

Inteligencia Artificial aplicada a la selección predictiva de proveedores de transporte internacional: un enfoque basado en Deep Learning para cadenas logísticas resilientes

Artificial Intelligence applied to the predictive selection of international transport providers: a Deep Learning-based approach for resilient logistics chains

Mayer S. Beltrán* y Alvaro E. Ortiz**

Recibido: 21/01/2016. Aceptado: 15/03/2026. Publicado: 1/04/2026.

Resumen. Las empresas a nivel mundial enfrentan un desafío significativo en la selección de proveedores en el transporte internacional, debido a la incertidumbre asociada a los tiempos de tránsito, la confiabilidad operativa y la variabilidad en condiciones logísticas y geopolíticas. Esta problemática impacta la eficiencia de las cadenas de suministro y la capacidad de respuesta ante eventos imprevistos. En este contexto, el estudio tiene como objetivo desarrollar un sistema predictivo basado en Deep Learning que permita mejorar la toma de decisiones estratégicas.

La investigación se fundamenta en la metodología CRISP-DM, abarcando recolección, limpieza, integración y transformación de datos provenientes de bases SQL empresariales, plataformas de seguimiento de carga y sistemas de información geográfica. El modelo integra redes neuronales recurrentes, específicamente arquitecturas LSTM y GRU, para capturar dependencias temporales en datos históricos de desempeño, así como variables relacionadas con rutas marítimas, tiempos de tránsito y eventos logísticos. Se incorporan técnicas de normalización, selección de variables y validación cruzada para optimizar rendimiento.

Los resultados evidencian una mejora significativa en la precisión predictiva frente a enfoques tradicionales, alcanzando un error promedio cercano a ± 3.4 días y alta

capacidad de generalización en diferentes escenarios operativos. Asimismo, el sistema permite identificar patrones de comportamiento de los proveedores y anticipar retrasos.

En conclusión, el sistema constituye una herramienta robusta para la selección y evaluación de proveedores en entornos logísticos complejos, contribuyendo a la reducción de la incertidumbre y al fortalecimiento de la resiliencia y sostenibilidad de la cadena de suministro en el transporte marítimo internacional.

Palabras clave: Analítica predictiva, Cadena de suministro, Transporte marítimo, Inteligencia artificial, Toma de decisiones.

Abstract. Companies worldwide are facing significant challenges when it comes to selecting international transport providers, due to the uncertainty surrounding transit times, operational reliability and the variability of logistical and geopolitical conditions. These issues impact the efficiency and responsiveness of supply chains to unforeseen events. The aim of this study is to develop a predictive system based on deep learning to enhance strategic decision-making. Following the CRISP-DM methodology, the research covers

* Universidad Distrital Francisco José de Caldas. ORCID: <https://orcid.org/0009-0008-9901-7019>. Email: msbeltranr@udistrital.edu.co. Autor de correspondencia.

** Universidad Distrital Francisco José de Caldas. ORCID: <https://orcid.org/0000-0001-8830-1657>. Email: aeortizd@udistrital.edu.co

data collection, cleaning, integration, and transformation using data from corporate SQL databases, cargo tracking platforms, and geographic information systems. The model incorporates recurrent neural networks – specifically, LSTM and GRU architectures – to identify temporal dependencies in historical performance data alongside variables related to maritime routes, transit times, and logistics events. Data normalisation, feature selection and cross-validation techniques are applied to optimise performance. The results demonstrate a significant improvement in predictive accuracy compared to traditional approaches, achieving an average

error of approximately ± 3.4 days, as well as strong generalisation capability across different operational scenarios. Furthermore, the system can identify supplier behaviour patterns and anticipate potential delays. In conclusion, the developed system is a robust tool for evaluating and selecting suppliers in complex logistics environments, reducing uncertainty and strengthening the resilience and sustainability of international maritime supply chains.

Keywords: Predictive analytics, Supply chain, Maritime transport, Artificial intelligence, Decision-making.

INTRODUCCIÓN

El transporte internacional es uno de los componentes fundamentales del comercio global y de la dinámica de las cadenas de suministro en todo el mundo. Los sistemas de transporte desempeñan un rol estratégico en la integración de mercados, la distribución de productos y el acceso a insumos, en un escenario donde la rapidez, la sostenibilidad y la confiabilidad del flujo de mercancías son cada vez más relevantes para la competitividad económica (Ganapati y Wong, 2023). Por lo tanto, resulta fundamental para el desarrollo y la estabilidad de las economías modernas contar con una gestión logística eficaz (Chirinos-Quintero y Bermúdez-Gómez, 2024).

Hoy en día, los proveedores de transporte afrontan numerosos obstáculos relacionados con la creciente inestabilidad del comercio a nivel mundial. La inestabilidad geopolítica, la variabilidad climática, los costos de combustible, la congestión portuaria y las interrupciones en las cadenas logísticas –como se evidenció durante la pandemia de COVID-19– han demostrado cuán vulnerables son los sistemas internacionales de transporte (Notteboom *et al.*, 2021b). Por ello, las compañías demandan soluciones tecnológicas que les permitan prever riesgos, mejorar la distribución de recursos y asegurar la continuidad de las operaciones en contextos inciertos (Li y Wang, 2024).

Uno de los principales problemas estructurales del transporte internacional es la ausencia de mecanismos predictivos que integren información logística y espacial para medir el desempeño de los proveedores en tiempo real. Por lo general, las decisiones estratégicas se apoyan en datos históricos,

estimaciones manuales o criterios subjetivos que no capturan la realidad actual del mercado. Esta forma de actuar limita la capacidad de reacción ante sucesos inesperados y perjudica la resiliencia de las cadenas de suministro, especialmente en entornos globalizados, donde se depende de una red interconectada de agentes, modos de transporte y factores externos (Vummadi and Raja Hajarath, 2022).

En este marco, la inteligencia artificial (IA) se presenta como una herramienta fundamental para la digitalización del sector logístico. Su capacidad para analizar grandes volúmenes de datos, identificar patrones no lineales y generar pronósticos precisos ofrece nuevas oportunidades para la toma de decisiones basada en evidencia. El aprendizaje profundo (Deep Learning), en particular, ha demostrado un notable potencial para optimizar rutas, analizar series temporales y prever el rendimiento de los proveedores logísticos. Estos modelos permiten capturar relaciones complejas entre variables, tales como el tráfico terrestre o marítimo, las condiciones climáticas, los tiempos de tránsito y la productividad histórica, lo que posibilita una perspectiva integral y dinámica del sistema logístico global (Khedr, 2024).

El presente estudio propone un modelo predictivo basado en Deep Learning, diseñado para anticipar el desempeño de los proveedores de transporte internacional mediante la integración de datos logísticos, operativos y geoespaciales. El modelo combina redes neuronales recurrentes (LSTM y GRU) para el análisis temporal con arquitecturas convolucionales (CNN) orientadas al reconocimiento de patrones espaciales. Esta integración permite identificar correlaciones entre trayectorias, zonas geográficas, temporadas comerciales

y comportamientos de desempeño que afectan la puntualidad y la confiabilidad de las operaciones (Young *et al.*, 2018b).

La metodología adoptada sigue el enfoque CRISP-DM (Cross Industry Standard Process for Data Mining), adaptado a las necesidades del sector logístico. Este marco proporciona una estructura sistemática que abarca desde la comprensión del negocio y la preparación de los datos hasta la validación y el despliegue del modelo predictivo (Wirth y Hipp, 2000a). Gracias a esta metodología, es posible integrar fuentes heterogéneas de información—como bases de datos SQL, API de seguimiento, sistemas AIS (Automatic Identification System) y plataformas de monitoreo portuario— para construir un sistema robusto y replicable.

El propósito principal de este trabajo es demostrar que la IA puede convertirse en una herramienta clave para la gestión logística a nivel mundial, ya que permite seleccionar proveedores de manera más sostenible, resiliente y precisa. Diversos estudios han subrayado, en esta línea, la capacidad de la IA para contribuir al logro de los Objetivos de Desarrollo Sostenible (ODS) mediante la mejora de procesos y el fomento de prácticas sostenibles en las empresas (Vinuesa *et al.*, 2020).

En síntesis, este trabajo contribuye al desarrollo de una perspectiva predictiva avanzada para la gestión del transporte internacional, combinando la capacidad analítica del Deep Learning con el componente espacial del sistema logístico global. Con ello, se busca avanzar hacia cadenas logísticas más inteligentes, sostenibles y adaptables, capaces de afrontar los retos presentes y futuros.

OBJETIVOS

Objetivo general

Desarrollar un sistema predictivo basado en Deep Learning para la selección sostenible de proveedores de transporte internacional, mediante la integración de información logística, operativa y geoespacial, con el fin de brindar a las empresas una herramienta que fortalezca la planeación, la confiabilidad y la resiliencia de las cadenas logísticas globales.

