

MODELADO DE EMISIONES DE CO₂ EN EL SECTOR TRANSPORTE PERUANO MEDIANTE SUSTITUCIÓN DE COMBUSTIBLES: UN ENFOQUE PREDICTIVO CON ARIMA Y REDES NEURONALES

MODELING CO₂ EMISSIONS IN THE PERUVIAN TRANSPORT SECTOR THROUGH FUEL SUBSTITUTION: A PREDICTIVE APPROACH WITH ARIMA AND NEURAL NETWORKS

Tipo de Publicación: Artículo Científico

Recibido: 01/02/2026

Aceptado: 02/03/2026

Publicado: 01/04/2026

Código Único AV: e682

Páginas: 1(596-616)

DOI: <https://doi.org/10.5281/zenodo.19373027>

Autor:

Carlos Aurelio Garván Gamarra

Ingeniero Mecánico

Maestría en Ingeniería, mención en Aplicación
Energética del Gas Natural

 <https://orcid.org/0009-0007-0888-8779>

E-mail: carlos.garvan.g@uni.pe

Afiliación: Universidad Nacional de Ingeniería

País: República del Perú

Resumen

El sector transporte en Perú es el principal generador de CO₂, con un alto uso de combustibles fósiles como el diésel y la gasolina, lo cual representa una problemática en cuanto al cumplimiento de los compromisos climáticos del país. Al respecto, la investigación tuvo como objetivo modelar las emisiones de dióxido de carbono que resultarían de sustituir estos combustibles por opciones que generen menos contaminación, como el gas natural vehicular (GNV) y el gas licuado de petróleo (GLP). La metodología partió de un enfoque cuantitativo mediante el estudio de series temporales, utilizando modelos autorregresivos integrados de medias móviles (ARIMA), programación lineal y redes neuronales artificiales sobre datos de consumo recopilados entre 2007 y 2021. Los resultados mostraron que el modelo ARIMA (2,1,1) (1,1,1) [12] ofreció el mejor ajuste para predecir las emisiones relacionadas con el diésel, la gasolina y el GLP, mientras que la serie del GNV mostró un crecimiento lineal. Las proyecciones para el año 2030 indicaron que, en un escenario continuo, el diésel seguiría siendo responsable del 64% de las emisiones totales en el sector. Por lo tanto, la sustitución completa del diésel por GNV podría llevar a una disminución del 99.21% en emisiones, y un cambio a GLP podría reducirlas en un 85.85%. Se concluye que avanzar hacia combustibles más ecológicos, especialmente el GNV, tiene un gran potencial para la mitigación, además de ofrecer un análisis basado en modelos predictivos para respaldar las políticas de descarbonización del transporte en Perú.

Palabras Clave

Emisiones de CO₂, Transporte terrestre, Sustitución de combustibles, Modelo ARIMA, Redes neuronales artificiales, Gas natural vehicular, Perú.

Abstract

The transportation sector in Peru is the main generator of CO₂, with high use of fossil fuels such as diesel and gasoline, which poses a challenge to the country's climate commitments. In this regard, the research aimed to model the carbon dioxide emissions that would result from replacing these fuels with less polluting alternatives, such as compressed natural gas (CNG) and liquefied petroleum gas (LPG). The methodology employed a quantitative approach using time series analysis, with autoregressive integrated moving average (ARIMA) models, linear programming, and artificial neural networks applied to consumption data collected between 2007 and 2021. The results showed that the ARIMA (2,1,1) (1,1,1) model [12] provided the best fit for predicting emissions related to diesel, gasoline, and LPG, while the CNG series showed linear growth. Projections for 2030 indicated that, under business as usual, diesel would still be responsible for 64% of total emissions in the sector. Therefore, a complete replacement of diesel with CNG could lead to a 99.21% decrease in emissions, and a switch to LPG could reduce them by 85.85%. It is concluded that moving towards cleaner fuels, especially CNG, has great potential for mitigation, and this analysis, based on predictive models, can support transportation decarbonization policies in Peru.

Keywords CO₂ emissions, Land transport, Fuel substitution, ARIMA model, Artificial neural networks, Vehicular natural gas, Peru.

Introducción

La situación actual del sector transporte en la matriz energética del Perú demanda un enfoque que contemple la eliminación de combustibles fósiles, tales como el diésel y la gasolina, que son los principales generadores de las emisiones de dióxido de carbono (CO₂) a la atmósfera y responsables del calentamiento global, un fenómeno cuyo efecto ya se está haciendo notar en todo el mundo. Este contexto se relaciona con los compromisos climáticos internacionales asumidos por el Perú, desde el Acuerdo de París hasta la más reciente Conferencia de las Partes (COP), donde se establecieron objetivos progresivas de reducción de emisiones de gases de efecto invernadero (GEI), alcanzando un compromiso del 40% para el año 2030 (MINAM – COP21, 2015).

La relevancia del tema radica en que el sector transporte es el mayor emisor de GEI dentro del sector energético peruano, representando aproximadamente el 40.56% de sus emisiones (MINAM – COP25, 2019). Por lo tanto, abordar la descarbonización de este sector no solo es importante para cumplir con los acuerdos internacionales, sino también para mejorar la calidad del aire, promover la seguridad energética y encaminar al país hacia un desarrollo sostenible de bajas emisiones.

El análisis de la sustitución de combustibles es delicado al observar la estructura del consumo

energético final nacional. En el año 2022, el sector transporte consumió 399.260,2 tera joule (TJ), lo que representa el 41,4% del consumo final nacional, dominado por derivados del petróleo como el diésel B5 y el gasohol (MINEM – BNE, 2022).

La dependencia con respecto al uso de combustibles fósiles genera una doble preocupación: por un lado, contribuye significativamente al cambio climático a través de las emisiones de CO₂; y por otro, expone al país a la volatilidad de los precios internacionales del petróleo y a los riesgos asociados con el agotamiento de recursos no renovables (Salaet & Roca, 2010). En consecuencia, transitar hacia una matriz de transporte más limpia se convierte en un imperativo ambiental, económico y social.

El problema central que aborda esta investigación es la elevada contribución del sector transporte terrestre peruano a las emisiones nacionales de gases de efecto invernadero, específicamente de dióxido de carbono (CO₂). Según el Inventario Nacional de GEI 2019, este sector es responsable del 40.56% de las emisiones del sector energía, siendo los combustibles fósiles derivados del petróleo sus principales fuentes (MINAM – INGEI, 2019). Esta situación genera externalidades negativas críticas, como el deterioro de la calidad del aire, de hecho Lima es la octava ciudad más contaminada de Latinoamérica (World Air Quality, 2018) y la contribución al calentamiento global.

