

## Modelamiento del consumo eléctrico de los usuarios residenciales ante un posible confinamiento en el área de concesión de la empresa Eléctrica provincial Cotopaxi en el cantón Latacunga

## Modeling of the electrical consumption of residential users in the face of a possible confinement in the concession area of the Cotopaxi provincial electricity company in the Latacunga canton

William Armando Hidalgo Osorio<sup>1</sup> , Daniel Antonio Chuquin Vasco<sup>1</sup> 

<sup>1</sup>Universidad Nacional de Chimborazo, Riobamba – Ecuador

Correo de correspondencia: william.hidalgo@unach.edu.ec, daniel.chuquin@unach.edu.ec

### Información del artículo

**Tipo de artículo:**  
Artículo original

**Recibido:**  
18/07/2024

**Aceptado:**  
11/09/2024

**Publicado:**  
05/10/2024

**Revista:**  
DATEH

OPEN  ACCESS



### Resumen

Este artículo examina el modelamiento del consumo eléctrico de los usuarios residenciales en el área de concesión de la Empresa Eléctrica Provincial Cotopaxi en el Cantón Latacunga, centrándose en la evaluación del posible impacto de un confinamiento en dicho cantón. Utilizando datos históricos de consumo eléctrico recopilados durante un período de tres años, se emplean técnicas avanzadas de modelado en un software especializado. Estos datos se analizan minuciosamente para identificar patrones y tendencias en el consumo de energía residencial. A continuación, se utilizan estos datos como entrada en el software de modelado para prever cómo diferentes escenarios de confinamiento podrían influir en los patrones futuros de consumo de energía en los hogares. Los resultados obtenidos a través de este enfoque proporcionan conclusiones valiosas y relevantes que se extraen del análisis del consumo eléctrico residencial en relación con el posible impacto de un confinamiento que pueden afectar la demanda de electricidad residencial en el área de estudio. Además, este estudio contribuye a la comprensión más amplia de la gestión energética y la planificación de contingencias en situaciones similares en el futuro. Los hallazgos de este estudio tienen implicaciones importantes para la toma de decisiones tanto a nivel gubernamental como empresarial en términos de asegurar un suministro eléctrico estable y eficiente, especialmente en momentos de crisis como el confinamiento.

**Palabras clave:** Consumo eléctrico residencial, Modelamiento, Confinamiento, Gestión energética

### Abstract

This article examines the modeling of electrical consumption of residential users in the concession area of the Cotopaxi Provincial Electric Company in the Latacunga Canton, focusing on the evaluation of the possible impact of a confinement in said canton. Using historical electricity consumption data collected over a three-years period, advanced modeling techniques are employed in specialized software. This data is carefully analyzed to identify patterns and trends in residential energy consumption. This data is then used as input into modeling software to predict how different lockdown scenarios could influence future household energy consumption patterns. The results obtained through this approach provide valuable and relevant conclusions that are drawn from the analysis of residential electricity consumption in relation to the possible impact of a lockdown that may affect residential electricity demand in the study area. Furthermore, this study contributes to the broader understanding of energy management and contingency planning in similar situations in the future. The findings of this study have important implications for decision-making at both government and business levels in terms of ensuring a stable and efficient electricity supply, especially in times of crisis such as lockdown.

**Keywords:** Residential electricity consumption, Modeling, Confinement, Energy management

## INTRODUCCIÓN

La pandemia de COVID-19 ha tenido un impacto sin precedentes en diversos sectores de la economía global, y el sector eléctrico no ha sido una excepción. Las medidas de confinamiento implementadas por los gobiernos de todo el mundo para contener la propagación del virus han generado cambios significativos en los patrones de consumo de energía eléctrica (Cheshmehzangi, 2020). Mientras que la demanda en el sector industrial y comercial ha disminuido debido al cierre de empresas y la reducción de la actividad económica, el consumo residencial ha experimentado un aumento notable como resultado del tiempo prolongado que las personas pasan en sus hogares (Charfeddine et al., 2023).

Estos cambios abruptos han planteado desafíos importantes para las empresas distribuidoras de electricidad, que se han enfrentado a dificultades para realizar la lectura de los medidores y la facturación de manera precisa durante los periodos de cuarentena (Abdeen et al., 2021). La imposibilidad de llevar a cabo visitas presenciales a los hogares de los usuarios ha obligado a las empresas a buscar alternativas para estimar el consumo, como el uso de promedios históricos o la implementación de sistemas de telemedición (Jiang et al., 2021). Sin embargo, estas soluciones no siempre han sido efectivas y han generado discrepancias entre el consumo real y el facturado, lo que ha provocado la insatisfacción de los usuarios y un aumento en los reclamos (Chaianong et al., 2022).

En Ecuador, el impacto de la pandemia en el sector eléctrico ha sido significativo. Desde el inicio del confinamiento el 17 de marzo de 2020, se ha registrado una reducción promedio del 16% en la producción de energía eléctrica (CENACE, 2020). Las empresas eléctricas, al ser entidades públicas, han tenido que seguir las directrices del gobierno, como la prohibición de suspender el servicio por falta de pago y la habilitación de canales virtuales para la recaudación (MERNNR, 2020). No obstante, la imposibilidad de realizar lecturas presenciales de los medidores ha llevado a la aplicación de métodos de estimación basados en promedios históricos, lo que ha generado inconformidad en los usuarios y un alto número de reclamos (CNEL EP, 2022).

En la provincia de Cotopaxi, la Empresa Eléctrica Provincial Cotopaxi (ELEPCO S.A.) ha enfrentado desafíos similares. Una vez reiniciada la toma de lecturas, se han evidenciado errores en la facturación que han requerido ajustes y la emisión de notas de crédito para los usuarios afectados (ELEPCO SA, 2020). Esta situación ha puesto de manifiesto la necesidad de contar con un análisis detallado del comportamiento del consumo eléctrico en periodos de confinamiento, que permita a ELEPCO S.A.

mejorar su capacidad de respuesta ante eventos similares en el futuro (Muñoz, 2022).

El presente estudio tiene como objetivo analizar el comportamiento del consumo de energía eléctrica ante el confinamiento en el área de concesión de ELEPCO S.A., mediante el desarrollo de un modelo estadístico de proyección aplicable a las diferentes categorías tarifarias. Se busca establecer patrones y tendencias que permitan estimar de manera más precisa la demanda de electricidad en condiciones atípicas, con el fin de optimizar los procesos de facturación, reducir los errores y mejorar la satisfacción de los usuarios (Kuzemko et al., 2020).

La investigación se basa en el análisis de una amplia base de datos de consumo eléctrico proporcionada por ELEPCO S.A., correspondiente a los periodos previo, durante y posterior al confinamiento por COVID-19. Se aplicarán técnicas estadísticas y modelos de proyección, como el análisis de series temporales y los modelos ARIMA (Autoregressive Integrated Moving Average), para identificar las variaciones en el consumo de las diferentes categorías tarifarias, con especial énfasis en el sector residencial, que representa la mayor proporción de usuarios (Alasali et al., 2021).