Objetivos específicos

- Analizar las principales variables logísticas, operativas y geográficas que influyen en el desempeño de los proveedores de transporte internacional, a partir de la experiencia de expertos del sector.
- Integrar y depurar múltiples fuentes de datos empresariales y sistemas de seguimiento (bases de datos SQL, AIS, API logísticas), garantizando la coherencia temporal, espacial y semántica de la información.
- Diseñar y entrenar modelos neuronales basados en arquitecturas recurrentes (LSTM y GRU) y convolucionales (CNN) para la predicción de los días reales de tránsito de los proveedores.
- Evaluar el desempeño de las diferentes configuraciones arquitectónicas mediante métricas cuantitativas como MAE, RMSE, R^2 y MAPE, con el fin de seleccionar la configuración óptima en términos de precisión y capacidad de generalización.
- Desplegar un prototipo funcional implementado en Python que permita a las empresas del sector logístico ingresar variables operativas y obtener un indicador de confiabilidad del proveedor en tiempo real.
- Contribuir al fortalecimiento de la sostenibilidad y la digitalización del transporte internacional, alineando el modelo propuesto con los Objetivos de Desarrollo Sostenible (ODS) relacionados con la eficiencia de recursos y la reducción de emisiones.

METODOLOGÍA

La investigación se desarrolló siguiendo la metodología CRISP-DM (Cross-Industry Standard Process for Data Mining), la cual estructura los proyectos de analítica de datos en seis fases principales (Figura 1): comprensión del negocio, comprensión de los datos, preparación de los datos, modelado, evaluación y despliegue (Wirth y Hipp, 2000a).

En este estudio se implementaron principalmente las fases de comprensión del negocio, preparación de los datos, modelado y evaluación,

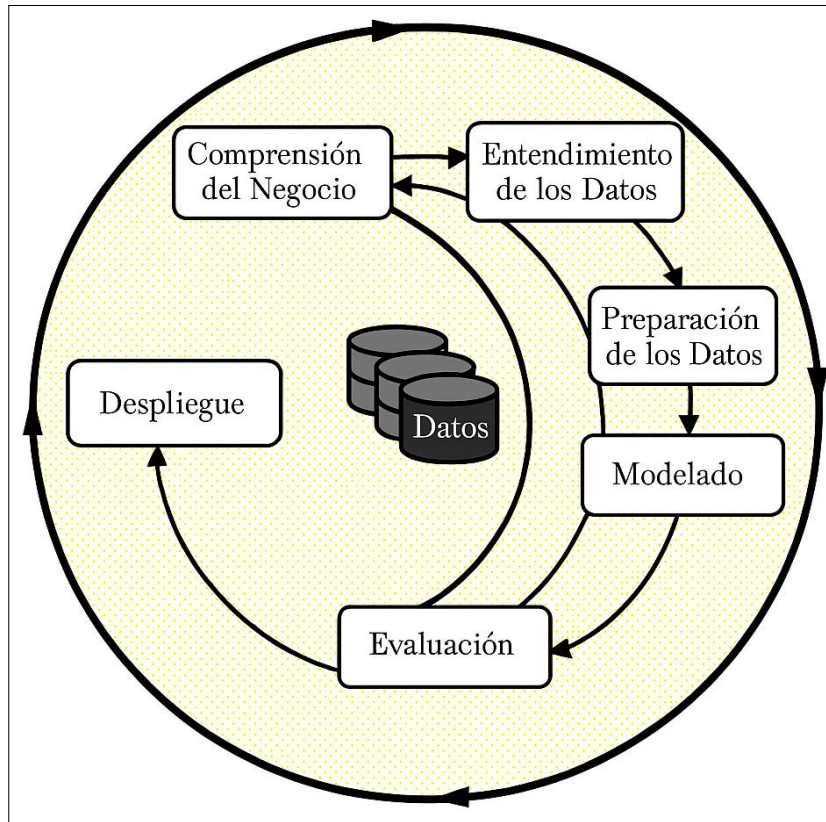


Figura 1. Etapas del modelo CRISP-DM traducido al español. Fuente: traducción y adaptación propia de (Wirth y Hipp, 2000a).

orientadas al desarrollo de un sistema predictivo para el análisis de tiempos de tránsito en operaciones logísticas internacionales.

Fase 1: Comprensión del negocio y los datos

Para comprender las necesidades de las empresas y las variables del transporte logístico internacional que generan mayor impacto en sus operaciones, se recurrió a expertos con amplia experiencia en el sector. Para ello, se realizó un proceso de indagación sobre la información y su funcionamiento con profesionales que actualmente trabajan en uno de los mayores generadores de carga, el cual atiende a más de 1000 clientes de diversos sectores. Con base en su experiencia en la interacción diaria con estos clientes, fue posible identificar las variables que más inciden en las operaciones de las empresas.

En la Tabla 1 se presentan los países considerados en el modelo predictivo, correspondientes a los principales corredores logísticos de transporte in-

ternacional asociados a la red operativa de estudio. La inclusión de una amplia diversidad geográfica permitió evaluar la robustez del modelo frente a distintos contextos comerciales y rutas marítimas.

En la Figura 2 se muestran los países de los puertos cuyas coordenadas geográficas fueron consideradas para el análisis de los corredores logísticos internacionales. Esta representación geoespacial permite observar la distribución global de los puntos utilizados en el modelado.

Fase 2: Preparación de los datos

Dado que la calidad y la coherencia de los datos tienen un impacto directo en el desempeño de los modelos de aprendizaje profundo, la etapa de preparación de los datos se convirtió en una de las más importantes del proyecto. Este proceso incluyó la recolección, integración, depuración, transformación y enriquecimiento de datos procedentes de diversas fuentes internas y externas, asegurando su coherencia semántica, temporal y espacial.

Para la recolección inicial, se incorporaron tres bases de datos SQL provenientes de diferentes sistemas empresariales: (i) operaciones navales de carácter internacional, (ii) historial de desempeño de los proveedores y (iii) registros de monitoreo de carga. Estas fuentes se integraron en una estructura única mediante procesos de extracción, transfor-

mación y carga (ETL), implementados en Python y SQL Server Integration Services (SSIS) (Figura 3).

El objetivo fue obtener un conjunto de datos estructurado que representara de manera precisa las operaciones logísticas realizadas por múltiples proveedores entre América, Europa y Asia.

Cada registro incluyó variables numéricas, categóricas y geoespaciales, entre ellas: tiempos de tránsito estimados y reales, tipo de servicio (FCL, LCL o aéreo), frecuencia de operación, tipo de carga y ubicaciones de los puertos de origen y destino. Además, se incorporaron variables derivadas, como la desviación entre los tiempos de tránsito ofrecidos y los reales, lo que permite calcular la confiabilidad de cada proveedor de manera cuantitativa.

Durante el proceso de depuración, se eliminaron registros duplicados, incompletos o inconsistentes. Asimismo, se aplicaron métodos de limpieza para estandarizar las denominaciones de puertos, los formatos de fecha y las unidades de tiempo, siguiendo la nomenclatura de UN/LOCODE. Los valores atípicos se identificaron mediante el análisis de cuartiles y solo se eliminaron cuando estaban asociados a errores de registro o a tiempos de tránsito físicamente inviables.

Para prevenir que magnitudes desproporcionadas interfieran con la convergencia de los modelos neuronales, se realizó una normalización min-max

Tabla 1. Países incluidos en la investigación.

Código	País	Código	País
AE	Emiratos Árabes Unidos	AR	Argentina
AU	Australia	BE	Bélgica
BR	Brasil	CA	Canadá
CL	Chile	CN	China
CO	Colombia	CR	Costa Rica
DE	Alemania	DK	Dinamarca
DO	República Dominicana	EC	Ecuador
EG	Egipto	ES	España
FR	Francia	GB	Reino Unido
GH	Ghana	GR	Grecia
GT	Guatemala	HN	Honduras
ID	Indonesia	IL	Israel
IN	India	IT	Italia
JP	Japón	KE	Kenia
KR	Corea del Sur	MA	Marruecos
MM	Myanmar	MX	México
MY	Malasia	NG	Nigeria
NL	Países Bajos	NO	Noruega
PA	Panamá	PE	Perú
PH	Filipinas	PK	Pakistán
PL	Polonia	PT	Portugal
RO	Rumania	RU	Rusia
SG	Singapur	SI	Eslovenia
SR	Surinam	TH	Tailandia
TR	Turquía	TW	Taiwán
US	Estados Unidos	UY	Uruguay
VN	Vietnam	ZA	Sudáfrica

Fuente: elaboración propia

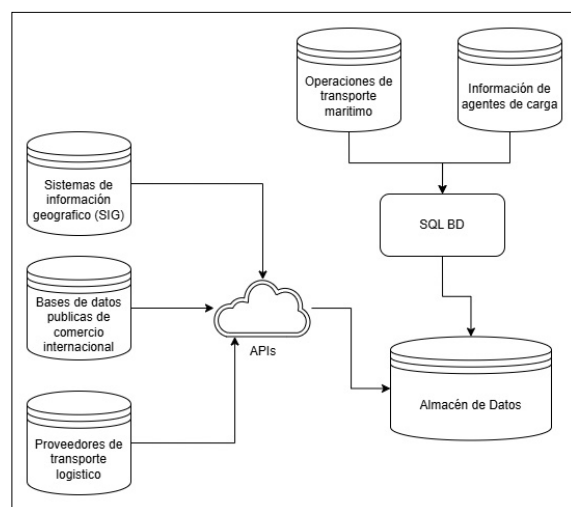


Figura 3. Arquitectura de integración y consolidación de datos logísticos. Fuente: elaboración propia.

