



ESCUELA DE HÁBITAT, INFRAESTRUCTURA Y CREATIVIDAD

Tema:

MODELO DE PREDICCIÓN DEL CONSUMO DE COMBUSTIBLE CON REDES NEURONALES PARA UNA ESTACIÓN DE SERVICIO

**Proyecto de investigación previo a la obtención de título de Ingeniero en
Sistemas de la Información**

Línea de investigación:

**DISEÑO, INFRAESTRUCTURA Y SISTEMAS SOCIALES Y AMBIENTALES PARA
UN HÁBITAT SOSTENIBLE**

Autor:

Eduardo Javier Oña Chiriboga

Director:

Mg. Edison Fernando Meneses Torres

Ambato – Ecuador

Julio 2026

DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD

Yo: **EDUARDO JAVIER OÑA CHIRIBOGA**, con CC. **0503959645**, autor del trabajo de graduación intitulado: "MODELO DE PREDICCIÓN DEL CONSUMO DE COMBUSTIBLE CON REDES NEURONALES PARA UNA ESTACION DE SERVICIO", previo a la obtención del título profesional de **INGENIERO EN SISTEMAS DE LA INFORMACIÓN**, en la **ESCUELA DE HÁBITAT, INFRAESTRUCTURA Y CREATIVIDAD**.

1. Declaro tener pleno conocimiento de la obligación que tiene la Pontificia Universidad Católica del Ecuador, 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 graduación para que sea integrado.
2. Autorizo a la Pontificia Universidad Católica del Ecuador a difundir a través de sitio web de la Biblioteca de la PUCE Ambato, el referido trabajo de graduación, respetando las políticas de propiedad intelectual de la Universidad.

Ambato julio 2026



EDUARDO JAVIER OÑA CHIRIBOGA
CC. 0503959645

PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR SEDE AMBATO iii
APROBACIÓN DEL TRIBUNAL DE GRADO

Tema:

**MODELO DE PREDICCIÓN DEL CONSUMO DE COMBUSTIBLE CON REDES
NEURONALES PARA UNA ESTACIÓN DE SERVICIO**

Líneas de Investigación:

**DISEÑO, INFRAESTRUCTURA Y SISTEMAS SOCIALES Y AMBIENTALES
PARA UN HÁBITAT SOSTENIBLE**

Autor:

Eduardo Javier Oña Chiriboga

Edison Fernando Meneses Torres, Ing. Mg.


CC. 1714355482

CALIFICADOR

f. 

Liliana del Rocío Mena Hernández, Ing. Mg.

CALIFICADOR

f. 

Verónica Maribel Pailiacho Mena, Ing. Mg.

CALIFICADOR

f. 

Francisco Javier Echeverría Tamayo, Ing. Mg.

**DIRECTOR ESCUELA DE HÁBITAT, INFRAESTRUCTURA
Y CREATIVIDAD**

f. 

Diego Gonzalo Coca Chanalata, Dr. Mg.

PROSECRETARIO PUCESA

f. 

Ambato-Ecuador

Julio 2026

 **PUCE** | AMBATO
PROSECRETARÍA

DEDICATORIA

A mis padres, por sostenerme en cada paso de este camino no solo con su apoyo material, sino con la confianza y la paciencia que solo ellos supieron darme.

A mis abuelos.

A mi abuelo, que ya no está físicamente conmigo, pero cuyas enseñanzas me acompañan en cada decisión. Me inculcó desde pequeño el valor del esfuerzo, la honestidad y hacer las cosas bien, aunque nadie estuviera mirando. Este logro también lleva su nombre.

A mi abuela, por estar siempre presente, por creer en mí y por su apoyo constante durante todos estos años de estudio.

Este trabajo es también de ustedes cuatro.

Eduardo Javier

AGRADECIMIENTO

El camino hasta llegar a estas páginas no fue lineal ni sencillo. Hubo momentos, sobre todo, al inicio, en los que me sentí perdido, sin saber muy bien por dónde empezar ni cómo dar el siguiente paso. Si logré avanzar fue porque no estuve solo. Agradezco profundamente a mis padres, quienes fueron el sostén constante de este proceso. Su apoyo económico hizo posible que pudiera dedicarme a estudiar, pero más allá de eso, fue su presencia diaria, su confianza y su ejemplo lo que me permitió seguir cuando las cosas se complicaban. Nada de lo que aquí se presenta habría sido posible sin ellos.

Al Mg. Edison Fernando Meneses Torres, director de este trabajo de titulación, le agradezco su guía, su paciencia y las observaciones oportunas que me ayudaron a dar forma a esta investigación. Su acompañamiento fue clave en las etapas donde más lo necesité.

A los docentes de la PUCE Sede Ambato, por acompañarme durante todo el proceso, por sus aportes en cada revisión y por la disposición con la que atendieron mis dudas a lo largo del desarrollo del proyecto.

A la Pontificia Universidad Católica del Ecuador Sede Ambato, y en particular a la carrera de Ingeniería en Sistemas de Información, por la formación recibida durante estos años, que hizo posible este trabajo.

A todas las personas que, de una u otra forma, aportaron un consejo, una idea o una palabra de aliento en el momento justo gracias.

Eduardo Javier

RESUMEN

La presente investigación desarrolla un modelo de predicción del consumo de combustible basado en redes neuronales para la Estación de Servicio Divino Niño, comercializadora Petroecuador, ubicada en Latacunga, Ecuador. La estación sustentaba sus decisiones de abastecimiento en estimaciones empíricas con márgenes de error de entre el 3 % y el 8 % en condiciones normales, con desfases mayores en períodos de alta demanda, lo que generaba episodios recurrentes de sobre almacenamiento y quiebres de stock.

La metodología es de tipo aplicada con enfoque mixto secuencial. La fase cuantitativa analiza 466.137 registros transaccionales de gasolina extra, súper y diésel del período febrero 2022 – noviembre 2025, consolidados en 1.368 observaciones diarias. La fase cualitativa documenta variables operativas y eventos exógenos mediante una Guía de Entrevista Técnica Estructurada aplicada al personal técnico-administrativo de la estación.

Se implementaron y compararon cuatro arquitecturas de redes neuronales recurrentes — LSTM, BiLSTM, CNN-LSTM y LSTM Multivariante — frente a un modelo de referencia estadístico. La arquitectura BiLSTM resultó ganadora con el mayor coeficiente de determinación promedio ($R^2 = 0,1606$) y el menor error porcentual promedio (sMAPE = 22,69 %). El modelo supera al referencial en diésel, reduciendo el MAE de 383,12 a 311,01 galones y elevando el R^2 de 0,179 a 0,434. Para la gasolina Extra, el error relativo de 13,28 % se sitúa dentro del umbral de tolerancia operativa de ± 15 % declarado por los operadores. El horizonte óptimo de predicción es de 7 días para Extra y diésel, coincidiendo con la frecuencia de planificación preferida por el personal de la estación.

Palabras claves: Inteligencia artificial, BiLSTM, redes neuronales recurrentes, predicción de demanda, estación de servicio, series temporales.

ABSTRACT

This study develops a fuel consumption forecasting model based on recurrent neural networks for the Divino Niño service station, a Petroecuador retail outlet located in Latacunga, Ecuador. Prior to this research, the station relied on empirical forecasting methods with error margins ranging from 3 % to 8 % under normal operating conditions and substantially larger deviations during periods of peak demand, resulting in recurrent stockouts and excess inventory that affected both operational continuity and commercial performance. The study adopts an applied research methodology with a sequential mixed-methods design. The quantitative phase analyzes 466,137 fuel dispatch transactions across three fuel types—Extra gasoline, Super gasoline, and diesel—covering the period from February 2022 to November 2025 and aggregated into 1,368 daily observations. The qualitative phase identifies operational variables and exogenous events through a structured technical interview conducted with the station's operational decision-makers. Four recurrent neural network architectures—LSTM, BiLSTM, CNN-LSTM, and Multivariate LSTM—were developed and compared with a statistical baseline model. Among them, the BiLSTM architecture achieved the best overall performance, obtaining the highest average coefficient of determination ($R^2 = 0.1606$) and the lowest average symmetric mean absolute percentage error (sMAPE = 22.69 %). The model outperformed the baseline for diesel forecasting, reducing the mean absolute error (MAE) from 383.12 to 311.01 gallons and increasing the coefficient of determination (R^2) from 0.179 to 0.434. For Extra gasoline, the relative forecasting error of 13.28 % remained within the ± 15 % operational tolerance established by station personnel. The optimal forecasting horizon was seven days for both Extra gasoline and diesel, consistent with the inventory replenishment cycle identified during the qualitative phase.

Keywords: Artificial intelligence, BiLSTM, recurrent neural networks, demand forecasting, service station, time series.

ÍNDICE GENERAL DE CONTENIDOS

DECLARACIÓN DE AUTENTICIDAD Y RESPONSABILIDAD	ii
APROBACIÓN DEL TRIBUNAL DE GRADO	iii
DEDICATORIA	iv
AGRADECIMIENTO	v
RESUMEN	vi
ABSTRACT	vii
INTRODUCCIÓN	1
CAPÍTULO I. ESTADO DEL ARTE Y LA PRÁCTICA	4
1.1. Estado del arte en la predicción de demanda para el sector de hidro- carburos	4
1.2. Análisis comparativo: Métodos estadísticos vs. Redes Neuronales . .	6
1.3. Desafíos en la calidad y estructuración de datos transaccionales en el sector minorista	8
CAPÍTULO II. DISEÑO METODOLÓGICO	11
2.1. Metodología de la investigación	11
2.2. Técnica e instrumento de recolección de datos	12
2.3. Metodología de desarrollo del sistema de predicción	14
CAPÍTULO III. ANÁLISIS DE LOS RESULTADOS DE LA INVESTIGACIÓN . .	18
3.1. Análisis exploratorio de datos	18
3.2. Diseño y entrenamiento de las arquitecturas de redes neuronales . . .	22
3.3. Evaluación del modelo BiLSTM seleccionado	25
3.4. Proyecciones futuras del modelo BiLSTM	30
3.5. Validación del modelo con datos reales	33
CONCLUSIONES	39
RECOMENDACIONES	41
BIBLIOGRAFÍA	43
ANEXOS	45

INTRODUCCIÓN

En el panorama económico mundial actual, la industria de los hidrocarburos continúa siendo un pilar fundamental para el desarrollo y la movilidad de las naciones. En este escenario, las estaciones de servicio juegan un rol indispensable como el último eslabón de la cadena, siendo responsables de garantizar la disponibilidad continua de productos esenciales como la gasolina y el diésel para el transporte y la industria. Según (Arceo, Bersten, & Wainer, 2022) la evolución del consumo primario de energía a nivel mundial permite inferir que, pese al inicio del proceso de transición energética, los combustibles fósiles seguirán teniendo un papel crítico en las próximas décadas. En efecto, entre el año 2000 y 2019, el consumo primario de energía se incrementó a una tasa anual acumulativa del 2,2 %.

Los retos derivados de métodos de suministro y patrones de demanda tan diversos incluyen el hacinamiento en los almacenes, el gasto excesivo, la caducidad de las piezas de repuesto almacenadas y la dificultad para mantener registros de inventario precisos. (Alwadi, 2025, p. 2)

En este contexto, la Inteligencia Artificial, ha emergido como herramientas disruptivas capaces de transformar la toma de decisiones. A diferencia de los modelos estadísticos clásicos, que a menudo fallan al intentar capturar patrones no lineales y dependencias a largo plazo en series temporales complejas, las Redes Neuronales Recurrentes (*RNN*) ofrecen una capacidad superior para modelar el comportamiento del consumo. Esta evolución tecnológica plantea un nuevo paradigma donde los datos históricos transaccionales dejan de ser simples registros contables para convertirse en activos estratégicos de predicción.

En este contexto, la Estación de Servicio Divino Niño, comercializadora Petroecuador, ubicada en la ciudad de Latacunga, provincia de Cotopaxi, enfrenta una problemática operativa concreta: la gestión del inventario de combustible gasolina extra, gasolina súper y diésel depende de estimaciones manuales, de lo vendido en semanas pasadas.

El exceso de almacenamiento en periodos de baja demanda o la falta de stock en fechas importantes por una alta demanda, afecta de forma negativa la imagen de la estación de servicio. Además, la ausencia de una herramienta de predicción impide prever una posible demanda para optimizar las decisiones y el control de inventarios.

Ante esta realidad, la presente investigación plantea el desarrollo de un modelo de predicción del consumo de combustible basado en redes neuronales, con el objetivo general de desarrollar un modelo de predicción del consumo de combustible con redes neuronales para una estación de servicio.

Para alcanzar este propósito, se establecen cuatro objetivos específicos: primero, fundamentar el desarrollo del modelo mediante una revisión del estado del arte en predicción de demanda para el sector de hidrocarburos; segundo, diagnosticar el estado actual del consumo de combustible en la estación mediante el análisis de sus registros históricos transaccionales; tercero, aplicar conceptos de redes neuronales en el desarrollo del modelo predictivo; y cuarto, Evaluar el desempeño predictivo del modelo mediante su comparación con registros históricos de consumo real correspondientes a un período de prueba de al menos 30 días, no incluido en el entrenamiento.

La metodología adoptada es de tipo aplicada con enfoque mixto secuencial. La fase cuantitativa se basa en el análisis documental de 466.137 transacciones de despacho de combustible registradas entre febrero de 2022 y noviembre de 2025, con las que se entrena el modelo. Mediante una Guía de Entrevista Técnica Estructurada (GETE) aplicada al personal administrativo de la estación de servicio, la fase cualitativa recoge los factores que el sistema de ventas no registra.

El modelo implementado como arquitectura ganadora corresponde a la red neuronal BiLSTM (Bidirectional Long Short-Term Memory), entrenada en TensorFlow/Keras y evaluada comparativamente frente a tres arquitecturas adicionales LSTM univariante, CNN-LSTM y LSTM Multivariante y un modelo de referencia estadístico, mediante las métricas MAE, RMSE, sMAPE y R^2 .

El presente documento se organiza en tres capítulos. El Capítulo I desarrolla el estado del arte y la práctica y presenta una revisión crítica de los métodos estadísticos clásicos y las arquitecturas de inteligencia artificial aplicadas a la predicción de demanda en el sector de hidrocarburos, así como los desafíos en la calidad y estructuración de datos transaccionales.

El Capítulo II describe el diseño metodológico de la investigación, que incluye la población y muestra, las técnicas e instrumentos de recolección de datos, y el proceso de desarrollo del sistema predictivo en sus cuatro fases: adquisición y preproce-

samiento de datos, análisis exploratorio, construcción del modelo y evaluación de resultados.

El Capítulo III presenta el análisis de resultados e integra los hallazgos cuantitativos del modelo con las evidencias cualitativas obtenidas mediante la entrevista técnica estructurada, para concluir con las proyecciones de demanda para el año 2026 y las recomendaciones operativas para la gestión de inventario de la estación.

