



Doi: <https://doi.org/10.70577/asce.v5i3.997>

Recibido: 2026-06-13

Aceptado: 2026-06-26

Publicado: 2026-07-10

Pronóstico de la demanda de una instalación industrial

Forecasting the demand of an industrial facility

Autor(s)

Jeimy Azeneth Pincay Arteaga ¹

Facultad de Ciencias de la Ingeniería y Aplicadas, Carrera
de Ingeniería en Electricidad
jeimy.pincay2509@utc.edu.ec
<https://orcid.org/0009-0001-7000-8142>
Universidad Técnica de Cotopaxi
Latacunga – Ecuador

Secundino Marrero Ramírez ²

Facultad de Ciencias de la Ingeniería y Aplicadas, Carrera
de Ingeniería en Electricidad
secundino.marrero@utc.edu.ec
<https://orcid.org/0000-0001-5161-545X>
Universidad Técnica de Cotopaxi
Latacunga – Ecuador

Brayan Stalin Taipe Cayancela ³

Facultad de Ciencias de la Ingeniería y Aplicadas, Carrera
de Ingeniería en Electricidad
brayan.taipe4242@utc.edu.ec
<https://orcid.org/0009-0006-3844-2957>
Universidad Técnica de Cotopaxi
Latacunga – Ecuador

Carlos Iván Quinatoa Caiza ⁴

Facultad de Ciencias de la Ingeniería y Aplicadas (CIYA),
Carrera de Ingeniería en Electricidad
carlos.quinatoa7864@utc.edu.ec
<https://orcid.org/0000-0001-6369-7480>
Universidad Técnica de Cotopaxi
Latacunga – Ecuador

Como Citar

Pincay Arteaga, J. A., Marrero Ramírez, S., Taipe Cayancela, B. S., & Quinatoa Caiza, C. I. (2026). Pronóstico de la demanda de una instalación industrial. *ASCE MAGAZINE*, 5(3), 434–453. <https://doi.org/10.70577/asce.v5i3.997>



Resumen

El pronóstico en la actualidad es un factor importante de la gestión, planificación y toma de decisiones. Esto presenta un dilema al tener que elegir un modelo para obtener mayor precisión y menos índice de error, especialmente con datos altamente variables como la demanda eléctrica. Este estudio tuvo como objetivo aplicar modelos de pronóstico mediante enfoques cualitativos y cuantitativos integrando diversos factores para robustecer la predicción de la demanda eléctrica de una instalación industrial de una manufacturera ecuatoriana. Para ello se aplicó una metodología bajo el paradigma mixto con modelos cuantitativos de Tendencia Lineal, Suavización Exponencial Simple, Holt-Winters y SARIMA, además se evaluó el modelo cualitativo juicio de expertos Delphi y se determinaron pruebas de error MAE (Mean Absolute Error), RMSE (Root Mean Square Error) y MAPE (Mean Absolute Porcentaje Error) en horizontes temporales diarios, semanales, mensuales y anuales. Los resultados determinan que no existe un modelo ideal, su elección depende de la temporalidad del análisis destacando según la aplicación en horizonte diario y semanal el modelo de suavización exponencial simple obteniendo MAPE de 3.90% para escala diaria y MAPE 0.76% para periodos semanales, mientras que en temporalidad mensual o anual con menos diferencia estructural de datos, el modelo SARIMA obtiene el MAPE más bajo de 0.05%, mientras que el modelo Holt-Winters tienen resultados intermedio en términos de precisión y el modelo cualitativo Delphi es el que demostró menos precisión métrica con un error promedio del 13%. Se acepta la hipótesis alternativa y se rechaza la hipótesis nula al considerar que la aplicación de modelos de pronóstico mejora la precisión de la proyección de demanda eléctrica.

Palabras clave: pronóstico, demanda, modelo cuantitativo, modelo cualitativo.



Abstract

Forecasting today is the boom in management, planning and decision-making. The dilemma is to choose a model that allows for greater accuracy and a lower error rate, especially with highly variable data such as electricity demand. The objective of the study was to apply forecasting models using qualitative and quantitative approaches that integrate various factors to strengthen the prediction of the demand of an industrial facility of an Ecuadorian manufacturing company. To this end, a methodology was applied under the mixed paradigm, the quantitative models of Linear Trend, Simple Exponential Smoothing, Holt-Winters and SARIMA were applied, in addition the qualitative model Delphi expert judgment was evaluated and MAE (Mean Absolute Square Error), RMSE (Root Mean Square Error) and MAPE (Mean Absolute Percentage Error) error tests were determined in daily time horizons. weekly, monthly, and yearly. The results determine that there is no ideal model, its choice depends on the temporality of the analysis, highlighting according to the application in the daily and weekly horizon the simple exponential smoothing model obtaining MAPE of 3.90% for daily scale and ASM 0.76% for weekly periods, while in monthly or annual temporality with less structural difference of data the SARIMA model obtains the lowest ASM of 0.05%, the Holt-Winters model remains intermediate in terms of accuracy and the qualitative Delphi model is the one that demonstrated the least metric accuracy with an average error of 13%. The alternative hypothesis is accepted and the null hypothesis is rejected, considering that the application of forecasting models improves the accuracy of the electricity demand projection.

Keywords: forecast, demand, quantitative model, qualitative model.



