

# Optimization of Solar PV Power Forecasting Using Bootstrap Techniques and the Feed-Forward Neural Network Model

Eliseo Zarate-Perez, Ph. D. Student<sup>1,2</sup>, Mariana Palumbo, Ph. D.<sup>3</sup>, Ana da Motta, Ph. D.<sup>2</sup>, and Juan Grados, Ph. D.<sup>4</sup>

<sup>1</sup>Facultad de ingeniería, Universidad Privada del Norte (UPN), Peru, eliseo.zarate@upn.edu.pe

<sup>2</sup>Pós-Graduação em Engenharia Civil, Universidade Federal Fluminense, Brasil, ezarate@id.uff.br

<sup>3</sup>Department Architecture, Universitat Politècnica de Catalunya (UPC), España, mariana.palumbo@upc.edu

<sup>4</sup>Facultad de Ingeniería Eléctrica y Electrónica, Universidad Nacional del Callao (UNAC), Peru, jhgradosg@unac.edu.pe

*Abstract– The outbreak of the COVID-19 disease has exerted a deep and extensive influence on the energy sector. The work modality and lifestyle caused by the confinement policy have increased electricity consumption in the residential sector. In such a way that the application of photovoltaic solar energy (PV) is rapidly evolving to mitigate the problems caused. However, due to the variability and uncertainty of solar irradiance, several technical challenges are created to produce PV energy. To reduce these adverse effects, forecasting of energy production at multiple scales is used. In this sense, the objective of this study is to determine the forecast performance of a hybrid model through the application of a Feed-Forward Neural Network (FFNN), together with the application of the moving block bootstrap technique (MBB), using the real data of the production of a PV system. The results show that the FFNN method combined with MBB techniques consistently outperform the original FFNN method in terms of forecast accuracy. That is, the original model presents a performance of 4.48% percentage forecast error (MAPE), compared to 3.14% for the proposed hybrid model. Finally, through the Ljung-Box test it is shown that the results are not correlated; therefore, the recommended model is validated.*

*Keywords-- Solar power forecasting, bootstrap, feed-forward neural network, forecasting technique, optimization.*

**Digital Object Identifier (DOI):**

<http://dx.doi.org/10.18687/LACCEI2022.1.1.18>

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



diferentes tipos de metodologías [16], clasificándose en tres categorías: métodos físicos, estadísticos e híbridos [17]. Los modelos físicos describen los procesos de conversión de la energía solar a electricidad utilizando las características de los módulos FV. Así, se realiza la previsión de la energía generada diariamente utilizando las condiciones climáticas esperadas en un día determinado. Por el contrario, los métodos estadísticos se basan en las series temporales estocásticas utilizando métodos de aprendizaje automático [18].

Con respecto a los métodos estadísticos, las redes neuronales artificiales (RNA) se han aplicado con éxito para los pronósticos de suministro de energía FV [19]. Estos métodos aprenden a reconocer patrones de las series temporales utilizando conjuntos de datos de entrenamiento, lo que producen previsiones confiables [20]. Sin embargo, todavía existen limitaciones en todas estas soluciones. Es por ello por lo que se referencian la combinación de dos o más métodos físicos/estadísticos que conduzcan a los denominados modelos híbridos [17]. La idea es combinar diferentes modelos con características únicas para mejorar la previsión de producción de energía [21]. Hay muchos artículos que tratan de una comparación entre las técnicas de pronóstico, entre el enfoque físico/determinista o estadístico; pero no se incluyen los modelos de RNAs. Por ejemplo, [22] enfoca los pronósticos de energía FV comparando la regresión del vector de soporte (SVR) y un método físico, en el rango de 15 min a 5 h por delante.

En tal sentido, la selección del método de pronóstico más adecuado depende de diferentes factores, como la complejidad, la naturaleza, la precisión y adaptabilidad de la estimación [23]. Esto está de acuerdo con otros estudios [12], [24], en los que los métodos de RNA se han utilizado ampliamente para pronosticar la demanda y la producción de energía FV, debido a su mejor desempeño. Sin embargo, para una serie temporal de alta frecuencia (es decir, registros diarios y horarios, etc.), la varianza cambia con el tiempo y de manera no sistemática en muchos casos, de modo que los periodos de varianza alta y baja se alternan; además de la variabilidad y la incertidumbre de la irradiancia a nivel del suelo.

Todo ello genera un mayor nivel de particularidad y, en consecuencia, un mayor nivel de ruido en las series temporales. El nivel de ruido afecta el proceso de aprendizaje de la RNA, disminuyendo la capacidad de generalización y provocando sobreajuste. Sin embargo, las implicaciones de esto podrían reducirse estabilizando y suavizando la variación en la serie temporal utilizando técnicas de arranque (*Bootstrap*) [25]. Algunos estudios mostraron un alto poder predictivo y menos errores en la técnica de arranque cuando esta última se utilizó con otros métodos de previsión; por ejemplo, se referencia un algoritmo de bosque aleatorio en [26]. En [27] se usa las técnicas de *bootstrap*, junto con modelos de promedio ponderado con pesos fijos. De la misma forma, en [28] se presenta un estudio de la combinación de las técnicas *Bootstrap* relacionando métodos del promedio aritmético y el promedio ponderado para la previsión de la

energía eólica. Por lo tanto, el objetivo de este estudio es determinar el rendimiento de la previsión en una forma híbrida del modelo *Feed-Forward Neural Network* (FFNN) y la aplicación de las técnicas *Moving Block Bootstrap* (MBB) utilizando los datos de producción de energía de un sistema FV.

