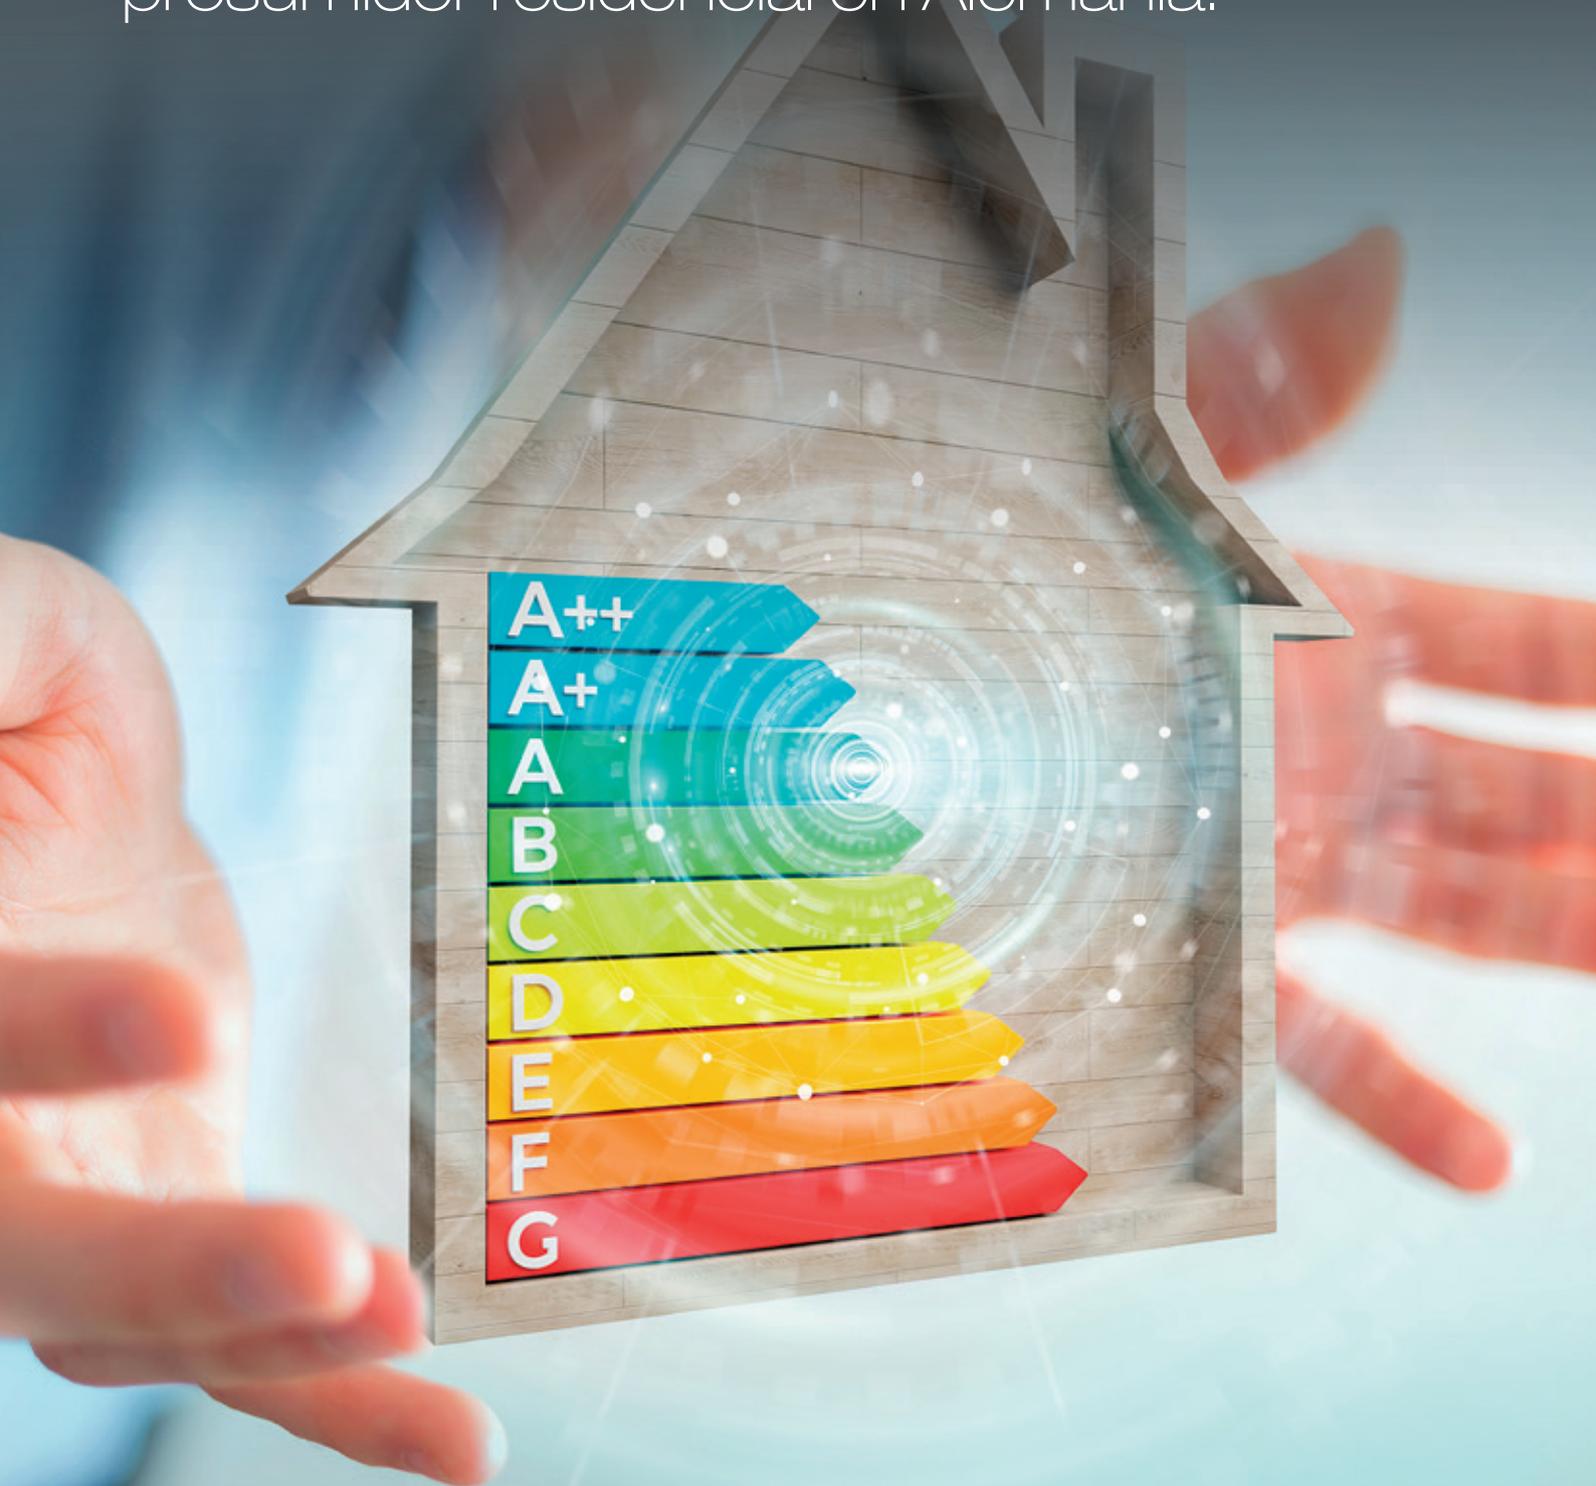


Se presenta **una metodología para construir e implementar, de manera práctica, modelos basados en el aprendizaje automático para resolver la complejidad de pronosticar el consumo de electricidad** de un prosumidor residencial en Alemania.



# Métodos de aprendizaje automático para el pronóstico del consumo eléctrico de prosumidores

## Machine Learning Methods for Forecasting Electricity Consumption of Prosumers

### RESUMEN

La tendencia hacia la llamada digitalización de los sistemas energéticos trae consigo la implementación de medidores de electricidad inteligentes y el desarrollo del mercado de «prosumidores» (usuarios productores y consumidores de energía quienes generan electricidad localmente a partir de fuentes renovables), el cual requiere de tecnologías emergentes, tales como el aprendizaje automático (en inglés, *machine learning*) para mejorar la gestión energética. El objetivo de la investigación es desarrollar modelos basados en métodos de aprendizaje automático para pronosticar el consumo eléctrico horario de un prosumidor residencial ubicado en Alemania.

En este estudio, se desarrolla una metodología para construir modelos de predicción basados en los métodos seleccionados «k-vecinos más cercanos» y «redes neuronales artificiales» (en inglés, *k-Nearest Neighbors* y *Artificial Neural Networks*, respectivamente), los cuales son aplicados a las mediciones históricas de consumo eléctrico de quince meses en combinación con datos meteorológicos de temperatura local.

A pesar de la complejidad para predecir el consumo, debido al uso irregular de energía eléctrica en un hogar, los modelos *k-Nearest Neighbors* y *Artificial Neural Networks* mostraron resultados de exactitud aceptables con un error porcentual absoluto medio en el orden del 30 % en tres escenarios diferentes con períodos de pronóstico de 48, 24 y 1 horas. Los modelos predictivos desarrollados pueden ser implementados por modelos de negocio emergentes orientados hacia el prosumidor, cuya propuesta de valor se basa en reducir los costos de electricidad a través de la mejora del autoconsumo de energía renovable.

### ABSTRACT

*The trend towards the so-called digitalization of energy systems brings with it the implementation of smart meters and the development of the “prosumer” market (energy producers and consumers which generate electricity locally), which demands emerging technologies, such as machine learning, to improve energy management. This research aims to build models based on machine learning methods for forecasting hourly electricity consumption of a residential prosumer located in Germany.*

