

# Tendencias Actuales en el Pronóstico de Generación Fotovoltaica y Demanda en Microrredes

Luis F. Martínez-Soto  
Tecnológico Nacional de México-Campus  
Quéretaro  
Centro de Ingeniería y Desarrollo Industrial  
Quéretaro, México  
[lmartinez@cidesi.edu.mx](mailto:lmartinez@cidesi.edu.mx)

Omar Rodríguez-Zalapa, José Joaquín  
Castellanos-Galindo, José Alberto López-  
Fernández  
Departamento de Ingeniería Eléctrica y  
Electrónica  
Tecnológico Nacional de México-Campus  
Quéretaro  
Quéretaro, México

José Horacio Tovar-Hernández  
Programa de Graduados e Investigación en  
Ingeniería Eléctrica  
Tecnológico Nacional de México-Campus  
Morelia  
Morelia, México

**Abstract**— En este trabajo se presenta una revisión del estado del arte de las técnicas de pronóstico utilizadas para la predicción de la demanda de energía eléctrica y la producción fotovoltaica en microrredes, con el objetivo de identificar las tendencias actuales y los horizontes de pronóstico más adecuados para su operación. La metodología utilizada se basa en la revisión de artículos y otras fuentes bibliográficas relevantes, identificando los principales algoritmos utilizados, sus ventajas y desventajas, las métricas de error empleadas y coincidencias entre las diferentes propuestas de algoritmos de pronóstico utilizados actualmente. En general, se ha identificado que las técnicas de pronóstico de microrredes aplican para horizontes de pronóstico de 24 horas en adelante y se basan principalmente en algoritmos basados en inteligencia artificial o métodos híbridos que combinan las ventajas de por lo menos dos algoritmos individuales.

**Palabras Clave**— *Microrred, gestión de la energía, pronóstico, generación distribuida, producción fotovoltaica, demanda, almacenamiento de energía*

## I. INTRODUCCIÓN

Al hablar del concepto de microrred se hace referencia a un grupo de cargas eléctricas y recursos energéticos distribuidos (DER: *Distributed Energy Resources*) con fronteras eléctricas claramente definidas, que actúan como una entidad controlable única con respecto a la red de suministro. Puede conectarse y desconectarse de ella para habilitar la operación tanto en modo conectado a la red, como de forma aislada [1]. Los criterios para realizar la transición entre el modo de operación conectado a red y aislado se basan en factores tales como fallas en la red, desastres naturales o aspectos económicos [2].

La incorporación de la generación renovable en las microrredes, tales como la energía solar, es un factor importante para reducir las pérdidas de los sistemas eléctricos y producir beneficios ambientales, siendo este último uno de los principales impulsores para la proliferación de las microrredes [3]. Sin embargo, su variabilidad e intermitencia relacionadas con las condiciones ambientales y factores del uso local de la energía, introducen complicaciones adicionales en su operación, tales como una mayor dinámica en el perfil

de la demanda con respecto a la demanda de los grandes sistemas eléctricos que las alojan [4]. Como consecuencia, los métodos convencionales de pronóstico, que utilizan modelos estadísticos de regresión, deben ser mejorados o inclusive reemplazados ante la incorporación de estas nuevas tecnologías [5].

La estrategia de gestión de la energía de las microrredes es responsable de ajustar el punto de operación de cada elemento de la microrred, tales como la potencia entregada por los sistemas de almacenamiento, la producción de la generación distribuida, la potencia utilizada por cargas administrables y la potencia intercambiada con la red [6].

La Fig. 1 muestra el diagrama conceptual de una microrred, donde es posible tener diversos DER, tales como sistemas fotovoltaicos (SFV), bancos de baterías, vehículos eléctricos, entre otros [7]. El punto de conexión a la red de suministro se representa como un interruptor (*on/off*). La microrred posee también un controlador, donde se aloja el Sistema de Gestión de la Energía (SGEn), desde el cual se pueden realizar las funciones propias de control y pronóstico de recursos energéticos, entre otras funciones.



Fig. 1. Esquema conceptual de una microrred.

El presente artículo presenta la identificación de técnicas de pronóstico de generación fotovoltaica y la demanda en microrredes, como parte del proyecto de implementación de una microrred fotovoltaica y su SGEn, en las instalaciones del laboratorio de Energía del Centro de Ingeniería y Desarrollo

Industrial (CIDESI) en Querétaro, México.

