

Predicción energética para decisiones sostenibles y justicia social

Energy Forecasting for Sustainable Decision-Making and Social Justice

Alejandro Macías Espinoza¹

Alberto Coronado Mendoza¹

ORCID: 0009-0000-2989-7577,
Macías Espinoza, A.

ORCID: 0000-0002-6283-4911,
Coronado Mendoza, A.

1. Centro Universitario de Tona-
lá. Universidad de Guadalajara.

Macías Espinoza, A. y Corona-
do Mendoza, A. (2026). Predic-
ción energética para decisiones
sostenibles y justicia social.
Concordia, 2 (4), 60-83.

Recibido: 11/05/2026

Aprobado: 11/08/2026

Resumen: La predicción de variables energéticas puede apoyar decisiones más eficientes, sostenibles y socialmente responsables. Este artículo presenta, con un enfoque divulgativo, técnicas de predicción aplicadas a la demanda eléctrica, la temperatura ambiente y los costos de la energía. Mediante un ejercicio con datos históricos y un modelo ETS de suavizamiento exponencial, se comparan valores estimados con datos reales para conocer la precisión y las limitaciones del modelo. Los resultados muestran un error porcentual absoluto medio de 8.99 % en la demanda eléctrica y de 3.72 % en el precio medio de la energía, mientras que para la temperatura se obtuvo un error absoluto medio de 0.43 °C. Estas diferencias muestran que la precisión depende del comportamiento de cada variable y de la calidad de los datos. Finalmente, se analiza cómo estas herramientas pueden apoyar la planificación energética, la sostenibilidad y una distribución más equitativa de los recursos.

Palabras clave: modelado predictivo, suavizamiento exponencial, justicia energética, análisis de datos, planificación energética.

Abstract: Energy forecasting can support more efficient, sustainable, and socially responsible decision-making. This article presents, from a science communication perspective, several forecasting techniques applied to electricity demand, ambient temperature, and energy costs. Through a practical exercise using historical data and an ETS exponential smoothing model, estimated values are compared with actual data to assess the model's accuracy and limitations. The results show a mean absolute percentage error of 8.99% for electricity demand and 3.72% for the average energy price, while temperature yielded a mean absolute error of 0.43 °C. These differences show that forecasting accuracy depends on the behavior of each variable and the quality of the available data. Finally, the article examines how these tools can support energy planning, sustainability, and a more equitable distribution of resources.

Keywords: predictive modeling, exponential smoothing, energy justice, data analysis, energy planning.

Introducción

Los sistemas energéticos se enfrentan a condiciones cada vez más variables debido a los cambios en la demanda de electricidad, las fluctuaciones en los costos y la influencia de factores ambientales. Ante este escenario, resulta necesario contar con herramientas que permitan comprender mejor su comportamiento y anticipar posibles cambios. La predicción de variables energéticas puede contribuir a esta tarea al ofrecer estimaciones que apoyen la operación, la planificación y el uso eficiente de los recursos (Deb et al., 2017; Sesay et al., 2026).

Actualmente existen diversas técnicas para realizar este tipo de pronósticos, desde modelos estadísticos tradicionales, como ARIMA y los métodos de suavizamiento exponencial, hasta enfoques basados en inteligencia artificial, como las redes neuronales y otros modelos de aprendizaje automático. Estos métodos permiten identificar patrones en los datos históricos y generar estimaciones sobre el comportamiento futuro de distintas variables. Sin embargo, ningún método es adecuado para todas las situaciones, ya que su desempeño depende del tipo de información disponible, de las características de la variable analizada y del objetivo del estudio (Ahmad et al., 2020; Ullah et al., 2024).

Entre las variables de interés se encuentran la demanda de energía eléctrica, la temperatura ambiente y los costos de la energía. Aunque cada una presenta un comportamiento distinto, pueden estar relacionadas y verse afectadas por factores climáticos, económicos y operativos. Por ejemplo, los cambios en la temperatura pueden modificar las necesidades de refrigeración o calefacción y, con ello, influir en el consumo eléctrico. De manera similar, las variaciones en la demanda y en las tarifas pueden modificar los costos asociados al suministro. Analizar estos elementos en conjunto permite obtener una visión más amplia de las condiciones que influyen en la planificación energética (Ahmad et al., 2020; Deb et al., 2017).

Anticipar estos comportamientos no tiene únicamente una utilidad técnica. Las decisiones relacionadas con el suministro, los costos y la distribución de los recursos pueden tener efectos diferentes entre los distintos sectores de la población. Desde la perspectiva de la justicia energética, resulta importante considerar aspectos como el acceso a los servicios energéticos, su asequibilidad y las condiciones de vulnerabilidad que pueden enfrentar determinados grupos sociales (Sovacool et al., 2016). En México, investigaciones recientes han analizado la relación entre pobreza energética, tarifas eléctricas y capacidad de los hogares para cubrir sus necesidades de energía (Marmolejo Cervantes & Reilly Solís, 2024; Suástegui Macías et al., 2023). Por ello, disponer de mejores estimaciones no garantiza por sí mismo una

distribución más justa de los recursos; sin embargo, puede aportar información útil para orientar decisiones que consideren tanto la eficiencia como sus posibles efectos económicos, ambientales y sociales.

Este artículo presenta una reflexión y análisis sobre algunas técnicas utilizadas para predecir variables energéticas, con especial atención a la demanda eléctrica, la temperatura ambiente y los costos de la energía. Mediante una revisión general y un ejercicio práctico con datos históricos y un modelo de suavizamiento exponencial, se comparan valores estimados con datos reales para mostrar, de manera sencilla, la utilidad y las limitaciones de este tipo de modelos. Más que profundizar en aspectos matemáticos complejos, se busca explicar su aplicación en un caso real y reflexionar sobre la manera en que la información obtenida puede apoyar la planificación energética, la sostenibilidad y decisiones socialmente responsables.

