Desempeño comparativo de Holt-Winters y Prophet en la predicción de la demanda eléctrica en sistemas de distribución y alumbrado público

Comparative Performance of Holt-Winters and Prophet in Forecasting Electricity Demand in Distribution Systems and Public Lighting

Galo Tapia Estrella[1], Nancy Rodríguez Sánchez[2], Carlos Ramiro Corrales Tapia[3], Alex Danilo Panchi Guamangallo[4], Mauricio Eduardo Mullo Pallo[5]

[1]Instituto Superior Tecnológico Tungurahua, Tungurahua, Ambato, Ecuador; gtapia@institutos.gob.ec
[2]Universidad Tecnológica Indoamérica, Facultad de ingenierías, Ambato, Tungurahua, Ecuador; nancyrodriguez@uti.edu.ec
[3]Instituto Superior Tecnológico Tungurahua, Tungurahua, Ambato, Ecuador; ccorrales.istt@institutos.gob.ec
[4]Empresa Eléctrica Provincial Cotopaxi S.A, Cotopaxi, Latacunga, Ecuador; alex.panchi@elepcosa.com.ec
[5]Universidad Técnica de Cotopaxi, Facultad de Ciencias de la Ingeniería y Aplicadas, Cotopaxi, Latacunga, Ecuador; mauricio.mullo@utc.edu.ec

DOI: https://doi.org/10.61236/qd0p8f87

Recibido: 30 de julio de 2026 – Revisión aceptada: 04 de octubre de 2026

Resumen

El pronóstico de demanda eléctrica apoya la planificación operativa y las decisiones de eficiencia energética en sistemas de distribución. Este artículo compara los modelos Holt-Winters aditivo y Prophet aplicados a la demanda de alumbrado público en Cotopaxi, Ecuador, utilizando un inventario institucional de 52 365 luminarias del periodo 2012-2020. El inventario se transformó en una serie mensual de energía teórica mediante depuración de datos, cálculo energético basado en calendario y una regla dinámica de reemplazo tecnológico para la transición de lámparas de mercurio y sodio hacia LED. Los modelos se implementaron en Python y se evaluaron con MAPE, RMSE y R^2. Holt-Winters obtuvo menor error de corto plazo, mientras que Prophet representó mejor el cambio estructural LED de 2019; por ello, ambos modelos son útiles de forma complementaria para la planificación operativa y estratégica.

Palabras claves: *demanda eléctrica; redes de distribución; alumbrado público; pronóstico; Holt-Winters; Prophet.*

Abstract

Accurate electricity demand forecasting supports operational planning and energy-efficiency decisions in distribution systems. This study compares the additive Holt-Winters and Prophet models applied to public lighting demand in Cotopaxi, Ecuador, using an institutional inventory of 52,365 luminaires from 2012 to 2020. The inventory was transformed into a monthly theoretical energy series through data cleaning, calendar-based energy calculation and a dynamic replacement rule for the transition from mercury and sodium lamps to LED technology. The models were implemented in Python and evaluated with MAPE, RMSE and R^2. Holt-Winters obtained lower short-term error,

whereas Prophet better represented the 2019 LED structural change; therefore, both models are useful for complementary operational and strategic planning.

Keywords: *electricity demand; distribution networks; public lighting; forecasting; Holt-Winters; Prophet.*

DOI: https://doi.org/10.61236/qd0p8f87

1. INTRODUCCIÓN

La gestión eficiente de sistemas eléctricos de distribución requiere pronósticos de demanda suficientemente precisos para programar la operación, dimensionar recursos y reducir desviaciones entre energía prevista y energía requerida. En sistemas con alta densidad de cargas de iluminación pública, la predicción temporal permite estimar el suministro futuro, evaluar la eficiencia de los programas de migración de tecnologías y apoyar propuestas de expansión o mantenimiento de la red [1], [3], [5], [8].

En este caso, el costo de un pronóstico impreciso no se limita al error estadístico: también puede trasladarse al despacho, a las compras de corto plazo y al uso de generación de respaldo. El problema se vuelve más evidente al analizar programas de eficiencia, porque un recambio tecnológico modifica la pendiente de la serie y puede confundirse con una variación ordinaria del consumo. En este sentido, la comparación debe considerar el error de predicción y la respuesta de cada modelo ante cambios estructurales [5], [8], [11], [18].

1.1. Estado del arte y fundamentación bibliográfica

Para la comparación de la presente investigación, se ha revisado bibliografía la cual se catalogó en dos grupos. El primer grupo es sobre ARIMA, suavización exponencial y Holt-Winters los cuales son métodos que no tienen requerimientos computacionales altos, son de fácil interpretación y son bastante fiables cuando se tienen patrones estables de estacionalidad [4]-[6], [8], [11], [15], [16]. El segundo grupo de bibliografía abarca regresiones, métodos de autoaprendizaje y modelos aditivos. Estos métodos ofrecen una mayor flexibilidad ante cambios abruptos de tendencia, relaciones que no son lineales o registros con datos incompletos, aunque exigen más parámetros para su modelación [1], [7], [12], [13].

