

Métodos basados en los modelos ARIMA estacional y Holt-Winters para la previsión de la demanda eléctrica a ultra corto plazo

Methods based on seasonal ARIMA and Holt-Winters models for ultra short-term electricity demand forecasting.

Ian Oswaldo Anaguano Pérez* y Fernando Francisco Sandoya Sánchez

Recepción: 15/04/2024 Aceptación: 12/08/2024 Publicación: 30/01/2025

Resumen La alta variabilidad del consumo de electricidad presenta una dificultad para los operadores del sistema eléctrico, quienes deben enfrentarse a cambios rápidos e impredecibles en la demanda para asegurar un suministro continuo y estable. Por lo que en este trabajo, se presentan varios métodos prácticos destinados a modelar y pronosticar la demanda eléctrica en el ultracorto plazo. Los métodos propuestos son: ARIMA estacional y Holt-Winters, que se utilizan para la predicción de la demanda del día futuro, se evalúan algunas consideraciones prácticas para las ventanas de tiempo de ultracorto plazo. Para la implementación se utilizan datos de la demanda de electricidad del Sistema Nacional Interconectado del Ecuador con granularidad de 30 minutos. También se realiza una evaluación de los dos métodos de previsión en dos contextos temporales diferentes para determinar su efectividad y precisión en cada escenario. El método ARIMA estacional ha demostrado ser altamente eficaz, ya que ha obtenido resultados exitosos en ambos contextos temporales evaluados.

Palabras clave: Previsión energética, demanda eléctrica, SARIMA, Holt-Winters

Abstract The high variability of electricity consumption presents a difficulty for power system operators, who must cope with rapid and unpredictable changes in demand to ensure a continuous and stable supply. Therefore, in this paper, sev-

Corresponding Author*: Ian Oswaldo Anaguano Pérez

Guayaquil, Ecuador, e-mail: ianaguan@espol.edu.ec.

 <https://orcid.org/0000-0003-3608-8772>

Mat. Fernando Francisco Sandoya Sánchez, PHD

Escuela Superior Politécnica del Litoral, Facultad de Ciencias Naturales y Matemáticas,

Guayaquil, Ecuador, e-mail: fsandoya@espol.edu.ec.

Universidad de Guayaquil, Facultad de Ciencias Químicas, e-mail: fernando.sandoyas@ug.edu.ec.

 <https://orcid.org/0000-0002-0011-4003>

eral practical methods aimed at modeling and forecasting electricity demand in the ultra-short term are presented. The proposed methods are: Seasonal ARIMA and Holt-Winters, which are used for future day demand forecasting, some practical considerations for ultra-short term time windows are evaluated. Electricity demand data from the National Interconnected System of Ecuador with 30-minute granularity are used for the implementation. An evaluation of the two forecasting methods in two different time contexts is also performed to determine their effectiveness and accuracy in each scenario. The seasonal ARIMA method has proven to be highly effective, since it has obtained successful results in both time contexts evaluated.

Keywords: Energy forecasting, load demand, SARIMA, Holt-Winters

1 Introducción

La electricidad es vital para la producción y el bienestar de cualquier nación, por tanto es muy importante disponer de metodologías que aseguren la exactitud en la predicción de las fluctuaciones de la demanda de electricidad, sin embargo, debido a la volatilidad de las variables económicas y comportamientos sociales, predecir la demanda eléctrica es un desafío, para lo cual se han investigado diversos métodos de pronóstico avanzados que logran resultados confiables (He et al., 2022).

La previsión de la carga a ultracorto plazo resulta ventajosa para establecer de manera adecuada la operación de una red eléctrica y se emplea para elaborar planes de mantenimiento para las unidades de generación, contribuyendo así a mejorar tanto aspectos económicos como sociales de un sistema eléctrico (Li et al., 2020). La previsión de la demanda eléctrica a ultracorto plazo abarca un horizonte de pronóstico que se extiende desde 15 minutos hasta algunas horas en términos de escala temporal (Zhao et al., 2022). Contar con una previsión precisa de la demanda eléctrica a ultracorto plazo es esencial para afrontar desafíos como la gestión en tiempo real del suministro de electricidad y las actividades comerciales en el mercado energético (Wang et al., 2017).

