

Predicción de la estabilidad de voltaje en redes eléctricas inteligentes

Victor Gil-Vera

victor.gilve@amigo.edu.co

<https://orcid.org/0000-0003-3895-4822>

Universidad Católica Luis Amigó, Colombia

Recibido: 29/05/2023 / Aceptado: 02/09/2023

doi: <https://doi.org/10.26439/ciis2023.7082>

RESUMEN. Las redes eléctricas inteligentes son un sistema de transporte de electricidad eficiente que no afecta al medio ambiente. Una red inteligente se considera estable cuando puede mantener un funcionamiento confiable y consistente mientras gestiona de manera efectiva diversos factores que pueden provocar interrupciones o desequilibrios en ella. La estabilidad es importante, ya que todo el proceso de transmisión depende del tiempo. En este trabajo se emplea el *deep learning* para predecir la estabilidad en este tipo de redes. Se utilizó una base de datos balanceada y libre de 60 000 observaciones con información de consumidores y productores obtenida a partir de simulaciones. Se concluye que esta técnica obtuvo un alto desempeño (*accuracy* = 97,98 %), lo que permite afirmar que el *deep learning* se puede considerar con seguridad para esta tarea. La cantidad de épocas influyó significativamente en el desempeño de las redes neuronales artificiales (RNA): las que tenían arquitecturas más complejas presentaron un mejor *accuracy*.

PALABRAS CLAVE: análisis / inteligencia artificial / control / aprendizaje automático / red inteligente / estabilidad

PREDICTION OF VOLTAGE STABILITY IN SMART POWER GRIDS

ABSTRACT. Smart grids are a system of electricity transmission networks that enable efficient use of electricity without affecting the environment. A smart grid is considered stable when it can maintain reliable and consistent operation while effectively managing various factors that can cause outages or imbalances within the power grid, stability is important since the entire transmission process is time-dependent. In this work, Deep Learning is employed to predict stability in this type of network. A balanced and free database of 60,000 observations with consumer and producer information obtained from simulations was used. This work concludes that this technique obtained a high performance (Accuracy = 97.98 %), which allows us to affirm that Deep Learning can be safely considered for this task. The number of epochs significantly influenced the performance of the ANNs, those with more complex architectures presented a better Accuracy.

KEYWORDS: analysis / control / artificial intelligence / machine learning / stability / smart grid

1. INTRODUCCIÓN

Las redes inteligentes suministran electricidad de forma controlada y ofrecen una serie de ventajas, entre ellas un mayor crecimiento y una gestión eficaz de las fuentes de energía renovables (Lamnatou et al., 2022). Garantizan la transferencia de información y electricidad entre centrales eléctricas y dispositivos y se utilizan principalmente para resolver problemas relacionados con el suministro de energía (Sai Pandraju et al., 2022). También gestionan la demanda, preservan la red de distribución, reducen costos y ahorran energía (Stright et al., 2022). Una red inteligente es esencialmente un sistema que utiliza tecnología de punta, incluyendo tecnologías de la información y comunicación (TIC), líneas de transmisión, tecnologías de medición, control de generación, subestaciones, medidores y alimentadores, además de tecnologías en las instalaciones (Judge et al., 2022). Los objetivos de las redes inteligentes son: generar un rápido rendimiento en beneficio del consumidor final, reducir los cortes de energía, aumentar la seguridad y la eficiencia energética, reducir la contaminación, regular el consumo de energía y realizar cambios en la ruta de transmisión eléctrica, reducir la vulnerabilidad de las redes de transmisión ante ataques o fallos y facilitar su rápida localización en zonas urbanas y rurales (Panda & Das, 2021).

Garantizar la estabilidad de las redes inteligentes es crucial para mantener una distribución de energía confiable y eficiente (Omitaomu & Niu, 2021); para ello se debe evaluar la funcionalidad del diseño de la red para prever su estabilidad (Singh et al., 2014), lo que permite mitigar la inestabilidad causada por el aumento de las construcciones domésticas y comerciales conectadas a la red o la incorporación de energía verde en ella. Sin embargo, pronosticar la estabilidad del voltaje de las redes eléctricas inteligentes en diferentes condiciones es una tarea de gran complejidad.

Como se mencionó anteriormente, las redes inteligentes integran tecnologías avanzadas y sistemas de comunicación para mejorar la gestión y el control de la generación, distribución y consumo de electricidad. Entre los métodos actuales para garantizar la estabilidad de las redes eléctricas inteligentes frente a escenarios energéticos cambiantes y demandas crecientes, se encuentra el monitoreo y control en tiempo real. Es decir, la implementación de sensores, medidores e infraestructura de comunicación avanzados para monitorear continuamente las condiciones de la red. Estos datos permiten a los operadores identificar problemas y tomar decisiones informadas para evitar la inestabilidad (Ghafouri et al., 2020). Otra solución es el uso del *machine learning* (ML) para anticipar posibles interrupciones o desequilibrios en la red, pues —al analizar datos y patrones históricos— la red inteligente puede abordar los problemas de manera proactiva antes de que se agraven (Azad et al., 2019). Otra es la gestión de recursos energéticos distribuidos (DER, siglas en inglés de *distributed energy resources*), es decir, la incorporación de recursos como paneles solares, turbinas eólicas y sistemas de almacenamiento de energía. La gestión eficaz de estos recursos puede ayudar a equilibrar la oferta y la demanda, reduciendo la tensión en la red durante las horas pico (Massaoudi et al., 2021).