1.2. Sustento matemático de los modelos de predicción

Cuando se analizó la base de datos de luminaria, el inventario de dichas luminarias presento dos retos. Primeramente, la serie derivada del inventario de luminaria conserva su nivel, tendencia y sus ciclos anuales; también, la sustitución de luminarias introduce quiebres que no

DOI: https://doi.org/10.61236/qd0p8f87

obedecen a la estacionalidad. Por ese motivo existe un contraste entre la la suavización exponencial triple y un modelo aditivo con puntos de cambio: el primer modelo muestra regularidades que se mantienen y el segundo ofrece flexibilidad frente a migración de tecnología de las lámparas [7], [8], [15], [16].

Suavización exponencial triple (Holt-Winters)

En este método de Holt-Winters, las nuevas observaciones modifican de forma recursiva los estados que representan la serie. Para esta especificación aditiva empleada, los estados son: el nivel (S_t), la tendencia (T_t) y el componente estacional (I_t). Se escoge este método es adecuado para una serie que su ciclo anual conserve una amplitud relativamente estable, en lugar de crecer en proporción al nivel [8], [15], [16].

A continuación se muestran las variables de estado usadas en la serie (1)-(4):

Nivel:

$$S_t = \alpha(X_t - I_{t-s}) + (1 - \alpha)(S_{t-1} + T_{t-1}) \quad (1)$$

Tendencia:

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1} \quad (2)$$

Estacionalidad:

$$I_t = \gamma(X_t - S_t) + (1 - \gamma)I_{t-s} \quad (3)$$

Ecuación de pronóstico:

$$\hat{X}_{t+m} = S_t + mT_t + I_{t-s+m} \quad (4)$$

Donde X_t representa la demanda observada en el mes t; $\hat{X}_{t+m}$ es el pronóstico para m meses adelante; S_t es el nivel suavizado; T_t es la tendencia; I_t es el índice estacional; s es la longitud del ciclo estacional, definida como 12 meses; y α, β y γ son parámetros de suavizado restringidos al intervalo (0,1). El subíndice t identifica el periodo actual, t-1 el periodo previo y t-s el periodo equivalente del ciclo estacional anterior.

Modelo Facebook Prophet

El modelo Prophet se basa en una formulación de regresión aditiva que se descompone la serie temporal y(t) en los componentes interpretables de la tendencia, estacionalidad, eventos especiales y error aleatorio, según (5). Esta estructura facilita el análisis de series con cambios de pendiente, datos faltantes e incertidumbre creciente en horizontes de predicción extendidos [7], [21].

Modelo general:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (5)$$

En esta ecuación, y(t) es la demanda estimada en el instante t; g(t) representa la tendencia de largo plazo y sus cambios de pendiente; s(t) modela la estacionalidad periódica mediante series de Fourier; h(t) incorpora eventos especiales cuando existen; y ε_t que representa el error. Una diferencia entre Holt-Winters y Prophet, es

DOI: https://doi.org/10.61236/qd0p8f87

que este último incorpora los denominados puntos de cambio (changepoints) que permiten representar variaciones abruptas en la tendencia, esto gana relevancia en aquellos escenarios en que exista migración de tecnologías en las luminarias.[7], [21].

1.3. Descripción del trabajo desarrollado

El objetivo del presente estudio es definir la demanda teórica en el alumbrado público de la provincia de Cotopaxi. La serie no proviene de ventas o requisiciones teóricas, solo de una base de datos consolidada y se reconstruyó a partir de 52 365 registros del inventario institucional entre 2012 y 2020. Para cada luminaria se consideró la potencia nominal, la tecnología instalada y la fecha tentativa de mantenimiento. Los datos de cada equipo permitieron representar el descenso de la demanda energética asociada a la sustitución de lámparas de mercurio y sodio por lámparas más modernas [19].

Para el análisis se ejecutaron tres tareas:

Cálculo dinámico de potencia:

En cada lampara se consideró para el cálculo del consumo hasta que en algún registro aparezca la migración de tecnología, en ese caso se sustituyen las potencias para el cálculo. De esa manera, la disminución por cambio de tecnología LED aparece en la fecha correspondiente al cambio y no como una reducción lineal impuesta a toda la serie.

Evaluación comparativa:

Con la serie definida se procedió a ajustar los parámetros de Holt-Winters y Prophet, de esa manera se generaron proyecciones mensuales para el intervalo comprendido entre 2021 y 2025. La comparación se centró en observar cómo responde cada método a los cambios introducidos por las sustituciones de las lámparas, nunca dejando de lado el incremento por expansiones de red.

Validación de precisión:

El desempeño se midió usando métodos estadísticos, en este caso calculando valores de MAPE, RMSE y R^2. Las dos primeras métricas cuantifican el error desde escalas distintas, mientras que R^2 muestra la variación que pueden producir ajustes. Estos valores definen la efectividad de los modelos frente a cambios que suscitan en la serie.

METODOLOGÍA

El presente estudio es cuantitativo y descriptivo, ya que se realizó la comparación de dos métodos de estimación sobre la misma seri, la cual es una serie de consumo del alumbrado público. El procedimiento siguió cuatro etapas

DOI: https://doi.org/10.61236/qd0p8f87

secuenciales: la primera es la depuración del inventario, luego la reconstrucción mensual de la energía teórica, posteriormente el ajuste computacional de Holt-Winters y la estimación usando el algoritmo de Prophet, por último se realizó la validación temporal mediante métricas de error y ajuste [8], [20], [21].