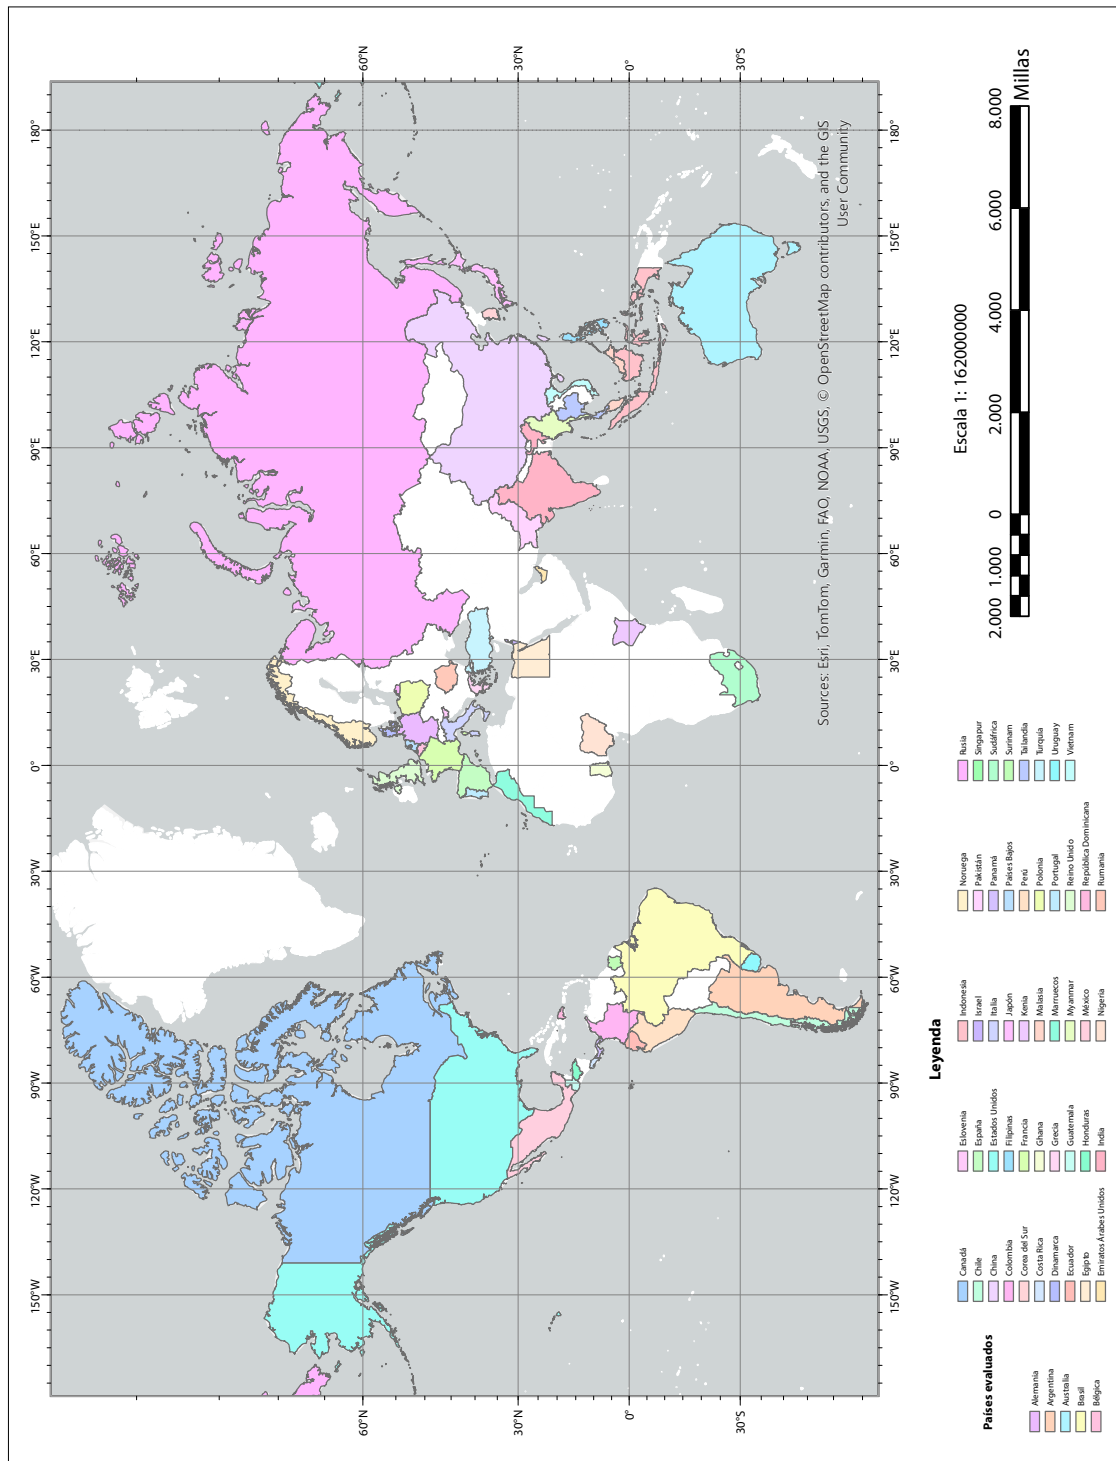


Figura 2. Distribución geoespacial de los países considerados en el estudio. Fuente: elaboración propia.

en las variables continuas. Asimismo, se utilizó codificación *one-hot* para las variables categóricas (tipo de carga, proveedor, país, puerto, etc.), con el fin de asegurar su compatibilidad con las arquitecturas de redes neuronales implementadas.

Respecto a la dimensión temporal, las fechas se transformaron en variables numéricas que reflejan el orden de los sucesos, tales como la semana del año, el día juliano y la desviación media temporal por proveedor. Esta representación permitió que los modelos RNN (LSTM y GRU) captaran relaciones de largo plazo en los patrones de tránsito marítimo. De forma simultánea, la información geográfica se procesó mediante sistemas de información geográfica (SIG), geocodificando los puertos de origen y destino con sus respectivas coordenadas. Este componente espacial permitió integrar mapas logísticos en el modelado y analizar correlaciones espaciales en etapas posteriores.

El conjunto final de datos estuvo conformado por registros operativos limpios y estandarizados, con más de 30 variables independientes que describen tanto las características operativas como las condiciones espaciales y temporales de las rutas marítimas. Este conjunto de datos se dividió en tres subconjuntos: 70 % para entrenamiento, 15 % para validación y 15 % para prueba, manteniendo el orden cronológico para preservar la secuencialidad inherente a los datos de tránsito.

La Figura 4 muestra la distribución geográfica de la densidad operativa por país, con agrupaciones notables en América, Europa y Asia oriental. Esto evidencia la relevancia global de los corredores logísticos seleccionados para el análisis. En la visualización, los tonos verdes claros representan regiones con menor densidad operativa, mientras que los tonos verdes oscuros indican una mayor concentración de operaciones logísticas.

Por último, se desarrollaron visualizaciones exploratorias (EDA, *Exploratory Data Analysis*) que permitieron identificar relaciones relevantes entre variables, como la correlación entre la distancia geográfica y el retraso promedio, así como una mayor variabilidad en los tiempos de tránsito en corredores intercontinentales (Figura 5). Este análisis no solo validó la coherencia de los datos, sino que también orientó el ajuste de los hiperpa-

rámetros en etapas posteriores de entrenamiento y validación del modelo.

Fase 3: Modelado

Dado que los datos de tránsito presentan un carácter temporal y secuencial, se optó por redes neuronales recurrentes de tipo LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit), ya que permiten identificar correlaciones de largo plazo en series temporales (Wu y Tan, 2016). De manera complementaria, se emplearon redes convolucionales (CNN) con el fin de analizar patrones espaciales derivados de mapas logísticos y rutas marítimas. Este enfoque híbrido permitió abordar de forma conjunta las dimensiones espacial y temporal de los datos.