## II. METODOLOGÍA

La Fig. 1 muestra los pasos realizados para obtener el análisis de resultados. Inicialmente, se realizó una transformación de Box-Cox, seguida de una descomposición de tendencia estacional usando Loess (STL, *Seasonal-Trend decomposition using LOESS*) de la muestra en tres partes: estacional, tendencia y residuo. Seguidamente, se crearon 100 subseries de la parte residual mediante la técnica de *MBB*.

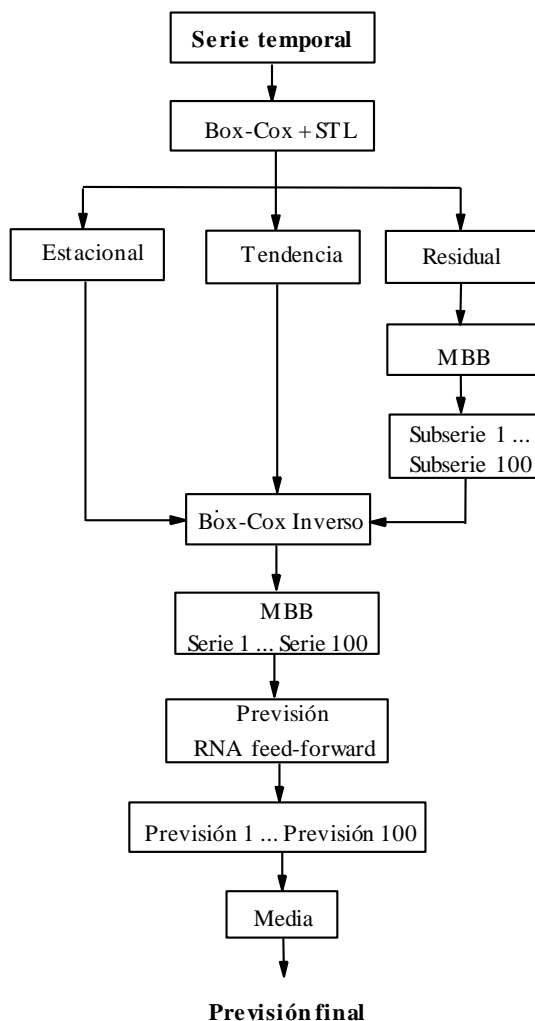


Fig. 1 Ilustración de la secuencia metodológica.

Posteriormente, a cada uno de ellos se unieron los componentes originales de estacional y tendencia, a los que se les aplicó una transformación inversa de Box-Cox para obtener 100 versiones de series *bootstrap* idénticas a la

original. A continuación, se realizaron pronósticos con cada una de las series *bootstrap* utilizando el modelo de FFNN. Finalmente, se obtuvo el promedio de las 100 previsiones para el resultado final.

#### A. Recopilación de datos

La Fig. 2 muestra los datos de producción de un sistema solar FV de 3,63 kWp, en el estado de Río de Janeiro, Brasil. La muestra de datos seleccionada incluía datos de todo un año. Es decir, la serie comenzó el 1 de enero a las 00:00 y finalizó el 31 de diciembre (23:59). Los datos se recolectaron con lecturas tomadas cada 10 s y se obtuvieron promedios de los valores cada 30 min. Los datos recopilados se almacenaron en el dispositivo de medición EnergyLOG plus y luego se transfirieron a una computadora personal. El sistema solar FV de 3,63 kWp constaba de 11 módulos de silicio policristalino, formando grupos en serie y en paralelo para satisfacer los requisitos de voltaje y corriente del inversor. Las principales características del panel se muestran en la Tabla I. Así como las características del inversor se muestran en la Tabla II.

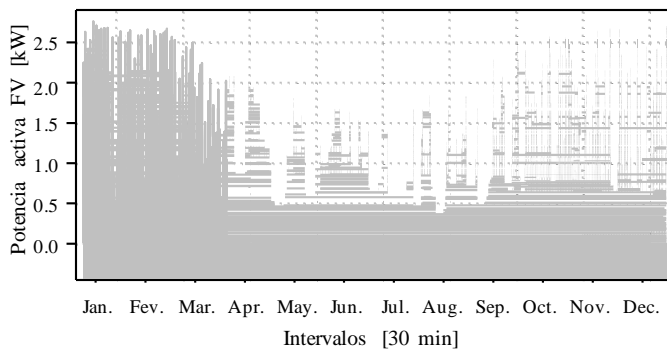


Fig. 2. Datos de potencia activa FV utilizados para evaluar el rendimiento del modelo de previsión.