Introducción

Pronosticar es la acción de anticiparse a los hechos y en el contexto de instalaciones industriales, pronosticar es anticipar los requerimientos y necesidades de nuevas instalaciones o a su vez de la reducción, optimización y efectivización de operaciones y recursos con el fin de garantizar la cobertura y evitar inconvenientes por escasas o exceso de disponibilidad [1]. En un entorno industrial dinámico y volátil donde los elementos como la tecnología, la economía y las condiciones del mercado mantienen cierta variedad, es importante integrar modelos de pronóstico basados en datos reales que permitan ejercer un control y planificación adecuada en base a la anticipación de demanda crucial.

Un suministro elemental para la operatividad del sector industrial, sin interrupciones a nivel mundial es la energía eléctrica. Según [2] se ha evidenciado que en los últimos años existen deficiencias operativas y sociales en el sector industrial, donde los desafíos funcionales que atraviesan países como Ecuador, donde existe un crecimiento reducido el periodo 2024 con importaciones de insumos industriales que se incrementaron solo un 0.3%. Esto se relaciona a la crisis eléctrica que atravesó el país desde octubre de 2023 donde episodios de apagones de hasta 14 horas diarias afecto de manera significativa el 72% del sector, debido a que la operatividad manufacturera depende exclusivamente del suministro de energía constante, esto hace énfasis en la necesidad de mantener un pronóstico de demanda energética en el sector.

Como afirma [3] los modelos de pronóstico son altamente utilizados en diferentes escenarios para incrementar la eficiencia, donde los modelos que se basan en machine learning ofrecen precisión de hasta el 99% de error promedio, la aceptación actual de los modelos de pronósticos, se debe a la utilidad que tienen en la disminución de la incertidumbre para planificar y gestionar la toma de decisiones en base a datos contextualizados y apegados a la realidad de la industria.

En los modelos de pronóstico, la efectividad en la precisión sobre todo cuando se incluyen otras variables y se consideran diversos factores según [4] un estudio realizado en Cuba sobre la predicción en empresas industriales determina que modelos de Deep Learning (como LSTM) reduce de forma significativa los niveles de error hasta en un 10% frente a los modelos clásicos al incorporar elementos, como las políticas y la inversión, esto generaliza el nivel macro que pueden



tener los modelos predictivos. Según [5] la precisión de pronóstico reduce errores en un rango del 40% al 50%. En el sector industrial la reducción de errores en las predicciones es sinónimo de agilidad y precisión, no obstante, los costos que supone implementar estos modelos en las industrias constituyen un desafío.

Desde la perspectiva social cuando no existe un pronóstico adecuado de demanda, donde incide también el incremento del desempleo. La falta de capacidad en la previsión de energía, ello impacta directamente la eficiencia operativa y la productividad de plantas industriales, ocasionando pérdidas significativas que se reflejan en inestabilidad laboral y de forma progresiva en inestabilidad social. Las instalaciones industriales según [6] deben manejar pronósticos con niveles aceptables de error, que debiliten brechas metodológicas y tecnológicas a fin de ofrecer información más acertada para la toma de decisiones. Por todo lo expuesto, la investigación plantea como formulación del problema: ¿Qué modelo de pronóstico genera información confiable para la toma de decisiones y reducción de costos operativos por sobreproducción o desabastecimiento en una planta industrial asociados con la demanda de energía?

La investigación enfatiza la necesidad de generar pronósticos con menor nivel de error en el sector manufacturero y los resultados de este tipo de investigación según [7] contribuyen a que el sector manufacturero emplee modelos de pronóstico que integren diversos elementos para generar resultados más precisos y contextualizados al entorno específico de la planta manufacturera, incrementando los niveles de resiliencia. En la industria objetivo de estudio este trabajo contribuyó a robustecer la gestión, planeación y control, dando la oportunidad de realizar ajustes dinámicos para reducir costos que puedan ser acrecentados por paros y fallos productivos no programados, estabiliza la eficiencia operativa, la estabilidad y continuidad laboral. El enfoque práctico permite que estos modelos sean replicables y fortalezcan los sistemas de predicción actuales de las industrias manufactureras ecuatorianas [8].

Pronóstico

De acuerdo a [9] la palabra pronóstico se refiere al hecho de pronosticar o adelantarse a lo que pasará en el futuro a través de diferentes medios como juicios, datos o información. Por su parte [10] considera que pronosticar es un arte, una ciencia que se adelanta a eventualidades futuras para



tomar decisiones en el presente. Se basa en la emisión de un juicio originado a partir de información que ha sido resultado del pasado hasta el presente, para generar un panorama de lo que sucederá reduciendo la incertidumbre para la toma de decisiones congruentes. Es importante mencionar que el nivel de éxito del pronóstico según [11] depende de que tan aproximado se encuentre de la realidad y de los datos que emplea para proyectarse. Aunque en todo pronóstico existe una probabilidad de error puesto que la propia acción de predecir el futuro mantiene un riesgo inherente de precisión, el hecho de pronosticar es un elemento indispensable en el campo de la ingeniería.

Pronóstico de demanda en instalaciones industriales

Predecir o pronosticar la demanda para [12] es un reto que han enfrentado los pronosticadores desde hace muchos años, debido al nivel de error que existe entre el pronóstico y la realidad se ha buscado solución mediante la generación de diversos modelos y técnicas de pronóstico de la demanda. En la actualidad a pesar de haber mejorado la precisión de los modelos de pronóstico al incluir elementos que complementan los análisis según [11] es importante considerar que no existe un modelo de pronóstico que estime de forma exacta la demanda futura, por ello es importante emplear más de un modelo a la vez en una misma estimación, ya que la demanda no siempre se ajusta a un comportamiento lineal, también es necesario considerar bajo que marco temporal u horizonte existe un comportamiento de datos más estable.