Otra solución es la implementación de programas de respuesta a la demanda que alienten a los consumidores a ajustar su consumo de energía durante períodos de alta demanda. Esto ayuda a prevenir sobrecargas de la red y minimiza la necesidad de medidas de emergencia (Shi et al., 2020). Una medida adicional es la creación de microrredes que puedan funcionar independientemente de la red principal durante emergencias o cortes. Las microrredes pueden garantizar el suministro de energía localizada y reducir el impacto de las perturbaciones en la red más grande (Yoldaş et al., 2017). Finalmente, también sería importante brindar capacitación a los operadores y al personal de mantenimiento para administrar y solucionar problemas de manera efectiva. La mano de obra calificada es esencial para mantener la estabilidad de este tipo de redes (Tufail et al., 2021).

Si bien las estrategias mencionadas anteriormente pueden mejorar la estabilidad de las redes inteligentes, también conllevan ciertas limitaciones y desafíos que deben abordarse, como por ejemplo los altos costos que requiere su implementación. Muchas de las tecnologías y actualizaciones de infraestructura necesarias para las redes inteligentes implican costos iniciales significativos, lo que puede representar un desafío para los gobiernos y las empresas de servicios públicos, especialmente en regiones con recursos financieros limitados (Ma et al., 2013). Garantizar la interoperabilidad entre varios dispositivos, sistemas y protocolos de comunicación es complejo y la falta de tecnologías estandarizadas puede generar problemas de compatibilidad y dificultar la integración perfecta de los componentes. Las redes inteligentes dependen en gran medida de las redes de comunicación para el intercambio de datos en tiempo real. Las fallas o interrupciones de la red pueden afectar su capacidad para operar sin problemas. Finalmente, la transición de redes tradicionales a redes inteligentes puede generar resistencia al cambio por parte de las partes interesadas que están acostumbradas a los sistemas y procesos existentes (Ayadi et al., 2019).

Reemplazar las redes eléctricas tradicionales por redes inteligentes ofrece varios beneficios importantes que pueden conducir a una distribución de electricidad más eficiente, confiable y sostenible. Entre estos beneficios se encuentran el mejoramiento de la eficiencia y la fiabilidad energética, la integración con energías renovables, beneficios económicos, generación de energía descentralizada y sostenibilidad ambiental. La adopción de redes inteligentes representa un cambio transformador de sistemas de energía tradicionales y centralizados a redes dinámicas e interconectadas que son capaces de satisfacer las demandas de un panorama energético que cambia rápidamente (Neffati et al., 2021).

En este trabajo se hace uso del *deep learning* para predecir la estabilidad de las redes inteligentes. Se utilizó una base de datos libre de 60 000 observaciones con información de consumidores y productores sobre doce características predictivas (tiempos de reacción, balances de potencia y coeficientes de elasticidad gama-precio) y una variable independiente (estable/inestable). En la siguiente sección de este documento se presenta el marco teórico; en la tercera, generalidades sobre el *machine learning*; en la cuarta la metodología; en la quinta los

resultados y en la sexta, se discuten estos últimos y se los compara con experiencias similares. Por último, el documento ofrece algunas conclusiones.

2. MARCO TEÓRICO


Según Dileep (2020), el término *redes inteligentes* se refiere comúnmente a las alteraciones tecnológicas y comerciales de los sistemas eléctricos modernos y engloba todo lo que está integrado con ellas, lo que utiliza los servicios de la red y lo que interactúa con ella. Por otro lado, Muthamizh Selvam et al. (2016), las definen como un complejo sistema de subsistemas tecnológicos de comercialización de electricidad y de servicios articulados con los sectores empresarial, legislativo, político y social. En el aspecto técnico, las redes inteligentes incluyen las redes de transmisión y distribución, las instalaciones de producción, consumo y almacenamiento, así como los sistemas relacionados de toma de decisiones operativas y de inversión. También tienen fuertes conexiones con otras fuentes de energía, dominios a través del acoplamiento de sectores y la electrificación de dominios energéticos como la calefacción y refrigeración de edificios, el transporte y los procesos industriales (Yapa et al., 2021). Las redes inteligentes permiten la integración de tecnologías de generación de energía renovable a la red de transmisión, lo que posibilita un acceso eficiente y fiable a la energía con la integración de tecnologías informáticas y de comunicación digital (Mollah et al., 2021). La implantación de redes inteligentes viene motivada por la realidad en la que están inmersas las empresas de servicios públicos, junto con valores intrínsecos como la cultura empresarial, la madurez tecnológica y de procesos, el mercado actual, así como el escenario socioeconómico y medioambiental de su zona de concesión (Liu et al., 2022).