1.4. Adquisición y Caracterización del Dataset

Para este paso, se ha construido la demanda mensual desde el inventario técnico de ELEPCO S.A.. El archivo contenía 52 365 registros de luminarias instaladas en Cotopaxi durante desde el año 2012 hasta el 2020. Debido a su origen institucional, se trabajó con datos anónimos y solo para fines académicos.

El inventario contiene el código de la luminaria, ubicación, la potencia original, la potencia posterior a la su sustitución cuando sea el caso, la tecnología (sodio, mercurio o LED) y la fecha de posible mantenimiento. Antes de calcular energía se eliminaron elementos duplicados, se coloco todas las potencias en watt ya que en el inventario existían pocos casos en que estaban las potencias en otras unidades y se llevó la fecha a escala mensual. También se descartaron registros sin potencia válida y se contrastaron los valores extremos con rangos técnicos propios del alumbrado público. Cuando una luminaria presento inconsistencias, se opto por eliminarla de ;a serie.

1.5. Construcción de la Demanda Teórica Mensual

Al momento de convertir la base de datos a la serie temporal, se lo realizo lampara por lampara. Para cada mes se calculó la energía teórica consumida por cada luminaria y, posteriormente, se sumaron los resultados. La energía mensual E_m del conjunto de n luminarias se obtuvo (6):

$$E_m = \sum_{i=1}^{n} (P_{i,m}\, h_m\, d_m) / 1000 \quad (6)$$

En (6), $P_{i,m}$ corresponde a la potencia en watts de la luminaria i durante el mes m; h_m, a las horas diarias de encendido consideradas para ese mes; y d_m, a sus días calendario. El índice n representa las luminarias activas y la división por 1000 convierte Wh en kWh. Se tomo en cuenta el número de días que tiene cada mes para conservar la diferencia de los años bisiestos y evitar una duración mensual fija de 30.4 días que usualmente usan algunas estimaciones.

La potencia asignada a cada luminaria depende de la base de datos, desde el mes de intervención, se cambia la potencia por la potencia de reemplazo.

DOI: https://doi.org/10.61236/qd0p8f87

1.6. Implementación del Modelo Holt-Winters (HW)

Holt-Winters se ajustó mediante la clase ExponentialSmoothing de la librería statsmodels. Se especificaron tendencia y estacionalidad de forma aditiva, con un periodo estacional de 12 meses. Esta configuración conserva por separado el nivel, la pendiente y el ciclo anual de la serie [8], [20].

Para la variante aditiva, la serie mensual construida presenta un ciclo anual regular y una amplitud estacional aparentemente estable; por ello se utilizó la forma aditiva, la cual se recomienda cuando el componente estacional no crece proporcionalmente con el nivel de la serie [8], [15], [16].

El ajuste actualiza con cada iteración el nivel S_t, la tendencia T_t y el índice estacional I_t según (1)-(4). En vez de de fijar α, β y γ de forma manual, se trabajó con la optimización numérica implementada por la librería.

Los estados iniciales también se estimaron con el procedimiento disponible de statsmodels, de esa manera se minimiza el error cuadrático durante el entrenamiento. Con los parámetros definidos se calcularon 60 valores mensuales, desde enero de 2021 hasta diciembre de 2025.

1.7. Implementación del Modelo Facebook Prophet

Prophet se implementó como segundo método ya que admite una tendencia no lineal y cambios de pendiente dentro de una estructura aditiva. En este estudio se buscaba comprobar si la flexibilidad capturaba el efecto de la sustitución tecnológica de las lámparas en el consumo de alumbrado público [7], [21].

Aquí se incluyó estacionalidad anual y la detección automática de puntos de sustitución de luminarias. Por lo tanto, la pendiente de la serie no fue constante durante todo el grafico histórico, sino que pudo modificarse en los meses donde la serie mostró un cambio significativo.

La implementación según la expresión (5) para la demanda se representa como la suma de parámetros que representan: tendencia, estacionalidad, eventos y el error [23].

En la ecuación, g(t) representa la tendencia y todas sus variaciones; s(t), representa el ciclo anual aproximado con series de Fourier; h(t) representa los eventos que se decida incorporar y ε_t, la parte no explicada que se puede interpretar como el error. La estimación de Prophet se enfoca en dos resultados observables: si ubicaba el cambio de régimen asociado con la sustitución de

DOI: https://doi.org/10.61236/qd0p8f87

lámparas y si reducía el sesgo de la trayectoria después de 2019.

1.8. Criterios de Evaluación y Validación

La validación respondió a dos preguntas: cuánto se alejaba cada pronóstico de la observación y si la diferencia entre modelos podía atribuirse al azar muestral. Para la primera se calcularon MAPE, RMSE y R^2; para la segunda se aplicó la prueba de Diebold-Mariano. En conjunto, las métricas describen error relativo, penalización de desviaciones excesivas, capacidad explicativa y significancia estadística [8], [17], [18].