A través del tiempo según [13] se ha procurado determinar indicadores que determinen el nivel de desempeño de los modelos de predicción a fin de obtener el que estime la demanda de forma más fiable y apegada a la realidad futura. Por su parte [14] determina que el pronóstico tiene una amplia aplicación y existen diversas técnicas y modelos, por ello para escoger cuales aplicar, de acuerdo a [15] se debe tener en cuenta cuatro factores claves para determinar los modelos a aplicar: 1. El propósito u objetivo de pronosticación y para que se empleará. 2. Los componentes, elementos y características específicas del sistema que se pretende pronosticar es decir el contexto del pronóstico. 3. La información histórica que está disponible y la calidad de esta. 4. El horizonte y el costo beneficio.

Los datos que se empleen según [16] son esenciales, pues pueden presentar patrones definidos, que puede ser mayor entre semana y menor durante los fines de semana o viceversa. Los pronósticos



de carga diarios y semanales se clasifican como pronósticos a corto plazo, mientras que el pronóstico de carga anual se clasifica como pronósticos de carga a largo plazo. Respecto a la aplicación de modelos se cita a [17] y [18] quienes evaluaron la precisión de pronóstico y destaca la eficacia de los modelos LSTM para capturar patrones temporales complejos y mejorar la precisión de los pronósticos en comparación con los modelos tradicionales.

En efecto, por lo mencionado la investigación se orientó al objetivo de aplicar modelos de pronóstico mediante enfoques cualitativos y cuantitativos que integren diversos factores para robustecer la predicción de la demanda de una instalación industrial de una manufacturera ecuatoriana.

Material y métodos

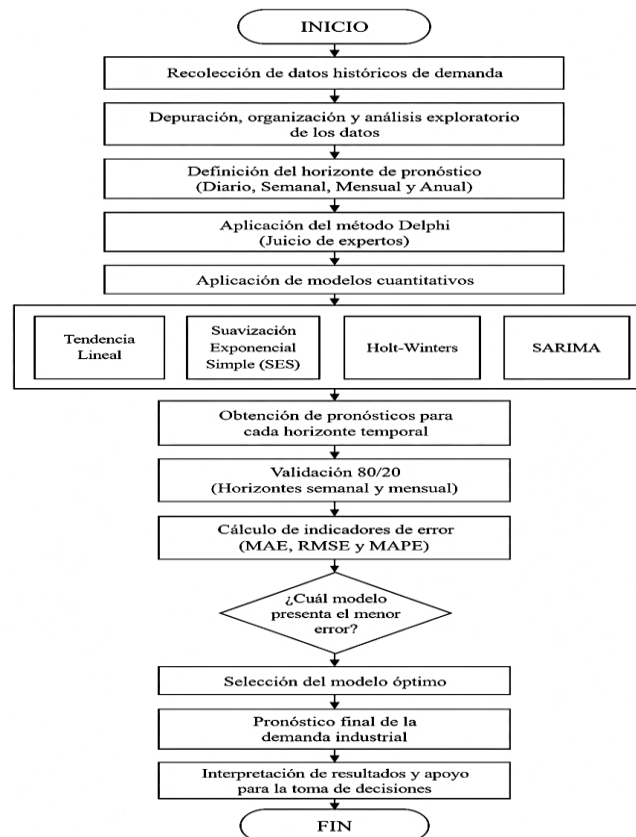
La investigación fue desarrollada bajo el enfoque del paradigma mixto al consistir específicamente en el análisis numérico y estadístico de series temporales de consumo y demanda eléctrica a fin de determinar el comportamiento y ajustar la demanda. Los modelos cuantitativos aplicados fueron: Modelo de Tendencia Lineal, Modelo de Suavización Exponencial Simple, Modelo Holt-Winters y el Modelo SARIMA.

Se aplicó como complemento un modelo cualitativo Juicio de expertos / Delphi este permitió identificar elementos técnicos de la demanda eléctrica. Estos modelos consolidan el enfoque mixto del estudio. Este caso se contempla como un estudio aplicado, puesto que se centra en contribuir a determinar el modelo que refleja mayor eficiencia para realizar pronósticos y de esta forma contribuir a una planificación y proyección y toma de decisiones más acertadas en cuanto a demanda de electricidad al utilizar tendencias estacionales, componentes y patrones aleatorios en los modelos aplicados. Además, es de carácter prospectivo por su naturaleza de pronosticar comportamientos futuros y analítico al efectuar una comparación del nivel de error de cada modelo empleando las métricas de error: MAE (Mean Absolute Error), RMSE (Root Mean Square Error) y MAPE (Mean Absolute Porcentaje Error) en cada modelo para hacerlo comparable.

Se emplearon temporalidad diaria, semanal, mensual y anual para los diferentes modelos de pronóstico aplicados. Las técnicas consistieron básicamente en: Análisis de series temporales, Regresión lineal tiempo–demanda, Suavización exponencial, Modelación estacional, Validación estadística mediante métricas de error, Consulta estructurada a expertos (método Delphi). Para efecto los instrumentos necesarios fueron: Base de datos de consumo y demanda histórica diaria, semanal, mensual y anual reflejada en kw, Formatos para el modelo Delphi., Software Jamovi con Rj Editor, Scripts en lenguaje R.