Una de sus principales características es la autocuración; es decir, pueden proporcionar una serie de beneficios que se prestan a un sistema más estable y eficiente. Dado que sus principales funciones incluyen el monitoreo y reacción en tiempo real, permiten que el sistema se ajuste constantemente a un estado óptimo (Fan et al., 2021). De hecho, gracias a la autorreparación, pueden reducir los cortes de energía y minimizar su duración cuando se producen, pueden detectar señales anómalas, realizar reconfiguraciones adaptativas y aislar las perturbaciones, eliminarlas o minimizarlas durante tormentas o catástrofes (Ashrafi et al., 2021).

Por otro lado, estas redes tienen capacidad de anticipación: buscan automáticamente problemas que podrían desencadenar perturbaciones mayores en el sistema y aíslan las partes de la red que experimentan fallos para evitar la propagación de cortes y permitir una restauración más rápida (Shobole & Wadi, 2021). Las redes inteligentes no solo proporcionan energía, sino también servicios que permiten el funcionamiento eficiente y seguro de un sistema eléctrico, mientras que las empresas de red mantienen el equilibrio del sistema, garantizan la estabilidad y la seguridad del suministro, conectan físicamente a productores y consumidores y permiten las transacciones de energía (Emmanuel et al., 2019). Entre los principales objetivos de las redes

inteligentes se encuentran: utilizar la infraestructura de transmisión existente de forma más eficiente, aumentar la capacidad de acogida de fuentes de energía renovables, vehículos eléctricos, bombas de calor y otras tecnologías de ahorro energético, mejorar el funcionamiento de los mercados energéticos y proporcionar una mayor flexibilidad a todas las partes interesadas, incluidos los agentes más pequeños, como los propietarios de recursos energéticos distribuidos (Ullah et al., 2021). La Figura 1 presenta los principales beneficios de las redes inteligentes.

Figura 1
Ventajas de las redes inteligentes



En una red inteligente, la información sobre la demanda de los consumidores se recoge, se evalúa de forma centralizada con respecto a las condiciones de suministro y se envía a los clientes una propuesta de precios para que decidan su consumo (Babar et al., 2020). Debido a que todo el proceso depende del tiempo, la estimación dinámica de la estabilidad de la red se convierte no solo en una preocupación, sino en un requisito. Por ello, es importante comprender y anticipar las perturbaciones y fluctuaciones en el consumo y la producción de energía introducidas por los participantes del sistema de forma dinámica, considerando no solo los aspectos técnicos, sino también cómo responden los participantes a los cambios en los precios de la energía (Babar et al., 2020). En la explotación y planificación de los sistemas eléctricos, la evaluación y predicción dinámicas de la seguridad son fundamentales para garantizar el suministro ininterrumpido de electricidad a los consumidores y mejorar la fiabilidad del sistema (Mukherjee & De, 2020). La estabilidad se refiere a la capacidad de las redes inteligentes para mantener el equilibrio a lo largo del tiempo, es decir, evitar apagones, independientemente de la demanda de los consumidores (Tiwari et al., 2022). En todo el mundo, en los sistemas de distribución y generación de energía eléctrica se emplean frecuencias que oscilan entre 50 Hz y 60 Hz. La frecuencia de la señal eléctrica aumenta en épocas de exceso de generación, mientras que disminuye en épocas de subproducción. Por lo tanto, medir la frecuencia de la red en las instalaciones de cada cliente es suficiente para proporcionar al gestor la información necesaria sobre el balance energético actual de la red, para que pueda tarificar su suministro energético e informar a los consumidores (Yapa et al., 2021).

3. MACHINE LEARNING

El *machine learning* (ML), junto con la analítica de datos, son campos de estudio interdependientes e interrelacionados que se centran en la adquisición de conocimiento decisivo (Zhang et al., 2020). Los modelos predictivos se utilizan para aprender patrones a partir de datos, de dos formas: aprendizaje supervisado o no supervisado. El primero parte de un conjunto de datos etiquetados —es decir, se conoce el valor de la variable objetivo—, mientras que en el segundo los datos no están etiquetados; es decir, no se conoce el valor de la variable objetivo (Ibrahim et al., 2020). El ML implica la creación de modelos que se construyen con datos de entrenamiento y se validan con datos de prueba. Actualmente, el ML está siendo ampliamente utilizado en diferentes ramas del conocimiento para realizar predicciones y facilitar la toma de decisiones, gracias a que permite que las máquinas descubran cómo pueden realizar tareas sin estar explícitamente programadas para ello (Lei et al., 2020). Para tareas sencillas, es factible crear algoritmos que indiquen a la máquina cómo ejecutar los pasos necesarios para resolver un problema, pero, para tareas con un mayor grado de complejidad, es más efectivo ayudar a la máquina a desarrollar su propio algoritmo en lugar de especificar cada paso (Kotsiopoulos et al., 2021). El ML se puede utilizar para la clasificación y la regresión: en la primera se pretende predecir la pertenencia a una clase o etiqueta, en la segunda se pretende predecir un valor numérico.

