

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO



PRONÓSTICO MULTIVARIABLE DE GENERACIÓN EÓLICA-SOLAR
MEDIANTE ALGORITMOS HÍBRIDOS MEJORADOS DE APRENDIZAJE
PROFUNDO PARA LA OPERACIÓN EN TIEMPO REAL DE REDES ELÉCTRICAS

POR

M. C. REINIER HERRERA CASANOVA

EN OPCIÓN AL GRADO DE

DOCTOR EN INGENIERÍA ELÉCTRICA

SAN NICOLÁS DE LOS GARZA, NUEVO LEÓN

AGOSTO, 2026

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO



PRONÓSTICO MULTIVARIABLE DE GENERACIÓN EÓLICA-SOLAR
MEDIANTE ALGORITMOS HÍBRIDOS MEJORADOS DE APRENDIZAJE
PROFUNDO PARA LA OPERACIÓN EN TIEMPO REAL DE REDES ELÉCTRICAS

POR

M. C. REINIER HERRERA CASANOVA

EN OPCIÓN AL GRADO DE

DOCTOR EN INGENIERÍA ELÉCTRICA

SAN NICOLÁS DE LOS GARZA, NUEVO LEÓN

AGOSTO, 2026

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
Facultad de Ingeniería Mecánica y Eléctrica
Posgrado

Los miembros del Comité de Evaluación de Tesis recomendamos que la tesis “Pronóstico multivariable de generación eólica-solar mediante algoritmos híbridos mejorados de aprendizaje profundo para la operación en tiempo real de redes eléctricas”, realizada por el estudiante Reinier Herrera Casanova, con número de matrícula , sea aceptada para su defensa como requisito parcial para obtener el grado de Doctorado en Ingeniería Eléctrica.

El Comité de Evaluación de Tesis

Dr. Arturo Conde Enríquez
Director

Dr. Carlos Santos Pérez
Codirector

Dr. Manuel Antonio Andrade Soto
Revisor

Dr. Miguel Francisco Escalante Gutiérrez
Revisor

Dr. Alberto Cavazos González
Revisor

Dr. Juan Segundo Ramírez
Revisor

Dr. Francisco Sergio Sellschopp Sánchez
Revisor

V.º B.º



Dr. Azael Martínez de la Cruz
Secretario de Estudios de Posgrado

**SECRETARÍA DE
ESTUDIOS DE
POSGRADO**

Institución	<u>190001</u>
Programa	<u>514601</u>
Acta núm.	<u>382</u>

Ciudad Universitaria, 13 de agosto de 2026



Programa de Doctorado en Electrónica: Sistemas Electrónicos
Avanzados. Sistemas Inteligentes

**Pronóstico multivariable de generación eólica-solar mediante algoritmos
híbridos mejorados de aprendizaje profundo para la operación en tiempo real
de redes eléctricas**

Tesis Doctoral presentada por

Reinier Herrera Casanova

Directores

Dr. Carlos Santos Pérez

Dr. Arturo Conde Enríquez

Alcalá de Henares, agosto de 2026

DEDICATORIA

«El Señor está cerca de los quebrantados de corazón,

y salva a los de espíritu abatido».

Salmos 34:18

Dedico esta tesis a Dios, a mis padres y a mi familia.

AGRADECIMIENTOS

Al Señor mi Dios, por brindarme la fortaleza y la sabiduría necesarias para culminar este proyecto, y por poner en mi camino personas de bien que hicieron posible este logro.

A mi madre y a mi padre†, pilares fundamentales de mi vida, por su amor incondicional, su cariño y sus enseñanzas. Este logro también les pertenece, gracias a ustedes he llegado hasta aquí. Mi padre deseaba verme concluir este doctorado y, aunque la vida no se lo permitió, su recuerdo y sus enseñanzas me impulsaron a seguir adelante en los momentos más difíciles. Del mismo modo, el ejemplo de fortaleza y constancia de mi madre ha sido la luz que me ha guiado cada día para no rendirme.