Para la previsión de la demanda a ultra corto plazo, los métodos que capturan la relación sustancial entre la variable independiente y la dependiente son los adecuados, entre los cuales, el estudio de Zeng et al. (2023) destaca tanto el método de series temporales, que desarrolla un modelo matemático al ajustar curvas y estimar los parámetros utilizando datos históricos de carga, así como también el método de suavizado exponencial, que emplea una combinación ponderada de exponenciales para este propósito.

El objetivo principal de este trabajo es pronosticar la demanda eléctrica del Sistema Nacional Interconectado del Ecuador (SNI) usando modelos en series de tiempo con un horizonte temporal de previsión de 24 horas. Para tal propósito se efectuaron las implementaciones de los modelos ARIMA estacional y Holt-Winters en dos escenarios temporales distintos: uno para los días regulares, que incorpora la semana completa; y otro para los días hábiles, que solo incorpora los días laborales

dentro de la semana. Esta distinción permitió comparar la eficacia de los métodos en diferentes contextos temporales.

2 Bases Teóricas

2.1 Series de tiempo

Una serie de tiempo consiste en una secuencia de registros x_t , cada uno de los cuales se toma en un instante específico t (Brockwell & Davis, 2016).

Un modelo de series temporales es empleado para representar la información registrada en distintos momentos en el tiempo, identificados como x_t , y describe las distribuciones conjuntas de una secuencia de variables aleatorias, basándose en la premisa que esta secuencia de variables aleatorias o procesos estocásticos representada por X_t es la fuente subyacente de los datos observados x_t (Brockwell & Davis, 2002). En definitiva, cada variable aleatoria de la secuencia genera una realización o valor observado en el tiempo específico t .

2.2 Métodos previsión

2.2.1 Método Holt-Winters

La definición de la estructura matemática del modelo de Holt-Winters multiplicativo se describe en la Ecuación (1), donde u_{t-1} , v_{t-1} , y s_{t-c} son el nivel local, la tendencia y el término estacional en ese orden, y_t es el valor o la realización de la serie de tiempo en el instante t , mientras que c es el número de puntos temporales en el periodo estacional de la serie (Shao et al., 2023).

$$y_t = (u_{t-1} + v_{t-1})s_{t-c} \quad (1)$$

El modelo descrito en la Ecuación (1) se actualiza de forma iterativa siguiendo las ecuaciones de transición presentadas en (2), (3) y (4). Posteriormente, se emplea el modelo actualizado para realizar el cálculo de la predicción \hat{y}_t .

$$u_t = \alpha(y_t/s_{t-c}) + (1 - \alpha)(u_{t-1} + v_{t-1}) \quad (2)$$

$$v_t = \beta(u_t - u_{t-1}) + (1 - \beta)v_{t-1} \quad (3)$$

$$s_t = \gamma(y_t/u_t) + (1 - \gamma)s_{t-c}, \quad (4)$$

Los coeficientes α , β , γ los cuales están restringidos al intervalo $0 \leq \alpha, \beta, \gamma \leq 1$ funcionan como factores de atenuación o suavizado (Guo et al., 2010).

2.2.2 Método ARIMA estacional

La mayoría de las series temporales no presentan una estabilidad en su comportamiento a lo largo del tiempo, lo cual se conoce como no estacionariedad en la serie temporal. Esta falta de estacionariedad complica el análisis en los modelos autorregresivos, ya que estos requieren que la serie tenga cierta estabilidad para su análisis.

Es factible modelar las series no estacionarias utilizando el modelo autorregresivo integrado de media móvil estacional (SARIMA), que se representa como $(p, d, q)(P, D, Q)_s$ el cual, emplea la diferenciación de series temporales e incorpora términos de polinomios tanto estacionales como no estacionales (Alonso et al., 2021). Entonces, se puede afirmar que la serie está siguiendo un proceso ARIMA estacional si se cumple la Ecuación (5), que utiliza la terminología del estudio de Cowpertwait and Metcalfe (2009):

$$\Theta_P(B^s)\theta_p(B)(1-B^s)^D(1-B)^d x_t = \Phi_Q(B^s)\phi_q(B)w_t \quad (5)$$

En esta expresión Θ_P y θ_p representan los polinomios de orden P y p , respectivamente; mientras que Φ_Q y ϕ_q son los polinomios de orden Q y q , en ese orden; $B(x_t) = x_{t-1}$ es el operador de desplazamiento hacia atrás; D representa la cantidad de diferenciaciones estacionales; d indica la cantidad de diferenciaciones regulares; y s corresponde al periodo estacional.