El *deep learning* (DL) es un subcampo del ML que se centra en el uso de redes neuronales artificiales (RNA) con múltiples capas (arquitecturas profundas) para aprender automáticamente jerarquías de características a partir de los datos. Los modelos de DL pueden aprender automáticamente patrones y representaciones complejas a partir de datos sin procesar, sin necesidad de una extensa ingeniería de funciones manual. El DL se inspiró en la forma en que funciona el cerebro humano, por lo tanto, al utilizar una malla de capas, cada una toma información diferente que generará resultados que luego servirán para nuevos cálculos (Heidari et al., 2019). En la ecuación (1) se presenta la ecuación general de una RNA.

$$Output = \sum_{i=1}^n W_i \cdot X_t + bias \quad (1)$$

En (1), *output* es la salida de la neurona, y la función de activación (reLU, sigmoide, tanh) incorpora la no linealidad al modelo. La suma de los pesos es el producto de los valores de entrada y los productos de los pesos correspondientes. Además, la suma ponderada incluye un término constante llamado sesgo.

4. METODOLOGÍA

Los datos empleados provienen de los resultados de simulaciones de la estabilidad de una red en estrella de cuatro nodos de referencia, es decir, tres nodos de consumo y un nodo de generación, tal y como se presenta en la Figura 2.

Figura 2

Red inteligente en estrella de cuatro nodos



Para construir los modelos se utilizó una base de datos gratuita de Kaggle¹. El conjunto de datos contiene 60 000 observaciones, doce características predictivas primarias y una variable dependiente (estable/inestable). Los valores de ambas clases estaban balanceados. Como los datos tenían rangos variables, se utilizó la función *standardscaler* de *sklearn* para normalizar los datos. Esta función lleva todas las variables a la escala 0-1 para eliminar los problemas asociados a la escala de los datos; es decir, que los modelos no generen una buena predicción porque existen diferencias muy grandes en los rangos de variación de las variables. Es necesario aclarar que cada observación proviene de una simulación, no hay valores perdidos y todas las características son numéricas. La Tabla 1 presenta las variables consideradas.

Tabla 1

Base de datos

Variable	Descripción
staf	Variable objetivo (inestable=0 / estable=1)
stafb	Parte real máxima de la raíz de la ecuación diferencial característica
tau1	Tiempo de reacción - productor de energía

(Continúa)

1 Accesible desde el siguiente enlace: <https://www.kaggle.com/datasets/pcbreviglieri/smart-grid-stability>

(Continuación)

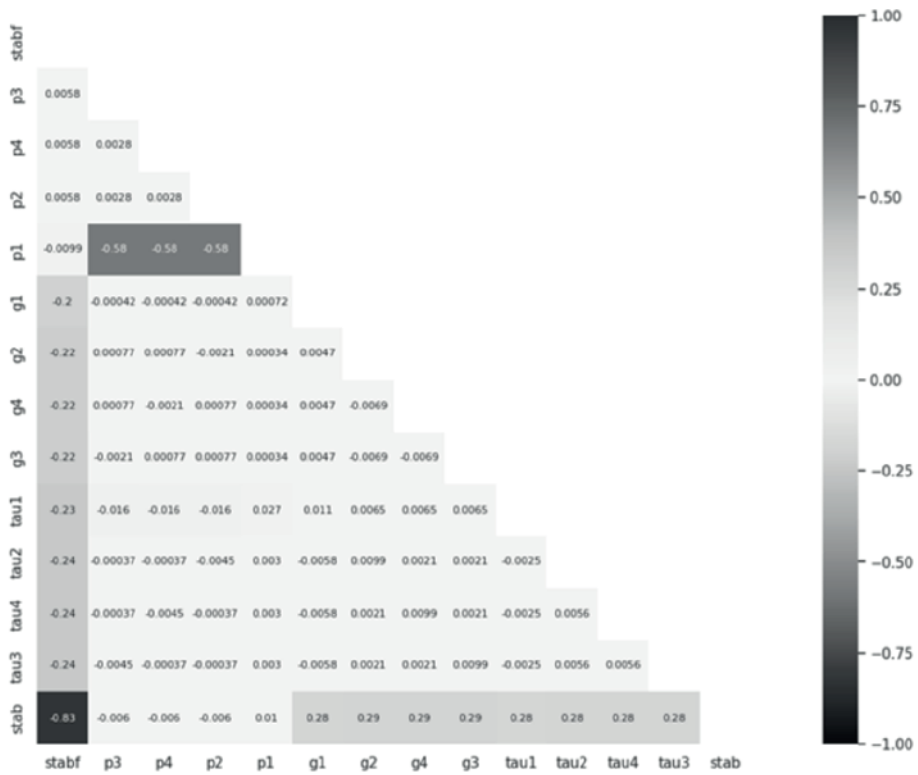
Variable	Descripción
tau2	Tiempo de reacción - consumidor 1
tau3	Tiempo de reacción - consumidor 2
tau4	Tiempo de reacción - consumidor 3
p1	Balance de energía - productor de energía
p2	Balance de energía - consumidor 1
p3	Balance de energía - consumidor 2
p4	Balance de energía - consumidor 3
g1	Coefficiente de elasticidad de precios (gamma) - productor de energía
g2	Coefficiente de elasticidad de precios (gamma) - consumidor 1
g3	Coefficiente de elasticidad de precios (gamma) - consumidor 2
g4	Coefficiente de elasticidad de precios (gamma) - consumidor 3