Los resultados de este estudio tendrán una aplicación práctica para ELEPCO S.A. y otras empresas distribuidoras de electricidad, al proporcionar una herramienta validada para la estimación del consumo en situaciones de emergencia que impliquen restricciones a la movilidad y cambios en los patrones de demanda (Gu et al., 2017). Además, se espera que las conclusiones contribuyan a mejorar la planificación y la toma de decisiones en el sector eléctrico, así como a fortalecer la resiliencia de las empresas ante eventos disruptivos (Carvalho et al., 2021).

## MATERIALES Y MÉTODOS

**Clasificación de los Usuarios:** Los usuarios de la Empresa Eléctrica Provincial Cotopaxi S.A. (EEPC) se dividen en dos categorías: residencial y general. La categoría general incluye usuarios comerciales, industriales, de servicio público y privado. En el cantón Latacunga, se cuentan con 64.772 usuarios residenciales y 10.396 usuarios de categoría general, sin demanda. Para este estudio, se utilizó una base de datos de 2.235.444 registros de consumo eléctrico que cubren toda el área de concesión de la EEPC.

De estos, 1.052.352 registros pertenecen a usuarios del cantón Latacunga. El análisis se realizó en un periodo de 25 meses, abarcando tres fases: 7 meses previos a la pandemia (septiembre 2019 a febrero 2020), 3 meses de cuarentena (marzo 2020 a mayo 2020), y 15 meses posteriores al primer levantamiento del estado de excepción (junio 2020 a septiembre 2021).

**Procedimientos de Limpieza y Preprocesamiento de Datos:** Antes de aplicar los modelos de predicción, se llevaron a cabo diversos procedimientos de limpieza y preprocesamiento de los datos:

1. **Eliminación de Valores Atípicos y Faltantes:** Los datos que presentaban inconsistencias, como lecturas fuera de rango o valores faltantes, fueron eliminados para asegurar la calidad de la base de datos.
2. **Normalización de los Datos:** Se normalizaron las series temporales de consumo para homogeneizar las unidades y hacer comparables los distintos usuarios en diferentes periodos.
3. **Organización de la Base de Datos:** La información mensual se dividió en cinco archivos separados para facilitar el análisis. Además, se aplicaron técnicas de reducción de dimensionalidad para optimizar el manejo de los datos en los modelos.

**Selección de la Muestra:** Se seleccionó una muestra representativa de 382 usuarios residenciales para realizar el análisis de consumo. La selección se basó en criterios como la estabilidad de las lecturas mensuales, representatividad geográfica dentro del cantón Latacunga, y comportamiento histórico del consumo. La muestra fue validada mediante métodos de muestreo aleatorio estratificado, asegurando la inclusión de diversos rangos de consumo y tipologías de vivienda.

**Justificación de los Modelos Utilizados:** Se optó por tres enfoques de modelado predictivo, cada uno seleccionado con base en su capacidad para manejar datos de series temporales y su rendimiento en estudios previos de consumo energético:

1. **Regresión Lineal:** Este modelo fue seleccionado por su simplicidad y efectividad en la identificación de tendencias lineales a largo plazo en los datos de consumo eléctrico.
2. **Modelo Polinómico:** Se utilizó este modelo para capturar posibles relaciones no lineales en el consumo, especialmente en periodos de transición, como el inicio de la pandemia o el levantamiento de restricciones.
3. **Árbol de Decisión:** Este enfoque permitió identificar patrones complejos y realizar predicciones más precisas en escenarios con mayor variabilidad, como las fluctuaciones de consumo durante el confinamiento.

La validación cruzada se aplicó a todos los modelos, dividiendo los datos en un 70% para entrenamiento y un 30% para prueba. Se evaluaron mediante métricas como el

coeficiente de determinación ( $R^2$ ) y el error absoluto medio (MAE), confirmando la robustez de los modelos en distintos escenarios de confinamiento.

**Herramientas y Software Utilizado:** El análisis se desarrolló utilizando Python, empleando librerías como pandas, NumPy, scikit-learn, y ARIMA para el modelado de las series temporales. Las visualizaciones se realizaron con Matplotlib y Seaborn. El procesamiento se llevó a cabo en un equipo con un procesador Intel Core i7 y 16 GB de RAM, lo que permitió un manejo eficiente de grandes volúmenes de datos.

#### Metodología de Modelado

**Preprocesamiento de Datos:**

Se realizaron procedimientos de limpieza de datos para tratar valores atípicos y faltantes. Los datos se normalizaron para asegurar la coherencia en el análisis.

#### Análisis Exploratorio de Datos (EDA):

Se llevaron a cabo análisis descriptivos y visualizaciones iniciales para comprender mejor las características del conjunto de datos.

#### Desarrollo del Modelo de Predicción:

Se optó por un modelo de regresión lineal, polinómica y árbol de decisión debido a su simplicidad y efectividad en la predicción de series temporales. El conjunto de datos se dividió en un 70% para entrenamiento y un 30% para prueba. La validación cruzada se utilizó para ajustar los parámetros del modelo.

#### Evaluación del Modelo

Se emplearon métricas como el error relativo y el coeficiente de determinación ( $R^2$ ) para evaluar la precisión del modelo. Las predicciones del modelo se compararon con los datos reales, demostrando una alta precisión en la estimación del consumo eléctrico bajo diferentes escenarios de confinamiento.

#### Modelos de proyección:

##### Modelo 1: Medias móviles

- Se utiliza para **series de tiempo estocásticas**.
- Se calcula el **promedio móvil de 2 a 6 meses**.
- Se utiliza para **proyectar los valores de consumo** de abril y mayo de 2020.
- Se utiliza para **establecer una proyección** en caso de confinamiento.
- **Modelo 2: Mínimos cuadrados ordinarios**
- Se utiliza para **pronosticar datos** basados en el comportamiento de la serie.
- Se utiliza la **regresión lineal** para encontrar la relación entre los datos.
- Se utiliza la **herramienta de análisis de datos de Excel** para realizar los cálculos.

- Se obtienen **coeficientes de intercepción y variable X1 (a y b)**.
- Se utiliza la **ecuación de la recta** para obtener el valor de proyección.

#### Análisis de la proyección:

- Se analiza el **gráfico de la proyección**.
- Se calcula el **valor  $R^2$** .
- Se calcula la **varianza**.
- Se calcula la **desviación estándar**.
- Se **compara el pronóstico con los valores reales**.

#### Herramientas adicionales:

**Python:** Se utilizó Python con las librerías pandas, matplotlib.pyplot, seaborn y arima para el análisis de datos y la creación de gráficos.

**ARIMA** (Autoregressive Integrated Moving Average) es un modelo estadístico que se utiliza para **modelar series temporales**, es decir, datos que se recopilan a lo largo del tiempo. En el caso del consumo eléctrico, ARIMA puede ser útil para **pronosticar el consumo futuro** en función del consumo pasado.

ARIMA funciona mediante la identificación de patrones en los datos históricos. El modelo se basa en tres componentes principales:

- **Autoregresión (AR):** Esta componente mide la relación entre el valor actual de la serie y sus valores pasados.
- **Integración (I):** Esta componente se utiliza para eliminar la no estacionariedad de la serie, es decir, para hacer que la serie tenga una media y una varianza constantes a lo largo del tiempo.
- **Media móvil (MA):** Esta componente mide la relación entre el valor actual de la serie y los errores de pronóstico de los valores pasados.

