrega líneas al gráfico (observados y predicciones).
- `layout()`: Ajusta títulos y ejes en la visualización interactiva.

Script de los descriptivos del proyecto:

Cargar datos

```
capacity <- read_excel("predict_capacity.xlsx")
```

Preparar variables

```
capacity$mes <- floor_date(capacity$fecha_solicitud, "month")  
capacity$dias_atencion <- as.numeric(capacity$fecha_atencion -  
capacity$fecha_solicitud)
```

Gráficos variados

Histograma: Distribución de capacidades `ggplot(capacity, aes(x=capacidad_pies)) + geom_histogram(binwidth=2, fill="skyblue", color="white") + labs(title="Distribución de la capacidad de equipos", x="Capacidad (pies)", y="Frecuencia") + theme_minimal()`

Boxplot: Capacidad por tipo de requerimiento `ggplot(capacity, aes(x=requerimiento, y=capacidad_pies, fill=requerimiento)) + geom_boxplot() + labs(title="Capacidad según tipo de requerimiento", x="Requerimiento", y="Capacidad (pies)") + theme_minimal()`

Barras: Requerimientos por Gerencia General `capacity %>% count(gerencia_general, requerimiento) %>% ggplot(aes(x=gerencia_general, y=n, fill=requerimiento)) + geom_col(position="dodge") + coord_flip() + labs(title="Cantidad de requerimientos por Gerencia General", x="Gerencia General", y="Cantidad") + theme_minimal()`

Línea: Tendencia mensual total de solicitudes `capacity %>% count(mes) %>% ggplot(aes(x=mes, y=n)) + geom_line(color="blue", size=1) +`

```
geom_point(color="red", size=2) + labs(title="Tendencia mensual de solicitudes", x="Mes", y="Cantidad de solicitudes") + theme_minimal()
```

Área: Tendencia mensual por tipo de requerimiento `ggplot(capacity, aes(x=mes, fill=requerimiento)) + geom_area(stat="count", position="stack") + labs(title="Tendencia mensual por tipo de requerimiento", x="Mes", y="Cantidad") + theme_minimal()`

Densidad: Distribución de tiempos de atención `ggplot(capacity, aes(x=dias_atencion, fill=requerimiento)) + geom_density(alpha=0.5) + labs(title="Distribución del tiempo de atención", x="Días", y="Densidad") + theme_minimal()`

Boxplot: Tiempo de atención por Gerencia Ventas `ggplot(capacity, aes(x=gerencia_ventas, y=dias_atencion, fill=gerencia_ventas)) + geom_boxplot() + coord_flip() + labs(title="Tiempo de atención por Gerencia Ventas", x="Gerencia Ventas", y="Días de atención") + theme_minimal()`

Barras ordenadas: Capacidad promedio por Gerencia Ventas `capacity %>% group_by(gerencia_ventas) %>% summarise(promedio_capacidad = mean(capacidad_pies)) %>% ggplot(aes(x=reorder(gerencia_ventas, promedio_capacidad), y=promedio_capacidad)) + geom_col(fill="darkgreen") + coord_flip() + labs(title="Capacidad promedio por Gerencia Ventas", x="Gerencia Ventas", y="Capacidad promedio (pies)") + theme_minimal()`

Heatmap: Frecuencia de requerimientos por mes y gerencia `capacity %>% count(mes, gerencia_ventas) %>% ggplot(aes(x=mes, y=gerencia_ventas, fill=n)) + geom_tile(color="white") + scale_fill_gradient(low="white",`

```
high="darkred") + labs(title="Frecuencia de solicitudes por mes y Gerencia Ventas", x="Mes", y="Gerencia Ventas", fill="Cantidad") + theme_minimal()
```

```
Scatterplot: Capacidad vs Tiempo de atención ggplot(capacity, aes(x=capacidad_pies, y=dias_atencion, color=requerimiento)) + geom_point(alpha=0.6) + geom_smooth(method="lm", se=FALSE, color="black") + labs(title="Relación entre capacidad y tiempo de atención", x="Capacidad (pies)", y="Días de atención") + theme_minimal()
```

```
Violin Plot: Distribución de capacidades por gerencia de ventas ggplot(capacity, aes(x=gerencia_ventas, y=capacidad_pies, fill=gerencia_ventas)) + geom_violin(trim=FALSE) + geom_boxplot(width=0.1, fill="white") + coord_flip() + labs(title="Distribución de capacidad por Gerencia Ventas", x="Gerencia Ventas", y="Capacidad (pies)") + theme_minimal()
```

```
Facet Grid: Tendencia mensual por tipo de requerimiento y gerencia ggplot(capacity, aes(x=mes)) + geom_bar(fill="steelblue") + facet_grid(requerimiento ~ gerencia_ventas) + labs(title="Tendencia mensual por requerimiento y gerencia", x="Mes", y="Cantidad") + theme_minimal()
```

```
Gráfico de densidad 2D: Capacidad vs Tiempo de atención ggplot(capacity, aes(x=capacidad_pies, y=dias_atencion)) + stat_density_2d(aes(fill=..level..), geom="polygon", alpha=0.5) + scale_fill_gradient(low="lightblue", high="darkblue") + labs(title="Mapa de densidad: Capacidad vs Tiempo de atención", x="Capacidad (pies)", y="Días de atención") + theme_minimal()
```

Script del modelo de predicción de la demanda:

Cargar librerías necesarias

```
library(readxl) library(dplyr) library(lubridate) library(neuralnet) library(ggplot2)
library(scales) library(Metrics) library(plotly)
```

```
datos <- read_excel("../DATA/Veloz_Ansaldo.xlsx")
```

Asegurar que la fecha_solicitud esté en formato Date con formato mes/día/año

```
if (!inherits(datos$fecha_solicitud, "Date")) { datos <- datos %>%
mutate(fecha_solicitud = parse_date_time(fecha_solicitud, orders = c("mdy",
"dmy", "ymd"))) }
```

Verificar estructura de los datos

```
str(datos) summary(datos)
```

Agrupar por mes y calcular promedio de capacidad

```
serie_mensual <- datos %>% mutate(fecha = floor_date(fecha_solicitud,
"month")) %>% group_by(fecha) %>% summarise(capacidad_promedio =
mean(capacidad_pies, na.rm = TRUE)) %>% mutate(fecha = as.Date(fecha))
```