CAPÍTULO I. ESTADO DEL ARTE Y LA PRÁCTICA

Históricamente, la predicción de demanda se basaba en modelos estadísticos lineales como ARIMA, eficaces en entornos estables pero limitados frente a variables exógenas y dependencias no lineales (Hossain, Shams, & Ullah, 2025; Ning, Kaze-mi, & Tahmasebi, 2022). Ante la actual volatilidad del mercado, la literatura destaca la superioridad de la inteligencia artificial específicamente las redes LSTM y los enfoques híbridos para procesar grandes volúmenes de datos históricos y capturar fluctuaciones de ventas altamente dinámicas (Alwadi, 2025; Hossain et al., 2025). Si bien la implementación de estos modelos predictivos enfrenta desafíos de escalabilidad, restricciones computacionales y el ruido generado por factores externos no registrados en las estaciones de servicio (Dritsas & Trigka, 2025), estas barreras se mitigan con una rigurosa división de los datos de entrenamiento y con la validación de la eficacia algorítmica mediante métricas estandarizadas como el Error Cuadrático Medio y el Error Absoluto Medio para evitar el sobreajuste.

1.1. Estado del arte en la predicción de demanda para el sector de hidrocarburos

Sin embargo, intentar aplicar esta estadística lineal a la realidad actual de una estación de servicio resulta en un error técnico, debido a que los datos transaccionales modernos están caracterizados por un alto nivel de ruido y volatilidad. Por ello los promedios y tendencias lineales pierden fiabilidad en este contexto. Las redes neuronales recurrentes como LSTM ofrecen una alternativa, modelan relaciones no lineales y ayudan a generar pronósticos aplicables a la operación, aunque su ventaja no es automática.

Al respecto, (Hossain et al., 2025) constatan que el aprendizaje profundo ha desplazado a la estadística clásica en el sector energético:

Ante estas restricciones, el estado del arte actual ha girado hacia la implementación de técnicas de Inteligencia Artificial, específicamente algoritmos de Aprendizaje Automático (*Machine Learning*). Investigaciones recientes destacan la superioridad del Aprendizaje Profundo (*Deep Learning*) para modelar series temporales complejas en el sector energético. El uso de redes neuronales permite procesar grandes vo-

lúmenes de datos históricos y detectar patrones ocultos que escapen al análisis estadístico convencional, lo que marca el inicio de una nueva era en la logística predictiva de combustibles caracterizada por una toma de decisiones proactiva y basada en datos (*data-driven*). (Hossain et al., 2025)

Al documentar este fenómeno mediante un hallazgo empírico donde los algoritmos de árboles de decisión sorpresivamente superaron a las redes neuronales ante la alta inestabilidad del mercado, (Alwadi, 2025) expresa:

Los modelos de aprendizaje profundo, como LSTM, han demostrado un buen rendimiento en datos secuenciales. Sin embargo, los resultados de este estudio muestran que Random Forest (RF) superó a LSTM en el manejo de datos volátiles de ventas de combustible. Esto difiere de estudios anteriores que enfatizaban la fortaleza de LSTM, lo que sugiere que los modelos basados en árboles pueden ser más adecuados para entornos de ventas altamente dinámicos. Para mejorar la generalización, las investigaciones futuras deberían explorar métodos de conjunto que combinen RF con aprendizaje profundo para optimizar la precisión en diferentes condiciones de mercado. (Alwadi, 2025)

Por último, gana terreno la adopción de enfoques híbridos. Estudios recientes (Hossain et al., 2025; Ning et al., 2022) combinan ARIMA para la tendencia lineal y LSTM para los residuos no lineales, uniendo interpretabilidad y precisión. Esto respalda la decisión de este proyecto: comparar varias arquitecturas para identificar cuál responde mejor a la gestión de inventarios.

El *dataset* utilizado en el presente proyecto es del registro histórico de transacciones de despacho de combustible de la Estación de Servicio Divino Niño, que consta de un volumen considerable de transacciones distribuidas en tres tipos de hidrocarburos: diésel, extra y súper, a lo largo de casi cuatro años de operación continua. Con un predominio del combustible extra en frecuencia de transacciones que es determinante en la elección de un modelo que pueda capturar patrones diferenciados por tipo de producto el detalle cuantitativo del *dataset* se presenta en el Capítulo II.

1.2. Análisis comparativo: Métodos estadísticos vs. Redes Neuronales

Antiguamente, al realizar la gestión de inventarios se ha apoyado en la experiencia del administrador y promedios simples. en un mercado con fluctuaciones imprevistas, los cuales estos métodos presentan límites. Mientras que el error resultante se traduce en pérdidas de stock de inventario. Esto alienta a explorar modelos de predicción más sistemáticos, sin asumir que reemplazaran por completo el criterio humano.

Al exponer la complejidad inherente a esta labor y reconocer que la dependencia de enfoques empíricos o convencionales representa un desafío crítico en el mercado actual, (Ahmed, Hasnain, Mahmood, & Mehmood, 2024) observan:

Se utilizan métodos estadísticos, planificación humana o una combinación de ambos para realizar previsiones. El proceso de predecir las necesidades o tendencias futuras está plagado de dificultades y es una tendencia emergente en el mercado. Para realizar las previsiones se utilizan algunos enfoques estadísticos, la planificación humana o una combinación de ambos. (Ahmed et al., 2024)

El entrenamiento de arquitecturas de aprendizaje profundo, como las redes LSTM, exige una capacidad de procesamiento matricial que frecuentemente supera los límites del hardware local convencional. Para evitar cuellos de botella durante las fases de iteración y ajuste de hiperparámetros, resulta imperativo trasladar el entorno de desarrollo hacia infraestructuras escalables. Como decisión de ingeniería, la adopción de plataformas interactivas basadas en la nube y respaldadas por librerías estándar de la industria garantiza no solo la reproducibilidad del experimento, sino también una drástica reducción en los tiempos de cómputo gracias a la aceleración por hardware (GPU/TPU).

En respaldo de esta decisión arquitectónica, al destacar el valor de centralizar el desarrollo en entornos en la nube para agilizar la codificación matemática, (Huillca Diaz, 2024) argumenta:

En el proceso de programación y análisis exploratorio de datos, se optó por aprovechar la versatilidad de Google Colab como biblioteca de codificación Tensor Flow. Esta elección estratégica no solo facilitó la ejecución de código de manera eficiente, sino que también proporcionó acceso a recursos compartidos y herramientas en la

nube, esto ayudó a para el proceso de codificación del modelo de redes neuronales artificiales LSTM. (Huillca Diaz, 2024)

El entrenamiento de la red LSTM implica cálculos matriciales repetidos sobre las series de ventas, por lo que programarlos desde cero resulta poco eficiente, el proyecto usa *TensorFlow* una librería optimizada para este tipo de operaciones, esto permite concentrarse en el diseño del modelo en lugar de los cálculos de bajo nivel.

La herramienta elegida para ese procesamiento es *TensorFlow*, (Chollet, 2021) la define de la siguiente manera:

TensorFlow es una plataforma de aprendizaje automático gratuita y de código abierto basada en Python, desarrollada principalmente por Google. Al igual que *NumPy*, el objetivo principal de *TensorFlow* es permitir a los ingenieros e investigadores manipular expresiones matemáticas sobre tensores numéricos. (Chollet, 2021, p. 69)

La elección del lenguaje base no responde una preferencia personal, sino que responde a criterios de estandarización. El proyecto usa Python: sus librerías especializadas en tensores y análisis estadístico, y el respaldo de la comunidad cubren lo que el trabajo necesita.

En la misma obra, (Chollet, 2021, p. 20) añade:

El punto en común de estas herramientas es que todas son bibliotecas de Python: Python es, con diferencia, el lenguaje más utilizado para el aprendizaje automático y la ciencia de datos. (Chollet, 2021, p. 20).

El proyecto emplea *TensorFlow* para las redes neuronales recurrentes y *scikit-learn* para el modelo de referencia estadístico. La selección responde al tipo de datos: series con una estacionalidad semanal marcada pero alta variabilidad dentro del día, lo que justifica comparar arquitecturas profundas con modelos de *gradient boosting* (Makridakis, Spiliotis, & Assimakopoulos, 2022).

La selección de una arquitectura no asume que el modelo más complejo o popular dará siempre el mejor resultado. En predicción de demanda, las series con baja volatilidad o tendencias estables se modelan bien con algoritmos simples y de menor consumo computacional. Por eso, usar una red neuronal solo se justifica si supera de forma medible a un modelo base estadístico (*baseline*). De lo contrario, no hay razón para descartar la econometría tradicional.

La literatura confirma este riesgo, (Feizabadi, 2022) sostiene:

Existen resultados no concluyentes en el uso de métodos de aprendizaje automático para la previsión de la demanda. Por ejemplo, algunos investigadores descubrieron que métodos tradicionales como el suavizado exponencial y el suavizado exponencial de Winters arrojaron una precisión de pronóstico comparable o, en ocasiones, superior a la de las redes neuronales artificiales (*ANN*). (Feizabadi, 2022)

La capacidad de las redes recurrentes para asimilar dependencias complejas en redes inteligentes y superar la precisión de los modelos *ARIMA* en pronósticos energéticos, (Hossain et al., 2025) destacan:

Las redes de memoria a corto y largo plazo (*LSTM*), un tipo de red neuronal recurrente (*RNN*), ofrecen fuertes capacidades para aprender dependencias temporales en secuencias largas. Han superado a *ARIMA* y otros modelos estadísticos en tareas de pronóstico de energía, especialmente en el manejo de patrones no lineales y demostraron que los modelos basados en *LSTM* superaron significativamente a los modelos tradicionales como *ARIMA* en el pronóstico de la producción de energía eólica en sistemas de redes inteligentes. Estudios recientes han avanzado aún más en el uso del aprendizaje profundo para el pronóstico de energía renovable al optimizar las arquitecturas de red e integrar características meteorológicas y temporales relevantes. (Hossain et al., 2025)

La arquitectura híbrida CNN-LSTM combina la extracción de rasgos locales mediante capas convolucionales con el aprendizaje de tendencias a largo plazo. Esta investigación evalúa comparativamente cuatro configuraciones LSTM univariante, BiLSTM, CNN-LSTM y LSTM Multivariante para determinar cuál se ajusta mejor a la proyección de consumo de combustible para una estación de servicio.

1.3. Desafíos en la calidad y estructuración de datos transaccionales en el sector minorista

En el contexto de una estación de servicio, la composición de los datos enfrenta la dificultad adicional de la variabilidad exógena. La demanda de combustible no es una serie temporal aislada; está fuertemente correlacionada con eventos externos que a menudo no quedan registrados en la base de datos transaccional, como cam-


bios repentinos en la regulación de precios, cierres viales o condiciones climáticas adversas. Si estos eventos atípicos (*outliers*) no son identificados correctamente durante la etapa de preprocesamiento, el modelo interpreta estas anomalías como un patrón normal, lo que degrada la precisión del pronóstico futuro. Esto obliga al investigador a realizar una labor exhaustiva de ingeniería de características para enriquecer los datos histórica con variables de contexto.

En la ingeniería de datos, el rendimiento de una red neuronal está directamente relacionada con la calidad estructural de la información que este recibe. Los registros transaccionales crudos de una estación de servicio suelen presentar formatos heterogéneos, valores atípicos y ruido operativo que imposibilitan su procesamiento directo por una arquitectura LSTM. Antes de eso toca iniciar cualquier fase de modelado matemático, resulta indispensable diseñar un flujo de procesamiento robusto que extraiga, limpie y unifique los históricos de ventas, transformándolos desde el sistema contable tradicional hacia matrices estandarizadas óptimas para el aprendizaje automático.

Al esquematizar la arquitectura técnica de este proceso de unificación para transformar orígenes heterogéneos en información lista para el análisis, (Verma, 2024) explica:

Estos pipelines incluyen ETL (figura 1.1), que se componen de las fases de extracción, transformación y carga, a través de las cuales los datos provenientes de orígenes con diferente tipo de dato, frecuencia y formato son recopilados, convertidos a una estructura de entrada armonizada, y almacenados en un almacén de datos (*data warehouse*) o en un lago de datos (*data lake*) para su análisis. (Verma, 2024)

Gráfico 1.1. Proceso ETL en los pipelines de datos.



Fuente: tomado a partir de Verma (2024).

La implementación de algoritmos de IA trasciende de mera formulación matemática; exige confrontar los desafíos operativos y técnicos inherentes al entorno real del negocio. En la gestión de una estación de servicio, la construcción de un modelo predictivo robusto lidia con bases de datos transaccionales imperfectas, la influencia de variables exógenas y limitaciones de hardware para el procesamiento continua. Resulta imperativo reconocer, que una solución tecnológica es viable si se gestionan adecuadamente los problemas de escalabilidad y la naturaleza de caja negra de las redes neuronales, de modo que los pronósticos sean interpretables, transparentes y directamente aplicables para tener como referencia a la hora de tomar decisiones administrativas.

Al evidenciar que el impacto transformador del aprendizaje automático está supeditado a la superación de estas complejas barreras de interpretabilidad, privacidad y escalabilidad computacional, (Dritsas & Trigka, 2025, p. 8) advierten:

A pesar del impacto transformador del ML en el comercio electrónico, varios retos y limitaciones dificultan su implementación y optimización sin fisuras. La creciente complejidad del comercio digital, junto con los vastos y cambiantes conjuntos de datos, presenta obstáculos que van desde preocupaciones sobre la privacidad de los datos y problemas de interpretabilidad hasta restricciones computacionales y limitaciones de escalabilidad. Abordar estos retos es crucial para garantizar implementaciones robustas, eficientes y éticas de soluciones de comercio electrónico impulsadas por el ML. (Dritsas & Trigka, 2025, p. 8)

CAPÍTULO II. DISEÑO METODOLÓGICO

El capítulo describe el diseño metodológico de la investigación. Se detalla el tipo y enfoque del estudio, los universos del análisis y el muestreo, las técnicas e instrumentos de recolección de datos y el proceso de desarrollo del modelo predictivo organizado en fases secuenciales.

2.1. Metodología de la investigación

La presente investigación adopta un diseño no experimental, de corte longitudinal y enfoque mixto secuencial (Cuan → cual). En la fase cuantitativa se realiza el análisis documental de los registros transaccionales de ventas de combustible de la Estación de Servicio Divino Niño, Comercializadora Petroecuador, ubicada en la ciudad de Latacunga, provincia de Cotopaxi, que corresponden al período entre febrero de 2022 y noviembre de 2025. Dicho diseño se sustenta en la propuesta metodológica (Creswell & Creswell, 2023), que sostienen que los diseños mixtos secuenciales permiten una comprensión más completa y profunda de los fenómenos complejos cuando una sola fuente de datos resulta insuficiente.

La fase cualitativa complementa el análisis cuantitativo mediante la recolección de la información primaria a través de la Guía de Entrevista Técnica Estructurada (GETE), que se aplica al personal administrativo encargado de tomar la decisión directa sobre el inventario y el abastecimiento de la estación de servicio.

Población y muestra

La presente investigación necesita dos análisis que son diferentes el uno al otro, pero complementarios, ambos delimitados al caso de la Estación de Servicio. El primero es documental y está constituido por los registros transaccionales generados por la estación durante el período comprendido entre febrero de 2022 y noviembre de 2025.

