



Modelado predictivo de emisiones de CO₂ empleando Machine Learning para la planificación energética sostenible del Ecuador

Predictive modeling of CO₂ emissions using Machine Learning for sustainable energy planning in Ecuador

Ciaddy Gina Rodríguez Borges^{I *}, Mariuxi Guillen Intriago^{II}, Leonardo Chancay García^I

^I Universidad Técnica de Manabí. Portoviejo, Ecuador.

^{II} Escuela Superior Politécnica Agropecuaria de Manabí Manuel Félix López. Calceta, Ecuador.

*Autor de correspondencia: ciaddy.rodriguez@utm.edu.ec

Recibido: 12 de enero de 2026

Aprobado: 26 de abril de 2026

Este documento posee una [licenciaCreativeCommonsReconocimiento-NoComercial4.0internacional](https://creativecommons.org/licenses/by-nc/4.0/)



RESUMEN/ABSTRACT

Este estudio desarrolla un modelo predictivo basado en aprendizaje automático para estimar las emisiones de CO₂ del sistema eléctrico ecuatoriano. Se empleó una metodología bajo el enfoque CRISP-ML(Q) y, se evaluaron modelos híbridos entre ellos: XGBoost, LightGBM y Random Forest, simulándose diferentes escenarios energéticos entre 2026–2036. Los resultados muestran que el modelo Random Forest optimizado presentó el mejor balance entre ajuste global, estabilidad y control de errores extremos, con un $R^2 = 0,7989$, evidenciando una adecuada capacidad para representar la dinámica de emisiones en un sistema hidrotérmico complejo. Posteriormente, se evaluaron diferentes escenarios prospectivos 2026–2036, analizando expansión energética, variabilidad climática y respaldo térmico. Los resultados alcanzados permiten evidenciar que la generación térmica y la variabilidad hidrológica son cruciales para dictar la dinámica de las emisiones. Estos resultados ofrecen una herramienta valiosa para aplicaciones en la planificación energética sostenible y la toma de decisiones en contextos de transición energética.

Palabras clave: emisiones de CO₂, machine learning, sistema eléctrico, planificación energética, escenarios energéticos.

This study develops a machine learning-based predictive model to estimate CO₂ emissions from the Ecuadorian electricity system. A methodology based on the CRISP-ML(Q) approach was used, and hybrid models, including XGBoost, LightGBM, and Random Forest, were evaluated, simulating different energy scenarios between 2026 and 2036. The results show that the optimized Random Forest model presented the best balance between overall fit, stability, and extreme error control ($R^2 = 0.7989$), demonstrating adequate capacity to represent the dynamics of emissions in a complex hydrothermal system. Subsequently, different prospective scenarios for 2026–2036 were evaluated, analyzing energy expansion, climate variability, and thermal backup. The results obtained demonstrate that thermal generation and hydrological variability are crucial for determining the dynamics of emissions. These results offer a valuable tool for applications in sustainable energy planning and decision-making within energy transition contexts.

Keywords: CO₂ emissions, machine learning, power system, energy planning, energy scenarios.

INTRODUCCIÓN

El cambio climático constituye uno de los principales desafíos del siglo XXI, estrechamente vinculado al incremento de las emisiones de gases de efecto invernadero derivadas del uso de combustibles fósiles.

Cómo citar este artículo:

Ciaddy Gina Rodríguez Borges y otros. Modelado predictivo de emisiones de CO₂ empleando Machine Learning para la planificación energética sostenible del Ecuador. Ingeniería Energética. Vol. 47(2026): publicación continua. ISSN 1815-5901.

Sitio de la revista: <https://rie.cujae.edu.cu/index.php/RIE/index>

En la actualidad, uno de los indicadores clave para evaluar la sostenibilidad de los sistemas energéticos y orientar la toma de decisiones en política pública es la contabilización de las emisiones de CO₂. La Agencia Internacional de Energía (IEA) ha establecido una serie de reportes anuales donde se reportan las emisiones globales de CO₂ asociadas al sector energético, reflejándose a partir del año 2023 incrementos a nivel mundial en este importante indicador. En este contexto, una estimación precisa de estas emisiones resulta fundamental tanto desde el punto de vista ambiental como desde el estratégico para la planificación energética [1]. El Panel Intergubernamental sobre Cambio Climático (IPCC), destaca la importancia de utilizar metodologías estandarizadas para la estimación de emisiones, tal es el caso de su propuesta del año 2019.

En general, la cuantificación de las emisiones en el sector energético se ha realizado mediante enfoques de contabilidad física basados en factores de emisión [2, 3]. Aunque estos métodos permiten realizar estimaciones estructuradas, presentan limitaciones cuando los datos son heterogéneos o no capturan dependencias no lineales entre variables operativas, económicas y climáticas. Estudios recientes evidencian que los enfoques tradicionales incorporan incertidumbre asociada a la calidad y disponibilidad de los datos, lo que justifica la incorporación de metodologías complementarias basadas en analítica avanzada [4].

En el caso ecuatoriano, es relevante realizar un análisis debido a los cambios experimentados en los últimos 20 años en su matriz energética, la cual ha disminuido muy significativamente el uso de fuentes de generación térmica. La elevada participación de la energía hidroeléctrica ha facilitado la reducción de la intensidad de carbono, pero también ha generado una alta vulnerabilidad debido a la variabilidad climática. En períodos de escasez de agua, la necesidad de incrementar la generación térmica se presenta obligando al sistema de forma directa a generar mayores emisiones, siendo importante considerar el comportamiento de las variables propias de este sistema, y la valoración de su comportamiento mediante modelos energéticos y climáticos [5]. Esta necesidad ha sido también señalada por la Organización Latinoamericana de Energía (OLADE) y por el Centro Nacional de Control de Energía (CENACE), organismos que destacan la creciente complejidad de los sistemas energéticos, la influencia de la variabilidad climática y la importancia de fortalecer las herramientas de planificación y análisis prospectivo en la región.

Además, influencias como el fenómeno El Niño–Oscilación del Sur (ENSO) impactan directamente la disponibilidad de agua y cambian el equilibrio de la generación de energía para aumentar esta complejidad. Las variables climáticas se incorporan en modelos predictivos para proporcionar una mejor comprensión de la dinámica de las emisiones. Ante los problemas de la energía que dependen de procesos que pueden ser demasiado difíciles o costosos de modelar [1, 6]. Actualmente la literatura reconoce enfoques basados en datos que capturan la complejidad entre las variables de energía y medio ambiente.