TABLA I  
CARACTERÍSTICAS ELÉCTRICAS DEL PANEL FOTOVOLTAICO

Ítem	MODULO 330P		
	Especificación	Valor	Unid.
1	Potencia Máxima Nominal (Pmax)	330	W
2	Tensión de funcionamiento (Vmp)	33.9	V
3	Corriente de funcionamiento (Imp)	9.74	A
4	Voltaje en circuito abierto (Voc)	41.1	V
5	Eficiencia del módulo	19.9	%

TABLA II  
CARACTERÍSTICAS DEL INVERSOR

Ítem	Growatt 3000TL		
	Especificación	Valor	Unid.
Entrada (CC)	Max. potencia DC	3200	W
	Max. Voltaje DC	500	V
	Rango de tensión Mpp a plena carga	250–450	V
	Rango de tensión fotovoltaica	120–450	V

Ítem	Growatt 3000TL		
	Especificación	Valor	Unid.
	MPPT		
Salida (CA)	Potencia nominal de salida de CA	2850	W
	Máx. Potencia de CA	3000	W
	Máx. corriente de salida	13	A
	Rango de frecuencia de la red de CA	50, 60 ±5%	Hz
Eficiencia	Eficiencia Max.	97	%

#### B. Transformación Box-Cox

Las transformaciones de Box-Cox incluyen logaritmos y transformaciones de potencia, que están determinadas por el parámetro  $\lambda$  [29]. Estas transformaciones se utilizan normalmente para estabilizar la varianza de una serie temporal y se propusieron originalmente en [29]. A continuación, se presenta la transformación de Box-Coxen la Ecuación 1.

$$\omega_t = \begin{cases} \log(y_t), & \lambda=0; \\ \frac{(y_t^\lambda - 1)}{\lambda}, & \lambda \neq 0. \end{cases} \quad (1)$$

Donde,  $y_t$  son los datos originales de la muestra que se muestra en la Fig. 2;  $y, \omega_t$  son los datos transformados. La transformación de Box-Cox es la identidad cuando  $\lambda = 1$  y el logaritmo cuando  $\lambda = 0$ , o una transformación dentro del rango dado. El parámetro  $\lambda$  está restringido al rango  $[0; 1]$ , y para seleccionar su valor se utilizó el método de Guerrero, como se describe en [29].

#### C. Descomposición STL

Una vez que se obtuvieron los datos transformados ( $\omega_t$ ), estos mostraron varios patrones. Por lo tanto, era conveniente dividirlos en diferentes componentes por medio de la descomposición STL, referenciado como un método poderoso en series temporales [30]. En tal sentido, la descomposición STL divide la serie temporal en sus componentes de tendencia, estacional y residual; como se muestra en la Ecuación 2 [29]. En la ejecución del análisis se utilizó la función  $stl()$  en el software libre R Team Core para la descomposición de la serie de tiempo en sus 3 componentes [31].

$$\omega_t = S_t + T_t + R_t \quad (2)$$

Donde,  $\omega_t$  son los datos de la serie temporal transformados;  $S_t$ ,  $T_t$  y  $R_t$  son los componentes estacionales, tendencia y residual de la serie, respectivamente.

#### D. Inicialización del residual con la técnica de MBB

Un requisito para el pronóstico con series de tiempo es la estacionariedad de los datos recopilados, porque generalmente están correlacionados. De tal forma, se realizó la inicialización del componente residual ( $R_t$ ) utilizando la técnica MBB,

utilizándose el procedimiento descrito en [32]. Para la serie de tiempo de producción solar FV con una longitud  $n$  y un tamaño de bloque de  $L$ , se utilizaron  $[n / L] + 2$  bloques del residual de la subserie de la descomposición STL.

Posteriormente, para obtener una serie de la misma longitud que la muestra, se descartaron los máximos valores posibles para llegar a la longitud requerida [32], utilizándose la función `bld.mbb.bootstrap()` en el `Software R Team Core` [33]. Posteriormente de realizar la inicialización del residual ( $R_t$ ), cada subserie de `bootstrap` se unió a los componentes estacionales y de tendencia, arrojando un total de 100 series similares. Finalmente, se realizó la transformación inversa de Box-Cox en cada una de las series `bootstrap`, obteniéndose 100 series similares a la serie temporal original  $(x_{i,t})$ .

#### D. Previsión con el método FFNN

i) Arquitectura de red neuronal: Una vez obtenido las series inicializadas  $(x_{i,t})$  en el paso anterior, se realizó el pronóstico utilizando las nuevas series temporales en base a los modelos de *Feed-Forward Neural Network*. Ellas están organizadas por capas, donde cada capa de nodos recibió entradas de las capas anteriores, y estas fueron entradas para la siguiente capa. Seguidamente, las entradas de cada nodo se combinan mediante una interacción lineal ponderada [29]. El producto es modificado usando una función no lineal antes de ser generado. Las entradas a la neurona oculta,  $j$ , en la Fig. 3, se combinaron linealmente, como se expresa en la Ecuación 3 [29].