La dependencia tecnológica actual, dominada por motores de combustión interna que utilizan diésel y gasolina, perpetúa este modelo insostenible. Además, factores como la antigüedad del parque automotor, donde el 30% de los vehículos supera los 16 años de uso, y el predominio del diésel en el 86% de la flota, agravan el problema de las emisiones (OCDE / ITF, 2009). Por lo tanto, se identifica una clara necesidad de transformar el paradigma energético del transporte.

Un aspecto clave del problema es la falta de aplicación de modelos predictivos que permitan cuantificar con precisión el impacto potencial de la sustitución de combustibles tradicionales por alternativos más limpios. Si bien existen compromisos políticos nacionales, como los establecidos en las COP y la Estrategia Nacional ante el Cambio Climático al 2050, la planificación para alcanzarlos carece frecuentemente de herramientas analíticas sofisticadas que simulen escenarios futuros bajo diferentes supuestos (Santa & Regalado, 2022). Esta carencia limita la capacidad de los tomar decisiones para priorizar inversiones, diseñar incentivos efectivos y evaluar el ritmo necesario de descarbonización. En consecuencia, la pregunta de investigación que guía este trabajo es: ¿De qué manera se puede modelar las emisiones de dióxido de carbono, debido a la sustitución de los combustibles en el sector transporte? Esta interrogante busca no solo desarrollar una

metodología predictiva, sino también generar evidencia concreta sobre el potencial de mitigación que ofrece el cambio de matriz energética en el transporte.

La justificación teórica de esta investigación se fundamenta en su contribución al conocimiento sobre la dinámica de las emisiones del sector transporte y la evaluación de estrategias de mitigación en el contexto peruano, alineándose con marcos conceptuales de economía ambiental, transición energética y análisis de sistemas complejos mediante series temporales (Sharma et al., 2024; Iftikhar et al., 2024; Altikat, 2021; Jena et al., 2021).

Desde una perspectiva práctica, el estudio posee alto potencial para influir en políticas públicas e inversiones, como lo evidencia su apoyo a iniciativas como el programa de cambio a GNV con tecnología EURO V, al cuantificar el impacto de sustituir diésel y gasolina por GNV y GLP, orientando así incentivos fiscales, normas técnicas e infraestructura. Metodológicamente, se justifica por la aplicación rigurosa y comparativa de técnicas cuantitativas avanzadas como modelos ARIMA, programación lineal y redes neuronales artificiales, que permiten una evaluación comprehensiva y una triangulación que fortalece la validez de los resultados (Li & Zhang, 2023), ofreciendo un marco replicable para futuras investigaciones en otros sectores o regiones.

El marco teórico se sustenta en varias bases conceptuales clave. En primer lugar, el cambio climático, definido por el IPCC (2013) como una alteración del estado del clima atribuible directa o indirectamente a la actividad humana, constituye el contexto global del problema. Los gases de efecto invernadero (GEI), especialmente el CO₂, actúan como forzantes radiativos, reteniendo calor en la atmósfera y provocando el calentamiento global (CMNUCC, 1992).

En el Perú, el sector energía es el segundo mayor emisor de GEI, y dentro de él, el transporte es la subcategoría más importante (MINAM - INGEI, 2019). La cadena de valor de los combustibles fósiles, desde su extracción hasta su combustión en los motores, está intrínsecamente ligada a estas emisiones. Por el contrario, el gas natural y sus derivados, como el GNV, presentan una huella de carbono significativamente menor debido a su mayor contenido de hidrógeno en la molécula de metano (CH₄), lo que resulta en una combustión más completa y con menores emisiones de CO₂ por unidad de energía liberada (OSINERGMIN, 2014).

La tecnología de los motores de combustión interna (MCI) es otro pilar teórico fundamental. Estos motores, que operan bajo los ciclos termodinámicos Otto (para gasolina y GNV) y Diésel (para diésel), son los principales convertidores de la energía química de los combustibles en trabajo mecánico para el transporte

(Rafael & Hernández, 2014). Sin embargo, su eficiencia y sus emisiones varían considerablemente según el combustible utilizado. Mientras los motores diésel suelen ser más eficientes térmicamente, también tienden a emitir mayores cantidades de material particulado y óxidos de nitrógeno. La conversión o adaptación de los MCI para utilizar combustibles gaseosos como el GNV o el GLP es una estrategia tecnológica viable para reducir emisiones, especialmente cuando se combina con sistemas de inyección y control electrónico modernos (García et al., 2016). Los antecedentes de la investigación parten del estudio de la Tabla 1:

Autores (Año)	País/Región	Modelo(s) Utilizado(s)	Principal Hallazgo
Sharma et al., (2024)	India	ARIMA	Los modelos ARIMA son efectivos para capturar tendencia y estacionalidad en emisiones de carbono.
Iftikhar et al., (2024)	Pakistán	Combinaciones híbridas (Regresión + Series de Tiempo)	Las técnicas de pronóstico híbridas propuestas son altamente precisas y eficientes.
Li & Zhang (2023)	China	ARIMA, SARIMAX, ANN, LSTM	Los modelos de aprendizaje automático (especialmente LSTM) superan sistemáticamente a los modelos estadísticos.
Mantilla et al., (2023)	Colombia	Método estandarizado IPCC/AEMA	Las emisiones del transporte por carretera mostraron un aumento progresivo, con reducción en 2020 por COVID-19.
Altikat (2021)	Condiciones de invernadero	ANN, DLNN, Regresión Lineal Múltiple	Las redes neuronales de aprendizaje profundo (DLNN) modelaron el flujo de CO ₂ con la mayor precisión (98.29%).
Hagos & Ahlgren (2020)	Dinamarca	Modelo TIMES	El gas natural puede servir como un combustible de transición rentable hacia 2050 en un sistema descarbonizado.

Tabla 1. Comparación de modelos de pronóstico de emisiones según estudios previos

El objetivo general de esta investigación es modelar las emisiones de dióxido de carbono debido a la sustitución de combustibles en el sector transporte. Para operacionalizar este propósito general, se plantean dos objetivos específicos. En primer lugar, establecer escenarios de sustitución de combustibles en el sector transporte, lo que implica definir y caracterizar diferentes trayectorias de penetración de combustibles alternativos como el GNV y el GLP en reemplazo del diésel y la gasolina.