A mis directores de tesis, el Dr. Arturo Conde Enríquez y el Dr. Carlos Santos Pérez, por su guía académica, amistad, sabiduría, profesionalismo y generosidad. Su apoyo incondicional, sus consejos y enseñanzas, así como su calidad humana excepcional, fueron fundamentales para el desarrollo de esta tesis y para mi crecimiento personal.

Un reconocimiento muy especial a mis abuelos, de quienes aprendí el verdadero significado del sacrificio y la fuerza de voluntad; gran parte de lo que soy hoy se lo debo a sus enseñanzas y a su ejemplo de vida. A ellos y al resto de mi familia, les agradezco su cariño, comprensión y apoyo constante a lo largo de este camino.

A los amigos que me acompañaron durante este proceso, en especial a Rolando, Alicia y su familia, así como a Paloma, Roberto y su familia. Su apoyo, cariño y la forma en que me hicieron sentir parte de sus vidas fueron invaluable. Expreso mi gratitud a Manuel Alejandro, Carlos Manuel y Dayron, por su amistad constante a lo largo de los años. De igual manera, agradezco a mis amigos en España, Miguel y Pablo, por su valioso apoyo en este camino, y de manera muy especial a mi amiga Rosa; su calidad humana, su constante atención, su cariño y su preocupación genuina por mi bienestar y el de mi familia han significado mucho para mí.

También deseo reconocer a los compañeros del doctorado que, con su apoyo en distintos momentos, contribuyeron a hacer más llevadera esta experiencia.

A los profesores que, tanto en Cuba, en México y en España, aportaron su conocimiento y experiencia, dejando una huella profunda en mi formación académica y fortaleciendo mi crecimiento profesional.

Finalmente, agradezco al SECIHTI (anteriormente CONACYT) por su valioso apoyo económico, el cual fue fundamental para el desarrollo de esta investigación, y a la Universidad Autónoma de Nuevo León y la Universidad de Alcalá por abrirme sus puertas y permitirme formar parte de sus comunidades académicas.

A todos los que de manera directa o indirecta compartieron conmigo este camino, mi más sincero agradecimiento; sin ustedes, alcanzar esta meta no habría sido posible.

RESUMEN

PRONÓSTICO MULTIVARIABLE DE GENERACIÓN EÓLICA-SOLAR MEDIANTE ALGORITMOS HÍBRIDOS MEJORADOS DE APRENDIZAJE PROFUNDO PARA LA OPERACIÓN EN TIEMPO REAL DE REDES ELÉCTRICAS

M. C. Reinier Herrera Casanova
Facultad de Ingeniería Mecánica y Eléctrica
Universidad Autónoma de Nuevo León

Director de Tesis: Dr. Arturo Conde Enríquez
Codirector de Tesis: Dr. Carlos Santos Pérez

La creciente penetración de fuentes de energía renovable (*Renewable Energy Sources*, RES), en particular la energía solar fotovoltaica (*Photovoltaic*, PV) y la energía eólica, plantea importantes desafíos para la operación segura y estable de los sistemas eléctricos. En este contexto, el pronóstico preciso de la generación renovable se convierte en un elemento esencial para la toma de decisiones operativas y el mantenimiento de la estabilidad de frecuencia. Esta tesis aborda de manera integral el desarrollo de una metodología avanzada para el pronóstico de energía solar PV y eólica, así como su impacto directo en el control de frecuencia de microrredes aisladas.

La investigación se centra en un horizonte temporal de muy corto plazo (15 min) y propone un marco de pronóstico basado en una red neuronal con memoria de largo y corto plazo bidireccional (*Bidirectional Long Short-Term Memory*, BiLSTM). El marco se complementa con un algoritmo robusto de preprocesamiento de datos, diseñado para mejorar la calidad y la consistencia de la información de entrada. También se integra un algoritmo de optimización Bayesiana (*Bayesian Optimization*, BO) para el ajuste automático de los hiperparámetros del modelo. Además, se incorpora un enfoque de pronóstico probabilístico basado en el método de remuestreo *bootstrap*. Esto permite la generación de intervalos de predicción que cuantifican la incertidumbre asociada a las predicciones determinísticas de las fuentes renovables.