Desarrollo

1.1 Sistemas de predicción en el contexto energético

Un sistema de predicción utiliza información histórica para estimar el comportamiento futuro de una variable. En el sector energético, estos sistemas pueden aplicarse al consumo de electricidad, los precios, la generación de energía o las condiciones ambientales que influyen en la operación. Su propósito no es conocer con exactitud lo que ocurrirá, sino identificar patrones y generar estimaciones que permitan anticiparse a posibles cambios.

A diferencia del análisis descriptivo, que ayuda a comprender lo que ya ocurrió, la predicción utiliza los datos disponibles para estimar lo que podría suceder posteriormente. Para ello se requiere información histórica, un modelo adecuado y una etapa de evaluación que permita comparar las estimaciones con los valores observados. Este proceso es especialmente útil en series de tiempo, donde los datos se registran de forma ordenada a lo largo de días, meses o años (Hyndman & Athanasopoulos, 2021).

De manera general, un sistema de predicción energética puede entenderse como un proceso que transforma datos históricos en estimaciones que posteriormente deben evaluarse antes de utilizarse como apoyo para la toma de decisiones (Figura 1).




Figura 1. Proceso general de un sistema de predicción energética, desde la recopilación de datos hasta su uso como apoyo para la toma de decisiones. Elaboración propia.

En los sistemas energéticos, la utilidad de estas técnicas ha aumentado debido a la necesidad de trabajar con variables que cambian continuamente y que pueden estar relacionadas entre sí. La incorporación de información sobre consumo, condiciones meteorológicas y otros factores permite construir modelos capaces de reconocer comportamientos que no siempre son evidentes a simple vista. Los enfoques actuales incluyen desde métodos estadísticos relativamente sencillos hasta modelos de aprendizaje automático capaces de analizar relaciones más complejas entre diferentes variables (Kong et al., 2019; Sesay et al., 2026).

Sin embargo, una predicción debe interpretarse como una estimación y no como una certeza. Su precisión depende de la calidad y cantidad de los datos, del método seleccionado y de la estabilidad del comportamiento que se intenta anticipar. Por esta razón, además de generar un pronóstico, es importante evaluar qué tan bien representa la realidad y reconocer los factores que el modelo no considera. Esta información es la que finalmente puede servir como apoyo para la planificación y para la toma de decisiones en distintos contextos energéticos.

1.2 Importancia para la toma de decisiones y su dimensión social

La capacidad de anticipar el comportamiento de las variables energéticas puede reducir la incertidumbre y proporcionar información útil para diferentes tipos de decisiones. En el ámbito operativo, los pronósticos permiten estimar las necesidades de consumo y ajustar con mayor anticipación la generación o el suministro de energía. Desde una perspectiva de mediano y largo plazo, también pueden apoyar la planificación de infraestructura, el análisis de costos y la gestión de los recursos. Sin embargo, estas estimaciones no eliminan la incertidumbre, por lo que deben interpretarse como información de apoyo y no como resultados exactos sobre lo que ocurrirá en el futuro.

Las decisiones relacionadas con la energía también tienen una dimensión social, ya que sus efectos no son necesariamente iguales para toda la población. El acceso al suministro, su continuidad y el costo que representa para los usuarios pueden afectar de manera distinta a los hogares y comunidades, especialmente cuando existen condiciones de vulnerabilidad. Desde esta perspectiva, la justicia energética plantea la importancia de considerar cómo se distribuyen los beneficios, los costos y las oportunidades relacionadas con los servicios energéticos (Sovacool et al., 2016).

En México, esta relación adquiere especial relevancia. Estudios recientes han analizado la pobreza energética y la justicia social relacionadas con el acceso y los costos de la electricidad (Marmolejo Cervantes & Reilly Solís, 2024). Asimismo, se ha estudiado cómo la estructura de las tarifas eléctricas residenciales puede relacionarse con situaciones de pobreza energética y con la capacidad económica de los hogares para cubrir sus necesidades de energía (Suástegui Macías et al., 2023). Estos antecedentes muestran que una decisión energética basada únicamente en criterios técnicos o económicos puede ser insuficiente si no se consideran también las condiciones de las personas que reciben y utilizan el servicio.

Las tres variables analizadas en este artículo permiten observar esta relación desde diferentes perspectivas. Anticipar la demanda eléctrica puede contribuir a planificar mejor la disponibilidad de energía; conocer el comportamiento de la temperatura ayuda a identificar periodos en los que pueden aumentar las necesidades de refrigeración o calefacción; y estimar la evolución de los costos puede aportar información sobre posibles cambios en el gasto asociado al consumo. En conjunto, estos datos pueden orientar decisiones más informadas, aunque para que estas sean también equitativas es necesario considerar factores sociales, económicos y ambientales que un modelo de predicción por sí solo no puede representar.

La relación entre la información generada por los modelos predictivos, las decisiones energéticas y su dimensión social se resume en la Figura 2.



Figura 2. Relación entre la predicción de variables energéticas, la toma de decisiones y su dimensión social. Elaboración propia.

Por ello, el valor de la predicción energética no se encuentra únicamente en obtener estimaciones con un menor margen de error, sino también en la forma en que esa información puede utilizarse para planificar y gestionar los recursos. Una predicción más precisa no garantiza por sí misma la justicia energética, pero puede ofrecer elementos que ayuden a reconocer necesidades, anticipar riesgos y valorar con mayor claridad las posibles consecuencias de una decisión.