En segundo lugar, determinar las emisiones de dióxido de carbono para los diferentes escenarios a proponer, mediante la aplicación de modelos predictivos (ARIMA, Programación Lineal y Redes Neuronales Artificiales) a las series históricas de consumo, lo que permitirá cuantificar y comparar el impacto en las emisiones de CO₂ de cada escenario a lo largo del horizonte de planificación hasta el año 2030.

Metodología

El método utilizado en este estudio se basa en un diseño correlacional descriptivo, no experimental, apoyado en un enfoque cuantitativo, y aplica un enfoque analítico interpretativo. Inicialmente, se eligió este modelo porque el objetivo principal era identificar y probar las relaciones de causa y efecto entre las variables de interés sin interferir ni modificar las condiciones bajo las cuales se obtuvieron los datos. El estudio se centró específicamente en examinar las emisiones de

CO₂ resultantes de la sustitución de fuentes de energía fósiles, como el diésel y la gasolina, por fuentes de energía alternativas más sostenibles, como el gas natural automotor (GNC) y el gas licuado de petróleo (GLP) en el sector del transporte por carretera en Perú.

Para ello se utilizan modelos estadísticos para describir tendencias históricas y evaluar emisiones, basados en series temporales y utilizando técnicas de previsión como ARIMA, programación lineal y redes neuronales artificiales para predecir escenarios futuros. En cuanto a las limitaciones del estudio, el tema incluye todas las emisiones de CO₂ generadas por el tráfico rodado en el Perú durante el período de análisis, incluyendo las emisiones de automóviles, camiones, autobuses y motocicletas en todo el país. Debido a la naturaleza del estudio y a la disponibilidad de documentos oficiales completos, el muestreo no se realizó en el sentido estadístico habitual. En su lugar, trabajamos con escaneo de datos, analizando todos los registros de consumo mensual de diésel, gasolina, GLP y GNC del sector del transporte por carretera durante el período especificado, asegurando así una cobertura total de la población de interés.

En cuanto a la recolección de información, la técnica utilizada fue examinar documentos de fuentes secundarias únicamente. Esto incluyó la consulta sistemática de bases de datos nacionales e internacionales, informes oficiales del Gobierno del

Perú y publicaciones de organismos multilaterales. Específicamente, se recopilan datos de entidades como el Ministerio del Ambiente (MINAM), el Ministerio de Energía y Minas (MINEM), el Organismo Supervisor de Inversiones Energéticas y Mineras (OSINERGMIN) y el sistema INFOGAS, entre otros organismos mencionados en el documento. Un aspecto clave del proceso es probar la validez y confiabilidad de estos datos, asegurando que sean relevantes, consistentes y actualizados para respaldar un análisis riguroso.

Una vez recopilada la información, para procesar los datos se utilizará el software libre RStudio, el cual fue elegido por su efectividad en el análisis estadístico y modelado de series de tiempo. El primer paso es limpiar y clasificar la información, donde se realizan análisis descriptivos para resumir las características más relevantes, incluyendo medidas de tendencia central y varianza. Por lo tanto, para estudiar las relaciones subyacentes y el pronóstico, en la práctica se han aplicado muchas técnicas estadísticas avanzadas.

Para pronosticar futuras emisiones de CO₂, se han implementado y comparado tres tipos de modelos: modelos ARIMA para análisis de series temporales, modelos de programación lineal para capturar relaciones funcionales específicas y modelos de redes neuronales artificiales para estudiar predicciones basadas en aprendizaje automático.

Finalmente, los resultados de todos estos análisis y predicciones se han condensado y presentado de forma clara a través de tablas, figuras y gráficos, facilitando la interpretación de los resultados y el alcance de los objetivos marcados en el estudio.

Resultados

Los resultados logrados, junto con las referencias bibliográficas, se muestran en la Tabla 1, respectivamente. En esta sección se presentan los resultados de la investigación, organizados según los objetivos específicos y obtenidos mediante la aplicación de un modelo autorregresivo móvil integrado, programación lineal y redes neuronales artificiales (RNA) los cuales ayudan a pronosticar las emisiones de dióxido de carbono (CO₂) en el sector transporte peruano, teniendo en cuenta la transición de combustibles fósiles tradicionales (diésel y gasolina) a opciones más sostenibles (gas licuado de petróleo-GLP y gas natural vehicular-GNC). El análisis se basa en datos históricos de consumo de 2007 a 2021 y se extiende hasta 2030, lo que permite escenarios de mitigación.

Modelado de las Emisiones de CO₂

El objetivo general de la investigación fue modelar las emisiones de dióxido de carbono derivadas de la sustitución de combustibles en el sector transporte. Este objetivo se cumplió mediante la aplicación y comparación de tres técnicas de

modelado predictivo a las series temporales de emisiones de CO₂ asociadas al consumo de diésel, gasolina, GLP y GNV.

Se utilizaron los datos secundarios de consumo proporcionados por OSINERGMIN (para diésel, gasolina y GLP, período 2007-2021) e INFOGAS (para GNV, período 2013-2021). Previo al modelado, se realizó un proceso de limpieza y tratamiento de datos para imputar valores atípicos y garantizar la consistencia de las series, tal como se ejemplifica en la Figura 1:




Figura 1. Imputación de valores atípicos (espurios) de CO₂ del diésel TM, gasolina TM y GLP TM

Nota. La Figura muestra la imputación de valores atípicos (espurios) de las emisiones de CO₂ en distintos combustibles

del sector transporte. En el caso del diésel, se observan los puntos rojos como datos atípicos, la línea gris representa las emisiones reales, la línea azul la serie ajustada y la línea roja el efecto causado por dichos valores. Para la gasolina (TM) y el GLP (TM), se identifican igualmente valores espurios que afectan la representación de las emisiones. Fuente: Elaboración propia.

El modelado se dividió en dos fases principales: a) el desarrollo y validación de modelos predictivos individuales para cada combustible, y b) la integración de estos pronósticos para construir escenarios agregados de emisiones y sustitución. Los resultados demuestran que es factible generar modelos robustos que capturen la tendencia histórica y permitan proyectar con un grado de confianza aceptable las emisiones futuras bajo condiciones de continuidad, sentando las bases para evaluar el impacto de políticas de sustitución.

