

Artificial Neural Networks in Forecasting Wind Energy: A Bibliometric Approach from 2007 to 2021

Eliseo Zarate-Perez, Ph. D Student¹, Juan Grados, Ph. D², Santiago Rubiños, Ph. D³, Jessica Meza, M. Sc⁴, Yesmi Ortega-Rojas, M. Sc⁵, Herbert Grados-Espinoza, Ph. D Student⁶, Arcelia Rojas, Ph. D⁷

¹⁻⁷ Centro de Investigación en Automatización para el Desarrollo, Universidad Nacional del Callao (UNAC), Perú,
ejzaratep@unac.edu.pe, jhgradosg@unac.edu.pe, slrubiñosj@unac.edu.pe, jrmezaz@unac.edu.pe, ykortegar@unac.edu.pe,
hjgradose@unac.edu.pe, aorojass@unac.edu.pe.

Abstract– The main objective of this study was to develop an evolutionary analysis of artificial neural networks (ANN) in the forecast of wind energy for the period from 2007 to 2021. The SciMat software tool was used to identify the performance and impact measures of the main research topics. For this, 250 research articles were retrieved from the Scopus and Web of Science databases. For the first evaluated period (2007–2011), there is a greater use of ANN models for the forecasting of wind energy. In the second period (2012–2016), the forecast interval approaches based on ANNs are used. Finally, in the third period (2017–2021), hybrid approaches are proposed for forecasting wind energy using ANN models and other approaches. Therefore, the results indicate that this field of research is constantly evolving, without yet reaching its stage of scientific maturity. Furthermore, results show that renewable energy source is the basic and transversal cluster of the application of forecasting wind models.

Keywords-- Energy forecast; artificial neural networks (ANN); wind energy; bibliometric analysis; SciMat.

Digital Object Identifier (DOI):

<http://dx.doi.org/10.18687/LACCEI2022.1.1.85>

ISBN: 978-628-95207-0-5 **ISSN:** 2414-6390

Redes Neuronales Artificiales en la Previsión de la Energía Eólica: Un Enfoque Bibliométrico de 2007 a 2021

Eliseo Zarate-Perez, Ph. D Student¹, Juan Grados, Ph. D², Santiago Rubiños, Ph. D³, Jessica Meza, M. Sc⁴, Yesmi Ortega-Rojas, M. Sc⁵, Herbert Grados-Espinoza, Ph. D Student⁶, Arcelia Rojas, Ph. D⁷
¹⁻⁷ Centro de Investigación en Automatización para el Desarrollo, Universidad Nacional del Callao (UNAC), Perú,
ejzaratep@unac.edu.pe, jhgradosg@unac.edu.pe, slrubiñosj@unac.edu.pe, jrmezaz@unac.edu.pe, ykortegar@unac.edu.pe,
hjgradose@unac.edu.pe, aorojass@unac.edu.pe.

Resumen– El objetivo principal de este estudio fue desarrollar un análisis evolutivo de las redes neuronales artificiales (RNA) en el pronóstico de la energía eólica para el período 2007 a 2021. Se utilizó la herramienta de software SciMat para identificar las medidas de desempeño e impacto de los principales temas de investigación. Para ello, se recuperaron 250 artículos de investigación de las bases de datos Scopus y Web of Science. Para el primer periodo evaluado (2007-2011), se observa un mayor uso de modelos de RNA para el pronóstico de energía eólica. En el segundo período (2012-2016) se utilizan los enfoques de intervalo de pronóstico basados en RNAs. Finalmente, en el tercer periodo (2017-2021) se proponen enfoques híbridos para pronosticar la energía eólica utilizando modelos de RNAs y otros enfoques. Por lo tanto, los resultados indican que este campo de investigación está en constante evolución, sin llegar aún a su etapa de madurez científica. Además, los resultados muestran que la fuente de energía renovable es el clúster básico y transversal de la aplicación de modelos de pronóstico de energía eólica.

Palabras clave-- Previsión de energía; redes neuronales artificiales (RNA); energía eólica; análisis bibliométrico; SciMat.

I. INTRODUCCIÓN

Uno de los principales desafíos para el sector energético mundial es garantizar la seguridad operativa a través de la creciente integración de los recursos de energía renovable (RE) [1], [2]. Actualmente, la industria de la energía eólica está pasando por una transición debido a los rápidos avances en ciencia y tecnología [3]–[6]. Organismos multilaterales clave como la Agencia Internacional de la Energía (AIE) y la Unión Europea (UE) ven en la crisis del Covid-19 una oportunidad para impulsar las energías renovables y favorecer una transición rápida hacia una economía descarbonizada [7]. De hecho, la energía eólica como fuente de energía renovable ha atraído mucha atención y se está desarrollándose rápidamente [1].

Sin embargo, la estructura del sistema de energía eólica es muy complejo. Este incluye tres subsistemas de conversión de energía: el sistema aerodinámico del rotor, del eje del tren de transmisión y el sistema del generador. Es por ello por lo que los modelos de mecanismos no pueden describir con precisión el sistema de energía eólica debido a las incertidumbres de los sistemas, la volatilidad de la energía eólica y la inexactitud de la previsión. Por lo tanto, el establecimiento de un modelo preciso de previsión de energía eólica es extremadamente

fundamental; lo que no solo favorece la programación del sistema de energía, sino que también es beneficioso para una operación económica y eficiente de las turbinas eólicas [8].

En base a ello, la inteligencia artificial (IA) ha producido numerosas herramientas para resolver problemas complejos en aplicaciones del mundo real. Por ejemplo, las redes neuronales artificiales (RNA) operan a altas velocidades, tienen una precisión aceptable y pueden usarse sin la necesidad de estudiar los fenómenos subyacentes utilizando en el enfoque físico [9], [10]. Las RNAs pueden pronosticar con éxito la producción de energía mediante el aprendizaje de patrones dentro de un dominio de información multidimensional [11]. Esta técnica es fundamentalmente vital para desafiar las tendencias anormales de la producción de energía eólica.