El componente de análisis es el sistema de facturación que es donde se almacenan las transacciones individuales de despacho de combustible automotriz, para sus di-

ferentes hidrocarburos: extra, súper y diésel. Cada registro incluye marca de tiempo, producto despachado, surtidor de origen, volumen en galones, precio unitario vigente y valor total de la operación. El período elegido contiene cuarenta y cinco meses de operación continua, que captura ciclos estacionales completos diarios, semanales y anuales, y al menos dos cambios estructurales de la política de precios del mercado ecuatoriano.

Dicha decisión tiene como fin el aprendizaje supervisado de una arquitectura BiLSTM que exige el mayor volumen disponible de datos para evitar el sobreajuste. Cuando la población es finita y accesible, el enfoque adecuado es el censo, es decir, incluir la totalidad de los casos en lugar de seleccionar una muestra representativa (Hernández-Sampieri & Mendoza, 2018). En este caso la Estación Divino Niño dispone de un sistema que registra cada despacho con precisión de segundos, lo que permite construir series temporales de alta frecuencia, condición necesaria para el entrenamiento de redes neuronales recurrentes. El acceso a los datos se realizó mediante una carta de autorización (Anexo A).

El segundo universo es humano y está constituido por el personal administrativo que toma las decisiones de inventario, abastecimiento y despacho en la estación de servicio. Su tamaño es finito y reducido ($N=2$): el administrador y su asistente de operaciones. El muestreo es censal, por lo que la entrevista se realiza a la totalidad del personal capacitado en tomar decisiones sobre el problema estudiado, esto garantiza cobertura completa del conocimiento operativo no registrado en la base de datos. Es coherente con la guía metodológica de (Vizcaíno Zúñiga, Cedeño Cedeño, & Maldonado Palacios, 2023) para investigaciones aplicadas con poblaciones finitas y delimitadas.

2.2. Técnica e instrumento de recolección de datos

La investigación usa dos técnicas para la recolección de los datos, diferentes por su naturaleza. Para la fase cuantitativa la técnica es el análisis documental, cuyo instrumento es la base de datos transaccional del sistema de punto de venta de la estación. Su uso se valida por ser de carácter oficial, dado que los registros generados y auditados por el sistema transaccional garantizan la confiabilidad de los datos. La descripción detallada de las variables que la componen se encuentra en la sección de base de datos y entorno tecnológico.

Para la fase cualitativa, la técnica es la entrevista estructurada, cuyo instrumento es la Guía de Entrevista Técnica Estructurada (GETE) diseñada para el estudio (Anexo B). La elección del instrumento se fundamenta (Creswell & Creswell, 2023), quienes recomiendan la entrevista estructurada cuando se necesita garantizar la comparabilidad entre informantes y reducir el sesgo del entrevistador.

El instrumento se organiza en cinco bloques temáticos con un total de veinte ítems de respuesta abierta: el Bloque A indaga el régimen actual del pronóstico empírico, el Bloque B explora los umbrales operativos de inventario y las reglas heurísticas de abastecimiento, el Bloque C recoge la información sobre costos de error de pronósticos, el Bloque D registra los eventos exógenos relevantes no inscritos en la base transaccional y el Bloque E define los requerimientos funcionales del sistema predictivo. La aplicación de un guion fijo e idéntico para ambos participantes garantiza la comparabilidad de las respuestas, y siguiendo los criterios de consistencia y credibilidad propuestas por (Ibarra-Sáiz, González-Elorza, & Gómez, 2023) para la recolección de datos por medio de entrevistas de investigación cualitativas.

Bases de datos y entorno tecnológico

La base de datos primaria corresponde al sistema transaccional de la Estación de Servicio Divino Niño. El *dataset* contiene 466.137 transacciones individuales para el periodo de estudio distribuidas en los tres diferentes hidrocarburos: diésel con 119.127 transacciones, extra con 334.470 transacciones y súper con 12.540 transacciones; tras el tratado de los datos durante su procesamiento, el conjunto depurado asciende a 466.137 transacciones. Cada uno de los registros incluye: fecha y hora del despacho, tipo de combustible, volumen en galones, precio unitario vigente y valor total de la operación.

El procesamiento se realiza en Python 3.11 con las bibliotecas Pandas (McKinney, 2010) para la carga y transformación, de datos tabulares, NumPy (Harris et al., 2020) para operaciones matriciales, Scikit-learn (Pedregosa, Fabian et al., 2011) para normalización y partición, y TensorFlow/Keras (Chollet, 2021) para la construcción, entrenamiento y evaluación de las arquitecturas en las redes neuronales. La Tabla 1 detalla el ecosistema tecnológico completo del proyecto

Tabla 1. Herramientas tecnológicas utilizadas en el sistema de predicción de demanda de combustible

Herramienta / Biblioteca	Versión	Función en el proyecto	Referencia
Python	3.11	Lenguaje de programación principal	(Van Rossum & Drake, F. L., 2009)
Pandas	2.0.x	Carga, transformación y procesamiento de datos tabulares	(McKinney, 2010)
NumPy	1.24.x	Operaciones numéricas sobre arrays y matrices	(Harris et al., 2020)
scikit-learn	1.2.x	Modelo GradientBoostingRegressor y métricas de evaluación	(Pedregosa, Fabian et al., 2011)
skforecast	0.12.x	Implementación del modelo de referencia (GBR-Baseline)	(Amat Rodrigo & Escobar Ortiz, 2026)
Matplotlib	3.7.x	Visualización de series temporales y gráficos de resultados	(Hunter, 2007)
Seaborn	0.12.x	Visualización estadística (boxplots, distribuciones)	(Waskom, 2021)

Fuente: elaboración propia.

2.3. Metodología de desarrollo del sistema de predicción

El desarrollo del sistema se divide en cuatro fases metodológicas secuenciales, adquisición y preprocesamiento de datos, análisis exploratorio, construcción del modelo predictivo y evaluación de resultados. Dicho enfoque se ajusta con el ciclo estándar del desarrollo del proyecto de ciencia de datos, propuesto por (Adetunji & Ademola, 2014), que establece la secuencialidad entre etapas que son: preparación de datos, modelado y evaluación como condición necesaria para garantizar la reproducibilidad y la trazabilidad del proceso.

El código fuente se organiza en tres cuadernos *Jupyter Notebook* ejecutados en *Python* 3.11: 03_preprocesamiento_ed.ipynb, realiza el procesamiento y el análisis exploratorio; 04_entrenamiento_nn.ipynb, se implementan y entrenan las arquitecturas; y 05_predicciones_nn.ipynb, donde se generan las predicciones y proyecciones del modelo seleccionado.

En la fase uno es para la adquisición y preprocesamiento de datos mediante la biblioteca Pandas (McKinney, 2010) en la que se comprenden las siguientes operaciones: conversión del campo fecha al formato *datetime*, agregación de las transacciones individuales a nivel diario por tipo de combustible por medio de la suma del volumen

total despachado, eliminación de registros duplicados, y detección y tratamiento de valores atípicos usando el método de rango intercuartílico (IQR). Los resultados *dataset_diario.csv* (serie diaria consolidada), *dataset_limpio.csv* (conjunto depurado) y *dataset_features.csv* (con características adicionales) constituyen los insumos de las fases siguientes.

Consecuente sigue la fase dos que es el análisis exploratorio de datos (EDA) se ejecuta sobre el *dataset_diario.csv* con el objetivo de identificar los patrones temporales de la demanda antes del tratamiento. Estos hallazgos confirman una estacionalidad semanal definida: la gasolina extra concentra a su mayor demanda los viernes y sábados, mientras que el diésel alcanza sus volúmenes más altos de martes a jueves, y los domingos registran los mínimos en los tres productos. Esta regularidad, es un justificante para la incorporación de rezagos semanales por Hyndman y Athanasopoulos (2021), fundamenta la inclusión de *lag_7* como característica principal del modelo.

En la fase tres se realiza la construcción del modelo predictivo correspondiente a la arquitectura BiLSTM (*Bidirectional Long Short-Term Memory*) se seleccionó mediante la comparación empírica frente a tres arquitecturas alternativas LSTM unidireccional, CNN-LSTM y LSTM Multivariante y un modelo de referencia estadístico (GBR-Baseline). La arquitectura BiLSTM para capturar dependencias temporales bidireccionales en series de alta volatilidad ha sido documentada por (Hossain et al., 2025), quienes reportan su desempeño superior frente a modelos ARIMA y LSTM unidireccional en pronósticos energéticos.

Todas las arquitecturas neuronales se implementaron en *TensorFlow/Keras* (Chollet, 2021) con una ventana de entrada de 30 días, la normalización *MinMaxScaler* en el rango [0, 1], función de pérdida MSE y parada temprana (*early stopping*) con 20 épocas. Además de entrenar un modelo independiente por tipo de combustible, los patrones de demanda presentan escalas y dinámicas distintas, y por la recomendación de (Makridakis et al., 2022) sobre la separación de series con comportamientos heterogéneos.

La estrategia de validación que se usa es la partición temporal cronológica en tres conjuntos 70 % para entrenamiento desde febrero 2022 hasta octubre 2024, un 15 % para validación de las fechas entre octubre 2024 hasta abril 2025 y un 15 % para una prueba usando entre abril a noviembre 2025, conservando el orden temporal de dichas observaciones. Este enfoque mitiga la contaminación de datos futuros en

el entrenamiento, requisito fundamental del aprendizaje supervisado sobre series temporales señalado por (Makridakis et al., 2022). Las predicciones se generan para múltiples horizontes: diario, semanal y a 30 días con intervalos de confianza.

Para finalizar llegamos a la fase 4 evaluación y validación de resultados a todas las arquitecturas mediante cuatro métricas estandarizadas: Error Absoluto Medio (MAE), Raíz del Error Cuadrático Medio (RMSE), Error Porcentual Absoluto Medio Simétrico (sMAPE) y Coeficiente de Determinación (R^2). Para la selección del modelo ganador se basa en el R^2 promedio y la mayor exactitud direccional (DA) promedio, las métricas capturan tanto la capacidad explicativa del modelo frente a la varianza de la serie como su precisión operativa.

La integración de los resultados cuantitativos con lo encontrado de la GETE permite validar la pertinencia operativa del sistema y resalta las métricas obtenidas con el umbral de tolerancia al error $\pm 15\%$ declarado por los informantes clave. Los resultados del benchmarking y las predicciones generadas se presentan en el Capítulo III.

Resultados de la entrevista técnica estructurada

Con el fin de completar el análisis cuantitativo y ampliar la comprensión del fenómeno desde la perspectiva operativa, se aplica la GETE a los participantes de la estación, y a continuación se exponen la información más relevante.

En el Bloque A que tiene como objetivo el pronóstico empírico de demanda, los resultados muestran que la estación aplica un método de estimación basado en el promedio móvil de las ventas de los mismos días de las semanas anteriores. Por ejemplo, el participante reportó que las ventas de cuatro martes consecutivos de abril: martes 7 con 2.320,94 galones; martes 14 con 1.974,94 galones; y el martes 21 con 2.106,01 galones, lo que arroja un promedio de 2.133,96 galones. Comparando a una venta del martes 28 con 2.106,01 galones, y la diferencia fue de 62,24 galones, que equivale a un error del 2,8 %. Aunque este margen parece aceptable en condiciones normales, el mismo método genera desfases entre 3 % y 8 % en periodos de demanda atípica, en base a los propios informantes.

En el Bloque B que busca umbrales operativos de inventario, se detectaron los niveles mínimos de reorden por hidrocarburo: 375 galones para diésel, 175 galones para extra y 80 galones para súper. Estos umbrales responden a las características

técnicas de las bombas sumergibles de los tanques de almacenamiento, los cuales pueden sufrir daños por cavitación si el nivel está por debajo de los mínimos establecidos. El tiempo de respuesta del proveedor oscila entre una y tres horas desde la solicitud de recarga, el cual varía dependiente de la capacidad de despacho.

En el Bloque C que busca el costo del error de pronóstico, los informantes identificaron la subestimación de la demanda como el error de mayor impacto operativo, especialmente durante las fechas de feriados y fechas de alta demanda vehicular. La pérdida de clientes por desabastecimiento, la insatisfacción de los usuarios y el deterioro de la reputación de la estación presentan costos difícilmente recuperables y posibles problemas logísticos en la descarga. Los dos informantes coinciden en que el umbral de tolerancia al error, a partir del cual el modelo dejaría de ser útil sería de $\pm 15\%$.

En el Bloque D que extrae eventos exógenos no transaccionales, los participantes muestran como periodos de demanda atípica recurrente las festividades de Navidad y Año Nuevo, el regreso a clases y el Día de la Madre. Entre otros eventos no recurrentes, además se reportó el paro nacional de junio de 2022, con una duración aproximada de 18 días, el cual generó una caída considerable en las ventas de diésel y extra. También señalaron decretos de cierre vial en zonas cercanas a centros carcelarios, cambios en la política de subsidios de combustibles y cierres de rutas como factores que alteran significativamente la circulación y demanda para el consumo de hidrocarburo.

En el Bloque E que recoge requerimientos funcionales, los participantes señalaron que el pronóstico más útil para apoyar decisiones de abastecimiento es de 7 días, este periodo de tiempo permite planificar los pedidos de manera organizada sin generar desabastecimiento ni exceso de almacenamiento. En cuanto a la granularidad de salida, se prefirió un resultado por producto y el total diario. Respecto a la visualización, se valora un *dashboard* con exportación a Excel y semáforos de stock.


CAPÍTULO III. ANÁLISIS DE LOS RESULTADOS DE LA INVESTIGACIÓN

En el siguiente capítulo se expone los resultados obtenidos en el desarrollo del modelo de predicción, se presenta el análisis exploratorio de los datos, que identifica los patrones temporales de la demanda de combustible y sustenta las variables empleadas, además de describir el diseño y entrenamiento de las diferentes arquitecturas de redes neuronales evaluadas, así como la muestra de datos que condujo a la selección del modelo BiLSTM. Consecutivamente, se detalla la evaluación del modelo seleccionado producto por producto, mediante las curvas de aprendizaje, la comparación entre valores reales y predichos y las métricas finales. Finalmente, se exponen las proyecciones de demanda generadas en los meses siguientes junto con la validación del modelo frente a datos reales que no fueron incluidos en el entrenamiento, con la finalidad de verificar el desempeño en condiciones operativas.

3.1. Análisis exploratorio de datos

El análisis exploratorio de datos (*EDA*) se aplicó sobre el *dataset* de 1.364 registros diarios que corresponden al periodo entre febrero de 2022 y noviembre de 2025 para los 3 tipos de hidrocarburos: gasolina extra, gasolina súper y diésel. El objetivo de esta fase es identificar los patrones temporales de la demanda antes del entrenamiento de las arquitecturas de redes neuronales, poder detectar anomalías y justificar las diferentes variables para construir el modelo.


Gráfico 3.1. Series temporales diarias de volumen de despacho por tipo de combustible. Período febrero 2022 – noviembre 2025.



Fuente: elaboración propia.