2.3 Técnicas para la evaluación de los modelos y exactitud de las previsiones

2.3.1 Criterios de información

Los criterios de información son herramientas fundamentales para evaluar el ajuste de los modelos estadísticos, destacando también que, entre varios modelos potenciales, aquel con el menor criterio de información se aproxima mejor al proceso real de generación de datos (Matsuda et al., 2021). Este trabajo se centra en tres criterios de información: el Criterio de información Akaike (AIC), el Criterio de información Akaike corregido (AICc) y el Criterio de información Bayesiano (BIC).

Para la valoración del AIC se emplea la Ecuación (6) que usa la terminología del estudio de Ingdal et al. (2019).

$$AIC = -2\ln\hat{L} + 2(p + 1) \quad (6)$$

$$-2\ln\hat{L} = n\ln(2\pi) + n\ln\left(\frac{S}{n}\right) + n \quad (7)$$

En estas formulaciones, \hat{L} es el estimador de la función de verosimilitud, p señala la cantidad de parámetros del modelo, S indica la suma de los residuos al cuadrado, mientras que n denota el número de observaciones utilizadas para la estimación del modelo.

En contextos con un bajo número de grados de libertad, se puede aplicar una corrección de sesgo al AIC, lo que da lugar al criterio AICc, de tal manera que la estructura para el cálculo del AICc toma la forma (Ingdal et al., 2019):

$$AIC_c = -2\ln\hat{L} + 2(p+1)\left(\frac{n}{n-p-2}\right) \quad (8)$$

Para la estimación del valor del BIC, se aplica la Ecuación (9) que utiliza la nomenclatura de Liu et al. (2022).

$$\gamma_{BIC} = M\ln\sigma^2 + k\ln M \quad (9)$$

$$\sigma^2 = \frac{\sum_{j=1}^M (y_j - \hat{y}_j)^2}{M - k} \quad (10)$$

En estas ecuaciones, k denota el número de parámetros, mientras que M simboliza el tamaño de la muestra. Además, y_j representa el valor verdadero en la posición j , y \hat{y}_j se refiere al valor estimado por el modelo para la observación número j durante el proceso de evaluación.

2.3.2 Error de exactitud

Es factible tener una referencia porcentual de la exactitud de la previsión. Para esto se puede emplear la estructura del Error Porcentual Absoluto Medio (MAPE, en sus siglas en inglés) conforme a la terminología usada en el estudio de Hyndman and Koehler (2006), que es la siguiente:

$$MAPE = \frac{1}{m} \sum_{t=1}^m \left| \frac{Y_t - F_t}{Y_t} \right| \times 100\% \quad (11)$$

Donde Y_t es el valor real y F_t es el resultado de la previsión, m es la cantidad de valores pronosticados por el modelo de previsión.

3 Metodología

Dentro del contexto de pronósticos a corto plazo, principalmente con un horizonte de pronóstico de un día, es factible generar una predicción muy precisa al emplear

únicamente datos recopilados en las últimas cuatro o cinco semanas (Haben et al., 2023). Con esta perspectiva, se recopilaron datos en megavatios del Sistema Nacional Interconectado del Ecuador, con regularidad de 30 minutos, por el período que va desde el 22 marzo 2023 hasta el 18 abril 2023, con el propósito de calcular las previsiones del miércoles 19 abril 2023.

La construcción de los modelos y posterior obtención de las previsiones ha sido posible mediante el uso del software R. De tal modo que, se emplearon algunos paquetes de R, incluyendo ‘stats’ y especialmente el paquete ‘forecast’. De tal forma que, para la elaboración del modelo Holt-Winters, se ha empleado la función ‘HoltWinters’ del paquete ‘stats’, la cual permitió el ajuste de la serie temporal a este modelo de suavizado exponencial. De similar manera, para el desarrollo del modelo SARIMA, se ha utilizado la función ‘Arima’ también del paquete ‘stats’, la cual permitió adecuar una serie temporal a un modelo autorregresivo.

La selección de los modelos óptimos se lo ha realizado aplicando los criterios de información, de tal manera, que el modelo que alcance el menor resultado obtenido de la agregación de los valores de los tres criterios: AIC, AICc y BIC, se consideró el mejor modelo.