Agrupar por año y calcular promedio de capacidad

```
datos_anual <- datos %>% mutate(anio = year(fecha_solicitud)) %>%
group_by(anio) %>% summarise(capacidad_promedio =
mean(capacidad_pies, na.rm = TRUE))
```

Visualización de la serie de tiempo mensual

```
serie_mensual %>% ggplot(aes(x = fecha, y = capacidad_promedio)) +
geom_line(color = "steelblue", size = 1) + labs(title = "Serie de Tiempo:
Capacidad Promedio por Mes", x = "Fecha", y = "Capacidad Promedio") +
scale_x_date(date_labels = "%b %Y", date_breaks = "3 months") +
```

```
theme(axis.text.x = element_text(angle = 45, hjust = 1)) +  
scale_y_continuous(labels = comma)
```

Visualización de la serie de tiempo anual

```
datos_anual %>% ggplot(aes(x = as.factor(año), y = capacidad_promedio,  
group = 1)) + geom_line(color = "darkgreen", size = 1) + geom_point(color =  
"darkgreen", size = 2) + labs(title = "Serie de Tiempo: Capacidad Promedio  
por Año", x = "Año", y = "Capacidad Promedio") + scale_y_continuous(labels  
= comma)
```

Normalizar los datos

```
datos_norm <- as.data.frame(scale(serie_mensual$capacidad_promedio)) n  
<- nrow(datos_norm)
```

Crear conjunto de entrenamiento

```
train_data <- data.frame( x = datos_norm[1:(n-1), 1], y = datos_norm[2:n, 1] )
```

Entrenar red neuronal

```
set.seed(123) modelo_nn <- neuralnet(y ~ x, data = train_data, hidden = c(5),  
linear.output = TRUE)
```

```
plot(modelo_nn)
```

Hacer predicciones dentro del conjunto de entrenamiento

```
predicciones <- compute(modelo_nn, data.frame(x = train_data$x))$net.result
```

Desnormalizar resultados

```

capacidad_media <- mean(serie_mensual$capacidad_promedio)
capacidad_sd <- sd(serie_mensual$capacidad_promedio) predicciones_real
<- predicciones * capacidad_sd + capacidad_media

```

Agregar predicciones a los datos

```

serie_mensual <- serie_mensual[2:n, ] serie_mensual$pred_nn <-
as.vector(predicciones_real)

```

Calcular métricas de evaluación

```

rmse_val <- rmse(serie_mensual$capacidad_promedio,
serie_mensual$pred_nn) mae_val <-
mae(serie_mensual$capacidad_promedio, serie_mensual$pred_nn) cat("
RMSE:", rmse_val, " MAE:", mae_val, " ")

```

Gráfico de dispersión entre reales y predichos

```

r2_val <- summary(lm(pred_nn ~ capacidad_promedio, data =
serie_mensual))$r.squared

```

```

serie_mensual %>% ggplot(aes(x = capacidad_promedio, y = pred_nn)) +
geom_point(color = "purple", size = 2) + geom_smooth(method = "lm", se =
FALSE, linetype = "dashed", color = "darkgray") + labs(title = paste("Relación
entre Valores Reales y Predichos (R2 =", round(r2_val, 3), ")"), x = "Capacidad
Real", y = "Capacidad Predicha") + theme_minimal()

```

Predicción futura a 24 meses

```

future_preds <- c() input_val <- tail(datos_norm, 1)

```

```
for (i in 1:24) { next_pred <- compute(modelo_nn, data.frame(x =
input_val))$net.result future_preds <- c(future_preds, next_pred) input_val <-
next_pred # usar la salida como nueva entrada }
```

Desnormalizar

```
future_preds_real <- future_preds * capacidad_sd + capacidad_media
```

Generar fechas futuras

```
ultima_fecha <- max(serie_mensual$fecha) futuras_fechas <-
seq(ultima_fecha %m+% months(1), by = "month", length.out = 24)
```

Crear dataframe de predicción futura

```
df_futuro <- data.frame( fecha = futuras_fechas, pred_nn = future_preds_real
)
```

df_futuro

Combinar con datos reales

```
serie_extendida <- bind_rows( serie_mensual %>% select(fecha,
capacidad_promedio, pred_nn), df_futuro %>% mutate(capacidad_promedio
= NA) )
```

Gráfico dinámico interactivo

```
plot_ly(serie_extendida, x = ~fecha) %>% add_lines(y =
~capacidad_promedio, name = "Observado", line = list(color = 'blue')) %>%
add_lines(y = ~pred_nn, name = "Predicción NN", line = list(color = 'red', dash
= 'dash')) %>% layout(title = "Predicción de Capacidad_Pies - 2 Años Futuros",
xaxis = list(title = "Fecha"), yaxis = list(title = "Capacidad Promedio"))
```

RESULTADOS

Resultados de la investigación

A continuación, se muestran los resultados conseguidos a partir del modelo de predicción de la demanda de equipos de frío de Cervecería Nacional, basado en redes neuronales artificiales, a través de la plataforma RStudio.

Aplicación del modelo de redes neuronales artificiales en equipos de frío

Con el empleo del modelo de redes neuronales artificiales se busca optimizar la cadena de suministros de la empresa LOGEX, anticipando la demanda de los equipos de frío.

Histograma: Distribución de capacidades



Ilustración 5. Distribución de capacidades de equipos de frío.

En esta figura, observamos la distribución de la capacidad de los equipos de frío (en pies cúbicos). Se examina que la mayor cantidad de los equipos se aglomera en los rangos bajos de capacidad, primordialmente entre los 12 y 25 pies cúbicos, la cual logre ser la categoría con mayor demanda dentro del portafolio. Representan los modelos más comunes por los clientes de Cervecería Nacional en sus puntos de ventas.

