

Impacto de Vehículos Eléctricos sobre Transformadores de Distribución: Influencia de los Errores de Modelado

Impact of Electric Vehicles on Distribution Transformers: Influence of Modeling Errors

Doctorando:

Gerardo D. Szwarc

<https://orcid.org/0009-0006-2305-8442>

Universidad Tecnológica Nacional Facultad Regional San Francisco. San Francisco, Córdoba, Argentina

gszwarc@facultad.sanfrancisco.utn.edu.ar

Director:

Diego M. Ferreyra

Codirector:

Jorge R. Vega

Resumen

En este trabajo, se abordan diferentes estrategias para el modelado de las variables (temperatura ambiente y demanda eléctrica) que participan en un modelo térmico para el cálculo de la temperatura de operación de un transformador de distribución, la cual afecta la vida útil de su material celulósico aislante. Debido a que ambas variables presentan estacionalidad, aproximadamente coincidente con las estaciones del año, se las divide en cuatro partes y se modelan mediante regresión no lineal, variando la cantidad de términos en el modelo resultante. Posteriormente se comparan los resultados anuales con los de la estratificación y se determina la cantidad de términos conveniente según el coeficiente de determinación y el desvío estándar. Se analiza la distribución de los errores y los casos extremos, seguido de la aplicación de un método iterativo para generar los resultados del modelo térmico. Se concluye que, al considerar diez términos con estratificación se reduce considerablemente la dispersión de los resultados y, la aplicación de un método iterativo como es el de Monte Carlo, evita la selección de casos extremos poco probables.

Palabras clave: Regresión no lineal; Transformadores de distribución; Vehículos eléctricos; Modelado térmico

Abstract

This paper addresses different strategies for modeling the variables (ambient temperature and electricity demand) involved in a thermal model used to calculate the operating temperature of a distribution transformer, which affects the service life of its cellulose-based insulating material. Since both variables exhibit seasonality that roughly coincides with the seasons of the year, they are divided into four parts and modeled using nonlinear regression, varying the number of terms in the resulting model. The annual results are then compared with those from the stratification, and the optimal number of terms is determined based on the coefficient of determination and the standard deviation. The distribution of errors and outliers is analyzed, followed by the application of an iterative method to generate the thermal model results. It is concluded that considering ten terms with stratification considerably reduces the dispersion of the results, and the application of an iterative method such as the Monte Carlo method prevents the selection of unlikely outliers.

Keywords: Nonlinear regression; Distribution transformers; Electric vehicles; Thermal modeling

Introducción

El avance de la electromovilidad incentivó la realización de estudios referidos al impacto que tendrá en las redes eléctricas de distribución, especialmente en el transformador asociado (Sexauer et ál., 2011; Bazurto Cubillos et ál., 2016). Un área de elevado interés internacional es la cantidad de vehículos eléctricos (VE) que se pueden cargar simultáneamente y su horario óptimo (Rutherford y Yousefzadeh, 2011; Pradhan et ál., 2020). En muchos de los estudios relacionados, los autores modelan los datos para facilitar su manejo (Hilshey et ál., 2012; Pradhan et ál., 2020) o extrapolarlos a futuro, anticipando el comportamiento de la red eléctrica (Godina et ál., 2016). Para el estudio del impacto de los VE en un transformador, es importante contar con información de la potencia demandada por los usuarios residenciales (P_D), la potencia de carga de los VE (P_C) y la temperatura ambiente (Θ_a). Las dos primeras variables modifican directamente el factor de carga (k) del transformador y, junto con la tercera, afectan su temperatura de punto caliente (Θ_h) (Szwarc et ál., 2026; Godina et ál., 2016). El calor generado por el transformador, debido a las pérdidas en los devanados y en el núcleo magnético, debe evacuarse para que Θ_h no alcance valores que comprometan la seguridad de los elementos que conforman al equipo, principalmente el aislante celulósico (Mihajlovic et ál., 2023). La capacidad de disipación de calor es limitada principalmente por Θ_a . El cálculo de Θ_h (variable que determina la pérdida de vida útil del equipo), se encuentra establecido por normas nacionales (IRAM 2473) e internacionales (IEC 60076-7) (Szwarc et ál., 2026).