En este contexto, el aprendizaje automático se destaca como una herramienta adecuada para modelar sistemas energéticos complejos, ya que permite identificar patrones y relaciones no lineales entre múltiples variables. Modelos como XGBoost, LightGBM y Random Forest han demostrado alta precisión en la estimación de emisiones [4, 6, 7]. Asimismo, la Organización Latinoamericana de Energía (OLADE) advierte que los sistemas energéticos de América Latina enfrentan desafíos asociados a la transición energética y la variabilidad climática. De manera similar, el Centro Nacional de Control de Energía (CENACE) reporta una creciente complejidad operativa y una elevada dependencia hidroeléctrica en el sistema ecuatoriano. Sin embargo, el uso de técnicas avanzadas de Machine Learning para modelar emisiones de CO₂ en Ecuador aún es limitado, lo que evidencia la necesidad de desarrollar herramientas predictivas orientadas a la planificación energética sostenible [4, 7, 8].

Antecedentes del problema

En los últimos años, la predicción de emisiones de CO₂ mediante modelos basados en datos ha ganado relevancia debido al crecimiento en la disponibilidad de información energética y climática. Ji et al. [1], destacan los modelos de Machine Learning, los cuales han evolucionado hacia algoritmos capaces de capturar relaciones complejas entre emisiones y múltiples variables, demostrando su utilidad en la estimación de emisiones antropogénicas a partir de datos multifuente. Este desarrollo nos permite superar las limitaciones de los modelos tradicionales basados en relaciones lineales.

Tal como han mencionado algunos autores, entre ellos Cai et al. [4] y Huang et al. [9], el desarrollo de modelos híbridos basados en LightGBM y XGBoost para estimar emisiones partiendo de los datos de generación eléctrica, de cada fuente y del comportamiento de la demanda, puede ofrecer mejoras en la precisión, frente a métodos tradicionales.

Asimismo, Gurcan [8], comparó varios algoritmos para la estimación de diferentes emisiones, reportando que el desempeño de los modelos de híbridos (o de ensamble) es superior en el ajuste y la minimización del error, lo cual respalda la aplicabilidad de estos modelos. A pesar de estos avances, existe una brecha en la aplicación de estas metodologías al sistema eléctrico ecuatoriano. La mayoría de estudios se ha desarrollado en contextos distintos, como transporte o plantas específicas, sin integrar simultáneamente variables energéticas, climáticas y criterios de estimación tipo IPCC. En este sentido, el presente estudio contribuye al adaptar modelos de Machine Learning al análisis de la matriz energética ecuatoriana, incorporando un enfoque aplicado a la planificación energética y evaluación de escenarios [1, 4].

El objetivo general de esta investigación es desarrollar un modelo predictivo basado en técnicas de Machine Learning que permita estimar las emisiones de CO₂ asociadas a la matriz energética ecuatoriana, integrando variables energéticas y climáticas relevantes para apoyar la planificación energética sostenible. Este objetivo persigue plantear nuevas herramientas analíticas que complementen los métodos tradicionales de estimación de emisiones y permitan anticipar el comportamiento del sistema bajo condiciones operativas y ambientales variables propias del Ecuador.

MATERIALES Y MÉTODOS

La investigación adoptó un enfoque cuantitativo, explicativo y predictivo, orientado a estimar las emisiones de CO₂ asociadas a la matriz energética ecuatoriana mediante técnicas de *Machine Learning*. El estudio integró variables energéticas, climáticas y temporales con el fin de capturar relaciones no lineales entre generación eléctrica, consumo de combustibles fósiles, variabilidad climática y emisiones. La metodología se estructuró bajo el marco CRISP-ML(Q), el cual permite organizar proyectos de aprendizaje automático con criterios de trazabilidad, calidad y reproducibilidad [4, 10].

Diseño metodológico

El proceso metodológico se desarrolló en siete fases: comprensión del problema, comprensión de los datos, ingeniería de datos, estimación de emisiones, ingeniería de variables, modelado predictivo, evaluación y despliegue analítico. Este enfoque permitió mantener coherencia entre los objetivos del estudio, la preparación de datos y la interpretación de resultados, favoreciendo la transparencia del proceso analítico [10]. En la figura 1, se presentan las fases seguidas en la investigación



Fig. 1. Metodología CRISP-ML(Q) Aplicada a la Predicción de la Demanda Eléctrica en Ecuador

Durante la fase inicial se definió como variable objetivo la emisión mensual de CO₂ fósil del sistema eléctrico ecuatoriano para el periodo 2001–2025. Se empleó una resolución temporal mensual debido a que permite capturar las variaciones de la generación hidroeléctrica ocasionadas por cambios en la disponibilidad de agua, las cuales suelen ser compensadas mediante generación térmica. Asimismo, esta escala facilita incorporar los efectos del fenómeno ENSO y su influencia sobre la dinámica de emisiones del sistema eléctrico nacional [1, 6].

Fuentes de información y arquitectura de datos

La base analítica se construyó mediante la integración de datos energéticos, climáticos y temporales provenientes de fuentes institucionales. Se incluyeron registros de generación por fuente, consumo de combustibles fósiles, participación tecnológica, variables temporales y datos climáticos asociados a la disponibilidad hídrica y variabilidad ENSO. Esta integración permitió estructurar un dataset multivariable adecuado para modelado predictivo, asegurando coherencia entre variables explicativas y la dinámica real del sistema energético. El uso de datos multifuente es consistente con estudios recientes que destacan su importancia para mejorar la precisión en la estimación de emisiones [11].

En la tabla 1, se resumen los principales grupos de variables considerados en el estudio, la misma resume los listados extensos de variables individuales y permite presentar de manera sintética el papel metodológico de cada grupo dentro del modelo.