Arquitectura del modelo híbrido CNN-LSTM/GRU

Las redes LSTM y GRU se seleccionaron por su capacidad para conservar información relevante durante períodos prolongados y mitigar el problema del desvanecimiento del gradiente en series temporales. Estas arquitecturas permiten modelar dependencias temporales complejas presentes en los datos de tránsito logístico. Por su parte, las redes convolucionales (CNN) se incorporaron con el objetivo de capturar patrones espaciales asociados a rutas marítimas, corredores logísticos y la distribución geográfica de los puertos.

A partir de estas características, se diseñó una arquitectura neuronal multimodal capaz de integrar simultáneamente información logística, operativa y geográfica en una misma estructura de aprendizaje profundo. La Figura 6 presenta la estructura general del modelo híbrido propuesto.

El diseño arquitectónico del modelo se organizó en varias capas que procesan de manera jerárquica las características extraídas del conjunto de datos. En primer lugar, las capas de entrada reciben variables numéricas y categóricas previamente normalizadas, incluyendo información espacial (coordenadas geográficas de origen y destino) utilizada por las redes convolucionales, así como variables logísticas y temporales utilizadas por las redes recurrentes.

Posteriormente, las capas convolucionales aplican filtros sobre representaciones espaciales

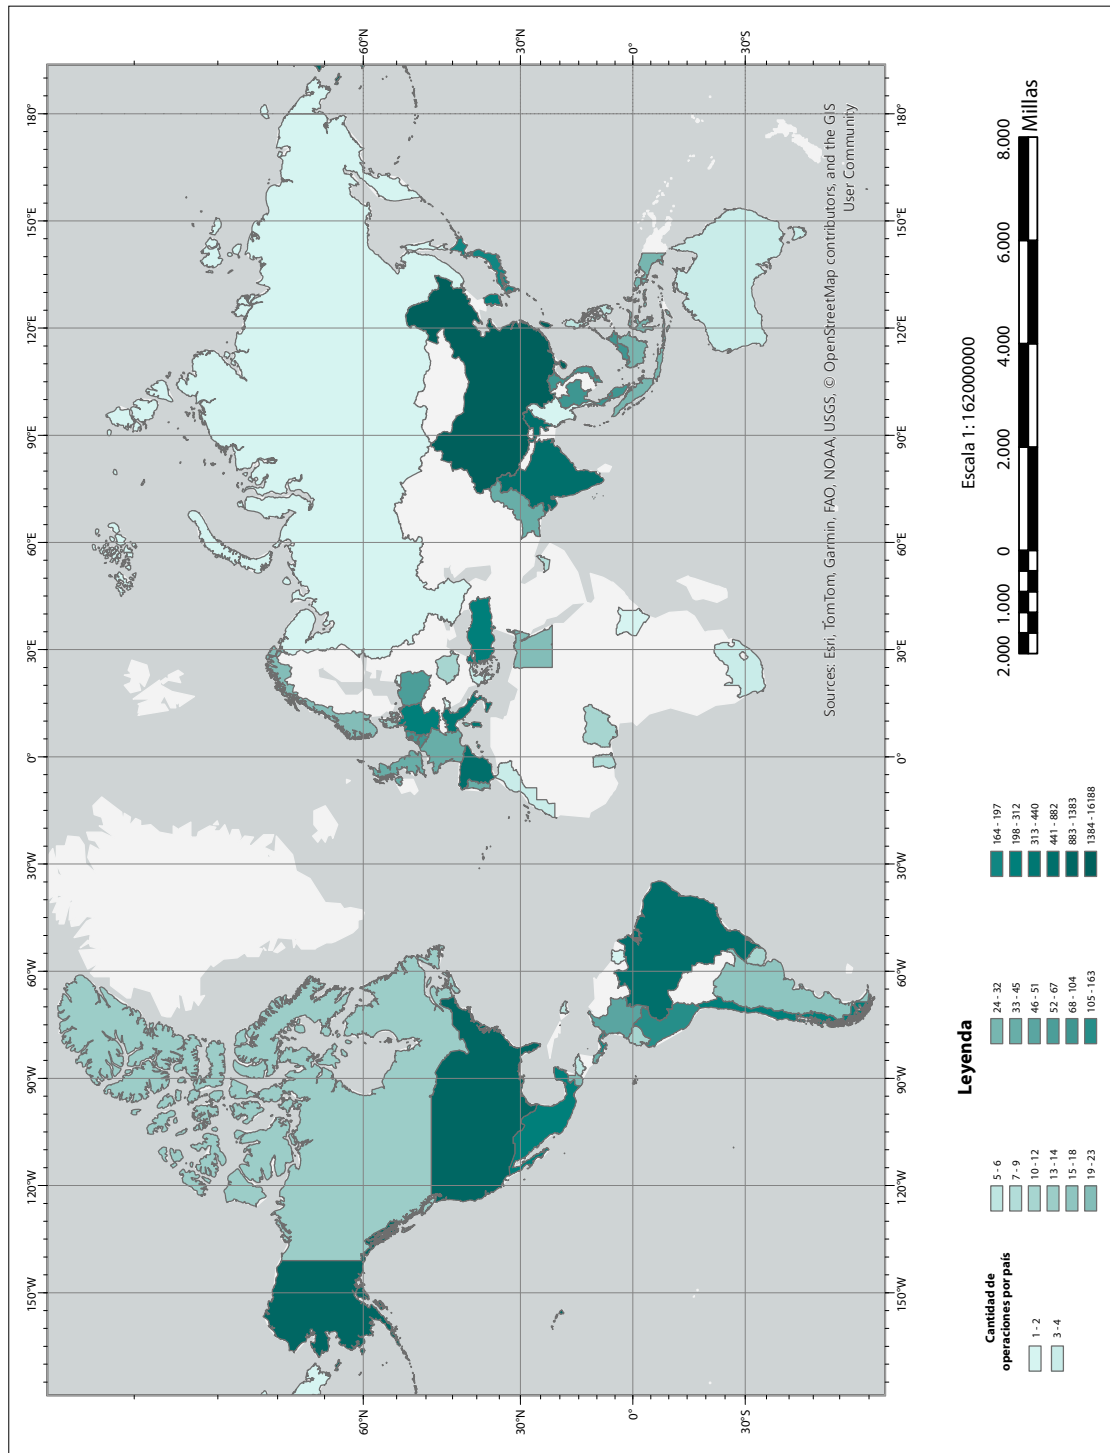


Figura 4. Visualización geoespacial de la densidad de operaciones por país de los puertos evaluados. Fuente: elaboración propia.