El artículo se organiza de la siguiente forma: La Sección II describe la clasificación general de los horizontes de pronóstico, en la Sección III se presenta un resumen de los principales trabajos en pronóstico de la demanda en microrredes (en el orden de kW), mientras que la Sección IV hace lo correspondiente para la producción fotovoltaica. Posteriormente, la Sección V muestra una clasificación general con ejemplos de las técnicas de predicción detectadas, y en la Sección VI, se definen los índices de evaluación del error más utilizados para evaluar el desempeño de las técnicas de pronóstico. Finalmente, la Sección VII presenta las conclusiones del artículo.

## II. CLASIFICACIÓN DE LOS HORIZONTES DE PRONÓSTICO

El pronóstico o predicción se basa en el análisis de series de tiempo de mediciones variantes en el tiempo, obtenidas en tiempo real o a partir de bases de datos, con el objetivo de descubrir comportamientos periódicos [8]–[10]. Estas mediciones pueden ser continuas o discretas [11], [12].

En general, los horizontes de pronóstico se dividen en corto, mediano y largo plazo. El pronóstico de corto plazo se divide a su vez en dos tipos: muy corto plazo y corto plazo. El pronóstico a muy corto plazo abarca horizontes de predicción de segundos o minutos hasta horas y permite modelar aplicaciones en control de flujos de potencia eléctrica. El pronóstico de corto plazo tiene un horizonte de predicción desde horas hasta semanas y es útil para modelar aplicaciones de ajuste de la generación y la demanda. El pronóstico del horizonte de muy corto plazo es muy importante para realizar operaciones en sistemas eléctricos día a día, evaluando intercambios entre redes, programando la asignación de unidades de generación y realizando análisis de seguridad de los sistemas eléctricos [13]. Sin embargo, en el contexto de las microrredes, el horizonte de pronóstico de corto plazo se acota a predicciones con un día en adelante únicamente [14], lo que permite abarcar el perfil de producción local de generación distribuida renovable y de las cargas eléctricas del lado del usuario.

Por otra parte, el horizonte de predicción de mediano plazo tiene una cobertura de uno a varios meses y se aplica principalmente en la planeación del mantenimiento, gestión de las reservas hidráulicas y en la programación del uso de combustibles, mientras que el horizonte de predicción de largo plazo abarca tiempos de pronóstico de hasta 20 años [15]. Los algoritmos de predicción de este tipo se aplican en la planeación de la capacidad de la red y en la programación de su mantenimiento [14]. La Fig. 2, muestra la clasificación de los horizontes de pronóstico.

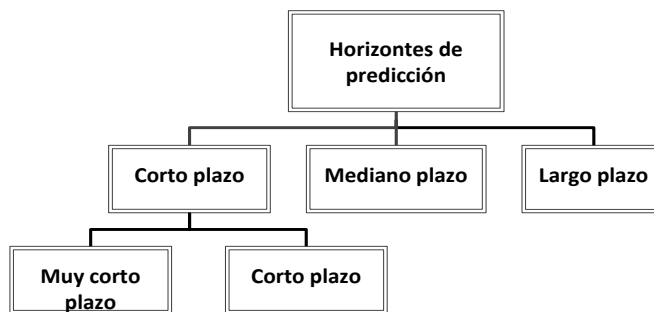


Fig. 2. Clasificación de horizontes de predicción [14].

## III. PRONÓSTICO DE LA DEMANDA

El objetivo principal de la tarea del pronóstico de la demanda es proveer predicciones del consumo de energía y de los picos de demanda, que cumplan con los requerimientos de planeación de los sistemas eléctricos de forma confiable. Para esto, desde el punto de vista de los grandes sistemas eléctricos, tradicionalmente se han aplicado una gran variedad de técnicas para el pronóstico de corto plazo, tales como algoritmos autorregresivos de media móvil (ARMA: *Autoregressive Moving Average*), algoritmos basados en filtros de Kalman, redes neuronales artificiales (ANN: *Artificial Neural Network*), sistemas expertos (ES), sistemas difusos (FS), entre otros [13], [16]. Para el caso de las microrredes, en [5] se utilizan redes neuronales artificiales de retropropagación para pronosticar la demanda en una instalación con un rango entre 20 y 180 kW, para periodos de predicción de corto plazo de 24 horas y hasta 7 días. Se da énfasis en la elección de los parámetros de entrada de la red neuronal, utilizado correlación de datos y la metodología Kaastra-Boyd. El índice de error utilizado fue la raíz del error medio cuadrático (RMSE: *Root Mean Squared Error*), identificando un aumento en el error de pronóstico a medida que se amplía el periodo de predicción.