Tabla 1. Grupos de variables utilizados en el modelo predictivo

Grupo de Variables	Variables representativas	Uso en el modelo
Variable objetivo	CO ₂ fósil mensual estimado	Variable dependiente a predecir
Generación eléctrica	Generación hidroeléctrica, térmica, renovable no convencional, importaciones/exportaciones	Representan la estructura mensual de la matriz energética
Combustibles fósiles	Diésel, fuel oil, gas natural u otros combustibles empleados en generación térmica	Permiten estimar emisiones mediante enfoque IPCC
Variables climáticas	Indicadores ENSO, precipitación, temperatura, humedad u otros registros climáticos disponibles	Capturan efectos de variabilidad climática sobre generación hidroeléctrica
Variables temporales	Año, mes, rezagos, tendencia y estacionalidad	Empleados para captura los n patrones temporales y comportamiento mensual
Variables derivadas	Participación porcentual por fuente, intensidad de carbono, relaciones entre generación térmica y renovable	Mejoran la capacidad explicativa del modelo

La organización de la información se realizó mediante una arquitectura tipo estrella, tal como se presenta en la figura 2, utilizando una dimensión temporal mensual como eje integrador. Esta estructura facilitó la unión de tablas provenientes de diferentes fuentes, la validación cronológica de las observaciones y la construcción de una base final apta para entrenamiento de modelos. La arquitectura de datos en estrella se mantiene como soporte metodológico del estudio, dado que permite ordenar las variables por dimensiones y asegurar trazabilidad durante el procesamiento.




Fig. 2. Arquitectura de datos en estrella para el desarrollo del dataset consolidado

Estimación de emisiones de CO₂

Las estimaciones se realizaron siguiendo las Directrices del Panel Intergubernamental sobre Cambio Climático (IPCC, por sus siglas en inglés: Intergovernmental Panel on Climate Change) para los Inventarios Nacionales de Gases de Efecto Invernadero, aplicando el enfoque Tier 2 (Nivel 2), que utiliza factores de emisión y datos de actividad más específicos y representativos de las condiciones nacionales o regionales que los empleados en el enfoque Tier 1 (que anteriormente se ha empleado en Ecuador), ya que permite incorporar factores de emisión, poder calorífico neto y datos de actividad asociados a los combustibles utilizados de forma específica señalados en la metodología IPPC del año 2019. Las emisiones de CO₂, se calcularon a partir del consumo mensual de combustibles fósiles empleados en la generación no renovable, considerando únicamente estas fuentes de generación, dado que se asume 0 para las provenientes de fuentes renovables.

De forma general, la estimación se expresó mediante la relación entre datos de actividad, poder calorífico neto y factor de emisión, como se muestra en la ecuación (1):

$$CO_2 = \sum_i (FC_i \times NCV_i \times EF_i \times OF_i) \quad (1)$$

Donde:

CO₂: emisión de CO₂

FC_i: consumo del combustible

NCV_i: poder calorífico neto del combustible (TJ/Gg)

EF_i: factor de emisión (kg CO₂/TJ)

OF_i: fracción de oxidación

Esta estimación permitió obtener la variable objetivo del modelo y, al mismo tiempo, mantener coherencia metodológica con los procedimientos internacionales de contabilización de emisiones. Se excluyeron las emisiones asociadas al uso de biomasa (bagazo y biogás), debido a que el dióxido de carbono liberado durante su combustión forma parte del ciclo natural del carbono y, de acuerdo con las directrices del IPCC, no se contabiliza dentro de las emisiones fósiles del sector energético.

Preparación e ingeniería de variables

La preparación de datos incluyó la depuración de registros, validación de la secuencia temporal y corrección de inconsistencias. Posteriormente, las variables numéricas fueron estandarizadas mediante el método Z-score, transformándolas a una distribución con media cero y desviación estándar unitaria, con el fin de reducir diferencias de escala entre variables energéticas, climáticas y económicas y mejorar la estabilidad del proceso de modelado. Asimismo, se evitó la fuga de información mediante la exclusión de variables derivadas directamente de la variable objetivo.

Estandarización Z-score

Para evitar que variables con diferentes magnitudes influyeran de forma desproporcionada en el proceso de aprendizaje, las variables numéricas fueron estandarizadas mediante la transformación Z-score, para lo cual se empleó la ecuación 2, que se presenta a continuación:

$$z_i = \frac{x_i - \mu}{\sigma} \quad (2)$$

Donde:

x_i: valor original de la variable.

μ: media de la variable.

σ: desviación estándar.

z_i: valor estandarizado.

Con el fin de mejorar la calidad de los datos y facilitar el aprendizaje de los algoritmos de Machine Learning, se aplicaron procedimientos de transformación y generación de características. Entre ellos se incluyeron la estandarización de variables mediante normalización Z-score, el cálculo de indicadores energéticos derivados, la generación de rezagos temporales y el cálculo de promedios móviles. Estas transformaciones permiten reducir diferencias de escala, capturar patrones temporales y representar adecuadamente la dinámica del sistema eléctrico ecuatoriano. A continuación, se generaron variables derivadas, incluyendo participaciones porcentuales de generación por fuente, indicadores de intensidad de carbono y variables temporales como rezagos (lags) y promedios móviles

Participación porcentual de generación por fuente

Para representar la composición relativa de la matriz energética, se calculó la participación porcentual de cada tecnología de generación, empleando la ecuación (3):

$$Part_{i,t} = \frac{Gen_{i,t}}{\sum_{j=1}^n Gen_{j,t}} \times 100 \quad (3)$$

Donde:

Part_{i,t}: participación de la fuente i en el período t.

Gen_{i,t}: generación de la fuente i.

ΣGen_{j,t}: generación total del sistema.

Rezago temporal (lag)

Con el propósito de capturar la dependencia temporal de las emisiones, se incorporaron variables de rezago. Como la utilizada para el lag₁ y lag₁₂, para lo cual se empleó la ecuación (4), que se presenta a continuación:

$$Lag_k(t) = Y_{t-k} \quad (4)$$

Donde:

Y_t: emisiones de CO₂.

k: número de periodos de rezago

t = mes actual.

t-1 = un mes anterior.

t-12 = doce meses anteriores (un año atrás).

t-k = k periodos anteriores.

Se considero particularmente el uso de las ecuaciones (5, 6):

$$Lag_1 = CO_{2,t-1} \quad (5)$$

$$Lag_{12} = CO_{2,t-12} \quad (6)$$

Promedio móvil (rolling mean)

Para capturar tendencias de corto y mediano plazo se calcularon promedios móviles, mediante la ecuación (7):

$$MA_n(t) = \frac{1}{n} \sum_{i=1}^n Y_{t-i} \quad (7)$$

Donde:

MA_n(t): promedio móvil.

n: ventana temporal.

Y_t: emisiones observadas.