En este trabajo, se estima la cantidad de VE que se pueden cargar juntamente en un transformador de distribución de 250 kVA, ubicado en la ciudad de San Francisco, Córdoba, elaborado con aislante celulósico no mejorado térmicamente, cuya temperatura nominal de trabajo es de 98 °C. Para ello, se modela P_D y Θ_a , y se proponen técnicas para mejorar su exactitud. Se aplica un método iterativo para resolver el modelo térmico del transformador. Se comparan los casos extremos con los más probables y los resultados al utilizar los percentiles (P5 y P95) y los cuartiles (Q1 y Q3) como medidas de posición.

Desarrollo

Los datos de P_D se estiman a partir de la información disponible en el informe oficial de la Compañía Administradora del Mercado Mayorista Eléctrico Sociedad Anónima (CAMMESA) de 2025 (CAMMESA, 2026). Para la temperatura ambiente, se utilizan los datos de la estación meteorológica de la Universidad Tecnológica Nacional Facultad Regional San Francisco (UTN FRSFco) (UTN FRSFco, 2026). Ambas series de datos corresponden a 2025, con un intervalo de promediación de 15 minutos para demanda y de 10 minutos para temperatura, esto implica 35 040 datos para P_D y 52 560 para Θ_a .

Mediante regresión no lineal se modelan los datos de P_D y Θ_a , aunque existen otras técnicas (*Seasonal Autoregressive Integrated Moving Average* -SARIMA-, redes neuronales, etc.), el método seleccionado ofrece una precisión adecuada en los resultados (Uhrig et ál., 2025; Kialashaki y Reisel, 2013; Kamoona et ál., 2023). La función objetivo está dada por (1), que representa los datos como la suma de componentes sinusoidales con diferentes amplitudes (A_j), frecuencias (f_j) y ángulos de fase (φ_j), A_0 es dado por la media de los datos y N es la cantidad de términos de la sumatoria que determina, en parte, la exactitud del modelo. Los componentes de la sumatoria en (1) se pueden obtener por diferentes métodos, como *stepforward*, *stepwise*, *backward*, entre otros (Desboullets, 2018), para este caso se selecciona el primero (Alvarado, 2015).

$$Y(j) = A_0 + \sum_{j=1}^N A_j \cdot \sin(2\pi \cdot f_j \cdot t + \varphi_j) \quad (1)$$

Debido a que P_D y Θ_a presentan comportamiento estacional, es posible estratificar los datos según las estaciones del año, a fin de mejorar la exactitud del modelo (Pérez González et ál., 2025). Sin embargo, el número de ecuaciones resultantes será igual a la cantidad de partes en las que se divida la serie de datos original, lo cual puede complejizar el proceso posterior.

A fin de establecer el N adecuado, se obtiene el coeficiente de determinación (R^2) y el desvío estándar (σ) que surge de comparar los resultados de (1) con los datos originales correspondientes, al variar N de 1 a 20. En las figuras 1 y 2 se muestra la variación de R^2 respecto a N y en las figuras 3 y 4 de σ . En las cuatro gráficas, la línea continua representa los resultados al considerar los datos anuales, y en línea de trazos, los correspondientes a la estratificación. Para los datos estratificados, como se muestra en la figura hasta $N=10$, el incremento promedio de R^2 es de 0,056 por cada incremento de N y de 0,007 para $10 < N \leq 20$; acorde a la figura 2, hasta $N=10$, R^2 aumenta en promedio en 0,037 y 0,007 para $10 < N \leq 20$. Esto indica un claro límite que puede alcanzarse, donde el agregado de términos adicionales no produce una mejora considerable en la regresión. En la tabla 1 se muestra la cantidad de términos necesarios para alcanzar dos R^2 diferentes en cada caso presentado.