Establecimiento de escenarios de sustitución de combustibles

El primer objetivo específico se orientó a establecer escenarios de sustitución de combustibles en el sector transporte. Para ello, fue necesario primero caracterizar la participación histórica de cada combustible en la matriz de emisiones del sector y, posteriormente, proyectar su trayectoria futura bajo un escenario "business as usual" (BAU), es decir, sin intervenciones de política adicionales. Estos pronósticos constituyen la línea base contra la cual se pueden medir los potenciales efectos de programas de sustitución.

Caracterización histórica de las emisiones por combustible (2007-2021)

Un dato importante, que sustenta plantear escenarios de sustitución, es la marcada heterogeneidad en la contribución de los diferentes combustibles a las emisiones totales del sector transporte. El análisis de la serie histórica 2007-2021, representada en la Figura 2 (Emisiones de CO₂ del sector transporte del Perú 2007-2021), revela una tendencia general de crecimiento en las emisiones hasta 2019, con una caída abrupta en 2020 debido a las restricciones impuestas por la pandemia de COVID-19, seguida de una recuperación incipiente en 2021.

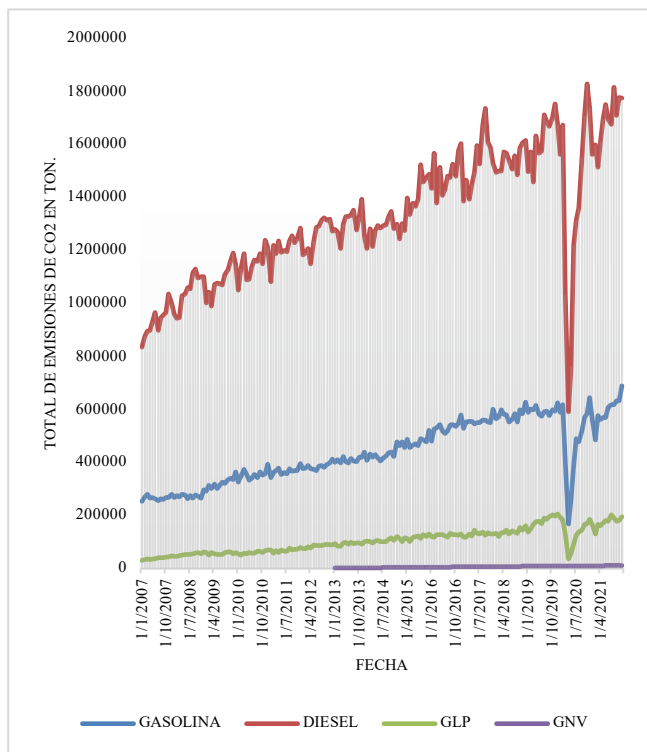


Figura 2 Emisiones de CO₂ del sector transporte del Perú, 2007– 2021 (TM)

Nota. La Figura detalla las emisiones de CO₂ del transporte nacional, 2007-2021(TM). Tomado el 2023 de OSINERGMIN-INFOGAS.

Al desagregar esta tendencia agregada por tipo de combustible, se identificó que el diésel fue, con gran diferencia, el principal emisor de CO₂ a lo largo de todo el período analizado. Le siguieron en orden decreciente la gasolina, el GLP y, finalmente, el GNV.

Este orden de prelación se mantuvo incluso durante la caída de 2020, aunque con una particularidad: mientras las emisiones de diésel, gasolina y GLP experimentaron una reducción significativa ese año, las del GNV mostraron una notable resiliencia, con una disminución mucho menos pronunciada.

Modelado predictivo para la construcción de la línea base (2022-2030)

La construcción de escenarios prospectivos requiere de pronósticos confiables. Para generar la línea base de emisiones hasta 2030, se seleccionaron y calibraron los mejores modelos para cada combustible.

Tras el análisis de las funciones de autocorrelación simple y parcial (ejemplificado en la Figura 3 para diésel, gasolina y GLP, respectivamente), el modelo que presentó el mejor ajuste y capacidad predictiva para estas tres series fue un ARIMA (2,1,1)(1,1,1)[12]. Este modelo indica que la serie requiere una diferenciación simple y estacional (parámetros "1" en las partes no estacional y estacional) para alcanzar estacionariedad, e incorpora componentes

autorregresivos y de medias móviles tanto para los rezagos inmediatos (orden 2,1) como para el patrón estacional anual (orden 1,1 con período 12 meses).

Específicamente, con respecto al diésel, la ecuación del modelo ajustado para las emisiones de CO₂ (en toneladas métricas) fue:

$$Y_t = 0.3798Y_{t-1} + 0.0608Y_{t-2} - 0.8656\varepsilon_{t-1} - 0.0288Y_{t-12} - 0.8446\varepsilon_{t-12} + \varepsilon_t$$

Las medidas de error en la etapa de testeo (2021) fueron RMSE = 52,012.78 TM y MAPE = 2.58% (Tabla 2), indicando una alta precisión.

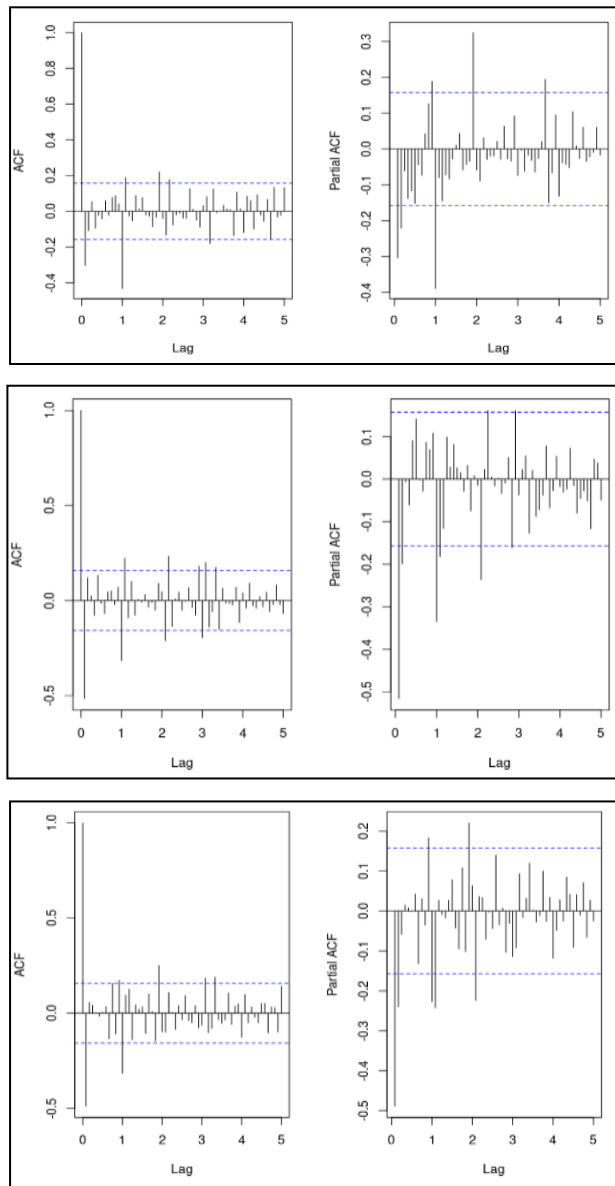


Figura 3. Autocorrelación simple y parcial de emisión CO₂, diésel, gasolina y GLP 2007-2020