Estas transformaciones permiten capturar dependencia temporal, estacionalidad y efectos diferidos en la dinámica de emisiones, aspectos fundamentales para representar adecuadamente el comportamiento de sistemas energéticos complejos [1, 6].

Modelos de Machine Learning

Se entrenaron tres modelos supervisados: XGBoost, LightGBM y RandomForestRegressor, ampliamente utilizados en la estimación de emisiones de CO₂ y en problemas de predicción energética [9, 12]. La selección de estos algoritmos se fundamentó en su capacidad para procesar conjuntos de datos multivariantes, capturar relaciones no lineales y mejorar la precisión predictiva en sistemas energéticos complejos [4, 8]. En particular, XGBoost fue incorporado por sus mecanismos de regularización y control del sobreajuste; LightGBM por su eficiencia computacional y capacidad para trabajar con grandes volúmenes de datos; y RandomForestRegressor por su robustez frente al ruido y su estabilidad en procesos de regresión [7]. En estudios previos se ha reportado un desempeño satisfactorio de estos modelos en aplicaciones relacionadas con emisiones y planificación energética [4, 8].

La optimización se realizó de forma específica para cada algoritmo. En los modelos de boosting (XGBoost y LightGBM) se ajustaron hiperparámetros como la tasa de aprendizaje (*learning rate*), el número de estimadores (*n_estimators*), la profundidad máxima de los árboles (*max_depth*) y parámetros de regularización, con el objetivo de mejorar la capacidad de generalización y reducir el sobreajuste [7]. Para RandomForestRegressor se optimizaron principalmente el número de árboles, la profundidad máxima y el número mínimo de observaciones requeridas para la división de nodos y formación de hojas. Este proceso permitió obtener configuraciones más estables y mejorar el desempeño predictivo de cada modelo.

Validación temporal y métricas de evaluación

Dado que la investigación se basa en una serie temporal mensual correspondiente al periodo 2001–2025, se empleó una estrategia de validación temporal mediante partición cronológica (*hold-out temporal*), utilizando aproximadamente el 80 % de las observaciones más antiguas para el entrenamiento y el 20 % más reciente para la validación. Este procedimiento garantiza que el modelo sea evaluado únicamente con información futura respecto al periodo de entrenamiento, evitando la fuga de información y reproduciendo condiciones similares a las de un escenario real de predicción [13]. Se empleó validación cruzada temporal (*TimeSeriesSplit*), mediante una estrategia de ventana expansiva (*expanding window*), donde cada partición utiliza observaciones históricas para entrenar el modelo y datos posteriores para validarlo.

El desempeño de los modelos se evaluó mediante las métricas coeficiente de determinación (R^2), error absoluto medio (MAE), raíz del error cuadrático medio (RMSE) y error porcentual absoluto medio (MAPE). El coeficiente de determinación (R^2) permitió cuantificar la proporción de variabilidad de las emisiones explicada por el modelo; el MAE proporcionó una medida directa del error promedio en las mismas unidades de la variable objetivo (tCO₂); el RMSE penalizó con mayor intensidad los errores de gran magnitud, permitiendo identificar desviaciones significativas; y el MAPE facilitó la comparación relativa del error entre modelos expresándolo en términos porcentuales. Estas métricas son ampliamente utilizadas en estudios de predicción energética y ambiental debido a su capacidad para evaluar simultáneamente precisión, robustez y capacidad de generalización [4, 6, 8].

Simulación de escenarios y despliegue analítico

Una vez seleccionado el modelo con mejor desempeño, balance entre ajuste global, estabilidad y control de errores extremos, se planteó su uso para la simulación de escenarios prospectivos de emisiones. Los resultados del modelo se conciben como herramientas de apoyo para la estimación de emisiones de CO₂ en el sistema energético y su incorporación en informes técnicos orientados a la toma de decisiones. Bajo este enfoque, la implementación no se orienta al desarrollo de aplicaciones informáticas, sino a la generación de salidas analíticas, tales como estimaciones, visualizaciones comparativas y escenarios prospectivos, que permitan interpretar la evolución de las emisiones asociadas al consumo eléctrico.

Los escenarios que a continuación se presentan permiten analizar la sensibilidad del sistema frente a cambios estructurales y condiciones climáticas [14], aportando una visión prospectiva para la planificación energética. A continuación, se presenta la tabla 2 de los escenarios proyectados.

Tabla 2. Definición de escenarios energéticos para la simulación de emisiones de CO₂

Nombre	Escenario	Supuestos principales	Objetivo de análisis
S1	Expansión de Referencia (EER)	Crecimiento de demanda del 4% anual; incorporación de proyectos según planificación oficial; sin restricciones operativas.	Representar la trayectoria base del sistema eléctrico.
S2	Variabilidad Climática (EVC–ENSO)	Considera incremento de la demanda del 4%/anual; incorporación de nuevos proyectos de generación; evaluación de patrones y sensibilidad del sistema a la variabilidad climática (fenómeno ENSO)	Evaluar el comportamiento del sistema energético frente a la variabilidad climática.
S3	Respaldo Térmico (ERT)	Considera incremento de la demanda del 4% anual; la capacidad de generación se mantiene estable; los déficits se cubren mediante generación térmica.	Estudiar la confiabilidad del suministro y las necesidades de generación térmica.

Por último, la salida del modelo está orientada a resultados analíticos (estimaciones, gráficos y escenarios) en lugar de implementarse como software, lo que establece un uso más sólido como apoyo a la toma de decisiones.

RESULTADOS

En cuanto al desempeño comparativo de los modelos, se evaluaron cuatro configuraciones de modelos: Random Forest base, Random Forest optimizado, XGBoost optimizado y LightGBM optimizado. La comparación entre emisiones reales y predichas muestra que todos los modelos reproducen adecuadamente la tendencia general de las emisiones mensuales de CO₂, aunque presentan desviaciones en algunos picos extremos, asociados probablemente a cambios bruscos en la generación térmica o a condiciones hidrológicas atípicas. El comportamiento real contrastado con el comportamiento real reportado puede observarse en la figura 3, a continuación:




Fig. 3. Comparación de emisiones reales y predicción del CO₂

En la tabla 3, se evidencia que el mejor desempeño según el coeficiente de determinación corresponde al Random Forest optimizado, con un $R^2 = 0,7989$, $RMSE = 75,34 \text{ ktCO}_2$, $MAE = 60,21 \text{ ktCO}_2$ y $MAPE = 19,95 \%$. Aunque modelos como LightGBM optimizado, presentan un MAE ligeramente menor ($58,02 \text{ ktCO}_2$), aun así, Random Forest optimizado obtiene el mejor equilibrio general al combinar mayor R^2 y menor RMSE. Por ello, se selecciona como modelo principal para la simulación prospectiva.