El enfoque propuesto se evalúa en distintos escenarios operativos, incluyendo condiciones atípicas caracterizadas por la presencia de ruido blanco y la pérdida parcial o total de información debido a fallos temporales en los sensores de medición. Asimismo, se emplean técnicas de inteligencia artificial explicable (*Explainable Artificial Intelligence*, XAI), específicamente la eliminación recursiva de características (*Recursive Feature Elimination*, RFE), para analizar la importancia global de las variables de entrada del modelo. Los resultados demuestran que el enfoque propuesto es capaz de mantener un alto nivel de precisión, robustez y capacidad de adaptación, incluso en escenarios de elevada incertidumbre y degradación de los datos.

Finalmente, los pronósticos se integran directamente en un esquema de control proactivo de frecuencia de una microrred. Dicha integración evidencia una relación directa entre la precisión predictiva y la

magnitud de las desviaciones de frecuencia. Además, se confirma que una mejora en la calidad de los pronósticos se traduce en un control de frecuencia más eficiente. Esto contribuye a la reducción del riesgo operativo y al aumento de la resiliencia de la microrred ante eventos críticos y altos niveles de penetración de fuentes renovables. De manera general, esta tesis propone una metodología de pronóstico avanzada, flexible y escalable. Asimismo, demuestra su relevancia práctica al establecer un vínculo directo entre la calidad del pronóstico y la estabilidad operativa de las microrredes modernas.

Palabras clave: Pronóstico de energía solar PV y eólica; BiLSTM; optimización Bayesiana; microrredes; control de frecuencia.

ABSTRACT

MULTIVARIATE WIND-SOLAR POWER FORECASTING USING ENHANCED HYBRID DEEP LEARNING ALGORITHMS FOR REAL-TIME OPERATION OF POWER SYSTEMS

M.Sc. Reinier Herrera Casanova

Autonomous University of Nuevo León. Faculty of Mechanical and Electrical Engineering

Thesis Supervisor: Dr. Arturo Conde Enríquez

Thesis Co-supervisor: Dr. Carlos Santos Pérez

The increasing penetration of renewable energy sources (RES), particularly solar photovoltaic (PV) and wind energy, poses significant challenges for the safe and stable operation of power systems. In this context, accurate forecasting of renewable generation becomes an essential element for operational decision-making and the maintenance of frequency stability. This thesis comprehensively addresses the development of an advanced methodology for solar PV and wind energy forecasting, as well as its direct impact on the frequency control of isolated microgrids.

The research focuses on a very short-term time horizon (15 min) and proposes a forecasting framework based on a bidirectional long short-term memory (BiLSTM) neural network. The framework is complemented by a robust data preprocessing algorithm designed to improve the quality and consistency of the input information. A Bayesian optimization (BO) algorithm is also integrated for the automatic tuning of the model's hyperparameters. Furthermore, a probabilistic forecasting approach based on the bootstrap resampling method is incorporated. This enables the generation of prediction intervals that quantify the uncertainty associated with the deterministic predictions of renewable sources.

The proposed approach is evaluated in different operational scenarios, including atypical conditions characterized by the presence of white noise and the partial or total loss of information due to temporary sensor measurement failures. Likewise, explainable artificial intelligence (XAI) techniques, specifically recursive feature elimination (RFE), are employed to analyze the global importance of the model's input variables. The results demonstrate that the proposed approach is capable of maintaining a high level of accuracy, robustness, and adaptability, even in scenarios of high uncertainty and data degradation.

Finally, the forecasts are directly integrated into a proactive frequency control scheme for a microgrid. This integration reveals a direct relationship between predictive accuracy and the magnitude of frequency deviations. Additionally, it is confirmed that an improvement in forecasting quality translates into more efficient frequency control. This contributes to the reduction of operational risk and an increase in microgrid resilience against critical events and high levels of renewable energy penetration. Overall, this thesis proposes an advanced, flexible, and scalable forecasting methodology. Likewise, it demonstrates its practical relevance by establishing a direct link between forecast quality and the operational stability of modern microgrids.

Keywords: Solar PV and wind power forecasting; BiLSTM; Bayesian optimization; microgrids; frequency control.