Las hipótesis que se plantean para el presente estudio son hipótesis nula (H_0): La aplicación de modelos de pronóstico no mejora la precisión de la demanda ni influye en la optimización de costos operativos de una instalación industrial. Hipótesis alternativa (H_1): La aplicación de modelos de pronóstico mejora la precisión de la demanda, optimiza el uso de recursos y reduce costos operativos de una instalación industrial. Las fases para desarrollar las predicciones se detallan a continuación:

Fig. 1. Fases de la aplicación de pronósticos



Resultados

Una vez analizada y depurada la data se pasó a la evaluación de los diferentes modelos que se relacionan a continuación.

Modelo cualitativo (Juicio de expertos / Delphi)

Para desarrollar el método Delphi se contactó a tres especialistas eléctricos con más de cinco años de trayectoria en el campo para obtener sus pronósticos en base al comportamiento histórico de demanda. La primera ronda de pronóstico de los expertos se realizó luego de analizar el comportamiento histórico (2020, 2021, 2022), en la segunda ronda denominada ronda (final) los expertos convergieron y estimaron de forma más consensuada. Los resultados determinan que el promedio de crecimiento de la demanda anual es del 2% aproximado, una vez obtenido el pronóstico para el año 2023, se aplica esa tasa de crecimiento para el pronóstico de los años 2024, 2025 y 2026. En la tabla I se observa el error absoluto medio (MAE) con valor de 236,28 kW desvía los valores pronosticados de los reales por más de 200 kW y el RMSE elevado sugiere que existen diferencias significativas en el modelo, destacando tendencia de sobrestimación, el porcentaje de error promedio de 13 % reflejado en la tabla I posiciona al modelo como una herramienta que puede ser empleada para tener una comprensión general del comportamiento que tendrá la demanda, pero no es eficiente en términos de precisión.

Tabla I. Resumen del modelo Delphi

RESUMEN DE ERROR DEL MODELO DELPHI	
Elemento de error	Valor
Real	135188.871
Pronóstico	143694.961
Diferencia	-8506.090
Error típico MAE promedio	236.280
Error Cuadrático Medio (RMSE)	265658.079
Porcentaje de Error	13%

Modelos cuantitativos modelo de Tendencia Lineal: Para pronosticar la demanda con una regresión tiempo-demanda.


El modelo de tendencia lineal en temporalidad mensual como se observa en la tabla II, determina tendencias de crecimiento sostenido de la demanda para el año 2026 y posteriores, inicia con valores de error porcentual bajos de 1%, valor que incrementa a la par con la temporalidad, es decir a mayor margen temporal mayor es el nivel de error, llegando a reflejar valores superiores al 10%. El 6,9% de error general defiende un nivel de precisión moderado siempre y cuando no existan variaciones radicales en los datos históricos de consumo. En temporalidad semanal la tabla II, es determinante en el ajuste de error con tendencia de incremento relativo de la temporalidad es decir cuando se amplía el horizonte temporal del pronóstico el error incrementa estableciendo que definitivamente puede generar a largo plazo mayor nivel de incertidumbre y error llegando al 90,5% en la predicción, situándolo como una herramienta con mayor utilidad al corto y mediano plazo.

Tabla II. Resumen del modelo de tendencia lineal temporalidad semanal y mensual.

Descripción	Mensual	Semanal
N	36	157
Índice de Tiempo (x)	630	12246
Consumo (y)	84521832.01	84521832.01
Pendiente (m)	11630.75683	612.5590762
Intersección (b)	2144290.422	490576.01
Predicción (y_pred)	9471667.228	7991974.457
Error (y_real - y_pred)	75050164.78	76529857.56
Porcentaje de error	6.9%	90.5%

En la figura 2 se puede observar con línea color azul (datos reales de demanda), la variabilidad de demanda diaria y semanal con picos marcados que pueden estar relacionados con situaciones operativas cambios en las actividades, suspensiones o interrupciones que varían considerablemente la demanda no obstante la tendencia se direcciona al crecimiento sostenido y la línea roja representa los valores de predicción que refleja un crecimiento exclusivamente lineal con limitado ajuste a las variaciones pronunciadas.

Fig. 2. Modelo de pronóstico de tendencia lineal en temporalidad demanda diaria y semanal.



Modelo de Suavización Exponencial Simple

El modelo de suavización exponencial simple responde a las siguientes ecuaciones:


$$\text{Ecuación de pronóstico: } F_t + 1 = \alpha Y_t + (1 - \alpha) F_t \quad (1)$$


$$\text{Fórmula extendida: } F_t + 1 = \alpha Y_t + \alpha(1 - \alpha)F_{t-1} + \alpha Y_t + \alpha(1 - \alpha)^2 F_{t-2} + \dots \quad (2)$$

Donde: F_t = pronóstico para el siguiente período. αY_t = valor real observado en el tiempo, t.

Respecto a las temporalidades la demanda diaria y mensual observada en la (figura 3) obtienen un ajuste de serie razonable obteniendo un MAPE de 3.9% mientras que semanal y anual (figura 3), obtuvieron 0.76% este modelo resalta que la precisión incrementa cuando la variabilidad disminuye es decir el suavizado de datos es más eficiente cuando los datos cuentan con mayor estabilidad y consistencia estructural. La figuras no deben ser tablas.

Fig. 3. Modelo de Suavización Exponencial Simple





El modelo de Suavización Exponencial Simple, de acuerdo a los niveles de error resumidos en la tabla III, se plantea como una opción ideal para pronósticos donde la demanda refleje un comportamiento más estable especialmente en temporalidad a mediano y largo plazo con escalas de temporalidad más amplias mientras que en este caso no fue tan preciso en capas de tiempo finas como diarias y mensual con MAE 168.70, RMSE 239.30 y MAPE 3.90 puesto que contiene variabilidad inherente del consumo.