Tabla 1: N necesario para diferentes R^2 tomados como ejemplo

R^2 objetivo	N sin estratificación para demanda	N con estratificación para demanda	N sin estratificación para temperatura	N con estratificación para temperatura
0,7	14	6	2	7
0,8	más de 20	9	16	13




Figura 1: Variación del R^2 en función N para demanda




Figura 2: Variación del R^2 en función N para temperatura




Figura 3: Variación de σ en función N para demanda




Figura 4: Variación de σ en función N para temperatura

La variación del desvío estándar para P_D (figura 3) sin estratificación, se ve reducida a partir de $N=6$, y desde $N=8$ para los datos estratificados, que presentan un σ promedio menor. Para los datos de temperatura sin estratificar (figura 4) se requiere de $N=2$ y con la estratificación $N=10$, nuevamente el σ promedio es menor en el segundo caso.

Los resultados muestran que con estratificación y N reducido es posible mejorar la exactitud de los modelos respecto a los obtenidos sin estratificación. Pero, si N aumenta a 10, se reduce σ y mejora la exactitud de los modelos. Para ilustrar el impacto de σ se debe conocer la distribución de los errores del modelado. Debido a que la cantidad de datos es superior a 1000, no se aplican pruebas formales de normalidad, sino que se compara con una curva normal estandarizada. Si el perfil del histograma es acorde a dicha curva, los errores tienen una distribución normal (Kamath et ál., 2025; Demir, 2022). Esto se comprueba en las figuras 5 y 6; aunque solo se muestra para invierno, el análisis se realizó para las cuatro estaciones y las dos variables.




Figura 5: Histograma de error de P_D




Figura 6: Histograma de error de la temperatura ambiente

Para la temperatura, el valor real se encontrará con un 99,7 % de certeza en el rango $Y(t) \pm 3\sigma$. Si en el modelado se utiliza, por ejemplo, $N=4$ sin estratificar, σ será de 4°C , es decir, el valor real de la temperatura se encontrará en un rango de 12°C respecto al modelado. Si se aplica la estratificación y se amplía la cantidad de términos a $N=10$, 3σ será de 9°C .

Para P_D , cuando $N=4$ el desvío sin estratificación es de 0,08 por unidad (p. u.) y para $N=10$ con estratificación es, en promedio, de 0,04 p. u. En el caso de un transformador de 250 kVA a plena carga, los resultados indican que el valor real puede estar en el rango ± 60 kVA para el primer caso y ± 30 kVA para el segundo.

Para comprobar la influencia de los errores de los modelos en la operación del transformador, se aplica el modelo térmico que se describe a continuación (Godina et ál., 2016). En el modelo, $S(i)$ es P_D más la potencia que se puede utilizar para cargar los VE manteniendo Θ_h en 98 °C, S_n es la potencia nominal del transformador, R , x , $\Delta\theta_{or}$, $\Delta\theta_{hr}$, τ_w y τ_o son constantes que dependen del tipo de transformador y del aceite utilizado, Dt es el intervalo de discretización. La ecuación (2) permite obtener el factor de carga. Para el intervalo inicial ($i=1$), mediante (3) se obtiene la temperatura en régimen permanente, con (4) y (5) su variación debido a k . Para los períodos siguientes ($i \geq 2$) (6) representa la temperatura en régimen permanente considerando la temperatura del punto anterior y Θ_a , (7) y (8) es su variación dinámica debido a la fluctuación de k , (9) es la temperatura de punto caliente para cualquier intervalo y (10) es la velocidad de envejecimiento del aislante (V).

$$k(i) = \frac{S(i)}{S_n} \quad (2)$$

$$\theta_{o(i=0)} = \left[\frac{1+k_{(i=1)}^2 \cdot R}{1+R} \right]^x \cdot \Delta\theta_{or} + \theta_{a(i=0)} \quad (3)$$

$$\Delta\theta_{h1(i=1)} = k_{21} \cdot k_{(i=1)}^y \cdot \Delta\theta_{hr} \quad (4)$$

$$\Delta\theta_{h2(i=1)} = (k_{21} - 1) \cdot k_{(i=1)}^y \cdot \Delta\theta_{hr} \quad (5)$$