PUBLICACIONES DERIVADAS DE LA TESIS

Artículos en revistas indexadas

- Reinier Herrera-Casanova, Arturo Conde and Carlos Santos-Pérez, “Hour-Ahead Photovoltaic Power Prediction Combining BiLSTM and Bayesian Optimization Algorithm, with Bootstrap Resampling for Interval Predictions,” *Sensors*, vol. 24, no. 3, p. 882, 2024. <https://doi.org/10.3390/s24030882>
- Reinier Herrera-Casanova and Arturo Conde, “Enhancement of LSTM models based on data pre-processing and optimization of Bayesian hyperparameters for day-ahead photovoltaic generation prediction,” *Computers and Electrical Engineering*, vol. 116, p. 109162, 2024. <https://doi.org/10.1016/j.compeleceng.2024.109162>
- Reinier Herrera-Casanova, Arturo Conde, Carlos Santos-Pérez, Carlos Cruz and Marcos Tostado-Véliz, “Photovoltaic power forecasting under atypical operating conditions validated by explainable artificial intelligence,” *Energy Conversion and Management*, vol. 356, p. 121358, 2026. <https://doi.org/10.1016/j.enconman.2026.121358>
- Reinier Herrera-Casanova, Arturo Conde, Carlos Santos-Pérez, Francisco Javier Rodríguez, Pedro Martín-Calzada, Jorge Ballesteros and Pablo José Hueros-Barrios “Reliable Ultra-Short-Term Wind Power Forecasting via Robust Preprocessing, Optimized Deep Learning, and Bootstrap Interval Prediction,” *Computers and Electrical Engineering*, (Accepted for publication).

Capítulo de libro

- Reinier Herrera-Casanova and Arturo Conde Enríquez, “Prediction of Photovoltaic Generation using Deep Learning Neural Networks with Hyperparameter Optimization,” in *Photovoltaic Modules: Fundamentals, Modeling, Performance Analysis and Control*, 1st ed., CRC Press, 2025. ISBN: 9781032393049. <https://doi.org/10.1201/9781003623168>

Artículo de conferencia

- Reinier Herrera-Casanova, Arturo Conde and Zbigniew M. Leonowicz, “Improved Wind Power Forecasting Based on BiLSTM-BO Hybrid Model and Data Preprocessing Algorithm,” *2024 IEEE International Conference on Environment and Electrical Engineering and 2024 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe)*, Rome, Italy, 2024, pp. 1-6. <https://doi.org/10.1109/EEEIC/ICPSEUROPE61470.2024.10751530>

ÍNDICE GENERAL

Dedicatoria	i
Agradecimientos	ii
Resumen	iii
Abstract	v
Publicaciones derivadas de la tesis	vii
Índice general	viii
Índice de figuras	xiii
Índice de tablas	xviii
Lista de acrónimos	xix
1 Introducción	1
1.1 Tendencias actuales de la energía renovable a nivel mundial	1
1.2 Justificación y motivación de la investigación	2
1.3 Hipótesis.....	5
1.4 Objetivos	6
1.5 Alcances y limitaciones.....	6
1.6 Estructura de la tesis.....	7
2 Pronósticos de energía solar PV y eólica	8
2.1 Introducción.....	8
2.2 Energía solar PV.....	8
2.2.1 Modelo matemático de un sistema PV.....	8
2.2.2 Análisis de las principales variables que influyen en el desempeño de los sistemas PV	9
2.3 Energía eólica	13
2.3.1 Modelo matemático de un sistema eólico	14
2.3.2 Análisis de las principales variables que influyen en el desempeño de los sistemas eólicos	14
2.4 Clasificación de los pronósticos	18
2.4.1 Clasificación basada en el horizonte de pronóstico	18
2.4.2 Clasificación basada en la variable a predecir	19