MAPE (Error Porcentual Absoluto Medio) se adoptó como lectura principal del error ya que expresa la desviación en porcentaje. Los límites en el modelo corresponden al menor y al mayor valor obtenidos en la validación de origen en la base de datos de 2019-2020.

RMSE (Raíz del Error Cuadrático Medio). Se empleó por su sensibilidad ante errores de gran magnitud y se reportó en kWh, que corresponde a la unidad de la serie mensual de energía.

R^2 (Coeficiente de determinación). Se incorporó para evaluar la capacidad explicativa del modelo y su respuesta ante el cambio estructural observado durante la transición LED.

Prueba Diebold-Mariano (DM). Para comprobar si la diferencia de exactitud entre Holt-Winters y Prophet fue estadísticamente significativa, se compararon los errores fuera de muestra mediante la prueba de Diebold-Mariano, usando como función de pérdida principal el error absoluto y un nivel de significancia del 5 % [17].

$$d_t = L(eHW,_t) - L(eP,_t), \quad DM = \bar{d} / \sqrt{(\hat{\sigma}^2 d / n)} \tag{10}$$

Donde d_t es el diferencial de pérdida en el mes t; $eHW,_t$ y $eP,_t$ son los errores de Holt-Winters y Prophet; $L(\cdot)$ representa la función de pérdida; $\bar{d}$ es el promedio de los diferenciales; $\hat{\sigma}^2 d$ es la varianza estimada del diferencial de pérdida; y n es el número de observaciones de validación.

La ejecución técnica se realizó en Python 3.x mediante scripts reproducibles. Se emplearon pandas y numpy para depuración y agregación mensual de datos; statsmodels para Holt-Winters; prophet para el modelo Prophet; y matplotlib para la generación de gráficas. La formulación matemática se trasladó al algoritmo mediante una secuencia de lectura, validación, cálculo de energía, partición entrenamiento-validación, ajuste de modelos, predicción y cálculo de métricas. La Fig. 1 resume el flujo computacional aplicado [20], [21].

DOI: https://doi.org/10.61236/qd0p8f87

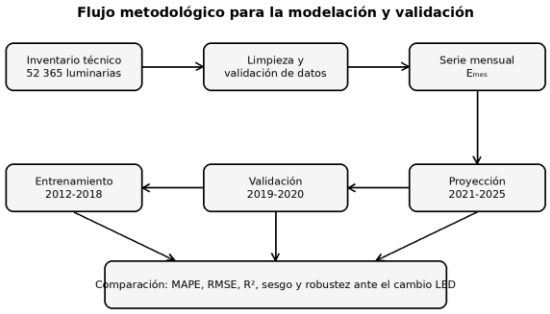


Figura 1 Diagrama de flujo de la implementación computacional de los modelos.

2. ANÁLISIS DE RESULTADOS

En esta sección se presentan los resultados derivados de la aplicación de los modelos Holt-Winters y Prophet para proyectar la demanda de alumbrado público de Cotopaxi en el horizonte 2021-2025. Para el presente análisis se toman en cuenta dos criterios: primero la precisión del ajuste validando fuera de muestra y segundo la capacidad de cada modelo para representar la migración tecnológica de lámparas antiguas a tecnología de luminarias LED.

2.1. Proceso de modelación y entrenamiento

Para la simulación de los modelos prospectivos, se usaron series temporales mensuales de 103 observaciones, para el intervalo de tiempo comprendido entre junio de 2012 y diciembre de 2020, esto debido al procesamiento de la base de datos de los 52 365 registros de luminarias.

La configuración de Holt-Winters (HW) se implementó con un modelo de suavización exponencial triple usando una tendencia y estacionalidad aditivas. El periodo estacional fue de s = 12 meses, valor que representa el ciclo anual de la luminaria pública.

La configuración de Prophet se empleó con un enfoque de regresión aditiva generalizada con estacionalidad anual y detección automática de changepoints. Esta configuración permitió que el modelo reconociera el quiebre de tendencia iniciado en 2019 por la migración masiva a tecnología LED.

Para el horizonte de predicción ambos modelos fueron configurados para generar 60 proyecciones mensuales, correspondientes al periodo enero de 2021-diciembre de 2025.

2.2. Análisis de las gráficas prospectivas

El estudio de las gráficas es fundamental para comprender la divergencia entre los enfoques estadísticos y de aprendizaje automático ante cambios estructurales en la red.