*In this study, a methodology is developed to build prediction models based on k-Nearest Neighbors and Artificial Neural Networks methods, which are applied on historical electricity consumption data obtained along fifteen months and in combination with local temperature data.*

*Despite the complexity of predicting consumption due to the irregular usage of electricity in a household, the k-Nearest Neighbors and Artificial Neural Networks models showed acceptable accuracy results with a medium absolute percentage error around 30% in three different scenarios with forecast periods of 48, 24 and 1 hours. The predictive models can be implemented through emerging prosumer-oriented business models, whose value proposition aims at reducing electricity costs through improvement of renewable energy self-consumption.*



### Palabras clave

Prosumidor, pronóstico de consumo eléctrico, k-vecinos más cercano, redes neuronales artificiales, aprendizaje automático.

### Key words

Prosumer, electricity consumption forecasting, k-Nearest Neighbors, Artificial Neural Networks, machine learning.

## INTRODUCCIÓN

El desarrollo del mercado de prosumidores, es decir, aquellos consumidores que producen y consumen electricidad, juega un papel importante en la llamada transición energética y sus principales impulsores: descarbonización, descentralización y digitalización. Descarbonización, mediante la generación de energía renovable, especialmente a partir de sistemas fotovoltaicos. Descentralización, mediante el consumo de electricidad autoproducida y la reducción de aquella importada de la red. Además, en la digitalización de los sistemas energéticos, descrita como la aplicación de tecnologías de la información y comunicaciones [5], los métodos de análisis avanzados, como el aprendizaje automático, permiten explotar grandes cantidades de datos con el objetivo de mejorar la gestión energética.

Pronosticar el consumo de electricidad de un prosumidor es una tarea bastante compleja debido al uso irregular de los aparatos eléctricos. La previsión a corto plazo, es decir, de 1 hora a varios días de antelación [7], es particularmente importante, ya que proporciona información para evaluar el consumo diario, la demanda pico, así como los perfiles de carga [2]. De esta manera, pronósticos confiables son requeridos para optimizar el consumo de electricidad y su respectivo costo.