2.4.3 Clasificación basada en la escala espacial	19
2.4.4 Clasificación basada en el método de pronóstico.....	20
2.4.5 Clasificación basada en el tipo de pronóstico	24
2.5 Métricas para evaluar la exactitud de los pronósticos	25
2.6 Importancia de los pronósticos de energía solar PV y eólica	27
2.7 Estado actual de los pronósticos de energía solar PV y eólica	27
2.7.1 Estado actual del pronóstico de energía solar PV	28
2.7.2 Estado actual del pronóstico de energía eólica.....	29
2.7.3 Principales tendencias, contribuciones y limitaciones en el pronóstico de energía solar PV y eólica	31
2.8 Conclusiones del capítulo	32
3 Metodología propuesta para el pronóstico de energía solar PV y eólica	34
3.1 Introducción.....	34
3.2 Adquisición de datos	35
3.3 Algoritmo propuesto para el preprocesamiento y la preparación de los datos	36
3.3.1 Análisis estadístico y gráfico de los datos.....	37
3.3.2 Limpieza de los datos	37
3.3.3 Ajuste de la resolución temporal de los datos	38
3.3.4 Selección de las características de entrada al modelo de pronóstico.....	39
3.3.5 Identificación de los rezagos y reestructuración del formato de los datos	40
3.3.6 División de los datos.....	41
3.3.7 Normalización de los datos.....	42
3.3.8 Descripción general del algoritmo propuesto para el preprocesamiento y la preparación de los datos ...	43
3.4 Formulación de los modelos de pronóstico	44
3.4.1 Redes neuronales recurrentes (RNN).....	44
3.4.2 Redes neuronales LSTM.....	46
3.4.3 Redes neuronales BiLSTM.....	47
3.5 Optimización de hiperparámetros.....	48
3.5.1 Tipos de hiperparámetros y su importancia	48
3.5.2 Métodos para la optimización de hiperparámetros	51
3.6 Modelos de referencia utilizados para la comparación.....	55
3.6.1 Modelo MLP.....	56
3.6.2 Modelo SVR	56
3.6.3 Modelo de persistencia	57

3.7 Implementación de los modelos de pronóstico	58
3.7.1 Pronósticos determinísticos	58
3.7.2 Pronósticos probabilísticos	59
3.8 Técnicas de inteligencia artificial explicable (XAI)	60
3.9 Pronóstico de energía solar PV y eólica en condiciones de operación atípicas	61
3.10 Conclusiones del capítulo	63
4 Control de frecuencia en redes eléctricas	65
4.1 Introducción	65
4.2 Conceptos fundamentales	65
4.3 Indicadores utilizados para evaluar la estabilidad de frecuencia	66
4.3.1 Inercia del sistema	66
4.3.2 Tasa de cambio de la frecuencia (RoCoF)	67
4.3.3 Desviación máxima de frecuencia (nadir o cenit)	68
4.4 Respuesta de frecuencia del sistema eléctrico	68
4.5 Control de frecuencia mediante generadores síncronos	69
4.5.1 Necesidad de los sistemas de control de frecuencia	69
4.5.2 Modelo equivalente del generador síncrono	70
4.5.3 Modelo equivalente de la carga	71
4.5.4 Modelo equivalente de la turbina mecánica	71
4.5.5 Modelo equivalente del gobernador de velocidad	72
4.5.6 Modelo equivalente de un sistema de potencia aislado	73
4.6 Efectos de la integración de RES en el control de frecuencia	74
4.7 Control de frecuencia mediante RES	76
4.7.1 Control de frecuencia mediante fuentes PV	76
4.7.1.1 Descarga PV	77
4.7.1.2 Capacitor de enlace de DC	78
4.7.2 Control de frecuencia mediante fuentes eólicas	78
4.7.2.1 Control de inercia	78
4.7.2.2 Control de descarga	80
4.8 Control de frecuencia mediante inversores	80
4.9 Control de frecuencia mediante sistemas de almacenamiento de energía	81
4.10 Consideraciones importantes para el control de frecuencia en microrredes	82
4.10.1 Principales características de las microrredes	82