Nota. Las Figuras comparativas muestran la autocorrelación simple y parcial de las emisiones de CO₂ en distintos combustibles del sector transporte. Fuente: Elaboración propia.

Modelo	Medidas de ajuste 2007-2020		Medidas de testeo 2021	
	RMSE	MAPE	RMSE	MAPE
ARIMA (2,1,1) (1,1,1) [12]	49945.11	2.61	52012.78	2.58

Tabla 2. MAPE y RMSE de emisiones de CO₂ del diésel.

Nota. La Tabla muestra el MAPE y RMSE de las emisiones de CO₂ del diésel.

El pronóstico (Ver Figura 4) muestra una tendencia de crecimiento sostenido hacia 2030.




Figura 4. Valores pronosticados ARIMA 2022 – 2030, CO₂ diésel (TM)

Nota. La Figura habla de la afinidad de tendencia ARIMA 2022-2030 del CO₂ del diésel (TM): Elaboración propia 2023.

En cuanto a la gasolina, el modelo ajustado para las emisiones de CO₂ (en toneladas métricas) fue:

$$Y_t = -0.9593Y_{t-1} - 0.4034Y_{t-2} + 0.3009\varepsilon_{t-1} + 0.0425Y_{t-12} - 0.82186\varepsilon_{t-12} + \varepsilon_t$$

Con un RMSE de 37,873.53 TM y un MAPE de 4.94% en 2021 (Tabla 3), el pronóstico (Figura 5) también proyecta un crecimiento, aunque con una pendiente menos pronunciada que la del diésel.

Modelo	Medidas de ajuste 2007-2020		Medidas de testeo 2021	
	RMSE	MAPE	RMSE	MAPE
ARIMA (2,1,1) (1,1,1) [12]	12404.99	2.13	37873.53	4.94

Tabla 3. Error porcentual absoluto medio (MAPE) y raíz cuadrada media del error (RMSE) de emisiones de CO₂ de la gasolina

Nota. La figura muestra el MAPE y RMSE de emisiones de CO₂ de la gasolina. Fuente: Elaboración propia 2023.




Figura 5. Valores pronosticados 2022 – 2030, CO₂ gasolina (TM)

Nota. La figura nos da a conocer los valores pronosticados 2022 al 2030 de CO₂ de la gasolina (TM).

Para el caso de GLP, la ecuación resultante para las emisiones de CO₂ (en toneladas métricas) fue:

$$Y_t = -0.6138Y_{t-1} - 0.2282Y_{t-2} + 0.0376\varepsilon_{t-1} + 0.1779Y_{t-12} - 0.8148\varepsilon_{t-12} + \varepsilon_t$$

Los errores de pronóstico para 2021 fueron RMSE = 17,829.1 TM y MAPE = 6.42% (Tabla 4). La proyección (Figura 6) evidencia la tendencia creciente de este combustible.

Modelo	Medidas de ajuste 2007-2020		Medidas de testeo 2021	
	RMSE	MAPE	RMSE	MAPE
ARIMA (2,1,1) (1,1,1) [12]	6059.68	4.13	17829.1	6.42

Tabla 4. MAPE y RMSE de emisiones de CO₂ del GLP
 Nota. La tabla muestra el MAPE y RMSE de las emisiones de CO₂ del GLP.




Figura 6. Valores pronosticados 2022 - 2030 ARIMA de CO₂ del GLP (TM)

Nota. La Figura muestra los valores pronosticados 2022-2030 ARIMA de CO₂ del GLP (TM).

Para GNV, dada la naturaleza marcadamente lineal y con menor historial de datos (desde 2013) de la serie de emisiones del GNV, el modelo óptimo fue una regresión lineal simple. Como se muestra en la Figura 7.




Figura 7. Valores ajustados de emisiones CO₂ del GNV, 2013-2020 (TM)

Nota. La Figura detalla el comportamiento lineal de emisiones de CO₂ del GNV.

El ajuste fue casi perfecto, con la ecuación 24 y un coeficiente de determinación R² = 0.9992.

$$y_{GNV} = 2.9495x - 119077$$

El resultado indica que, en el período analizado, el crecimiento de las emisiones por GNV siguió un patrón lineal constante, permitiendo proyecciones muy confiables (Ver Figura 8).

La Tabla 5 sintetiza la superioridad del modelo ARIMA sobre los modelos de Redes Neuronales Artificiales (RNA) tipo NNAR para pronosticar las series de diésel, gasolina y GLP, al presentar menores valores de Error Cuadrático Medio (RMSE) y Error Porcentual Absoluto Medio (MAPE).

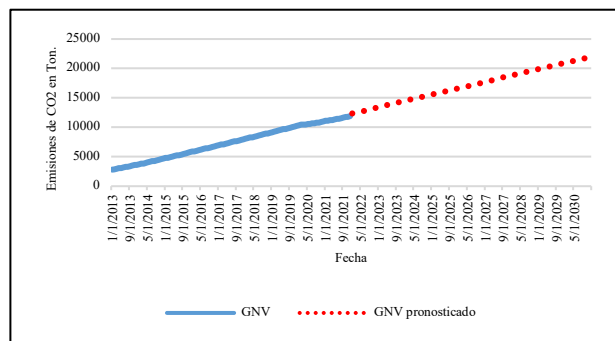


Figura 8. Valores pronosticados 2022 - 2030 con y_{GNV} de CO₂ del GNV (TM)

Nota. La Figura detalla los valores pronosticados 2022-2030 con modelo Y_{GNV} de CO₂ (TM).