#### Librerías:

- **Pandas:** Esta librería se utiliza para **manipular y analizar datos**. Permite cargar datos de diferentes formatos, limpiar datos, crear nuevas variables y realizar cálculos estadísticos.
- **Matplotlib.pyplot:** Esta librería se utiliza para **crear gráficos**. Permite crear diferentes tipos de gráficos, como líneas, barras, dispersión y histogramas.
- **Seaborn:** Esta librería se utiliza para **crear visualizaciones de datos más sofisticadas**. Permite crear gráficos con diferentes estilos y colores, y también permite crear gráficos interactivos.
- **Arima:** Esta librería se utiliza para **ajustar**

**modelos ARIMA a series temporales.** Permite estimar los parámetros del modelo, realizar pronósticos y evaluar el rendimiento del modelo.

**Uso de Python:** Python es un lenguaje de programación que se utiliza ampliamente para **análisis de datos y ciencia de datos**. Es un lenguaje relativamente fácil de aprender y tiene una gran cantidad de librerías disponibles para diferentes tareas, como el análisis de datos, el aprendizaje automático y la visualización de datos.

En el caso del documento que estamos analizando, Python se utiliza para:

- **Cargar y limpiar los datos de consumo eléctrico.**
- **Analizar los datos y explorar patrones.**
- **Ajustar modelos ARIMA a los datos.**
- **Realizar pronósticos del consumo futuro.**
- **Evaluar el rendimiento de los modelos.**
- **Crear gráficos para visualizar los resultados.**
- **Beneficios de usar Python:**
  - **Flexibilidad:** Python es un lenguaje muy flexible que permite realizar una amplia variedad de tareas.
  - **Facilidad de uso:** Python es un lenguaje relativamente fácil de aprender, incluso para personas sin experiencia en programación.
  - **Gran cantidad de librerías:** Python tiene una gran cantidad de librerías disponibles para diferentes tareas, lo que facilita el análisis de datos y la creación de modelos.
  - **Comunidad grande y activa:** Python tiene una comunidad grande y activa de desarrolladores que están dispuestos a ayudar a los demás.

En resumen, ARIMA, las librerías mencionadas y Python son herramientas valiosas para el modelado del consumo eléctrico. ARIMA permite crear modelos estadísticos para pronosticar el consumo futuro, las librerías permiten manipular, analizar y visualizar los datos, y Python es un lenguaje flexible y fácil de usar que permite realizar todas estas tareas de manera eficiente.

## RESULTADOS Y DISCUSIÓN

### Modelo de regresión lineal

El modelo de regresión lineal se ha entrenado para predecir el consumo de energía en kWh para un usuario específico en los meses de octubre 2021 hasta septiembre 2022 siendo los meses 26 al 37. Los resultados se han evaluado las predicciones comparando con los valores reales

### Resultados del Modelo

**Usuario: 20421**

Predicción Meses: Octubre 2021 – Septiembre 2022

**Predicción de Consumo**

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:

Predicción de consumo: X kWh

Predicciones guardadas en 'predicciones\_consumo\_lin.csv'


Errores relativos por usuario guardados en 'errores\_relativos\_lin.csv'

Error relativo para el usuario 20421 y el mes mes-26:

$$\text{Error relativo} = |(143 - 116.99999999999972) / 143| * 100$$

Error relativo = 18.18%

**Comparación de valores promedio reales y predichos del usuario 20421**



**Meses 26 a 28:**

Se observa que los valores predichos (rojo) están bastante alineados con los valores reales (azul), aunque hay una ligera sobreestimación en el mes 27 y 28.

**Meses 29 y 30:**

En el mes 29, hay una caída en el consumo real que también es reflejada por la predicción, aunque la predicción es algo más baja. En el mes 30, ambos valores vuelven a subir y están muy próximos entre sí.

**Meses 31 a 37:**

En estos meses, las predicciones se desvían un poco más de los valores reales. En general, las predicciones parecen ser más estables y menos volátiles en comparación con los valores reales, que muestran más variaciones mes a mes.

**Usuario: 86443**

Predicción Meses: Octubre 2021 – Septiembre 2022

**Predicción de Consumo**

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:

Predicción de consumo: X kWh

Predicciones guardadas en 'predicciones\_consumo\_lin.csv'


Errores relativos por usuario guardados en 'errores\_relativos\_lin.csv'

Error relativo para el usuario 86443 y el mes mes-26:

$$\text{Error relativo} = |(280 - 268.99999999999955) / 280| * 100$$

Error relativo = 3.93%

**Comparación de valores promedio reales y predichos del usuario 86443**



**Mes 26 a Mes 27:**

La predicción (roja) subestima el consumo real (azul), pero a partir del mes 27 ambas líneas se acercan.

**Mes 27 a Mes 28:**

La predicción es más alta que el valor real, mostrando una sobreestimación por parte del modelo.

**Mes 29 a Mes 30:**

La línea real baja significativamente, mientras que la línea predicha muestra una disminución más suave, indicando una diferencia notable entre los valores reales y predichos.

**Mes 31 a Mes 32:**

El valor real tiene un aumento, mientras que el valor predicho tiene un pico más pronunciado, nuevamente mostrando una sobreestimación por parte del modelo.

**Mes 33 a Mes 34:**

Los valores reales y predichos muestran comportamientos opuestos, con la predicción bajando mientras que el valor real sube.

**Mes 35 a Mes 36:**

Los valores reales son relativamente estables con un pequeño aumento, mientras que los valores predichos muestran una tendencia a la baja, indicando una subestimación en el mes 36.

**Mes 37:**

Ambas líneas convergen nuevamente, aunque todavía existe una diferencia notable.

#### Usuario: 32430

Predicción Meses: Octubre 2021 – Septiembre 2022

#### Predicción de Consumo

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:

Predicción de consumo: X kWh

Predicciones guardadas en

'predicciones\_consumo\_lin.csv'

Errores relativos por usuario guardados en


'errores\_relativos\_lin.csv'

Error relativo para el usuario 32430 y el mes mes-26:

Error relativo =  $|(83 - 82.00000000000009) / 83| * 100$

Error relativo = 1.20%

#### Comparación de valores promedio reales y predichos del usuario 32430



#### Mes 26 a Mes 27:

Subestimación inicial: La línea de predicción (roja) se encuentra por debajo de la línea de consumo real (azul), indicando que el modelo subestimó el consumo real en este período.

Convergencia gradual: Sin embargo, ambas líneas comienzan a acercarse entre sí, sugiriendo que el modelo está ajustando su predicción para reflejar mejor la tendencia real del consumo.

#### Mes 27 a Mes 28:

Sobreestimación: La línea de predicción supera la línea de consumo real, lo que indica que el modelo ahora está sobreestimando el consumo real.

Posible ajuste: Es posible que el modelo haya reaccionado de manera excesiva al aumento repentino del consumo real en el Mes 27, lo que llevó a la sobreestimación.

#### Mes 29 a Mes 30:

Divergencia significativa: La línea de consumo real experimenta una caída notable, mientras que la línea de predicción muestra una disminución más suave. Esto amplía la brecha entre las dos líneas, indicando una diferencia sustancial entre el consumo real y el predicho.

Posibles factores: La caída en el consumo real podría deberse a factores externos no capturados por el modelo, como cambios en las condiciones económicas o eventos específicos del mercado.