4.10.2 Enfoques utilizados para el control de frecuencia en microrredes	83
4.10.3 Modelo de los elementos de la microrred para estudios de control de frecuencia	85
4.10.3.1 Modelo de las RES	85
4.10.3.2 Modelo de las fuentes de generación controladas	86
4.10.3.3 Modelo de los ESS	86
4.10.3.4 Modelo para analizar las desviaciones de frecuencia	87
4.10.4 Diseño del controlador de la microrred.....	88
4.10.4.1 Descripción del controlador de tipo PID	88
4.10.4.2 Optimización de los parámetros del controlador	89
4.11 Acciones remediales en el sistema eléctrico.....	90
4.12 Conclusiones del capítulo.....	91
5 Principales resultados obtenidos en el pronóstico de energía solar PV	93
5.1 Introducción.....	93
5.2 Descripción de los datos utilizados	93
5.3 Resultados obtenidos en el preprocesamiento y la preparación de los datos	94
5.3.1 Resultados obtenidos en el análisis estadístico y gráfico de los datos	94
5.3.2 Resultados obtenidos en la limpieza de los datos	95
5.3.3 Resultados obtenidos en la selección de las características de entrada al modelo de predicción.....	98
5.3.4 Resultados obtenidos en la identificación de rezagos en las series temporales.....	100
5.4 Consideraciones generales para el pronóstico	102
5.5 Resultados obtenidos en el pronóstico determinístico de energía solar PV a muy corto plazo	104
5.6 Resultados obtenidos en el pronóstico probabilístico de energía solar PV a muy corto plazo	110
5.7 Pronóstico de energía solar PV en condiciones de operación atípicas	113
5.7.1 Explicabilidad del modelo de pronóstico	114
5.7.2 Pérdida de información en las variables de entrada	114
5.7.3 Presencia de ruido blanco en las mediciones disponibles	117
5.7.4 Predicción probabilística en escenarios de operación atípicos.....	118
5.8 Conclusiones del capítulo.....	119
6 Principales resultados obtenidos en el pronóstico de energía eólica	121
6.1 Introducción.....	121
6.2 Descripción de los datos utilizados	121
6.3 Resultados obtenidos en el preprocesamiento y la preparación de los datos	122
6.3.1 Resultados obtenidos en el análisis estadístico y gráfico de los datos	122

6.3.2 Resultados obtenidos en la limpieza de los datos	123
6.3.3 Resultados obtenidos en la selección de características de entrada al modelo de predicción	126
6.3.4 Resultados obtenidos en la identificación de rezagos en las series temporales.....	128
6.4 Consideraciones generales para el pronóstico	129
6.5 Resultados obtenidos en el pronóstico determinístico de energía eólica a muy corto plazo	130
6.6 Resultados obtenidos en el pronóstico probabilístico de energía eólica a muy corto plazo	136
6.7 Pronóstico de energía eólica en condiciones de operación atípicas.....	138
6.7.1 Explicabilidad del modelo de pronóstico	139
6.7.2 Pérdida de información en las variables de entrada	139
6.7.3 Presencia de ruido blanco en las mediciones disponibles	140
6.7.4 Predicción probabilística en escenarios de operación atípicos.....	142
6.8 Conclusiones del capítulo	143
7 Impacto de los pronósticos de energía solar PV y eólica en el control de frecuencia	144
7.1 Introducción.....	144
7.2 Descripción de la metodología propuesta.....	144
7.3 Consideraciones generales para el estudio	145
7.4 Modelo de pequeña señal de la microrred	147
7.5 Diseño del controlador de la microrred	152
7.6 Análisis de los errores derivados del pronóstico de las RES	152
7.7 Impacto de los pronósticos realizados en el control de frecuencia	155
7.8 Evaluación de la robustez del sistema ante contingencias severas	159
7.9 Conclusiones del capítulo	161
8 Conclusiones, contribuciones y recomendaciones	162
8.1 Conclusiones	162
8.2 Contribuciones.....	163
8.3 Recomendaciones y trabajos futuros	163
Referencias	165