El tiempo de reacción se refiere al tiempo de respuesta de los participantes de la red para ajustar el consumo o la producción en respuesta a cambios en el precio. El balance de potencia se refiere a la potencia nominal producida o consumida en cada nodo de la red.

El coeficiente de elasticidad del precio se refiere a la variación porcentual de la demanda de electricidad en respuesta a pequeñas variaciones porcentuales en el precio. Las RNA fueron entrenadas en Python utilizando Google Colab. Esta herramienta proporciona máquinas virtuales gratuitas con tarjetas gráficas para realizar algoritmos de ML y tiene la misma potencia que plataformas como Azure o Amazon Web Services. Estas máquinas virtuales de Google se reinician cada doce horas, permiten ejecutar y programar en Python en un navegador web, no requieren configuración, permiten el acceso gratuito a unidades de procesamiento gráfico (GPU) y permiten compartir contenidos. Puede ser utilizada por estudiantes, científicos de datos o investigadores de inteligencia artificial. En el siguiente enlace se encuentra disponible el cuaderno de Colab donde se realizó la construcción del modelo de *deep learning* y la validación cruzada: https://colab.research.google.com/drive/1tLhnpnotuNNnUXYjcQkF_BoTtyLp86v

Antes de construir el modelo, se verificó la correlación entre cada característica numérica y la variable dependiente (“stabf”), así como la correlación entre las características numéricas que conducen a una posible colinealidad no deseada. La Figura 3 presenta un mapa de calor que ofrece una visión general de la correlación entre la variable dependiente y las doce características numéricas. La correlación entre p1 y sus componentes p2, p3 y p4 está por encima de la media, pero no es tan alta como para justificar su eliminación.

Figura 3
Mapa de calor



La Tabla 2 presenta la arquitectura de la RNA óptima empleada en este trabajo. A pesar de que los datos se comportan bien y se distribuyen uniformemente, se propone un ajuste basado en la validación cruzada KFold con diez conjuntos de validación diferentes. Se empleó la función relu como función de activación para las capas ocultas y la sigmoide para la capa de salida por tratarse de una clasificación binaria (estable/ inestable). Como optimizador adam y como función de pérdida binary_crossentropy. El desempeño se evaluará haciendo uso de la métrica *accuracy*.

Tabla 2

Configuración de la RNA

Capa	Unidades	Inicializador kernel	Activación
1	24	Uniforme	relu
2	24	Uniforme	relu
3	12	Uniforme	relu
Salida	1	Uniforme	sigmoide

La métrica $accuracy(2)$ puede ser obtenida de la matriz de confusión en la Tabla 3. TN son los valores que fueron negativos en la predicción y también fueron negativos en los valores reales. TP son los valores que fueron positivos en la predicción y también fueron positivos en los valores reales. FN son los valores que fueron negativos en la predicción y no fueron negativos en los valores reales. Y FP son los valores que fueron positivos en la predicción y no fueron positivos en los valores reales.

Tabla 3

Matriz de confusión

Valores	Valores predichos	
	negativo	positivo
negativo	verdadero-negativo	falso-positivo
positivo	falso-negativo	verdadero-positivo

Accuracy: % de predicciones correctas:

$$Accuracy = \frac{(TP+TN)}{Total} \tag{2}$$

Los resultados de la métrica $accuracy$ en cada conjunto de validación KFold [1-10], se presentan en la Tabla 4.

Tabla 4

Resultados de la validación cruzada

k-Fold	1	2	3	4	5	6	7	8	9	10
Accuracy	0,963	0,975	0,975	0,982	0,980	0,986	0,985	0,985	0,989	0,986