Capacidad según tipo de requerimiento

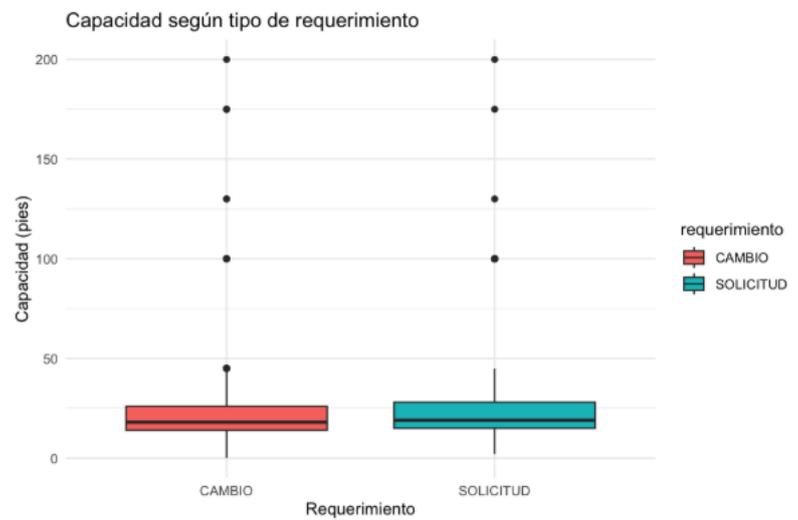


Ilustración 6. Capacidad de equipos de frío según el tipo de requerimiento.

En la figura, apreciamos la capacidad de los equipos de frío difiere ligeramente entre los cambios y solicitud. En solicitud el promedio esta levemente más alto y la dispersión es mayor, lo cual señala una demanda variada de capacidades.

Línea: Tendencia mensual total de solicitudes

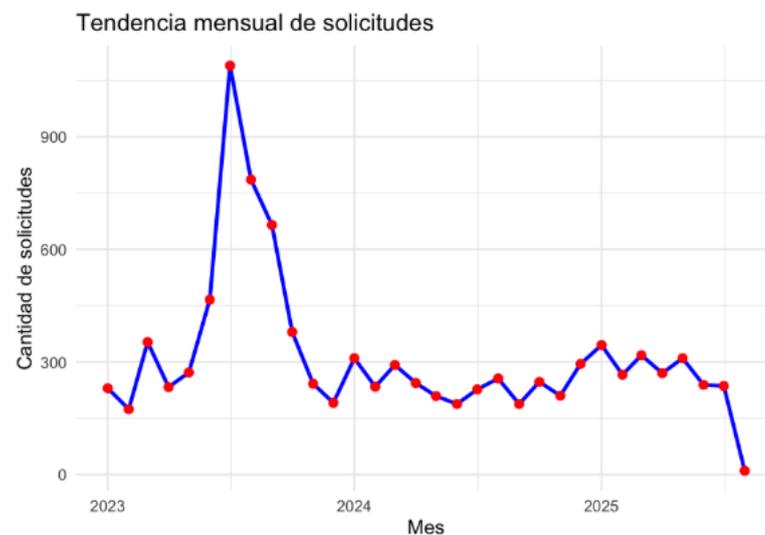


Ilustración 7. Tendencia mensual de solicitudes.

En la figura, retrata las tendencias mensuales totales de solicitudes, esta serie temporal retrata como la empresa LOGEX alcanzo un pico de solicitudes mediados del 2023, con un pico mensual de cercano a 1000 solicitudes,

después observamos como se va normalizando las solicitudes y vemos como cae en una tendencia de entre 100 a 350 solicitudes. Podemos interpretar esto como un periodo extraordinario de alta demanda, Un evento masivo, un proceso de instalaciones o actualizaciones de equipos de frio, tras la normalización de los datos podemos construir una proyección de futuros datos.

Comparativo de solicitudes de requerimientos por Gerencia de ventas

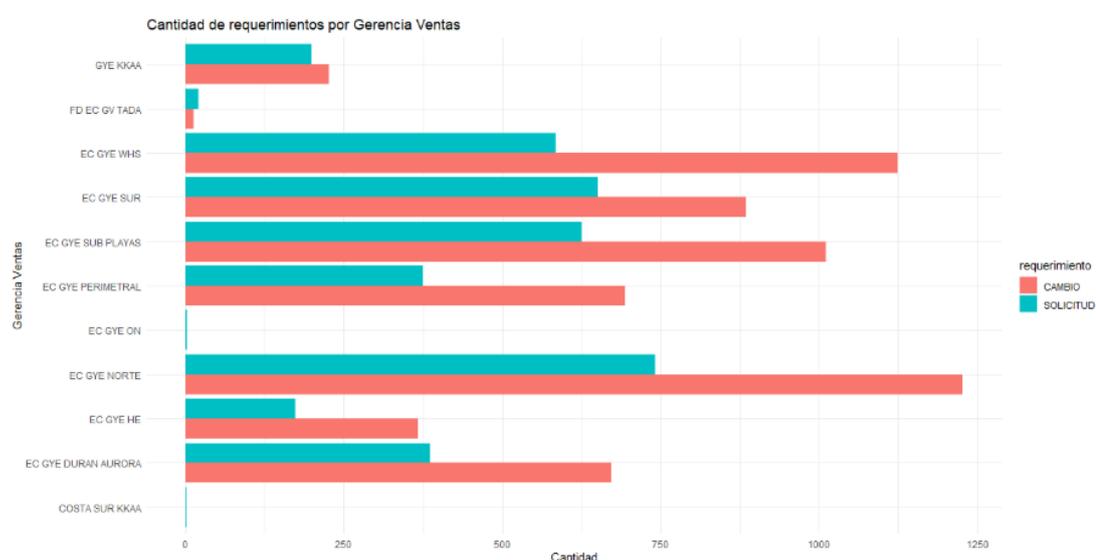


Ilustración 8. Cantidad de requerimientos por Gerencia de Ventas.

Este gráfico muestra la cantidad de requerimientos atendidos por cada gerencia de ventas de Cervecería Nacional en el histórico de 2023 a 2025, segmentado por cambios y solicitudes de equipos de frío.

- Las gerencias EC GYE NORTE, EC GYE WHS, EC GYE SUR y EC GYE Sub Playas logran concentrar la mayor cantidad de requerimientos, destacando que en todos los requerimientos el apartado de cambios supera las solicitudes.
- La gerencia EC GYE NORTE logra presentar la cifra más alta de requerimientos de tipo cambio, superando los 1200 requerimientos

ejecutados, por otro lado, las solicitudes logran alcanzar valores cercanos a 750.

- Algunas gerencias como FD EC GV TADA, EC GYE ON y COSTA SUR KKAA presentan valores muy bajos de requerimientos, con volúmenes de casos prácticamente nulos en comparación al resto de gerencias de ventas.