Tabla 3. Métricas comparativas de desempeño de modelos

Modelo	MAE (ktCO ₂)	MSE (ton ²)	RMSE (ktCO ₂)	R ²	MAPE (%)
Random Forest optimizado	60.21	5.67E+09	75.34	0.7989	19.95
LightGBM optimizado	58.02	5.03E+09	76.82	0.7909	19.77
XGBoost optimizado	58.30	5.03E+09	77.24	0.7886	19.35
Random Forest base	62.05	6.08E+09	81.27	0.7660	21.20

El uso de **MAE en ktCO₂** resulta importante porque expresa el error medio absoluto en una unidad directamente interpretable para planificación energética. Es decir, posibilita conocer la cantidad de kilotoneladas de CO₂ que se desvían, en promedio, las predicciones mensuales con respecto a los valores observados. Esta métrica se añade a R^2 , que señala la capacidad de explicación, y a RMSE, que castiga más severamente los errores grandes. Sin embargo, la diferencia de rendimiento entre los modelos optimizados es mínima; por lo tanto, los resultados deben ser considerados como prueba de un rendimiento similar entre algoritmos de ensamble. En este contexto, Random Forest optimizado se adopta como modelo de referencia por presentar el mejor balance entre ajuste global, estabilidad y control de errores extremos.

Importancia de variables

El análisis de importancia de variables del modelo Random Forest optimizado muestra que los predictores con mayor contribución corresponden a los rezagos temporales y promedios móviles, tal es el caso de lag_1, rolling_3, rolling_6 y lag_12. Este resultado indica que las emisiones mensuales de CO₂ presentan una fuerte dependencia temporal, en la cual los valores observados en los meses previos influyen significativamente en el comportamiento futuro de la serie. Asimismo, la relevancia de lag_12 evidencia la presencia de patrones estacionales asociados a la operación del sistema eléctrico, la disponibilidad hídrica y las variaciones en la participación de la generación térmica a lo largo del año. En conjunto, estos resultados sugieren que la evolución histórica de las emisiones constituye uno de los principales factores explicativos de su dinámica futura, como se muestra en la figura 4.




Fig. 4. Importancia de variables del modelo Random Forest optimizado

En la figura 4, se presentan como variables relevantes también las variables demográficas, climáticas y de tendencia temporal, entre ellas las de población, personas por vivienda, temperatura media y radiación solar. Esto sugiere que el modelo no solo capta la inercia histórica de las emisiones, sino también los factores estructurales que se asocian al consumo eléctrico, a las condiciones ambientales y evolución temporal del sistema.

Curva ROC y matriz de confusión como análisis complementario

Aunque el problema principal corresponde a una regresión, se incorporó una evaluación complementaria mediante curvas ROC y matriz de confusión. Para ello, las emisiones fueron categorizadas en niveles cualitativos, por ejemplo, bajo, medio y alto, con el propósito de evaluar si los modelos también eran capaces de identificar meses con niveles críticos de emisión.




Fig. 5. Curvas ROC complementarias para la clase alta de CO₂

La curva ROC revela que todos los modelos tienen capacidad discriminativa mejor que al azar. El modelo optimizado de Random Forest es el mejor con AUC (0.853), seguido de XGBoost optimizado (0.827), LightGBM optimizado (0.813) y el Random Forest base (0.800). Esto valida que el modelo seleccionado no solo funciona bien con datos continuos, sino que también clasifica adecuadamente los meses de alta emisión. A continuación, se presenta en la figura 6, la matriz de confusión para el mejor modelo.




Fig. 6. Matriz de confusión del modelo Random Forest Optimizado

La figura 6, se presenta la matriz de confusión obtenida para el modelo Random Forest optimizado, la cual permite evaluar la capacidad del algoritmo para clasificar correctamente los niveles de emisiones de CO₂ en las categorías baja, media y alta. Se observa un dominante número de clasificaciones correctas en la diagonal principal, con 18 casos correctamente identificados en la categoría baja, 12 en la categoría media y 15 en la categoría alta, lo que evidencia una adecuada capacidad de discriminación entre los diferentes niveles de emisiones.

Los errores de clasificación se concentran principalmente entre las categorías adyacentes (*media y alta*), mientras que prácticamente no se presentan confusiones entre los extremos (*baja y alta*). Este comportamiento sugiere que el modelo logra capturar de forma consistente los patrones generales asociados a la dinámica de emisiones del sistema eléctrico ecuatoriano, aunque presenta ciertas dificultades para distinguir observaciones ubicadas en zonas de transición entre niveles intermedios y altos.

En términos generales, los resultados reflejan un desempeño robusto del modelo, confirmando que las variables energéticas, climáticas y temporales incorporadas durante el proceso de entrenamiento aportan información relevante para la clasificación de escenarios de emisiones. La concentración de valores en la diagonal principal indica una buena capacidad predictiva y una adecuada generalización del modelo sobre datos no utilizados durante el entrenamiento.

Simulación mensual y anual 2026–2036

Con el Random Forest optimizado se realizaron simulaciones prospectivas para el periodo 2026–2036 bajo tres escenarios: escenario base tendencial, escenario de reducción térmica y escenario de estrés climático. Los resultados muestran una tendencia creciente de emisiones en el horizonte proyectado, asociada al crecimiento esperado de la demanda y a la permanencia de la generación térmica como respaldo del sistema eléctrico, tal como se presenta en la figura 7.

Las emisiones de CO₂ del sistema eléctrico ecuatoriano están fuertemente condicionadas por la generación térmica, evidenciando una relación casi lineal entre ambas variables, lo cual es consistente con la metodología Tier 2 del IPCC, donde las emisiones se estiman como función del consumo de combustibles fósiles, razón por la cual en un escenario de reducción térmica presenta los menores niveles relativos de emisiones, mientras que el escenario de estrés climático muestra los valores más altos.