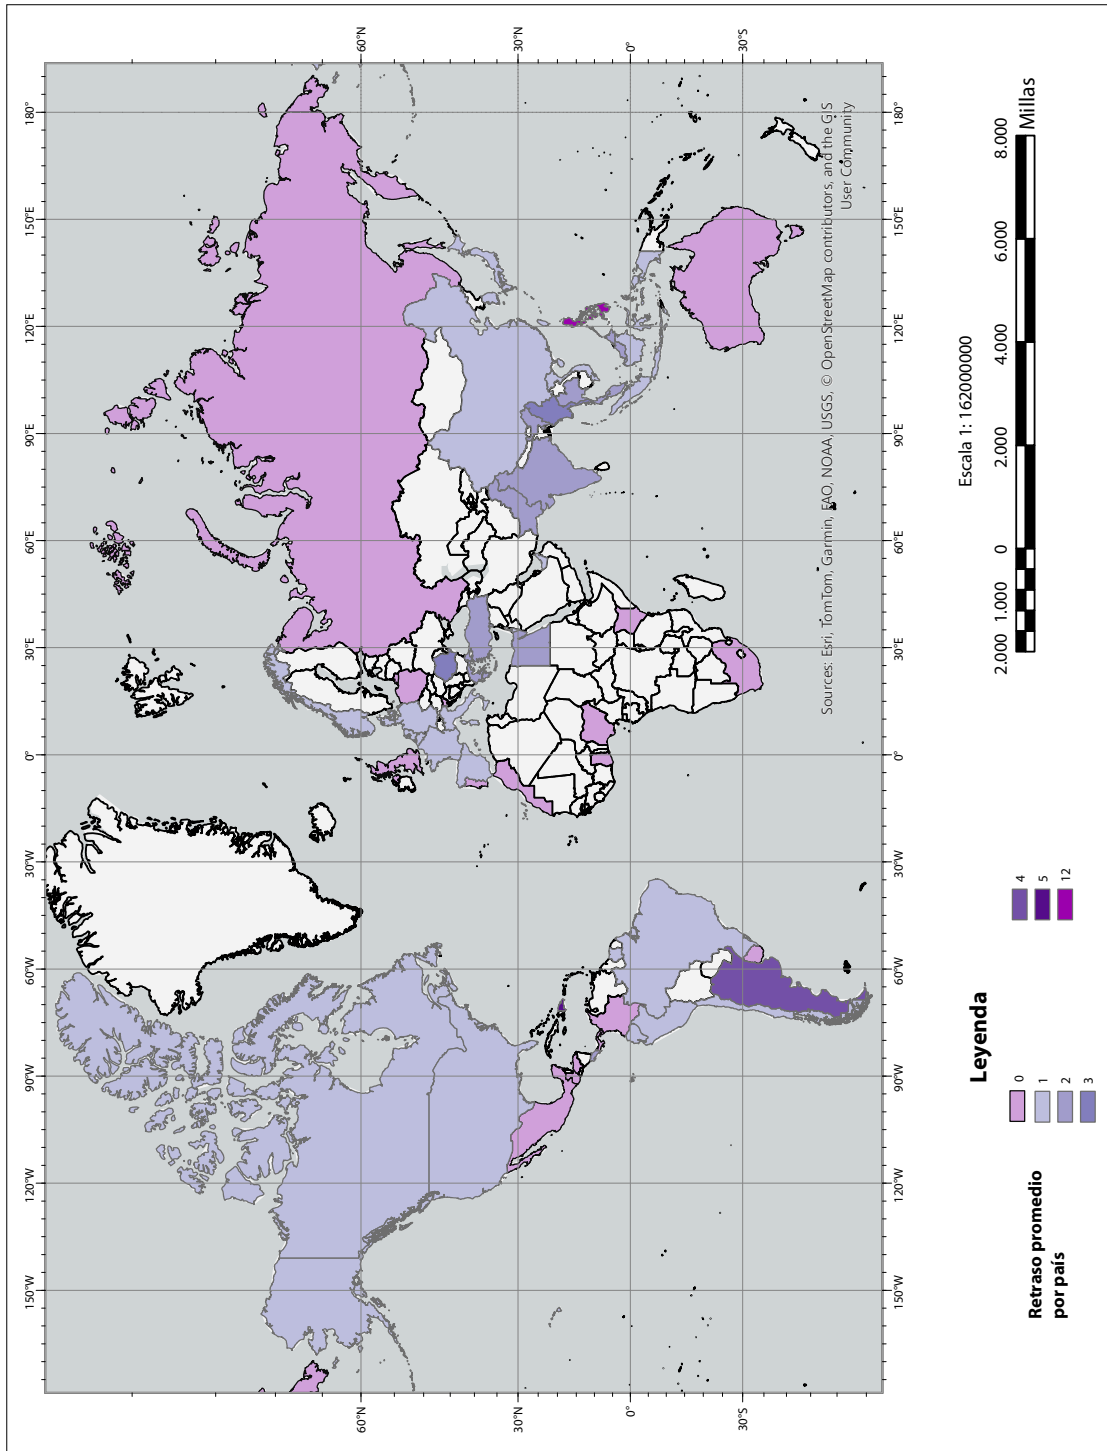


Figura 5. Visualización geoespacial del retraso promedio por país de los puertos evaluados. Fuente: elaboración propia.

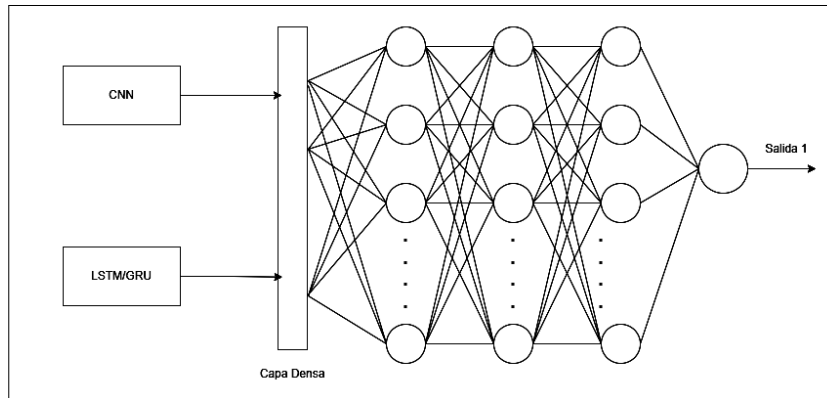


Figura 6. Arquitectura interna del modelo híbrido multimodal CNN-LSTM/GRU. Fuente: elaboración propia.

derivadas de los mapas logísticos para identificar patrones geográficos asociados a los corredores de transporte. De forma paralela, los bloques recurrentes basados en LSTM y GRU procesan las variables temporales con el fin de identificar dependencias entre eventos logísticos consecutivos.

Los vectores de características generados por ambos módulos se integran mediante una capa de fusión completamente conectada, la cual permite combinar de manera conjunta las representaciones espaciales y temporales aprendidas por el modelo. Finalmente, las capas densas realizan el mapeo no lineal hacia la variable objetivo correspondiente al tiempo de tránsito real estimado.

Representación geoespacial mediante matrices

Para el procesamiento de datos geoespaciales, las coordenadas de los puertos se transformaron en representaciones matriciales discretas mediante una cuadrícula uniforme de 20 × 20 celdas que representa el espacio global. Esta discretización permitió convertir la información geográfica en estructuras numéricas compatibles con redes convolucionales, facilitando la identificación de patrones espaciales en el sistema logístico internacional.

Las coordenadas de latitud y longitud se normalizaron al intervalo [0, 1] mediante una transformación min-max. Posteriormente, se convirtieron en índices matriciales según las siguientes ecuaciones:

$$i = \lfloor \text{Latesc} \times (N - 1) \rfloor \quad (1)$$

$$j = \lfloor \text{Lonesc} \times (N - 1) \rfloor \quad (2)$$

donde N = 20 representa la resolución espacial de la cuadrícula; i corresponde a la fila asociada a la latitud y j a la columna asociada a la longitud. De esta forma, cada puerto se proyecta en una celda específica según su posición geográfica normalizada.

La Tabla 3 presenta un ejemplo del proceso de indexación geoespacial aplicado a diferentes puertos internacionales.

A partir de esta indexación, cada operación logística –definida como la combinación entre un puerto de origen y uno de destino– se representó mediante una matriz espacial de 20 × 20, en la que las celdas correspondientes se codificaron con valores diferenciados:

$$M[i_{\text{origen}}, j_{\text{origen}}] = 1$$

$$M[i_{\text{destino}}, j_{\text{destino}}] = 0.5$$

$$M[x, y] = 0 \quad \text{para el resto de las celdas}$$

Por ejemplo, una operación logística entre China (CN) y Colombia (CO) puede representarse conceptualmente mediante la siguiente matriz:

$$\text{CN} \rightarrow \text{CO} : \begin{bmatrix} 0 & 0 & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & & \vdots \\ 0 & 0,5 & 0 & \dots & 0 \\ \vdots & & & & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix}$$

Donde la posición (17, 17) corresponde al puerto de origen (China) y la posición (11, 2) corresponde al puerto de destino (Colombia).

De este modo, cada registro generó una matriz espacial que describe la conexión geográfica entre puertos, conformando un conjunto de datos tridimensional apto para la extracción de características mediante redes convolucionales.

Estrategias de regularización

Con el fin de mejorar la capacidad de generalización del modelo y reducir el riesgo de sobreajuste, se incorporaron diversas técnicas de regularización ampliamente utilizadas en aprendizaje profundo.

En primer lugar, se implementó *Batch Normalization*, técnica que normaliza las activaciones intermedias y estabiliza la distribución de los datos en cada capa, facilitando el proceso de optimización.

Asimismo, se utilizó *Dropout*, que consiste en desactivar aleatoriamente un porcentaje de neuronas durante cada iteración de entrenamiento. Esta estrategia evita la dependencia excesiva de ciertas neuronas y favorece representaciones más robustas. En este estudio se evaluaron tasas entre 0.2 y 0.4.

Finalmente, en configuraciones más profundas se incorporó regularización L2 en los pesos de la red, penalizando valores excesivos y promoviendo soluciones más estables.

La aplicación conjunta de estas estrategias permite controlar la complejidad del modelo y mejorar su capacidad de generalización frente a nuevos datos.

Configuración de hiperparámetros

Se diseñaron múltiples configuraciones arquitectónicas variando el número de capas, la cantidad de neuronas, las funciones de activación y las estrategias de regularización, con el objetivo de analizar el comportamiento del modelo bajo distintos niveles de complejidad estructural.

Para tal fin, se definieron diversas configuraciones denominadas Simple, Media, Compleja, Profunda, Residual y Ancha. Cada una de estas representa diferentes niveles de profundidad y capacidad de representación del modelo, lo que permite evaluar su desempeño bajo distintas estructuras de red.