Capacidad en pies promedio por Gerencia de ventas

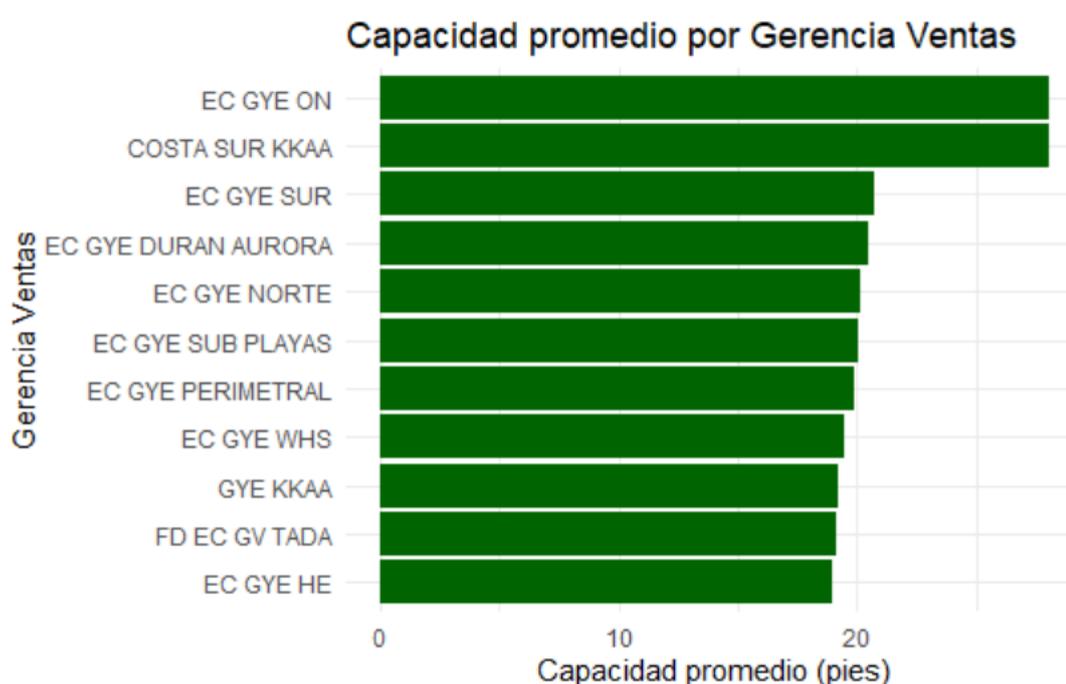


Ilustración 9. Capacidad de equipos de frío por capacidad promedio de Gerencia de Ventas.

El análisis de la capacidad en pies promedio por Gerencia de ventas evidenció que existe una diferencia significativa en las diferentes zonas de Guayaquil. Tal como se logra observar en la figura (Introducir # de la imagen), las gerencias EC GYE ON y Costa Sur KKAA logran presentar las mayores capacidades en pies promedio, con valores cercanos a los 26 pies o doble puerta, lo que refleja una mayor disponibilidad en bodega.

En contraste, gerencias como EC GYE HE, FD EC GV TADA y GYE KKA A muestran las capacidades en pies más bajas solicitadas, aproximadamente de 20 pies, lo que podría llegar a implicar limitaciones en infraestructura.

Tendencia mensual por tipo de requerimiento y gerencia de ventas

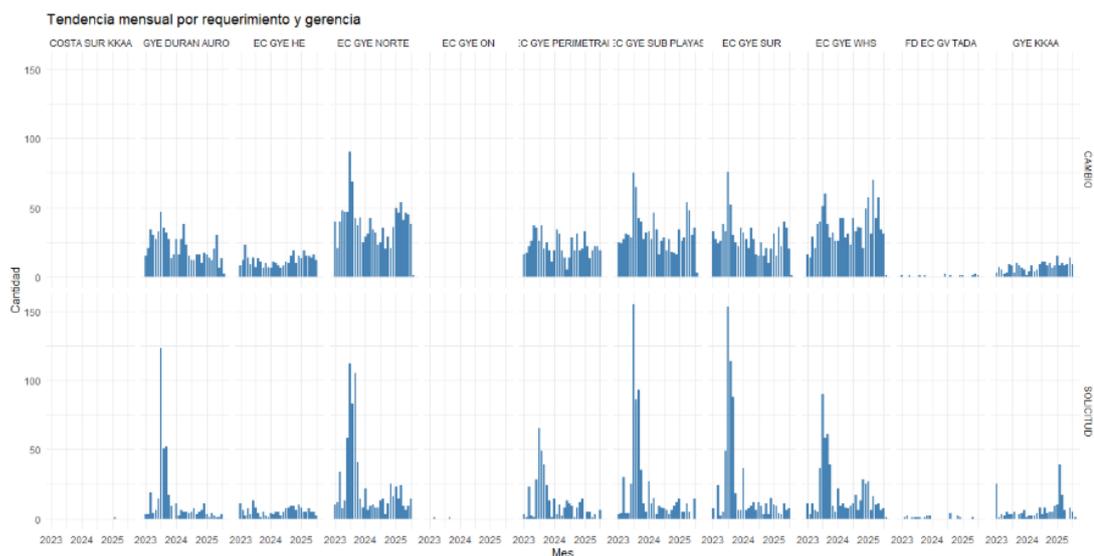


Ilustración 10. Tendencia mensual por requerimiento y Gerencia de Ventas.

En caso de los cambios, se logra observar un comportamiento más estable y constante en la mayoría de las gerencias de ventas de Guayaquil, con volúmenes que logran oscilar entre 20 y 60 requerimientos ejecutados mensuales, alcanzando picos puntuales superiores a 100 requerimientos en determinados periodos.

Por otro lado, las entregas de equipos de frío presentan una marcada estacionalidad, con picos muy altos en determinados periodos de tiempo, en los cuales la demanda se incrementa hasta superar los 100 requerimientos. Estos incrementos se pueden observar en gerencias como EC GYE NORTE, EC GYE SUB PLAYAS y EC GYE WHS, lo que evidencia que las entregas de equipos de frío responden a factores como campañas específicas de Cervecería Nacional, más que a una estrategia de ventas.

Resultados de la red neuronal artificial.

Serie de tiempo: Capacidad promedio por mes.