Fig. 7. Emisiones proyectadas de CO₂ por escenario en el periodo 2026–2036

Este comportamiento confirma que las emisiones futuras dependen de la proporción de generación térmica requerida para cubrir déficit hidroeléctrico o incrementos de demanda. Con el fin de complementar la interpretación de la planificación energética, se presenta la evolución de la generación incorporada por tecnología para el periodo 2026–2036, donde se consideró la Figura 8, que refleja la matriz base (condición inicial).




Fig. 8. Matriz base del sistema eléctrico (año base)

Nota: los valores sobre las barras indican la generación en Gwh y el porcentaje correspondiente

En la figura 9, se presenta para la incorporación a lo largo de los próximos 10 años de manera agregada la contribución relativa de cada fuente energética, evidenciando una transición progresiva hacia tecnologías renovables, especialmente hidroeléctrica, eólica y solar.




Fig. 9. Fuentes de generación proyectadas desde 2026 hasta 2036

La elaboración de la figura 8, responde a los datos suministrados en los balances anuales del CENACE, el Inventario de Emisiones de la Agencia de Regulación y Control de Energía y Recursos Naturales no Renovables (ARCERNNR) para el periodo 2025-2026, y datos de proyecciones de demanda del Plan Maestro de Electricidad, considerando un escenario moderado respecto al conjunto de obras propuestas hasta ahora, se observa la presencia inicial de generación térmica, lo cual explica el incremento de emisiones en los primeros años del horizonte analizado. Esta representación gráfica facilita la comprensión de la dinámica de expansión del sistema y su relación con los resultados de emisiones proyectadas.

DISCUSIÓN

Los resultados evidencian que los modelos de aprendizaje automático alcanzan un desempeño adecuado para estimar emisiones de CO₂ en el sistema eléctrico ecuatoriano, con valores de R² cercanos a 0,80. Aunque estos resultados son inferiores a los obtenidos en entornos altamente controlados, son consistentes con sistemas energéticos reales caracterizados por una elevada variabilidad operativa, climática y económica. La literatura señala que el desempeño de los modelos predictivos está condicionado tanto por la complejidad del sistema analizado como por la calidad y disponibilidad de los datos, siendo más exigente alcanzar altos niveles de ajuste cuando se trabaja con escalas nacionales y horizontes temporales extensos [3, 15, 17].

Desde la perspectiva energética, las emisiones de CO₂ del sistema eléctrico ecuatoriano están condicionadas por la participación de generación térmica y por la dependencia estructural respecto a la hidrogenación. Parra [18], reportó factores de emisión entre 188,6 y 397,4 gCO₂/kWh, variabilidad asociada a los cambios en la participación de combustibles fósiles y a la composición tecnológica de la matriz eléctrica. El modelo Random Forest optimizado presentó el mejor desempeño global, resultado coherente con investigaciones que destacan su capacidad de generalización frente a datos ruidosos, variables correlacionadas y relaciones no lineales. Estudios recientes reportan que los algoritmos basados en árboles mantienen robustez en aplicaciones de predicción bajo incertidumbre y elevada complejidad de datos [15, 19, 20].

Sin embargo, otros autores han encontrado desempeños superiores en modelos de boosting como LightGBM y XGBoost, especialmente cuando existen grandes volúmenes de datos y patrones altamente no lineales. En este sentido, la efectividad de cada algoritmo depende tanto de la naturaleza del problema como de la estructura y calidad del conjunto de datos utilizado para el entrenamiento [4, 16, 20]. Los resultados también son coherentes con investigaciones internacionales que reportan comportamientos similares en sistemas eléctricos complejos. En este contexto, la menor precisión observada respecto a estudios desarrollados bajo condiciones controladas puede atribuirse a la incertidumbre inherente a la interacción de variables energéticas, económicas y climáticas.

Li et al. [10], señalan que algoritmos como XGBoost pueden alcanzar niveles de ajuste superiores cuando se dispone de información homogénea y de alta calidad; sin embargo, su desempeño disminuye cuando

aumenta la complejidad del sistema analizado. En este sentido, la principal contribución de la presente investigación radica en la integración de metodologías IPCC Tier 2 con técnicas de Machine Learning para evaluar escenarios prospectivos del sistema eléctrico ecuatoriano, proporcionando una herramienta de apoyo para la planificación energética sostenible y la toma de decisiones bajo condiciones reales de operación [19, 20].

Interpretación energética de los escenarios

Los escenarios analizados no deben interpretarse únicamente como resultados estadísticos, sino como ejercicios prospectivos orientados a comprender posibles trayectorias futuras del sistema eléctrico ecuatoriano. El escenario base representa la continuidad de las condiciones actuales de operación; el escenario de transición energética evalúa los efectos asociados a una reducción progresiva de la generación térmica; mientras que el escenario de estrés climático reproduce condiciones de menor disponibilidad hídrica similares a las observadas durante eventos extremos recientes, que obligan a incrementar el despacho de generación térmica para garantizar la seguridad del suministro.

Los resultados muestran que el comportamiento futuro de las emisiones de CO₂ depende principalmente de la participación de la generación térmica y del tipo de combustible utilizado. Durante el periodo histórico de análisis, los factores de emisión oscilaron entre 188,6 y 397,4 gCO₂/kWh [18], reflejando la sensibilidad de la matriz energética ecuatoriana a las variaciones hidrológicas. Diversos estudios han señalado que los sistemas eléctricos con alta dependencia hidroeléctrica presentan una mayor vulnerabilidad frente a sequías prolongadas y eventos asociados al fenómeno ENSO, lo que incrementa la necesidad de generación térmica de respaldo y, por consiguiente, las emisiones de CO₂ [17, 18, 20]. Estos resultados refuerzan la importancia de diversificar la matriz energética mediante fuentes renovables complementarias que permitan reducir simultáneamente la vulnerabilidad climática y la intensidad de carbono del sistema eléctrico nacional.

Relación con fuentes nacionales y aporte del estudio

Los informes oficiales del sector eléctrico ecuatoriano calculan el factor de emisión de CO₂ del Sistema Nacional Interconectado siguiendo las metodologías y directrices recomendadas por la Convención Marco de las Naciones Unidas sobre el Cambio Climático (CMNUCC/UNFCCC), basadas en directrices del IPCC y en información de consumo de combustibles proporcionada por Petroecuador. Bajo este enfoque, se reportaron factores de emisión de 0,3834 tCO₂/MWh para el margen operativo (OM) y 0,1917 tCO₂/MWh para el margen combinado (CM) en 2020, mientras que para 2024 se registró un valor de 0,1616 tCO₂/MWh, reflejando cambios en la composición de la matriz energética y en las condiciones de operación del sistema eléctrico nacional [7].