Componente	Modelo	Medidas de ajuste 2007 - 2020		Medidas de testeo 2021	
		RMSE	MAPE	RMSE	MAPE
Diésel	ARIMA (2,1,1) (1,1,1) [12]	49945.1 1	2.61	52012.78	2.58
	NNAR (4,1,3) [12]	48217.6 5	2.64	91456.90	3.94
Gasolina	ARIMA (2,1,1) (1,1,1) [12]	12404.9 9	2.13	37873.53	4.94
	NNAR (2,1,2) [12]	15834.9 0	2.57	45507.86	4.99
GLP	ARIMA (2,1,1) (1,1,1) [12]	6059.68	4.13	17829.10	6.42
	NNAR(2,1,2)[12]	6280.50	4.68	17887.05	6.79

Tabla 5. Comparación de modelos ARIMA y NNAR de emisiones de CO₂ (TM)

Nota. La tabla muestra los modelos ARIMA y NNAR con sus emisiones de CO₂ (TM).

Esta comparación valida la elección del ARIMA como herramienta principal para establecer la línea base de emisiones de los combustibles convencionales.

Composición de la línea base de emisiones al 2030

La agregación de los pronósticos individuales permite cuantificar el escenario tendencial. Los resultados, consolidados en el análisis son contundentes: si se mantienen las dinámicas actuales de consumo, el diésel continuará dominando la matriz de emisiones del transporte peruano al menos hasta 2030. La participación porcentual proyectada



del total de emisiones de CO₂ para el período 2022-2030 sería la siguiente:

Componente	Suma total de emisiones de CO ₂ proyectados de 2022 hasta 2030 (en toneladas métricas)	% de emisiones de CO ₂
Diésel	234 355 536.00	64.00
Gasolina	96 807 968.00	26.44
GLP	33 168 736.70	9.06
GNV	1 853 188.06	0.51
Total	366 185 428.76	100.00

Tabla 6. Comparación de componentes contaminantes de CO₂, 2022-2030 (TM)

Nota. La tabla muestra el resultado de las emisiones de CO₂ del 2022-2030 (TM)

Las cifras, derivadas de la modelación, constituyen el escenario de referencia (BAU) y enfatizan la urgencia de intervenir, principalmente, sobre el consumo de diésel, dado su impacto desproporcionado.

Determinación de emisiones de CO₂ para diferentes escenarios

El segundo objetivo específico buscaba determinar las emisiones de dióxido de carbono para los diferentes escenarios a proponer. Con la línea base definida, la investigación procedió a estimar el impacto potencial en la reducción de emisiones mediante la sustitución parcial de diésel y gasolina por GLP y GNV.

Construcción y cuantificación de escenarios de sustitución

Un insumo clave para la construcción de escenarios de sustitución es la comprensión del

factor de emisión relativo entre combustibles. Si bien el modelo pronostica volúmenes absolutos, la justificación para promover un combustible sobre otro reside en su menor intensidad de carbono por unidad de energía entregada.

Por lo tanto, desde una perspectiva de mitigación, cada unidad de diésel o gasolina sustituida por GLP, y en mayor medida por GNV, genera una reducción neta de emisiones de CO₂. La Tabla 6, podría interpretarse como un resumen de las contribuciones absolutas proyectadas en el escenario BAU, que son el punto de partida para calcular los potenciales de reducción.

La investigación propone la construcción de escenarios basados en tasas hipotéticas de sustitución, como se muestra en la Tabla 7. Los valores de emisiones corresponden a la proyección acumulada total para el período 2022-2030 en el escenario base (business as usual), según los modelos ARIMA y de Programación Lineal desarrollados. La "Reducción de Contaminación Lograda" representa el porcentaje teórico en que se reducirían las emisiones si el combustible sustituto reemplazara completamente al combustible sustituido, manteniendo constante la demanda energética del sector.

N°	Combustible	Sustituto	Emisiones del sustituto (tm)	del	Emisiones del sustituido (tm)	% De emisiones del sustituto	Reducción de contaminación lograda
1	Diésel	GNV	1 853 188.063		234 355 536	0.79%	99.21%
2	Diésel	GLP	33 168 736.70		234 355 536	14.15%	85.85%
3	Diésel	Gasolina	96 807 968		234 355 536	41.31%	58.69%
4	Gasolina	GLP	33 168 736.70		96 807 968	34.26%	65.74%
5	Gasolina	GNV	1 853 188.063		96 807 968	1.91%	98.09%
6	Gasolina + Diésel	GNV + GLP	35 021 924.763		331 163 504	10.57%	89.42%

Tabla 7. Escenarios de reducción de emisiones de CO₂ por sustitución de combustibles

Nota: La Tabla muestra la propuesta de escenarios para la reducción de emisiones de CO₂ por sustitución de combustibles.

Para mayor entendimiento la Figura 9, muestra los posibles escenarios de reducción de emisiones de CO₂, producto de la investigación desarrollada.




Figura 9. Resumen de escenarios posibles 2022-2030 de mitigación de CO₂ (TM)

Nota. La Figura muestra el resumen de los posibles escenarios

Discusión

Al comparar esta investigación con otras recientes a nivel global y regional, se puede observar que, en cuanto al desempeño predictivo de los modelos, los resultados de este artículo indican que el modelo ARIMA (2,1,1)(1,1,1)[12] se destaca en la predicción de emisiones de diésel, gasolina y GLP, ya que mostró bajos errores (MAPE de 2,58% a 6,42%). El dato coincide con el aporte de Sharma et al., (2024) quienes confirmaron la efectividad de los modelos ARIMA para detectar tendencias y estacionalidad en series de emisiones de carbono.

Sin embargo, para Li & Zhang (2023) esto es diferente ya que desde su estudio en China, los modelos de aprendizaje profundo (LSTM) fueron más efectivos que los modelos estadísticos. La diferencia puede ser por la naturaleza más estable y estacional de la serie peruana, donde prevalecen patrones lineales y estacionales en lugar de comportamientos complejos y no lineales.

En cuanto al uso de redes neuronales artificiales (RNA), los resultados muestran que los modelos NNAR, aunque competitivos, no logran una precisión de predicción similar a ARIMA para las secuencias analizadas. Esto difiere de los hallazgos de Altikat (2021), quien informó que una RNA de aprendizaje profundo logró una tasa de precisión de más del 98 % al modelar el flujo de CO₂. Pese a, el presente estudio confirma que las

RNA pueden ser una herramienta adicional útil para la validación y el emparejamiento, como demostraron Cemrek & Demir (2021) en su estudio comparativo de métodos.