En ese sentido, surge la idea de explorar la aplicación práctica de métodos de aprendizaje automático en prosumidores. El objetivo de la investigación es construir modelos predictivos basados en el aprendizaje automático para pronosticar el consumo de electricidad a corto plazo de un prosumidor residencial; asimismo, determinar el rendimiento de los modelos en términos de exactitud. La investigación es relevante, dado que hasta la fecha solo se han realizado estudios limitados sobre este tema.

En este estudio, se describe una metodología experimental para resolver el problema de previsión energética, la cual comprende un proceso de construcción y evaluación de modelos de predicción basados en los métodos *k-Nearest Neighbors* y *Artificial Neural Networks*. Esta metodología es aplicada en un prosumidor residencial, cuyas mediciones históricas de consumo eléctrico en combinación con variables meteorológicas son utilizadas como datos de entrada para entrenar y optimizar los modelos predictivos.

## FUNDAMENTOS

Las técnicas de pronóstico de consumo eléctrico pueden clasificarse en dos grupos: métodos convencionales y métodos de aprendizaje automático [8]. Diversos estudios han desarrollado modelos basados en métodos convencionales de análisis de series temporales para predecir la demanda de energía eléctrica. El método estadístico Box y Jenkins, también conocido como modelo Autorregresivo Integrado de Media Móvil (ARIMA, por sus siglas en inglés), ha sido ampliamente utilizado.

Asimismo, solo algunas publicaciones han explorado la aplicación de técnicas de aprendizaje automático para predecir el consumo individual de un usuario, con especial interés en mejorar la exactitud de los pronósticos. En este estudio, se analiza la literatura relacionada con los métodos *k-Nearest Neighbors* (k-NN) y *Artificial Neural Networks* (ANN).

### K-vecinos más cercanos (k-NN)

El método de aprendizaje automático k-NN es ampliamente utilizado para la clasificación de patrones; sin embargo, también es aplicado a problemas de regresión tales como el pronóstico de series temporales.

El algoritmo k-NN aprende a pronosticar a partir de los datos de entrenamiento, los cuales utiliza para encontrar la relación entre las variables predictoras (variables independientes) y la variable objetivo (variable dependiente). Para calcular el valor de un pronóstico, el algoritmo promedia el valor de las muestras más similares, es decir, los k vecinos más cercanos, de los datos de entrenamiento. Por lo tanto, los modelos k-NN son de fácil parametrización [14], es decir, la selección del valor de k, el cual es un parámetro clave y puede seleccionarse ejecutando un proceso iterativo para encontrar aquel que produce el menor error de validación [15].

Según la revisión de la literatura, el método de aprendizaje automático *k-Nearest Neighbors* se ha aplicado de forma individual [2] [14] o en combinación con otras técnicas [4] para pronosticar demandas de electricidad.

### Redes neuronales artificiales (ANN)

Las redes neuronales artificiales están inspiradas en el proceso biológico y las conexiones de las neuronas en el cerebro, en donde cada neurona recibe entradas que son al mismo tiempo salidas de otras neuronas en una capa anterior [12]. Por ejemplo, la figura 1 muestra la topología de una red simple, donde  $X_1$ ,  $X_2$  y  $X_3$  son las variables de entrada (predictoras) conectadas a un nodo (que actúa como una neurona), y donde  $Y$  es la variable de salida (objetivo). Además, el número 1 se le denomina intercepción y los números 2, 3 y 4 son los coeficientes. Se puede observar que el último nodo llamado «nodo de umbral» en la capa de entrada es especial y no tiene entradas. La función de  $Y$  es una representación matemática de la red neuronal para un modelo lineal [6].

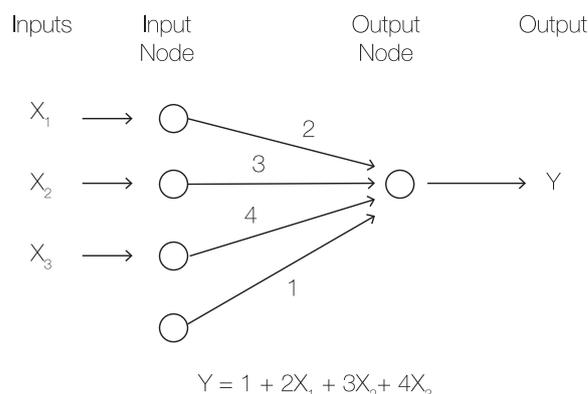


Figura 1. Ejemplo de una red neuronal artificial. Fuente: [6]

Modelos basados en ANN han sido aplicados para predecir el consumo eléctrico de un hogar. En algunos estudios, utilizando ANN (con datos históricos de consumo, temperatura y humedad como variables), se obtuvieron resultados con exactitud similar al método k-NN y mejores que los del método convencional

ARIMA [3]. Sin embargo, los resultados de otro análisis señalan la dificultad para predecir el consumo eléctrico y detectar los picos en un hogar individual, debido al uso irregular de los electrodomésticos [16].

electricidad (variable objetivo) de un prosumidor residencial. Los modelos k-NN y ANN son propuestos como alternativas a métodos convencionales y utilizan mediciones históricas de consumo y datos meteorológicos como variables predictoras.

## METODOLOGÍA

En este estudio, se construyen modelos basados en el aprendizaje automático para pronosticar el consumo de

El proceso para construir los modelos consta de cinco pasos generales: preprocesamiento de datos, entrenamiento, validación, prueba y evaluación [13]. La figura 2 muestra el diagrama de flujo utilizado para construir los modelos propuestos.