En este contexto, la principal contribución de la presente investigación no radica únicamente en la estimación histórica de emisiones mediante el enfoque IPCC Tier 2, sino en la integración de variables energéticas, climáticas y temporales empleando modelos de aprendizaje automático capaces de analizar y proyectar el comportamiento futuro de las emisiones de CO₂. Esta aproximación complementa los métodos tradicionales de cálculo al incorporar una perspectiva predictiva y prospectiva, permitiendo evaluar escenarios de operación bajo condiciones normales, estrategias de reducción térmica y situaciones de estrés climático.[7, 19, 20].

Implicaciones para la planificación eléctrica ecuatoriana

Los resultados muestran que reducir emisiones no depende únicamente de incorporar proyectos renovables, sino de disminuir la dependencia térmica en periodos críticos. La Planificación de la Energía Eléctrica en Ecuador debe abordar, de manera conjunta, la expansión de la demanda, los recursos renovables, la disponibilidad de almacenamiento, la disponibilidad de la hidroeléctrica y los eventos de ENSO. Con ello, el modelo nos permite predecir situaciones en las que el sistema podría expandir sus emisiones a pesar de introducir renovables, debido a que la demanda desplaza la capacidad limpia instalada o a que la hidrología obliga al despacho térmico. Esto es especialmente relevante para el diseño de políticas de transición energética, la seguridad de suministro y los compromisos climáticos.

CONCLUSIONES

El presente estudio demuestra que los modelos de aprendizaje automático permiten estimar de manera robusta las emisiones de CO₂ del sistema eléctrico ecuatoriano, identificando al Random Forest optimizado como la mejor alternativa predictiva bajo condiciones reales de alta variabilidad. Los resultados confirman que la dinámica de emisiones está fuertemente condicionada por la generación térmica y la disponibilidad hidroeléctrica, lo cual refleja la naturaleza hidrotérmica del sistema y su sensibilidad frente a cambios operativos y climáticos.

Dado que, a nivel prospectivo, los escenarios analizados revelan que el aumento de la demanda energética generará por completo un incremento sostenido de las emisiones, que solo se verá superado mediante una disminución estructural de la generación térmica y la incorporación efectiva de medios de fuentes renovables. El estudio, por lo tanto, presenta una herramienta de análisis predictivo que permite evaluar decisiones de planificación energética en función de diferentes escenarios, de acuerdo con la perspectiva de fortalecer la toma de decisiones a favor de una transición energética sostenible para el Ecuador.

Declaración de Ética, Transparencia y Uso de Inteligencia Artificial (IA)

Los datos utilizados provienen de fuentes oficiales y de acceso abierto, incluyendo el Operador Nacional de Electricidad (CENACE), la Agencia de Regulación y Control de Electricidad (ARCONEL), el Instituto Nacional de Estadística y Censos (INEC), el Banco Central del Ecuador (BCE) y la base de datos Prediction of Worldwide Energy Resources de la National Aeronautics and Space Administration (NASA POWER). La información fue sometida a procesos de validación, integración y normalización para garantizar su calidad, consistencia y confiabilidad. Los modelos fueron implementados en entornos reproducibles utilizando Python y Google Colab, mientras que la gestión bibliográfica se realizó mediante Zotero. Para el desarrollo de la investigación se emplearon herramientas de inteligencia artificial como Consensus AI, Scopus e IEEE Xplore para la búsqueda de literatura científica, así como ChatGPT (OpenAI) como apoyo en la mejora de la redacción y optimización de código. Estas herramientas fueron utilizadas exclusivamente como soporte técnico, sin intervenir en el análisis, interpretación ni generación de resultados.

Agradecimientos

Se agradece a la Beca de apoyo a actividades académicas de la Facultad de Posgrado de la Universidad Técnica de Manabí y al Rectorado de la Universidad Técnica de Manabí por el respaldo brindado durante el desarrollo de esta investigación. Asimismo, se reconoce el apoyo en el proceso investigativo al Grupo de Investigación Ingenierías Integradas, Sostenibles e Inteligentes (GIISI) de la Universidad Técnica de Manabí y a la Red para la Integración a Gran Escala de Energías Renovables en los Sistemas Eléctricos (RIBIERSE-CYTED), cuya colaboración ha contribuido significativamente al fortalecimiento académico y técnico del estudio.

REFERENCIAS

- [1] Ji, Z., *et al.* "A Novel Approach for Predicting Anthropogenic CO₂ Emissions Using Machine Learning Based on Clustering of the CO₂ Concentration,". *Atmosphere*. 2024, vol. 15, n. 3, p. 323. ISSN 2073-4433. Disponible en: <https://www.mdpi.com/2073-4433/15/3/323>
- [2] Ding, N., *et al.* "State-of-the-art carbon metering: Continuous emission monitoring systems for industrial applications,". *Heliyon*. 2025, vol. 11, n. 3. ISSN 2405-8440. Disponible en: https://www.researchgate.net/publication/381716430_State-of-The-Art_Carbon_Metering_Continuous_Emission_Monitoring_Systems_for_Industrial_Applications
- [3] Liu, H., *et al.* "A Real-Time Accounting Method for Carbon Dioxide Emissions in High-Energy-Consuming Industrial Parks,". *Processes*. 2024, vol. 12, n. 12, p. 2657. ISSN 2227-9717. Disponible en: <https://www.mdpi.com/2227-9717/12/12/2657>
- [4] Cai, Y., *et al.* "The Optuna-LightGBM-XGBoost Model: A Novel Approach for Estimating Carbon Emissions Based on the Electricity-Carbon Nexus,". *Applied Sciences*. 2024, vol. 14, n. 11, p. 4632. ISSN 2076-3417. Disponible en: <https://www.mdpi.com/2076-3417/14/11/4632>
- [5] Silva, S., *et al.* "Hydropower Scenarios in the Face of Climate Change in Ecuador,". *Sustainability*. 2023, vol. 15, n. 13, p. 10160. ISSN 2071-1050. Disponible en: <https://www.mdpi.com/2071-1050/15/13/10160>
- [6] Li, S., *et al.* "Estimation of transport CO₂ emissions using machine learning algorithm,". *Transportation Research Part D: Transport and Environment*. 2024, vol. 133, p. 104276. ISSN 1879-2340. Disponible en: https://www.researchgate.net/publication/382776942_Estimation_of_transport_CO2_emissions_using_machine_learning_algorithm
- [7] Chilan, P. "Bayesian Hyperparameter Optimization of Machine Learning Models for Predicting Biomass Gasification Gases,". *Applied Sciences*. 2025, vol. 15, n. 3, p. 1018. ISSN 2076-3417. Disponible en: <https://www.mdpi.com/2076-3417/15/3/1018>
- [8] Gurcan, F. "Forecasting CO₂ emissions of fuel vehicles for an ecological world using ensemble learning, machine learning, and deep learning models,". *PeerJ Computer Science*. 2024, vol. 10. ISSN 2376-5992. Disponible en: https://www.researchgate.net/publication/382954245_Forecasting_CO2_emissions_of_fuel_vehicles_for_an_ecological_world_using_ensemble_learning_machine_learning_and_deep_learning_models
- [9] Huang, Z., *et al.* "Comparison of Carbon Emission Forecasting in Guangdong Province Based on Multiple Machine Learning Models,". In *2022 IEEE 5th International Conference on Knowledge Innovation and Invention (ICKII)*, 2022, p. 90–93. Disponible en: <https://ieeexplore.ieee.org/document/9983576>
- [10] Studer, S., *et al.* "Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology,". *MAKE*. 2021, vol. 3, n. 2, p. 392–413. ISSN 2504-4990. Disponible en: <https://www.mdpi.com/2504-4990/3/2/20>
- [11] Guamán, W., *et al.* "Machine Learning-Based Projections of Long-Term Electricity Consumption: The Case Study of Ecuador," in *Advanced Research in Technologies, Information, Innovation and Sustainability*, Springer,