Una técnica de pronóstico basada en predicción difusa se propuso y aplicó en una microrred Diesel-eólica-fotovoltaica ubicada en Huatacondo, Chile, para el pronóstico de la demanda con valores máximos de hasta 28 kW [17]. En esta, se utilizó un algoritmo basado en intervalos de predicción difusa (FPI: *Fuzzy Prediction Interval*) para representar la incertidumbre futura de la carga. El desempeño del pronóstico se evaluó con respecto a los índices RMSE y el error medio absoluto (MAE: *Mean Absolute Error*), para horizontes de pronóstico de 15 minutos y 24 horas en adelante, observando un detrimento de los resultados del pronóstico al ampliar el horizonte de predicción. Otra propuesta utilizando también un método de FPI para solucionar el problema de la intermitencia e incertidumbre relacionado al pronóstico de energías renovables y la carga, se presenta en [18]. Se utilizó un sistema difuso tipo Takagi-Sugeno, entrenado con varios algoritmos evolutivos de optimización (algoritmos genéticos, regresión difusa, algoritmos culturales, algoritmo de luciérnagas y optimización por enjambre de partículas). El pronóstico se aplicó en la microrred de prueba Goldwind

TABLA 1  
COMPARACIÓN DE TÉCNICAS DE PRONÓSTICO DE LA DEMANDA

Ref.	Modelo de predicción	Horizonte	Escala	Métrica
[17]	Lógica difusa - FPI	15 minutos 24 horas	28 kW	RMSE, MAE
[18]	FPI + Optimización PSO	24 horas	3 MW	RMSE, MAE
[19]	NAR ARMA	24 horas	75 kW	RMSE
[20]	CNN	24 horas-clima frío	650 kW	RMSE
	ARIMAX			
	RNN			
	CNN	24 horas-clima no frío		
	ARIMAX			
	RNN			
[21]	DRNN+LSTM MLP SVM	100 horas	17-83 kW	RMSE, MAPE

localizada en Beijing, China, eólico-fotovoltaica, con una carga eléctrica local de 3 MW. Se realizaron pruebas para pronóstico de 10 minutos en adelante y un día en adelante, evaluándolos en términos del RMSE, el MAE y el tiempo de entrenamiento. En cuanto al pronóstico de la demanda con un día en adelante, el mejor resultado fue utilizando un algoritmo de optimización por enjambre de partículas (PSO: *Particle Swarm Optimization*) en combinación con los intervalos difusos.

Se han realizado evaluaciones comparativas de métodos estadísticos y de inteligencia artificial para el pronóstico de la demanda (hasta 75kW) en una microrred, utilizando algoritmos ARMA con predicción del error final (FPE: *Final Prediction Error*), y modelos basados redes neuronales auto regresivas no lineales (NAR: *Nonlinear Autoregressive*) [19]. En todos los casos de comparación, se observó que la red neuronal posee mejores capacidades para predecir cambios súbitos, mientras que el algoritmo ARMA sólo fue capaz de seguir tendencias. De la misma forma, se observó que para menores horizontes de predicción los errores fueron menores, utilizando el RMSE como indicador de referencia.

Como ejemplo de aplicación de aprendizaje profundo (*Deep Learning*), en [20] se proponen algoritmos de pronóstico para un día en adelante, aplicables a edificios comerciales con demandas de entre 40 y 650 kW. El primer algoritmo se basa en redes neuronales recurrentes (RNN: *Recurrent Neural Network*) y el segundo en una red neuronal convolucional (CNN: *Convolutional Neural Network*). Los resultados son comparados con los obtenidos por un modelo autorregresivo integrado de media móvil con entradas exógenas (ARIMAX: *Autoregressive Integrated Moving Average*), en términos de precisión, eficiencia computacional y robustez. Se realizaron pronósticos para periodos fríos y no fríos con respecto al RMSE. En todos los casos, el modelo de mejores resultados fue la CNN, seguido por el algoritmo ARIMAX y finalmente la RNN. Fue posible observar que la aplicación de variables exógenas en combinación con un modelo ARIMA significó mejores resultados de pronóstico que los obtenidos con aprendizaje automático basado en RNN. Por otra parte, en

[21] se propusieron algoritmos de pronóstico de la demanda aplicables a microrredes comunitarias, utilizando una red neuronal profunda recurrente (DRNN: *Deep Recurrent Neural Network*) en conjunto con unidades de gran memoria de corto plazo (LSTM: *Long Short-Term Memory Units*) como algoritmo de pronóstico, con un horizonte de corto plazo. El algoritmo se probó en una microrred residencial fotovoltaica en Austin, Texas, con una demanda de entre 17 y 83 kW. Los resultados fueron evaluados en términos del RMSE, MAE, y el error porcentual medio absoluto (MAPE: *Mean Absolute Percentage Error*), así también con el coeficiente de correlación de Pearson (PCC: *Pearson Correlation Coefficient*). Los resultados se compararon con algoritmos de predicción basados en máquina de soporte vectorial (SVM: *Support Vector Machine*) y de una ANN perceptrón multicapa (MPL: *Multi-Layer Perceptron*). En todos los casos, la DRNN superó en desempeño a los algoritmos basados en MPL y SVM.