Tabla III. Resumen de error MAE – RMSE – MAPE modelo de suavización exponencial simple

Horizonte	MAE	RMSE	MAPE (%)
Diario	168.70	239.30	3.90
Semanal	36.16	36.16	0.7643
Mensual	168.70	239.30	3.90
Anual	36.16	36.16	0.7643

Modelo Holt-Winters

El modelo Holt-Winters corresponde a las tres ecuaciones: Nivel (L), Tendencia (T) y Estacionalidad (S):

$$\text{Nivel } L_t = \alpha \left(\frac{Y_t}{S_{t-s}} \right)_t + (1 - \alpha) (L_{t-1} + T_{t-1}) \tag{3}$$

$$\text{Tendencia } T_t = \beta (L_t - L_{t-1}) + (1 - \beta) T_{t-1} \tag{4}$$

$$\text{Estacionalidad } Y_{t+h} = (L_t - hT_t) S_{t-s+h} \tag{5}$$

Donde:

L_{t-1} = nivel de la serie.

T_t = tendencia.

S_{t-s} = factor estacional.

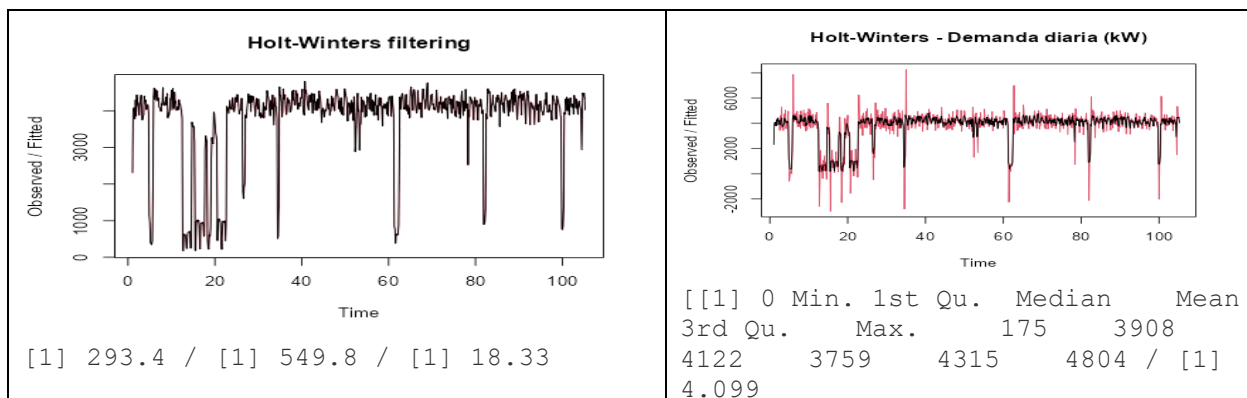
α = parámetro de nivel.


β = parámetro de tendencia.
 Y_{t+h} = parámetro de estacionalidad.
 $L_t - hT_t$ = longitud de la estacionalidad.
 S_{t-s+h} = horizonte de pronóstico.

En este modelo la línea roja representa el pronóstico y la línea negra son los datos históricos observados. Según los resultados la demanda mensual (figura 4) de forma general mantiene una buena trayectoria en los picos de subida y bajada de la línea roja que se mantiene constante sin una separación extrema en la mayor parte del gráfico, solo en los últimos tramos de divisa diferencias o separación significativa de forma explícita en esta temporalidad los niveles de error son , con valores de MAE de 136.4, RMSE de 155.6 y MAPE de 3.008, datos que sugieren consistencia aceptable de ajuste para el pronóstico mensual pero con poca precisión en variaciones puntuales.

Respecto a la temporalidad semanal (figura 4) es más estable y con mejor ajuste la línea roja que es la de predicción mantiene un mejor ajuste en logrando atenuar oscilaciones presentes, aunque los valores de error son más elevados que en la temporalidad mensual el MAPE es bajo aun sugiriendo que en esta temporalidad existen más fluctuaciones por lo que existe más ruido que el modelo debe explicar no obstante el desempeño es bueno. En este sentido en la temporalidad diaria (figura 4), existe la mayor parte de variaciones por lo que es difícil que el modelo se ajuste de forma consolidada, especialmente en las caídas marcadas la línea roja de predicción no logra ajustarse, debido a la atipicidad e irregularidad que mantienen los datos en esta temporalidad, las caídas abruptas y los valores cercanos a cero, resaltan que mientras más inestables sean los datos menor es la precisión sobre todo en tiempos de estimación cortos como es el caso de datos diarios.

Fig. 4. Holt – Winters en temporalidad diaria, semanal mensual y anual






Modelo SARIMA

El modelo Sarima reúne elementos volátiles de consumo y complejamente dinámicos, reuniendo factores estacionales y autorregresivos en la demanda diaria figura 5 con picos y caídas pronunciadas relacionadas al uso de equipos eléctrico con paradas operativas y conmutaciones o variaciones significativas, razones por las que este modelo es eficiente frente a otros modelos simples. Los resultados remarcan una buena alineación y correspondencia en las estimaciones especialmente respaldadas por la estabilidad que presenta en el horizonte final.