1.3 Variables clave: demanda eléctrica, temperatura y costos

Para realizar una predicción es necesario definir con claridad qué variable se desea analizar y cuáles son los factores que pueden influir en su comportamiento. En los sistemas energéticos intervienen numerosos elementos; sin embargo, en este artículo se consideran tres variables por su relación con la operación y la planificación: la demanda de energía eléctrica, la temperatura ambiente y los costos de la energía. Cada una presenta características diferentes y, por lo tanto, también distintos niveles de variabilidad y dificultad para ser pronosticada.

La demanda de energía eléctrica representa la cantidad de energía consumida durante un periodo determinado. Su comportamiento puede cambiar de acuerdo con los horarios de uso, la actividad productiva, las condiciones climáticas, los hábitos de consumo y otros factores externos. Contar con una estimación de la demanda futura puede ayudar a anticipar necesidades de suministro y a planificar con mayor precisión la operación del sistema eléctrico (Hong & Fan, 2016).

La temperatura ambiente es otra variable relevante porque puede modificar las necesidades de consumo de electricidad. En periodos de temperaturas elevadas puede aumentar el uso de sistemas de refrigeración, mientras que en zonas o temporadas frías puede incrementarse la demanda asociada a la calefacción. Esta relación no es igual en todos los lugares, ya que depende del clima, de las características de los edificios, de los equipos disponibles y de los hábitos de los usuarios. Debido a que la temperatura suele presentar patrones estacionales, su análisis también puede aportar información útil para comprender parte de las variaciones observadas en la demanda energética (Deb et al., 2017).

Los costos de la energía representan una tercera variable de interés. Estos pueden cambiar como resultado de las tarifas aplicables, el nivel y horario del consumo, las condiciones del mercado y otros componentes relacionados con el suministro eléctrico. Anticipar su comportamiento puede apoyar la elaboración de presupuestos, la evaluación de gastos futuros y la planificación de medidas orientadas a un uso más eficiente de la energía. En este artículo, el análisis se realiza a partir del precio medio mensual obtenido de la facturación eléctrica de la empresa estudiada, aspecto que se explicará con mayor detalle en el ejercicio práctico.

Aunque estas variables se analizan de manera individual, pueden existir relaciones entre ellas. Por ejemplo, un cambio en la temperatura puede modificar el consumo eléctrico y, dependiendo de las condiciones tarifarias, producir también cambios en el gasto asociado. Sin embargo, estas relaciones no deben asumirse como iguales en todos los casos, ya que pueden intervenir factores operativos, económicos y de comportamiento que no necesariamente están incluidos en un modelo de predicción.

La elección de estas tres variables responde tanto a su relevancia para la gestión energética como a la disponibilidad de información histórica para realizar el ejercicio presentado en este artículo. Esto no significa que sean las únicas variables importantes. Otros factores, como la irradiación solar, la velocidad del viento, la actividad económica, los cambios en los procesos productivos, los hábitos de consumo o las modificaciones regulatorias, también pueden influir en el comportamiento de un sistema energético. La selección de variables dependerá siempre del problema que se desea analizar, de los datos disponibles y del propósito de la predicción.

1.4 Métodos de predicción: un enfoque práctico

Existen diferentes métodos para realizar pronósticos y su elección depende del tipo de variable, de la cantidad y calidad de los datos disponibles y del objetivo del análisis.

Para facilitar su comprensión, en este artículo se presentan dos grupos principales: los métodos estadísticos tradicionales y los métodos basados en aprendizaje automático. Esta clasificación permite comparar sus características generales, aunque en aplicaciones recientes también pueden encontrarse modelos híbridos que combinan distintas técnicas (Hyndman & Athanasopoulos, 2021).

Los métodos estadísticos trabajan principalmente con patrones presentes en los datos históricos. Entre los más conocidos se encuentran ARIMA y los métodos de suavizamiento exponencial. Ambos son utilizados para el análisis de series de tiempo, pero siguen principios diferentes: los modelos ARIMA representan relaciones de dependencia entre observaciones a lo largo del tiempo, mientras que el suavizamiento exponencial asigna mayor importancia a los datos recientes y puede incorporar componentes como nivel, tendencia y estacionalidad (Hyndman & Athanasopoulos, 2021). Estos métodos suelen ser útiles cuando se busca una solución relativamente sencilla de interpretar y cuando el comportamiento de la serie puede describirse mediante patrones temporales identificables.

Por otro lado, los métodos de aprendizaje automático buscan aprender relaciones directamente a partir de los datos. Dentro de este grupo se encuentran algoritmos basados en árboles, como Random Forest y Gradient Boosting, así como redes neuronales diseñadas para trabajar con información secuencial, como las redes LSTM. La técnica de Random Forest combina múltiples árboles de decisión para generar una predicción conjunta, mientras que Gradient Boosting construye modelos de manera progresiva para reducir los errores de predicción (Breiman, 2001; Friedman, 2001). En el ámbito energético, las redes LSTM se han utilizado para pronosticar demanda eléctrica debido a su capacidad para trabajar con dependencias temporales en series de consumo (Kong et al., 2019).

En años recientes también se han desarrollado modelos que combinan diferentes técnicas de aprendizaje profundo. Por ejemplo, Sesay et al. (2026) propusieron un modelo híbrido Transformer–BiLSTM para la predicción multivariable de demanda energética residencial incorporando información meteorológica. Este tipo de trabajos muestra cómo los enfoques actuales pueden integrar varias variables y estructuras de aprendizaje para analizar comportamientos más complejos.

Las principales diferencias entre ambos enfoques se presentan de manera resumida en la Figura 3.