DOI: https://doi.org/10.61236/qd0p8f87

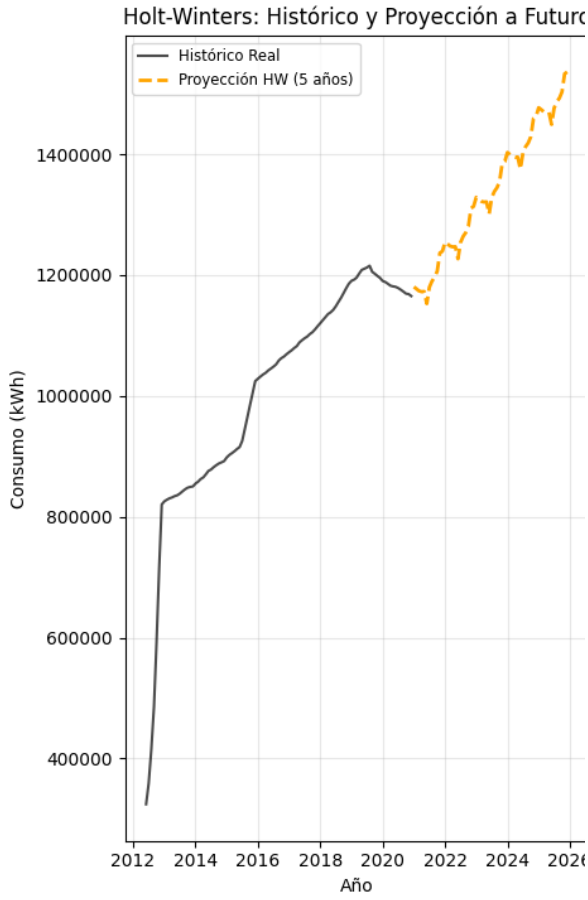


Figura 2 Proyección según el modelo de Holt-Winters

Gráfica de proyección Holt-Winters (Fig. 2) muestra la visualización muestra variaciones estacionales regulares y una tendencia ascendente moderada. El modelo HW mantiene la inercia estadística del periodo 2012-2018 y proyecta recuperación del consumo después de 2020. Este comportamiento es coherente con modelos recursivos que priorizan estabilidad en los parámetros de suavizado.

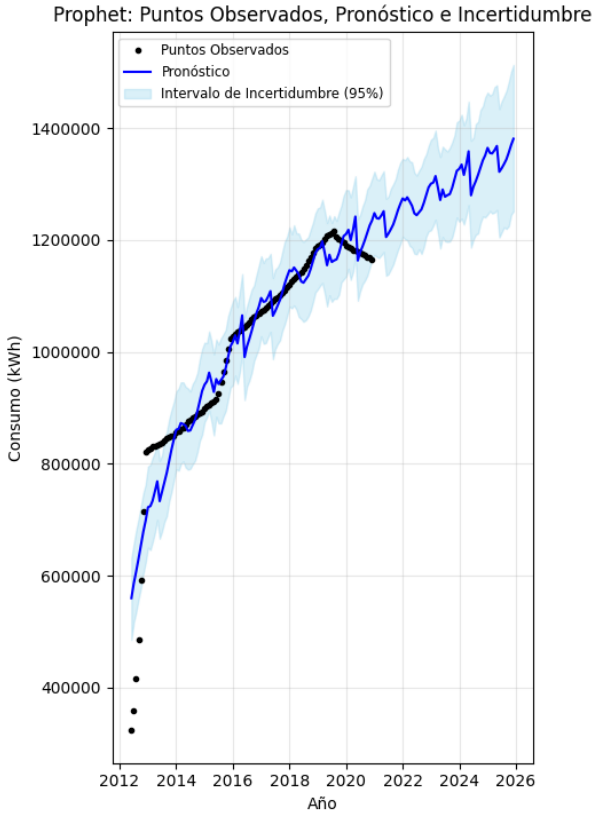


Figura 3 Proyección según el modelo Prophet

Gráfica de proyección Prophet (Fig. 3) muestra la curva de tendencia se ajusta bien a la saturación del consumo y presenta algunas bandas de incertidumbre que se amplían conforme aumenta el horizonte de pronóstico. Prophet identifica el periodo 2019-2020 como un cambio de régimen técnico, proyectando un crecimiento más moderado y compatible con la incorporación de luminarias eficientes.