La Tabla 1, muestra un resumen de las técnicas de pronóstico de demanda de cada una de las referencias analizadas, incluyendo el nombre de los algoritmos propuestos, los horizontes de predicción evaluados, las métricas del error utilizadas y la escala de la demanda de la microrred analizada.

#### IV. PRONÓSTICO DE LA GENERACIÓN FOTOVOLTAICA

Uno de los mayores problemas para pronosticar la potencia fotovoltaica es su variabilidad. Por ejemplo, el paso de una nube puede reducir la radiación solar hasta en un 80% en un segundo, lo cual representa un gran reto para los operadores de los sistemas eléctricos. En algunos casos, se utilizan modelos determinísticos basados en ecuaciones matemáticas para pronosticar la producción de los sistemas fotovoltaicos, tales como el modelo de un solo diodo, el método de Osterwald o el método de Araujo-Green [22], [23]. Estos métodos requieren datos de los módulos fotovoltaicos (MFV) bajo diferentes condiciones meteorológicas, lo cual representa una desventaja cuando no se dispone de esa información por parte de los fabricantes [22] o como en la mayoría de los casos, sólo se proporciona de forma limitada para las condiciones nominales del MFV. Como consecuencia, estos modelos suelen ser válidos únicamente para una planta y ubicación en particular [23].

También es posible pronosticar la generación fotovoltaica utilizando FPI [17], [18], como se hizo en proyectos desarrollados en la microrred experimental de Huatocondo, Chile (24 kW) y en la microrred Goldwind en China (dos SFV: 200 y 250 kW). En el primer caso se obtuvieron resultados superiores a los obtenidos con algoritmos de regresión lineal para horizontes de 15 minutos y 24 horas en adelante; mientras que, en el segundo, en combinación con un algoritmo de optimización PSO, se obtuvo un desempeño superior frente a la aplicación de otros algoritmos de optimización, para horizontes de 10 minutos y 24 hora en adelante.

Se han utilizado también combinaciones de técnicas de inteligencia artificial con algoritmos de optimización tipo PSO. Por ejemplo, en [24] se combina el PSO con un algoritmo adaptativo de inferencia neurodifuso (ANFIS: *Adaptive Neuro-Fuzzy Inference System*) para el pronóstico de la potencia fotovoltaica de 3 unidades de generación fotovoltaica, de 100 kW cada una. Los resultados del algoritmo fueron evaluados en términos del RMSE, el MAE y el nMAE (MAE normalizado) y se obtuvieron resultados superiores para un horizonte de pronóstico de una hora en adelante, que los obtenidos con algoritmos basados en ANN de retropropagación y el método de persistencia.

Como parte del diseño de un controlador centralizado para la gestión de la energía de una microrred, en [19] se aplican dos algoritmos de pronóstico de la generación fotovoltaica: el primero ARMA utilizando FPE y el segundo modelo basado en NAR de perceptrón multicapa. De la misma forma que para el caso que el pronóstico de la demanda, la red neuronal tuvo mejor capacidad para predecir cambios súbitos, mientras que el algoritmo ARMA sólo pudo seguir tendencias.

Una metodología basada en redes ANN en combinación con algoritmos de vecinos cercanos (k-NN: *k-nearest neighbor*) se propone en [25], realizando un pronóstico de corto plazo (24 horas) de potencia de corriente directa (CD) generada por un sistema fotovoltaico de 3.6 kW, instalado en una Universidad en Morelia, México. Primero se aplicaron dos algoritmos independientes de vecinos cercanos en combinación con una ANN para pronosticar la irradiancia solar y la temperatura ambiente. Posteriormente, se utilizó un modelo determinístico para convertir la temperatura ambiente en la temperatura del panel fotovoltaico. Finalmente, se utilizaron los valores pronosticados de irradiancia y temperatura del panel para alimentar un algoritmo de predicción de la potencia fotovoltaica basado en ANN. Se obtuvieron buenos resultados en términos del RMSE, ante escenarios con alta interferencia nubosa y días soleados.