La previsión de la demanda de electricidad para el miércoles, 19 de abril 2023, fueron generados por los modelos exitosamente construidos y seleccionados, empleando la función ‘forecast’ de R. Es decir, estas predicciones han sido obtenidas activando tanto los modelos de Holt-Winters como poniendo en marcha los modelos Autorregresivos Integrados de Medias Móviles Estacionales.

La evaluación de los resultados de la previsión energética de la demanda se lo ha realizado aplicando la formulación del error porcentual absoluto medio (MAPE), la cual, posibilitó la comparación de los resultados generados tanto por el método SARIMA como por el método de Holt-Winters, en diferentes escenarios temporales.

4 Resultados

En la Figura 1 se presenta la serie de tiempo correspondiente a los datos observados, los cuales han sido registrados con una resolución temporal de 30 minutos, también conocida como resolución semihoraria. Esta alta frecuencia de muestreo permite una detallada y precisa captura de las variaciones y tendencias presentes en el conjunto de datos, proporcionando así una visión más clara de los fenómenos estudiados. La elección de una resolución semihoraria es especialmente útil en contextos donde las fluctuaciones pueden ocurrir en intervalos cortos de tiempo, permitiendo un análisis más granular y facilitando la identificación de patrones y anomalías que podrían pasar desapercibidos con una resolución temporal menos frecuente.

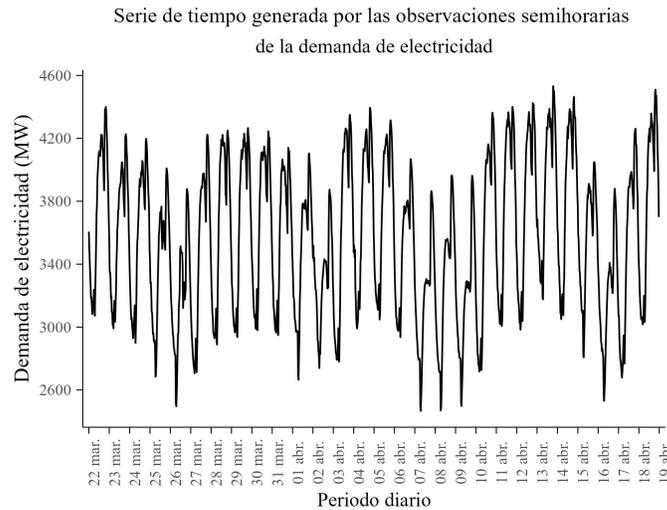


Figura 1 Serie de tiempo de la demanda eléctrica con datos semihorarios y periodo diario
Fuente: Elaboración propia

En la Tabla 1, se presentan los modelos que han sido seleccionados empleando los criterios de información tanto para el escenario de los días regulares como para el escenario de los días hábiles. Estos esquemas proporcionan una representación precisa y eficaz en ambos escenarios, y fueron empleados para obtener las previsiones futuras.

Tabla 1 Modelos seleccionados para el escenario de días regulares y días hábiles

Escenario temporal	Modelos	
	SARIMA	Holt-Winters
días regulares	$(3, 1, 0)(3, 1, 3)_{48}$	$(\alpha = 0.8742, \beta = 0.0015, \gamma = 1)$
días hábiles	$(0, 1, 2)(3, 1, 1)_{48}$	$(\alpha = 0.8037, \beta = 0.0015, \gamma = 0.7464)$

Fuente: Elaboración propia

En la Figura 2 se muestra la predicción de la demanda empleando los métodos SARIMA y Holt-Winters en el escenario de días regulares; también incorpora la demanda real para observar la posición comparativa de los resultados de predicción con la trayectoria real de la demanda, y así tener un concepto visual de como se han ajustado estos resultados a los datos auténticos. Para un análisis con detalle, en

la Figura 3 se expresa el error de cada uno de los pronósticos empleando los dos métodos.