- 2025, p. 174–187. Disponible en: https://www.researchgate.net/publication/389583939_Machine_Learning-Based_Projections_of_Long-Term_Electricity_Consumption_The_Case_Study_of_Ecuador
- [12] Chimphee, S., and Chimphee, W. "Forecasting Carbon Dioxide Emission in Thailand Using Machine Learning Techniques,". International Journal of Electrical and Electronics Engineering Indonesia. 2023, vol. 11, n. 3, p. 896–910. ISSN 2614-2589. Disponible en: https://www.researchgate.net/publication/374479513_Forecasting_Carbon_Dioxide_Emission_in_Thailand_Using_Machine_Learning_Techniques
- [13] Plevris, V., *et al.* "Investigation of Performance Metrics in Regression Analysis and Machine Learning-Based Prediction Models," in ECCOMAS Congress, Oslo, Noruega, 2022. Disponible en: https://www.researchgate.net/publication/374479513_Forecasting_Carbon_Dioxide_Emission_in_Thailand_Using_Machine_Learning_Techniques
- [14] Parra, R. "Contribution of Non-Renewable Sources for Limiting the Electrical CO₂ Emission Factor in Ecuador,". WIT Transactions on Ecology and the Environment. 2020, vol. 244, p. 65–77. ISSN 1743-3541. Disponible en: https://www.researchgate.net/publication/343469533_CONTRIBUTION_OF_NON-RENEWABLE_SOURCES_FOR_LIMITING_THE_ELECTRICAL_CO2_EMISSION_FACTOR_IN_ECUADOR
- [15] Reis, I., *et al.* "Probabilistic Random Forest: A Machine Learning Algorithm for Noisy Data Sets,". The Astronomical Journal. 2019, vol. 157, n. 1, p. 16. ISSN 1538-3881. Disponible en: <https://iopscience.iop.org/article/10.3847/1538-3881/aaf101>
- [16] Fajardo, J., *et al.* "Predicting Academic Success of College Students Using Machine Learning Techniques,". DATA. 2024, vol. 9, n. 4, p. 60. ISSN 2306-5729. Disponible en: <https://www.mdpi.com/2306-5729/9/4/60>
- [17] Rahimi, M., *et al.* "Toward Smart Carbon Capture with Machine Learning,". Cell Reports Physical Science. 2021, vol. 2, n. 4. ISSN 2666-3864. Disponible en: <https://www.sciencedirect.com/science/article/pii/S2666386421000862>
- [18] Oscullo, J. "Evolución de las Emisiones de CO₂ Producido por el Parque Generador del Sistema Nacional Interconectado del Ecuador para el Periodo 2010-2015". Revista Técnica Energía. 2017, vol. 13, n. 1. ISSN 1390-5074. Disponible en: https://www.researchgate.net/publication/338876199_Evolucion_de_las_Emisiones_de_CO2_Producido_por_el_Parque_Generador_del_Sistema_Nacional_Interconectado_del_Ecuador_para_el_Periodo_2010-2015
- [19] Du, X., *et al.* "Machine Learning in Carbon Capture, Utilization, Storage, and Transportation: A Review of Applications in Greenhouse Gas Emissions Reduction,". Processes. 2025, vol. 13, n. 4. ISSN 2227-9717. Disponible en: <https://www.mdpi.com/2227-9717/13/4/1160>
- [20] Couture, H., *et al.* "Estimating Carbon Dioxide Emissions from Power Plant Water Vapor Plumes Using Satellite Imagery and Machine Learning,". Remote Sensing. 2024, vol. 16, n. 7. ISSN 2072-4292. Disponible en: <https://www.mdpi.com/2072-4292/16/7/1290>

CONFLICTO DE INTERESES

Los autores declaran que no existen conflictos de intereses.

CONTRIBUCIÓN DE LOS AUTORES

Ciaddy Gina Rodríguez Borges: <https://orcid.org/0000-0003-1097-4194>

Participó en el aporte de ideas, recolección de datos, revisión del estado del arte, programación de software empleado en la investigación, análisis de los resultados, trabajo estadístico, redacción del borrador del artículo, revisión crítica de su contenido y aprobación final.

Mariuxi Guillen Intriago: <https://orcid.org/0009-0005-6923-0538>

Participó en el aporte de ideas, recolección de datos, análisis de los resultados, revisión crítica del borrador del artículo y aprobación final.

Leonardo Chancay García: <https://orcid.org/0000-0002-4090-048X>

Participó en el aporte de ideas, revisión del estado del arte, revisión crítica del borrador del artículo y aprobación final