El potencial de mejora de los modelos de predicción de la potencia fotovoltaica al aplicar pronóstico rodante (*Rolling Forecasting*), se muestra en [26]. Esta técnica hace posible mejorar los valores predichos por el modelo de pronóstico, extendiendo y corrigiendo simultáneamente el modelo de series de tiempo; utilizando mediciones en tiempo real. Los resultados de esta estrategia se combinaron con un modelo híbrido de pronóstico basado en subelementos de regresión de soporte vectorial (SVR: *Support Vector Regression*) o sub-SVRs y un algoritmo autorregresivo integrado de promedio móvil o ARIMA (ARIMA: *Autoregressive Integrated Moving Average*) para el pronóstico de la potencia fotovoltaica instantánea. La precisión del modelo fue evaluada con el RMSE y el MAPE y los resultados fueron mejores para días soleados que los obtenidos ante la presencia de nubes.

La combinación de dos algoritmos ANFIS ha demostrado ser efectiva aplicando sistemas de inferencia tipo Sugeno [27], para realizar pronóstico en una microrred con un SFV de 10 kW. El análisis se realizó vía simulación, utilizando bases de

TABLA 2  
COMPARACIÓN DE TÉCNICAS DE PRONÓSTICO DE LA DEMANDA

Ref.	Modelo de predicción	Horizonte	Escala	Métrica
[17]	Lógica difusa - FPI	15 minutos 24 horas	24 kW	RMSE, MAE
[18]	FPI-Sugeno + Optimización PSO	24 horas	450 kW	RMSE, MAE
[19]	ARMA NAR	24 horas	110 kW	RMSE
[21]	DRNN+LSTM MLP SVM	100 horas	100 kW	RMSE, MAPE
[23]	BP-ANN	24 horas + Soleado 24 horas + Parc. nuboso 24 horas + Nuboso	264 kW	NMAE, nRMSE, WMAE
[25]	NN + Vecinos cercanos	24 horas + Soleado 24 horas + Parc. Nuboso	3.6 kW	RMSE
[26]	SVR + ARIMA + pronóstico rodante	12 horas + Soleado 12 horas + Nuboso	1500 kW	RMSE, MAPE
[27]	ANFIS-Sugeno ANFIS-Sugeno, 3 MF	100 pasos en adelante 20 a 100 pasos en adelante	10 kW	RMSE, MAE

datos de monitoreo de un SFV ubicado en la ciudad de Targoviste, Rumania. Los resultados fueron evaluados en términos del MAE y el RMS, observando que al aumentar el horizonte de pronóstico se incrementa también el error. Se obtuvieron mejoras en las predicciones aumentando el número de funciones de membresía para cada variable (incremento de 2 a 3).

Por otra parte, se ha propuesto un método de pronóstico de potencia fotovoltaica aplicable a microrredes comunitarias, basado en aprendizaje profundo [21], utilizando una DRNN con LSTM como algoritmo de pronóstico, con un horizonte de corto plazo. El algoritmo se probó en una microrred residencial de Austin, Texas, conformada por un SFV de 100 kW. Los resultados fueron evaluados en términos del RMSE, MAE, MAPE y el coeficiente de relación de Pearson, y se compararon con algoritmos de predicción basados SVM y en una ANN de perceptrón multicapa. Los resultados de pronóstico mostraron el mejor rendimiento para el algoritmo DRNN, seguido por el MLP y finalmente el SVM. El modelo DRNN prácticamente superó en 2 a 1 el desempeño del algoritmo SVM.

La Tabla 2, muestra un resumen de las técnicas de pronóstico de generación fotovoltaica de las referencias analizadas, incluyendo el nombre de los algoritmos propuestos, los horizontes de predicción evaluados, las métricas de del error utilizadas y la capacidad de generación de la microrred.

## V. INDICADORES PARA LA EVALUACIÓN DEL ERROR

Considerando que las herramientas de pronóstico incorporadas en microrredes se utilizan no solamente para estimar la generación futura de energía en el corto plazo, sino también para mejorar su control, es importante evaluar su eficiencia, precisión y exactitud [3]. Para esa evaluación existen varios índices, que evalúan el rendimiento de los algoritmos de predicción mediante la comparación de los valores pronosticados contra los valores reales u observados. Generalmente, estos índices son los mismos empleados en estadística, aunque también es posible encontrar índices planteados por las autoridades regulatorias para temas de mercados eléctricos [23].