Resultados de los métodos de previsión SARIMA y Holt-Winters en el escenario temporal de días regulares del miércoles 19 abril 2023

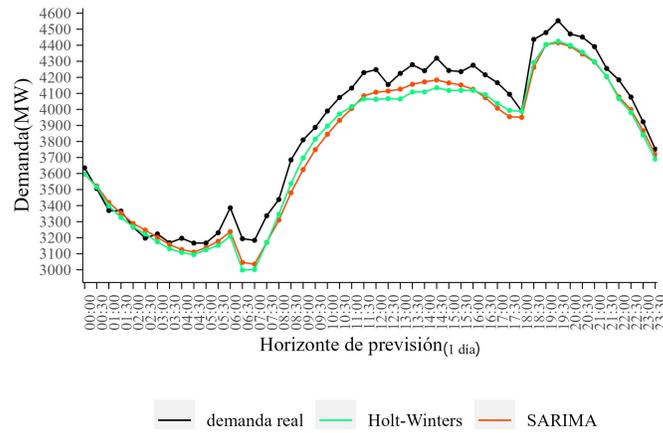


Figura 2 Resultados de los métodos de previsión en el escenario temporal de días regulares
Fuente: Elaboración propia

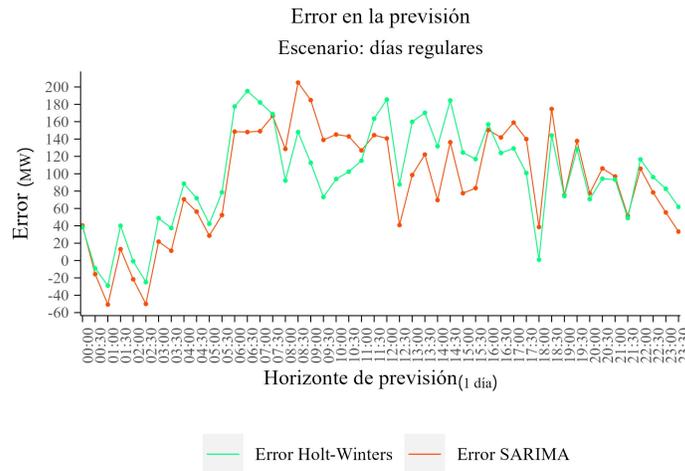


Figura 3 Error en la previsión de la demanda eléctrica en el escenario temporal de días regulares
Fuente: Elaboración propia

En la Figura 4 se presenta la previsión energética de la demanda utilizando los métodos SARIMA y Holt-Winters en el contexto de días hábiles. Así mismo se añaden los datos reales para observar la ubicación relativa de los resultados pronosticados en comparación con la trayectoria efectiva de la demanda, lo cual posibilita

una evaluación de la exactitud de las predicciones en relación con los datos efectivos. De igual manera, la Figura 5 muestra el error de cada una de las predicciones de los dos métodos de previsión.

Resultados de los métodos de previsión SARIMA y Holt-Winters en el escenario temporal de días hábiles del miércoles 19 abril 2023

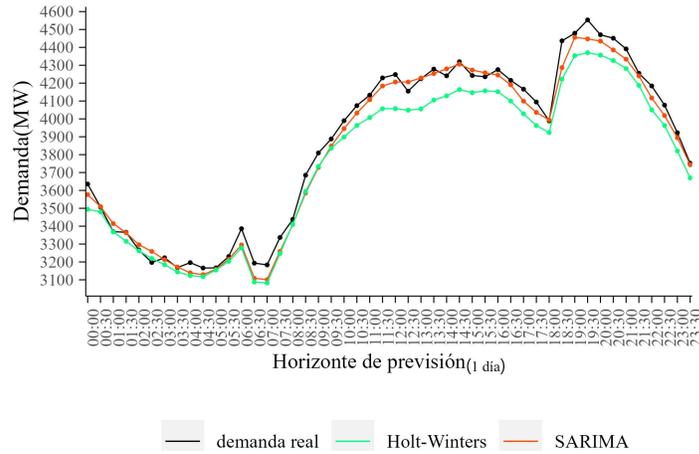


Figura 4 Resultados de los métodos de previsión en el escenario temporal de días hábiles
Fuente: Elaboración propia