En el contexto latinoamericano, los hallazgos coinciden con el estudio de Mantilla et al., (2023) en Colombia, que registró una fuerte caída de las emisiones en 2020 debido a la pandemia, seguida de una recuperación gradual. Además, el notable predominio del diésel en la composición de las emisiones del Perú, con el 64% en 2030 en el escenario BAU, resalta una dependencia estructural similar a la de otros países de la región, destacando la necesidad urgente de implementar políticas de sustitución tecnológica.

En cuanto a escenarios alternativos, el análisis valida que sustituir completamente diésel por GNV podría reducir las emisiones en un 99,21% entre 2022 y 2030, mientras que el cambio a gas licuado de petróleo podría reducirlo en un 85,85%. Estos resultados apoyan la idea de que el gas natural es una opción viable como combustible de transición, similar a lo sugerido por Hagos & Ahlgren (2020) en Dinamarca, quienes destacaron el GNV como una alternativa económica a los sistemas más limpios. Además, estos resultados coinciden con pronósticos del Panorama Energético de América Latina y el Caribe (OLACDE) (2024) que predicen un aumento significativo en el uso de gas natural en el transporte regional para 2050.

Finalmente, desde una perspectiva metodológica global, el estudio confirma la efectividad de la triangulación de modelos (ARIMA, programación lineal, ANN) para mejorar la robustez de los pronósticos, un enfoque respaldado por Iftikhar et al., (2024) quienes combinaron regresión y series temporales para aumentar la precisión del modelado de emisiones. En general, este estudio proporciona datos cuantitativos consistentes que facilitan la toma de decisiones en el Perú, al tiempo que los integra al diálogo académico internacional sobre modelación ambiental, destacando la importancia de adaptar métodos de vanguardia a las realidades específicas del país para promover una transición energética eficiente y verificable.

Conclusión

Respecto al objetivo principal de modelar las emisiones de CO₂ provenientes de la sustitución de combustibles para el transporte, se determinó que el uso de modelos de pronóstico híbridos, incluyendo integración ARIMA, programación lineal y redes neuronales artificiales, es una forma efectiva y precisa de predecir escenarios de descarbonización en el Perú. La validación de estos modelos mediante parámetros de error (RMSE y MAPE) respalda su confiabilidad y confiabilidad para la toma de decisiones informadas. Se sugiere que las instituciones públicas como el MINAM y el MINEM adopten este enfoque para planificar y

monitorear continuamente las políticas de descarbonización, actualizando periódicamente los modelos con datos actualizados para mantener su efectividad predictiva.

Respecto al primer objetivo específico de generar escenarios de sustitución de combustibles, los resultados indican que en el escenario tendencial (BAU), el diésel seguirá siendo el principal emisor de CO₂ del transporte en el Perú, representando el 64% de las emisiones estimadas para el período 2022-2030, seguido por la gasolina (26,44%), GLP (9,06%) y GNV (0,51%). Esta estructura muestra que la matriz energética es altamente dependiente de los combustibles fósiles y subraya la necesidad de implementar políticas tecnológicas alternativas. Por lo tanto, los esfuerzos regulatorios y fiscales deberían centrarse en desalentar el uso de diésel y, al mismo tiempo, fomentar el consumo de combustibles alternativos como el GNV y GLP, especialmente en áreas de alto consumo como el transporte marítimo y el transporte público.

Respecto al segundo objetivo específico de calcular las emisiones de CO₂ para varios escenarios propuestos, el análisis mide el potencial de reducción debido a la sustitución de combustibles, destacando que un cambio completo del diésel al GNV podría reducir las emisiones en un 99,21%, mientras que la sustitución por GLP logrará una reducción del 85,85%. En cuanto a la gasolina, sustituirla por GNV supondría una

reducción de emisiones del 98,09% y del GLP del 65,74%. La combinación de GNV y GLP en lugar de diésel y gasolina supondrá una reducción global del 89,42% de las emisiones de este sector.

Se propone desarrollar programas específicos de conversión de vehículos, basados en incentivos económicos y técnicos, dando prioridad al GNV por su importante capacidad reductora, sin descuidar el papel que puede jugar el GLP como una alternativa práctica y más económica a corto plazo.

Desde un punto de vista metodológico, se ha demostrado que el modelo ARIMA (2,1,1)(1,1,1)[12] proporciona un desempeño predictivo superior para las series de diésel, gasolina y GLP en comparación con los modelos de redes neuronales (NNAR), ofreciendo valores más bajos de RMSE y MAPE. En el caso de GNV, debido al carácter lineal de su serie histórica, se utilizó un modelo de regresión lineal simple ($y_{GNV}=2.9495x-119077$) muestra un ajuste casi perfecto ($R^2=0.999$) lo que confirma su aplicabilidad a proyecciones hasta 2030.

Se recomienda continuar utilizando el modelo ARIMA para pronosticar combustibles convencionales en futuras investigaciones, mientras se exploran otras variables como SARIMAX y modelos híbridos que incluyen variables exógenas (crecimiento económico, precios de combustible, políticas ambientales) para aumentar la precisión y realismo de los resultados.

En cuanto a la imputación y procesamiento de datos, el proceso de identificación y corrección de valores atípicos en la cadena de consumo es fundamental para asegurar la calidad de los modelos predictivos. Para futuros estudios se deberían establecer protocolos estandarizados de limpieza de datos, evaluando diferentes métodos de imputación (como modelos de interpolación o descomposición estacional) para series con alta varianza o muestras irregulares, y documentando en detalle los criterios utilizados para garantizar la reproducibilidad de los análisis.

Finalmente, en términos de integración de los resultados en las políticas públicas, los resultados brindan una base cuantitativa sólida para apoyar la transición energética en el sector transporte del Perú, en línea con compromisos internacionales como el Acuerdo de París y las metas de reducción de emisiones para 2030. Se propone establecer un observatorio de emisiones del transporte, aplicar modelos predictivos en tiempo real para monitorear el avance de las políticas de descarbonización, evaluar el impacto de las medidas adoptadas y ajustar las estrategias en función de los resultados, asegurando así una transición ordenada, medible y efectiva hacia un sistema de transporte bajo en carbono.