La producción histórica de energía eólica está asociada con varios factores estacionales, días festivos, fechas del calendario y tendencias de consumo de energía de los usuarios residenciales [1]. Por lo tanto, la adopción de soluciones de previsiones en energía eólica requiere la determinación de variables, metodologías o conceptos que contribuyan al desarrollo de aplicaciones de RNAs. Por lo tanto, el objetivo principal de este estudio fue realizar un análisis de mapeo científico conceptual de las previsiones de energía eólica utilizando RNAs. Es decir, se realizó un análisis bibliométrico utilizando el software SciMAT (herramienta de análisis de mapeo científico) [12].

Este estudio contribuirá al campo de la investigación al definir tendencias y patrones, identificar temas importantes y sugerir áreas para estudios adicionales. El documento está organizado de la siguiente manera: la Sección II describe el procedimiento del análisis bibliométrico y los datos utilizados. La sección III presenta el análisis conceptual del campo de investigación; que incluye la visualización de temas, redes temáticas y análisis de desempeño. Finalmente, se presentan las conclusiones en la Sección IV.

II. METODOLOGÍA

A. Selección de datos

Para llevar a cabo el análisis, se utilizó la colección de artículos de las bases de datos multidisciplinarias Scopus y Web of Science, que contiene artículos de investigación de alto impacto relacionados con este tema [13]. La búsqueda se

realizó utilizando las palabras clave y operadores en los campos “Título/Resumen/Palabra clave” de las bases de datos, tal como se muestra en la siguiente fórmula: “wind” AND “energy forecast*” AND (“model” OR “approach” OR “technique*”) AND (“artificial neural networks” OR “ANN”). Posteriormente, se seleccionaron solo los documentos relevantes en función del tema abordado y los periodos del horizonte temporal en función de las características del conjunto de documentos encontrados [14].

B. Análisis bibliométrico

El análisis bibliométrico se realizó utilizando el software libre SciMAT, el cual puede ser utilizado para aplicar técnicas de mapeo científico para analizar la evolución social, intelectual y conceptual en un campo de investigación [12], [13], [15]. Esta herramienta utiliza palabras conjuntas y el índice h para formar una base de conocimiento utilizando los conjuntos de datos científicos seleccionados. SciMAT realiza el flujo de trabajo de mapeo científico en los siguientes pasos: adquisición, preprocesamiento de datos, visualización e interpretación de los resultados [12], [16]–[22].

1) *Detección de tema de investigación:* En cada período del horizonte de datos seleccionado, SciMAT detecta los temas de investigación aplicando un análisis de palabras conjuntas a los datos de todos los documentos seleccionados en el campo de investigación [23]. Es decir, se realiza un agrupamiento de palabras clave por tema para ubicar las redes de palabras clave fuertemente vinculadas entre sí y los objetos que son de gran interés para los investigadores [24]. Finalmente, la similitud entre las palabras clave se evalúa utilizando el índice de equivalencia [25].

El gráfico superpuesto indica el número de elementos compartidos mediante una flecha horizontal. La cantidad de elementos nuevos se representa con la flecha de entrada superior, y los elementos incluidos en el período anterior se indican con la flecha de salida superior [17]. Además, el mapa de evolución muestra los temas relacionados que comparten un nombre o el nombre de uno de los temas forma parte de otro nombre, mediante líneas continuas; y la línea punteada muestra la relación conceptual entre ellos. Finalmente, el grosor de la línea es relativo al índice de inclusión, y el tamaño del círculo es equivalente al número de artículos [26].

2) *Visualización de temas de investigación y redes temáticas:* En esta fase, los temas detectados del campo de investigación se visualizan utilizando dos instrumentos diferentes. El primero está relacionado con el diagrama estratégico [27] y el segundo se refiere a la red temática [26]. Cada grupo se puede describir utilizando las medidas de centralidad y densidad de Callon [16]. La centralidad mide el grado de interacción externa de una red con otras. Se define como $c = 10 * \sum e_{uv}$, donde u es un elemento perteneciente al grupo evaluado v es un elemento de otros grupos [16].

De manera similar, la densidad de Callon mide la fuerza interna de la red. Esta interacción se define como $100 \sum e_{ij} / n$, donde i y j son elementos que pertenecen al grupo; y, n es el número de elementos en el clúster [12]. Con base en estos

indicadores, un campo de investigación puede visualizarse como un conjunto de tópicos o temas mapeados en un diagrama estratégico bidimensional y clasificados en cuatro grupos, como se muestra en la Fig. 1 [26].

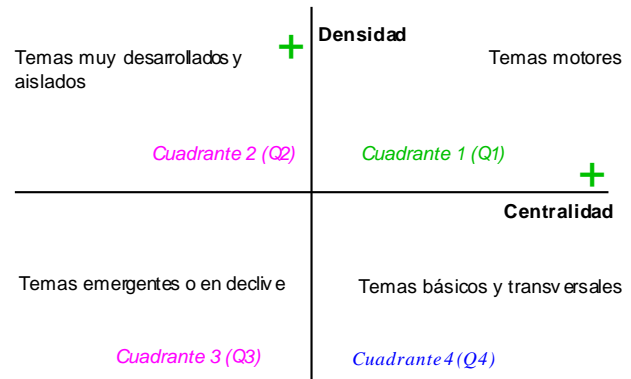


Fig. 1 Diagrama estratégico para el campo de investigación

En la Fig. 1, los temas del Q1 están bien desarrollados y son importantes para la estructura del campo de investigación. Son conocidos como temas motores en el campo de la investigación porque presentan valores elevados en cuanto a centralidad y densidad. Los temas en Q2 presentan enlaces internos bien desarrollados, pero enlaces externos sin mucha relación con el campo de investigación. Por esta razón, se consideran temas menos relevantes en el campo, pero son altamente especializados [26]. Los temas del Q3 están subdesarrollados y se considera que están en declive debido a su baja densidad y centralidad. Finalmente, los temas en el Q4 son los temas emergentes y son importantes para el campo de investigación, pero que todavía no han sido desarrollados. Por lo tanto, los temas de este cuadrante se denominan básicos y transversales en el campo de la investigación [26].