De acuerdo a la literatura revisada, los índices más comunes son el error medio absoluto (MAE) [17], [18], [27], el error medio porcentual absoluto (MAPE) para efectos de medir el error global del algoritmo [21], [26], y la raíz del error medio cuadrático (RMSE), que permite evaluar en general la diferencia entre los valores pronosticados y los reales [3], [17], [19], [26], [28], [25]. Cada uno de estos índices tiene características particulares, por lo que la selección del índice más adecuado depende de las condiciones particulares de cada caso [29] y se calculan a partir de las expresiones (1 a 3):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (1)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (2)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{y}_i - y_i|}{y_i} \times 100\% \quad (3)$$

Donde  $y_i$  es el valor real u observado en el instante  $i$ ,  $\hat{y}_i$  es el valor pronosticado en el instante  $i$  y  $N$  representa el número de muestras de datos utilizadas para realizar el pronóstico y es, por lo tanto, el horizonte de predicción.

En algunos casos, los indicadores de evaluación del error de pronóstico se utilizan de forma normalizada o promediada, con el objetivo de poseer un marco de referencia único con respecto a la capacidad de una planta o instalación en particular, o tener el mismo horizonte temporal de referencia [23].

## VI. RESUMEN DE PRINCIPALES TÉCNICAS DE PRONÓSTICO UTILIZADAS EN MICRORREDES

Con base a la literatura revisada, se adaptó y amplió la clasificación de las técnica de pronóstico propuesta en [30], y mostrada en la Fig. 3. Se agregaron subclasificaciones tanto a los modelos de predicción híbridos, como a las técnicas simples de predicción, incluyendo ejemplos específicos de cada una de ellas. No se hacen distinciones entre los algoritmos utilizados para la predicción de la demanda y la producción fotovoltaica, ya que se observó que es posible utilizar los mismos algoritmos con resultados adecuados en ambas aplicaciones [17]–[19], [21]. Como se puede observar en el diagrama, las técnicas de predicción de corto plazo aplicables a microrredes más utilizadas actualmente, ya sea de forma individual o en combinación con algoritmos de optimización o métodos estadísticos, son los métodos de predicción basados en inteligencia artificial (IA).