ÍNDICE DE FIGURAS

1.1. Evolución de la capacidad eléctrica instalada de las principales RES a nivel mundial desde 2015 hasta 2024.....	1
2.1. Curvas características de un sistema PV para diferentes niveles de irradiancia solar: (a) Curva de corriente-voltaje (I-V) y (b) Curva de potencia-voltaje (P-V).	9
2.2. Comportamiento de la irradiancia solar y la potencia PV en diferentes condiciones atmosféricas: (a) Día soleado y (b) Día nublado. *(Los datos de potencia corresponden a una instalación PV con potencia nominal de 2.97 kW).	10
2.3. Curva característica de potencia-voltaje (P-V) para distintos niveles de irradiancia solar y de temperatura del panel PV.	11
2.4. Correlación entre las variables meteorológicas y la potencia PV generada en distintas ubicaciones geográficas [30].	13
2.5. Curva característica de la potencia de salida de un aerogenerador en función de la velocidad del viento [37]. ...	14
2.6. Comportamiento de la velocidad del viento y la potencia eólica generada en diferentes tipos de días: (a) Día con mucho viento y (b) Día con poco viento. *(Los datos de potencia eólica corresponden a un aerogenerador con potencia nominal de 2350 kW).	15
2.7. Espectro de Van der Hoven para la componente horizontal de la velocidad del viento [40].	17
2.8. Clasificación general de los pronósticos de energía solar PV y eólica.	18
2.9. Representación gráfica del horizonte de pronóstico en la predicción de energía solar PV.	19
2.10. Clasificación de los pronósticos en función de la variable a predecir: (a) Pronóstico directo y (b) Pronóstico indirecto.	19
2.11. Clasificación de los pronósticos en función de la escala espacial considerada.	20
2.12. Clasificación de los métodos de pronóstico de energía solar PV y eólica.	21
2.13. Diagrama de Venn que muestra la relación entre IA, ML y DL.	22
2.14. Clasificación de los métodos de pronóstico híbridos.	23
2.15. Representación gráfica de los pronósticos determinísticos y probabilísticos de energía eólica.	24
3.1. Estructura general de la metodología propuesta para el pronóstico de energía solar PV y eólica.	34
3.2. Representación general del proceso de adquisición de datos de energía solar PV y eólica.	35
3.3. Principales etapas que conforman el algoritmo propuesto para el preprocesamiento y la preparación de los datos.	36
3.4. Estructura del algoritmo propuesto para la limpieza de los datos.	37
3.5. Estructura general del enfoque propuesto para llevar a cabo el proceso de FS.	39
3.6. Esquema de reestructuración de los datos en función de las características de entrada, la salida del modelo y el horizonte de pronóstico.	41
3.7. Estrategia de división de los datos basada en los meses del año.	42
3.8. Estructura básica de una RNN [93].	44