3) *Análisis de desempeño:* El análisis de desempeño se basó en la contribución relativa de los temas al campo de investigación. El desempeño se midió cuantitativa y cualitativamente para establecer los subcampos más destacados e impactantes. Esto se logró utilizando indicadores bibliométricos como el número de documentos publicados, citas e índice H [28]. En otras palabras, la medida de desempeño se calculó considerando los documentos asociados a cada clúster o grupo. El índice H se calculó a partir de las citas de los artículos correspondientes a cada tema [29], [30].

III. RESULTADOS Y DISCUSIÓN

A. Datos seleccionados

Se recuperaron un total de 250 artículos de investigación, quedando 238 documentos relevantes para el estudio bibliométrico, una vez que se excluyeron los artículos según los criterios descritos. El horizonte temporal utilizado en este estudio fue de 2007 a 2021. Además, considerando el número de artículos y tendencias, los datos se subdividieron en tres períodos (2007-2011, 2012-2016 y 2017-2021). La Fig. 2 muestra una distribución irregular y tendencia creciente de los

238 artículos de investigación. Ello demuestra el interés de los investigadores en los métodos de RNAs para pronosticar la energía eólica.




Fig. 2 Artículos recuperados para el análisis bibliométrico

B. Análisis Bibliométrico

1) *Detección de tema de investigación:* Los resultados del número de palabras clave por periodo y su evolución se muestran en la Fig. 3a. El número de palabras clave que entran es mayor que el número de palabras clave que salen. Por lo tanto, el porcentaje de palabras clave que se retienen entre los periodos 1 y 2 es del 58 %, mientras que entre los periodos 2 y 3 es del 78 %. Ello indica que la cantidad de palabras clave nuevas y de transición es baja; sin embargo, la cantidad de palabras clave compartidas ha aumentado en periodos sucesivos; y ello demuestra que el campo de investigación se está consolidando progresivamente.

Las interrelaciones de los temas y el índice de inclusión, a través del grosor de las líneas, muestran la evolución temática del campo de investigación en la Fig. 3b. En el primer periodo (2007-2011), se muestran tres grupos relevantes, a saber, método de pronóstico, red neuronal artificial (RNA) y energía eólica. En el segundo periodo (2012-2016) se presentan los temas de las redes neuronales artificiales relacionados con las fuentes de energía renovable y la energía eólica, como se muestra en la Fig. 4.

En el último periodo (2017-2021), se presentan cuatro grupos clústeres de investigación: redes inteligentes, energía eólica, fuentes de energía renovable y RNAs, como se muestra en la Fig. 3. Los artículos de investigación en este grupo utilizan varios enfoques, de los cuales la aplicación del aprendizaje profundo para la previsión de energías renovables, utilizando un codificador automático de memoria a largo plazo (LSTM) es el más importante [31].

En la Fig. 3, cada grupo está representado por círculos, junto con el número de documentos publicados. Así, si se analiza el gráfico desde el punto de vista del número de documentos, los artículos que involucran fuentes de energía renovables y redes neuronales (RNA) fueron publicados en mayor número, tanto en el segundo como en el tercer periodo

evaluado. Por lo tanto, utilizando el clúster de RNA, se presentan nuevos métodos de pronóstico de las propuestas de energía eólica, mientras que el clúster de fuentes de energía renovable se utiliza para evaluar el rendimiento de los métodos propuestos.

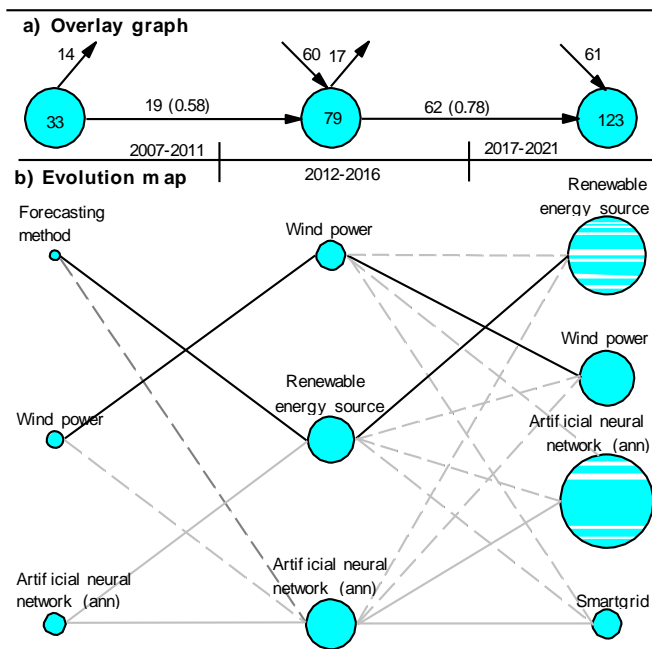


Fig. 3 Mapa de superposición y evolución de los temas de investigación.

2) *Visualización de temas de investigación y redes temáticas:* La Fig. 4 muestra la evolución temática con tres temas para el primer periodo de evaluación (2007-2011). El método de previsión se encuentra en el Q1, que es un tema importante y bien desarrollado para la estructura del campo de investigación. El clúster de energía eólica se encuentra en el Q2 y presenta un desarrollo interno muy desarrollado, pero es un tema aislado durante este periodo. Por el contrario, las RNAs se encuentran en el Q4; considerándose importante para el campo de la investigación, pero que aún se encuentran en un estado emergente.