Sin embargo, los valores de error observados en la tabla IV con un MAE de 277.121, RMSE de 500.340 y MAPE de 19.0551, son más elevados por la intrínseca variabilidad de los datos diarios de demanda. Como en los otros modelos aplicados en la temporalidad semanal (Tabla IV) con un valor del MAE 280.619, RMSE de 645.180 y MAPE de 6.3199, se ajusta de mejor forma y es más estable debido a los patrones cíclicos más consistentes (figura 5) incrementando la capacidad predictiva. Esto se verifica en el horizonte mensual (figura 5) que presenta valores de error (Tabla VII) más bajos MAE = 2.073, RMSE = 3.521 y MAPE = 0.0457, esto hace posible que se enmarquen de mejor forma los elementos autorregresivos y estacionales presentes en la naturalidad del consumo eléctrico.

Fig. 5. Resumen de error MAR – RMSE – MAPE modelo Sarima





[1] 2 1 2 / [1] 0 1 1 / [1] 11084 / [1] 277.1 / [1] 500.3 / [1] 19.06	[1] 1 1 2 / [1] 0 1 0 / [1] 865.6 / [1] 280.6 / [1] 645.2 / [1] 6.32	[1] 0 1 2 / [1] 1 1 0 / [1] - 253.5 / [1] 2.073 / [1] 3.521 / [1] 0.04568
---	--	---

Tabla IV. Resumen de error mae – RMSE – MAPE modelo Sarima

Horizonte	ARIMA (P, D, Q)	Estacional (P, D, Q)	AIC	MAE	RMSE	MAPE (%)
Diario	(2,1,2)	(0,1,1)[7]	11083.9	277.121	500.340	19.0551
Semanal	(1,1,2)	(0,1,0)[52]	865.6	280.619	645.180	6.3199
Mensual	(0,1,2)	(1,1,0)[12]	-253.5	2.073	3.521	0.0457

Comparación de modelos

Del análisis se determina que el periodo de temporalidad que se aplique en los modelos de pronóstico influye de manera significativa en los niveles de error que se obtiene mientras menor es el tiempo y presenta mayores niveles de variabilidad en la capacidad de precisión que se reduce elevando, niveles de error. En la tabla V, se observa que los modelos cuantitativos superan el modelo cualitativo, puesto que en estos se integra de forma estable los datos históricos y elementos intrínsecos del comportamiento histórico de consumo y demanda eléctrica ajustando el pronóstico al comportamiento específico observado.

En términos definitivos no se puede asegurar que un método es mejor que otro de forma global o que sea aplicable para cualquier caso, todo depende de la naturaleza y las características específicas de cada patrón, la temporalidad, la variabilidad, el ruido y los cambios estructurales propios. Esto se puede corroborar en la tabla V, que compara los modelos aplicados y los indicadores de error, donde se determina precisión superior de un modelo a otro, solo en casos o en datos específicos, algo en común es que mientras mayor es la variabilidad de los datos base menor es la precisión de los modelos de pronóstico. El modelo SARIMA en la temporalidad mensual obtuvo el mejor desempeño con valores MAE = 2.073, RMSE = 3.521 y MAPE = 0.05 %. Por su parte el modelo de Suavización exponencial refleja mejores resultados en temporalidad semanal y anual con un valor MAPE de 0.76 %.

Los modelos Delphi y el e tendencia lineal obtuvieron los resultados de errores más elevados con valores 13 %, 6.9 % y 4.7 % respectivamente, reflejando una capacidad predictiva más limitada en comparación a los otros modelos, especialmente con datos volátiles como la demanda de

electricidad. El modelo Holt-Winters se ubicó en el espacio intermedio, logrando mejor precisión que tendencia lineal y Delphi pero sin igualar o superar la precisión del modelo SARIMA.

Tabla V. Resumen de error MAE – RMSE – MAPE modelo Sarima

COMPARACIÓN DE MODELOS				
Modelo	Horizonte	MAE	RMSE	MAPE / % Error
Delphi (Juicio de expertos)	Global	236.28	265,658.08	13%
Tendencia lineal	Mensual	—	—	6.90%
	Semanal	—	—	4.70%
Suavización Exponencial Simple (SES)	Diario	168.7	239.3	3.90%
	Semanal	36.16	36.16	0.76%
	Mensual	168.7	239.3	3.90%
	Anual	36.16	36.16	0.76%
Holt-Winters	Diario	—	—	—
	Semanal	179.7	275.6	4.10%
	Mensual	136.4	155.6	3.01%
SARIMA	Diario	277.121	500.34	19.06%
	Semanal	280.619	645.18	6.32%
	Mensual	2.073	3.521	0.05%

Discusión

Los resultados obtenidos luego de aplicar los diferentes modelos cuantitativos (SES, Holt-Winters y SARIMA) y el modelo cualitativo (Delphi), presentan como principal hallazgo la determinación de que no es correcto aseverar que un método es mejor que otro y que debe ser aplicado para predicciones de cualquier tipo de temporalidad, es propicio recalcar que todo depende de la naturaleza de los datos, las escalas temporales, comportamientos y elementos diferenciadores. En el caso de la demanda eléctrica, los métodos cuantitativos superan el cualitativo. Pero si se analiza en horizontes temporales para la demanda diaria, de acuerdo a los niveles de error obtenidos se determina que el que logró mayor precisión fue el de Suavización Exponencial Simple (SES) con 3.90% en el valor del MAPE y el que obtuvo menor precisión y valores de errores elevados fue SARIMA con MAPE de 19.06%, demostrando que en los datos analizados, mientras mayor sea la variabilidad y la capa temporal corta como en el caso de la demanda diaria, el método SARIMA



no demostró eficiencia aceptable. En la temporalidad semanal el modelo SES conserva el nivel de error más bajo con el MAPE de 0.76%, en segundo lugar Holt-Winters con el MAPE de 4.10%, en tercer lugar la tendencia lineal con MAPE 4.70% y SARIMA en cuarto lugar con un valor de 6.32%, demostrando que los métodos como el de suavización simple se alinea de forma más precisa a datos con alto índice de volatilidad, por su parte los modelos que incluyen elementos auto regresivos pierden capacidad predictiva si los datos no son estables y poseen picos marcados generando datos atípicos.