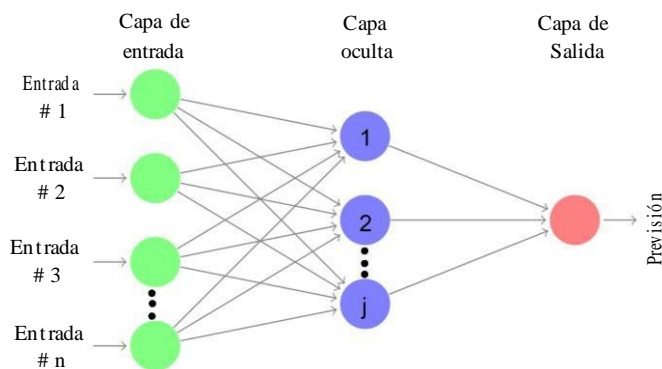


Fig. 3. RNA feed-forward con una capa oculta.

$$z_j = b_j + \sum_{i=1}^n w_{i,j} x_{i,t} \quad (3)$$

Donde,  $z_j$  corresponde al nivel de actividad interna de la neurona y se obtiene al combinar la suma de las entradas ponderadas  $(w_{i,j}, x_{i,t})$  con otro valor ajustable llamado bias ( $b_j$ ). Las entradas ponderadas comprenden pesos sinápticos  $(w_{i,j})$  y datos de entrada  $(x_{i,t})$ . Por lo tanto, los parámetros  $b_j$  y  $w_{i,j}$  se obtuvieron durante la fase de entrenamiento, en la que la red aprendió a utilizar los datos observados [29].

Se ha demostrado que los modelos FFNN son efectivas para resolver tareas complejas. Los fundamentos teóricos para

la solución de tareas de aprendizaje se atribuyen al teorema de aproximación universal. Este teorema impone una condición de no linealidad en los nodos ocultos; es decir, la función debe ser continua, limitada y aumentar uniformemente [34]. En este contexto, la derivada de la función de activación es requerida por las reglas de actualización de peso, y la condición de diferenciación se convierte en un requisito algorítmico. Por lo tanto, la función sigmoidea se usó en el modelo de pronóstico porque exhibe estas propiedades [34]. La salida  $(s_{(z)})$  de la combinación lineal se modifica luego usando una función no lineal antes de la salida de cada capa usando la función sigmoidea,  $S(z)$ , que se muestra en la Ecuación 4 [29].

$$S_{(z)} = \frac{1}{1 + e^{-z_j}} \quad (4)$$

ii) Autorregresión de redes neuronales: Los datos de la serie temporal se pueden utilizar como entrada para una FFNN, como se muestra en la Ecuación 5 [35]. En este estudio se consideró un modelo FFNN con una capa oculta, y se presenta como FFNN  $(p, P, k)$  [f]. Esto indica que  $p$  entradas retrasadas no estacionales,  $P$  entradas retrasadas estacionales y  $k$  neuronas existen en la capa oculta; además, [f] se expresa por la frecuencia.

$$(x_{i,t-1}, x_{i,t-2}, \dots, x_{i,t-p}, x_{i,t-f}, x_{i,t-2f}, x_{i,t-pf}) \quad (5)$$

La función `nnetar()` en R Team Core [31] se ajusta al modelo FFNN  $(p, P, k)$  [f]. Para esta función, cuando no se especifican los valores de  $p$  y  $P$ , se seleccionan automáticamente. Es decir, para la serie de tiempo estacional,  $P = 1$ ; además,  $p$  se selecciona del modelo lineal apropiado según el criterio de información de Akaike. Si no se especifica  $k$ , se define como  $(p + P + 1) / 2$ , acercándose al valor entero más próximo. Finalmente, como los datos presentados en la Fig. 2 se obtuvieron con valores leídos cada 30 min, la frecuencia diaria [f] fue de 48.

iii) Proceso de aprendizaje de las redes neuronales: Los valores  $p, P$  y  $k$  en el proceso de aprendizaje de la FFNN se utilizaron para el entrenamiento de la red. Por lo tanto, los datos de potencia activa fotovoltaica se separaron en datos de entrenamiento y de prueba. Se determinó que el tamaño del conjunto de datos para el entrenamiento era del 80 % [29]. Una vez obtenidos los parámetros que ajustan el modelo con la función `nnetar()` tanto para la serie original  $(y_t)$  como para la serie inicializada  $(x_{i,t})$ , se verificaron tabulando el número de neuronas internas ( $k$ ), registrando el error cuadrático medio (MSE) para cada caso. El MSE es la función de rendimiento utilizada por la red neuronal.

iv) Evaluación de la precisión del pronóstico: Una vez verificados los parámetros de los modelos FFNN, se utilizaron tanto los datos de la serie original como la serie `bootstrap` y se realizaron pronósticos para determinar el desempeño. Finalmente, se evaluó el desempeño de los pronósticos mediante el procedimiento de validación cruzada de los pronósticos [36]. Las dos medidas de escala independientes

más utilizadas se basan en los errores absolutos o errores cuadráticos y se expresan mediante el error porcentual absoluto medio (MAPE) [37] y el error cuadrático medio (RMSE) [38] respectivamente, como se muestra en las Ecuaciones 6 y 7, respectivamente.

$$MAPE = \left( \frac{\sum_{t=T+1}^{T+h} |e_t|}{\sum_{t=T+1}^{T+h} y_t} \right) \times 100\% \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{t=T+1}^{T+h} (e_t)^2}{h}} \quad (7)$$

Donde, la estimación del error de pronóstico ( $e_t$ ) se expresa por la diferencia entre el valor observado ( $y_t$ ) y su pronóstico ( $\hat{e}_t$ ). Es decir, la parte impredecible de la observación, como se indica en la Ecuación 8. Además, ( $h$ ) es el número de casos evaluados [29].