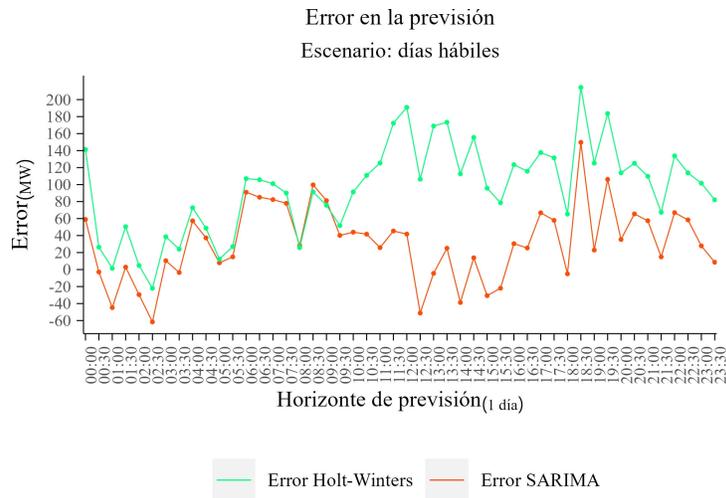


Figura 5 Error en la previsión de la demanda eléctrica en el escenario temporal de días hábiles
Fuente: Elaboración propia

Los errores porcentuales absolutos medios (MAPE) de las previsiones se utilizó para estimar y comparar la precisión de cada modelo en dos situaciones distintas. Estos resultados se encuentran detallados en la Tabla 2. Para una mejor interpretación de los resultados se ha utilizado el diagrama de barras de la figura 6.

Tabla 2 MAPE de la previsión energética de la demanda en el escenario de días regulares y hábiles

Escenario temporal	Modelos de predicción	
	SARIMA	Holt-Winters
días regulares	2.56%	2.67%
días hábiles	1.15%	2.49%

Fuente: Elaboración propia

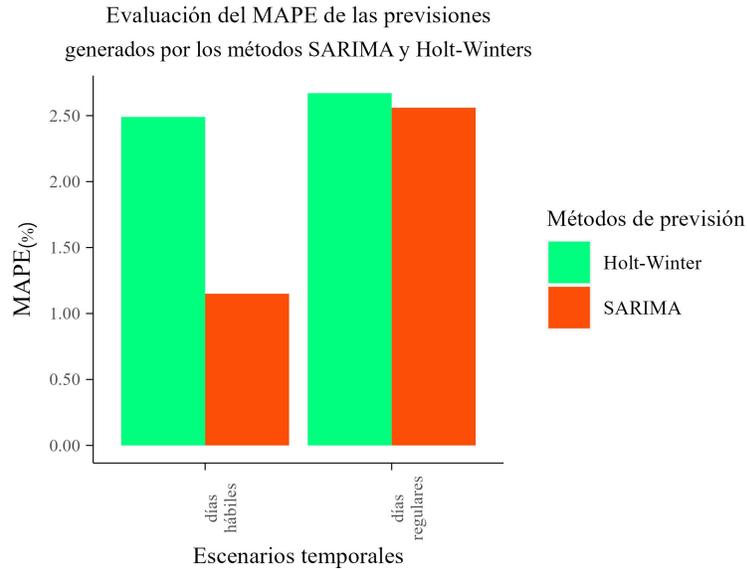


Figura 6 Evaluación del MAPE de la previsión energética de la demanda en dos escenarios

Fuente: Elaboración propia

El método SARIMA destaca en los dos escenarios temporales, lo que resalta su fuerte capacidad para prever valores futuros. No obstante, el espacio temporal donde los dos métodos coinciden en buenos resultados es durante el escenario de los días hábiles.

5 Conclusiones

- Para la previsión energética de la demanda a ultracorto plazo, es esencial disponer de un modelo de proyección de datos que sea manejable y sólido, que solicite únicamente la información necesaria para llevar a cabo el análisis.
- En este estudio se han introducido sistemas univariantes mediante la implementación de modelos de series temporales SARIMA y Holt-Winters, los cuales han sido capaces de realizar predicciones efectivas de la demanda eléctrica sin requerir una elevada cantidad de información previa.
- La trayectoria de los resultados de los métodos SARIMA y Holt-Winters se ajustan a los valores de la demanda real de forma excepcional; ambos métodos muestran una adaptación muy precisa a los datos reales.
- El error porcentual absoluto medio del método SARIMA experimentó un cambio, disminuyendo del 2.56% al 1.15% al pasar del escenario de días regulares al escenario de días hábiles. Este descenso sugiere una mejor anticipación de los resultados cuando en este caso ARIMA ha excluido el efecto de los fines de semana. Por otro lado, en el método Holt-Winters no se observó un cambio tan radical como en SARIMA, ya que el error porcentual pasó de 2.67% a 2.49% al cambiar del escenario de días regulares al de días hábiles, que representa una disminución del 7%.
- En el escenario de días hábiles, tanto el método SARIMA como el método de Holt-Winters presentan resultados superiores, lo que sugiere que estos métodos se adaptan de manera más efectiva a este escenario.