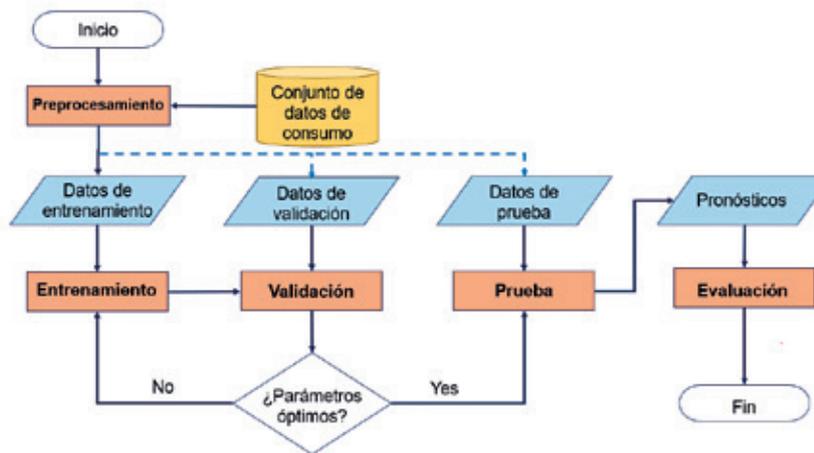


Figura 2. Diagrama de flujo para construir modelos basados en el aprendizaje automático. Fuente: Elaboración propia.

En primer lugar, problemas tales como datos faltantes o no estructurados se abordan en el preprocesamiento del conjunto de datos [7]. Luego, los datos preprocesados se dividen en tres subconjuntos para el entrenamiento, validación y prueba del algoritmo de aprendizaje automático (k-NN o ANN), respectivamente.

Los datos de entrenamiento se introducen en el algoritmo para que este pueda aprender la relación entre las variables predictoras y la variable objetivo. A continuación, los datos de validación se utilizan para evaluar el rendimiento general del modelo y ajustar los parámetros del algoritmo. Para el presente estudio, a fin de minimizar el riesgo de sobreajuste (conocido en inglés como *overfitting*) [6], se realizó un muestreo estratificado con una relación de 80 a 20 entre los datos de entrenamiento

y validación [9]. Posteriormente, utilizando los datos de prueba, el modelo final pronostica el consumo eléctrico para un periodo específico. Finalmente, la exactitud del modelo se evalúa comparando los pronósticos de prueba con el consumo real y se mide en términos de métricas comunes: raíz del error cuadrático medio (RMSE), error absoluto medio (MAE), error porcentual medio absoluto (MAPE) y coeficiente de correlación.

### Software de modelado

Para construir desde cero los modelos propuestos, k-NN y ANN, se utiliza un *software* popular de ciencia de datos: RapidMiner Studio [11]. La figura 3 muestra el modelo general construido en la aplicación, el cual está conformado por subprocesos.

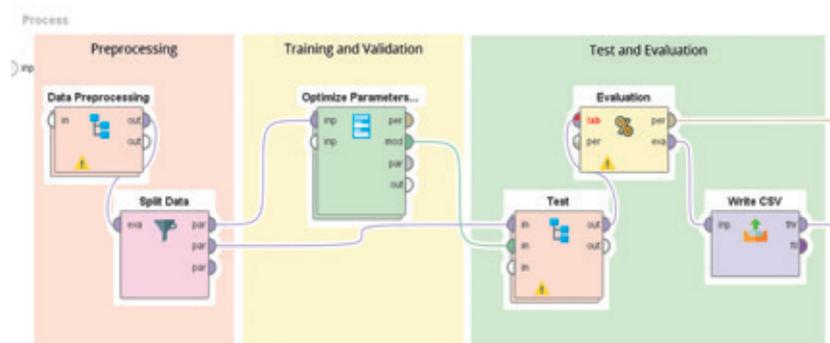


Figura 3. Modelo construido en RapidMiner Studio. Fuente: Elaboración propia.

### Descripción de datos

Para llevar a cabo el estudio, se seleccionó un conjunto de datos del proyecto *Open Power System Data* (OPSD) [10]. Estos datos pertenecen a un prosumidor residencial ubicado en Constanza, Alemania, y consisten en mediciones acumuladas de consumo y producción eléctrica en kWh.

De acuerdo con el propósito de esta investigación, la variable objetivo es el consumo de electricidad, independientemente de si esta es suministrada por la red pública o autoproducida por el sistema fotovoltaico, y se ha definido como la adición del consumo de los dispositivos individuales, tales como bomba de calor, vehículo eléctrico, lavavajillas, lavadora, congelador, y refrigerador.

Luego de la tarea de preprocesamiento, el conjunto de datos contiene 11 196 observaciones horarias para el periodo comprendido entre el 1 de noviembre de 2015 y el 9 de febrero de 2017 (15 meses). Una muestra del intervalo entre el 1 de enero al 9 de febrero de 2017 es representada en la figura 4. Se puede observar que los valores varían entre 0,4 y 3,8 kWh.

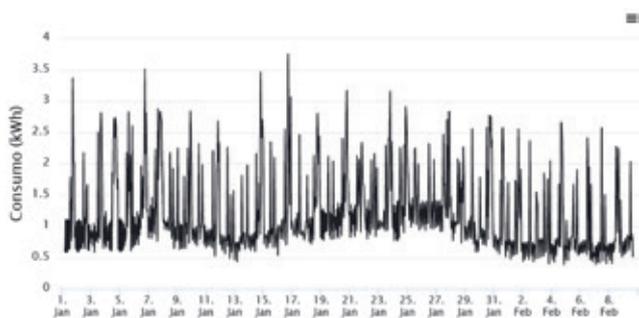


Figura 4. Consumo eléctrico horario.  
Fuente: Elaboración propia.

### Autocorrelación

Se analiza la correlación entre el consumo de electricidad en la hora siguiente y las mediciones anteriores. La correlación es medida a través del coeficiente de correlación de *Pearson* ( $r$ ), el cual indica la relación lineal entre dos variables [6]. La figura 5 muestra que las mediciones de las dos horas anteriores ( $t$  y  $t-1$ , respectivamente), así como la del día anterior ( $t-23$ ), son las más correlacionadas con el consumo de la hora siguiente ( $t+1$ ).