$$e_t = \hat{y}_t - y_t \quad (8)$$

Si los modelos no se ajustan a los datos y dan como resultado errores fuertemente correlacionados, esta ocurrencia se puede identificar fácilmente al verificar los residuos de la correlación serial usando la prueba de Ljung-Box. El estadístico de prueba de Ljung-Box tiene una distribución chi-cuadrado con  $u - n$  grados de libertad y se expresa como se muestra en la Ecuación 9 [36]. Para el análisis, la prueba Ljung-Box se implementó en R utilizando la función `Box.test()` [31].

$$Q = N(N+2) \sum_{i=1}^u (N-i)^{-1} r_i^2 \quad (9)$$

Donde,  $u$  es el número de retardos utilizados, es decir, 15;  $r_u$  es el valor estimado del  $u$ -ésimo coeficiente de autocorrelación serial; el valor  $p$  se expresa como  $\text{Prob}[Q \geq \chi^2_{2G.L.}]$ .

### III. RESULTADOS Y DISCUSIONES

En esta sección se presentan los resultados de la previsión de la producción de energía FV. Para ello se obtuvieron los modelos FFNN (30, 1, 16) 48 y MBB-FFNN (30, 1, 15) 48 para los datos originales ( $y_t$ ) y series inicializadas ( $x_t$ ), respectivamente. La verificación de estos modelos basada en la tabulación del número de neuronas en la capa oculta ( $k$ ) se muestra en la Fig. 4. Como se muestra, el número de neuronas ocultas para los modelos FFNN y MBB-FFNN fue de 16 y 15, respectivamente, según determinado en el registro de la MSE.

En la Fig. 5 se presentan los resultados de los pronósticos en base al desempeño de los modelos de previsión definidos, tanto para la serie original como para la inicializada. Se muestran los resultados de tres semanas de diferentes meses, seleccionados aleatoriamente del conjunto de resultados. La primera semana corresponde al período del 19 al 25 de

febrero, la segunda del 2 al 8 de junio y la última del 23 al 29 de diciembre, para los modelos FFNN y MBB-FFNN. En la Fig. 5, el resultado de previsión con los datos de remuestreo de la serie original basada en la técnica MBB-FFNN muestra una mejor generalización que es similar a los datos reales. Para los pronósticos de febrero y junio, el modelo FFNN funcionó bien, aunque no mejor que el modelo MBB-FFNN. Sin embargo, el desempeño en diciembre fue peor para la FFNN,

mientras que para el modelo MBB-FFNN mostró un mejor desempeño debido a su mejor generalización, con base en el remuestreo de la serie temporal con técnicas de *bootstrap*.

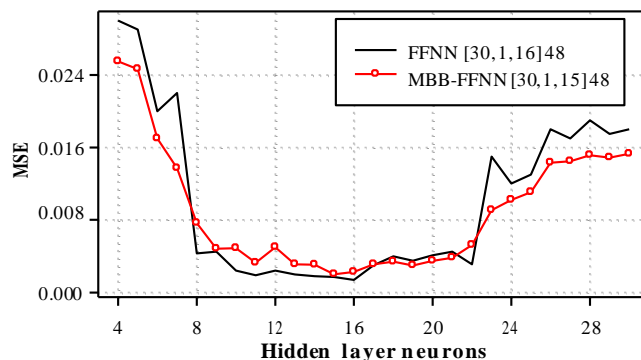


Fig. 4. Número de neuronas ocultas para los modelos FFNN y MBB-FFNN.

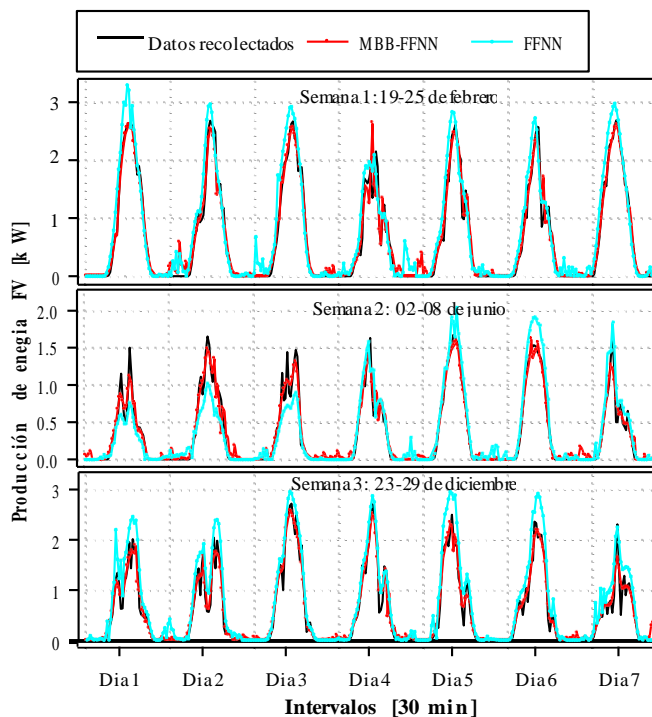


Fig. 5. Previsión a partir de modelos FFNN y MBB-FFNN.