El Gráfico 3.1 evidencia tres comportamientos diferenciados. La gasolina extra muestra un descenso sostenido a lo largo del período: parte de un promedio cercano a 1.400 galones diarios en 2022 y cae de forma marcada durante 2024, hasta estabilizarse alrededor de 640 galones en 2025. Este cambio es consistente con las modificaciones de política de subsidios reportadas por los entrevistados en la GETE. El diésel exhibe la mayor volatilidad, con picos que superan los 4.000 galones diarios en períodos de alta demanda agrícola o comercial, y caídas abruptas durante eventos de desabastecimiento, mientras que la gasolina súper se mantiene en volúmenes muy inferiores a los otros dos productos durante todo el período, sin una tendencia de crecimiento definida.


Gráfico 3.2. Volumen mensual de despacho por tipo de combustible. Período febrero 2022 – noviembre 2025.



Fuente: elaboración propia.

El Gráfico 3.2 confirma la asimetría de escala entre los tres productos: el diésel domina el volumen mensual, seguido por la extra, mientras que la súper representa apenas el 1,7 % del despacho total. Esa diferencia justifica entrenar un modelo de red neuronal por cada tipo de combustible, en lugar de uno solo compartido.

Gráfico 3.3. Distribución del volumen de ventas por día de la semana para gasolina extra, súper y diésel.




Fuente: elaboración propia.

El Gráfico 3.3 revela una estacionalidad semanal en los tres productos. En la gasolina extra, el viernes y el sábado concentran las medianas más altas, entre 900 y 940 galones, mientras que el domingo registra la más baja, cerca de 700. La gasolina súper se mantiene en niveles bajos y poco regulares durante la semana, con su mediana más alta el sábado, mientras que el diésel alcanza sus volúmenes medianos más altos de martes a jueves y cae con fuerza el fin de semana, hasta su mínimo el domingo, cerca de 1.020 galones, lo que refleja una menor actividad del trans-

porte de carga. Estos patrones justifican incluir el día de la semana como variable categórica y los rezagos semanales (lag_7) en las redes neuronales.

Gráfico 3.4. Matriz de correlaciones entre productos en días con ventas registradas.



Fuente: elaboración propia.


El Gráfico 3.4 muestra que la correlación entre extra y diésel es moderada $r = 0,480$, mientras que súper presenta correlaciones prácticamente nulas con ambos productos $r = 0,115$ con extra; $r = -0,004$ con diésel. Esta independencia de súper confirma que su demanda responde a factores distintos y refuerza la decisión de modelar cada combustible por separado.”

3.2. Diseño y entrenamiento de las arquitecturas de redes neuronales

Para la fase de modelado se implementaron y compararon cuatro arquitecturas de redes neuronales recurrentes: LSTM unidireccional, LSTM Bidireccional (BiLSTM), CNN-LSTM y LSTM Multivariante (LSTM-Multi). Como modelo de referencia se usó un *GradientBoostingRegressor* (GBR) implementado con *skforecast*, con rezagos de 1, 7 y 30 días.

El conjunto de datos se dividió cronológicamente en tres partes: 70 % para entrenamiento (febrero 2022 – octubre 2024), 15 % para validación (octubre 2024 – abril 2025) y 15 % para prueba (abril – noviembre 2025), preservando el orden temporal de las observaciones. Todos los modelos usaron una ventana de entrada (*look-back*) de 30 días y los datos se normalizaron con *MinMaxScaler* en el rango $[0, 1]$. El entrenamiento empleó el optimizador Adam y la función de pérdida MSE, con un máximo de 150 épocas y parada temprana (*early stopping*) de paciencia 20 sobre el conjunto de validación.

Gráfico 3.5. Comparación de arquitecturas según MAE promedio, sMAPE promedio y R^2 promedio en los tres productos.



Fuente: elaboración propia.

El Gráfico 3.5 muestra la comparación entre arquitecturas en promedio de los tres tipos de combustibles. En MAE promedio, el BiLSTM obtiene el valor más bajo de 138 galones, seguido por CNN-LSTM con 155 galones y GBR-Baseline con 159 galones. LSTM y LSTM-Multi registran los MAE más elevados de 172 y 175 galones respectivamente. En R^2 promedio, el BiLSTM y el GBR-Baseline lideran con valores cercanos a 0,16, mientras que LSTM-Multi presenta un R^2 negativo (-0,12), lo que indica que su capacidad explicativa es inferior a la de un modelo constante de

media. Con base en estos resultados, el BiLSTM se selecciona como arquitectura ganadora: alcanza el mayor R^2 promedio entre las redes neuronales y, además, el menor MAE promedio, lo que confirma su desempeño superior.

Tabla 2. Comparación de métricas de evaluación por arquitectura y tipo de combustible en el conjunto de prueba.


Modelo	Producto	MAE	RMSE	sMAPE (%)	R ²	Supera GBR
GBR-Baseline	Extra	76,10	103,51	12,32	-0,029	—
GBR-Baseline	Súper	19,01	24,79	31,90	0,322	—
GBR-Baseline	Diésel	383,12	499,32	25,60	0,179	—
LSTM	Extra	81,11	109,60	13,13	-0,062	No
LSTM	Súper	22,03	28,68	32,45	0,166	No
LSTM	Diésel	413,64	544,04	27,55	-0,045	No
BiLSTM	Extra	82,10	109,69	13,28	-0,064	No
BiLSTM	Súper	22,93	29,61	33,59	0,112	No
BiLSTM *	Diésel	311,01	400,33	21,20	0,434	Sí
CNN-LSTM	Extra	82,86	109,91	13,39	-0,068	No
CNN-LSTM	Súper	21,75	28,42	32,08	0,181	No
CNN-LSTM	Diésel	362,93	466,54	24,55	0,231	Sí
LSTM-Multi	Extra	87,76	126,72	13,93	-0,419	No
LSTM-Multi	Súper	21,82	28,49	32,12	0,177	No
LSTM-Multi	Diésel	414,01	561,33	27,25	-0,113	No

Nota. * Filas resaltadas en verde: BiLSTM-Diésel supera al GBR-Baseline MAE reducido de 383,12 a 311,01; R² mejorado de 0,179 a 0,433. Filas en azul: resultados BiLSTM para Extra y Súper. Fuente: elaboración propia.

3.3. Evaluación del modelo BiLSTM seleccionado

Esta sección analiza en detalle el comportamiento del BiLSTM en el conjunto de prueba, producto por producto. Se analizan las curvas de aprendizaje, la comparación entre valores reales y predichos, residuos y las métricas finales desagregadas por hidrocarburo.

Gráfico 3.6. Curvas de aprendizaje del modelo *BiLSTM* para gasolina extra, gasolina súper y diésel.




Fuente: elaboración propia.

Las curvas de aprendizaje del Gráfico 3.6 revelan comportamientos distintos según el producto. En la gasolina extra, la pérdida de validación (val loss $\approx 0,0008$) se mantiene por debajo de la de entrenamiento (train loss $\approx 0,0053$) durante las 33 épocas efectivas. Este patrón indica que el periodo de validación es más estable

que el de entrenamiento; ambas curvas convergen sin señales de un sobreajuste severo.

En la gasolina súper se observa un comportamiento similar a lo largo de 21 épocas efectivas, con la pérdida de validación estabilizada cerca de 0,008 frente a un (*train loss* de 0,010). El diésel, en cambio, requirió 136 épocas y una convergencia más gradual, coherente con la mayor complejidad de su serie: las curvas se aproximan y se estabilizan alrededor de 0,011. Este mejor ajuste es consistente con el R^2 más alto obtenido en este producto 0,434.

Gráfico 3.7. Modelo BiLSTM: evaluación en el conjunto de prueba. Valores reales vs. predichos para los últimos 120 días de prueba, los tres productos.




Fuente: elaboración propia.

El Gráfico 3.7 muestra el desempeño del *BiLSTM* sobre los últimos 120 días del conjunto de prueba. Para el diésel, el modelo captura con notable fidelidad el patrón oscilatorio semanal de la demanda y sigue la alternancia entre días de alta y baja actividad del transporte de carga. Las predicciones se mantienen dentro de un rango razonable respecto a los valores reales, aunque con suavizamiento de los picos extremos.

Para la gasolina extra, el modelo predice correctamente la tendencia central de la serie, pero subestima los valores de pico y sobreestima los valles, comportamiento que explica el sesgo promedio de $-5,43$ galones registrado en la Tabla 3. La gasolina súper presenta la mayor dificultad de seguimiento, con predicciones que capturan la tendencia creciente general pero no reproducen la alta variabilidad intradiaria de la serie.

Gráfico 3.8. Modelo *BiLSTM*: valores reales vs. predichos con análisis de residuos para Diésel, Extra y Súper (primeros 200 días del conjunto de prueba).



Fuente: elaboración propia.

El análisis de residuos del Gráfico 3.8 confirma que los errores se distribuyen de forma cercana a cero para los tres tipos de hidrocarburos, sin una tendencia creciente o decreciente sostenida en el tiempo. Para el diésel, los residuos oscilan en el rango de ± 1.250 galones, con picos asociados a eventos de demanda atípica identificados en la GETE. La gasolina extra tiene sus residuos mayormente en ± 200 galones, con excepciones en los períodos de caída abrupta de la demanda observados entre los días 150 y 175 del conjunto de prueba, mientras que, para súper los residuos se concentran en ± 60 galones, lo que evidencia el menor error absoluto de las tres series.

Tabla 3. Métricas de evaluación finales del modelo *BiLSTM* por tipo de combustible, sesgo promedio y volumen real promedio.

Producto	MAE (gal)	RMSE (gal)	sMAPE (%)	R ²	Sesgo prom. (gal)	Vol. real prom. (gal)
Extra	82,10	109,69	13,28	-0,064	-5,43	648,03
Súper	22,93	29,61	33,59	0,112	-9,70	72,16
Diésel	311,01	400,34	21,20	0,434	+11,15	1.637,56

Fuente: elaboración propia.


La Tabla 3 explica un comportamiento diferenciado del BiLSTM según cada hidrocarburo. El diésel es donde el modelo obtiene su mejor desempeño: un R^2 de 0,434 explica buena parte de la variación para una serie de alta variabilidad (desviación estándar diaria cercana a 650 galones). Su sesgo de +11,15 galones indica una ligera sobreestimación que, en términos operativos, resulta preferible a la subestimación, pues reduce el riesgo de desabastecimiento.

En extra y en súper, el modelo explica poco la varianza: el R^2 de extra es negativo (-0,064) y el de súper apenas positivo (0,112), lo que confirma que ambas series tienen un comportamiento que el modelo no alcanza a capturar en su configuración actual. Sin embargo, el error relativo varía mucho entre productos: para extra, el MAE de 82,10 galones equivale al 12,67 % del volumen diario promedio (648 galones), dentro del umbral de ± 15 % que los entrevistados de la GETE consideraron tolerable; para diésel (18,99 %) y súper (31,78 %), en cambio, el error supera ese umbral, lo que hace al modelo poco confiable en esos dos productos.

3.4. Proyecciones futuras del modelo BiLSTM


Una vez validado el modelo *BiLSTM*, se generó proyecciones para los 30 días siguientes al último dato disponible de nuestro *dataset* (18 de noviembre al 17 de diciembre de 2025), así como agregaciones semanales, mensuales y anuales, dichas proyecciones componen el consumo directo para la planificación de abastecimiento de la estación.

Gráfico 3.9. Pronóstico BiLSTM a 30 días futuros con intervalo de confianza $\pm 1\sigma$ para extra, súper y diésel (18 nov. – 17 dic. 2025).



Fuente: elaboración propia.

Gráfico 3.10. Continuidad entre los 90 días históricos y los 30 días pronosticados por el modelo *BiLSTM* para los tres productos.



Fuente: elaboración propia.

Los Gráficos 3.9 y 3.10 muestran la proyección diaria del período entre noviembre y diciembre de 2025. El diésel exhibe el comportamiento oscilatorio semanal más pronunciado, con picos cercanos a los 2.000 galones en días de alta actividad de transporte y próximos a los 1.000 galones los domingos, mientras que la gasolina extra, se proyecta en un rango estable de 587 a 619 galones diarios, sin una tendencia marcada, lo que refleja la estabilidad reciente de su demanda, por otro lado, la gasolina súper, muestra una leve tendencia decreciente, de 75 a 60 galones a lo largo del mes.

Tabla 4. Predicciones semanales de volumen de despacho (galones) para noviembre y diciembre de 2025, modelo BiLSTM.

Semana (inicio)	Extra (gal)	Súper (gal)	Diésel (gal)
17 nov. 2025	3.572,79	434,55	9.428,90
24 nov. 2025	4.282,10	481,35	10.171,32
1 dic. 2025	4.295,48	463,41	11.411,89
8 dic. 2025	4.283,09	444,44	11.288,95
15 dic. 2025	1.768,18	180,40	4.893,09

Fuente: elaboración propia.

Tabla 5. Proyección anual de volumen de despacho (galones) para 2025 y 2026, modelo BiLSTM.

Año	Extra (gal)	Súper (gal)	Diésel (gal)
2025 (parcial)	26.602,07	2.817,17	69.529,85
2026 (proyectado)	187.814,51	15.862,54	552.161,88

Nota. El valor de 2025 corresponde al período noviembre-diciembre proyectado. El valor de 2026 es una proyección anual completa obtenida por acumulación de predicciones diarias encadenadas. Fuente: elaboración propia.

La Tabla 5 presenta las proyecciones anuales del modelo BiLSTM. Para el año 2026, el modelo estima un volumen total de 552.161 galones de diésel, 187.815 galones de extra y 15.863 galones de súper. Estas proyecciones anuales se obtienen por acumulación de predicciones diarias encadenadas, lo que implica una propagación del error a lo largo del horizonte. Por la forma en la que se calculan estos valores, la administración de la estación debe tomarlos como indicadores de referencia para una planificación estratégica del abastecimiento, no como un pronóstico de precisión diaria. El intervalo de confianza $\pm 1\sigma$ presentado en el Gráfico 3.10 cuantifica la incertidumbre asociada y provee los límites inferior y superior para la toma de decisiones de inventario.

3.5. Validación del modelo con datos reales

Con el propósito de evaluar la capacidad predictiva del modelo BiLSTM en condiciones reales, se realizaron proyecciones generadas para el periodo comprendido entre el 18 de noviembre y 17 de diciembre de 2025 con los datos registrados en ese mismo intervalo. El modelo se entrenó con información del *dataset* hasta el 17 de noviembre del 2025, dicho periodo ayuda con una verificación fuera de nuestra

muestra. Los datos con los que se verifica no formaron parte del entrenamiento ni de las particiones de validación y prueba, lo que permite medir el desempeño del modelo con información nueva.

Los datos reales se obtuvieron del mismo sistema de donde se extrajo los mismos datos que se usaron para entrenar el modelo. Antes de la comparación se comprobó que este nuevo reporte y el conjunto de datos empleados en el entrenamiento reafirmen su contenido contrastando un periodo en común a ambas fuentes (1 de enero al 17 de noviembre de 2025), según se ve en la Tabla 6.

Tabla 6. Consistencia entre el conjunto de entrenamiento y el reporte de validación en el período común (1 ene. – 17 nov. 2025).