DOI: https://doi.org/10.61236/qd0p8f87

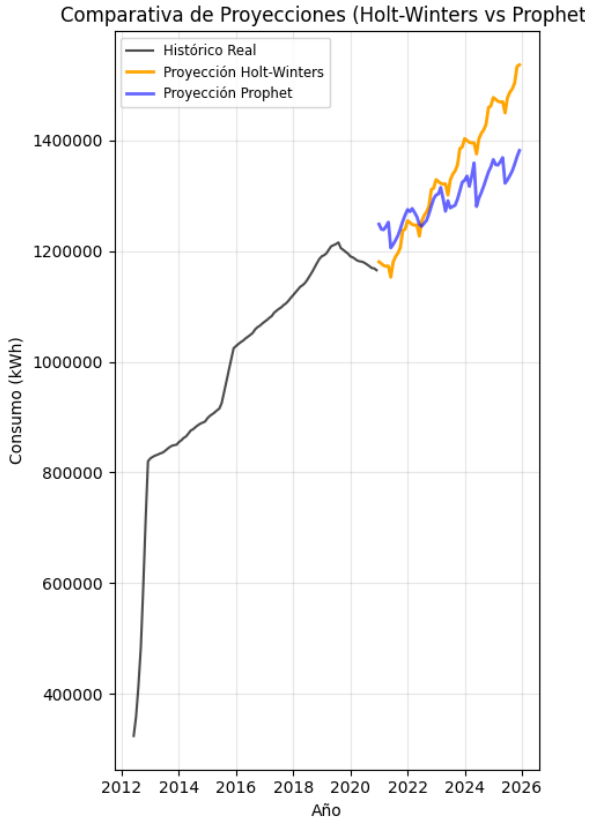


Figura 4 Comparativa de los métodos prospectivos

La superposición de la Fig. 4 permite observar dos comportamientos. Holt-Winters estima con mayor cercanía los "picos" y "valles" mensuales, dando resultados relativamente coherentes según su menor MAPE de corto plazo. Prophet, en contraste, deja de prolongar la pendiente previa a 2019 y sigue su estabilización asociada con el cambio de luminarias a tecnología LED. Por tanto, existe una ventaja absoluta: la elección cambia según se utilice el seguimiento mensual o la representación del quiebre tecnológico.

2.3. Métricas de evaluación y validación

Las métricas se prepararon para mostrar el error desde tres ángulos. MAPE muestra la desviación relativa, RMSE da mayor peso a los errores de gran magnitud y R^2 resume la proporción de variabilidad reproducida por el modelo. Gracias a esta combinación de parámetros se puede comparar los ajustes de Cotopaxi sin reducir la decisión a un único indicador [8], [18].

Ahora se definen los valores estadísticos usados:

El Error Porcentual Absoluto Medio (MAPE) permite interpretar el error promedio en términos porcentuales y comparar la precisión entre periodos o escenarios de distinta escala. Se define en (7):

$$MAPE = (100/n) \sum_{t=1}^{n} |(X_t - \hat{X}_t) / X_t| \quad (7)$$

Donde X_t es el valor observado, $\hat{X}_t$ es el valor pronosticado y n es el número de observaciones evaluadas.

Raíz del Error Cuadrático Medio (RMSE). Penaliza con mayor intensidad los errores grandes al elevar las diferencias al cuadrado antes de promediarlas. Se expresa en (8):

$$RMSE = \sqrt{[(1/n) \sum_{t=1}^{n} (X_t - \hat{X}_t)^2]} \quad (8)$$

Coeficiente de determinación (R^2). Mide la proporción de la variabilidad de los datos observados explicada por el modelo. Se calculó mediante (9):

DOI: https://doi.org/10.61236/qd0p8f87

$$R^2 = 1 - [\sum(X_t - \hat{X}_t)^2 / \sum(X_t - \bar{X})^2] \quad (9)$$

Donde $\bar{X}$ es el promedio de los valores observados en el conjunto de validación. Un valor de R^2 más cercano a 1 indica mayor capacidad explicativa.

Resultados comparativos de validación

La validación se realizó mediante un enfoque fuera de muestra con partición temporal. De las 103 observaciones mensuales disponibles, 79 observaciones (junio de 2012-diciembre de 2018; 76.7 %) se destinaron al entrenamiento y 24 observaciones (enero de 2019-diciembre de 2020; 23.3 %) se reservaron para validación. Esta partición se justificó porque el bienio 2019-2020 concentra el cambio tecnológico hacia LED y, por tanto, permite evaluar el comportamiento de los modelos ante una alteración estructural de la tendencia.

Los rangos de MAPE y RMSE reportados en la Tabla 1 no corresponden a corridas aleatorias, sino al mínimo y máximo obtenidos mediante validación de origen móvil dentro del conjunto 2019-2020, con horizontes mensuales sucesivos. El valor de R^2 se calculó sobre el conjunto total de validación de 24 observaciones.

Previo a la interpretación de los resultados se revisaron los residuos mediante los indicadores ACF/PACF y prueba de Ljung-Box con valor de rezago de 12. En ambos modelos no se identificó autocorrelación residual estadísticamente significativa al 5 % después de considerar tendencia y estacionalidad ($p > 0.05$), por lo que la comparación de errores fuera de muestra se consideró adecuada para el presente objetivo del estudio.

Tabla 1 Resumen de métricas de desempeño

Modelo	MAPE (%)	RMSE (kWh)	R^2	Uso técnico
HW aditivo	1.70-2.65	20 850-32 470	0.92	Operativo
Prophet	2.51-3.15	29 640-38 920	0.94	Estratégico
Naive	>10.0	>120 000	<0.60	Base

Nota: HW corresponde al modelo Holt-Winters aditivo. Los rangos de MAPE y RMSE corresponden a los valores mínimo y máximo obtenidos en la validación de origen móvil sobre el periodo 2019-2020; RMSE se expresa en kWh porque la variable modelada fue energía mensual. Los valores de Holt-Winters concuerdan con estudios donde la suavización exponencial alcanza errores bajos en series con estacionalidad estable [2], [5], [6]. Por otro lado, el R^2 de Prophet confirma que se tiene mayor capacidad para explicar el cambio estructural asociado con la transición LED.

3. DISCUSIÓN

Usando 24 meses de validación, la prueba de Diebold-Mariano aplicada a los errores absolutos mostró un DM = -2.16 y p = 0.041. Como se definió $d_t = L(eHW_{,t}) - L(eP_{,t})$, el signo negativo favorece a Holt-Winters. Al nivel del 5 %, el resultado permite obviar la

DOI: https://doi.org/10.61236/qd0p8f87

igualdad de precisión para el pronóstico mensual. Este hecho no vuelve inútil al modelo de Prophet: su R^2 y los puntos de cambio aun aportan información para interpretar el cambio de régimen técnico.