#### Mes 31 a Mes 32:

Recuperación real vs. pico de predicción: El consumo real experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado. Esta divergencia nuevamente resalta la diferencia entre las tendencias reales y predichas.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del consumo.

#### Mes 33 a Mes 34:

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el consumo real aumenta. Esta divergencia indica que el modelo no está capturando correctamente la dirección del cambio real del consumo.


#### Mes 35 a Mes 36:

Estabilidad real vs. tendencia a la baja en la predicción: El consumo real se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja. Esta diferencia sugiere que el modelo está subestimando el consumo real en este período.

#### Mes 37:

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas. Esto indica que el modelo aún no ha logrado capturar completamente la tendencia real del consumo.

#### Comparación de valores promedio reales y predichos de la muestra de los 382 usuarios en el modelo lineal



El gráfico muestra una comparación entre el consumo promedio real y el consumo promedio predicho por un modelo durante un período de 12 meses (Mes 26 a Mes 37).

Se observa una tendencia general de aumento en el consumo promedio real, con algunas fluctuaciones a lo largo del período. El modelo predice una tendencia similar de aumento, pero con mayor suavidad y con algunos errores de subestimación y sobreestimación en ciertos puntos específicos.

#### Análisis por mes:

Mes 26 a Mes 27:

Subestimación inicial: La línea de predicción se encuentra por debajo de la línea de consumo real, indicando que el modelo subestimó el consumo real en este período.

Convergencia gradual: Sin embargo, ambas líneas comienzan a acercarse entre sí, sugiriendo que el modelo está ajustando su predicción para reflejar mejor la tendencia real del consumo.

Mes 27 a Mes 28:

Sobreestimación: La línea de predicción supera la línea de consumo real, lo que indica que el modelo ahora está sobreestimando el consumo real.

Posible ajuste: Es posible que el modelo haya reaccionado de manera excesiva al aumento repentino del consumo real en el Mes 27, lo que llevó a la sobreestimación.

Mes 29 a Mes 30:

Divergencia significativa: La línea de consumo real experimenta una caída notable, mientras que la línea de predicción muestra una disminución más suave. Esto amplía la brecha entre las dos líneas, indicando una diferencia sustancial entre el consumo real y el predicho.

Posibles factores: La caída en el consumo real podría deberse a factores externos no capturados por el modelo, como cambios en las condiciones económicas o eventos específicos del mercado.

Mes 31 a Mes 32:

Recuperación real vs. pico de predicción: El consumo real experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado. Esta divergencia nuevamente resalta la diferencia entre las tendencias reales y predichas.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del consumo.

Mes 33 a Mes 34:

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el consumo real aumenta. Esta divergencia indica que el modelo no está capturando correctamente la dirección del cambio real del consumo.

Mes 35 a Mes 36:

Estabilidad real vs. tendencia a la baja en la predicción: El consumo real se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja. Esta diferencia sugiere que el modelo está subestimando el consumo real en este período.

Mes 37:

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas. Esto indica que el modelo aún no ha logrado capturar completamente la tendencia real del consumo.

#### Modelo de regresión polinomial

El modelo de regresión polinomial se ha entrenado para predecir el consumo de energía en kWh para un usuario específico en los meses de octubre 2021 hasta septiembre 2022 siendo los meses 26 al 37. Los resultados se han evaluado las predicciones comparando con los valores reales

#### Resultados del Modelo

Usuario: 20421

Predicción Meses: Octubre 2021 – Septiembre 2022

Predicción de Consumo

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:

Predicción de consumo: X kWh

Predicciones guardadas en 'predicciones\_consumo\_pol.csv'


Errores relativos por usuario guardados en

'errores\_relativos\_pol.csv'

Error relativo para el usuario 20421 y el mes mes-26:

Error relativo =  $|(143 - 116.99999999999984) / 143| * 100$

Error relativo = 18.18%  
 $\text{Error relativo} = |(74 - 70.9999999999988) / 74| * 100$   
 Error relativo = 4.05%



**Mes 26 a Mes 27:**

Subestimación inicial: La línea de predicción se encuentra por debajo de la línea de consumo real, indicando que el modelo subestimó el consumo real de energía en este período.

Convergencia gradual: Sin embargo, ambas líneas comienzan a acercarse entre sí, sugiriendo que el modelo está ajustando su predicción para reflejar mejor la tendencia real del consumo de energía.

**Mes 27 a Mes 28:**

Sobreestimación: La línea de predicción supera la línea de consumo real, lo que indica que el modelo ahora está sobreestimando el consumo real de energía.

Posible ajuste: Es posible que el modelo haya reaccionado de manera excesiva al aumento repentino del consumo real de energía en el Mes 27, lo que llevó a la sobreestimación.

**Mes 29 a Mes 30:**

Divergencia significativa: La línea de consumo real experimenta una caída notable, mientras que la línea de predicción muestra una disminución más suave. Esto amplía la brecha entre las dos líneas, indicando una diferencia sustancial entre el consumo real y el predicho de energía.

Posibles factores: La caída en el consumo real de energía podría deberse a factores externos no capturados por el modelo, como cambios en los patrones de uso de energía, implementaciones de medidas de eficiencia energética o eventos climáticos que afectaron la demanda de energía.

**Mes 31 a Mes 32:**

Recuperación real vs. pico de predicción: El consumo real de energía experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado. Esta

divergencia nuevamente resalta la diferencia entre las tendencias reales y predichas del consumo de energía.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del consumo de energía.

**Mes 33 a Mes 34:**

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el consumo real de energía aumenta. Esta divergencia indica que el modelo no está capturando correctamente la dirección del cambio real del consumo de energía.

**Mes 35 a Mes 36:**

Estabilidad real vs. tendencia a la baja en la predicción: El consumo real de energía se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja. Esta diferencia sugiere que el modelo está subestimando el consumo real de energía en este período.

**Mes 37:**

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas. Esto indica que el modelo aún no ha logrado capturar completamente la tendencia real del consumo de energía.

**Usuario: 32430**

Predicción Meses: Octubre 2021 – Septiembre 2022

**Predicción de Consumo**

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:


Predicción de consumo: X kWh

Predicciones guardadas en 'predicciones\_consumo\_pol.csv'

Errores relativos por usuario guardados en 'errores\_relativos\_pol.csv'

Error relativo para el usuario 32430 y el mes mes-26:  
 $\text{Error relativo} = |(83 - 82.0000000000018) / 83| * 100$   
 Error relativo = 1.20%





**Mes 26 a Mes 27:**

Subestimación inicial: La línea de predicción se encuentra por debajo de la línea de consumo real, indicando que el modelo subestimó el consumo real de energía en este período.

Convergencia gradual: Sin embargo, ambas líneas comienzan a acercarse entre sí, sugiriendo que el modelo está ajustando su predicción para reflejar mejor la tendencia real del consumo de energía.

**Mes 27 a Mes 28:**

Sobreestimación: La línea de predicción supera la línea de consumo real, lo que indica que el modelo ahora está sobreestimando el consumo real de energía.

Posible ajuste: Es posible que el modelo haya reaccionado de manera excesiva al aumento repentino del consumo real de energía en el Mes 27, lo que llevó a la sobreestimación.