Referencias

Altikat, S. (2021). Predicción de la emisión de CO₂ de los gases de efecto invernadero la atmósfera

- con redes neuronales artificiales y redes neuronales de aprendizaje profundo. *Int. J. Environ. Sci. Technol.*, 18, 3169–3178. Documento en línea. Disponible <https://doi.org/10.1007/s13762-020-03079-z>
- Cemrek, F., & Demir, O. (2021). Estimación de series temporales de emisiones de CO2 con máquinas de vectores de soporte Regresión, redes neuronales artificiales y análisis de series temporales clásicas. 5(2), 36 - 44. Documento en línea. Disponible <https://doi.org/10.34110/forecasting.1035912>
- CMNUCC. (1992). *Convención Marco de las Naciones Unidas sobre el Cambio Climático, FCCC/INFORMAL/84: Nuevo tiraje por razones técnicas, GE.05-62301 (S) 220705-ONU, N.Y, EE.UU.* Documento en línea. Disponible <https://unfccc.int/resource/docs/convkp/convsp.pdf>
- García, A., Cendales, E., & Eslava, A. (2016). Motores de Combustión Interna (MCI) Operando con Mezclas del Etanol y la Gasolina: Revisión. *Ciencia e Ingeniería Neogranadina*, 26(1), 75-96. Documento en línea. Disponible <https://doi.org/10.18359/rcin.1626>
- Hagos, D. A., & Ahlgren, E. O. (2020). Explorando transiciones rentables hacia un transporte independiente de combustibles fósiles en el futuro sistema energético. *Dinamarca*, 261(1). Documento en línea. Disponible <https://doi.org/10.1016/j.apenergy.2019.114389>
- Iftikhar, H., Han, M., Zywiotek, J., Khan, M., & Lopez, J. (2024). *Modelado y pronóstico de emisiones de dióxido de carbono en Pakistán utilizando una combinación híbrida de modelos de regresión y series temporales.* Documento en línea. Disponible <https://doi.org/10.1016/j.heliyon.2024.e33148>.
- IPCC. (2013). *Cambio Climático 2013. Bases físicas. Contribución del Grupo de Trabajo al Quinto Informe de Evaluación del Grupo Intergubernamental de Expertos sobre el Cambio Climático.* Cambridge, Reino Unido.
- Documento en línea. Disponible https://www.ipcc.ch/site/assets/uploads/2018/03/WG1AR5_SummaryVolume_FINAL_SPANISH.pdf
- Jena, P., Managi, S., & Majhi, B. (2021). Pronóstico de las emisiones de CO2 a nivel global: un modelo de red neuronal artificial multicapa. *Energies*, 14(19), 6311-6333. Documento en línea. Disponible <https://doi.org/10.3390/en14196336>
- Li, X., & Zhang, X. (2023). Un estudio comparativo de modelos estadísticos y de aprendizaje automático sobre la predicción de las emisiones de dióxido de carbono de China. *Environ Sci Pollut Res Int*, 30(55), 117485–117502. Documento en línea. Disponible <https://doi.org/10.1007/s11356-023-30428-5>
- Mantilla, L., Camargo, Y., Bolaño, S., & Tovar, F. (2023). Estimation of Road Transportation Emissions in Colombia from 2010 to 2021. *Atmosphere*, 14(7), 1167. Documento en línea. Disponible <https://doi.org/10.3390/atmos14071167>
- MINAM – COP21. (2015). *Ministerio del Ambiente – Conferencia de las Partes 21a.* (Primera ed.). Perú. Documento en línea. Disponible <https://repositoriodigital.minam.gob.pe/bitstream/handle/123456789/437/BIV01726.pdf?sequence=1&isAllowed=y>
- MINAM – COP25. (2019). *Ministerio del Ambiente – Conferencia de las Partes 25 a Foro Anual de Miembros del NDC Partnership, Convención Marco de las Naciones Unidas sobre el Cambio Climático.* Madrid. Documento en línea. Disponible <https://www.gob.pe/institucion/minam/noticias/70650-cop25-peru-apuesta-por-una-mayor-ambicion-para-enfrentar-el-cambio-climatico-al-2030>
- MINAM – INGEI. (2019). *Ministerio del Ambiente – Inventario Nacional de Gases de efecto Invernadero. Sector Energía, PIUP, Desechos, Agricultura y USCUS, Infocarbono.* Documento en línea. Disponible

- <https://infocarbono.minam.gob.pe/annios-inventarios-nacionales-gei/ingei-2019/>. Documento en línea. Disponible https://doi.org/10.1007/978-981-99-6749-0_53
- MINEM – BNE. (2022). *Ministerio de Energía y Minas-Balance Nacional de Energía. Consumo Final Nacional*. Documento en línea. Disponible <https://www.gob.pe/institucion/minem/informes-publicaciones/5575775-balance-nacional-de-energia-2022>
- OCDE / ITF. (2009). *Challenges & Opportunities in the Downturn / International Transport Forum. Transport for a Global Economy*. Documento en línea. Disponible <https://www.itf-oecd.org/sites/default/files/docs/09highlights.pdf>
- OSINERGMIN. (2014). *La industria del gas natural en el Perú. A diez años del Proyecto Camisea*. Documento en línea. Disponible https://issuu.com/osinergmin/docs/industria_del_gas_natural_en_peru/43
- Rafael, M., & Hernández, A. (2014). *Caracterización de un motor de combustión interna con dos tipos de combustible*. Instituto Mexicano del Transporte. Documento en línea. Disponible <https://www.imt.mx/archivos/Publicaciones/PublicacionTecnica/pt417.pdf>
- Salaet, S., & Roca, J. (2010). Agotamiento de los Combustibles Fósiles y Emisiones de CO₂: Algunos Posibles Escenarios Futuros de Emisiones. *Revista Galega de Economía*, 19(1), 1-19. Documento en línea. Disponible <http://redalyc.uaemex.mx/src/inicio/ArtPdf.jsp?iCve=39113124001>
- Santa, E., & Regalado, M. (2022). El transporte frente al desafío de la Transición Energética en el Perú hacia el 2050. *Natura@economía*, 7(2), 131-148. Documento en línea. Disponible <https://doi.org/10.21704/ne.v7i2.2115>
- Sharma, S., Mittal, A., Bansal, M., Joshi, B., & Rayal, A. (2024). Pronóstico de las emisiones de carbono en la India utilizando el enfoque de predicción de series temporales (ARIMA). *Apuntes de Ingeniería Eléctrica*, 1086.