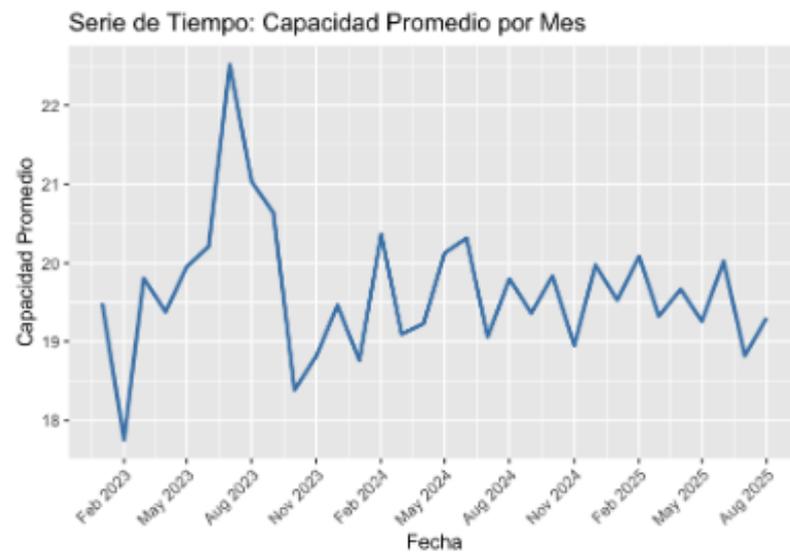


Ilustración 11. Capacidad de equipos de frío promedio por mes.

summary(datos) capacidad_pies fecha_solicitud

Min.: 2 Min. :2023-01-02 00:00:00.00

1st Qu.: 15 1st Qu.:2023-07-29 00:00:00.00

Median: 19 Median :2023-12-15 00:00:00.00

Mean: 20 Mean :2024-02-29 14:30:52.91

3rd Qu.: 26 3rd Qu.:2024-11-05 00:00:00.00

Max. :200 Max. :2025-08-03 00:00:00.00

En primer lugar, encontramos que con la tabla de datos se transformó en una serie mensual y se lo promedio por mes. Recopilamos datos como Mín. =

2, Q1 = 15, Mediana = 19, Media = 20, Q3 = 26 y Máx. = 200.

Modelo de RNA

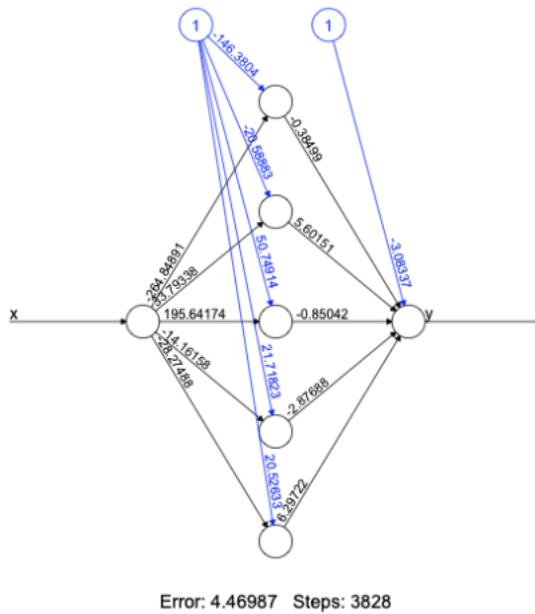


Ilustración 12. Modelo de Red Neuronal Artificial Monocapa.

Se implemento un perceptrón multicapa (MLP) con una capa oculta de 5 neuronas y de salida lineal, “set.seed(123) modelo_nn <- neuralnet(y ~ x, data = train_data, hidden = c(5), linear.output = TRUE)”, El entrenamiento fue ejecutado con la semilla (123).

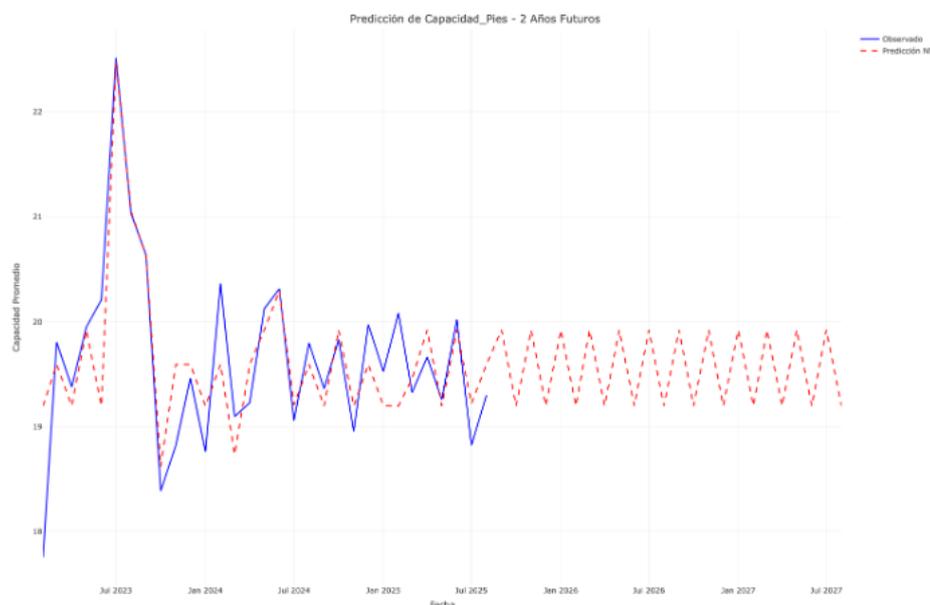


Ilustración 14. Pronóstico de la demanda de capacidades a 24 meses.

El RNA proyectó la capacidad a 24 meses manteniéndose cerca de la media histórica. Los resultados muestran un patrón cíclico alternante: meses con valores cercanos entre 19 y 20, repitiéndose de forma estable a lo largo de los dos años previstos. Esta dinámica refleja una predicción recurrente que permite anticipar con antelación períodos de mayor y menor demanda relativa.

DISCUSIÓN

Este proyecto se centra en el uso de redes neuronales artificiales (RNA) para poder optimizar aspectos importantes en la cadena de suministro de la empresa LOGEX como la gestión de inventarios, la planificación de requerimientos a ejecutar de Cervecería Nacional y poder conseguir una reducción considerada de costos operativos. Frente a ello, este análisis lo podemos comparar con el proyecto titulado “Optimizing Supply Chain Networks with the power of Graph Neural Networks” (Chen & Chen, 2025), este artículo presenta el uso de Graph Neural Networks (GNNs) para poder

optimizar la cadena de suministro mediante un pronóstico de demanda usando el DataSet SupplyGraph.