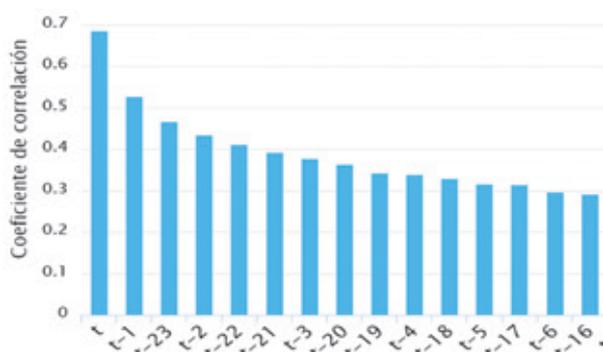


Figura 5. Coeficiente de correlación del consumo.  
Fuente: Elaboración propia.

### Correlación de variables meteorológicas

El consumo de electricidad puede estar influenciado por factores externos como las condiciones meteorológicas [3]. La figura 6 muestra que la correlación entre el consumo de electricidad y la temperatura es significativa, y la más importante entre las otras variables meteorológicas [1] de la zona donde se ubica el prosumidor.

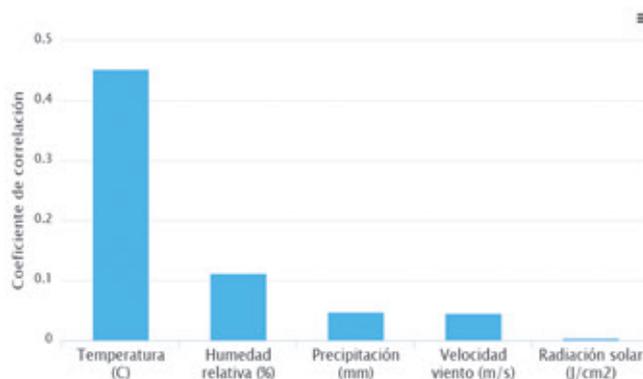


Figura 6. Correlación de variables meteorológicas.  
Fuente: Elaboración propia.

### Escenarios de prueba

Los modelos son diseñados para pronosticar el consumo de electricidad con una anticipación entre 1 y 48 horas. Asimismo, se elige una resolución de una hora, la cual es adecuada para comprender las variaciones y patrones de consumo durante el día, y permite tomar acciones oportunas para optimizar el consumo.

En la tabla 1 se resumen los escenarios seleccionados para evaluar el desempeño de los modelos propuestos.

Tabla 1  
Escenarios propuestos

Escenario	Resolución	Periodo de pronóstico
1	1 hora	48 horas
2	1 hora	24 horas
3	1 hora	1 hora

Fuente: Elaboración propia.

Los modelos pronostican el consumo de forma recursiva en los escenarios 1 y 2, es decir, el valor del pronóstico para la siguiente hora se utiliza para predecir el consumo en la hora subsiguiente; mientras que en el escenario 3, se simulan pronósticos con una hora de anticipación durante un periodo de 48 horas.

### Construcción del modelo k-NN

A diferencia de métodos convencionales como ARIMA, los modelos de aprendizaje automático no se limitan a series temporales de una variable, sino que permiten introducir múltiples variables.

En las etapas de entrenamiento y validación, se introducen diferentes combinaciones de variables predictoras en el algoritmo k-NN a fin de evaluar si la exactitud del modelo mejora. Las variables óptimas seleccionadas se muestran en la tabla 2.

Tabla 2  
Variables predictoras para el modelo k-NN

Tipo	Etiqueta	Descripción
<b>Variable objetivo</b>	consumo (t+1)	Consumo en la próxima hora (tiempo t+1) en kWh.
<b>Variables predictoras</b>	consumo (t0)	Consumo en horas previas en kWh.
	consumo (t-1)	
	consumo (t-23)	
	hora (t0)	Hora actual (valores enteros entre 0 y 23).
	mes (t0)	Mes actual (valores enteros entre 1 y 12).
	fin de semana (t0)	Valores binarios para días de fin de semana (1) y laborables (0).
	feriado (t0)	Valores binarios para días festivos (1) y laborables (0).
	temperatura (t0)	Temperatura actual.

Fuente: Elaboración propia.

Asimismo, la figura 7 resume los resultados de probar el modelo k-NN con diferentes valores del parámetro k en la etapa de validación. Se observa que un valor de 8 es el parámetro óptimo, ya que produce el menor error cuadrático medio (RMSE).

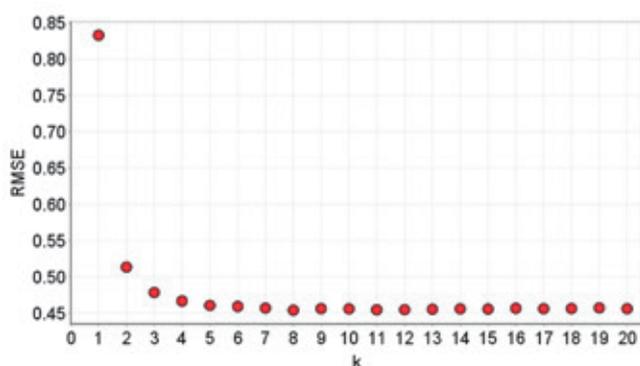


Figura 7. Selección del parámetro k.  
Fuente: Elaboración propia.

### Construcción del modelo ANN

A diferencia del modelo k-NN, el análisis de múltiples iteraciones en la etapa de validación determina que el modelo ANN arroja mejores resultados utilizando variables predictoras binarias. Por ejemplo, se requieren 24 variables binarias para la hora de consumo y 12 variables binarias para el número de mes.

Por otro lado, el número de capas y nodos se determina de forma iterativa [6]. En RapidMiner Studio, el tamaño de la capa oculta se establece de forma predeterminada mediante la

siguiente fórmula: (número de entradas + número de salidas)/2 + 1, sin incluir el nodo de umbral.