Resultados de pronosticabilidad

Los resultados no hacen evidente un único modelo dominante para todas las condiciones. Cuando el ciclo anual conserva su regularidad, Holt-Winters minimiza el error mensual y es más adecuado, pero cuando la serie cambia de pendiente, Prophet representa mejor esa transición y ofrece una lectura mejor de la incertidumbre [7], [8], [21].

En el conjunto fuera de muestra, Holt-Winters registró valores menores de MAPE y RMSE, adicionalmente reprodujo con mayor fidelidad la oscilación estacional. El resultado de Diebold-Mariano indica que esa ventaja en el horizonte mensual evaluado, no se explica solo por una variación aleatoria, debido a esto se considera la opción más directa para decisiones operativas de corto plazo [22].

Prophet, aunque presentó un MAPE ligeramente superior, alcanzó un R^2 más elevado y una trayectoria menos optimizada después de 2019, debido a esto se demuestra su robustez ante la transición de lámparas a tecnología LED, ya que el modelo identifica changepoints y evita la extrapolación indefinidamente y la tendencia histórica previa a la migración tecnológica de las lámparas a nuevas tecnologias.

De acuerdo a la Tabla 2, una la elección del modelo óptimo va a depender escencialmente del horizonte y el objetivo de la planificación:

Tabla 2 Criterios para la selección según aplicación

Requerimiento	Modelo recomendado	Justificación técnica
Precisión mensual	Holt-Winters	Menor MAPE en validación de corto plazo.
Transición LED	Prophet	Identifica changepoints y reduce sesgo posterior a 2019.
Planificación estratégica	Prophet	Incluye tendencia flexible e intervalos de incertidumbre.
Estabilidad operativa	Holt-Winters	Parámetros estables ante estacionalidad regular.

La implementación de estos modelos contribuye a la planificación energética al reducir la incertidumbre en la estimación de demanda y al facilitar la evaluación de programas de eficiencia. En lugar de asumir un crecimiento lineal permanente, el enfoque que aquí se propone nos permite distinguir entre aumento de carga, reducción de potencia instalada y la estabilización por la migración de las lámparas antiguas a tecnologías más modernas.

CC BY NC
DOI: https://doi.org/10.61236/qd0p8f87

4. CONCLUSIONES

- Al momento de proyectar los datos a futuro validando los datos de los años entre 2019 y 2020, el modelo de Holt-Winters fue mejor cuando se analizó las variaciones mensuales y obtuvo los menores valores de MAPE y RMSE. La prueba de Diebold-Mariano ($p = 0.041$) confirmó que la diferencia entre los errores absolutos favoreció a dicho modelo tomando en cuenta el horizonte operativo y los resultados del otro modelo analizado.

- Al momento de llegar al año 2019, existen datos de que las lámparas se cambiaron a tecnología LED. Prophet ajustó la pendiente mediante sus puntos de cambio y produjo una trayectoria más moderada después de que se cambien las lámparas a tecnología LED. Esta característica, junto con sus intervalos de incertidumbre, lo hace ideal para analizar escenarios de mediano plazo, aunque no sea tan bueno en intervalos mensuales, muestra de ello es que su error mensual es mayor al otro modelo.

- Reconstruir la demanda desde el inventario permitió vincular cada variación de potencia con la fecha de sustitución de la luminaria. Si se quisiera replicar el estudio en otra empresa distribuidora, se deben contar con datos actualizados, como mínimo, la potencia antes y después del cambio de luminarias, la tecnología anterior y nueva al momento del cambio y el mes de mantenimiento. Con esos datos se puede evaluar el efecto energético de una migración tecnológica o de una ampliación de la red de alumbrado público.

5. RECOMENDACIONES

Para el uso inmediato, los resultados sugieren dos análisis distintos. Holt-Winters puede ser la mejor herramienta para la programación mensual y el seguimiento de costos mientras que Prophet conviene como contraste cuando se analizan recambios tecnológicos o escenarios con cambios de pendiente. En trabajos posteriores se recomienda evaluar un esquema combinado y comprobar su desempeño con nuevas observaciones.

DOI: https://doi.org/10.61236/qd0p8f87

El horizonte superior a un año también debería incorporar información que el inventario de potencia no describe. Entre las variables a ser analizadas se encuentran datos como la expansión de cobertura, las horas reales de funcionamiento, la frecuencia con la que se ejecutan los mantenimientos, las expansiones de red y las políticas de sobre calidad y eficiencia energética. Su aporte debería medirse mediante validación de series temporales, no solo por la mejora del ajuste dentro de una muestra.

Finalmente, el modelo debería actualizarse al mismo ritmo que se actualiza el inventario de luminaria instalada. Un proceso de retroalimentación periódica permitirá registrar las nuevas intervenciones, además revisar los casos sin fecha de mantenimiento y recalcular los puntos de cambio. Sin este procedimiento, el error del pronóstico reflejara inevitablemente la limitación del método y el rezado de la base de datos.