En la Fig. 5, se muestra el diagrama estratégico de los clústeres que involucra el segundo periodo de evaluación. El gráfico presenta tres temas principales para el campo de investigación en el periodo (2012-2016). Los temas de fuentes de energía renovable y energía eólica se encuentran en el Q1. Por lo tanto, se consideran temas impulsores en el campo de la investigación porque presentan características de alta densidad y centralidad. Los resultados del diagrama estratégico para el tercer periodo (2017-2021) muestran cuatro temas principales de investigación en el campo estudiado y el periodo seleccionado (Fig. 6). El grupo de redes neuronales artificiales pasó del Q3 (periodo anterior) al Q4. Esto muestra la fuerza de interacción interna de la red (densidad), pero aumenta considerablemente la fuerza de interacción externa (centralidad) con las otras redes en el campo de investigación, convirtiéndose en un tema básico y transversal.

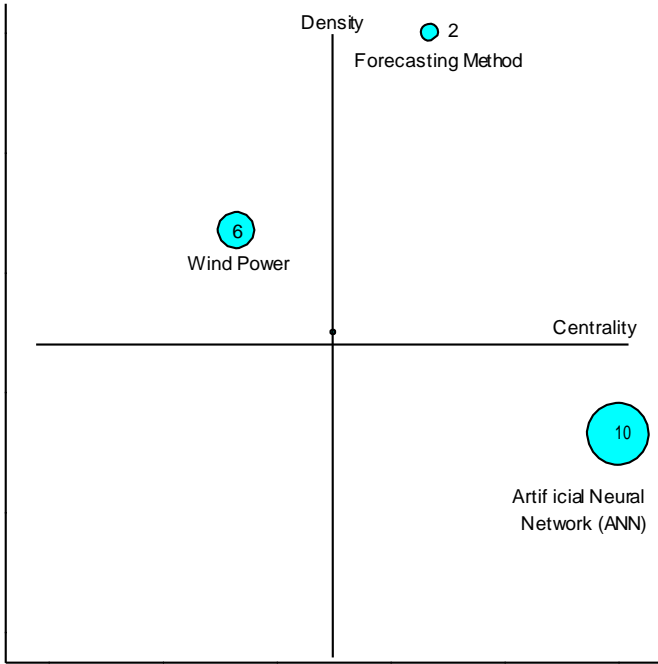


Fig. 4 Diagrama estratégico para el período 2007-2011.

desarrollada; aunque aún no se ha alcanzado su desarrollo de interacción interna.

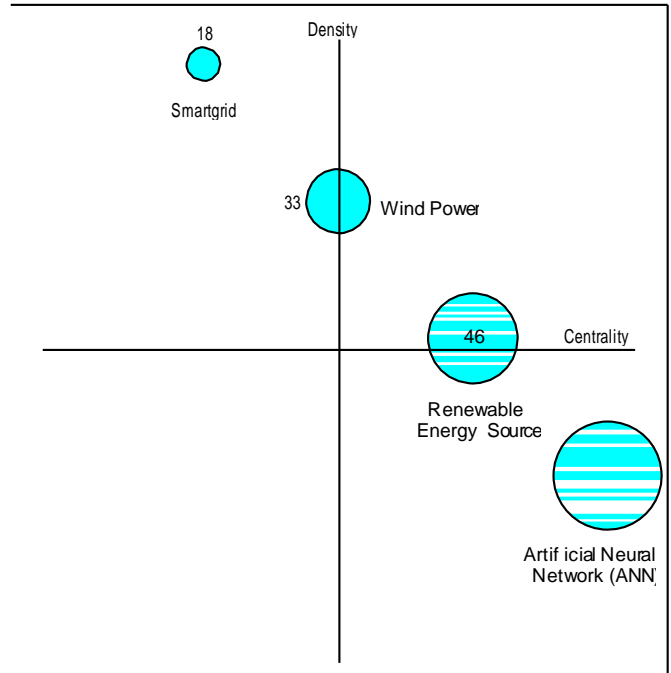


Fig. 6 Diagrama estratégico para el período 2017-2021.

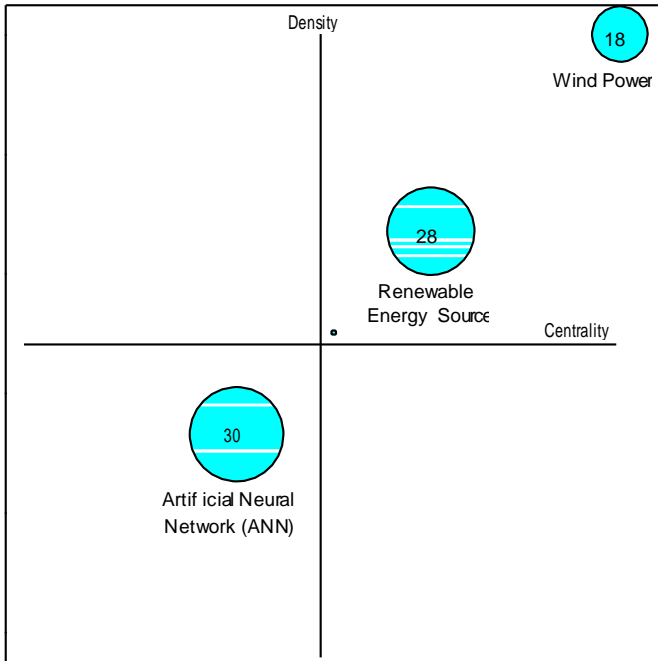


Fig. 5 Diagrama estratégico para el período 2012-2016.