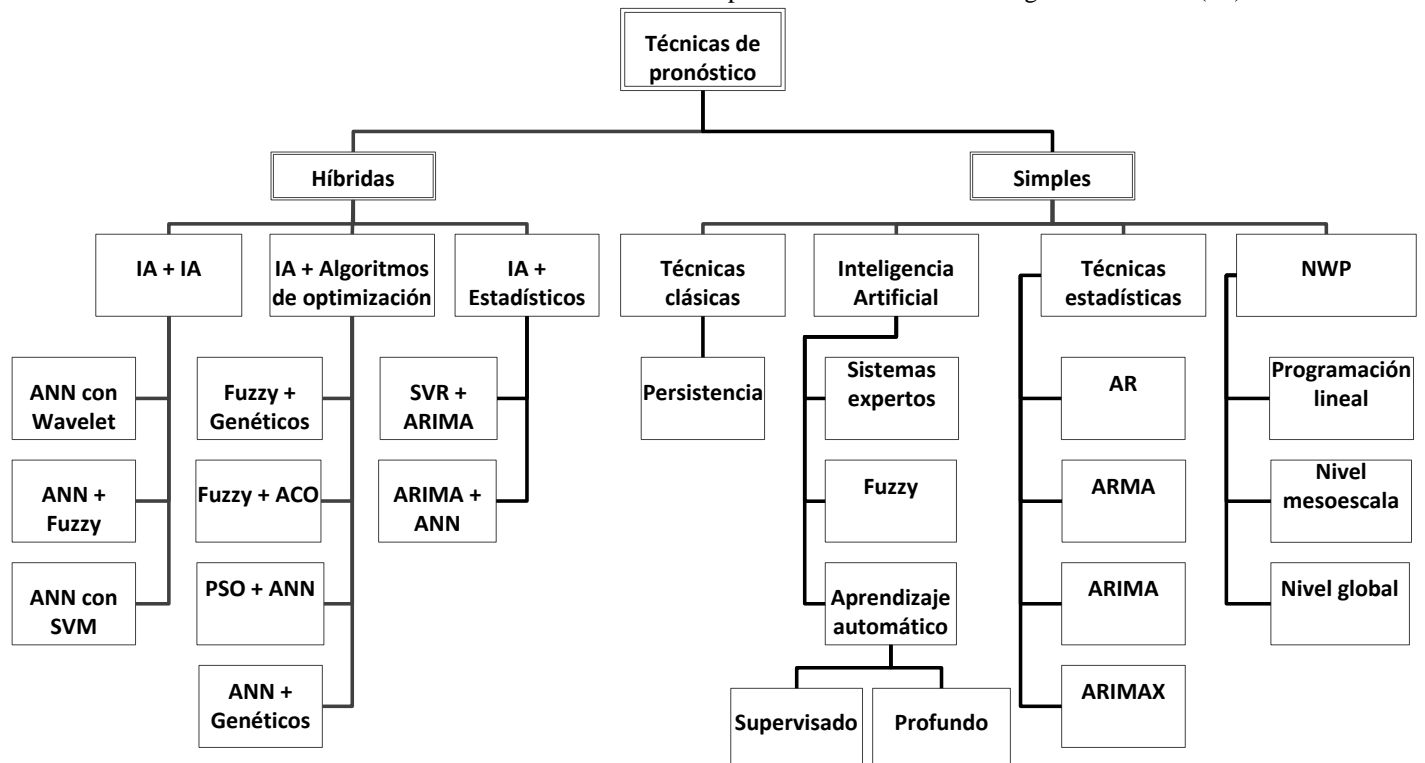


Fig. 3. Clasificación general de las técnicas de pronóstico.

## VII. CONCLUSIONES

Como resultado de este trabajo se detectaron las principales técnicas de pronóstico de la generación fotovoltaica y de la demanda, empleadas en horizontes de corto plazo, y, por lo tanto, aplicables en microrredes. Se identificó su clasificación general y posibles algoritmos híbridos para mejorar su desempeño, usando por lo menos dos técnicas de pronóstico.

A diferencia del pronóstico de corto plazo en sistemas eléctricos de gran escala, donde es posible obtener resultados adecuados con técnicas estadísticas, estas deben ser mejoradas mediante su combinación con algoritmos de optimización, variables exógenas o métodos IA, de tal forma que puedan ofrecer resultados adecuados en el contexto de la operación de microrredes.

Las técnicas de pronóstico más utilizadas para el pronóstico de la demanda y la generación fotovoltaica en microrredes son las basadas en métodos de IA, principalmente ANN y más recientemente, algoritmos de aprendizaje profundo. En general, se observa que es posible mejorar los resultados de pronóstico utilizando algoritmos de optimización, siendo posible utilizar un mismo algoritmo para predecir tanto la generación fotovoltaica, como la demanda.

## AGRADECIMIENTOS

Los autores agradecen el apoyo para la elaboración de este trabajo al TecNM-Campus Querétaro y al Centro de Ingeniería y Desarrollo Industrial (CIDESI).

## REFERENCIAS

[1] IEEE Power & Energy Society, *IEEE Standard for the Specification of Microgrid Controllers*. 2017.

[2] A. Ali, W. Li, R. Hussain, X. He, B. W. Williams, and A. H. Memon, "Overview of current microgrid policies, incentives and barriers in the European Union, United States and China," *Sustainability (Switzerland)*, vol. 9, no. 7. MDPI AG, 29-Jun-2017.

[3] F. Rodríguez, A. Fleetwood, A. Galarza, and L. Fontán, "Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control," *Renew. Energy*, vol. 126, pp. 855–864, 2018.

[4] H. Chitsaz, H. Shaker, H. Zareipour, D. Wood, and N. Amjadi, "Short-term electricity load forecasting of buildings in microgrids," *Energy Build.*, vol. 99, pp. 50–60, 2015.

[5] X. Serrano-Guerrero, R. Prieto-Galarza, E. Huilcatanda, J. Cabrera-Zeas, and G. Escriba-Escriba, "Election of variables and short-term forecasting of electricity demand based on backpropagation artificial neural networks," in *2017 IEEE International Autumn Meeting on Power, Electronics and Computing, ROPEC 2017*, 2018.

[6] J. Pascual, J. Barricarte, P. Sanchis, and L. Marroyo, "Energy management strategy for a renewable-based residential microgrid with generation and demand forecasting," *Appl. Energy*, vol. 158, pp. 12–25, 2015.

[7] Berkeley-Lab, "About Microgrids," 2019. [Online]. Available: <https://building-microgrid.lbl.gov/about-microgrids>. [Accessed: 17-May-2019].

[8] I. Naim, T. Mahara, and A. R. Idrisi, "Effective Short-Term Forecasting for Daily Time Series with Complex Seasonal Patterns," in *Procedia Computer Science*, 2018.

[9] M. G. De Giorgi, P. M. Congedo, and M. Malvoni, "Photovoltaic

power forecasting using statistical methods: Impact of weather data," *IET Sci. Meas. Technol.*, 2014.

[10] J. Shi, W. J. Lee, Y. Liu, Y. Yang, and P. Wang, "Forecasting power output of photovoltaic systems based on weather classification and support vector machines," in *IEEE Transactions on Industry Applications*, 2012.