El panorama mensual los resultados difieren y el modelo SARIMA logra el MAPE más bajo de 0.05%, generando una diferencia significativa y remarcando que la eficiencia se maximiza con datos más estables, lo que refleja dependencia estructural de la serie es decir SARIMA predice con mayor eficiencia cuando hay elementos de estacionalidad debido a que los otros modelos no capturan oscilaciones sistémicas derivadas de la naturaleza de los datos estudiados.

Los resultados se alinean con investigaciones recientes como la efectuada por [19] quienes luego de su estudio al comparar los modelos de pronóstico, estableció que SARIMA es un modelo destacado frente a otros cuando los datos mantienen estacionalidad persistente y clara y teniendo especial precisión en temporalidades mensuales.

El método cualitativo se posiciona más como una herramienta de respaldo complementaria, que si bien no refleja precisión elevada en métricas específicas sirve para fundamentar las predicciones concordando con la investigación [20] que determina que los modelos de predicción en series de tiempo como el caso de Holt-Winters/SARIMA que evalúan o emplean elementos de horizontes temporales y el nivel de error que surja, se puede complementarse por el método Delphi, especialmente para factores que no son integrados por datos históricos, como paralizaciones, ampliaciones o reducciones de turnos, periodos de mantenimiento, etc.

Definitivamente se rechaza la hipótesis nula y H_0 y se acepta la hipótesis alternativa H_1 puesto que se comprueba que la aplicación de modelos de pronóstico incrementa la precisión en la proyección de demanda pudiendo influir en la optimización de costos operativos industriales.

Conclusiones

La investigación refleja que al determinar el grado de precisión de los modelos de predicción especialmente cuando son modelos cuantitativos un elemento determinante es la temporalidad del análisis, es necesario considerar el horizonte temporal aplicado, puesto que influye directamente en el nivel de error debido a la variabilidad de los datos empleados. Los modelos cuantitativos superan al cualitativo en términos de precisión, resaltando que las técnicas estadísticas generan pronósticos más confiables para la toma de decisiones. Al analizar los modelos aplicados el Delphi o cualitativo, obtuvo el mayor error 13%, seguido por el de tendencia lineal con errores de 6,9% en predicción mensual y 4,7% en semanal, El modelo Holt-Winters se mantuvo en el nivel medio de error con valores de 3,01% en el periodo mensual y 4,10% en el periodo semanal. El modelo SARIMA obtuvo el mejor desempeño de predicción con valores de error MAE de 2.073, RMSE 3.521 y MAPE 0.05% en temporalidad mensual.

Finalmente, se acota que no existe un método que demuestre superioridad en todas las temporalidades de estudio, por esta razón la elección del modelo a aplicar debe hacerse en función de los elementos intrínsecos que incluyen datos para el análisis, como las temporalidades, la combinación de métodos la mejor alternativa, en el caso de estudio el método SES que se ajusta mejor para temporalidades cortas como diarias o semanales, SARIMA para horizontes más amplios como la demanda mensual y/o anual y el método cualitativo como un respaldo o complemento.

Referencias bibliográficas

- [1] N. A. Nguyen Thi, A. Nguyen Nhat, T. Tran Ngoc, S. Vijender Kumar, R. González Crespo, y N. Quang Dat, “Online SARIMA applied for short-term electricity load forecasting”, *Applied Intelligence* , vol. 54, núm. 1, pp. 1003–1019, dic. 2023, <https://doi.org/10.1007/S10489-023-05230-Y>.
- [2] L. Jaramillo, C. Alarcón, y M. Yépez, “Programación macroeconómica 2025 - 2028”, Qutio, 2025. Consultado: el 25 de junio de 2025. [En línea]. Disponible en: https://www.finanzas.gob.ec/wp-content/uploads/downloads/2025/04/Programacio%CC%81n-Macroecono%CC%81mica-2025-2028_VersionFinalEnvio_15042025.pdf