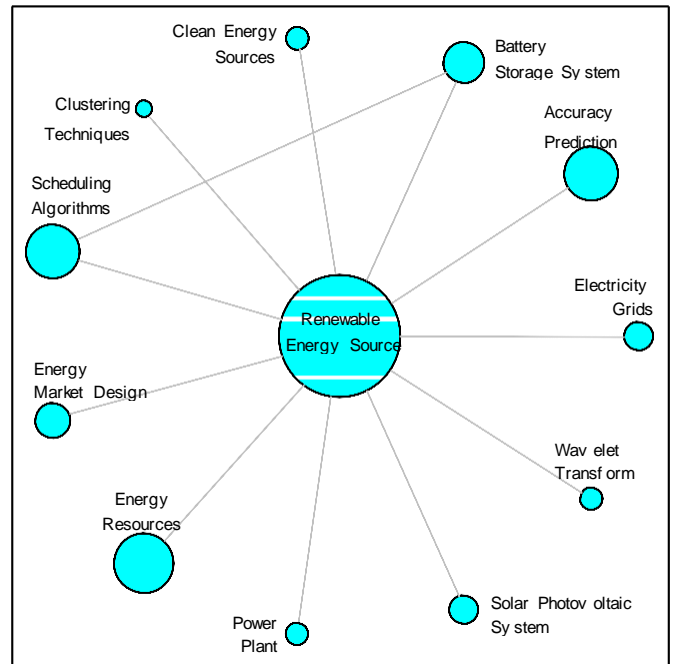


Fig. 7 Red temática de fuente de energía renovable.

Considerando la tendencia de los nuevos enfoques encontrados en el período (2017-2021), se presenta una red temática que muestra el interés de los investigadores en la aplicación de la RNA para previsión en la energía eólica (Fig. 6). Por lo tanto, la red temática del clúster de fuentes de energía renovable se considera un tema importante en el campo (Q1), porque presenta una interacción externa

Las fuentes de energía renovables inician una etapa de crecimiento dentro de la red (fuerza interna). La etapa cubre diferentes temas de investigación (Fig. 7), como la precisión de previsión, los sistemas de almacenamiento por batería, las fuentes de energía limpia, las técnicas de agrupamiento, los

algoritmos de programación, el diseño del mercado energético, los recursos energéticos, las centrales eléctricas, las fuentes de energía renovable, los sistemas solares fotovoltaicos, la transformada de wavelet y las redes eléctricas.

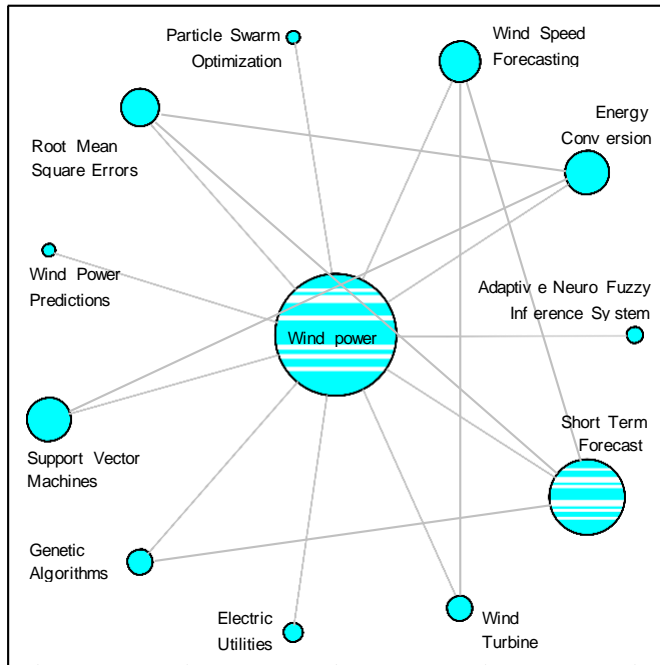


Fig. 8 Red temática de energía eólica.

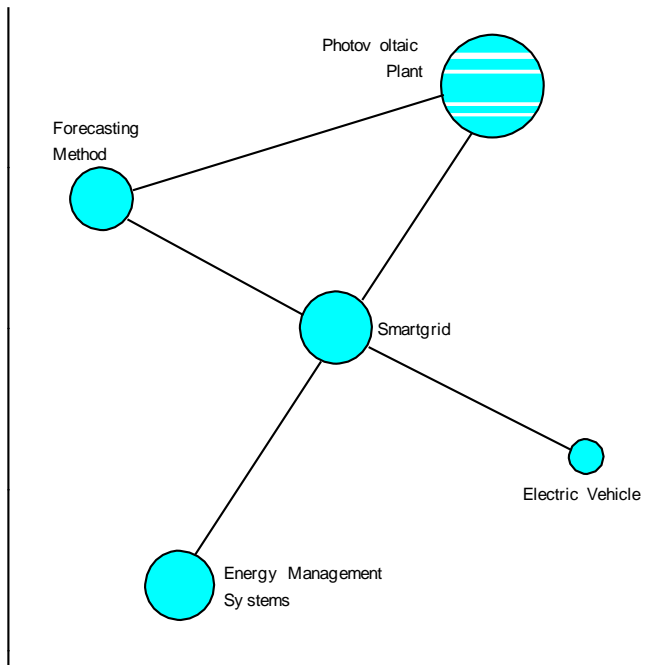


Fig. 9 Red temática para Smartgrid.

Además, el grupo de energía eólica se considera un tema impulsor para el campo de investigación porque se encuentra en el Q1. Este grupo tiene una alta densidad; es decir, una fuerte relación interna y una moderada fuerza de interacción

externa entre sus componentes. Está conformado por el sistema de inferencia neuro fuzzy adaptable, Previsión a corto plazo, aerogenerador, servicios eléctricos, algoritmos genéticos, máquinas vectoriales de soporte, previsiones de energía eólica, el error cuadrático medio (RMSE), optimización de enjambre de partículas, previsión de la velocidad del viento y conversión de energía. A diferencia del clúster de fuentes de energía renovable, el clúster de energía eólica comparte una mayor interacción e inclusión temática en la red.

A continuación, se presenta el clúster de redes inteligentes que corresponde al Q2, con una alta interacción interna pero baja centralidad; considerándose un tema muy desarrollado pero periférico porque no presenta una alta relación externa con las otras redes. Redes inteligentes integra los temas de vehículos eléctricos, sistemas de gestión de energía, métodos de previsión y plantas fotovoltaicas. Como se muestra en la Fig. 9, la mayoría de los temas de este grupo presentan interacción e inclusión temática en la red a través de las líneas de interacción.