En consecuencia, la Fig. 6(a) presenta los resultados del desempeño de entrenamiento de los modelos evaluados. El modelo MBB-FFNN y FFNN demostraron valores RMSE de  $12,15 \times 10^{-2}$  y  $11,13 \times 10^{-2}$  W, respectivamente. Esta diferencia

se debe a que la serie de arranque generada se suavizó previamente, lo que resultó en un RMSE ligeramente más alto para el modelo híbrido, como se muestra en la selección del número de neuronas ocultas en la Fig. 4. Sin embargo, en la evaluación del desempeño de previsión, el modelo híbrido MBB- FFNN demostró una mejor consistencia de pronóstico en todo el horizonte, comparando con el desempeño del modelo FFNN. Los valores obtenidos en términos de RMSE es de  $13,46 \times 10^{-2}$  y  $17,66 \times 10^{-2}$  W, respectivamente; siendo muy favorable para el modelo híbrido, como se muestra en Fig. 6 (b).

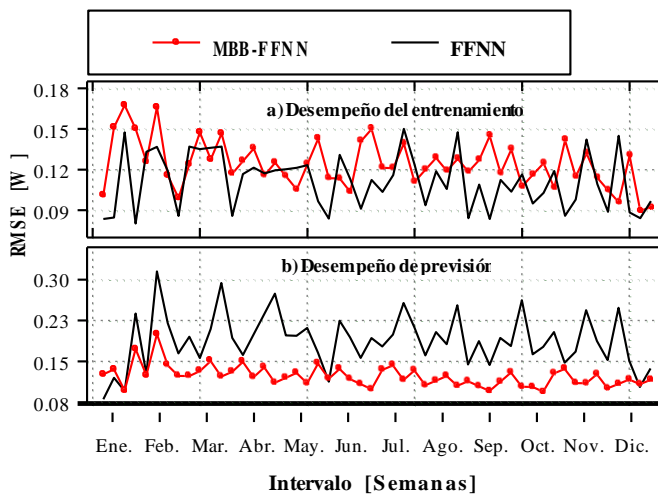


Fig. 6. Desempeño de pronóstico de los modelos FFNN y MBB- FFNN.

Para la validación porcentual basada en el indicador MAPE, los desempeños de los modelos FFNN y MBB- FFNN fueron de 4,48% y 3,14%, respectivamente. Por tanto, se puede afirmar que, al utilizar el remuestreo del componente residual de la serie temporal mediante la técnica MBB, las previsiones de la producción de energía FV mejoran consistentemente. Ello se relaciona con los estudios de [27], [28], donde el autor demostró un alto poder predictivo y menos incertidumbre de pronóstico al usar la técnica MBB utilizados en la previsión de energía eólica. De igual manera, el resultado coincide con los de otros estudios que utilizan el enfoque bootstrap con el modelo de promedio móvil integrado autorregresivo, que se utilizó para el pronóstico mensual de cargas eléctricas [32]. Los resultados muestran que la combinación de las técnicas de bootstrap con el modelo de FFNN para pronosticar cada 30 min mejoró sustancialmente el rendimiento.

Finalmente, considerando el mejor desempeño de pronóstico del modelo MBB- FFNN, se verificaron los resultados obtenidos de la prueba de Ljung-Box, como se muestra en la Fig. 7. Los resultados muestran que la media de los valores obtenidos para todo el horizonte estuvo cerca de la unidad, indicando que los resultados son estadísticamente significativos, verificando así la no correlación de los errores de pronóstico y validando el modelo propuesto.




Fig. 7. Prueba de Ljung-Box para el modelo MBB- FFNN.

#### IV. CONCLUSIONES

En este documento, se presentó el modelado de previsión de la producción de energía solar FV. Como se demostró, el remuestreo de la serie temporal mediante la técnica de *bootstrap* permitió obtener un mejor desempeño de la *Feed-Forward Neural Network (FFNN)*. Además, se demostró la estabilidad frente a las incertidumbres de los pronósticos debido a que las técnicas *Moving Block Bootstrap (MBB)* garantizaron la generalización de los resultados al inicializar el residual de la serie de tiempo.

Por lo tanto, los modelos FFNN combinado con técnicas MBB, superaron consistentemente la precisión del pronóstico en comparación con el modelo original de previsión, muy referenciado en este campo de investigación. Ello se comprueba en base a los valores de los indicadores de desempeño RMSE y MAPE, al predecir un día de anticipación con una frecuencia de 30 min. De la misma forma, los resultados fueron estadísticamente significativos, como se demostró a través de la prueba de Ljung-Box, verificando así la no correlación de los errores de pronóstico y validando el modelo propuesto.

#### AGRADECIMIENTOS

Los autores desean agradecer el apoyo en parte de la Universidad Privada del Norte (UPN) - Perú, y de CAPES – Brasil (*Coordenação de Aperfeiçoamento de Pessoal de Nível Superior*) por la asistencia en este estudio.