$$\theta_{o(i)} = \frac{Dt}{k_{11} \cdot \tau_o} \cdot \left[\left(\frac{1+k_{(i)}^2 \cdot R}{1+R} \right)^x \cdot \Delta\theta_{or} - (\theta_{o(i-1)} - \theta_{a(i)}) \right] \quad (6)$$

$$\Delta\theta_{h1(i)} = \frac{Dt}{k_{22} \cdot \tau_w} \cdot (k_{21} \cdot \Delta\theta_{hr} \cdot k_{(i)}^y + \Delta\theta_{h1(i-1)}) \quad (7)$$

$$\Delta\theta_{h2(i)} = \frac{Dt}{\left(\frac{1}{k_{22}}\right) \cdot \tau_o} \cdot ((k_{21} - 1) \cdot \Delta\theta_{hr} \cdot k_{(i)}^y + \Delta\theta_{h2(i-1)}) \quad (8)$$

$$\theta_{h(i)} = \theta_{o(i)} + \Delta\theta_{h1(i)} - \Delta\theta_{h2(i)} \quad (9)$$

$$V_{(i)} = 2^{\left(\frac{\theta_h - 98}{6}\right)} \quad (10)$$

Al aplicar el modelo, se puede verificar que, para un transformador de 250 kVA, con $k=1$ constante y Θ_a de 20 °C, Θ_h será de 98 °C. Si la variación de Θ_a es de ± 12 °C, asumirá valores entre 8 y 32 °C y Θ_h será de 86 °C y 110 °C respectivamente. En tales condiciones de temperatura ambiente, para mantener Θ_h en 98 °C y la velocidad de envejecimiento del aislante en 1, k deberá asumir valores de 1,105 y 0,887 respectivamente, acorde a la capacidad del transformador esto es 276,50 kVA y 221,75 kVA. Si la variación de Θ_a se reduce a ± 9 °C, k será de 1,08 y 0,916, equivalente a 270 kVA y 229 kVA.

En la situación más desfavorable, cuando se combinan las situaciones extremas para P_D y Θ_a , sin la estratificación de los datos, la carga real del transformador puede variar cerca de 28,25 kVA por temperatura más 60 kVA por demanda, es decir, 87 kVA, esto es el 35,3 % de la capacidad del equipo. Con la estratificación y $N=10$ la variación aproximada es de 21 kVA por temperatura más 30 kVA por demanda (51 kVA), es decir, el 20,4 % de la capacidad del transformador.

Sin embargo, los valores mostrados son los más desfavorables y no necesariamente muestran la realidad del equipo. Para evitar el sesgo y obtener resultados acordes a la distribución de los errores, se puede utilizar diferentes métodos iterativos, por ejemplo, Monte Carlo. Este método realiza una determinada cantidad de iteraciones entre los diferentes modelos con su respectivo error acorde al tipo de distribución, y el modelo térmico en el que interfieren. Los resultados se deben resumir con medidas estadísticas, las cuales pueden ser, entre otros, los percentiles P5 y P95 que permiten abarcar el 90 % de los resultados, o los cuartiles Q1 y Q3 que abarcan el 50 % de los valores obtenidos. El resultado es la potencia adicional (en valores por unidad) (P_a) que se puede demandar al transformador para cargar los VE manteniendo Θ_h constante en 98 °C.

Una vez obtenido de los resultados de Monte Carlo, se calcula la potencia promedio de carga de los VE (P_C). Para ello se aprovecha la información de los VE puros (*Battery Electric Vehicle* -BEV-) patentados en Argentina en los últimos 3 años (7,09 kW) (SIOMMA, 2026). Con dicha potencia se aplica (11), considerando un factor de potencia (FP) de 0,9. Luego se promedian los valores horarios para todo el año, obteniendo una curva diaria representada por 96 puntos, uno cada 15 minutos.