Comparación general de métodos de predicción		
Aspecto	Métodos estadísticos 	Aprendizaje automático 
 Ejemplos	ARIMA, suavizamiento exponencial	Random Forest, Gradient Boosting, LSTM
 Base del análisis	Patrones temporales y relaciones estadísticas	Relaciones aprendidas a partir de los datos
 Cantidad de datos	Pueden funcionar con conjuntos relativamente pequeños	Generalmente se benefician de una mayor cantidad de datos
 Interpretación	Suele ser más directa	Puede ser más compleja
 Recursos computacionales	Generalmente menores	Pueden ser mayores
 Aplicación	Series de tiempo con patrones identificables	Problemas con múltiples variables y relaciones complejas

 **La elección del método depende de los datos disponibles, del objetivo del análisis y del nivel de complejidad requerido.**

Figura 3. Comparación general entre métodos estadísticos y métodos basados en aprendizaje automático utilizados en predicción. Elaboración propia con base en (Breiman, 2001; Friedman, 2001; Hyndman & Athanasopoulos, 2021; Kong et al., 2019; Sesay et al., 2026).

Sin embargo, un modelo más complejo no necesariamente es la mejor opción para todos los problemas. La elección debe considerar el propósito del análisis, el volumen y calidad de los datos, los recursos disponibles y la facilidad con la que puedan interpretarse los resultados. En un artículo de carácter divulgativo y en un ejercicio con una cantidad limitada de información histórica, puede ser preferible utilizar un método sencillo que permita comprender con claridad el proceso de predicción antes que emplear un modelo más sofisticado cuya interpretación resulte menos accesible.

Por esta razón, para el ejercicio práctico presentado en este artículo se utiliza un modelo de suavizamiento exponencial. Su elección permite mostrar de manera sencilla cómo los datos históricos pueden utilizarse para generar estimaciones y posteriormente compararlas con valores reales. El propósito no es demostrar que este método sea superior a otras técnicas, sino utilizarlo como una herramienta accesible para explicar el proceso de predicción y analizar sus resultados y limitaciones.

1.5 Modelo ETS de suavizamiento exponencial

El suavizamiento exponencial es un método utilizado para realizar pronósticos a partir de datos ordenados en el tiempo. Su principio consiste en utilizar la información histórica dando mayor importancia a los valores recientes, sin dejar de considerar el comportamiento observado en periodos anteriores. De esta manera, las

estimaciones pueden actualizarse conforme se incorporan nuevos datos (Hyndman & Athanasopoulos, 2021).

En su forma más sencilla, el suavizamiento exponencial puede expresarse mediante la siguiente ecuación:

$$\hat{Y}_{t+1} = \alpha Y_t + (1 - \alpha)\hat{Y}_t \quad (1)$$

Donde:

- $\hat{Y}_{t+1}$: es el pronóstico para el siguiente período.
- Y_t : es el valor real observado en el período actual.
- $\hat{Y}_t$: es el valor estimado para el periodo actual.
- α : es el parámetro de suavizamiento, cuyo valor se encuentra entre 0 y 1.

En términos sencillos, el parámetro α determina cuánto peso se da a la información más reciente. Un valor cercano a 1 hace que el modelo responda con mayor rapidez a los cambios recientes, mientras que un valor cercano a 0 produce estimaciones que cambian de forma más gradual. Sin embargo, cuando una serie presenta además de tendencia o estacionalidad, pueden utilizarse modelos de suavizamiento exponencial con componentes adicionales para representar mejor ese comportamiento (Hyndman & Athanasopoulos, 2021).

Para el ejercicio desarrollado en este artículo se utilizó la herramienta de pronóstico de Microsoft Excel basada en el modelo ETS (Exponential Smoothing) (Microsoft, s.f.). Este procedimiento se aplicó por separado a las tres variables analizadas: demanda eléctrica, temperatura ambiente y precio medio de la energía. La herramienta permite reconocer patrones presentes en la serie histórica, incluida la posible estacionalidad, y generar estimaciones para periodos posteriores.

En cada caso se utilizaron 36 observaciones mensuales, correspondientes de enero de 2022 a diciembre de 2024, para construir el pronóstico. Posteriormente, se estimaron los valores de 2025 y se compararon con los datos reales disponibles para ese mismo año. Esta comparación permitió evaluar qué tan cercanas fueron las estimaciones a los valores reales. Una vez realizada la validación, el modelo se utilizó para obtener el pronóstico correspondiente a 2026.

Los parámetros internos del modelo fueron calculados automáticamente por Excel a

partir de las características de cada serie. Por ello, en este ejercicio no se seleccionaron manualmente valores específicos para los componentes de nivel, tendencia o estacionalidad. Esto permite mantener el procedimiento accesible para lectores que no están familiarizados con modelos matemáticos avanzados, sin perder de vista que los resultados dependen de las características y de la calidad de los datos utilizados.

La elección de este método responde principalmente al propósito divulgativo del artículo. No se busca demostrar que ETS sea superior a otras técnicas, sino utilizar una herramienta accesible para mostrar cómo los datos históricos pueden convertirse en estimaciones, cómo estas pueden compararse con información real y qué limitaciones deben considerarse antes de utilizar un pronóstico como apoyo para la toma de decisiones.

1.6 Aplicación práctica y validación del modelo

Para mostrar de manera sencilla cómo puede aplicarse una técnica de predicción en un contexto real, se desarrolló un ejercicio utilizando datos históricos mensuales de demanda eléctrica, temperatura ambiente y precio medio de la energía. El mismo procedimiento de pronóstico se aplicó de manera independiente a cada variable, lo que permitió comparar posteriormente su comportamiento y el nivel de precisión obtenido.