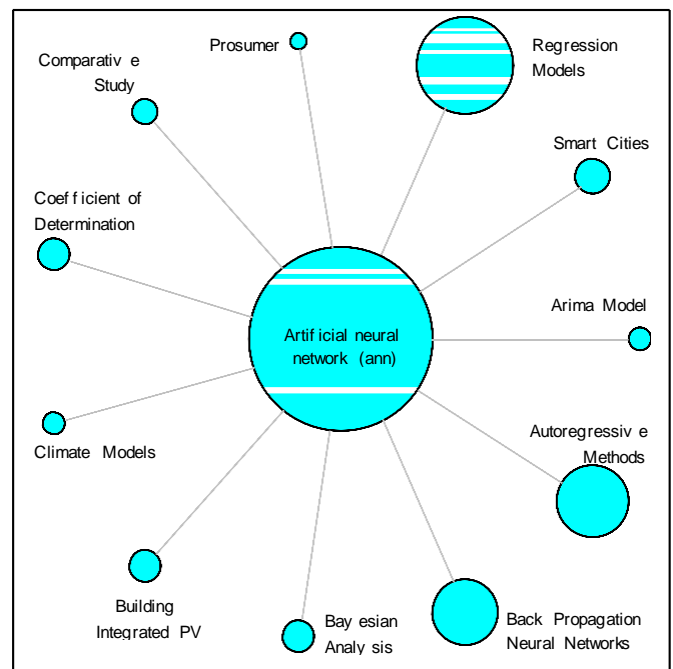


Fig. 10 Red temática para redes neuronales artificiales.

Finalmente, en la Fig. 10 se presenta la red temática del clúster o grupo de red neuronal artificial. Los temas involucrados dentro de este grupo corresponden a los modelos arima, métodos autorregresivos, redes neuronales de retropropagación, análisis bayesiano, edificio fotovoltaico integrado, modelos climáticos, coeficiente de determinación, estudio comparativo, productor-consumidor, modelos de regresión y ciudades inteligentes. El tema análisis bayesiano corresponde a un enfoque que se utiliza para encontrar respuestas de investigación sobre parámetros desconocidos utilizando enunciados de probabilidad.

3) *Análisis de rendimiento*: La Tabla I muestra los resultados de desempeño en términos de número de documentos publicados, citas e índice h. Como se puede observar, el clúster con mejor desempeño en los tres periodos corresponde a la las RNAs. Así, en el primer periodo, el clúster presenta 10 artículos de investigación con índice h de 6 y 864 citas. En el segundo período, el clúster de mayor desempeño presentó 30 artículos de investigación, con índice h de 16 y 1649 citas. Finalmente, el clúster en el último período presenta 55 trabajos de investigación, con un índice h de 11 y 798 citas. En el último período, el clúster de fuentes de energía renovable también tuvo un buen desempeño con 46 artículos de investigación, con un índice h de 9 y 400 citas.

TABLA I
MEDIDAS DE DESEMPEÑO DE TEMAS POR PERÍODO.

Clúster o grupo	Documentos	Índice H	Citas
Periodo 1: 2006-2011			
Forecasting method	2	2	582
Artificial neural network	10	6	864
Wind-power	6	4	261
Periodo 2: 2012-2016			
Artificial neural network	30	16	1649
Renewable energy source	28	14	1350
Wind power	18	10	933
Periodo 3: 2017-2021			
Smartgrid	18	8	419
Wind power	33	6	115
Renewable energy source	46	9	400
Artificial neural network	55	11	798

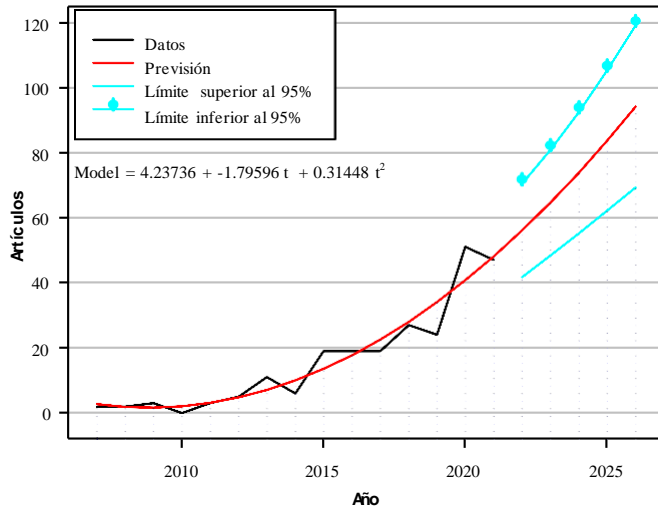


Fig. 11 Proyección de publicación de artículos para el período 2022-2026.

Considerando que los artículos seleccionados para este estudio corresponden a una serie de tiempo, se presentan los resultados del modelo de pronóstico. Este modelo asume que el mejor pronóstico para datos futuros viene dado por una curva de regresión cuadrática: $4.237 + -1.796t + 0.314t^2$. Los resultados de la validación estadística dan como resultado un valor p que es inferior a 0,05; siendo estadísticamente

significativamente diferente de cero al 95,0% de nivel de confianza. Además, el modelo presenta un RMSE de 4,91 y un MAE de 3,0, que mide la magnitud de los errores.

Así, el modelo realizará la proyección del número de artículos sobre los métodos para la evaluación de las RNAs en la previsión energía eólica. Así, considerando que el índice de partida es igual a 2007 (primer año de los datos) como dato inicial de la serie temporal y con un intervalo de muestreo de 1,0 año, se presentan las proyecciones de publicaciones en este campo, como se muestra en la Fig. 11. Las proyecciones indican que el campo de investigación se encuentra en pleno crecimiento; por lo tanto, aún no ha alcanzado su etapa de madurez científica.