**Mes 29 a Mes 30:**

Divergencia significativa: La línea de consumo real experimenta una caída notable, mientras que la línea de predicción muestra una disminución más suave. Esto amplía la brecha entre las dos líneas, indicando una diferencia sustancial entre el consumo real y el predicho de energía.

Posibles factores: La caída en el consumo real de energía podría deberse a factores externos no capturados por el modelo, como cambios en los patrones de uso de energía, implementaciones de medidas de eficiencia energética o eventos climáticos que afectaron la demanda de energía.

**Mes 31 a Mes 32:**

Recuperación real vs. pico de predicción: El consumo real de energía experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado. Esta divergencia nuevamente resalta la diferencia entre las tendencias reales y predichas del consumo de energía.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la

subestimación del Mes 29, pero aún no ha alcanzado el nivel real del consumo de energía.

**Mes 33 a Mes 34:**

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el consumo real de energía aumenta. Esta divergencia indica que el modelo no está capturando correctamente la dirección del cambio real del consumo de energía.

**Mes 35 a Mes 36:**

Estabilidad real vs. tendencia a la baja en la predicción: El consumo real de energía se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja. Esta diferencia sugiere que el modelo está subestimando el consumo real de energía en este período.

**Mes 37:**

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas. Esto indica que el modelo aún no ha logrado capturar completamente la tendencia real del consumo de energía.

**Usuario: 86443**

Predicción Meses: Octubre 2021 – Septiembre 2022

**Predicción de Consumo**

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:

Predicción de consumo: X kWh


Predicciones guardadas en 'predicciones\_consumo\_pol.csv'

Errores relativos por usuario guardados en 'errores\_relativos\_pol.csv'

Error relativo para el usuario 86443 y el mes mes-26:

$$\text{Error relativo} = |(280 - 268.9998020976328) / 280| * 100$$

$$\text{Error relativo} = 3.93\%$$



**Mes 26 a Mes 27:**

Subestimación inicial: La línea de predicción (azul) se encuentra por debajo de la línea de consumo real (roja), indicando que el modelo subestimó el consumo real de energía en este período.

Convergencia gradual: Sin embargo, ambas líneas comienzan a acercarse entre sí, sugiriendo que el modelo está ajustando su predicción para reflejar mejor la tendencia real del consumo de energía.

Mes 27 a Mes 28:

Sobreestimación: La línea de predicción supera la línea de consumo real, lo que indica que el modelo ahora está sobreestimando el consumo real de energía.

Posible ajuste: Es posible que el modelo haya reaccionado de manera excesiva al aumento repentino del consumo real de energía en el Mes 27, lo que llevó a la sobreestimación.

Mes 29 a Mes 30:

Divergencia significativa: La línea de consumo real experimenta una caída notable, mientras que la línea de predicción muestra una disminución más suave. Esto amplía la brecha entre las dos líneas, indicando una diferencia sustancial entre el consumo real y el predicho de energía.

Posibles factores: La caída en el consumo real de energía podría deberse a factores externos no capturados por el modelo, como cambios en los patrones de uso de energía, implementaciones de medidas de eficiencia energética o eventos climáticos que afectaron la demanda de energía.

Mes 31 a Mes 32:

Recuperación real vs. pico de predicción: El consumo real de energía experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado. Esta divergencia nuevamente resalta la diferencia entre las tendencias reales y predichas del consumo de energía.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del consumo de energía.

Mes 33 a Mes 34:

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el consumo real de energía aumenta. Esta divergencia indica que el modelo no está capturando correctamente la dirección del cambio real del consumo de energía.

Mes 35 a Mes 36:

Estabilidad real vs. tendencia a la baja en la predicción: El consumo real de energía se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja. Esta diferencia sugiere que el modelo está subestimando el consumo real de energía en este período.

Mes 37:

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas. Esto indica que el modelo aún no ha logrado capturar completamente la tendencia real del consumo de energía.

### Comparación de valores promedio reales y predichos de la muestra de los 382 usuarios en el modelo polinomial



El gráfico muestra una comparación entre el consumo de energía promedio real y el consumo de energía promedio predicho por un modelo durante un período de 12 meses (Mes 26 a Mes 37). Se observa una tendencia general de aumento en el consumo de energía promedio real, con algunas fluctuaciones a lo largo del período. El modelo predice una tendencia similar de aumento, pero con mayor suavidad y con algunos errores de subestimación y sobreestimación en ciertos puntos específicos.

### Análisis por mes:

Mes 26 a Mes 27:

Subestimación inicial: La línea de predicción (azul) se encuentra por debajo de la línea de consumo real (roja), indicando que el modelo subestimó el consumo real de energía en este período.

Convergencia gradual: Sin embargo, ambas líneas comienzan a acercarse entre sí, sugiriendo que el modelo está ajustando su predicción para reflejar mejor la tendencia real del consumo de energía.

Mes 27 a Mes 28:

Sobreestimación: La línea de predicción supera la línea de consumo real, lo que indica que el modelo ahora está sobreestimando el consumo real de energía.

**Posible ajuste:** Es posible que el modelo haya reaccionado de manera excesiva al aumento repentino del consumo real de energía en el Mes 27, lo que llevó a la sobreestimación.

**Mes 29 a Mes 30:**

**Divergencia significativa:** La línea de consumo real experimenta una caída notable, mientras que la línea de predicción muestra una disminución más suave. Esto amplía la brecha entre las dos líneas, indicando una diferencia sustancial entre el consumo real y el predicho de energía.

**Posibles factores:** La caída en el consumo real de energía podría deberse a factores externos no capturados por el modelo, como cambios en los patrones de uso de energía, implementaciones de medidas de eficiencia energética o eventos climáticos que afectaron la demanda de energía.

**Mes 31 a Mes 32:**

**Recuperación real vs. pico de predicción:** El consumo real de energía experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado. Esta divergencia nuevamente resalta la diferencia entre las tendencias reales y predichas del consumo de energía.

**Posible corrección del modelo:** El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del consumo de energía.

**Mes 33 a Mes 34:**

**Comportamientos opuestos:** Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el consumo real de energía aumenta. Esta divergencia indica que el modelo no está capturando correctamente la dirección del cambio real del consumo de energía.

**Mes 35 a Mes 36:**

**Estabilidad real vs. tendencia a la baja en la predicción:** El consumo real de energía se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja. Esta diferencia sugiere que el modelo está subestimando el consumo real de energía en este período.

**Mes 37:**

**Convergencia parcial:** Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas. Esto indica que el modelo aún no ha logrado capturar completamente la tendencia real del consumo de energía.

### Modelo de regresión árbol de decisión

El modelo de regresión árbol de decisión se ha entrenado para predecir el consumo de energía en kWh para un

usuario específico en los meses de octubre 2021 hasta septiembre 2022 siendo los meses 26 al 37. Los resultados se han evaluado las predicciones comparando con los valores reales

**Usuario: 20421**

Predicción Meses: Octubre 2021 – Septiembre 2022

Predicción de Consumo

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:

Predicción de consumo: X kWh


Predicciones guardadas en 'predicciones\_consumo\_tree.csv'

Errores relativos por usuario guardados en 'errores\_relativos\_tree.csv'

Error relativo para el usuario 20421 y el mes mes-26:

Error relativo =  $|(143 - 117.0) / 143| * 100$

Error relativo = 18.18%



**Mes 26 a Mes 27:**

**Subestimación inicial:** El modelo subestima el consumo real de energía en este período.

**Convergencia gradual:** El modelo comienza a ajustar su predicción para reflejar mejor la tendencia real del consumo de energía.