#### REFERENCIAS

- [1] M. L. Chalal, M. Benachir, M. White, and R. Shrahily, "Energy planning and forecasting approaches for supporting physical improvement strategies in the building sector: A review," *Renew. Sustain. Energy Rev.*, vol. 64, pp. 761–776, Oct. 2016, doi: 10.1016/J.RSER.2016.06.040.
- [2] F. Yutaka Kuwabata Takigawa, R. Cavalcante Fernandes, E. Antonio Cardoso Aranha Neto, D. Tenfen, and E. Taghori Sica, "Energy Management by the Consumer with Photovoltaic Generation: Brazilian Market," *IEEE Lat. Am. Trans.*, vol. 14, no. 5, pp. 2226–2232, May 2016, doi: 10.1109/TLA.2016.7530417.
- [3] K. Gaspar *et al.*, "Assessing the impact of the COVID-19 lockdown on the energy consumption of university buildings," *Energy Build.*, vol. 257, p. 111783, Feb. 2022, doi: 10.1016/J.ENBUILD.2021.111783.
- [4] J. J. Klemeš, Y. Van Fan, R. R. Tan, and P. Jiang, "Minimising the present and future plastic waste, energy and environmental footprints related to COVID-19," *Renew. Sustain. Energy Rev.*, vol. 127, p. 109883, Jul. 2020, doi: 10.1016/J.RSER.2020.109883.