La tabla 3 muestra las 42 variables predictoras seleccionadas para el modelo. Asimismo, la figura 8 presenta la topología del modelo ANN: 42-23-1, es decir, 42 nodos en la capa de entrada, 23 nodos en la capa oculta y 1 nodo en la capa de salida.

Tabla 3  
Variables predictoras para el modelo ANN

Tipo	Etiqueta	Descripción
<b>Variable objetivo</b>	consumo (t+1)	Consumo en la próxima hora (tiempo t+1) en kWh.
<b>Variables predictoras</b>	consumo (t0), consumo (t-1), consumo (t-23)	Consumo en horas previas en kWh.
	hora (t0)	24 variables binarias para la hora actual.
	mes (t0)	12 variables binarias para el mes actual.
	fin de semana (t0)	Valores binarios para días de fin de semana (1) y laborables (0).
	feriado (t0)	Valores binarios para días festivos (1) y laborables (0).
	temperatura (t0)	Temperatura actual.

Fuente: Elaboración propia.

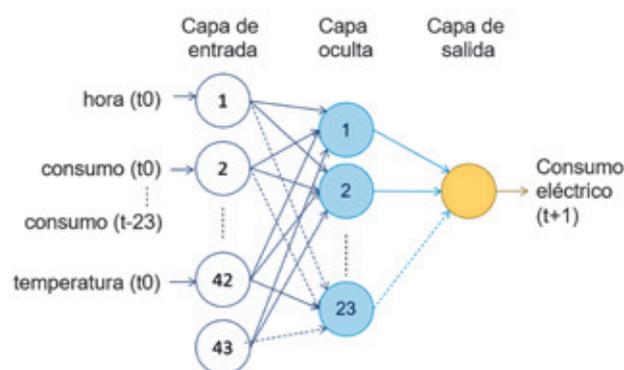


Figura 8. Topología del modelo ANN.  
Fuente: Elaboración propia.

Finalmente, en el entrenamiento y la validación del modelo, se determinan los parámetros óptimos, es decir, el número de ciclos de entrenamiento y el ratio de aprendizaje. La tabla 4 resume los resultados, en donde se observa que el RMSE más bajo se obtiene con 500 ciclos y un ratio de aprendizaje de 0,001. Cabe mencionar que con un mayor número de ciclos y un menor ratio, el RMSE no disminuye; no obstante, el tiempo de ejecución aumenta considerablemente.

Tabla 4  
Selección de parámetros para el modelo ANN

Ciclos de entrenamiento	Ratio de aprendizaje	RMSE
300	0,100	0,655
400	0,100	0,595
300	0,010	0,436
400	0,010	0,449
300	0,001	0,425
400	0,001	0,423
500	0,001	0,423

Fuente: Elaboración propia.

## RESULTADOS

Los modelos propuestos k-NN y ANN basados en el aprendizaje automático mostraron pronósticos de exactitud aceptable, con un error porcentual absoluto medio (MAPE) en el orden del 30 % en tres diferentes períodos de pronóstico. Además, la capacidad de los modelos para detectar patrones de consumo fue otro hallazgo importante. Asimismo, se observa en los resultados que los modelos lograron pronosticar picos y variaciones en el consumo; sin embargo, los picos fueron suavizados ligeramente.

### Validación de modelos

El tercer paso en el proceso para construir los modelos de predicción basados en el aprendizaje automático fue la validación. En este subproceso, la exactitud de los modelos

indica cómo podrían funcionar los modelos con nuevos datos. En esta etapa, los pronósticos obtenidos por el modelo ANN fueron más exactos que los del modelo k-NN. Asimismo, puede observarse que los cálculos del modelo ANN tienen mayor correlación con el consumo real. Sin embargo, la exactitud de ambos modelos disminuye cuando el consumo real es alto. Las métricas de exactitud se presentan en la tabla 5 y la figuras 9 y 10 muestra la correlación entre el consumo real y los pronósticos.

Tabla 5  
Validación de los modelos k-NN y ANN

Modelo	RMSE	MAE	MAPE	Correlación
k-NN (T)	0,454	0,258	133,98 %	0,691
ANN (T)	0,423	0,249	143,46 %	0,741

Fuente: Elaboración propia.

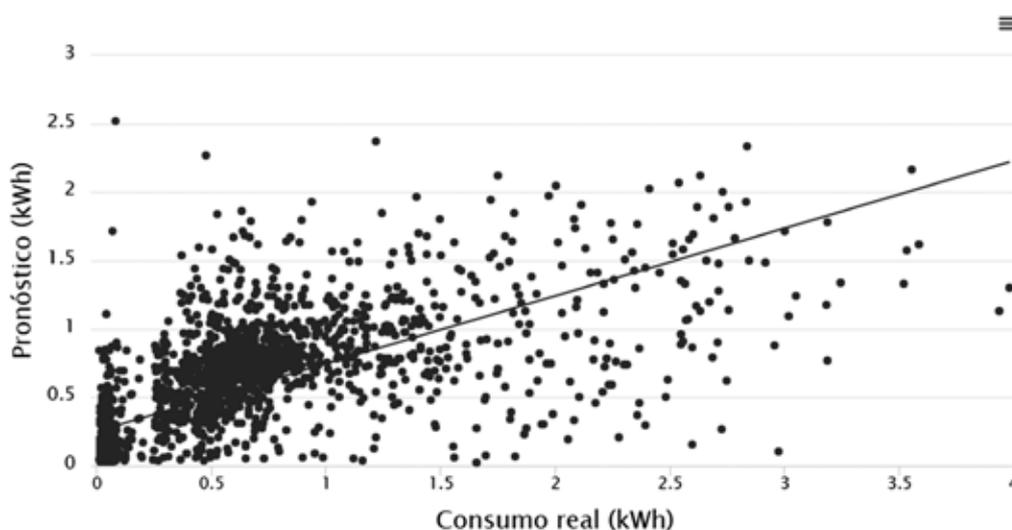


Figura 9. Correlación entre consumos reales y pronósticos del modelo k-NN.  
Fuente: Elaboración propia.