IV. CONCLUSIONES

Se utilizó el SciMAT para el análisis bibliométrico de la evolución temática de los métodos de redes neuronales en la previsión de energía eólica. Esto se hizo utilizando las publicaciones disponibles de las bases de datos Scopus y Web of Science desde 2007 hasta 2021. Los resultados muestran que el campo de investigación abordado presenta temas muy importantes que contribuyen a la sostenibilidad energética. El gráfico de superposición de período a período presenta un alto porcentaje de palabras clave que permanecen entre subperíodos. Además, el campo de investigación está en constante evolución, pero aún no ha alcanzado su etapa de madurez científica. Esto se evidencia en el pronóstico de producción científica para los próximos cinco años, siendo estadísticamente significativamente diferente de cero al 95,0% de nivel de confianza, con un p-valor de 0,0014.

En el primer período (2007-2011), los métodos de previsión de MLP (Multilayer Perceptron) son de gran interés para los investigadores en la aplicación del pronóstico de energía eólica. En el segundo período (2012-2016), los modelos de redes neuronales de onda diagonal recurrente combinados con técnicas difusas, enfoques de combinación adaptativa bayesiana, método híbrido de lógica difusa, e intervalos de predicción basados en redes neuronales son los métodos con mayor importancia.

En el tercer período (2017-2021), las técnicas más importantes se basaron en modelos híbridos. Entre ellos se encuentran métodos de aprendizaje profundo que utilizan el codificador automático LSTM, MLP con un algoritmo de máquina de aprendizaje extremo (ELM), MLP con un enfoque estadístico de regresión, propagación inversa de redes neuronales utilizando el método de pronóstico gris, y aplicaciones basadas en web basadas en enfoques de RNAs.

Por lo tanto, en el período final, las energías renovables emergen como los clústeres básicos y transversales, que tienen una importancia considerable por su impacto dentro del campo de la investigación. De igual manera, los temas motores del campo evaluado fueron presentados a través del clúster de energía eólica y RNAs que presentan temas muy importantes para el campo de la investigación.

AGRADECIMIENTOS

A la Universidad Nacional del Callao por el apoyo en parte en este trabajo de investigación.