- [5] N. Norouzi, G. Zarazua de Rubens, S. Choubanpishhezafar, and P. Enevoldsen, "When pandemics impact economies and climate change: Exploring the impacts of COVID-19 on oil and electricity demand in China," *Energy Res. Soc. Sci.*, vol. 68, p. 101654, Oct. 2020, doi: 10.1016/J.ERSS.2020.101654.
- [6] S. Yaya, S. Yaya, A. Otu, A. Otu, and R. Labonté, "Globalisation in the time of COVID-19: Repositioning Africa to meet the immediate and remote challenges," *Global. Health*, vol. 16, no. 1, pp. 1–7, Jun. 2020, doi: 10.1186/S12992-020-00581-4/METRICS.
- [7] E. Ghiani, M. Galici, M. Mureddu, and F. Pilo, "Impact on Electricity Consumption and Market Pricing of Energy and Ancillary Services during Pandemic of COVID-19 in Italy," *Energies 2020, Vol. 13, Page 3357*, vol. 13, no. 13, p. 3357, Jul. 2020, doi: 10.3390/EN13133357.
- [8] A. T. Hoang *et al.*, "Impacts of COVID-19 pandemic on the global energy system and the shift progress to renewable energy: Opportunities, challenges, and policy implications," *Energy Policy*, vol. 154, p. 112322, Jul. 2021, doi: 10.1016/J.ENPOL.2021.112322.
- [9] Z. A. Elum and A. S. Momodu, "Climate change mitigation and renewable energy for sustainable development in Nigeria: A discourse approach," *Renew. Sustain. Energy Rev.*, vol. 76, pp. 72–80, Sep. 2017, doi: 10.1016/J.RSER.2017.03.040.
- [10] L. Wen, K. Zhou, S. Yang, and X. Lu, "Optimal load dispatch of community microgrid with deep learning based solar power and load forecasting," *Energy*, vol. 171, pp. 1053–1065, Mar. 2019, doi: 10.1016/J.ENERGY.2019.01.075.
- [11] J. Jurasz, "Modeling and forecasting energy flow between national power grid and a solar-wind-pumped-hydroelectricity (PV-WT-PSH) energy source," *Energy Convers. Manag.*, vol. 136, pp. 382–394, Mar. 2017, doi: 10.1016/J.ENCONMAN.2017.01.032.
- [12] F. Wang *et al.*, "A satellite image data based ultra-short-term solar PV power forecasting method considering cloud information from neighboring plant," *Energy*, vol. 238, p. 121946, Jan. 2022, doi: 10.1016/J.ENERGY.2021.121946.
- [13] M. Abdel-Basset, H. Hawash, R. K. Chakraborty, and M. Ryan, "PV-Net: An innovative deep learning approach for efficient forecasting of short-term photovoltaic energy production," *J. Clean. Prod.*, vol. 303, p. 127037, Jun. 2021, doi: 10.1016/J.JCLEPRO.2021.127037.
- [14] D. J. Pedregal and J. R. Trapero, "Adjusted combination of moving averages: A forecasting system for medium-term solar irradiance," *Appl. Energy*, vol. 298, p. 117155, Sep. 2021, doi: 10.1016/J.APENERGY.2021.117155.
- [15] Y. Jung, J. Jung, B. Kim, and S. U. Han, "Long short-term memory recurrent neural network for modeling temporal patterns in long-term power forecasting for solar PV facilities: Case study of South Korea," *J. Clean. Prod.*, vol. 250, p. 119476, Mar. 2020, doi: 10.1016/J.JCLEPRO.2019.119476.
- [16] J. Liu *et al.*, "Power system load forecasting using mobility optimization and multi-task learning in COVID-19," *Appl. Energy*, vol. 310, p. 118303, Mar. 2022, doi: 10.1016/J.APENERGY.2021.118303.
- [17] R. Ulbricht, U. Fischer, W. Lehner, and H. Donker, "First Steps Towards a Systematical Optimized Strategy for Solar Energy Supply Forecasting," 2013.
- [18] E. Ogliairi, A. Dolara, G. Manzolini, and S. Leva, "Physical and hybrid methods comparison for the day ahead PV output power forecast," *Renew. Energy*, vol. 113, pp. 11–21, Dec. 2017, doi: 10.1016/J.RENENE.2017.05.063.
- [19] A. Mellit and A. M. Pavan, "A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy," *Sol. Energy*, vol. 84, no. 5, pp. 807–821, May 2010, doi: 10.1016/j.solener.2010.02.006.
- [20] E. İzgi *et al.*, "Short-mid-term solar power prediction by using artificial neural networks," *SoEn*, vol. 86, no. 2, pp. 725–733, Feb. 2012, doi: 10.1016/J.SOLENER.2011.11.013.
- [21] E. Ogliairi, F. Grimaccia, S. Leva, and M. Mussetta, "Hybrid Predictive Models for Accurate Forecasting in PV Systems," *Energies 2013, Vol. 6, Pages 1918-1929*, vol. 6, no. 4, pp. 1918–1929, Apr. 2013, doi: 10.3390/EN6041918.
- [22] B. Wolff, J. Kühnert, E. Lorenz, O. Kramer, and D. Heinemann, "Comparing support vector regression for PV power forecasting to a physical modeling approach using measurement, numerical weather prediction, and cloud motion data," *Sol. Energy*, vol. 135, pp. 197–208, Oct. 2016, doi: 10.1016/J.SOLENER.2016.05.051.
- [23] K. B. Debnath and M. Mourshed, "Forecasting methods in energy planning models," *Renew. Sustain. Energy Rev.*, vol. 88, pp. 297–325, May 2018, doi: 10.1016/J.RSER.2018.02.002.
- [24] S. N. Mughal, Y. R. Sood, and R. K. Jarial, "Design and optimization of photovoltaic system with a week ahead power forecast using autoregressive artificial neural networks," *Mater. Today Proc.*, Oct. 2021, doi: 10.1016/J.MATPR.2021.10.223.
- [25] Jian Zheng, Cencen Xu, Ziang Zhang, and Xiaohua Li, "Electric load forecasting in smart grids using Long-Short-Term-Memory based Recurrent Neural Network," in *2017 51st Annual Conference on Information Sciences and Systems (CISS)*, Mar. 2017, pp. 1–6, doi: 10.1109/CISS.2017.7926112.
- [26] H. Byeon, "Developing A Model for Predicting the Speech Intelligibility of South Korean Children with Cochlear Implantation using a Random Forest Algorithm," *Int. J. Adv. Comput. Sci. Appl.*, vol. 9, no. 11, pp. 88–93, 2018, doi: 10.14569/IJACSA.2018.091113.
- [27] U. Hounyo and K. Lahiri, "Estimating the variance of a combined forecast: Bootstrap-based approach," *J. Econom.*, Oct. 2021, doi: 10.1016/J.JECONOM.2021.09.011.
- [28] P. Tapetado and J. Usaola, "Capacity credits of wind and solar generation: The Spanish case," *Renew. Energy*, vol. 143, pp. 164–175, Dec. 2019, doi: 10.1016/J.RENENE.2019.04.139.
- [29] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*, 2nd ed. OTexts, 2018.
- [30] S. Yang *et al.*, "A novel hybrid model based on STL decomposition and one-dimensional convolutional neural networks with positional encoding for significant wave height forecast," *Renew. Energy*, vol. 173, pp. 531–543, Aug. 2021, doi: 10.1016/J.RENENE.2021.04.010.
- [31] R version 4.0.2, "R: The R Project for Statistical Computing," 2020. <https://www.r-project.org/> (accessed Aug. 25, 2020).
- [32] C. Bergmeir, R. J. Hyndman, and J. M. Benítez, "Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation," *Int. J. Forecast.*, vol. 32, no. 2, pp. 303–312, Apr. 2016, doi: 10.1016/J.IJFORECAST.2015.07.002.
- [33] "R Core Team (2018). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria." [Online]. Available: <https://www.r-project.org/>.
- [34] A. Mishra, P. Chandra, U. Ghose, and S. S. Sodhi, "Bi-modal derivative adaptive activation function sigmoidal feedforward artificial neural networks," *Appl. Soft Comput. J.*, vol. 61, pp. 983–994, Dec. 2017, doi: 10.1016/j.asoc.2017.09.002.
- [35] J. P. S. Catalão, H. M. I. Pousinho, and V. M. F. Mendes, "An artificial neural network approach for short-term wind power forecasting in Portugal," *2009 15th Int. Conf. Intell. Syst. Appl. to Power Syst. ISAP '09*, Dec. 2009, doi: 10.1109/ISAP.2009.5352853.
- [36] C. Bergmeir, R. J. Hyndman, and B. Koo, "A note on the validity of cross-validation for evaluating autoregressive time series prediction," *Comput. Stat. Data Anal.*, vol. 120, pp. 70–83, Apr. 2018, doi: 10.1016/J.CSDA.2017.11.003.
- [37] M. Khairalla, Xu-Ning, and N. T. AL-Jallad, "Hybrid Forecasting Scheme for Financial Time-Series Data using Neural Network and Statistical Methods," *Int. J. Adv. Comput. Sci. Appl.*, vol. 8, no. 9, 2017, doi: 10.14569/IJACSA.2017.080945.
- [38] A. F. Sheta, S. E. M. Ahmed, and H. Faris, "A Comparison between Regression, Artificial Neural Networks and Support Vector Machines for Predicting Stock Market Index," *Int. J. Adv. Res. Artif. Intell.*, vol. 4, no. 7, Jul. 2015, doi: 10.14569/IJARAI.2015.040710.