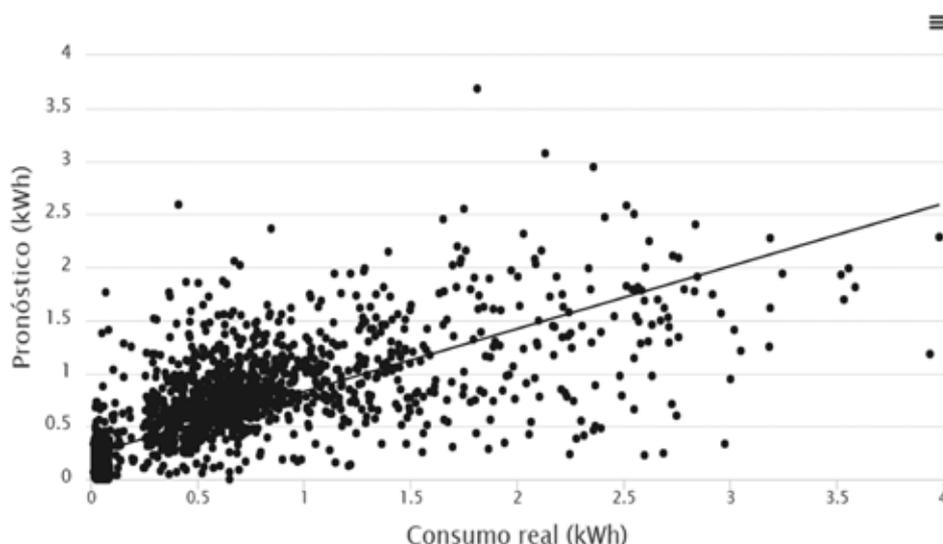


Figura 10. Correlación entre consumos reales y pronósticos del modelo ANN.  
Fuente: Elaboración propia.

### Evaluación de modelos

En la etapa de evaluación, se determinó que el modelo k-NN obtuvo resultados más exactos en términos de RMSE, MAE, MAPE y coeficiente de correlación que el modelo ANN. Además,

puede observarse que el error de los modelos disminuye en el segundo y tercer escenario con periodos de pronóstico más cortos. Los resultados para los tres escenarios propuestos se muestran en las tablas 6, 7 y 8, y las figuras 11, 12 y 13.

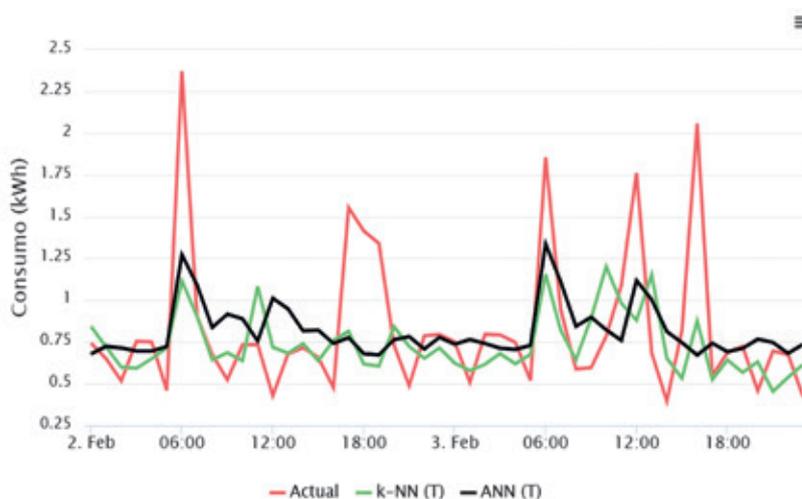


Figura 11. Escenario 1: pronósticos y consumos reales.  
Fuente: Elaboración propia.

Tabla 6  
Exactitud de los modelos en el Escenario 1

Modelo	RMSE	MAE	MAPE	Correlación
k-NN	0,393	0,263	29,07 %	0,467
ANN	0,390	0,265	32,52 %	0,432

Fuente: Elaboración propia.

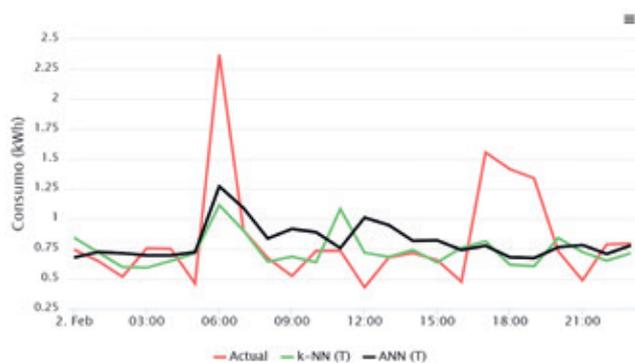


Figura 12. Escenario 2: pronósticos y consumos reales.  
Fuente: Elaboración propia.

Tabla 7  
Exactitud de los modelos en el Escenario 2

Modelo	RMSE	MAE	MAPE	Correlación
<b>k-NN</b>	0,400	0,255	27,56 %	0,436
<b>ANN</b>	0,397	0,280	34,10 %	0,384

Fuente: Elaboración propia.

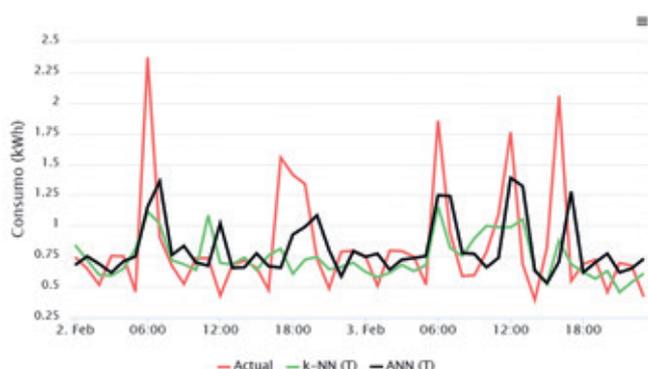


Figura 13. Escenario 3: pronósticos y consumos reales.  
Fuente: Elaboración propia.