5. DISCUSIÓN

En esta sección se comparan los resultados con otros estudios encontrados en la literatura. En el trabajo realizado por Alsirhani et al., (2023), se construyó un modelo empleando un perceptrón multicapa-máquina de aprendizaje extremo (MLP-ELM) para predecir la estabilidad de redes eléctricas inteligentes; obtuvieron un *accuracy* del 95,8 %, una precisión del 90 %, una recuperación del 88 % y una puntuación F1 del 89 %. Concluyeron que esta técnica supera a las técnicas tradicionales de ML. Alazab et al., (2020) desarrollaron un modelo empleando la técnica de memoria multidireccional a corto y largo plazo (MLSTM, por sus siglas en inglés) para predecir la estabilidad de redes eléctricas inteligentes; obtuvieron un *accuracy* del 99,07 % y concluyeron que esta técnica es mejor que otras empleadas en aprendizaje profundo: por ejemplo, la unidad recurrente cerrada (GRU, por sus siglas en inglés), la red neuronal recurrente (RNN, por sus siglas en inglés) y las redes neuronales de memoria de corto-largo plazo (LSTM, por sus siglas en inglés). Bashir et al. (2021) entrenaron diferentes modelos de ML (máquinas de vectores de soporte, k-vecinos más cercanos K-NN, regresión logística, naïve-Bayes, redes neuronales y árboles de decisión) para predecir la estabilidad de las redes eléctricas inteligentes y resaltan la superioridad del algoritmo de clasificación de árboles de decisión, el cual superó a otros algoritmos de última generación y obtuvo una precisión del 100 %, una recuperación del 99,9 %, una puntuación F1 del 100 % y un *accuracy* del 99,96 %.

Como hipótesis se sugiere que el modelo predictivo construido con *deep learning* funciona mejor que otros tipos de modelos de ML, sobre todo por su capacidad de aprender automáticamente representaciones jerárquicas a partir de datos, lo que puede conducir a un mejor rendimiento en tareas complejas. Se debe señalar que esta técnica no es una solución única para todos y su idoneidad debe evaluarse en función del problema específico, los datos disponibles, los recursos computacionales y otros factores. En definitiva, se logró el objetivo planteado: el modelo construido con *deep learning* permitirá a los operadores de redes inteligentes tomar decisiones posteriores en relación con la estabilidad de las redes eléctricas inteligentes, gestionar de forma proactiva el rendimiento de la red, prevenir eventos de inestabilidad y garantizar un sistema de distribución de energía más confiable y eficiente.

Es importante recordar que el objetivo del modelado predictivo es encontrar tendencias que se generalicen a datos no analizados, en lugar de registrar los datos aprendidos durante el entrenamiento. Las métricas de rendimiento deben calcularse después de realizar la validación cruzada. Como puede haber desequilibrio de clases o problemas de sobrentrenamiento también se deben analizar los modelos que están más alejados del caso aleatorio, además de aquellos que se basan únicamente en altas precisiones.

CONCLUSIONES

En este trabajo se ha empleado el *deep learning* para predecir la estabilidad de voltaje en redes eléctricas inteligentes. Se empleó una validación cruzada KFold (10) y se calculó la métrica de desempeño *accuracy* para cada conjunto de validación. El *deep learning* demostró ser una herramienta de predicción excepcional para esta aplicación concreta. Las arquitecturas RNA más complejas obtuvieron mejores resultados que las más sencillas; sin embargo, no es correcto afirmar que esta técnica es superior a las demás, pues el objetivo del investigador, la cantidad y la calidad de los datos disponibles son también relevantes. Además, aspectos como la no normalización de los datos, la no identificación de los parámetros óptimos y un procesamiento inadecuado pueden afectar considerablemente su rendimiento. Trabajos futuros pueden enfocarse en validar el nivel de precisión obtenido con esta técnica en términos prácticos, con ayuda de operadores.

La implantación de redes inteligentes en zonas urbanas y rurales presenta grandes ventajas, ya que estas fomentan el desarrollo de energías renovables, contribuyen a la reducción de gases contaminantes, reducen el impacto ambiental y los daños al ecosistema causados por la construcción de obras de infraestructura eléctrica. Para evitar fallos y colapsos en el sistema compuesto por tales redes, resulta vital predecir su estabilidad con antelación.

REFERENCIAS

- Alazab, M., Khan, S., Krishnan, S. S. R., Pham, Q. V., Reddy, M. P. K. & Gadekallu, T. R. (2020). A multidirectional LSTM model for predicting the stability of a smart grid. *IEEE Access*, 8, 85454-85463. <https://doi.org/10.1109/ACCESS.2020.2991067>
- Alsirhani, A., Alshahrani, M. M., Abukwaik, A., Taloba, A. I., Abd El-Aziz, R. M. & Salem, M. (2023). A novel approach to predicting the stability of the smart grid utilizing MLP- ELM technique. *Alexandria Engineering Journal*, 74, 495-508. <https://doi.org/10.1016/j.aej.2023.05.063>
- Ashrafi, R., Amirahmadi, M., Tolou-Askari, M. & Ghods, V. (2021). Multi-objective resilience enhancement program in smart grids during extreme weather conditions. *International Journal of Electrical Power & Energy Systems*, 129, 106824. <https://doi.org/https://doi.org/10.1016/j.ijepes.2021.106824>
- Ayadi, F., Colak, I. & Bayindir, R. (2019). Interoperability in smart grid. En *7th International Conference on Smart Grid (icSmartGrid)* (pp. 165-169). Institute of electrical and electronics engineers. <https://doi.org/10.1109/icSmartGrid48354.2019.8990680>
- Azad, S., Sabrina, F. & Wasimi, S. (2019). Transformation of smart grid using machine learning. En *29th Australasian Universities Power Engineering Conference (AUPEC)*,