6. AGRADECIMIENTOS

Los autores agradecen de manera especial a la Empresa Eléctrica Provincial Cotopaxi S.A. (ELEPCO S.A.) por el el acceso a la información técnica usada en el presente estudio.

7. BIBLIOGRAFÍA

[1] 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: estado del arte,” Revista Técnica Energía, 2024.
[2] E. J. Mejía Vásquez y S. Gonzales Chávez, “Predicción del consumo de energía eléctrica residencial de la Región Cajamarca mediante modelos Holt-Winters,” Ingeniería Energética, 2021.
[3] M. Muñoz García, D. Peña Banegas, J. Murillo Oviedo y F. Ortega Loza, “Análisis de los factores que condicionan la demanda energética en la Región Costa del Ecuador,” Revista Científica, 2022.
[4] I. O. Anaguano Pérez y F. F. Sandoya Sánchez, “Métodos basados en los modelos ARIMA estacional y Holt-Winters para la previsión de la demanda eléctrica a ultra corto plazo,” Revista Politécnica, 2020.
[5] J. W. Taylor, “Triple seasonal methods for short-term electricity demand forecasting,” European Journal of Operational Research, vol. 204, no. 1, pp. 139-152, 2010.
[6] E. S. Gardner Jr., “Exponential smoothing: The state of the art,” Journal of Forecasting, vol. 4, pp. 1-28, 1985.
[7] S. J. Taylor and B. Letham, “Forecasting at scale,” The American Statistician, vol. 72, no. 1, pp. 37-45, 2018, doi: 10.1080/00031305.2017.1380080.
[8] R. J. Hyndman y G. Athanasopoulos, Forecasting: Principles and Practice, 2nd ed. Melbourne, Australia: OTexts, 2018.

CC BY NC
DOI: https://doi.org/10.61236/qd0p8f87

[9] D. C. Montgomery, C. L. Jennings y M. Kulahci, Introduction to Time Series Analysis and Forecasting, 2nd ed. New Jersey, NJ, USA: John Wiley & Sons, 2015.
[10] G. E. P. Box y G. M. Jenkins, Time Series Analysis: Forecasting and Control. San Francisco, CA, USA: Holden-Day, 1976.
[11] O. Trull Domínguez, "Predicción a corto plazo de la demanda horaria de energía eléctrica en España mediante modelos optimizados de Holt-Winters múltiple-estacional," Trabajo de Fin de Máster, Univ. Politécnica de Valencia, Valencia, España, 2024.
[12] J. M. Sánchez López, "Pronóstico de consumo eléctrico y detección de anomalías mediante machine learning," Trabajo de Fin de Máster, Escuela Técnica Superior de Ingeniería, España, 2024.
[13] E. Romero Depablos, "Predicción del volumen neto de los desvíos generación/demanda (MW) de la red eléctrica de España," Trabajo de Fin de Máster, Univ. Europea de Madrid, Madrid, España, 2025.
[14] A. Toapanta Lema, "Comparación de modelos de regresión para la eficiencia en el consumo de electricidad en las escuelas ecuatorianas: un caso de estudio," Repositorio UISEK, Ecuador, 2020.
[15] C. C. Holt, "Forecasting seasonals and trends by exponentially weighted averages," O.N.R. Memorandum, vol. 52, Carnegie Institute of Technology, 1957.
[16] P. R. Winters, "Forecasting sales by exponentially weighted moving averages," Management Science, vol. 6, no. 3, pp. 324-342, 1960.
[17] F. X. Diebold and R. S. Mariano, "Comparing predictive accuracy," Journal of Business & Economic Statistics, vol. 13, no. 3, pp. 253-263, 1995, doi: 10.1080/07350015.1995.10524599.
[18] Secretaría de Energía, "Acuerdo por el que se emite el Manual de Pronósticos," Diario Oficial de la Federación, México, nov. 23, 2017.
[19] Agencia de Regulación y Control de Electricidad, "Regulación No. ARCONEL-006/18: Prestación del Servicio de Alumbrado Público General," Ecuador, 2018.
[20] Statsmodels Developers, "statsmodels.tsa.holtwinters.ExponentialSmoothing," documentación oficial, 2026. [En línea]. Disponible en: https://www.statsmodels.org/. Consultado: 2 jul. 2026.
[21] Meta Open Source, "Prophet: Forecasting at scale," documentación oficial, 2026. [En línea]. Disponible en: https://facebook.github.io/prophet/. Consultado: 2 jul. 2026.
[22] Gaón-Escobar K, Quinatoa-Caiza C, Proaño-Maldonado X, Mullo-Pallo M, "Advanced Statcom Integration Through Hybrid Co-Simulation for Stability Improvement in Power Systems," WSEAS Transactions on Power Systems, vol. 20, pp. 493-502, 2025, DOI:10.37394/232016.2025.20.39
[23]"Estimación Paramétrica del Modelo de Carga de Recuperación Exponencial Utilizando Mediciones Sincrofasoriales", *re*, vol. 22, no. 2, pp. PP. 65–74, Jan. 2026, doi: 10.37116/revistaenergia.v22.n2.2026.735.