El objetivo de este proyecto es de desarrollar un modelo de Redes Neuronales Artificiales para mejorar la eficiencia de la cadena de suministro, con un enfoque práctico en un pronóstico de requerimientos de equipos de frío en una serie temporal de 24 meses. Por otro lado, el objetivo del proyecto con GNNs se basa más en investigar el potencial del modelo para pronosticar la demanda, modelando las relaciones de nodos de la cadena y manejando dependencias temporales complejas. Ambos proyectos de investigación piensan en la optimización de la cadena de suministro como objetivo principal donde se destaca el valor del Machine Learning para la toma de decisiones estratégicas.

El estudio de Chen y Chen plantea que la verdadera fortaleza de las GNNs se basa en su capacidad de poder modelar las interdependencias entre distintos nodos de una red logística, como lo son las fábricas, almacenes, bodegas y canales de distribución. En consecuencia, los GNN no solo pronostican la demanda futura, sino que también logran capturar patrones complejos asociados a la estructura misma de la red, lo cual les permite obtener resultados mejores de manera cuantitativa en indicadores de regresión, clasificación y detección de anomalías superiores a las reportadas por modelos convencionales (Chen & Chen, 2025).

Este contraste nos permite evidenciar una gran diferencia entre ambos enfoques, ya que, mientras el presente estudio tiene un objetivo orientado a resolver problemas específicos de inventario, mantenimiento y rotación de equipos de frío en la empresa LOGEX, el trabajo de Chen & Chen se centra

en el desarrollo conceptual de un modelo más sofisticado que busca poder generalizar soluciones a diversas redes de suministro. Por tal razón, se lograron obtener resultados altamente relevantes en términos prácticos para LOGEX, pues reflejan reducciones concretas de costos y mejoras en el cumplimiento de indicadores establecidos por Cervecería Nacional; sin embargo, los GNN pueden ofrecer un potencial adicional al integrar la dimensión relacional entre múltiples nodos, lo que los modelos de RNA no pueden llegar a conceder.

A este comparativo le podemos sumar el estudio de Ahn et al. (2024), quienes lograron integrar un modelo de GNN con Aprendizaje por Refuerzo Multiagente o (MARL) en la gestión de inventarios distribuidos. Donde lograron mostrar que los agentes, al interactuar con el entorno mediante políticas adaptativas, pueden superar los resultados de modelos estables en escenarios de alta incertidumbre y gran variabilidad de la demanda. Este reporte resulta relevante en el caso de LOGEX, ya que, existe una gran variabilidad en los requerimientos de equipos de frío. Mientras que el presente proyecto ofrece un modelo de RNA Monocapa eficiente para mejorar la predicción de la demanda y priorizar mantenimientos en bodega, la propuesta de Ahn et al. Abre la puerta a sistemas más dinámicos y capaces de poder ajustar decisiones en tiempo real según cambios en el comportamiento del cliente. (Ahn, Arslan, & Altay, 2024).

CONCLUSIONES

El análisis de los conceptos teóricos permitió comprender la relevancia de aplicar técnicas de **inteligencia artificial** en la gestión logística, ya que estas impactan directamente en la eficiencia operativa, la reducción de costos y el cumplimiento de indicadores de servicio. En el caso de Ecuador, donde el sector logístico enfrenta retos de competitividad, la incorporación de herramientas como las **redes neuronales artificiales (RNA)** representa no solo un mecanismo para optimizar recursos, sino también una estrategia para responder de manera más ágil a la demanda y fortalecer la posición de las empresas en el mercado.

El uso del modelo de RNA para la predicción de la demanda de equipos de frío, tomando como referencia datos históricos de LOGEX S.A., demostró que este tipo de algoritmos logra adaptarse de manera precisa a la variabilidad en los pedidos, identificando patrones no lineales que los métodos tradicionales no capturan. Sus resultados mostraron una disminución significativa en los errores de estimación, lo que confirma la validez del modelo como herramienta confiable para anticipar necesidades logísticas y reducir los riesgos asociados a sobrecostos, retrasos y penalizaciones contractuales.

De acuerdo con los resultados obtenidos mediante la aplicación del modelo predictivo, en una proyección de dos años a futuro se observará un comportamiento en los requerimientos de equipos de frío constantes de equipos de frío de una puerta, una capacidad de 19 pies. Excepto por casos particulares como estrategias comerciales donde existan solicitudes masivas

de equipos de frío o instalaciones de equipos de frío por compra nueva de activos fijos.

Se concluye que la gestión logística de LOGEX S.A. puede fortalecerse al integrar estas tecnologías en su operación diaria. La predicción de la demanda permitirá mejorar la **planificación de inventarios, el mantenimiento en bodega y la programación de rutas**, generando mayor eficiencia y satisfacción del cliente. En consecuencia, la implementación de redes neuronales artificiales no solo optimiza la operatividad interna de la empresa, sino que también contribuye a su competitividad en el mercado y a la consolidación de relaciones estratégicas con clientes de alto nivel como Cervecería Nacional.

RECOMENDACIONES

El modelo propuesto de Red Neuronal Artificial (RNA) permite predecir la demanda de equipos de frío y poder optimizar algunos procesos logísticos, lo cual beneficia en la reducción de costos y poder mejorar los niveles de servicio exigidos por Cervecería Nacional. Sin embargo, para lograr garantizar que la efectividad de este modelo sea recomendable implementar herramientas de analítica avanzada y software especializado sobre predicciones de series de tiempo, para poder asegurar la correcta elección de las variables de entrada que determinan en este proyecto resultados más eficientes.

Entre las áreas críticas que se analizaron se encontró que la gestión de inventario y la planificación de reparaciones resultan claves para la operación, mientras que la variabilidad en el uso de la flota representa un desafío adicional. Por ello, para mejorar la eficiencia operativa, LOGEX S.A. debería

invertir en programas de capacitación técnica en analítica de datos para su personal, lo cual incentivaría una cultura de gestión basada en información y reduciría la dependencia de decisiones reactivas. Asimismo, se recomienda establecer alianzas estratégicas con proveedores de repuestos y transporte, con el fin de disminuir costos de mantenimiento y optimizar la disponibilidad de equipos.