$$N^{\circ} VE = \frac{P_a * S_{nom} * FP}{P_C} \quad (11)$$

Resultados

Los resultados se muestran en la figura 7. Se aprecia que los cuartiles (línea de trazos) y los percentiles (líneas continuas) no difieren demasiado entre ellos. Esto resulta de: la estratificación de los datos, la cantidad de términos (N) adoptada y el uso del método de Monte Carlo. La diferencia de P5 y P95, con respecto a P50 es de 2,5 VE, mientras que, para los cuartiles, es de 1 VE respecto a P50. Desde el punto de vista de la potencia nominal del transformador, la dispersión de los resultados al considerar los cuartiles es del 3,15 % y del 15,7 % al usar los percentiles. Estos porcentajes demuestran que es posible utilizar los percentiles para representar los resultados, abarcando una mayor cantidad de valores obtenidos del método de Monte Carlo, a la vez que se reduce la variabilidad obtenida al analizar los valores extremos.




Figura 7: Diferencia de la cantidad horaria promedio de VE que se pueden cargar simultáneamente

Conclusiones

En este trabajo, se analizó el impacto del modelado de la temperatura ambiente y la demanda eléctrica como variables en un modelo térmico para el cálculo de la temperatura de operación de un transformador de distribución. Los datos anualizados de potencia demandada y temperatura ambiente pueden ser modelados mediante regresión no lineal, como la sumatoria de un término independiente y sinusoides con diferentes amplitudes, ángulos de fase y frecuencia. La cantidad de términos de la sumatoria (N) debe establecerse a partir de múltiples indicadores, como R^2 y σ . Al aplicar los modelos generados con $N=4$ en el modelo térmico de un transformador de 250 kVA, los resultados extremos varían en un 35,3 % respecto a la potencia nominal del transformador. Al estratificar los datos según las estaciones del año e incrementar N a 10, los valores extremos obtenidos varían en un 20,4 % de la potencia nominal del transformador. Aunque el análisis de los errores y sus valores extremos permite conocer la variabilidad de los resultados, dichas situaciones rara vez se producen en la práctica. La aplicación del método iterativo de Monte Carlo redujo la variación de los resultados a un 15,7 % de la potencia nominal del transformador. La baja dispersión de los resultados muestra que es posible utilizar los percentiles P5 y P95 en lugar de los cuartiles Q1 y Q3.

Referencias

- Alvarado, M. (2015). Pronóstico de la demanda eléctrica residencial basado en el modelo de regresión adaptativa multivariante spline (MARS). Universidad Politécnica Salesiana, Ecuador. [En línea]. Disponible en: <https://dspace.ups.edu.ec/bitstream/123456789/11290/3/UPS-KT01191.pdf>
- Bazurto Cubillos, Á. J.; Balanta, J. Z.; Echeverry, D. F. y Lozano, C. A. (2016). Perspectiva del transformador de distribución en redes eléctricas con alta penetración de generación distribuida y vehículos eléctricos. Ciencia e Ingeniería Neogranadina. Vol. 26. No. 2. Pp. 35–48. Doi: 10.18359/rcin.1710
- Compañía Administradora del Mercado Mayorista Eléctrico Sociedad Anónima (CAMMESA). (2026). Informe Síntesis Mensual – Principales indicadores del mes. [En línea]. Disponible en: <https://cammesaweb.cammesa.com/informe-sintesis-mensual/>