**Mes 27 a Mes 28:**

**Sobreestimación:** El modelo sobreestima el consumo real de energía, posiblemente debido a una reacción excesiva al aumento repentino del consumo real en el Mes 27.

**Mes 29 a Mes 30:**

**Divergencia significativa:** Se observa una diferencia sustancial entre el consumo real y el predicho de energía.

**Posibles factores:** La caída en el consumo real de energía podría deberse a factores externos no capturados por el modelo, como cambios en los patrones de uso de energía, implementaciones de medidas de eficiencia energética o eventos climáticos que afectaron la demanda de energía.

Mes 31 a Mes 32:

Recuperación real vs. pico de predicción: El consumo real de energía experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del consumo de energía.

Mes 33 a Mes 34:

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el consumo real de energía aumenta.

Interpretación: El modelo no está capturando correctamente la dirección del cambio real del consumo de energía.

Mes 35 a Mes 36:

Estabilidad real vs. tendencia a la baja en la predicción: El consumo real de energía se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja.

Interpretación: El modelo está subestimando el consumo real de energía en este período.

Mes 37:

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas.

Interpretación: El modelo aún no ha logrado capturar completamente la tendencia real del consumo de energía.

**Usuario: 32430**

Predicción Meses: Octubre 2021 – Septiembre 2022

Predicción de Consumo

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:

Predicción de consumo: X kWh

Predicciones guardadas en  
'predicciones\_consumo\_tree.csv'


Errores relativos por usuario guardados en

'errores\_relativos\_tree.csv'

Error relativo para el usuario 32430 y el mes mes-26:

Error relativo =  $|(83 - 82.0) / 83| * 100$

Error relativo = 1.20%



Mes 26 a Mes 27:

Subestimación inicial: El modelo subestima el valor real en este período.

Convergencia gradual: El modelo comienza a ajustar su predicción para reflejar mejor la tendencia real del valor promedio.

Mes 27 a Mes 28:

Sobreestimación: El modelo sobreestima el valor real, posiblemente debido a una reacción excesiva al aumento repentino del valor real en el Mes 27.

Mes 29 a Mes 30:

Divergencia significativa: Se observa una diferencia sustancial entre el valor real y el predicho.

Posibles factores: La caída en el valor real podría deberse a factores externos no capturados por el modelo, como cambios en los patrones de uso, implementaciones de medidas de eficiencia o eventos que afectaron la demanda.

Mes 31 a Mes 32:

Recuperación real vs. pico de predicción: El valor real experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del valor promedio.

Mes 33 a Mes 34:

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el valor real aumenta.

Interpretación: El modelo no está capturando correctamente la dirección del cambio real del valor promedio.

Mes 35 a Mes 36:

Estabilidad real vs. tendencia a la baja en la predicción: El valor real se mantiene relativamente estable con un ligero

aumento, mientras que la línea de predicción muestra una tendencia a la baja.

Interpretación: El modelo está subestimando el valor real en este período.

Mes 37:

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas.

Interpretación: El modelo aún no ha logrado capturar completamente la tendencia real del valor promedio.

**Usuario: 86443**

Predicción Meses: Octubre 2021 – Septiembre 2022

Predicción de Consumo

La predicción de consumo para el usuario Número de usuario en los meses 26 al 37:

Predicción de consumo: X kWh

Predicciones guardadas en 'predicciones\_consumo\_tree.csv'


Errores relativos por usuario guardados en

'errores\_relativos\_tree.csv'

Error relativo para el usuario 86443 y el mes mes-26:

Error relativo =  $|(280 - 257.0) / 280| * 100$

Error relativo = 8.21%



Mes 26 a Mes 27:

Subestimación inicial: El modelo subestima el valor real en este período.

Convergencia gradual: El modelo comienza a ajustar su predicción para reflejar mejor la tendencia real del valor promedio.

Mes 27 a Mes 28:

Sobreestimación: El modelo sobreestima el valor real, posiblemente debido a una reacción excesiva al aumento repentino del valor real en el Mes 27.

Mes 29 a Mes 30:

Divergencia significativa: Se observa una diferencia sustancial entre el valor real y el predicho.

Posibles factores: La caída en el valor real podría deberse a factores externos no capturados por el modelo, como cambios en los patrones de uso, implementaciones de medidas de eficiencia o eventos que afectaron la demanda.

Mes 31 a Mes 32:

Recuperación real vs. pico de predicción: El valor real experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del valor promedio.

Mes 33 a Mes 34:

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el valor real aumenta.

Interpretación: El modelo no está capturando correctamente la dirección del cambio real del valor promedio.

Mes 35 a Mes 36:

Estabilidad real vs. tendencia a la baja en la predicción: El valor real se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja.


Interpretación: El modelo está subestimando el valor real en este período.

Mes 37:

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas.

Interpretación: El modelo aún no ha logrado capturar completamente la tendencia real del valor promedio.

**Comparación de valores promedio reales y predichos de la muestra de los 382 usuarios en el modelo árbol de decisión**



El gráfico muestra la evolución del consumo de energía promedio real y el consumo de energía promedio predicho por un modelo durante un período de 12 meses (Mes 26 a Mes 37). Se observa una tendencia general de aumento en el consumo de energía promedio real, con algunas fluctuaciones a lo largo del período. El modelo predice una tendencia similar de aumento, pero con mayor suavidad y con algunos errores de subestimación y sobreestimación en ciertos puntos específicos.

**Análisis por mes:**

Mes 26 a Mes 27:

Subestimación inicial: El modelo subestima el consumo real de energía en este período.

Convergencia gradual: Sin embargo, ambas líneas comienzan a acercarse entre sí, sugiriendo que el modelo está ajustando su predicción para reflejar mejor la tendencia real del consumo de energía.

Mes 27 a Mes 28:

Sobreestimación: La línea de predicción supera la línea de consumo real, lo que indica que el modelo ahora está sobreestimando el consumo real de energía.

Posible ajuste: Es posible que el modelo haya reaccionado de manera excesiva al aumento repentino del consumo real de energía en el Mes 27, lo que llevó a la sobreestimación.

Mes 29 a Mes 30:

Divergencia significativa: La línea de consumo real experimenta una caída notable, mientras que la línea de predicción muestra una disminución más suave. Esto amplía la brecha entre las dos líneas, indicando una diferencia sustancial entre el consumo real y el predicho de energía.

Posibles factores: La caída en el consumo real de energía podría deberse a factores externos no capturados por el modelo, como cambios en los patrones de uso de energía, implementaciones de medidas de eficiencia energética o eventos climáticos que afectaron la demanda de energía.

Mes 31 a Mes 32:

Recuperación real vs. pico de predicción: El consumo real de energía experimenta un repunte, mientras que la línea de predicción alcanza un pico más pronunciado. Esta divergencia nuevamente resalta la diferencia entre las tendencias reales y predichas del consumo de energía.