En los tres casos se utilizaron 36 datos mensuales correspondientes al periodo de enero de 2022 a diciembre de 2024 para construir el modelo. A partir de esta información se generaron las estimaciones para los doce meses de 2025. Debido a que también se contaba con los valores reales de ese año, fue posible comparar ambos conjuntos de datos y evaluar qué tan cercanas fueron las predicciones. Una vez realizada esta validación, se generó el pronóstico correspondiente a 2026. De manera resumida, el procedimiento se organizó en seis etapas, como se muestra en la Figura 4.

Este procedimiento permite evaluar el modelo con información que no se utilizó para generar inicialmente el pronóstico. La comparación entre los valores estimados y los observados proporciona una medida sencilla de su desempeño antes de utilizarlo para proyectar periodos posteriores.

Para la demanda eléctrica y el precio medio de la energía se utilizó el error porcentual absoluto medio (MAPE), una medida que expresa, en promedio, qué tan alejadas se encuentran las estimaciones de los valores reales en términos porcentuales (Hyndman & Athanasopoulos, 2021). Se calcula mediante:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \quad (2)$$

Donde:

- Y_t : es el valor real observado.
- $\hat{Y}_t$: es el valor pronosticado.
- n : es el número de observaciones utilizadas para la validación.

En términos sencillos, mientras menor sea el valor del MAPE, menor es la diferencia porcentual promedio entre los datos reales y los estimados. Sin embargo, esta medida no resulta adecuada para variables expresadas en escalas cuyo cero es arbitrario, como los grados Celsius. Hyndman y Athanasopoulos (2021) señalan específicamente que los errores porcentuales no tienen una interpretación apropiada para temperaturas en Celsius o Fahrenheit.

Por esta razón, para evaluar la predicción de la temperatura ambiente se empleó el error absoluto medio (MAE), que indica directamente la diferencia promedio entre las temperaturas reales y las estimadas, expresada en grados Celsius. Esta medida es sencilla de interpretar cuando se evalúan pronósticos de una misma variable y con las mismas unidades

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (3)$$

La aplicación de estas métricas permite evaluar cada variable de acuerdo con sus características. Para la demanda y los costos se mantiene una medida porcentual, mientras que para la temperatura se expresa directamente la diferencia promedio en grados Celsius.




Figura 4. Esquema general del procedimiento utilizado para generar y validar las predicciones.
Elaboración propia.

a) Demanda de energía eléctrica

Para analizar la demanda se utilizaron registros mensuales de consumo eléctrico de una empresa real con tarifa Gran Demanda en Media Tensión Horaria (GDMTH). El consumo total mensual, expresado en kilowatt-hora (kWh), se obtuvo mediante la suma de la energía registrada en los periodos base, intermedio y punta. Para construir el modelo se utilizaron los datos correspondientes a enero de 2022 a diciembre de 2024, mientras que los valores reales de 2025 se reservaron para evaluar el desempeño del pronóstico.

Año	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
2022	18,960	18,720	20,640	22,440	29,160	28,200	30,000	28,800	27,720	27,360	24,480	21,600
2023	22,800	19,320	23,160	26,160	27,600	28,680	31,320	29,400	27,720	27,960	27,840	24,240
2024	18,404	17,282	19,567	19,902	23,749	21,315	22,617	22,153	21,080	22,057	24,118	18,541
2025	16,589	15,910	18,127	18,395	21,335	22,153	22,451	22,272	20,458	21,729	21,991	20,471

Tabla 1. Consumo mensual de energía eléctrica, 2022-2025

Nota: Valores expresados en kWh. Los datos de 2022–2024 se utilizaron para construir el modelo y los correspondientes a 2025 para su validación. Elaboración propia a partir de los registros de consumo de la empresa analizada.

La serie histórica muestra variaciones a lo largo del año y diferencias entre periodos. Por ejemplo, durante 2022 y 2023 se observaron consumos mensuales superiores a 30,000 kWh en algunos meses, mientras que durante 2024 los valores fueron, en general, menores. Estas diferencias muestran que el consumo eléctrico de la empresa

no permanece constante y puede verse afectado por cambios en su operación, nivel de actividad y otros factores que no necesariamente están incluidos en el modelo.

A partir de los 36 datos utilizados para construir el modelo ETS, se generaron las estimaciones correspondientes a los doce meses de 2025. Posteriormente, estos valores se compararon con los consumos reales registrados durante el mismo periodo. Como se observa en la **Figura 5**, el pronóstico reproduce de manera general las variaciones mensuales del consumo, aunque en algunos meses presenta diferencias visibles respecto de los valores observados.




Figura 5. Consumo eléctrico histórico, validación del pronóstico para 2025 y proyección para 2026. Elaboración propia a partir de los registros de consumo de la empresa analizada.

El error porcentual absoluto medio (MAPE) obtenido durante la validación fue de 8.99 %. Esto significa que, considerando los doce meses de 2025, las estimaciones se alejaron de los consumos reales aproximadamente 9 % en promedio. Sin embargo, el error no fue uniforme durante todo el año. En febrero la diferencia fue de solo 0.28 %, mientras que en abril, mayo, julio y diciembre se observaron desviaciones superiores al 13 %. El mayor error se presentó en diciembre, con 19.59 %.

En términos anuales, el consumo real de 2025 fue de 241,881 kWh, mientras que el valor pronosticado acumulado fue de aproximadamente 256,113 kWh. Esto representa una sobreestimación cercana a 14,232 kWh, equivalente a aproximadamente 5.9 % respecto del consumo real anual. La diferencia entre el error mensual promedio y la desviación del total anual se debe a que el MAPE evalúa cada mes por separado antes de obtener el promedio.