La configuración Simple corresponde a una arquitectura con un número reducido de capas y neuronas, diseñada para establecer una línea base de comparación. La configuración Media incorpora una mayor cantidad de unidades y capas, lo que permite capturar patrones más complejos en los datos. Por su parte, la arquitectura Compleja incrementa aún más la profundidad y el número de parámetros del modelo con el propósito de ampliar su capacidad de representación.

Adicionalmente, se consideró una configuración Profunda, caracterizada por el aumento del número de capas convolucionales y recurrentes, lo que permite explorar estructuras más profundas en el proceso de aprendizaje. La arquitectura Residual incorpora conexiones que facilitan la propagación de la información entre capas, mientras que la configuración Ancha incrementa el número de neuronas en determinadas capas con el objetivo de ampliar el espacio de representación del modelo.

Con el fin de realizar una comparación sistemática entre los diferentes algoritmos y arquitecturas evaluadas, se definieron combinaciones de los siguientes hiperparámetros durante el proceso de entrenamiento:

- *Learning rate*
- *Batch size*
- Número de *epochs*
- *Early stopping*

El ajuste de estos hiperparámetros permite controlar la dinámica de aprendizaje del modelo, optimizar el proceso de entrenamiento y mejorar su capacidad de generalización frente a datos no observados.

Métricas de evaluación

El desempeño de los modelos fue evaluado mediante métricas estándar de regresión utilizadas en problemas de predicción temporal. Se emplearon el error absoluto medio (MAE), la raíz del error cuadrático medio (RMSE) y el coeficiente de determinación (R^2).

El MAE mide la magnitud promedio del error absoluto entre los valores predichos y los valores reales:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

El RMSE penaliza con mayor intensidad los errores de mayor magnitud:

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

Finalmente, el coeficiente de determinación R^2 permite medir la proporción de varianza explicada por el modelo:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}$$

Estas métricas permitieron comparar de manera objetiva el desempeño de las distintas arquitecturas neuronales evaluadas.

Fase 4: Entrenamiento y validación

El modelo fue entrenado utilizando un conjunto de datos históricos compuesto por más de 20 000 registros de operaciones de transporte marítimo entre América, Europa y Asia. Los datos fueron organizados en secuencias temporales con el fin de preservar la estructura cronológica de las operaciones logísticas.

Para evaluar la capacidad de generalización del modelo, se empleó una estrategia de validación cruzada temporal, adecuada para datos secuenciales, evitando el uso de información futura durante el entrenamiento.

Durante esta fase se evaluaron múltiples configuraciones arquitectónicas y combinaciones de hiperparámetros implementadas en Python. En total, se entrenaron 108 modelos correspondientes a diferentes estructuras de red y parámetros de aprendizaje, lo que permitió analizar el comportamiento del modelo bajo distintos niveles de complejidad.

El desempeño de cada configuración se evaluó mediante las métricas *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), coeficiente de

determinación (R^2) y *Mean Absolute Percentage Error* (MAPE). Estas métricas permiten cuantificar la precisión de las predicciones y evaluar la capacidad del modelo para explicar la variabilidad observada en los datos.

Fase 5: Despliegue

Como última fase de la metodología CRISP-DM, se plantea el despliegue del modelo en un entorno empresarial orientado a compañías que buscan importar o exportar mercancías mediante distintos proveedores de transporte internacional.

A partir del modelo entrenado, las empresas pueden ingresar variables de entrada como el puerto de origen, el puerto de destino, las fechas estimadas de salida y llegada, los tiempos de tránsito ofertados y el proveedor logístico a evaluar. Con base en esta información, el sistema genera una estimación de los días reales de tránsito y un indicador de confiabilidad asociado al cumplimiento de los tiempos logísticos.

Como trabajo futuro, se plantea exponer el modelo mediante una interfaz de programación de aplicaciones (API) desarrollada en FastAPI, lo que permitirá su integración con una interfaz gráfica construida en tecnologías web como JavaScript, CSS y HTML. Esto facilitaría la interacción de los usuarios con el sistema y permitiría su utilización en entornos operativos dentro de organizaciones del sector logístico.

RESULTADOS Y DISCUSIÓN

Evaluación y selección de variables

Con base en las entrevistas realizadas a los expertos del sector —quienes mantienen interacción directa con los clientes (Tabla 4)—, se determinó que uno de los factores más relevantes para estos es el cumplimiento riguroso de los tiempos de tránsito ofertados por los proveedores.

En caso de que los tiempos se adelanten, pueden generarse impactos en los costos de almacenamiento, la disponibilidad de vehículos y la gestión de inventarios. Por el contrario, los retrasos pueden ocasionar afectaciones significativas en la disponibilidad de mercancía, especialmente en temporadas

de alta demanda, así como en la planificación logística y operativa.

A partir del análisis de las entrevistas y del conocimiento experto del sector, se definió como variable objetivo la diferencia entre los días de tránsito ofertados y los días de tránsito reales ejecutados, indicador que permite evaluar la precisión en el cumplimiento de los tiempos logísticos y la eficiencia operativa de los proveedores.

Las variables utilizadas en este proyecto de evaluación fueron definidas con el apoyo de expertos del sector (Tabla 5).

Evaluación de configuraciones arquitectónicas

Con el objetivo de identificar la arquitectura con mayor capacidad predictiva, se evaluaron diferentes configuraciones del modelo híbrido CNN-LSTM/GRU, variando la profundidad de la red, el número de neuronas y las estrategias de regularización.

Las configuraciones evaluadas corresponden a las arquitecturas Simple, Media, Compleja, Profunda, Residual y Ancha (Tabla 2). Cada una de estas

estructuras fue entrenada utilizando los mismos conjuntos de datos y criterios de evaluación, lo que permitió realizar una comparación directa de su desempeño predictivo.

Los resultados obtenidos evidencian que las configuraciones con mayor profundidad y número de parámetros presentan una mayor capacidad para capturar relaciones complejas en los datos logísticos; sin embargo, también implican un mayor costo computacional durante el entrenamiento.

En términos generales, las arquitecturas profundas y residuales mostraron consistentemente un mejor desempeño predictivo, mientras que las arquitecturas simples funcionaron como una línea base adecuada para la comparación del modelo.

Evaluación del modelo

Durante la fase experimental se entrenaron un total de 108 modelos correspondientes a distintas combinaciones de arquitecturas neuronales y parámetros de entrenamiento. Entre todas las configuraciones evaluadas, el modelo con mejor

Tabla 2. Configuraciones de hiperparámetros evaluadas.

Arquitectura	Nº capas de ocultas	Neuronas por capa	Funciones y regularización	Dropout	Propósito principal
Simple	2	64, 32	ReLU	0.2	Modelo base de baja complejidad para pruebas iniciales y control del sobreajuste.
Media	3	128, 64, 32	Batch Normalization, ReLU	0.3–0.2	Mejora la estabilidad del gradiente y la generalización del modelo.
Compleja	4	256 → 128 → 64 → 32	BatchNorm, ReLU	0.3	Aumenta la capacidad de representación sin sobreajuste.
Profunda	5	512 → 256 → 128 → 64 → 32	Regularización L2, ReLU	0.4–0.3	Captura relaciones no lineales y dependencias complejas.
Residual	5+	512 → 256 → 128 → 64 → 32	Conexiones skip, BatchNorm	0.3	Entrena redes profundas sin degradación del gradiente.
Ancha	3	512, 512, 256	ReLU	0.3	Capta interacciones complejas en variables tabulares.

Tabla 3. Ejemplo de indexación geoespacial con puertos proyectados sobre una cuadrícula global de 20 × 20.

País	Puerto	Latitud	Longitud	Lat_esc	Lon_esc	i (fila)	j (columna)
CN (China)	Shanghai	31.230	121.473	0.86	0.88	17	17
SG (Singapur)	Singapur	1.352	103.819	0.78	0.82	15	16
IN (India)	Mumbai	19.076	72.877	0.71	0.73	13	14
ES (España)	Valencia	39.469	-0.376	0.90	0.47	18	9
NL (Países Bajos)	Róterdam	51.948	4.142	0.92	0.51	18	10
BR (Brasil)	Santos	-23.967	-46.329	0.37	0.31	7	6
CO (Colombia)	Cartagena	10.391	-75.479	0.57	0.10	11	2
US (Estados Unidos)	Los Ángeles	33.740	-118.270	0.87	0.05	17	1
MX (México)	Manzanillo	19.052	-104.317	0.74	0.02	14	0
CL (Chile)	Valparaíso	-33.047	-71.612	0.33	0.26	6	5
ZA (Sudáfrica)	Durban	-29.857	31.029	0.35	0.64	6	12
AE (E.A.U.)	Dubái	25.276	55.297	0.82	0.68	16	13
VN (Vietnam)	Hai Phong	20.864	106.683	0.73	0.83	14	16
KR (Corea del Sur)	Busan	35.179	129.076	0.89	0.91	18	18
JP (Japón)	Yokohama	35.444	139.638	0.89	0.93	18	18

Fuente: elaboración propia.