- pp. 1-6. Institute of electrical and electronics engineers. <https://doi.org/10.1109/AUPEC48547.2019.211809>
- Babar, M., Tariq, M. U. & Jan, M. A. (2020). Secure and resilient demand side management engine using machine learning for IoT-enabled smart grid. *Sustainable Cities and Society*, 62, 102370. <https://doi.org/https://doi.org/10.1016/j.scs.2020.102370>
- Bashir, A. K., Khan, S., Prabadevi, B., Deepa, N., Alnumay, W. S., Gadekallu, T. R., & Maddikunta, P. K. R. (2021). Comparative analysis of machine learning algorithms for prediction of smart grid stability. *International Transactions on Electrical Energy Systems*, 31(9). <https://doi.org/10.1002/2050-7038.12706>
- Dileep, G. (2020). A survey on smart grid technologies and applications. *Renewable Energy*, 146, 2589-2625. <https://doi.org/https://doi.org/10.1016/j.renene.2019.08.092>
- Emmanuel, M., Rayudu, R. & Welch, I. (2019). Modelling impacts of utility-scale photovoltaic systems variability using the wavelet variability model for smart grid operations. *Sustainable Energy Technologies and Assessments*, 31, 292-305. <https://doi.org/https://doi.org/10.1016/j.seta.2018.12.011>
- Fan, D., Ren, Y., Feng, Q., Liu, Y., Wang, Z. & Lin, J. (2021). Restoration of smart grids: Current status, challenges, and opportunities. *Renewable and Sustainable Energy Reviews*, 143, 110909. <https://doi.org/https://doi.org/10.1016/j.rser.2021.110909>
- Ghafouri, M., Au, M., Kassouf, M., Debbabi, M., Assi, C., & Yan, J. (2020). Detection and mitigation of cyber-attacks on voltage stability monitoring of smart grids. *IEEE Transactions on Smart Grid*, 11(6), 5227-5238. <https://doi.org/10.1109/TSG.2020.3004303>
- Heidari, A. A., Faris, H., Aljarah, I. & Mirjalili, S. (2019). An efficient hybrid multilayer perceptron neural network with grasshopper optimization. *Soft Computing*, 23(17), 7941-7958. <https://doi.org/10.1007/s00500-018-3424-2>
- Ibrahim, M. S., Dong, W. & Yang, Q. (2020). Machine learning driven smart electric power systems: current trends and new perspectives. *Applied Energy*, 272, 115237. <https://doi.org/https://doi.org/10.1016/j.apenergy.2020.115237>
- Judge, M. A., Khan, A., Manzoor, A. & Khattak, H. A. (2022). Overview of smart grid implementation: frameworks, impact, performance and challenges. *Journal of Energy Storage*, 49, 104056 <https://doi.org/https://doi.org/10.1016/j.est.2022.104056>
- Kotsiopoulos, T., Sarigiannidis, P., Ioannidis, D. & Tzovaras, D. (2021). Machine learning and deep learning in smart manufacturing: the smart grid paradigm. *Computer Science Review*, 40, 100341. <https://doi.org/https://doi.org/10.1016/j.cosrev.2020.100341>
- Lamnatou, Chr., Chemisana, D. & Cristofari, C. (2022). Smart grids and smart technologies in relation to photovoltaics, storage systems, buildings and the environment.