Mes	Consumo real 2025 (kWh)	Pronóstico (kWh)	Error Absoluto (%)
Ene	16,589	17,270	4.11
Feb	15,910	15,954	0.28
Mar	18,127	18,909	4.31
Abr	18,395	21,282	15.70
May	21,335	24,635	15.47
Jun	22,153	23,562	6.36
Jul	22,451	25,589	13.98
Ago	22,272	24,344	9.30
Sep	20,458	22,845	11.67
Oct	21,729	23,005	5.87
Nov	21,991	22,256	1.21
Dic	20,471	16,461	19.59
Promedio:	20,157	21,343	8.99
Total:	241,881	256,113	

Tabla 2. Validación del modelo y error porcentual 2025

Estos resultados muestran que el modelo ofrece una aproximación útil para identificar el comportamiento general de la demanda, pero también evidencian sus limitaciones cuando ocurren cambios que no pueden anticiparse únicamente a partir del historial de consumo. Por esta razón, el pronóstico debe interpretarse como información de apoyo para la planificación y no como una estimación exacta de la energía que será requerida.

Una vez validado el procedimiento con los datos de 2025, se generó el pronóstico mensual para 2026. Estos valores permiten ilustrar cómo una serie histórica puede utilizarse para anticipar posibles necesidades futuras; sin embargo, deberán compararse posteriormente con datos reales para conocer su desempeño.

b) Temperatura ambiente

Para el análisis de la temperatura se utilizaron registros de temperatura media mensual correspondientes a Puerto Vallarta, Jalisco. En el archivo de trabajo, los

datos provienen de la estación climatológica 14339 El Cuale, perteneciente al sistema de información del Servicio Meteorológico Nacional de la Comisión Nacional del Agua (CONAGUA, s.f.). El SMN dispone de información climatológica y registros mensuales de temperatura para el análisis de las condiciones meteorológicas en distintas regiones del país.

Al igual que en el análisis de la demanda eléctrica, se utilizaron los datos mensuales comprendidos entre enero de 2022 y diciembre de 2024 para construir el modelo. Posteriormente, se generaron las estimaciones de temperatura para 2025 y se compararon con los valores reales registrados durante ese mismo año.

Para evaluar el desempeño del pronóstico se utilizó el error absoluto medio (MAE). Esta medida indica, en las mismas unidades de la variable, cuánto se alejan en promedio los valores estimados de los datos reales. Su uso resulta más apropiado que un error porcentual para temperaturas expresadas en grados Celsius, ya que esta escala tiene un punto cero arbitrario y, por ello, los errores porcentuales pueden resultar difíciles de interpretar correctamente.

Mes	Temperatura real (°C)	Pronóstico (°C)	Error absoluto (°C)
ene-25	22.2	22.51	0.31
feb-25	22.8	22.22	0.58
mar-25	21.8	22.81	1.01
abr-25	22.1	23.91	1.81
may-25	26.6	26.65	0.05
jun-25	28.4	28.26	0.14
jul-25	29.0	28.93	0.07
ago-25	28.8	28.87	0.07
sep-25	28.8	28.93	0.13
oct-25	28.6	27.94	0.66
nov-25	25.6	25.74	0.14
dic-25	23.6	23.81	0.21
Promedios:	25.7	25.88	0.43

Tabla 3. Validación del pronóstico de temperatura para 2025

Durante el periodo de validación de 2025 se obtuvo un: $MAE = 0.43\text{ }^{\circ}\text{C}$

Esto significa que, considerando los doce meses analizados, las temperaturas pronosticadas se alejaron de los valores reales aproximadamente 0.43°C en promedio. Este resultado muestra una cercanía importante entre las estimaciones y los datos observados, aunque las diferencias no fueron iguales durante todo el año.

La mayor desviación se presentó en abril, cuando la temperatura real fue de 22.1°C y el modelo estimó aproximadamente 23.91°C , lo que representa una diferencia absoluta de 1.81°C . En contraste, durante mayo, julio y agosto las diferencias fueron menores a 0.1°C . Estos resultados muestran que el modelo reproduce de manera cercana el patrón general de la serie, aunque pueden presentarse meses con desviaciones mayores.

Como se observa en la Figura 6, las temperaturas muestran un comportamiento estacional relativamente definido, con valores más bajos al inicio y al final del año y temperaturas mayores durante los meses intermedios. Esta regularidad ayuda a explicar por qué el modelo logró generar estimaciones cercanas a los valores reales. Sin embargo, el resultado corresponde únicamente al periodo y a la ubicación analizados, por lo que no debe generalizarse automáticamente a otras regiones o condiciones climáticas.




Figura 6. Temperatura media mensual histórica, validación del pronóstico para 2025 y proyección para 2026. Elaboración propia a partir de datos del Servicio Meteorológico Nacional-CONAGUA.

Una vez realizada la validación con los datos de 2025, se obtuvo también el pronóstico correspondiente a 2026. Al igual que en el análisis de la demanda, estos valores deben entenderse como estimaciones basadas en los patrones históricos disponibles y no como temperaturas que necesariamente ocurrirán.

c) Costos de la energía

Para analizar los costos se utilizó el precio medio mensual de la energía eléctrica, expresado en MXN/kWh, obtenido a partir de los registros de facturación de la empresa analizada. Este indicador permite representar de manera resumida el costo unitario de la electricidad durante cada periodo y facilita su comparación a lo largo del tiempo. En aquellos meses en los que existía más de un registro para el mismo periodo, los valores fueron consolidados antes de construir la serie utilizada para el pronóstico.

Al igual que en las variables anteriores, se emplearon 36 observaciones mensuales correspondientes de enero de 2022 a diciembre de 2024 para generar las estimaciones. Posteriormente, los valores pronosticados para 2025 se compararon con los precios medios reales registrados durante ese mismo año. De esta forma fue posible evaluar qué tan cerca se encontraba el modelo del comportamiento observado.