Tabla 8  
Exactitud de los modelos en el Escenario 3

Modelo	RMSE	MAE	MAPE	Correlación
<b>k-NN</b>	0,381	0,258	28,75 %	0,535
<b>ANN</b>	0,404	0,280	34,79 %	0,376

Fuente: Elaboración propia.

### Tiempos de ejecución

El tiempo de procesamiento de datos, el cual se muestra en la tabla 9, varía entre los modelos k-NN y ANN; sin embargo, una vez que son entrenados, solo se necesitan unos segundos para elaborar pronósticos.

Tabla 9  
Tiempos de ejecución

Modelo	Procesamiento	Pronóstico
<b>k-NN</b>	2 min	1 s
<b>ANN</b>	10 min	2 s

Fuente: Elaboración propia.

## CONCLUSIONES

- En esta investigación, se presentó una metodología para construir e implementar, de manera práctica, modelos basados en el aprendizaje automático para resolver la complejidad de pronosticar el consumo de electricidad de un prosumidor residencial, cuyo rol es muy importante en la llamada transición energética.
- Se comprobó, en tres escenarios distintos, que los modelos basados en los métodos de aprendizaje automático k-NN y ANN permiten obtener pronósticos de consumo eléctrico a corto plazo (hasta 48 horas) con niveles de exactitud aceptables.
- El tiempo de ejecución requerido por los modelos para procesar los datos es corto, por lo tanto, adecuado para su implementación en el pronóstico de consumo eléctrico a corto plazo.
- Los modelos propuestos pueden ser adoptados y aprovechados por diferentes modelos de negocio emergentes orientados en gestionar la demanda y oferta de energía de los prosumidores, a fin de mejorar el autoconsumo de energía renovable y reducir los costos de electricidad.

## REFERENCIAS

- [1] DWD Climate Data Center (2018). Historical hourly station observations of 2m air temperature and humidity for Germany. Version v006. Recuperado de [ftp://opendata.dwd.de/climate\\_environment/CDC/observations\\_germany/climate/hourly/](ftp://opendata.dwd.de/climate_environment/CDC/observations_germany/climate/hourly/).
- [2] Fan, C., Xiao, F., Wang, S. (2014). Development of prediction models for next-day building energy consumption and peak power demand using data mining techniques. *Applied Energy*, 127, 1–10.
- [3] Gajowniczek, K., Ząbkowski, T. (2017). Electricity forecasting on the individual household level enhanced based on activity patterns. *PloS one*, 12 (4). Recuperado de <https://doi.org/10.1371/journal.pone.0174098>.
- [4] He, W. (2008). Forecasting electricity load with optimized local learning models. *International Journal of Electrical Power & Energy Systems*, 30 (10), 603–608.

- [5]** International Energy Agency (2017). *Digitalization and Energy. International Energy Agency (IEA)*. Recuperado de <https://www.iea.org/publications/freepublications/publication/DigitalizationandEnergy3.pdf>.
- [6]** Kotu, V., Deshpande, B. (2015). *Predictive analytics and data mining. Concepts and practice with RapidMiner*. Amsterdam: Elsevier/Morgan Kaufmann.
- [7]** Kuster, C., Rezgui, Y., Mourshed, M. (2017). Electrical load forecasting models. A critical systematic review. *In Sustainable Cities and Society*, 35, 257–270.
- [8]** Makridakis, S., Spiliotis, E., Assimakopoulos, Vassilios (2018). Statistical and Machine Learning forecasting methods. Concerns and ways forward. *PloS one*, 13 (3). Recuperado de <https://doi.org/10.1371/journal.pone.0194889>.
- [9]** Moon, J., Park, J., Hwang, E., Jun, S. (2018). Forecasting power consumption for higher educational institutions based on machine learning. *The Journal of Supercomputing*, 74 (8), 3778–3800.
- [10]** Open Power System Data (2017). Data Package Household Data. Versión 2017-11-10. Recuperado de [https://doi.org/10.25832/household\\_data/2017-11-10](https://doi.org/10.25832/household_data/2017-11-10).
- [11]** RapidMiner Inc. (2018). RapidMiner Studio. Versión 9.0.3. Recuperado de <https://rapidminer.com/get-started>.
- [12]** Shalev-Shwartz, S., Ben-David, S. (Eds.) (2014). *Understanding machine learning. From theory to algorithms*. New York: Cambridge University Press.
- [13]** Suthaharan, S. (2016). *Machine Learning Models and Algorithms for Big Data Classification*. Boston, MA: Springer US.
- [14]** Valgaev, O., Kupzog, F., Schmeck, Harmut (2016). Low-voltage power demand forecasting using K-nearest neighbors approach. *2016 IEEE Innovative Smart Grid Technologies - Asia (ISGT-Asia)*. Melbourne: IEEE, 1019–1024.
- [15]** Zhang, R., Xu, Y., Dong, Z., Kong, W., Wong, K. (2016). A composite k-nearest neighbor model for day-ahead load forecasting with limited temperature forecasts. *2016 IEEE Power and Energy Society General Meeting (PESGM)*. Boston: IEEE, 1–5.
- [16]** Zufferey, T., Ulbig, A., Koch, S., Hug, G. (Eds.) (2017). Forecasting of Smart Meter Time Series Based on Neural Networks. *Data Analytics for Renewable Energy Integration*. Cham: Springer International Publishing.

## ACERCA DEL AUTOR

### Javier Castillo Peña

Profesional técnico en Mantenimiento de Maquinaria de Planta por Tecsup (2004), bachiller en Ingeniería Industrial por la Universidad Peruana de Ciencias Aplicadas (2012), y Master of Business Administration (MBA) - Energy Management por la Technische Universität Berlin (2019).

@ javiercastillopena@gmail.com

Recibido: 27-05-19    Revisado: 24-06-19    Aceptado: 02-07-19



Esta obra está bajo una Licencia Creative Commons Atribución-NonComercial 4.0 Internacional.