Referencias

1. Alonso, G. R., Rivero Villaverde, A., Lau Quan, A., & Ruíz Pérez, M. E. (2021). Comparison between SARIMA and Holt-Winters models for forecasting monthly streamflow in the western region of Cuba. *SN Applied Sciences*, 3. Retrieved from <https://doi.org/10.1007/s42452-021-04667-5>.
2. Brockwell, P. J., & Davis, R. A. (2002). *Introduction to Time Series and Forecasting*.
3. Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*. Retrieved from <https://doi.org/10.1007/978-3-319-29854-2>.
4. Cowpertwait, P. S., & Metcalfe, A. V. (2009). *Introductory Time Series with R*. Retrieved from <https://doi.org/10.1007/978-0-387-88698-5>.
5. Guo, Y.-h., Shi, X.-p., & Zhang, X.-d. (2010). A study of short-term forecasting of the railway freight volume in China using ARIMA and Holt-Winters models. In *2010 8th International Conference on Supply Chain Management and Information* (pp. 1–6).

6. Haben, S., Voss, M., & Holderbaum, W. (2023). *Core Concepts and Methods in Load Forecasting: With Applications in Distribution Networks*. Retrieved from <https://doi.org/10.1007/978-3-031-27852-5>.
7. He, Y., Xiao, J., An, X., Cao, C., & Xiao, J. (2022). Short-term power load probability density forecasting based on GLRQ-stacking ensemble learning method. *International Journal of Electrical Power and Energy Systems*, 142. Retrieved from <https://doi.org/10.1016/j.ijepes.2022.108243>.
8. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. Retrieved from <https://doi.org/10.1016/j.ijforecast.2006.03.001>.
9. Ingdal, M., Johnsen, R., & Harrington, D. A. (2019). The Akaike information criterion in weighted regression of immittance data. *Electrochimica Acta*, 317, 648–653. Retrieved from <https://doi.org/10.1016/j.electacta.2019.06.030>.
10. Li, H., Liu, H., Ji, H., Zhang, S., & Li, P. (2020). Ultra-short-term load demand forecast model framework based on deep learning. *Energies*, 13(18). Retrieved from <https://doi.org/10.3390/en13184900>.
11. Liu, X., Yang, J., Wang, L., & Wu, J. (2022). Bayesian information criterion based data-driven state of charge estimation for lithium-ion battery. *Journal of Energy Storage*, 55. Retrieved from <https://doi.org/10.1016/j.est.2022.105669>.
12. Matsuda, T., Uehara, M., & Hyvärinen, A. (2021). Information criteria for non-normalized models. *Journal of Machine Learning Research*, 22(1), 1–33. Retrieved from <http://jmlr.org/papers/v22/20-1366.html>.
13. Shao, Q., Aldhafeeri, A., Qiu, S., & Khuder, S. (2023). A multiplicative Holt–Winters model and autoregressive moving-average for hyponatremia mortality rates. *Healthcare Analytics*, 4. Retrieved from <https://doi.org/10.1016/j.health.2023.100262>.
14. Wang, L., Zhang, Z., & Chen, J. (2017). Short-term electricity price forecasting with stacked denoising autoencoders. *IEEE Transactions on Power Systems*, 32(4), 2673–2681. Retrieved from <https://doi.org/10.1109/TPWRS.2016.2628873>.
15. Zeng, W., Li, J., Sun, C., Cao, L., Tang, X., Shu, S., & Zheng, J. (2023). Ultra short-term power load forecasting based on similar day clustering and ensemble empirical mode decomposition. *Energies*, 16(4), 1–15. Retrieved from <https://doi.org/10.3390/en16041989>.
16. Zhao, X., Li, Q., Xue, W., Zhao, Y., Zhao, H., & Guo, S. (2022). Research on ultra-short-term load forecasting based on real-time electricity price and window-based XGBoost model. *Energies*, 15(19), 1–11. Retrieved from <https://doi.org/10.3390/en15197367>.