Durante 2025, el precio medio real presentó variaciones entre los distintos meses, con valores aproximados entre 2.89 y 3.27 MXN/kWh. El modelo reprodujo de manera general el nivel de la serie, aunque mostró una tendencia más gradual que los datos reales. Esto significa que pudo seguir la evolución general del precio, pero respondió con menor rapidez ante algunos cambios mensuales.




Figura 7. Precio medio mensual de la energía, validación del pronóstico para 2025 y proyección para 2026. Elaboración propia a partir de los registros de facturación de la empresa analizada.

78

El error porcentual absoluto medio (MAPE) obtenido durante la validación fue de 3.72 %. En términos sencillos, esto indica que las estimaciones se alejaron de los valores reales aproximadamente 3.7 % en promedio durante los doce meses analizados.

Las diferencias mensuales no fueron uniformes. Los menores errores se presentaron en marzo y abril, con valores aproximados de 0.66 % y 0.92 %, respectivamente. En cambio, las mayores desviaciones se observaron en mayo, con alrededor de 7.20 %, y en diciembre, con aproximadamente 9.88 %. Estos resultados muestran que el modelo puede aproximarse adecuadamente a periodos con cambios moderados, pero presenta mayores diferencias cuando el precio se modifica de manera más marcada respecto de la tendencia histórica.

Mes	Precio Medio Real (MXN/kWh)	Pronóstico (MXN/kWh)	Error (%)
Ene	3.08	3.03	1.70
Feb	3.13	3.05	2.50
Mar	3.04	3.06	0.66

Abr	3.11	3.08	0.92
May	2.89	3.09	7.20
Jun	2.98	3.11	4.30
Jul	3.07	3.12	1.65
Ago	3.00	3.14	4.58
Sep	3.04	3.15	3.62
Oct	3.27	3.17	3.17
Nov	3.05	3.19	4.52
Dic	2.91	3.20	9.88
Prome- dios:	3.05	3.12	3.72

Tabla 4. Validación del pronóstico del precio medio de la energía para 2025

El precio medio real de 2025 fue de aproximadamente 3.05 MXN/kWh, mientras que el promedio de las estimaciones fue cercano a 3.12 MXN/kWh. En términos generales, el modelo presentó una ligera sobreestimación del nivel promedio anual. Sin embargo, esta diferencia fue relativamente pequeña frente a las variaciones observadas mes a mes.

79

A diferencia de variables con patrones estacionales más regulares, los costos de la energía pueden verse afectados por elementos que no dependen únicamente del comportamiento histórico, como modificaciones tarifarias, condiciones económicas, cambios regulatorios o variaciones en la estructura del consumo. Por ello, el pronóstico debe entenderse como una referencia para apoyar la planificación económica y no como una estimación exacta del precio futuro.

Una vez realizada la validación con los datos de 2025, se generó también el pronóstico correspondiente a 2026. Estos valores permiten observar una posible trayectoria futura del precio medio, pero su utilidad dependerá de que posteriormente se comparen con los datos reales y se actualice el modelo conforme se disponga de nueva información.

d) Comparación de resultados

Los resultados obtenidos muestran que el desempeño del modelo varía de acuerdo con las características de cada variable. En la demanda eléctrica, el MAPE fue de 8.99 %, mientras que para el precio medio de la energía fue de 3.72 %. Por lo tanto, entre las dos variables evaluadas mediante la misma métrica porcentual, el precio medio

presentó una menor diferencia promedio entre los valores reales y los pronosticados.

En el caso de la temperatura ambiente, se obtuvo un MAE de 0.43 °C, lo que significa que las estimaciones se alejaron de las temperaturas reales aproximadamente esa cantidad en promedio durante 2025. Este resultado no debe compararse directamente con los porcentajes obtenidos para demanda y costos, ya que corresponde a una métrica diferente y se expresa en las mismas unidades de la variable analizada.

En conjunto, el ejercicio muestra que un mismo procedimiento de predicción puede presentar resultados diferentes según el comportamiento de los datos. La demanda eléctrica mostró mayores variaciones mensuales, mientras que la temperatura presentó un comportamiento más regular durante el periodo analizado. El precio medio de la energía se mantuvo en una posición intermedia, aunque también registró cambios que el modelo no reprodujo con la misma precisión en todos los meses.

Estos resultados refuerzan una idea central del artículo: la utilidad de una predicción no depende únicamente del método empleado, sino también de las características de la variable, de la información disponible y de las condiciones que pueden modificar su comportamiento. Por ello, los pronósticos deben utilizarse como estimaciones que apoyan el análisis y no como valores exactos sobre lo que ocurrirá posteriormente.

1.7 Alcances, limitaciones e implicaciones sociales

El ejercicio desarrollado muestra de manera práctica cómo los datos históricos pueden utilizarse para generar y validar pronósticos de variables relacionadas con la energía. El uso de información mensual de 2022 a 2024, seguida de una validación con datos reales de 2025, permitió observar el comportamiento del modelo antes de utilizarlo para generar estimaciones correspondientes a 2026. Este procedimiento ofrece una forma accesible de acercar las técnicas de predicción a lectores no especializados.

Sin embargo, los resultados deben interpretarse dentro de los límites del ejercicio. El análisis utiliza un periodo histórico relativamente corto y se concentra en una empresa y una ubicación determinadas. Además, los pronósticos se construyeron principalmente a partir del comportamiento previo de cada serie, sin incorporar de manera directa otros factores que podrían modificarla, como cambios en la actividad de la empresa, condiciones económicas, ajustes tarifarios, modificaciones regulatorias o eventos climáticos poco habituales. Por estas razones, los resultados no deben generalizarse automáticamente a otros usuarios, regiones o periodos.