- Demir, S. (2022). Comparison of Normality Tests in Terms of Sample Sizes under Different Skewness and Kurtosis Coefficients. *International Journal of Assessment Tools in Education*. Vol. 9. No. 2. Pp. 397–409. Doi: 10.21449/ijate.1101295
- Desboulets, I. D. D. (2018). A Review on Variable Selection in Regression Analysis. *Econometrics*. Vol. 6. Art. no. 45. Doi: 10.3390/econometrics6040045.
- Godina, R.; Rodrigues, E. M. G.; Paterakis, N. G.; Erdinc, O.; y Catalão, J. P. S. (2016). Innovative impact assessment of electric vehicles charging loads on distribution transformers using real data. *Energy Conversion and Management*. Vol. 120. Pp. 206–216. Doi: 10.1016/j.enconman.2016.04.087
- Hilshey, A. D.; Hines, P. D. H.; Rezaei, P.; y Dowds, J. R. (2012). Estimating the Impact of Electric Vehicle Smart Charging on Distribution Transformer Aging. *IEEE Transactions on Smart Grid*. Vol. 3. No. 4. Pp. 905–913. Doi: 10.1109/TSG.2012.2217385
- Kamath, A.; Poojari, S.; y Varsha, K. (2025). Assessing the robustness of normality tests under varying skewness and kurtosis: a practical checklist for public health researchers. *BMC Medical Research Methodology*. Vol. 25. Art. no. 206. Doi: 10.1186/s12874-025-02641-y
- Kamoon, A.; Song, H.; Keshavarzian, K.; Levy, K.; Jalili, M.; Wilkinson, R.; Yu, X.; McGrath, B. and Meegahapola, L. (2023). Machine learning based energy demand prediction. *Energy Reports*. Vol. 9. Pp. 171–176. Doi: 10.1016/j.egy.2023.09.151.
- Kialashaki, A. and Reisel, J. R. (2013). Modeling of the energy demand of the residential sector in the United States using regression models and artificial neural networks. *Applied Energy*. Vol. 108. Pp. 271–280. Doi: 10.1016/j.apenergy.2013.03.034.
- Mihajlovic, D.; Vasovic, V. y Lukic, J. (2023). Development of New Accelerated Aging Test for Comparison of the Quality of Different Insulating Papers Based on Cellulose. *Polymers*. Vol. 15. No. 11. Art. no. 2556. Doi: 10.3390/polym15112556
- Pérez González, M. A.; Rincón Ramírez, S. A.; Jiménez Betancourt, R. O.; González López, J. M. y Villalvazo Laureano, E. (2025). Desarrollo de una herramienta de análisis estadístico aplicado al pronóstico de la demanda en sistemas eléctricos de potencia. *CientiFICA. Revista Científica de la Facultad de Ingeniería y Ciencias Agropecuarias*. No. 2. Pp. 74–92
- Pradhan, P.; Ahmad, I.; Habibi, D.; Kothapalli, G. y Masoum, M. A. S. (2020). Reducing the Impacts of Electric Vehicle Charging on Power Distribution Transformers. *IEEE Access*. Vol. 8. Pp. 210183–210193 Doi: 10.1109/ACCESS.2020.3040056
- Rutherford, M. J. y Yousefzadeh, V. (2011). The impact of Electric Vehicle battery charging on distribution transformers. *Twenty-Sixth Annual IEEE Applied Power Electronics Conference and Exposition (APEC)*. Doi: 10.1109/APEC.2011.5744627
- Sexauer, J. M.; McBee, K. D. y Bloch, K. A. (2011). Applications of Probability Model to Analyze the Effects of Electric Vehicle Chargers on Distribution Transformers. *2011 IEEE Electrical Power and Energy Conference (EPEC)*. Winnipeg, MB, Canada. Pp. 290–295. Doi: 10.1109/EPEC.2011.6070213
- SIOMAA. (2024). Informe trimestral sobre electromovilidad: Automóviles y Comerciales Livianos. [En línea]. Disponible en: <https://www.siomaa.com/eShop/Contact/185>
- Szwarc, G. D.; Vega, J. R.; y Ferreyra, D. M. (2026). Envejecimiento de las aislaciones de un transformador de distribución según su material y la temperatura ambiente. *CITTIE 2026*. UTN Fac. Reg. Santa Fe, Santa Fe, Argentina. [En prensa]
- Uhrig, M. N.; L. Vignolo, D.; and Müller, O. V. (2025). Modelado y predicción de la demanda eléctrica: comparación de enfoques estadísticos y de aprendizaje automático. *SADIO Electronic Journal of Informatics and Operations Research (EJS)*. vol. 24. No. 1. Doi: 10.24215/15146774e067.
- Universidad Tecnológica Nacional, Facultad Regional San Francisco (UTN FRSFco). (2026). Climatología - Estación Meteorológica y Climatológica. [En línea]. Disponible en: <https://climatologia.sanfrancisco.utn.edu.ar/tiempo/>