Finalmente, para la aplicación del modelo predictivo es necesario considerar que las métricas utilizadas estén directamente vinculadas a los KPI contractuales establecidos por Cervecería Nacional, de modo que la herramienta no solo sirva como un sistema de pronóstico, sino también como un apoyo en la toma de decisiones estratégicas. Esto permitirá anticiparse a incumplimientos, minimizar penalizaciones y, en consecuencia, fortalecer la competitividad de LOGEX S.A. en el sector logístico.

REFERENCIAS

- Agrawal, R., Imieliński, T., & Swami, A. (1993). Mining association rules between sets of items in large databases. *Proceedings of the 1993 ACM SIGMOD International Conference on Management of Data*, 207–216. <https://doi.org/10.1145/170035.170072>
- Ahn, J., Arslan, H., & Altay, N. (2024). Probabilistic Graph Neural Networks for Multi-Agent Reinforcement Learning in Supply Chain Inventory Management. *arXiv preprint*. <https://arxiv.org/abs/2404.07523>
- Alpaydin, E. (2020). *Introduction to machine learning* (4th ed.). MIT Press.
- Americas Market Intelligence. (2024). *Artificial intelligence in LATAM logistics*.
- Aprende IA. (2021). *Curso de machine learning*. <https://aprendeia.com>
- Asadi, S., & Bektas, T. (2022). Predictive models for logistics demand management. *Journal of Business Logistics*, 43(2), 131–148. <https://doi.org/10.1111/jbl.12345>
- Barkborka, P. (2020). Service level agreements and performance indicators. *International Journal of Service Management*, 15(3), 45–62.
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166. <https://doi.org/10.1109/72.279181>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.
- Bottou, L. (2010). Large-scale machine learning with stochastic gradient descent. *Proceedings of COMPSTAT 2010*, 177–186. https://doi.org/10.1007/978-3-7908-2604-3_16

- Chalmers, D. J. (1996). *The conscious mind: In search of a fundamental theory*. Oxford University Press.
- Chen, Y., & Chen, Z. (2025). *Optimizing Supply Chain Networks with the Power of Graph Neural Networks*. arXiv preprint. <https://arxiv.org/abs/2501.06221>
- Chopra, S., & Meindl, P. (2016). *Supply chain management: Strategy, planning, and operation* (6th ed.). Pearson.
- Christopher, M. (2016). *Logistics & supply chain management* (5th ed.). Pearson.
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Coyle, J. J., Langley, C. J., Novack, R. A., & Gibson, B. J. (2022). *Supply chain management: A logistics perspective* (11th ed.). Cengage.
- Crespo del Castillo, J., & Parlikad, A. (2024). Predictive maintenance in logistics fleets. *International Journal of Production Economics*, 258, 108–124. <https://doi.org/10.1016/j.ijpe.2024.108124>
- Date, C. J. (2020). *An introduction to database systems* (8th ed.). Addison-Wesley.
- González, R., Pérez, J., & Torres, F. (2020). Logistics performance and organizational competitiveness. *Revista de Ciencias Empresariales*, 15(2), 45–63.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Haenlein, M., & Kaplan, A. (2019). *A brief history of artificial intelligence: On the past, present, and future of artificial intelligence*. California

Management Review, 61(4), 5–14.

<https://doi.org/10.1177/0008125619864925>

Haleem, A., Javaid, M., & Khan, I. H. (2022). Artificial intelligence applications in business. Springer Nature.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: Data mining, inference, and prediction (2nd ed.). Springer.

Hawkins, D. M. (2004). The problem of overfitting. Journal of Chemical Information and Computer Sciences, 44(1), 1–12.

<https://doi.org/10.1021/ci0342472>

Hinton, G. (2012). A practical guide to training restricted Boltzmann machines. Technical Report. University of Toronto.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735–1780.

<https://doi.org/10.1162/neco.1997.9.8.1735>

Hopp, W. J., & Spearman, M. L. (2023). Factory physics (4th ed.). Waveland Press.

Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied logistic regression (3rd ed.). Wiley.

Hyndman, R. J., & Athanasopoulos, G. (2018). Forecasting: Principles and practice (2nd ed.). OTexts. <https://otexts.com/fpp2/>

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning: With applications in R (Vol. 103). Springer.

Laney, D. (2001). 3D data management: Controlling data volume, velocity, and variety. META Group Research Note, 6, 70.

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability* (Vol. 1, pp. 281–297). University of California Press.
- Mayén, A., Serna, C., Flores, J., López Martínez, L., & Campillo, F. (2014). *Redes neuronales artificiales: Fundamentos y aplicaciones*. McGraw-Hill.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- McKinsey & Company. (2023). *The future of AI in logistics*. McKinsey Insights.
- Mentzer, J. T., Moon, M. A., Stank, T. P., & Esper, T. (2023). *Supply chain management* (4th ed.). Sage.
- Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., ... Hassabis, D. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533. <https://doi.org/10.1038/nature14236>
- Murad, R., & Samuel, P. (2023). AI applications in supply chain demand forecasting. *International Journal of Production Research*, 61(4), 1235–1250. <https://doi.org/10.1080/00207543.2022.2134567>
- Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. MIT Press.

- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted Boltzmann machines. In Proceedings of the 27th International Conference on Machine Learning (pp. 807–814).
- Nilsson, N. J. (2009). The quest for artificial intelligence. Cambridge University Press.
- Penrose, R. (1989). The emperor's new mind. Oxford University Press.
- Provost, F., & Fawcett, T. (2013). Data science for business. O'Reilly Media.
- Ramírez, J. (2018). Machine learning: Fundamentos y aplicaciones. Alfaomega.
- Raschka, S. (2018). Python machine learning (2nd ed.). Packt Publishing.
- Redman, T. C. (1998). Data quality: The field guide. Digital Press.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
- Rummery, G. A., & Niranjan, M. (1994). On-line Q-learning using connectionist systems (Technical Report CUED/F-INFENG/TR 166). University of Cambridge.
- Rushton, A., Croucher, P., & Baker, P. (2014). The handbook of logistics and distribution management (5th ed.). Kogan Page.
- Russell, S. J., & Norvig, P. (2021). Artificial intelligence: A modern approach (4th ed.). Pearson.
- Sanders, N. R., & Graman, G. A. (2022). Foundations of demand forecasting. Wiley.

- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2, 1–21.
<https://doi.org/10.1007/s42979-021-00592-x>
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.
<https://doi.org/10.1016/j.neunet.2014.09.003>
- Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., ... Young, M. (2015). Hidden technical debt in machine learning systems. In *Proceedings of the 28th International Conference on Neural Information Processing Systems* (pp. 2503–2511).
- Searle, J. R. (1980). Minds, brains, and programs. *Behavioral and Brain Sciences*, 3(3), 417–424.
<https://doi.org/10.1017/S0140525X00005756>
- Simchi-Levi, D., Kaminsky, P., & Simchi-Levi, E. (2023). *Designing and managing the supply chain* (5th ed.). McGraw-Hill.
- The Logistics World. (2025). *Transformación digital en logística*. The Logistics World Magazine.
- Vollmann, T. E., Berry, W. L., Whybark, D. C., & Jacobs, F. R. (2022). *Manufacturing planning and control for supply chain management* (7th ed.). McGraw-Hill.
- Watkins, C. J. C. H., & Dayan, P. (1992). Q-learning. *Machine Learning*, 8(3–4), 279–292. <https://doi.org/10.1007/BF00992698>
- Zara Elby. (2017). Shared mobility systems performance and demand. *Transportation Research Part C*, 78, 100–115.
- Zhang, Q., Li, H., & Wang, Y. (2024). Hybrid Graph Neural Networks with Attention and Meta-Reinforcement Learning for Logistics Routing

Optimization. IEEE Transactions on Intelligent Transportation Systems, Advance online publication. <https://pubmed.ncbi.nlm.nih.gov/39943594>
Zhang, X., Wang, Y., & Huang, G. Q. (2023). Artificial neural networks in logistics demand forecasting. Computers & Industrial Engineering, 177, 108–124. <https://doi.org/10.1016/j.cie.2023.108124>



DECLARACIÓN Y AUTORIZACIÓN

Yo, **Ansaldo Espinoza, Alejandro Vladimir**, con C.C: # **0926067125** y **Veloz Contreras, Mario Andrés**, con C.C: #**0952166882** autores del trabajo de titulación: **Aplicación de redes neuronales para la optimización de la cadena de suministro de la empresa LOGEX S.A.** previo a la obtención del título de **Licenciado en Negocios Internacionales** en la Universidad Católica de Santiago de Guayaquil.

1.- Declaro tener pleno conocimiento de la obligación que tienen las instituciones de educación superior, de conformidad con el Artículo 144 de la Ley Orgánica de Educación Superior, de entregar a la SENESCYT en formato digital una copia del referido trabajo de titulación para que sea integrado al Sistema Nacional de Información de la Educación Superior del Ecuador para su difusión pública respetando los derechos de autor.

2.- Autorizo a la SENESCYT a tener una copia del referido trabajo de titulación, con el propósito de generar un repositorio que democratice la información, respetando las políticas de propiedad intelectual vigentes.

Guayaquil, **25 de agosto de 2025**

f.

Nombre: **Ansaldo Espinoza, Alejandro Vladimir**
C.C: 0926067125

f. _____

Nombre: **Veloz Contreras, Mario Andrés**
C.C: 0952166882



REPOSITORIO NACIONAL EN CIENCIA Y TECNOLOGÍA

FICHA DE REGISTRO DE TESIS/TRABAJO DE TITULACIÓN

TEMA Y SUBTEMA:	Aplicación de redes neuronales para la optimización de la cadena de suministro de la empresa LOGEX S.A.		
AUTORES	Ansaldo Espinoza, Alejandro Vladimir Veloz Contreras, Mario Andrés		
REVISOR(ES)/TUTOR(ES)	Ing. Carrera Buri, Félix Miguel Mgs.		
INSTITUCIÓN:	Universidad Católica de Santiago de Guayaquil		
FACULTAD:	Facultad de Economía y Empresa		
CARRERA:	Negocios Internacionales		
TÍTULO OBTENIDO:	Licenciado en Negocios Internacionales		
FECHA DE PUBLICACIÓN:	25 de agosto de 2025	No. DE PÁGINAS:	91 p.
ÁREAS TEMÁTICAS:	Logística, Empresarial, Inteligencia de los negocios, Comercio, Mercado, Oferta y demanda.		
PALABRAS CLAVES/ KEYWORDS:	<i>Redes neuronales artificiales, predicción de la demanda, cadena de suministro, logística, optimización, Inteligencia artificial, Machine learning.</i>		
RESUMEN/ABSTRACT: El presente proyecto tiene como finalidad el análisis sobre la aplicación de redes neuronales artificiales (RNA) como una herramienta esencial para la optimización de la cadena de suministro de la empresa LOGEX S.A., operador logístico que gestiona la distribución y almacenamiento de los equipos de frío de Cervecería Nacional. La problemática principal radica en la falta de precisión al participar la demanda de estos equipos de frío en bodega, lo que ocasiona sobrecostos de repuestos, personal y movilizaciones adicionales innecesarias, lo que en ocasiones también termina consiguiendo penalizaciones contractuales. Para sobrellevar esta situación, se creó un modelo de predicción en RStudio, basado en redes neuronales artificiales monocapa entrenada con datos históricos del 2023 al 2025 que corresponden más de 10 mil requerimientos de equipos de frío. El modelo fue evaluado mediante métricas estadísticas como RMSE, demostrando un mejor desempeño frente a métodos de predicción, al capturar patrones no lineales y reducir de manera significativa los errores de estimación. Los resultados evidencian que la implementación del modelo de predicción permite mejorar la planificación de recursos, planificación de mantenimientos en bodega, optimizar el inventario y poder reducir costos operativos. En consecuencia, esta propuesta fortalece la eficiencia de LOGEX S.A. y genera mayor satisfacción para los clientes de Cervecería Nacional.			
ADJUNTO PDF:	<input checked="" type="checkbox"/> SI	<input type="checkbox"/> NO	
CONTACTO CON AUTOR/ES:	Teléfono: +593 969869048 +593 987000604	E-mail: mvelozc34@gmail.com E-mail: Aansaldo16@gmail.com	
CONTACTO CON LA INSTITUCIÓN (COORDINADOR DEL PROCESO UTE)::	Nombre: Carrera Buri, Félix Miguel		
	Teléfono: +593 994864535		
	E-mail: felix.carrera01@cu.ucsg.edu.ec		
SECCIÓN PARA USO DE BIBLIOTECA			
Nº. DE REGISTRO (en base a datos):			
Nº. DE CLASIFICACIÓN:			
DIRECCIÓN URL (tesis en la web):			