Otra limitación es que la validación se realizó con un solo año de datos. Contar con series históricas más amplias, nuevos periodos de validación y variables adicionales permitiría evaluar con mayor profundidad la estabilidad de los pronósticos y comparar el desempeño de diferentes métodos. En futuros análisis también podrían incorporarse técnicas estadísticas y de aprendizaje automático para determinar si ofrecen ventajas en determinados contextos.

Desde una perspectiva social, disponer de mejores pronósticos puede ayudar a anticipar necesidades de consumo, cambios en los costos o condiciones ambientales que influyen en el uso de la energía. Sin embargo, una predicción más precisa no genera por sí misma una decisión más justa. Para que esta información contribuya a una planificación socialmente responsable debe complementarse con elementos como las condiciones económicas de los usuarios, el acceso a los servicios, la vulnerabilidad y las características particulares de cada comunidad.

Conclusiones

La predicción de variables energéticas puede proporcionar información útil para comprender posibles cambios en la demanda eléctrica, la temperatura y los costos de la energía. El ejercicio presentado en este artículo mostró, mediante un modelo ETS y datos históricos, una forma accesible de generar estimaciones y evaluar su comportamiento a partir de información real.

81

Los resultados también muestran que la precisión no es igual para todas las variables. Cada serie presenta características propias y puede verse afectada por factores que un modelo basado en datos históricos no siempre logra anticipar. Por esta razón, los pronósticos deben entenderse como herramientas de apoyo que ayudan a reducir la incertidumbre, pero no sustituyen el análisis del contexto ni garantizan por sí mismos lo que ocurrirá en el futuro.

Su utilidad adquiere mayor importancia cuando la información obtenida se incorpora a decisiones que consideran no solo criterios técnicos y económicos, sino también sus posibles efectos ambientales y sociales. Anticipar necesidades, costos o cambios en las condiciones de operación puede favorecer una mejor planificación; sin embargo, avanzar hacia una gestión energética más equitativa requiere complementar estos análisis con información sobre acceso, asequibilidad y vulnerabilidad.

En este sentido, el valor de la predicción energética no se encuentra únicamente en anticipar el futuro con mayor precisión, sino en utilizar esa información de manera responsable para orientar decisiones más informadas, sostenibles y sensibles a las

necesidades de la sociedad.

Por último, es importante mencionar que éstas y otras técnicas de predicción se utilizan en todos los ámbitos de la actividad humana, como por ejemplo modelos financieros, evolución de pandemias, negocios y marketing, ciencias sociales y políticas, entre otros. Por lo que se invita al lector, a reflexionar en ¿cómo podrían estas técnicas ayudarlo en su actividad económica o profesional?

Referencias

- Ahmad, T., Zhang, H., y Yan, B. (2020). A review on renewable energy and electricity requirement forecasting models for smart grid and buildings. *Sustainable Cities and Society*, 55, 102052. <https://doi.org/10.1016/J.SCS.2020.102052>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Comisión Nacional del Agua. (s. f.). Jalisco: Normales climatológicas por estado. Servicio Meteorológico Nacional. Recuperado el 10 de agosto de 2026, de <https://smn.conagua.gob.mx/es/climatologia/informacion-climatologica/normales-climatologicas-por-estado?estado=jal/>
- Deb, C., Zhang, F., Yang, J., Lee, S. E., y Shah, K. W. (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74, 902–924. <https://doi.org/10.1016/j.rser.2017.02.085>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>
- Hong, T., y Fan, S. (2016). Probabilistic electric load forecasting: A tutorial review. *International Journal of Forecasting*, 32(3), 914–938. <https://doi.org/10.1016/j.ijforecast.2015.11.011>
- Hyndman, R. J., y Athanasopoulos, G. (2021). *Forecasting: principles and practice* (3ª ed.). OTexts. <https://otexts.com/fpp3/>
- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y., y Zhang, Y. (2019). Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network. *IEEE Transactions on Smart Grid*, 10(1), 841–851. <https://doi.org/10.1109/tsg.2017.2753802>
- Marmolejo Cervantes, M. Á., y Reilly Solís, L. (2024). Energy poverty and social justice in Mexico: The rights of electricity consumers. *The Electricity Journal*, 37(2), 107372. <https://doi.org/10.1016/j.tej.2024.107372>
- Microsoft. (s. f.). Función PRONOSTICO.ETS. Soporte técnico de Microsoft. <https://support.microsoft.com/es-es/excel/functions/forecast-ets-function>

- Sesay, M. M., Ngunyi, A., y Imboga, H. (2026). An explainable hybrid transformer–BiLSTM framework for multivariate household energy demand forecasting with weather integration. *Energy Informatics*, 9, Article 33. <https://doi.org/10.1186/s42162-026-00635-8>
- Sovacool, B. K., Heffron, R. J., McCauley, D., y Goldthau, A. (2016). Energy decisions reframed as justice and ethical concerns. *Nature Energy*, 1, 16024. <https://doi.org/10.1038/nenergy.2016.24>
- Suástegui Macías, J. A., López Valenzuela, A. J., Acuña Ramírez, A., Rosales Escobedo, P. F., y Ruelas Puente, A. H. (2023). Reduction of energy poverty in Mexico by applying an optimization model to residential energy tariffs. *Energy Reports*, 9, 3431–3439. <https://doi.org/10.1016/j.egy.2023.02.022>
- Ullah, K., Ahsan, M., Hasanat, S. M., Haris, M., Yousaf, H., Raza, S. F., Tandon, R., Abid, S., y Ullah, Z. (2024). Short-Term Load Forecasting: A Comprehensive Review and Simulation Study with CNN-LSTM Hybrids Approach. *IEEE Access*, 12, 111858–111881. <https://doi.org/10.1109/access.2024.3440631>