- Renewable Energy*, 185, 1376-1391. <https://doi.org/https://doi.org/10.1016/j.renene.2021.11.019>
- Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N. & Nandi, A. K. (2020). Applications of machine learning to machine fault diagnosis: a review and roadmap. *Mechanical Systems and Signal Processing*, 138, 106587. <https://doi.org/https://doi.org/10.1016/j.ymssp.2019.106587>
- Liu, D., Zhang, Q., Chen, H. & Zou, Y. (2022). Dynamic energy scheduling for end-users with storage devices in smart grid. *Electric Power Systems Research*, 208, 107870. <https://doi.org/https://doi.org/10.1016/j.epr.2022.107870>
- Ma, R., Chen, H. H., Huang, Y. R., & Meng, W. (2013). Smart grid communication: its challenges and opportunities. *IEEE transactions on Smart Grid*, 4(1), 36-46. <https://doi.org/10.1109/TSG.2012.2225851>
- Massaoudi, M., Abu-Rub, H., Refaat, S. S., Chihi, I., & Oueslati, F. S. (2021). Accurate smart grid stability forecasting based on deep learning: point and interval estimation method. En *Kansas Power and Energy Conference (KPEC)* (pp. 1-6). Institute of electrical and electronics engineers. <https://doi.org/10.1109/KPEC51835.2021.9446196>
- Mollah, M. B., Zhao, J., Niyato, D., Lam, K.-Y., Zhang, X., Ghias, A. M. Y. M., Koh, L. H. & Yang, L. (2021). Blockchain for future smart grid: a comprehensive survey. *IEEE Internet of Things Journal*, 8(1), 18-43. <https://doi.org/10.1109/JIOT.2020.2993601>
- Mukherjee, R. & De, A. (2020). Development of an ensemble decision tree-based power system dynamic security state predictor. *IEEE Systems Journal*, 14(3), 3836-3843. <https://doi.org/10.1109/JSYST.2020.2978504>
- Muthamizh Selvam, M., Gnanadass, R. & Padhy, N. P. (2016). Initiatives and technical challenges in smart distribution grid. *Renewable and Sustainable Energy Reviews*, 58, 911-917. <https://doi.org/https://doi.org/10.1016/j.rser.2015.12.257>
- Neffati, O. S., Sengan, S., Thangavelu, K. D., Kumar, S. D., Setiawan, R., Elangovan, M., Mani, D., & Velayutham, P. (2021). Migrating from traditional grid to smart grid in smart cities promoted in developing country. *Sustainable Energy Technologies and Assessments*, 45, 101125. <https://doi.org/10.1016/j.seta.2021.101125>
- Omitaomu, O. A., & Niu, H. (2021). Artificial intelligence techniques in smart grid: a survey. *Smart Cities*, 4(2), 548-568. <https://doi.org/10.3390/smartcities4020029>
- Panda, D. K. & Das, S. (2021). Smart grid architecture model for control, optimization and data analytics of future power networks with more renewable energy. *Journal of Cleaner Production*, 301, 126877. <https://doi.org/10.1016/j.jclepro.2021.126877>
- Sai Pandraju, T. K., Samal, S., Saravanakumar, R., Yaseen, S. M., Nandal, R. & Dhablya, D. (2022). Advanced metering infrastructure for low voltage distribution system in smart

- grid based monitoring applications. *Sustainable Computing: Informatics and Systems*, 35, 100691. <https://doi.org/https://doi.org/10.1016/j.suscom.2022.100691>
- Singh, A. K., Singh, R., & Pal, B. C. (2014). Stability analysis of networked control in smart grids. *IEEE Transactions on Smart Grid*, 6(1), 381-390. <https://doi.org/10.1109/TSG.2014.2314494>
- Shi, Z., Yao, W., Li, Z., Zeng, L., Zhao, Y., Zhang, R., Tang, Y., & Wen, J. (2020). Artificial intelligence techniques for stability analysis and control in smart grids: Methodologies, applications, challenges and future directions. *Applied Energy*, 278, 115733. <https://doi.org/10.1016/j.apenergy.2020.115733>
- Shobole, A. A. & Wadi, M. (2021). Multiagent systems application for the smart grid protection. *Renewable and Sustainable Energy Reviews*, 149, 111352. <https://doi.org/https://doi.org/10.1016/j.rser.2021.111352>
- Stright, J., Cheetham, P. & Konstantinou, C. (2022). Defensive cost-benefit analysis of smart grid digital functionalities. *International Journal of Critical Infrastructure Protection*, 36, 100489. <https://doi.org/https://doi.org/10.1016/j.ijcip.2021.100489>
- Tiwari, S., Jain, A., Ahmed, N. M. O. S., Charu, Alkwai, L. M., Dafhalla, A. K. Y. & Hamad, S. A. S. (2022). Machine learning-based model for prediction of power consumption in smart grid. Smart way towards smart city. *Expert Systems*, 39(5), e12832. <https://doi.org/https://doi.org/10.1111/exsy.12832>
- Tufail, S., Parvez, I., Batool, S., & Sarwat, A. (2021). A survey on cybersecurity challenges, detection, and mitigation techniques for the smart grid. *Energies*, 14(18), 5894. <https://doi.org/10.3390/en14185894>
- Ullah, K., Hafeez, G., Khan, I., Jan, S. & Javaid, N. (2021). A multi-objective energy optimization in smart grid with high penetration of renewable energy sources. *Applied Energy*, 299, 117104. <https://doi.org/https://doi.org/10.1016/j.apenergy.2021.117104>
- Yapa, C., de Alwis, C., Liyanage, M. & Ekanayake, J. (2021). Survey on blockchain for future smart grids: technical aspects, applications, integration challenges and future research. *Energy Reports*, 7, 6530-6564. <https://doi.org/https://doi.org/10.1016/j.egy.2021.09.112>
- Yoldaş, Y., Önen, A., Muyeen, S. M., Vasilakos, A. V., & Alan, I. (2017). Enhancing smart grid with microgrids: challenges and opportunities. *Renewable and Sustainable Energy Reviews*, 72, 205-214. <https://doi.org/10.1016/j.rser.2017.01.064>
- Zhang, Y., Xin, J., Li, X. & Huang, S. (2020). Overview on routing and resource allocation based machine learning in optical networks. *Optical Fiber Technology*, 60, 102355. <https://doi.org/https://doi.org/10.1016/j.yofte.2020.102355>