- [3] P. Pena, G. Ermida, y C. Zoppolo, “Procesamiento de Datos Históricos para la Proyección de Demanda Eléctrica”, *2018 IEEE 9th Power, Instrumentation and Measurement Meeting, EPIM 2018*, vol. 53, pp. 38–46, nov. 2021, <https://doi.org/10.1109/EPIM.2018.8756349>.
- [4] R. Montero Laurencio, O. Torres Breff, S. Marrero Ramírez, y D. Jiménez Jiménez, “Predicción de Consumo y Demanda de Electricidad Mediante Redes Neuronales Artificiales y Algoritmo Iterativo”, *Revista Politénica*, vol. 54, núm. 3, pp. 45–57, 2024, Consultado: el 16 de enero de 2026. [En línea]. <https://doi.org/10.33333/rp.vol54n3.05>.
- [5] G. Apeksha, M. Anirban, y K. Chaitanya, “AI-Based Demand Sensing: Improving Forecast Accuracy in Supply Chains.”, *Journal of Informatics Education and Research*, vol. 14, núm. 9, 2024, <https://doi.org/10.52783/JIER.V4I2.1205>.
- [6] M. Seyedan y F. Mafakheri, “Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities”, *Journal of Big Data 2020 7:1*, vol. 7, núm. 1, pp. 1–22, jul. 2020, <https://doi.org/10.1186/S40537-020-00329-2>.
- [7] Z. Dou, Y. Sun, Y. Zhang, T. Wang, C. Wu, y S. Fan, “Regional manufacturing industry demand forecasting: A deep learning approach”, *Applied Sciences (Switzerland)*, vol. 11, núm. 13, jul. 2021, <https://doi.org/10.3390/APP11136199>.
- [8] J. Rodríguez León y M. Pachón Rincón, “Estudio de pronóstico para la planeación, caso de estudio empresa distribuidora del sector farmacéutico”, *Revista UIS ingenierías*, vol. 20, núm. 4, pp. 59–78, 2021, <https://doi.org/10.18273/revuin.v20n4-2021005>.
- [9] Diccionario de la Lengua Española, “pronóstico | Definición | Diccionario de la lengua española | RAE - ASALE”. Consultado: el 2 de julio de 2025. [En línea]. Disponible en: <https://dle.rae.es/pron%C3%B3stico>
- [10] W. Gilstrap, “Por qué es importante la previsión de la demanda: Guía para el éxito empresarial”. Consultado: el 9 de julio de 2025. [En línea]. Disponible en: https://www.inventory-planner.com/why-demand-forecasting-important/?utm_source=chatgpt.com
- [11] Intitute for Supply Management, “Optimización de la previsión de la demanda: desafíos y mejores prácticas”. Consultado: el 9 de julio de 2025. [En línea]. Disponible en: <https://www.ismworld.org/supply-management-news-and-reports/news-publications/inside-supply-management-magazine/blog/2024/2024-03/optimizing-demand-forecasting-challenges-and-best-practices/>
- [12] J. Casanova Terán, “Pronósticos para la toma de decisiones”, *Revista Semestre Económico*, pp. 120–140, 2021. Consultado: el 2 de julio de 2025. [En línea]. Disponible en: <https://revistas.udem.edu.co/index.php/economico/es/article/view/1435/1520>
- [13] P. Ugbehe, O. Diemuodeke, y D. Aikhuele, “Electricity demand forecasting methodologies and applications: a review”, *Sustainable Energy Research 2025 12:1*, vol. 12, núm. 1, pp. 1–32, abr. 2025, <https://doi.org/10.1186/S40807-025-00149-Z>.
- [14] C. Á. Fierro Torres, V. H. Castillo Pérez, C. I. Torres Saucedo, C. Á. Fierro Torres, V. H. Castillo Pérez, y C. I. Torres Saucedo, “Análisis comparativo de modelos tradicionales y modernos para pronóstico de la demanda: enfoques y características”, *RIDE. Revista Iberoamericana para la*



- Investigación y el Desarrollo Educativo*, vol. 12, núm. 24, p. 354, jun. 2022, <https://doi.org/10.23913/RIDE.V12I24.1203>.
- [15] B. Peak *et al.*, “Peak Electrical Energy Consumption Prediction by ARIMA, LSTM, GRU, ARIMA-LSTM and ARIMA-GRU Approaches”, *Energies 2023, Vol. 16, Page 4739*, vol. 16, núm. 12, p. 4739, jun. 2023, <https://doi.org/10.3390/EN16124739>.
- [16] Y. Sanchez Henao, “Propuesta para la selección de parámetros de modelos de pronóstico mediante ponderación de indicadores claves de desempeño: Caso suavización exponencial”, Universidad EAFIT, Medellín, 2021. Consultado: el 2 de julio de 2025. [En línea]. Disponible en: <https://repository.eafit.edu.co/server/api/core/bitstreams/2c9d6124-95b6-4d0a-aab2-59144678bcf7/content>
- [17] A. Bandlamudi, “Household Energy Consumption Forecasting Using LSTM and ARIMA Models: A Comprehensive Analysis”, *Res. Sq.*, vol. 1, núm. 12, pp. 1–37, ene. 2025, <https://doi.org/10.21203/RS.3.RS-5916961/V1>.
- [18] B. Olalekan Ariyo, L. Mutalub Adesina, O. Ogunbiyi, A. Musa, B. J. Ojuolape, y M. Omolara Balogun, “AI-driven demand forecasting for enhanced energy management in renewable microgrids: A hybrid lstm-cnn approach”, *JOURNAL OF ENGINEERING RESEARCH AND REVIEWS*, vol. 2, núm. 1, pp. 1–11, 2025, <https://doi.org/10.5455/JERR.20241007042800>.
- [19] M. Mohammad Awad, A. Rafed Khaldoun, A. Baraa Mohammad, y N. Mohammad Ayman, “Comparative Analysis of ARIMA and SARIMA Models in Electrical Load Forecasting: Insights for Long and Short-Term Projections”, *International Journal of Electrical Engineering and Computer Science*, vol. 7, núm. 2025, pp. 83–89, 2025, <https://doi.org/10.37394/232027.2025.7.8>.
- [20] A. Thamer Mustafa, O. Sharaf Al, y D. Al-Yozbaky, “Forecasting energy demand and generation using time series models: A comparative analysis of classical, grey, fuzzy, and intelligent approaches”, *Franklin Open*, vol. 12, núm. 2025, p. 100350, sep. 2025, <https://doi.org/10.1016/J.FRAOPE.2025.100350>.

Conflicto de intereses:

Los autores declaran que no existe conflicto de interés posible.

Financiamiento:

No existió asistencia financiera de partes externas al presente artículo.

Agradecimiento:

N/A

Nota:

El artículo no es producto de una publicación anterior.