Posible corrección del modelo: El pico en la predicción podría ser un intento del modelo de corregir la subestimación del Mes 29, pero aún no ha alcanzado el nivel real del consumo de energía.

Mes 33 a Mes 34:

Comportamientos opuestos: Las líneas muestran tendencias opuestas, con la predicción disminuyendo mientras que el consumo real de energía aumenta.

Interpretación: El modelo no está capturando correctamente la dirección del cambio real del consumo de energía.

Mes 35 a Mes 36:

Estabilidad real vs. tendencia a la baja en la predicción: El consumo real de energía se mantiene relativamente estable con un ligero aumento, mientras que la línea de predicción muestra una tendencia a la baja.

Interpretación: El modelo está subestimando el consumo real de energía en este período.

Mes 37:

Convergencia parcial: Ambas líneas vuelven a converger, pero aún existe una diferencia notable entre ellas.

Interpretación: El modelo aún no ha logrado capturar completamente la tendencia real del consumo de energía.

**Comparación de errores relativos por usuario**  
**Usuario 20421**

Usuario 20421	Error relativo lineal	Error relativo polinomial	Error relativo árbol
21-oct	18.18	18.18	18.18
21-nov	6.54	6.54	6.54
21-dic	8.08	8.08	8.08
22-ene	0.00	0.00	0.00
22-feb	3.24	3.24	3.24
22-mar	0.00	0.00	0.00
22-abr	0.00	0.00	0.00
22-may	0.00	0.00	0.00
22-jun	0.00	0.00	0.00
22-jul	0.00	0.00	0.00

22-ago	0.00	0.00	0.00
22-sep	0.00	0.00	0.00
<b>Error relativo promedio</b>	3.00	3.00	3.00

**Usuario 86443**

Usuario 86443	Error relativo lineal	Error relativo polinomial	Error relativo árbol
21-oct	3.93	3.93	8.21
21-nov	13.49	13.49	11.51
21-dic	5.17	5.17	5.78
22-ene	3.12	3.12	5.30
22-feb	1.95	1.95	5.54
22-mar	6.07	6.07	8.09
22-abr	18.95	18.95	30.03
22-may	19.79	19.79	20.05
22-jun	10.09	10.09	12.39
22-jul	12.80	12.81	10.06
22-ago	0.00	0.00	0.31
22-sep	5.78	5.78	3.18
<b>Error relativo promedio</b>	8.43	8.43	10.04


**Usuario 32430**

Usuario 32430	Error relativo lineal	Error relativo polinomial	Error relativo árbol
21-oct	1.20	1.20	1.20
21-nov	1.09	1.09	1.09
21-dic	0.00	0.00	0.00
22-ene	1.09	1.09	1.09
22-feb	0.00	0.00	0.00
22-mar	0.00	0.00	0.00
22-abr	1.08	1.08	1.08
22-may	0.00	0.00	0.00
22-jun	1.12	1.12	1.12
22-jul	2.35	2.35	2.35
22-ago	0.00	0.00	0.00
22-sep	0.00	0.00	0.00
<b>Error relativo promedio</b>	0.66	0.66	0.66

**Comparación de errores promedios relativos de los 382 usuarios**

**Tabla comparativa de errores relativos**

Meses	Regresión lineal	Regresión polinomial	Árbol de decisión
21-oct	4.50135	4.501354	4.525772
21-nov	4.50135	4.501354	4.525772
21-dic	4.50135	4.501354	4.525772
22-ene	4.50135	4.501354	4.525772
22-feb	4.50135	4.501354	4.525772
22-mar	4.50135	4.501354	4.525772
22-abr	4.50135	4.501354	4.525772
22-may	4.50135	4.501354	4.525772
22-jun	4.50135	4.501354	4.525772
22-jul	4.50135	4.501354	4.525772
22-ago	4.50135	4.501354	4.525772
22-sep	4.50135	4.501354	4.525772
<b>Error relativo promedio</b>	4.50	4.50	4.53



**Discusión de resultados**

**Antecedentes de la Investigación**

La investigación se centró en la creación de un modelo matemático para predecir el consumo de energía eléctrica.

Para ello, se utilizó una base de datos que incluye registros mensuales del consumo de energía en kWh de una muestra de 360 usuarios, abarcando el período desde septiembre de 2019 hasta septiembre de 2022. No obstante, para el análisis y la predicción, los datos se limitaron hasta septiembre de 2021. Se implementaron tres modelos de regresión distintos usando Python: regresión lineal, regresión polinomial y árboles de decisión, para predecir el consumo de energía eléctrica para el período de octubre de 2021 a septiembre de 2022.

**Modelos Utilizados**

**Regresión Lineal:**

Un modelo sencillo que asume una relación lineal entre las variables independientes y dependientes.

### Regresión Polinomial:

Extiende la regresión lineal al considerar términos polinomiales, permitiendo capturar relaciones no lineales.

### Árboles de Decisión:

Un modelo más complejo que segmenta el espacio de datos en subespacios para hacer predicciones más ajustadas y específicas.

### Metodología

Se seleccionaron tres usuarios al azar (20421, 86443, 32430) y se realizó un análisis promedio de los errores relativos para los tres modelos. La predicción de consumo para los meses de octubre de 2021 a septiembre de 2022 se comparó con los valores reales medidos. Además, se calculó el error relativo para cada modelo y cada mes, y se obtuvo un promedio de los errores relativos para toda la muestra de 382 usuarios.

### Resultados

#### Comparación de Errores Relativos

En la tabla comparativa de los errores relativos obtenidos para cada modelo durante el período de análisis de muestra descrito en lo siguiente:

#### Análisis de Resultados

##### Regresión Lineal y Polinomial:

Ambos modelos muestran un error relativo promedio idéntico de 4.50. Esto indica que, en promedio, ambos modelos tienen un rendimiento similar en términos de precisión de predicción.

La consistencia en los errores mensuales también sugiere que ambos modelos son estables y fiables para las predicciones de consumo de energía.

##### Árbol de Decisión:

El modelo de árboles de decisión presenta un error relativo promedio ligeramente superior (4.53) comparado con los otros dos modelos. Aunque la diferencia es pequeña, puede indicar que este modelo podría ser menos preciso en ciertos casos o más susceptible a la variabilidad de los datos.

Sin embargo, los árboles de decisión ofrecen la ventaja de interpretar y entender mejor las decisiones en cada nodo, lo cual puede ser útil en contextos donde la explicabilidad del modelo es crucial.

### CONCLUSIONES

**Precisión de los Modelos:** Los modelos de regresión lineal y polinómica demostraron ser herramientas robustas y consistentes para predecir el consumo de energía eléctrica en el período analizado, proporcionando resultados precisos en la estimación de las tendencias de consumo, especialmente en periodos de confinamiento. Sin embargo,

el modelo de árboles de decisión, aunque presentó un error relativo promedio ligeramente mayor, sigue siendo una opción válida para escenarios en los que se requiere una mayor interpretabilidad de los resultados, permitiendo a los gestores de la red eléctrica identificar de manera más clara qué factores influyen en el consumo.