Fuente	Transacciones	Volumen (gal)
dataset_crudo	77 702	755 604
Reporte de validación	78 028	757 922
Diferencia	326 (0,42 %)	2 318 (0,31 %)

Nota. La diferencia inferior al 1 % se atribuye a la limpieza adicional aplicada al conjunto de entrenamiento (eliminación de anulaciones y duplicados). Ambas fuentes se consideran consistentes. Fuente: elaboración propia.

Antes de evaluar el error, se caracterizó la demanda real del periodo de validación y se comparó con la de los meses anteriores (1 de septiembre al 17 de noviembre de 2025). El objetivo fue verificar la presencia de un incremento estacional de fin de año, el cual fue señalado por el personal de la estación en la (GETE). Los resultados se muestran en la Tabla 7.

Tabla 7. Volumen diario promedio en el período previo frente al período de validación, por tipo de combustible.


Producto	Previo (gal/día)	Validación (gal/día)	Cambio (%)
Extra	648,6	685,3	+5,7
Súper	91,9	81,6	-11,2
Diésel	1 695,0	1 873,9	+10,6

Nota. El período previo abarca del 1 de septiembre al 17 de noviembre de 2025; el de validación, del 18 de noviembre al 17 de diciembre de 2025. Fuente: elaboración propia.

El diésel y el extra registraron un incremento del 10,6 % y 5,7 % respectivamente coherentes con el aumento de actividad propia de las festividades de fin de año. En este caso, la gasolina súper mostró un descenso del 11,2 %, coherente con su

comportamiento irregular y baja predictibilidad y de baja predictibilidad observado a lo largo del estudio.

Gráfico 3.11. Continuidad entre los 90 días históricos y los 30 días pronosticados por el modelo *BiLSTM* para los tres productos.



Fuente: elaboración propia.


La tabla 8 presenta la comparación entre el volumen pronosticado por el modelo y el volumen real despachado durante los 30 días del periodo de validación. Se reporta el error total acumulado, el error absoluto medio diario (MAE) y el error porcentual medio simétrico (sMAPE) para cada uno de los hidrocarburos.

Tabla 8. Validación fuera de muestra del modelo BiLSTM: predicción frente a demanda real (18 nov. – 17 dic. 2025).

Producto	Predicho	Real	Error total (%)	MAE diario	sMAPE (%)	Producto
Extra	18 201,64	20 559,90	-11,47	105,83	16,13	Extra
Súper	2 004,15	2 447,73	-18,12	24,05	31,38	Súper
Diésel	47 194,15	56 216,61	-16,05	415,80	23,98	Diésel

Nota. El error total negativo indica subestimación de la demanda. MAE expresado en galones por día. Fuente: elaboración propia.

Gráfico 3.12. Continuidad entre los 90 días históricos y los 30 días pronosticados por el modelo *BiLSTM* para los tres productos.



Fuente: elaboración propia.

El modelo arrojó una predicción por debajo de la demanda real en los tres tipos de combustibles con desviaciones de 11,47 % en extra, 16,05 % en diésel y 18,12 % en súper. Aun así, el error diario fue parecido al medido en prueba, MAE de 105,83 comparado con 82,10 en extra; 415,80 con relación a 311,01 en diésel; 24,05 frente a 22,93 en súper. Esto confirma que la evaluación previa reflejaba bien cómo se comporta el modelo ante nuevos datos.

Esta subestimación se explica por el aumento de fin de año que muestra la Tabla 8: como el entrenamiento incluyo pocas temporadas de fin de año, el modelo no alcanzó a aprender y a prever la subida de diciembre, pero esto no significa que falle; al contrario, muestra que acierta la demanda habitual, y se queda corto por el pico estacional. Aquí la mejora es clara: incluir más información externa, como feriados,

temporadas altas, indicadores del mes que permitan ajustar las proyecciones en épocas atípicas.

El contraste con los datos reales confirma que el modelo es útil para apoyar la planificación de abastecimiento, siempre que sus resultados se tomen como una referencia y se complementen con la experiencia del personal en temporadas de mayor demanda.

CONCLUSIONES

- La revisión del estado del arte evidencia que la predicción de demanda en el sector de hidrocarburos ha migrado desde modelos estadísticos lineales, como ARIMA, hacia arquitecturas de aprendizaje profundo capaces de capturar dependencias no lineales en series de alta volatilidad. Esta superioridad no es universal: la literatura documenta casos en los que modelos de árboles de decisión superan a las redes neuronales en mercados altamente inestables, hallazgo que respalda la inclusión de un modelo de referencia estadístico (GBR-Baseline) en el diseño comparativo del presente estudio.
- El diagnóstico del estado actual confirma que la Estación de Servicio Divino Niño gestiona su inventario mediante estimaciones empíricas basadas en promedios móviles, con márgenes de error de entre el 3 % y el 8 % en condiciones normales y desfases mayores en periodos de demanda atípica. El análisis de 466.13 registros transaccionales, consolidados en 1.364 observaciones diarias entre febrero de 2022 y noviembre de 2025, evidenció una estacionalidad semanal marcada: la gasolina extra alcanza su mediana más alta los sábados, el diésel concentra su demanda entre martes y jueves, y los domingos registran los volúmenes mínimos en los tres productos.
- De las cuatro arquitecturas de redes neuronales recurrentes evaluadas — LSTM, BiLSTM, CNN-LSTM y LSTM Multivariante—, la arquitectura BiLSTM se posiciona como la de mejor desempeño promedio, con el mayor coeficiente de determinación ($R^2 = 0,1606$) y el menor error porcentual simétrico (sMAPE = 22,69 %). Su ventaja frente al modelo de referencia estadístico es selectiva: únicamente supera al GBR-Baseline en el producto diésel, donde reduce el MAE de 383,12 a 311,01 galones (mejora del 18,8 %) y aumenta el R^2 de 0,179 a 0,434.
- Se concluye que el modelo BiLSTM cumple el criterio de validación operativa para El modelo BiLSTM satisface el umbral de tolerancia operativa de ± 15 % declarado por el personal de la estación en dos de los tres productos evaluados. Para gasolina extra, el sMAPE de 13,28 % se ubica dentro del umbral sobre un volumen diario promedio de 648,03 galones. Para diésel, el modelo alcanza su mejor ajuste ($R^2 = 0,434$) con un sesgo promedio de +11,15 galones, comportamiento preferible al desabastecimiento. Para gasolina súper, el sMAPE de 33,59 % excede ampliamente el umbral declarado, lo que limita su aplicabilidad operativa en la configuración actual.

- La validación fuera de muestra, realizada con datos reales del 18 de noviembre al 17 de diciembre de 2025 no incluidos en el entrenamiento, mostró que el modelo subestimó la demanda real en los tres productos (–11,47 % en extra, –16,05 % en diésel y –18,12 % en súper). Esta subestimación coincide con el incremento estacional de fin de año (+5,7 % en extra y +10,6 % en diésel frente al periodo previo), fenómeno insuficientemente representado en los datos de entrenamiento, lo que confirma que el modelo predice correctamente la demanda habitual, pero requiere variables adicionales para anticipar picos estacionales atípicos.
- La investigación demuestra que es técnicamente viable desarrollar un modelo de predicción del consumo de combustible basado en redes neuronales para la Estación de Servicio Divino Niño. Su viabilidad plena está condicionada a la incorporación de variables exógenas —feriados, cambios de precio regulado, paros nacionales, cierres viales y competencia— identificadas mediante la Guía de Entrevista Técnica Estructurada, pero actualmente ausentes en la base transaccional.

RECOMENDACIONES

- Se recomienda incorporar como características binarias de evento las seis categorías de variables exógenas identificadas en la GETE (feriados nacionales, inicio de clases, paros nacionales, cambios de precio regulado, cierres viales y apertura o cierre de estaciones competidoras), actualmente ausentes en la base transaccional, con el fin de reducir el impacto de los valores atípicos que degradan el desempeño del modelo en gasolina extra y súper.
- Se recomienda evaluar arquitecturas complementarias para los productos en los que el BiLSTM no logró superar al modelo de referencia estadístico (extra y súper), explorando modelos híbridos que combinen el GBR con capas recurrentes, dado que ambas series presentan alta variabilidad intradiaria no capturada por la configuración actual de la red.
- Se recomienda establecer un flujo de reentrenamiento periódico, con una frecuencia mínima trimestral, que incorpore los nuevos datos de despacho acumulados desde el último registro disponible (17 de noviembre de 2025). Las proyecciones anuales se generan por acumulación de predicciones diarias encadenadas, lo que propaga el error a medida que el horizonte se aleja del punto de entrenamiento, y el reentrenamiento periódico mitiga este efecto.
- Se recomienda implementar la interfaz solicitada por los operadores de la estación durante la GETE: un dashboard con exportación a formato Excel, visualización por producto y por total diario, y semáforos de stock, apoyado en herramientas de código abierto (Streamlit o Power BI) que no impliquen costos de licenciamiento adicionales.
- Se recomienda completar y documentar formalmente el análisis de degradación del error por horizonte de predicción (1, 7, 15 y 30 días) para los tres productos, con sus tablas y gráficos correspondientes. Este análisis figura en la estructura del capítulo de resultados, pero sus valores no se encuentran actualmente sustentados en el cuerpo del documento, lo que impide justificar con evidencia la elección del horizonte de 7 días señalado como preferido por el personal de la estación.
- Se recomienda reportar la métrica de exactitud direccional (DA) mencionada en el diseño metodológico como criterio de selección del modelo ganador, o bien ajustar la redacción de dicho apartado si finalmente no se empleó esta métrica en la evaluación final.

- Se recomienda replicar el diseño experimental en estaciones de distintos contextos geográficos y perfiles de demanda dentro de la red Petroecuador. El régimen tarifario regulado bajo el cual opera la Estación Divino Niño es compartido por la mayoría de las estaciones minoristas del país, lo que permitiría construir un benchmark sectorial y validar si los umbrales de desempeño obtenidos son representativos del sector o específicos del caso Latacunga.

BIBLIOGRAFÍA

- Adetunji, A., & Ademola, A. (2014). A Proposed Architectural Model for an Automatic Adaptive E-Learning System Based on Users Learning Style. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 5(4). <https://doi.org/10.14569/IJACSA.2014.050401>
- Ahmed, R. S., Hasnain, M., Mahmood, M. H., & Mehmood, M. A. (2024). Comparison of Deep Learning Algorithms for Retail Sales Forecasting. *ICCK Transactions on Intelligent Systematics*, 1(3), 112–126. <https://doi.org/10.62762/TIS.2024.300700>
- Alwadi, M. A. (2025). Fuel Sales Price Forecasting using Time Series, Machine Learning, and Deep Learning Models. *Engineering, Technology & Applied Science Research*, 15(3), 22360–22366. <https://doi.org/10.48084/etasr.10348>
- Amat Rodrigo, J., & Escobar Ortiz, J. (2026). *Skforecast*. Zenodo. <https://doi.org/10.5281/ZENODO.8382787>
- Arceo, N., Bersten, L., & Wainer, A. (2022). *La evolución del sector de hidrocarburos*. Cholle, F. (2021). *Deep Learning with Python, Second Edition*. New York: Manning Publications Co. LLC.
- Creswell, J. W., & Creswell, J. D. (2023). *Research Design. Qualitative, Quantitative, and Mixed Methods Approaches*. Recuperado de <https://repositorio.ciem.ucr.ac.cr/handle/123456789/514>
- Dritsas, E., & Trigka, M. (2025). Machine Learning in E-Commerce: Trends, Applications, and Future Challenges. *IEEE Access*, 13, 99048–99067. <https://doi.org/10.1109/ACCESS.2025.3572865>
- Feizabadi, J. (2022). Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications*, 25(2), 119–142. <https://doi.org/10.1080/13675567.2020.1803246>
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585(7825), 357–362. <https://doi.org/10.1038/s41586-020-2649-2>
- Hernández-Sampieri, R., & Mendoza Torres, C. P. (2018). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill Education. http://www.biblioteca.cij.gob.mx/Archivos/Materiales_de_consulta/Drogas_de_Abuso/Articulos/SampieriLasRutas.pdf
- Hossain, M. L., Shams, S. M. N., & Ullah, S. M. (2025). Time-series and deep learning approaches for renewable energy forecasting in Dhaka: A comparative study of ARIMA, SARIMA, and LSTM models. *Discover Sustainability*, 6(1), 775. <https://doi.org/10.1007/s43621-025-01733-5>

- Huillca Diaz, A. L. (2024). Análisis aplicando redes neuronales artificiales para incrementar la producción de acarreo de material estéril de las fases 5 y 3 del tajo Ferrobamba – Las Bambas – Apurímac.
- Hunter, J. D. (2007). Matplotlib: A 2D Graphics Environment. *Computing in Science & Engineering*, 9(3), 90–95. <https://doi.org/10.1109/MCSE.2007.55>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3ª ed.). OTexts. <https://otexts.com/fpp3/>
- Ibarra-Sáiz, M. S., González-Elorza, A., & Gómez, G. R. (2023). Aportaciones metodológicas para el uso de la entrevista semiestructurada en la investigación educativa a partir de un estudio de caso múltiple. *Revista de Investigación Educativa*, 41(2), 501–522. <https://doi.org/10.6018/rie.546401>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). M5 accuracy competition: Results, findings, and conclusions. *International Journal of Forecasting*, 38(4), 1346–1364. <https://doi.org/10.1016/j.ijforecast.2021.11.013>
- McKinney, W. (2010). Data Structures for Statistical Computing in Python. *SciPy 2010*. <https://doi.org/10.25080/Majora-92bf1922-00a>
- Ning, Y., Kazemi, H., & Tahmasebi, P. (2022). A comparative machine learning study for time series oil production forecasting: ARIMA, LSTM, and Prophet. *Computers & Geosciences*, 164, 105126. <https://doi.org/10.1016/j.cageo.2022.105126>
- Pedregosa, Fabian, Varoquaux, Gaël, Gramfort, Alexandre, Michel, Vincent, Thirion, Bertrand, Grisel, Olivier, ... Duchesnay, Édouard. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Van Rossum & Drake, F. L. (2009). The Python Language Reference. Recuperado el 29 de junio de 2026, de Python documentation website: <https://docs.python.org/3/reference/index.html>
- Verma, R. (2024). *Building Robust AI Systems in Finance: The Indispensable Role of Data Engineering and Data Quality*.
- Vizcaíno Zúñiga, Cedeño Cedeño, & Maldonado Palacios. (2023). Metodología de la investigación científica: Guía práctica. *Ciencia Latina Revista Científica Multidisciplinar*, 7(4), 9723–9762. https://doi.org/10.37811/cl_rcm.v7i4.7658
- Waskom, M. L. (2021). seaborn: Statistical data visualization. *Journal of Open Source Software*, 6(60), 3021. <https://doi.org/10.21105/joss.03021>

ANEXOS

Anexo A. Autorización institucional para recopilación de datos

AUTORIZACIÓN INSTITUCIONAL PARA LA RECOPILACIÓN Y USO DE DATOS CON FINES ACADÉMICOS

Latacunga, 17 de noviembre de 2025

Señores

PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR, SEDE AMBATO (PUCE Ambato)

Escuela de Hábitat, Infraestructura y Creatividad

Presente. -

De mi consideración:

Yo, **EDY ORLANDO CHIRIBOGA HUILCAMAIGUA**, portador(a) de la cédula de ciudadanía N.º 0501771547, en mi calidad de **Representante Legal** de la Estación de Servicio Divino Niño (afiliada a la comercializadora EP Petroecuador), con RUC N.º 0591746081001, ubicada en Antigua panamericana norte vía a Quito, km 4/2 entrada a Saquisilí, cantón Latacunga, provincia de Cotopaxi, por medio de la presente

AUTORIZO

de manera expresa al señor **EDUARDO JAVIER OÑA CHIRIBOGA**, portador de la cédula de ciudadanía N.º 0503959645, estudiante de la carrera de Ingeniería en Sistemas de la Información de la Pontificia Universidad Católica del Ecuador, Sede Ambato, para acceder, recopilar y utilizar los registros históricos transaccionales de despacho de combustible (productos extra, súper y diésel) de esta estación, correspondientes al período comprendido entre febrero de 2022 y noviembre de 2025.