Tabla 4. Experiencia y formación de expertos entrevistados.

Cargo	Años de experiencia en el mercado	Formación
Presidente de la compañía Interworld Freight	42 años	Profesional en Administración de Empresas; Especialista en Finanzas Internacionales
Directora Comercial Nacional	29 años	Administradora de Empresas; Especialista en Servicio al Cliente; Magíster en Gestión y Experiencia al Cliente
Director Corporativo de Tecnologías de la Información	25 años	Ingeniero de Sistemas; Especialista en Ciberseguridad
Director Corporativo Comercial	22 años	Profesional en Finanzas y Negocios Internacionales
Directora de Servicio al Cliente	21 años	Administradora de Empresas; Especialista en Gerencia Logística
Director de Operaciones y Proyectos	20 años	Profesional en Negocios Internacionales; Especialista en Comercio Exterior; Magíster en Cadena de Suministro
Director de Pricing	16 años	Profesional en Comercio Internacional; Especialista en Negocios Internacionales
Gerente Regional Comercial	10 años	Administrador de Empresas; Especialista en Negocios Internacionales
Director Overseas	7 años	Administrador de Empresas; Magíster en Comercio Internacional

Fuente: elaboración propia.

desempeño correspondió a la arquitectura Media, entrenada con los siguientes hiperparámetros:

- *Learning rate*: 0.001
- *Batch size*: 64
- *Epochs*: 200
- Función de activación: ReLU
- Optimizador: Adam
- Regularización: *Batch Normalization* y *Dropout*

Esta configuración alcanzó los siguientes valores de desempeño:

- MAE: 3.37 días
- RMSE: 6.73 días
- R^2 : 0.818
- MAPE: 20.49 %

Estos resultados indican que el modelo es capaz de predecir los días de tránsito reales con un error

medio aproximado de ± 3.4 días, lo cual representa un nivel de precisión adecuado para aplicaciones logísticas de planificación y evaluación de proveedores.

El análisis comparativo entre valores observados y predichos evidenció una alta correlación entre ambas series, lo que sugiere que el modelo captura adecuadamente las dinámicas temporales presentes en los datos logísticos. Asimismo, la incorporación de técnicas de regularización, como *Batch Normalization* y *Dropout*, contribuyó a estabilizar el proceso de aprendizaje y reducir el riesgo de sobreajuste.

La Figura 7 presenta la arquitectura final seleccionada.

Análisis geoespacial de los resultados

Desde una perspectiva geoespacial, la integración de herramientas de sistemas de información geográfica (SIG) permitió visualizar patrones espaciales asociados al desempeño logístico de las rutas marítimas.

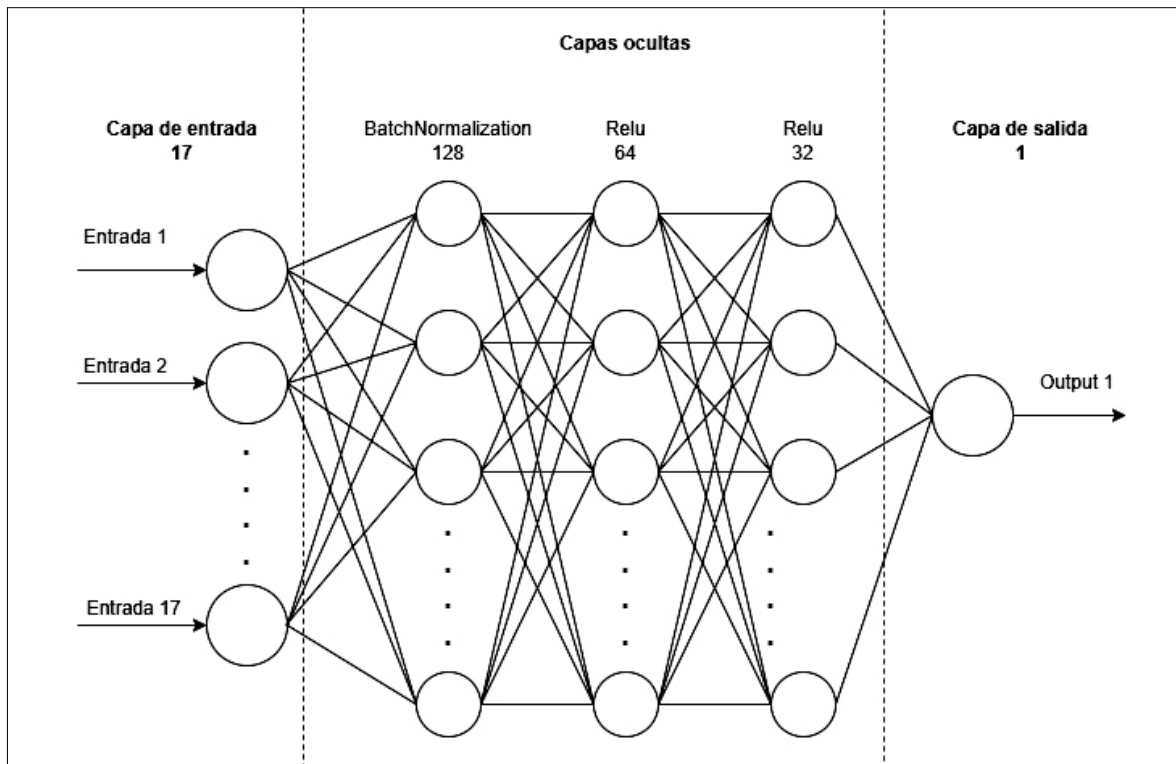


Figura 7. Arquitectura RNN seleccionada. Fuente: elaboración propia.

Tabla 5. Matriz de variables seleccionadas.

Nombre de la Variable	Descripción
ID	Identificador único del registro
Fecha de creación del registro	Fecha en la que se creó el registro en el sistema
Proveedor	Nombre del proveedor o agente logístico encargado
Servicio	Tipo de servicio logístico prestado
Tipo de carga	Modalidad de carga, FCL (contenedor completo), LCL (carga consolidada) o aéreo
Puerto de origen	Puerto desde donde se embarca la mercancía
Puerto de destino	Puerto donde se espera que llegue la mercancía
Ciudad de origen	Ciudad de origen de la carga
Ciudad de destino	Ciudad destino final de la carga
Departamento de origen	Departamento o estado de origen de la carga
Departamento de destino	Departamento o estado destino de la carga
País de origen	País de donde se embarca
País de destino	País donde se recibirá la mercancía
Fecha estimada de zarpe	Fecha prevista de salida del embarque desde el puerto de origen
Fecha estimada de arribo	Fecha prevista de arribo al puerto destino
Días de tránsito ofertados	Días de tránsito ofertados por el proveedor
Fecha confirmada de zarpe	Fecha en la que efectivamente zarpó la embarcación
Fecha y hora confirmada de arribo al puerto final	Fecha y hora real de llegada al puerto final
Días de tránsito reales	Fecha y hora real de llegada al puerto final

Fuente: elaboración propia.

Los mapas de activación generados por la CNN evidenciaron patrones espaciales vinculados a corredores logísticos de alta frecuencia, particularmente entre Asia oriental y América. Asimismo, se observó que las rutas con mayor distancia geográfica presentan una mayor variabilidad en los tiempos reales de tránsito, lo que sugiere una influencia significativa del componente espacial en la capacidad predictiva del modelo.

Adicionalmente, se identificaron concentraciones de retrasos recurrentes en puertos estratégicos como Cartagena y Buenaventura, así como variaciones en los tiempos de tránsito hacia destinos en Asia oriental durante temporadas de alta demanda. Este análisis espacial permitió complementar la predicción numérica con una interpretación geográfica de los resultados.

Aplicación del modelo en entornos logísticos

El prototipo implementado permitió validar el funcionamiento del sistema en un entorno funcional orientado a empresas del sector logístico. La herramienta desarrollada procesa variables de entrada como proveedores, puertos, fechas de salida y llegada, y tiempos de tránsito ofertados, generando una estimación de los días reales de tránsito y un indicador de confiabilidad asociado.

El sistema puede generar resultados en menos de cinco minutos, lo que representa una reducción significativa del tiempo de análisis en comparación con métodos manuales tradicionales, que pueden requerir varias horas para evaluar proveedores y rutas logísticas.