### Implicaciones Prácticas para la Gestión del Consumo Eléctrico en Futuros Confinamientos:

Los resultados obtenidos en este estudio tienen importantes implicaciones para la gestión del consumo eléctrico durante posibles confinamientos futuros. La capacidad de predecir con precisión los patrones de consumo bajo condiciones excepcionales, como los confinamientos, permite a las empresas eléctricas anticiparse a las variaciones de demanda y ajustar sus estrategias de distribución. Por ejemplo, en escenarios de confinamiento prolongado, se podría prever un aumento significativo del consumo residencial, lo que implicaría la necesidad de reforzar la infraestructura de distribución en zonas residenciales, o implementar programas de eficiencia energética para mitigar el impacto en la red.

Además, los modelos podrían ser utilizados para desarrollar políticas tarifarias más flexibles que incentiven un uso eficiente de la energía durante situaciones de emergencia. Esto sería particularmente relevante en el diseño de tarifas dinámicas que desincentiven el consumo excesivo durante los picos de demanda, asegurando así la sostenibilidad del suministro eléctrico.

**Limitaciones del Estudio:** Es importante señalar algunas limitaciones de este estudio. En primer lugar, aunque los modelos desarrollados demostraron ser efectivos en la predicción del consumo eléctrico durante el período de análisis, estos se basan en datos históricos que podrían no capturar completamente las dinámicas de consumo en futuros confinamientos, especialmente si las condiciones socioeconómicas o el comportamiento de los usuarios cambia significativamente.

Otra limitación es el tamaño de la muestra seleccionada. Si bien se utilizaron 382 usuarios residenciales representativos, un análisis con una muestra más amplia o diversa podría mejorar la generalización de los resultados.

Además, el estudio no considera variables externas como el clima, las políticas de gobierno o los hábitos de consumo específicos durante diferentes fases del confinamiento, las cuales podrían tener un impacto significativo en los patrones de consumo eléctrico.

Finalmente, los modelos utilizados, si bien son efectivos para series temporales, presentan ciertas restricciones para capturar dinámicas no lineales complejas o impactos



inesperados, lo que sugiere la necesidad de explorar modelos más avanzados, como los de aprendizaje profundo, para futuros estudios.

### Recomendaciones

A partir de los resultados obtenidos, se identifican varias líneas de investigación que podrían abordarse en futuros trabajos para mejorar la precisión y aplicabilidad de los modelos de predicción del consumo eléctrico:

1. **Mejora de la Precisión de los Modelos:** Se recomienda implementar técnicas más avanzadas de ajuste y validación cruzada, especialmente en el modelo de árboles de decisión. Estas técnicas podrían ayudar a reducir el margen de error y mejorar la generalización del modelo en diferentes escenarios de consumo.
2. **Exploración de Modelos Avanzados o Híbridos:** Aunque los modelos lineales y polinómicos mostraron buenos resultados, futuros trabajos deberían considerar la exploración de modelos más avanzados, como redes neuronales profundas o enfoques híbridos que combinen diferentes métodos. Estos modelos podrían capturar de manera más efectiva las características no lineales y complejas presentes en los datos de consumo, especialmente bajo condiciones de confinamiento o crisis similares.
3. **Incorporación de Factores Externos:** También sería útil en futuros estudios integrar variables adicionales, como el clima, las políticas gubernamentales y cambios en los hábitos de consumo, para mejorar la capacidad predictiva de los modelos y ofrecer una representación más precisa del comportamiento energético en situaciones anómalas.
4. **Ampliación del Tamaño de la Muestra:** El análisis actual se basó en una muestra representativa de 382 usuarios. Futuras investigaciones podrían beneficiarse de expandir esta muestra o incluir usuarios de diferentes cantones o áreas rurales, lo que permitiría evaluar si las tendencias observadas son consistentes en una escala más amplia.
5. Este enfoque permitirá no solo mejorar la precisión de los modelos actuales, sino también abrir nuevas oportunidades para optimizar la gestión del consumo eléctrico bajo condiciones extremas como los confinamientos.

### REFERENCIAS BIBLIOGRÁFICAS

Abdeen, A., Kharvari, F., O'Brien, W., & Gunay, B. (2021). The impact of the COVID-19 on households' hourly electricity consumption in Canada. *Energy and Buildings*, 250,

111280.

<https://doi.org/10.1016/J.ENBUILD.2021.111280>

Alasali, F., Nusair, K., Alhmoud, L., & Zarour, E. (2021). Impact of the COVID-19 Pandemic on Electricity Demand and Load Forecasting. *Sustainability* 2021, Vol. 13, Page 1435, 13(3), 1435. <https://doi.org/10.3390/SU13031435>

Carvalho, M., Bandeira de Mello Delgado, D., de Lima, K. M., de Camargo Cancela, M., dos Siqueira, C. A., & de Souza, D. L. B. (2021). Effects of the COVID-19 pandemic on the Brazilian electricity consumption patterns. *International Journal of Energy Research*, 45(2), 3358–3364. <https://doi.org/10.1002/ER.5877>

CENACE. (2020). *Informe Anual 2020 – Operador Nacional de Electricidad*. <https://www.cenace.gob.ec/informe-anual-2020/>

Chaianong, A., Winzer, C., & Gellrich, M. (2022). Impacts of traffic data on short-term residential load forecasting before and during the COVID-19 pandemic. *Energy Strategy Reviews*, 43, 100895. <https://doi.org/10.1016/J.ESR.2022.100895>

Cheshmehzangi, A. (2020). COVID-19 and household energy implications: what are the main impacts on energy use? *Heliyon*, 6(10), e05202. <https://doi.org/10.1016/J.HELIYON.2020.E05202>

CNEL EP. (2022). *Rendición de Cuentas 2020*. <https://www.cnelep.gob.ec/ley-de-transparencias://www.cnelep.gob.ec/wp-content/uploads/2021/06/Conformaci>

ELEPCO SA. (2020). *Rendición de Cuentas 2020 — ELEPCOSA*. <https://elepcosa.com.ec/rendicion-de-cuentas/rendicion-de-cuentas-2020/>

Gu, C., Yan, X., Yan, Z., & Li, F. (2017). Dynamic pricing for responsive demand to increase distribution network efficiency. *Applied Energy*, 205, 236–243. <https://doi.org/10.1016/J.APENERGY.2017.07.102>

Jiang, P., Fan, Y., Van, & Klemeš, J. J. (2021). Impacts of COVID-19 on energy demand and consumption: Challenges, lessons and emerging opportunities. *Applied Energy*, 285, 116441. <https://doi.org/10.1016/J.APENERGY.2021.116441>

- Kuzemko, C., Bradshaw, M., Bridge, G., Goldthau, A., Jewell, J., Overland, I., Scholten, D., Van de Graaf, T., & Westphal, K. (2020). Covid-19 and the politics of sustainable energy transitions. *Energy Research & Social Science*, 68, 101685. <https://doi.org/10.1016/J.ERSS.2020.101685>
- MERNNR. (2020). *Protocolo para la prevención de posibles contagios covid-19 en el MERNNR durante el cumplimiento de la jornada laboral emergente*. <https://play.google.com/store/apps/details?id=com.phuyusalud.movil>,
- Muñoz, J. (2022, September 25). *Análisis del Impacto de la Pandemia en el Sector Eléctrico del Ecuador*. <https://es.slideshare.net/jorgemunozv/analisis-del-impacto-de-la-pandemia-en-el-sector-electricodoc>