Dejo constancia de que esta autorización se concede **exclusivamente con fines académicos**, en el marco del proyecto de investigación titulado *“MODELO DE PREDICCIÓN DEL CONSUMO DE COMBUSTIBLE CON REDES NEURONALES PARA UNA ESTACIÓN DE SERVICIO”*, previo a la obtención del título de Ingeniero en Sistemas de la Información, dirigido por el Mg. Edison Fernando Meneses Torres.

El investigador se compromete a: (a) utilizar la información únicamente para los fines académicos señalados; (b) mantener la confidencialidad de los datos comerciales y operativos de la estación; (c) no divulgar información que pueda afectar los intereses de la institución; y (d) presentar los resultados de forma agregada y anonimizada cuando corresponda.

Particular que comunico para los fines pertinentes.

Atentamente,

EDY ORLANDO CHIRIBOGA HUILCAMAIGUA

REPRESENTANTE LEGAL

Estación de Servicio Divino Niño

C.C. N.º 0501771547 / RUC N.º 0591746081001

Anexo B.

B.1 Guía de Entrevista Técnica Estructurada (GETE) Administrador Contable

1. Introducción y justificación del instrumento

El presente documento contiene la Guía de Entrevista Técnica Estructurada (GETE), instrumento diseñado para la fase humana de recolección de datos del proyecto de investigación titulado “Modelo de redes neuronales para predecir el consumo de combustible automotriz en una estación de servicio”, desarrollado en la Estación de Servicio Divino Niño (comercializadora Petroecuador), ubicada en la ciudad de Latacunga, provincia de Cotopaxi.

La investigación adopta un enfoque mixto secuencial: una fase cuantitativa, sustentada en el análisis documental de los registros transaccionales del punto de venta entre el 1 de febrero de 2022 y el 30 de septiembre de 2025, y una fase cualitativa, sustentada en la entrevista técnica al personal con responsabilidad decisional directa sobre el inventario y el abastecimiento. Para esta segunda fase se elige la entrevista estructurada como técnica óptima, dado que la población humana del estudio es finita y reducida ($N = 2$: administrador de la estación y asistente de operaciones) y, por tanto, no admite un cuestionario masivo ni un muestreo probabilístico.

La elección del instrumento se fundamenta en (Creswell & Creswell, 2023, Capítulo 9), quienes recomiendan la entrevista estructurada cuando el investigador requiere garantizar comparabilidad entre informantes, reducir el sesgo del entrevistador y, al mismo tiempo, levantar conocimiento experto que no se encuentra inscrito en bases de datos. La GETE permite reconstruir el método empírico actual de pronóstico, levantar las reglas heurísticas no documentadas de inventario y registrar variables exógenas que no quedan registradas en la base transaccional, las cuales serán incorporadas como *features* adicionales en el modelo de redes neuronales recurrentes (LSTM).

La escala de medición predominante en el instrumento es de tipo nominal–descriptiva con respuesta abierta acotada, complementada con preguntas de cuantificación directa (galones, porcentajes, horas, días) en los bloques que abordan umbrales operativos y costos de error. Esta combinación se justifica porque el objetivo del instrumento no es medir actitudes sino documentar procedimientos operativos y estimar magnitudes técnicas verificables, en línea con (Creswell & Creswell, 2023, Capítulo 8).

2. Objetivos del instrumento

Objetivo general:

Levantar, mediante entrevista técnica estructurada, el conocimiento operativo y las variables exógenas no registradas en la base transaccional de la Estación de Servicio Divino Niño, con el fin de complementar el conjunto de datos histórico utilizado

para entrenar el modelo de redes neuronales LSTM de predicción del consumo de combustible automotriz.

Objetivos específicos:

- Caracterizar el régimen actual de pronóstico empírico aplicado por el personal técnico-administrativo de la estación.
- Documentar los umbrales operativos de inventario y las reglas heurísticas de abastecimiento utilizadas para cada producto (extra, súper y diésel).
- Estimar, desde la perspectiva del usuario, la estructura de costos asociada al error de pronóstico, tanto por quiebre de stock como por sobre almacenamiento.
- Registrar los eventos exógenos relevantes (estacionalidades, eventos atípicos, cambios regulatorios) no inscritos en la base transaccional.
- Definir los requerimientos funcionales del sistema predictivo deseado por el usuario final.

3. Instrucciones para el participante

Estimado(a) colaborador(a):

Agradecemos su participación en esta entrevista, que forma parte del trabajo de investigación de grado del autor. A continuación, se presentan las indicaciones para responder de manera adecuada al instrumento

- La presente entrevista tiene una duración estimada de cuarenta y cinco a sesenta minutos.
- La entrevista está organizada en cinco bloques temáticos, con un total de veinte ítems de respuesta abierta acotada.
- Responda a cada pregunta con base en su experiencia directa en la operación de la estación de servicio; no se busca una respuesta correcta o incorrecta, sino la descripción veraz de la práctica operativa actual.
- Cuando se le solicite estimar magnitudes (galones, porcentajes, horas, costos aproximados), proporcione el dato más cercano a la realidad operativa; si no posee el dato exacto, ofrezca un rango aproximado.
- La entrevista podrá ser registrada en audio, previa autorización expresa, con el único fin de transcripción literal. Sus respuestas serán tratadas de forma confidencial y utilizadas exclusivamente con fines académicos.

- Al finalizar cada bloque temático, dispondrá de un espacio para añadir observaciones adicionales que considere relevantes y que no hayan sido capturadas por las preguntas cerradas.
- Puede solicitar al entrevistador la repetición o aclaración de cualquier ítem que no comprenda con claridad.

4. Datos sociodemográficos y de contexto del participante

Cuadro B.1. Datos sociodemográficos y de contexto del participante

Complete la información solicitada en el siguiente cuadro:

Nombres y apellidos (opcional):	Datos ocultos por confidencialidad
Edad:	25 años
Género:	Femenino
Nivel de instrucción:	Tercer Nivel
Cargo que desempeña:	Administradora
Tiempo en el cargo (años/meses):	1 año 05 meses
Funciones principales relacionadas con la gestión de combustible:	Cumplimiento normativo con las entidades de control. Manejo de inventario del combustible. Ejecución en el proceso de compra de combustible Cuadros de caja diarios. Conciliación de ventas.
Fecha de la entrevista:	01/012/2025
Lugar de la entrevista:	Estación de servicio Divino Niño
Duración aproximada:	1 hora

Fuente: Datos proporcionados por el participante.

5. Cuerpo del instrumento — Ítems por bloque temático

El instrumento se compone de veinte ítems organizados en cinco bloques temáticos, articulados directamente con la operacionalización de variables del Capítulo II del proyecto y con la lógica de entrada de datos del modelo de redes neuronales LSTM.

BLOQUE A. Caracterización del régimen actual de pronóstico empírico

Objetivo del bloque: Reconstruir el método actual con el que la estación estima la demanda diaria de combustible y los criterios decisionales que se aplican sin apoyo de un modelo predictivo.

Variable / dimensión asociada: Variable independiente — Pronóstico empírico de demanda.

Ítem 1. Describa, paso a paso, cómo estima usted hoy la cantidad de galones de gasolina extra, súper y diésel que se venderán mañana en la estación.

Indicador asociado: Procedimiento empírico de estimación de demanda diaria.

Con respecto a la estimación se lo realiza en base a:

Experiencia operativa y análisis de ventas de las semanas anteriores y con ello también el comportamiento que tuvo con el día anterior, aquí se toma en cuenta los fines de semana y feriados que son los días donde no se presentan alto flujo de vehículos.

Revisión del stock que existe en los tanques de almacenamiento para asegurar el abastecimiento y con base a todos estos factores se realiza una proyección para cada combustible.

Ítem 2. ¿Qué fuentes de información (libros contables, reportes del punto de venta, planillas Excel, observación visual del nivel de tanques, intuición) utiliza para tomar esa decisión y con qué frecuencia las consulta?

Indicador asociado: Fuentes de información utilizadas en el pronóstico empírico.

Reportes de ventas diarias que son facilitadas por el sistema FULL CONTROL

Reporte diario de medidas del stock de tanques de almacenamiento

El control se lo realiza diariamente con el fin de no tener desabastecimiento de combustible.

Ítem 3. Cuando su estimación difiere de la venta real, ¿qué tan grande suele ser ese desfase en galones o en porcentaje? Proporcione un ejemplo concreto del último trimestre.

Indicador asociado: Margen de error subjetivo del pronóstico empírico.

Cuando la estimación de ventas no coincide con la venta real, normalmente existe una diferencia aproximada entre el 3 % y el 8 %, debido a cambios en la cantidad de vehículos que llegan a cargar combustible, feriados o días con mayor movimiento. Por ejemplo, en el mes de marzo de 2026 se calculó que se venderían alrededor de 40.000 galones entre diésel, gasolina extra y súper, pero al finalizar el mes la venta real fue de 37.546,24 galones, existiendo una diferencia de 2.453,76 galones, lo que representa aproximadamente un 6,13 % menos de lo estimado.

Ítem 4. ¿Con qué frecuencia ocurre que se queda sin stock de algún producto antes del siguiente abastecimiento, y con qué frecuencia se quedan con tanques sobrelLENADOS que limitan el siguiente despacho?

Indicador asociado: Frecuencia de quiebres de stock y sobre almacenamiento.

Es muy poco probable que la estación se quede sin stock de combustible se realiza el seguimiento diario de ventas con las medidas de los tanques de almacenamiento, los tanques no quedan demasiado llenos por el volumen de ventas que no es tan alto para tener un completo abastecimiento.

Observaciones adicionales del Bloque A:

BLOQUE B. Umbrales operativos de inventario y reglas heurísticas de abastecimiento

Objetivo del bloque: Documentar las reglas operativas no escritas que rigen el momento y el volumen del pedido de combustible, para incorporarlas como restricciones del modelo predictivo.

Variable / dimensión asociada: Variable interviniente — Reglas heurísticas de inventario.

Ítem 5. ¿Cuál es el nivel mínimo de combustible (en galones o en porcentaje de la capacidad del tanque) en el que usted decide solicitar un nuevo abastecimiento a Petroecuador, y por qué se eligió ese umbral?

Indicador asociado: Nivel mínimo de reorden (stock de seguridad operativo).

Los niveles mínimos son:

Diésel: 375 galones

Extra: 175 galones

Súper: 80 galones

Se eligió estos niveles por las bombas sumergibles que existe dentro de los tanque, estas bombas nos ayudan para el despacho en la islas, si se deja bajar menos las bombas tienden a dañarse.

Ítem 6. ¿Qué volumen estándar de pedido maneja para cada producto (extra, súper y diésel) y bajo qué criterios ajusta este volumen ante semanas con demanda atípica?

Indicador asociado: Volumen de pedido estándar y criterios de ajuste.

Se maneja un volumen estándar de pedido de combustible de acuerdo con la capacidad de almacenamiento y el promedio de ventas de cada producto, solicitando generalmente mayores cantidades de gasolina extra y diésel por ser los combustibles de mayor rotación.

Tomando en cuenta el historial de consumo, el nivel disponible en los tanques y el tiempo estimado de entrega del abastecimiento, con el fin de evitar tanto el desabastecimiento.

Ítem 7. ¿Cuál es el tiempo promedio de respuesta (lead time) entre que se solicita el abastecimiento y se recibe el producto en sitio, y qué tan estable es ese tiempo?

Indicador asociado: Lead time de abastecimiento y su variabilidad.

Puede tardar entre 1-3 horas la respuesta para el despacho del combustible desde el beaterio y el producto está en aproximadamente 1 hora en la estación, las horas de despacho pueden variar dependiendo el despacho en los beaterios.

Ítem 8. Describa la última vez que tuvo que tomar una decisión urgente de abastecimiento fuera del calendario habitual. ¿Qué señales del negocio le obligaron a actuar?

Indicador asociado: Señales operativas detonantes de decisiones no programadas. Por el desabastecimiento de combustible en los beaterios mediante un comunicado de Petroecuador, es ahí donde se debe comprar o anticipar la compra.

Observaciones adicionales del Bloque B:

BLOQUE C. Percepción de la estructura de costos del error de pronóstico

Objetivo del bloque: Cuantificar, desde la perspectiva del personal con responsabilidad sobre el negocio, el costo económico y operativo de cada tipo de error predictivo.

Variable / dimensión asociada: Variable dependiente — Costo del error de pronóstico.

Ítem 9. Cuando la estación se queda sin un producto antes del abastecimiento programado, ¿qué consecuencias económicas y operativas observa? Estime, si es posible, el costo aproximado de una hora sin producto disponible.

Indicador asociado: Costo de oportunidad por quiebre de stock.

Las principales consecuencias son la pérdida de ventas, la disminución de ingresos y la posible inconformidad de los clientes, muchos usuarios buscan abastecerse en otras estaciones y en algunos casos no regresan inmediatamente.

Ítem 10. Cuando se realiza un pedido mayor al necesario y los tanques quedan sobrellenados, ¿qué problemas operativos se generan (capacidad ociosa, retraso del siguiente pedido, riesgo de derrames, capital inmovilizado)?

Indicador asociado: Costo operativo por sobrealmacenamiento.

Puede existir derrame sobre los tanques de almacenamiento, adicional que el tanquero debe esperar que existan ventas para poder seguir descargando.

Ítem 11. Entre subestimar la demanda y sobrestimarla, ¿cuál de los dos errores considera usted más costoso para la estación y por qué?

Indicador asociado: Asimetría percibida del costo del error de pronóstico.

El error más costoso para la estación es subestimar la demanda, porque puede provocar quedarse sin combustible antes del siguiente abastecimiento, generando pérdida de ventas y clientes. En cambio, sobrestimar la demanda solo ocasiona mantener más producto almacenado, lo cual normalmente tiene un impacto menor.

Ítem 12. ¿En qué porcentaje aproximado de error de pronóstico (por ejemplo, $\pm 5\%$, $\pm 10\%$, $\pm 15\%$) considera usted que un modelo predictivo dejaría de ser útil para la operación diaria de la estación?

Indicador asociado: Umbral de tolerancia al error de pronóstico (criterio de validación funcional).

Aproximadamente el $\pm 15\%$, a partir de ese nivel las estimaciones podrían generar problemas de desabastecimiento o exceso de combustible almacenado, afectando la planificación y las ventas.