REFERENCIAS

- [1] T. Ahmad, H. Zhang, and B. Yan, "A review on renewable energy and electricity requirement forecasting models for smart grid and buildings," *Sustain. Cities Soc.*, vol. 55, p. 102052, Apr. 2020, doi: 10.1016/j.scs.2020.102052.
- [2] Y. Yu, J. Yang, and B. Chen, "The Smart Grids in China—A Review," *Energies 2012, Vol. 5, Pages 1321-1338*, vol. 5, no. 5, pp. 1321–1338, May 2012, doi: 10.3390/EN5051321.
- [3] Z. Huang and A. Mu, "Numerical research on a novel flow field design for vanadium redox flow batteries in microgrid," *Int. J. Energy Res.*, vol. 45, no. 10, pp. 14579–14591, 2021, doi: 10.1002/er.6710.
- [4] Y. Zhu, M. Cheng, W. Hua, and W. Wang, "A Novel Maximum Power Point Tracking Control for Permanent Magnet Direct Drive Wind Energy Conversion Systems," *Energies 2012, Vol. 5, Pages 1398-1412*, vol. 5, no. 5, pp. 1398–1412, May 2012, doi: 10.3390/EN5051398.
- [5] H. G. Jeong, R. H. Seung, and K. B. Lee, "An Improved Maximum Power Point Tracking Method for Wind Power Systems," *Energies 2012, Vol. 5, Pages 1339-1354*, vol. 5, no. 5, pp. 1339–1354, May 2012, doi: 10.3390/EN5051339.
- [6] M. Arzani, A. Abazari, A. Oshnoei, M. Ghafuri, and S. M. Muyeen, "Optimal Distribution Coefficients of Energy Resources in Frequency Stability of Hybrid Microgrids Connected to the Power System," *Electron. 2021, Vol. 10, Page 1591*, vol. 10, no. 13, p. 1591, Jul. 2021, doi: 10.3390/ELECTRONICS10131591.
- [7] J. Blazquez, M. Galeotti, and J. M. Martín-Moreno, "Green recovery packages for a post-Covid-19 world: A lesson from the collapse of Spanish wind farms in the past financial crisis," *Renew. Sustain. Energy Rev.*, vol. 151, p. 111570, Nov. 2021, doi: 10.1016/j.rser.2021.111570.
- [8] Y. Xu, L. Jia, and W. Yang, "Correlation based neuro-fuzzy Wiener type wind power forecasting model by using special separate signals," *Energy Convers. Manag.*, vol. 253, p. 115173, Feb. 2022, doi: 10.1016/j.enconman.2021.115173.
- [9] T. Rajaei, H. Ebrahimi, and V. Nourani, "A review of the artificial intelligence methods in groundwater level modeling," *J. Hydrol.*, vol. 572, pp. 336–351, May 2019, doi: 10.1016/j.jhydrol.2018.12.037.
- [10] F. Wang, Z. Mi, S. Su, and H. Zhao, "Short-Term Solar Irradiance Forecasting Model Based on Artificial Neural Network Using Statistical Feature Parameters," *Energies 2012, Vol. 5, Pages 1355-1370*, vol. 5, no. 5, pp. 1355–1370, May 2012, doi: 10.3390/EN5051355.
- [11] S. A. Kalogirou, "Artificial neural networks in renewable energy systems applications: A review," *Renew. Sustain. Energy Rev.*, vol. 5, no. 4, pp. 373–401, Dec. 2000, doi: 10.1016/S1364-0321(01)00006-5.
- [12] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, "SciMAT: A new science mapping analysis software tool," *J. Am. Soc. Inf. Sci. Technol.*, vol. 63, no. 8, pp. 1609–1630, Aug. 2012, doi: 10.1002/asi.22688.
- [13] C. Díaz-López, M. Carpio, M. Martín-Morales, and M. Zamorano, "Analysis of the scientific evolution of sustainable building assessment methods," *Sustain. Cities Soc.*, vol. 49, p. 101610, Aug. 2019, doi: 10.1016/j.scs.2019.101610.
- [14] D. Moher, A. Liberati, J. Tetzlaff, and D. G. Altman, "Preferred Reporting Items for Systematic Reviews and Meta-Analyses: The PRISMA Statement," *PLoS Med.*, vol. 6, no. 7, p. e1000097, Jul. 2009, doi: 10.1371/journal.pmed.1000097.
- [15] A. Samia, M. M. Djamel, and B. Samira, "Proposal of a flexible and universal survey generator for a Business Intelligence," Oct. 2018, doi: 10.1109/CEIT.2018.8751913.
- [16] E. Zarate-Perez, R. Sebastián, and J. Grados, "Online Labs: A Perspective Based on Bibliometric Analysis," in *19th LACCEI International Multi-Conference for Engineering, Education Caribbean Conference for Engineering and Technology: "Prospective and Trends in Technology and Skills for Sustainable Social Development"* and "Leveraging Emerging Technologies to Con," 2021, vol. 2021-July, doi: 10.18687/LACCEI2021.1.1.267.
- [17] E. J. Zarate, A. L. T. S. Da Motta, and J. H. Grados, "Evolution of Smart Grid Assessment Methods: Science Mapping and Performance Analysis," *Int. J. Eng. Res. Technol.*, vol. 13, pp. 5166–5175, 2020.
- [18] A. Z. Arsal et al., "Solid State Switching Control Methods: A Bibliometric Analysis for Future Directions," *Electron. 2021, Vol. 10, Page 1944*, vol. 10, no. 16, p. 1944, Aug. 2021, doi: 10.3390/ELECTRONICS10161944.
- [19] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, "SciMAT: Version 1.0 User guide," Spain, 2016.
- [20] J. López-Belmonte, A. Segura-Robles, A.-J. Moreno-Guerrero, and M.-E. Parra-González, "Robotics in Education: A Scientific Mapping of the Literature in Web of Science," *Electron. 2021, Vol. 10, Page 291*, vol. 10, no. 3, p. 291, Jan. 2021, doi: 10.3390/ELECTRONICS10030291.
- [21] R. M. G. Salvador, N. Novas, A. Alcayde, D. El Khaled, and F. G. Montoya, "Electronics and Its Worldwide Research," *Electron. 2020, Vol. 9, Page 977*, vol. 9, no. 6, p. 977, Jun. 2020, doi: 10.3390/ELECTRONICS9060977.
- [22] M.-D. González-Zamar, E. Abad-Segura, E. Vázquez-Cano, and E. López-Meneses, "IoT Technology Applications-Based Smart Cities: Research Analysis," *Electron. 2020, Vol. 9, Page 1246*, vol. 9, no. 8, p. 1246, Aug. 2020, doi: 10.3390/ELECTRONICS9081246.
- [23] M. Callon, J.-P. Courtial, W. A. Turner, and S. Bauin, "From translations to problematic networks: An introduction to co-word analysis," *Soc. Sci. Inf.*, vol. 22, no. 2, pp. 191–235, Mar. 1983, doi: 10.1177/053901883022002003.
- [24] N. Coulter, I. Monarch, and S. Konda, "Software engineering as seen through its research literature: A study in co-word analysis," *J. Am. Soc. Inf. Sci.*, vol. 49, no. 13, pp. 1206–1223, Nov. 1998, doi: 10.1002/(SICI)1097-4571(1998)49:13<1206::AID-ASI7>3.0.CO;2-F.
- [25] M. Callon, J. P. Courtial, and F. Laville, "Co-word analysis as a tool for describing the network of interactions between basic and technological research: The case of polymer chemistry," *Scientometrics*, vol. 22, no. 1, pp. 155–205, Sep. 1991, doi: 10.1007/BF02019280.
- [26] M. J. Cobo, A. G. López-Herrera, E. Herrera-Viedma, and F. Herrera, "An approach for detecting, quantifying, and visualizing the evolution of a research field: A practical application to the Fuzzy Sets Theory field," *J. Informetr.*, vol. 5, no. 1, pp. 146–166, Jan. 2011, doi: 10.1016/j.joi.2010.10.002.
- [27] H. Qin, "Knowledge Discovery Through Co-Word Analysis," *IDEALS*, vol. 48, no. 1, pp. 133–159, 1999, doi: http://hdl.handle.net/2142/8267.
- [28] S. Alonso, F. J. Cabrerizo, E. Herrera-Viedma, and F. Herrera, "h-Index: A review focused in its variants, computation and standardization for different scientific fields," *J. Informetr.*, vol. 3, no. 4, pp. 273–289, Oct. 2009, doi: 10.1016/j.joi.2009.04.001.
- [29] E. J. Zarate, M. Palumbo, A. L. T. S. da Motta, and J. H. Grados, "FORECASTING PHOTOVOLTAIC POWER USING BAGGING FEED-FORWARD NEURAL NETWORK," *www.tjprc.org SCOPUS Indexed Journal editor@tjprc.org*, vol. 10, pp. 12479–12488, Jun. 2020.
- [30] E. J. Z. Perez, M. P. Fernández, and A. L. T. S. da Motta, "Performance Analysis of Bagging Feed-Forward Neural Network for Forecasting Building Energy Demand," *Curr. J. Appl. Sci. Technol.*, vol. 30, no. 2, pp. 1–12, Oct. 2018, doi: 10.9734/CJAST/2018/44836.
- [31] A. Gensler, J. Henze, B. Sick, and N. Raabe, "Deep Learning for solar power forecasting - An approach using AutoEncoder and LSTM Neural Networks," in *2016 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2016 - Conference Proceedings*, Feb. 2017, pp. 2858–2865, doi: 10.1109/SMC.2016.7844673.