[11] K. Brecl and M. Topic, "Photovoltaics (PV) system energy forecast on the basis of the local weather forecast: Problems, uncertainties and solutions," *Energies*, 2018.

[12] Y. Kwon, A. Kwasinski, and A. Kwasinski, "Solar irradiance forecast using naïve bayes classifier based on publicly available weather forecasting variables," *Energies*, 2019.

[13] S. N. Fallah, M. Ganjkhani, S. Shamshirband, and K. wing Chau, "Computational intelligence on short-term load forecasting: A methodological overview," *Energies*. 2019.

[14] A. Ahmad, N. Javaid, A. Mateen, M. Awais, and Z. A. Khan, "Short-Term load forecasting in smart grids: An intelligent modular approach," *Energies*, vol. 12, no. 1, pp. 1–21, 2019.

[15] H. S. Hippert, C. E. Pedreira, and R. C. Souza, "Neural networks for short-term load forecasting: A review and evaluation," *IEEE Trans. Power Syst.*, 2001.

[16] A. El khantach, M. Hamlich, and N. eddine Belbounaguia, "Short-term load forecasting using machine learning and periodicity decomposition," *AIMS Energy*, 2019.

[17] D. Sáez, F. Ávila, D. Olivares, C. Cañizares, and L. Marín, "Fuzzy prediction interval models for forecasting renewable resources and loads in microgrids," *IEEE Trans. Smart Grid*, vol. 6, no. 2, pp. 548–556, 2015.

[18] S. F. Rafique, Z. Jianhua, R. Rafique, J. Guo, and I. Jamil, "Renewable Generation (Wind/Solar) and Load Modeling through Modified Fuzzy Prediction Interval," *Int. J. Photoenergy*, vol. 2018, pp. 1–14, 2018.

[19] C. Hernández-Hernández, F. Rodríguez, J. C. Moreno, P. R. Da Costa Mendes, J. E. Normey-Rico, and J. L. Guzmán, "The comparison study of short-term prediction methods to enhance the model predictive controller applied to microgrid energy management," *Energies*, vol. 10, no. 7, 2017.

[20] M. Cai, M. Pipattanasomporn, and S. Rahman, "Day-ahead building-level load forecasts using deep learning vs. traditional time-series techniques," *Appl. Energy*, vol. 236, no. October 2018, pp. 1078–1088, 2019.

[21] 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, 2019.

[22] J. L. Sanchez-García, E. Espinosa-Juarez, and R. Tapia-Juarez, "Photovoltaic panel characterization by using artificial neural networks and comparison with classical models," in *2015 IEEE International Autumn Meeting on Power, Electronics and Computing, ROPEC 2015*, 2016.

[23] S. Leva, A. Dolara, F. Grimaccia, M. Mussetta, and E. Ogliari, "Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power," *Math. Comput. Simul.*, 2017.

[24] Y. K. Semero, D. Zheng, and J. Zhang, "A PSO-ANFIS based Hybrid Approach for Short Term PV Power Prediction in Microgrids," *Electric Power Components and Systems*, 2018.

[25] J. L. Sánchez-García, E. Espinosa-Juárez, and J. J. Flores, "Short term photovoltaic power production using a hybrid of nearest neighbor and artificial neural networks," in *2016 IEEE PES Transmission and Distribution Conference and Exposition-Latin America, PES T and D-LA 2016*, 2017.

[26] F. Mei, Y. Pan, K. Zhu, and J. Zheng, "A hybrid online forecasting model for ultrashort-term photovoltaic power generation," *Sustain.*, vol. 10, no. 3, pp. 1–17, 2018.

[27] V. S. \* and E. M. Otilia Elena Dragomir, Florin Dragomir, "Adaptive Neuro-Fuzzy Inference Systems as a Strategy for Predicting and Controlling the Energy Produced from Renewable Sources," *Energies*, vol. 8, no. 11, pp. 13047–13061, 2015.

- [28] L. Hernandez, C. Baladrón, J. M. Aguiar, B. Carro, A. J. Sanchez-Esguevillas, and J. Lloret, "Short-term load forecasting for microgrids based on artificial neural networks," *Energies*, vol. 6, no. 3, pp. 1385–1408, 2013.
- [29] Z. Xu, Z. Hu, J. Zhao, Y. Song, J. Lin, and C. Wan, "Photovoltaic and solar power forecasting for smart grid energy management," *CSEE J. Power Energy Syst.*, vol. 1, no. 4, pp. 38–46, 2016.
- [30] J. Ma and X. Ma, "A review of forecasting algorithms and energy management strategies for microgrids," *Syst. Sci. Control Eng.*, vol. 6, no. 1, pp. 237–248, 2018.