Observaciones adicionales del Bloque C:

BLOQUE D. Registro de eventos exógenos relevantes no inscritos en la base transaccional

Objetivo del bloque: Levantar las variables exógenas que afectan el consumo y que no quedan registradas en el sistema de punto de venta, con el fin de incorporarlas como features adicionales del modelo LSTM.

Variable / dimensión asociada: Variable interviniente — Eventos exógenos no transaccionales.

Ítem 13. ¿Qué fechas o periodos del año (feriados, inicio de clases, temporadas turísticas, fines de mes, días de pago) muestran de manera recurrente un comportamiento de demanda atípico en la estación?

Indicador asociado: Estacionalidades exógenas calendario.

Diciembre es el mes con mayor volumen de ventas por el traslado de los clientes, además de los días en donde existen actividades comerciales y agrícolas de los lugares aledaños a la estación

Ítem 14. Describa eventos no recurrentes ocurridos entre 2022 y 2025 (paros nacionales, cierres viales, cambios de subsidio de combustibles, escasez logística, eventos climáticos extremos) que hayan alterado significativamente las ventas. Indique fecha aproximada, duración y producto afectado.

Indicador asociado: Eventos atípicos exógenos (outliers contextuales).

En junio de 2022, durante el paro nacional en Ecuador, se registró una disminución considerable en las ventas debido a cierres viales y problemas de abastecimiento; este evento tuvo una duración aproximada de 18 días y afectó principalmente la venta de diésel y gasolina extra. De igual manera, en distintos periodos se presentaron cierres de carreteras por deslizamientos y condiciones climáticas fuertes en la provincia, generando retrasos en el abastecimiento y reducción temporal de clientes. También existieron semanas con alta demanda ocasionadas por rumores o anuncios relacionados con posibles cambios en subsidios o precios de combustibles, provocando incrementos repentinos en las ventas de gasolina extra y diésel durante varios días consecutivos. Estos eventos alteraron el comportamiento normal de la demanda y dificultaron la planificación habitual del abastecimiento.

Ítem 15. ¿Cuál es el impacto observado de los cambios de precio regulado del combustible sobre el volumen de ventas en los días inmediatamente anteriores y posteriores al ajuste de precio?

Indicador asociado: Sensibilidad de la demanda a la política de precios.

Antes de un aumento en el precio del combustible, las ventas suelen incrementarse porque los clientes buscan abastecerse anticipadamente. Después del ajuste, las ventas normalmente bajan por algunos días hasta volver a la normalidad, especialmente en gasolina extra y diésel.

Ítem 16. ¿Existen patrones de demanda asociados a la apertura o cierre de estaciones de servicio competidoras en el área de influencia, o a obras viales que modifiquen el tránsito vehicular? Describa los casos observados.

Indicador asociado: Variables competitivas y de tránsito.

Sí, se han observado cambios en la demanda cuando abren o cierran estaciones de servicio cercanas, esto modifica la cantidad de clientes y el flujo de vehículos en la zona. También las obras viales, cierres de carreteras o desvíos de tránsito afectan las ventas, porque pueden disminuir o aumentar temporalmente la circulación vehicular frente a la estación. En algunos casos, cuando existen cierres en rutas cercanas, se registra una reducción en las ventas, mientras que los desvíos de tránsito pueden generar un incremento temporal de clientes.

Observaciones adicionales del Bloque D:

BLOQUE E. Requerimientos funcionales del sistema predictivo deseado

Objetivo del bloque: Definir, desde la voz del usuario final, los requisitos funcionales y de interfaz que debe cumplir el modelo de redes neuronales para ser efectivamente adoptado en la operación de la estación.

Variable / dimensión asociada: Variable dependiente — Aceptabilidad funcional del modelo predictivo.

Ítem 17. ¿Con qué horizonte temporal (1 día, 7 días, 15 días, 30 días) considera más útil recibir el pronóstico de consumo de combustible para apoyar sus decisiones de abastecimiento?

Indicador asociado: Horizonte de pronóstico requerido.

El pronóstico de consumo de combustible es entre 7 días, permite planificar de mejor manera los pedidos de abastecimiento, controlar los niveles de inventario y anticiparse a cambios en la demanda sin generar desabastecimiento ni exceso de producto almacenado.

Ítem 18. ¿Con qué granularidad de salida prefiere el resultado (por producto, por surtidor, por franja horaria, total diario), y qué nivel de detalle considera necesario para la operación?

Indicador asociado: Granularidad de la predicción requerida.

Es contar con el pronóstico por producto y total diario, permite planificar el abastecimiento de gasolina extra, súper y diésel de manera más organizada. Adicionalmente, en ciertos casos también resulta útil revisar la demanda por franja horaria para identificar los momentos de mayor movimiento y mejorar la atención a los clientes.

Ítem 19. ¿De qué forma desearía visualizar el pronóstico (tabla en Excel, gráfico de línea, semáforo de stock, notificación móvil, dashboard web) y por qué considera ese formato más útil?

Indicador asociado: Requerimientos de interfaz y visualización.

Se podría visualizar mediante excel y semáforos de stock puede existir una mejor visualización.

Ítem 20. ¿Qué condiciones operativas (acceso a internet, equipos disponibles, perfil técnico del personal, costo de mantenimiento) considera críticas para que el modelo predictivo pueda implementarse y usarse de manera sostenida en la estación?

Indicador asociado: Restricciones de implementación y sostenibilidad.

Para implementar el modelo predictivo de manera adecuada, es necesario contar con internet estable, equipos en buen estado, personal que pueda manejar los reportes y un sistema fácil de usar y de bajo costo de mantenimiento.

Observaciones adicionales del Bloque E:

6. Escala de medición y tratamiento de las respuestas

Las respuestas se registran en formato abierto acotado y se procesan posteriormente bajo dos esquemas diferenciados, según la naturaleza del ítem:

- Ítems descriptivos (procedimientos, fuentes, señales operativas, requerimientos): se procesan mediante análisis de contenido temático, con codificación abierta en categorías que se contrastan entre los dos informantes para identificar coincidencias y divergencias.
- Ítems de cuantificación directa (galones, porcentajes, horas, costos, umbrales de tolerancia al error): se registran en escala de razón y se tabulan numéricamente, generando rangos mínimos y máximos cuando los informantes ofrezcan estimaciones aproximadas.
- Ítems de criterio funcional (horizonte de pronóstico, granularidad, formato de visualización): se registran en escala ordinal, con opciones predefinidas en la pregunta y posibilidad de respuesta alternativa explicitada por el informante.

La elección de esta combinación de escalas se justifica porque el instrumento persigue dos finalidades complementarias: (i) levantar conocimiento operativo verbalizable, propio de un enfoque cualitativo descriptivo, y (ii) obtener estimaciones técnicas cuantificables que puedan transformarse en restricciones, hiperparámetros o features del modelo predictivo. Esta articulación corresponde al diseño mixto secuencial descrito por (Creswell & Creswell, 2023, Capítulo 10).

7. Matriz de correspondencia entre ítems, variables e indicadores

La siguiente matriz evidencia la coherencia entre los veinte ítems del instrumento y la operacionalización de variables del Capítulo II del proyecto.

Tabla B.1. Matriz de correspondencia entre ítems, variables e indicadores

Bloque	Ítem	Variable / dimensión	Indicador medido	Escala
A	1	Pronóstico empírico de demanda	Procedimiento empírico de estimación diaria	Descriptiva
A	2	Pronóstico empírico de demanda	Fuentes de información utilizadas	Descriptiva
A	3	Pronóstico empírico de demanda	Margen de error subjetivo	Razón (%)
A	4	Pronóstico empírico de demanda	Frecuencia de quiebres y sobrellenado	Razón (frec.)
B	5	Reglas heurísticas de inventario	Nivel mínimo de reorden	Razón (gal/ %)
B	6	Reglas heurísticas de inventario	Volumen de pedido y ajuste	Razón (gal)
B	7	Reglas heurísticas de inventario	Lead time de abastecimiento	Razón (horas)
B	8	Reglas heurísticas de inventario	Señales detonantes no programadas	Descriptiva
C	9	Costo del error de pronóstico	Costo por quiebre de stock	Razón (USD/h)
C	10	Costo del error de pronóstico	Costo por sobrealmacenamiento	Descriptiva
C	11	Costo del error de pronóstico	Asimetría percibida del error	Ordinal
C	12	Costo del error de pronóstico	Umbral de tolerancia al error	Razón (%)
D	13	Eventos exógenos no transaccionales	Estacionalidades calendario	Descriptiva
D	14	Eventos exógenos no transaccionales	Eventos atípicos 2022–2025	Descriptiva
D	15	Eventos exógenos no transaccionales	Sensibilidad a precio regulado	Descriptiva
D	16	Eventos exógenos no transaccionales	Competencia y tránsito	Descriptiva
E	17	Aceptabilidad funcional del modelo	Horizonte de pronóstico requerido	Ordinal
E	18	Aceptabilidad funcional del modelo	Granularidad de la predicción	Ordinal
E	19	Aceptabilidad funcional del modelo	Requerimientos de interfaz	Ordinal
E	20	Aceptabilidad funcional del modelo	Restricciones de implementación	Descriptiva

Fuente: Elaboración propia.

8. Cierre y agradecimiento al participante

Estimado(a) participante:

Agradezco sincera y profundamente el tiempo, la disposición y la confianza brindados al responder esta entrevista técnica. Su conocimiento operativo es el insumo más valioso de esta investigación, permite incorporar al modelo de redes neuronales LSTM aquellas variables y reglas que no quedan registradas en la base transaccional del punto de venta, pero que en la práctica diaria determinan el éxito o el fracaso de la gestión de abastecimiento de la Estación de Servicio Divino Niño.

La información que usted ha proporcionado será tratada con absoluta confidencialidad y exclusivamente con fines académicos. Los resultados consolidados del estudio serán entregados a la administración de la estación, con la finalidad de que el modelo predictivo desarrollado pueda convertirse en una herramienta real de mejora operativa para el negocio y para el equipo del cual usted forma parte.

Si en el transcurso de los próximos días recuerda algún aspecto relevante que no fue capturado durante la entrevista, le agradeceré comunicarlo al investigador a fin de incorporarlo al análisis.

Una vez más, gracias por su colaboración.

Firma del participante
C.I.: _____

Eduardo Javier Oña Chiriboga
Investigador — C.I. 0503959645

Anexo B.

B.2 Guía de Entrevista Técnica Estructurada (GETE) Administrador

Introducción y justificación del instrumento

El presente documento contiene la Guía de Entrevista Técnica Estructurada (GETE), instrumento diseñado para la fase humana de recolección de datos del proyecto de investigación titulado “Modelo de redes neuronales para predecir el consumo de combustible automotriz en una estación de servicio”, desarrollado en la Estación de Servicio Divino Niño (comercializadora Petroecuador), ubicada en la ciudad de Latacunga, provincia de Cotopaxi.

La investigación adopta un enfoque mixto secuencial: una fase cuantitativa, sustentada en el análisis documental de los registros transaccionales del punto de venta entre el 1 de febrero de 2022 y el 30 de septiembre de 2025, y una fase cualitativa, sustentada en la entrevista técnica al personal con responsabilidad decisional directa sobre el inventario y el abastecimiento. Para esta segunda fase se elige la entrevista estructurada como técnica óptima, dado que la población humana del estudio es finita y reducida ($N = 2$: administrador de la estación y asistente de operaciones) y, por tanto, no admite un cuestionario masivo ni un muestreo probabilístico.

La elección del instrumento se fundamenta en (Creswell & Creswell, 2023, Capítulo 9), quienes recomiendan la entrevista estructurada cuando el investigador requiere garantizar comparabilidad entre informantes, reducir el sesgo del entrevistador y, al mismo tiempo, levantar conocimiento experto que no se encuentra inscrito en bases de datos. La GETE permite reconstruir el método empírico actual de pronóstico, levantar las reglas heurísticas no documentadas de inventario y registrar variables exógenas que no quedan registradas en la base transaccional, las cuales serán incorporadas como *features* adicionales en el modelo de redes neuronales recurrentes (LSTM).

La escala de medición predominante en el instrumento es de tipo nominal–descriptiva con respuesta abierta acotada, complementada con preguntas de cuantificación directa (galones, porcentajes, horas, días) en los bloques que abordan umbrales operativos y costos de error. Esta combinación se justifica porque el objetivo del instrumento no es medir actitudes sino documentar procedimientos operativos y estimar magnitudes técnicas verificables, en línea con (Creswell & Creswell, 2023, Capítulo 8).

2. Objetivos del instrumento

Objetivo general:

Levantar, mediante entrevista técnica estructurada, el conocimiento operativo y las variables exógenas no registradas en la base transaccional de la Estación de Servicio Divino Niño, con el fin de complementar el conjunto de datos histórico utilizado

para entrenar el modelo de redes neuronales LSTM de predicción del consumo de combustible automotriz.

Objetivos específicos:

- Caracterizar el régimen actual de pronóstico empírico aplicado por el personal técnico-administrativo de la estación.
- Documentar los umbrales operativos de inventario y las reglas heurísticas de abastecimiento utilizadas para cada producto (extra, súper y diésel).
- Estimar, desde la perspectiva del usuario, la estructura de costos asociada al error de pronóstico, tanto por quiebre de stock como por sobrealmacenamiento.
- Registrar los eventos exógenos relevantes (estacionalidades, eventos atípicos, cambios regulatorios) no inscritos en la base transaccional.
- Definir los requerimientos funcionales del sistema predictivo deseado por el usuario final.

3. Instrucciones para el participante

Estimado(a) colaborador(a):

Agradecemos su participación en esta entrevista, que forma parte del trabajo de investigación de grado del autor. A continuación, se presentan las indicaciones para responder de manera adecuada al instrumento

- La presente entrevista tiene una duración estimada de cuarenta y cinco a sesenta minutos.
- La entrevista está organizada en cinco bloques temáticos, con un total de veinte ítems de respuesta abierta acotada.
- Responda a cada pregunta con base en su experiencia directa en la operación de la estación de servicio; no se busca una respuesta correcta o incorrecta, sino la descripción veraz de la práctica operativa actual.
- Cuando se le solicite estimar magnitudes (galones, porcentajes, horas, costos aproximados), proporcione el dato más cercano a la realidad operativa; si no posee el dato exacto, ofrezca un rango aproximado.
- La entrevista podrá ser registrada en audio, previa autorización expresa, con el único fin de transcripción literal. Sus respuestas serán tratadas de forma confidencial y utilizadas exclusivamente con fines académicos.

- Al finalizar cada bloque temático, dispondrá de un espacio para añadir observaciones adicionales que considere relevantes y que no hayan sido capturadas por las preguntas cerradas.
- Puede solicitar al entrevistador la repetición o aclaración de cualquier ítem que no comprenda con claridad.