Estos resultados evidencian que la combinación de modelos de aprendizaje profundo con análisis geoespacial no solo mejora la precisión en la predic-

ción de los tiempos de tránsito, sino que también proporciona herramientas analíticas útiles para la toma de decisiones estratégicas en la planificación logística, la selección de proveedores y la optimización de rutas de transporte internacional.

En conjunto, los hallazgos resaltan el potencial del Deep Learning como una herramienta clave para la transformación digital del sector logístico. La integración de información temporal, espacial y operacional en un mismo modelo predictivo abre nuevas oportunidades para el desarrollo de sistemas inteligentes orientados a mejorar la eficiencia y resiliencia de las cadenas de suministro globales.

CONCLUSIONES

El sistema predictivo basado en Deep Learning desarrollado en esta investigación demostró ser una herramienta eficaz para la estimación de los días de tránsito en operaciones de transporte marítimo internacional. La integración de datos logísticos y geoespaciales permitió capturar la complejidad inherente a las cadenas de suministro globales, proporcionando un modelo analítico robusto, replicable y adaptable a distintos contextos del sector logístico.

Los resultados evidencian que las arquitecturas neuronales de complejidad intermedia, combinadas con mecanismos de regularización como *Batch Normalization* y *Dropout*, permiten alcanzar un equilibrio adecuado entre precisión predictiva, estabilidad del entrenamiento y capacidad de generalización. El modelo seleccionado logró explicar más del 80 % de la variabilidad observada en los tiempos de tránsito y mantener un error medio inferior a cuatro días, lo cual representa un nivel de precisión adecuado para aplicaciones de planificación logística y evaluación del desempeño de proveedores.

Desde una perspectiva metodológica, la aplicación del enfoque CRISP-DM permitió estructurar de manera sistemática el proceso de minería de datos, desde la comprensión del problema hasta el despliegue del modelo. Esta metodología facilitó la integración de diversas fuentes de información –incluyendo bases de datos SQL, API de monitoreo y sistemas de información geográfica–, garantizando

la trazabilidad y calidad de los datos a lo largo del proceso analítico.

El componente geoespacial aportó un valor significativo al permitir identificar patrones espaciales asociados a retrasos recurrentes en corredores logísticos y puertos estratégicos, como Buenaventura y Cartagena. La incorporación de esta dimensión facilita una interpretación más contextual de los resultados y abre nuevas posibilidades para la identificación anticipada de cuellos de botella operativos o riesgos asociados a condiciones meteorológicas y congestión portuaria.

En términos prácticos, el prototipo desarrollado permite automatizar el proceso de evaluación de proveedores logísticos, reduciendo significativamente el tiempo de análisis requerido para estimar la confiabilidad de los tiempos de tránsito. Esto representa un avance relevante hacia la digitalización y optimización de la toma de decisiones en el transporte internacional.

Como líneas de trabajo futuro, se propone la incorporación de fuentes de datos en tiempo real –como información meteorológica, tráfico marítimo (AIS), variables económicas y datos portuarios– con el fin de fortalecer la capacidad predictiva del modelo y habilitar sistemas de alerta temprana ante posibles desviaciones logísticas. Asimismo, se contempla la extensión del enfoque hacia otros modos de transporte, como el aéreo y el terrestre, con el objetivo de evolucionar hacia plataformas inteligentes de análisis multimodal que contribuyan a mejorar la eficiencia, sostenibilidad y resiliencia de las cadenas de suministro en la región andino-caribe.

En conjunto, los resultados evidencian el potencial del Deep Learning como herramienta estratégica para el desarrollo de sistemas de apoyo a la toma de decisiones en logística internacional, contribuyendo al fortalecimiento de procesos más eficientes, sostenibles y resilientes dentro del comercio global.

REFERENCIAS

- Bakhshi, T. y Zafar, S. (2023). Hybrid Deep Learning Techniques for Securing Bioluminescent Interfaces in Internet of Bio Nano Things. *Sensors*, 23, 8972.

- Barua, L., Zou, B. y Zhou, Y. (2020). Machine learning for international freight transportation management: A comprehensive review. *Research in Transportation Business & Management*, 37, 100512.
- Caicedo, E. y López, J. (2009). *Una aproximación práctica a las redes neuronales artificiales*. Programa Editorial Universidad del Valle.
- Centeno Franco, A. (2019). Deep Learning. [Tesis de Doctorado]. Universidad de Sevilla. Depósito de Investigación Universidad de Sevilla. <https://idus.us.es/items/482de78f-0f42-4df3-8d59-004974e9ee94>
- Chelali, M., Kurtz, C., Puissant, A. y Vincent, N. (2020). Image time series classification based on a planar spatio-temporal data representation. *VISIGRAPP (4: VISAPP)*, 276–283.
- Chirinos-Quintero, N. y Bermúdez-Gómez, J. (2024). La gestión logística y su importancia para la internacionalización de productos. *IPSA Scientia, Revista Científica Multidisciplinaria*, 9, ev9r7.
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. y Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. En A. Moschitti, B. Pang, W. Daelemans (eds), *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, (pp. 1724–1734). Association for Computational Linguistics.
- Dai, Q., Huo, X., Hao, Y. y Yu, R. (2023). Spatio-temporal prediction for distributed PV generation system based on deep learning neural network model. *Frontiers in Energy Research*, 11. <https://www.frontiersin.org/journals/energy-research/articles/10.3389/fenrg.2023.1204032>.
- Deneu, B., Servajean, M., Bonnet, P., Botella, C., Muñoz, F. y Joly, A. (2021). Convolutional neural networks improve species distribution modelling by capturing the spatial structure of the environment. *PLOS Computational Biology*, 17(4), 1-21. <https://doi.org/10.1371/journal.pcbi.1008856>.
- Duan, Y., Edwards, J. S. y Dwivedi, Y. K. (2019). Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. *International Journal of Information Management*, 48, 63–71.
- Ganapati, S., Notteboom, T. y Rodrigue, J.-P. (2023). Far trade: the shifting geography of long-distance containerized maritime trade. *Journal of Transport Geography*, 104, 103528.
- Ganapati, S., Wong, W. F. (2023). How far goods travel: global transport and supply chains from 1965–2020. *Journal of Economic Perspectives*, 37(3), 3–30.
- Goodfellow, I., Bengio, Y. y Courville, A. (2018). *Deep Learning*. MIT Press.
- He, K., Zhang, X., Ren, S. y Sun, J. (2016). Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- Hinton, G. E., Osindero, S. y Teh, Y.-W. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 18(7), 1527–1554.
- Hochreiter, S. y Schmidhuber, J. (1997a). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
- Hochreiter, S. y Schmidhuber, J. (1997b). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Ioffe, S. y Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *International conference on machine learning*, pmlr, 448–456.
- Khedr, A. M. y Rani, S. (2024). Enhancing supply chain management with deep learning and machine learning techniques: A review. *Journal of Open Innovation: Technology, Market, and Complexity*, 10(4), 100379. <https://www.sciencedirect.com/science/article/pii/S2199853124001732>.
- Krizhevsky, A., Sutskever, I. y Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems*, 1097–1105.
- LeCun, Y., Bottou, L., Bengio, Y. y Haffner, P. (1998). Gradientbased learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Lee, H., Grosse, R., Ranganath, R. y Ng, A. Y. (2009). Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. *Proceedings of the 26th International Conference on Machine Learning*, 609–616.
- Li, C. y Wang, Y. (2024). Digital transformation and enterprise resilience: Enabling or burdening? *Plos One*, 19(7), e0305615.
- Li, Z., Chen, F., Lu, P. y Xu, J. (2024). Digital twin-driven sustainable shipping logistics: a conceptual framework. *Transportation Research Part E: Logistics and Transportation Review*, 184, 103698.
- Notteboom, T., Pallis, A. y Rodrigue, J.-P. (2021a). Disruptions and resilience in global container shipping and ports: the COVID-19 pandemic and the 2020–2022 crisis. *Maritime Economics & Logistics*, 23(3), 295–319.
- Notteboom, T., Pallis, T. y Rodrigue, J.-P. (2021b). Disruptions and resilience in global container shipping and ports: the COVID-19 pandemic versus the 2008–2009 financial crisis. *Maritime Economics & Logistics*, 23(2), 179.
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N. y Prabhat (2019). Deep

- learning and process understanding for data-driven Earth system science. *Nature*, 566, 195–204.
- Salakhutdinov, R. y Hinton, G. E. (2009). Deep boltzmann machines. *Proceedings of Machine Learning Research*, 448–455.
- Sharma, R., Shishodia, A., Gunasekaran, A., Min, H. y Haque, Z. (2022). The role of artificial intelligence in supply chain management: mapping the territory. *International Journal of Production Research*, 60(24), 7527–7550.
- Singh, A., Wiktorsson, M. y Baalsrud, J. (2021). Trends in machine learning to solve problems in logistics. *Procedia CIRP*, 104, 67–72.