4. Datos sociodemográficos y de contexto del participante

Cuadro B.2. Datos sociodemográficos y de contexto del participante

Complete la información solicitada en el siguiente cuadro:

Nombres y apellidos (opcional):	Datos ocultos por confidencialidad
Edad:	25
Género:	Masculino
Nivel de instrucción:	Tercer Nivel
Cargo que desempeña:	Administrador
Tiempo en el cargo (años/meses):	3 años
Funciones principales relacionadas con la gestión de combustible:	Compra y venta de combustible
Fecha de la entrevista:	01/012/2025
Lugar de la entrevista:	Latacunga
Duración aproximada:	1 hora

Fuente: Datos proporcionados por el participante.

5. Cuerpo del instrumento — Ítems por bloque temático

El instrumento se compone de veinte ítems organizados en cinco bloques temáticos, articulados directamente con la operacionalización de variables del Capítulo II del proyecto y con la lógica de entrada de datos del modelo de redes neuronales LSTM.

BLOQUE A. Caracterización del régimen actual de pronóstico empírico

Objetivo del bloque: Reconstruir el método actual con el que la estación estima la demanda diaria de combustible y los criterios decisionales que se aplican sin apoyo de un modelo predictivo.

Variable / dimensión asociada: Variable independiente — Pronóstico empírico de demanda.

Ítem 1. Describa, paso a paso, cómo estima usted hoy la cantidad de galones de gasolina extra, súper y diésel que se venderán mañana en la estación.

Indicador asociado: Procedimiento empírico de estimación de demanda diaria.

Se realiza una recolección de datos de días pasados.

Si queremos saber ventas del día martes tomamos los 3 o 4 días martes de 3 o 4 semanas atrás.

de los datos de venta y realizamos una aproximación de venta.

Indicador asociado: Procedimiento empírico de estimación de demanda diaria.

Ítem 2. ¿Qué fuentes de información (libros contables, reportes del punto de venta, planillas Excel, observación visual del nivel de tanques, intuición) utiliza para tomar esa decisión y con qué frecuencia las consulta?

Indicador asociado: Fuentes de información utilizadas en el pronóstico empírico.

Datos del sistema de facturación

Datos del registro contable

Datos de compra. (Para saber cuando comprar en base a la venta)

Ítem 3. Cuando su estimación difiere de la venta real, ¿qué tan grande suele ser ese desfase en galones o en porcentaje? Proporcione un ejemplo concreto del último trimestre.

Indicador asociado: Margen de error subjetivo del pronóstico empírico.

Venta aproximada del Martes 28 de abril extra: ????

Venta de gasolina extra de semanas anteriores en galones:

Martes 7 de abril: 2320,936

Martes 14 de abril: 1974,940

Martes 21 de abril: 2106,008

Martes 7 2320,936

Martes 14 1974,94

Martes 21 2106,008

Promedio 2133,96133

Venta del día 28: 2196,199

Diferencia: 62,238 galones

Ítem 4. ¿Con qué frecuencia ocurre que se queda sin stock de algún producto antes del siguiente abastecimiento, y con qué frecuencia se quedan con tanques sobrelLENados que limitan el siguiente despacho?

Indicador asociado: Frecuencia de quiebres de stock y sobrealmacenamiento.

2 veces al mes sobrelLENados

Y sin stock solo por feriados de fin de año 1 vez al año.

Eso se sale de nuestras manos por la gestión de las empresas privadas o pública.

Observaciones adicionales del Bloque A:

BLOQUE B. Umbrales operativos de inventario y reglas heurísticas de abastecimiento

Objetivo del bloque: Documentar las reglas operativas no escritas que rigen el momento y el volumen del pedido de combustible, para incorporarlas como restricciones del modelo predictivo.

Variable / dimensión asociada: Variable interviniente — Reglas heurísticas de inventario.

Ítem 5. ¿Cuál es el nivel mínimo de combustible (en galones o en porcentaje de la capacidad del tanque) en el que usted decide solicitar un nuevo abastecimiento a Petroecuador, y por qué se eligió ese umbral?

Indicador asociado: Nivel mínimo de reorden (stock de seguridad operativo).

Ítem 6. ¿Qué volumen estándar de pedido maneja para cada producto (extra, súper y diésel) y bajo qué criterios ajusta este volumen ante semanas con demanda atípica?

Indicador asociado: Volumen de pedido estándar y criterios de ajuste.

Ítem 7. ¿Cuál es el tiempo promedio de respuesta (lead time) entre que se solicita el abastecimiento y se recibe el producto en sitio, y qué tan estable es ese tiempo?

Indicador asociado: Lead time de abastecimiento y su variabilidad.

Ítem 8. Describa la última vez que tuvo que tomar una decisión urgente de abastecimiento fuera del calendario habitual. ¿Qué señales del negocio le obligaron a actuar?

Indicador asociado: Señales operativas detonantes de decisiones no programadas.

Observaciones adicionales del Bloque B:

BLOQUE C. Percepción de la estructura de costos del error de pronóstico

Objetivo del bloque: Cuantificar, desde la perspectiva del personal con responsabilidad sobre el negocio, el costo económico y operativo de cada tipo de error predictivo.

Variable / dimensión asociada: Variable dependiente — Costo del error de pronóstico.

Ítem 9. Cuando la estación se queda sin un producto antes del abastecimiento programado, ¿qué consecuencias económicas y operativas observa? Estime, si es posible, el costo aproximado de una hora sin producto disponible.

Indicador asociado: Costo de oportunidad por quiebre de stock.

Ítem 10. Cuando se realiza un pedido mayor al necesario y los tanques quedan sobrellenados, ¿qué problemas operativos se generan (capacidad ociosa, retraso del siguiente pedido, riesgo de derrames, capital inmovilizado)?

Indicador asociado: Costo operativo por sobre almacenamiento.

Problemas con el tanquero de combustible, debe realizar otros pedidos a otras estaciones.

Ítem 11. Entre subestimar la demanda y sobrestimarla, ¿cuál de los dos errores considera usted más costoso para la estación y por qué?

Indicador asociado: Asimetría percibida del costo del error de pronóstico.

Cuando no se calcula bien en feriados o por cuestiones de feriados en empresas públicas, no hay quien ayude con la compra.

se pierden clientes

se molestan

la reputación de la gasolinera queda en juego

por quedarnos sin stock

en sobreestimar problemas con el transporte de combustible, posibles problemas dependiendo el conductor.

Ítem 12. ¿En qué porcentaje aproximado de error de pronóstico (por ejemplo, $\pm 5\%$, $\pm 10\%$, $\pm 15\%$) considera usted que un modelo predictivo dejaría de ser útil para la operación diaria de la estación?

Indicador asociado: Umbral de tolerancia al error de pronóstico (criterio de validación funcional).

Observaciones adicionales del Bloque C:

BLOQUE D. Registro de eventos exógenos relevantes no inscritos en la base transaccional

Objetivo del bloque: Levantar las variables exógenas que afectan el consumo y que no quedan registradas en el sistema de punto de venta, con el fin de incorporarlas como features adicionales del modelo LSTM.

Variable / dimensión asociada: Variable interviniente — Eventos exógenos no transaccionales.

Ítem 13. ¿Qué fechas o periodos del año (feriados, inicio de clases, temporadas turísticas, fines de mes, días de pago) muestran de manera recurrente un comportamiento de demanda atípico en la estación?

Indicador asociado: Estacionalidades exógenas calendario.

Regreso a clases

día de la madre

Inicios de clase

Navidad

Año nuevo

Ítem 14. Describa eventos no recurrentes ocurridos entre 2022 y 2025 (paros nacionales, cierres viales, cambios de subsidio de combustibles, escasez logística, eventos climáticos extremos) que hayan alterado significativamente las ventas. Indique fecha aproximada, duración y producto afectado.

Indicador asociado: Eventos atípicos exógenos (outliers contextuales).

Paros nacionales

Decreto de cierre y control de vías donde estén cárceles

Cambio de precios por subsidios.

Productos afectados; extra, súper y diésel

Ítem 15. ¿Cuál es el impacto observado de los cambios de precio regulado del combustible sobre el volumen de ventas en los días inmediatamente anteriores y posteriores al ajuste de precio?

Indicador asociado: Sensibilidad de la demanda a la política de precios.

Días antes del cambio de precios se aumenta las ventas significativamente, de productos extra y diésel.

días después del cambio, las ventas son normales o posiblemente bajas porque ya cargaron con 1 día de anticipación.

Ítem 16. ¿Existen patrones de demanda asociados a la apertura o cierre de estaciones de servicio competidoras en el área de influencia, o a obras viales que modifiquen el tránsito vehicular? Describa los casos observados.

Indicador asociado: Variables competitivas y de tránsito.

Sí, cuando se crean o se construyen nuevas gasolineras, el tránsito vehicular varía y por ende baja la venta.

Al de igual manera cuando se cierra unas estaciones, el tráfico vehicular cambia y se nota más ventas.

Observaciones adicionales del Bloque D:

BLOQUE E. Requerimientos funcionales del sistema predictivo deseado

Objetivo del bloque: Definir, desde la voz del usuario final, los requisitos funcionales y de interfaz que debe cumplir el modelo de redes neuronales para ser efectivamente adoptado en la operación de la estación.

Variable / dimensión asociada: Variable dependiente — Aceptabilidad funcional del modelo predictivo.

Ítem 17. ¿Con qué horizonte temporal (1 día, 7 días, 15 días, 30 días) considera más útil recibir el pronóstico de consumo de combustible para apoyar sus decisiones de abastecimiento?

Indicador asociado: Horizonte de pronóstico requerido.

1 día

Ítem 18. ¿Con qué granularidad de salida prefiere el resultado (por producto, por surtidor, por franja horaria, total diario), y qué nivel de detalle considera necesario para la operación?

Indicador asociado: Granularidad de la predicción requerida.

Por producto y por total diario

Ítem 19. ¿De qué forma desearía visualizar el pronóstico (tabla en Excel, gráfico de línea, semáforo de stock, notificación móvil, dashboard web) y por qué considera ese formato más útil?

Indicador asociado: Requerimientos de interfaz y visualización.

Todas, un dashboard donde nos permita descargar la tabla de Excel

Ítem 20. ¿Qué condiciones operativas (acceso a internet, equipos disponibles, perfil técnico del personal, costo de mantenimiento) considera críticas para que el modelo predictivo pueda implementarse y usarse de manera sostenida en la estación?

Indicador asociado: Restricciones de implementación y sostenibilidad.

Costo de mantenimiento, equipos disponibles

Observaciones adicionales del Bloque E:

6. Escala de medición y tratamiento de las respuestas

Las respuestas se registran en formato abierto acotado y se procesan posteriormente bajo dos esquemas diferenciados, según la naturaleza del ítem:

- Ítems descriptivos (procedimientos, fuentes, señales operativas, requerimientos): se procesan mediante análisis de contenido temático, con codificación abierta en categorías que se contrastan entre los dos informantes para identificar coincidencias y divergencias.
- Ítems de cuantificación directa (galones, porcentajes, horas, costos, umbrales de tolerancia al error): se registran en escala de razón y se tabulan numéricamente, generando rangos mínimos y máximos cuando los informantes ofrezcan estimaciones aproximadas.
- Ítems de criterio funcional (horizonte de pronóstico, granularidad, formato de visualización): se registran en escala ordinal, con opciones predefinidas en la pregunta y posibilidad de respuesta alternativa explicitada por el informante.

La elección de esta combinación de escalas se justifica porque el instrumento persigue dos finalidades complementarias: (i) levantar conocimiento operativo verbalizable, propio de un enfoque cualitativo descriptivo, y (ii) obtener estimaciones técnicas cuantificables que puedan transformarse en restricciones, hiperparámetros o features del modelo predictivo. Esta articulación corresponde al diseño mixto secuencial descrito por (Creswell & Creswell, 2023, Capítulo 10).

7. Matriz de correspondencia entre ítems, variables e indicadores

La siguiente matriz evidencia la coherencia entre los veinte ítems del instrumento y la operacionalización de variables del Capítulo II del proyecto.

Tabla B.2. Matriz de correspondencia entre ítems, variables e indicadores

Bloque	Ítem	Variable / dimensión	Indicador medido	Escala
A	1	Pronóstico empírico de demanda	Procedimiento empírico de estimación diaria	Descriptiva
A	2	Pronóstico empírico de demanda	Fuentes de información utilizadas	Descriptiva
A	3	Pronóstico empírico de demanda	Margen de error subjetivo	Razón (%)
A	4	Pronóstico empírico de demanda	Frecuencia de quiebres y sobrellenado	Razón (frec.)
B	5	Reglas heurísticas de inventario	Nivel mínimo de reorden	Razón (gal/ %)
B	6	Reglas heurísticas de inventario	Volumen de pedido y ajuste	Razón (gal)
B	7	Reglas heurísticas de inventario	Lead time de abastecimiento	Razón (horas)
B	8	Reglas heurísticas de inventario	Señales detonantes no programadas	Descriptiva

Fuente: Elaboración propia.

Tabla B.2. Matriz de correspondencia entre ítems, variables e indicadores (continuación)

Bloque	Ítem	Variable / dimensión	Indicador medido	Escala
C	9	Costo del error de pronóstico	Costo por quiebre de stock	Razón (USD/h)
C	10	Costo del error de pronóstico	Costo por sobrealmacenamiento	Descriptiva
C	11	Costo del error de pronóstico	Asimetría percibida del error	Ordinal
C	12	Costo del error de pronóstico	Umbral de tolerancia al error	Razón (%)
D	13	Eventos exógenos no transaccionales	Estacionalidades calendario	Descriptiva
D	14	Eventos exógenos no transaccionales	Eventos atípicos 2022–2025	Descriptiva
D	15	Eventos exógenos no transaccionales	Sensibilidad a precio regulado	Descriptiva
D	16	Eventos exógenos no transaccionales	Competencia y tránsito	Descriptiva
E	17	Aceptabilidad funcional del modelo	Horizonte de pronóstico requerido	Ordinal
E	18	Aceptabilidad funcional del modelo	Granularidad de la predicción	Ordinal
E	19	Aceptabilidad funcional del modelo	Requerimientos de interfaz	Ordinal
E	20	Aceptabilidad funcional del modelo	Restricciones de implementación	Descriptiva

Fuente: Elaboración propia.

8. Cierre y agradecimiento al participante

Estimado(a) participante:

Agradezco sincera y profundamente el tiempo, la disposición y la confianza brindados al responder esta entrevista técnica. Su conocimiento operativo es el insumo más valioso de esta investigación, permite incorporar al modelo de redes neuronales LSTM aquellas variables y reglas que no quedan registradas en la base transaccional del punto de venta, pero que en la práctica diaria determinan el éxito o el fracaso de la gestión de abastecimiento de la Estación de Servicio Divino Niño.

La información que usted ha proporcionado será tratada con absoluta confidencialidad y exclusivamente con fines académicos. Los resultados consolidados del estudio serán entregados a la administración de la estación, con la finalidad de que el modelo predictivo desarrollado pueda convertirse en una herramienta real de mejora operativa para el negocio y para el equipo del cual usted forma parte.

Si en el transcurso de los próximos días recuerda algún aspecto relevante que no fue capturado durante la entrevista, le agradeceré comunicarlo al investigador a fin de incorporarlo al análisis.

Una vez más, gracias por su colaboración.

Firma del participante
C.I.: _____

Eduardo Javier Oña Chiriboga
Investigador — C.I. 0503959645