3.9. Estructura básica de una celda de memoria del modelo LSTM [98].....	46
3.10. Estructura básica del modelo BiLSTM.	47
3.11. Representación de una red neuronal que contiene dos capas ocultas con cuatro neuronas en cada capa.....	49
3.12. Estructura de una red neuronal: (a) Antes de aplicar el <i>dropout</i> y (b) Después de aplicar el <i>dropout</i>	50
3.13. Comparación de la exploración del espacio de búsqueda mediante: (a) GS y (b) RS [104]. *(En este caso las curvas en el lado izquierdo y en la parte superior de cada figura representan la exactitud del modelo en función de cada dimensión de búsqueda).	52
3.14. Representación del comportamiento de la BO orientada hacia: (a) Exploración (alta incertidumbre) y (b) Explotación (en regiones prometedoras) [104]. *(El área sombreada indica el nivel de incertidumbre del modelo sustituto).	54
3.15. Principales aspectos que intervienen en el proceso de HPO mediante el algoritmo de BO.	55
3.16. Representación esquemática simplificada de una red neuronal MLP.	56
3.17. Representación esquemática simplificada del modelo SVR para la predicción de la potencia PV ($\hat{P}$) en función del núcleo aplicado a la irradiancia $\phi(I)$ [22].	57
3.18. Estructura general del modelo utilizado para la obtención de pronósticos determinísticos.	59
3.19. Metodología propuesta para asegurar la operatividad del modelo de pronóstico en condiciones de operación atípicas derivadas de fallos temporales en los sensores de medición.	62
3.20. Metodología propuesta para evaluar la capacidad de adaptación del modelo de pronóstico y obtener las predicciones necesarias en condiciones de operación atípicas relacionadas con la presencia de ruido blanco en las mediciones.	63
4.1. Analogía del balance entre generación y carga y su relación con la frecuencia del sistema eléctrico.	66
4.2. Etapas de la respuesta de frecuencia de un sistema eléctrico.	68
4.3. Esquema simple para el control de frecuencia en un generador síncrono.	70
4.4. Modelo del generador síncrono para estudios de control de frecuencia.....	70
4.5. Modelo del generador síncrono y la carga para estudios de control de frecuencia.	71
4.6. Modelo de una turbina de vapor sin recalentamiento para estudios de control de frecuencia.	72
4.7. Gobernador de velocidad: (a) Modelo para estudios de control de frecuencia y (b) Característica de caída.	73
4.8. Modelo para el control de frecuencia en un sistema de potencia aislado.	73
4.9. Estructura general de los sistemas eléctricos: (a) Sistemas tradicionales y (b) Sistemas modernos.	74
4.10. Comparación de la respuesta de frecuencia de un sistema eléctrico convencional (dominado por generadores síncronos) y de un sistema eléctrico con baja inercia (alta penetración de RES).	75
4.11. Descripción de la técnica de descarga PV: (a) Estructura del bloque de control y (b) Representación gráfica.	77
4.12. Diagrama general de un sistema PV que muestra la ubicación del capacitor de enlace de DC.	78
4.13. Diagrama en bloques de la técnica de emulación de inercia oculta con un lazo de control.	79
4.14. Diagrama en bloques de la técnica de control de reserva de potencia rápida.	80
4.15. Representación aproximada de los inversores: (a) GFL y (b) GFM.	81

4.16. Modelo de pequeña señal de las RES para estudios de control de frecuencia: (a) Sistema PV y (b) Sistema eólico.	85
4.17. Modelo de pequeña señal del FCG para estudios de control de frecuencia.	86
4.18. Modelo de pequeña señal de los ESS para estudios de control de frecuencia: (a) BESS y (b) FESS.	87
4.19. Estructura del controlador PID.....	89
4.20. Esquema UFLS de tipo estático: (a) Representación general y (b) Efecto de la variación del número de etapas [123].	91
5.1. Variación anual de la potencia PV según la hora del día y el mes del año para los conjuntos de datos: (a) <i>D1</i> , (b) <i>D2</i> y (c) <i>D3</i>	95
5.2. Resultados obtenidos en la detección y corrección de valores atípicos: (a) Serie temporal de <i>Tp</i> del conjunto de datos <i>D1</i> y (b) Serie temporal de <i>GHI</i> del conjunto de datos <i>D2</i>	96
5.3. Resultados obtenidos en la detección e imputación de valores ausentes: (a) Serie temporal de <i>Ta</i> del conjunto de datos <i>D2</i> y (b) Serie temporal de <i>Ppv</i> del conjunto de datos <i>D3</i>	97
5.4. Resultados obtenidos en la detección y corrección de valores anómalos en el conjunto de datos <i>D1</i> : (a) Gráfico de dispersión inicial de <i>GHI</i> vs. <i>Ppv</i> , (b) Curva de potencia ajustada y (c) Gráfico de dispersión final de <i>GHI</i> vs. <i>Ppv</i>	98
5.5. Resultados obtenidos en el proceso de FS: (a) Análisis de PCC para el conjunto de datos <i>D1</i> , (b) Estimación de la importancia del predictor mediante un modelo RF para el conjunto de datos <i>D1</i> , (c) Análisis de PCC para el conjunto de datos <i>D2</i> y (d) Estimación de la importancia del predictor mediante un modelo RF para el conjunto de datos <i>D2</i>	99
5.6. Análisis de las funciones ACF y PACF aplicadas a las series temporales de <i>GHI</i> , <i>Ta</i> y <i>Ppv</i> del conjunto de datos <i>D1</i> para la selección del número de rezagos.	101
5.7. Análisis de las funciones ACF y PACF aplicadas a las series temporales de <i>GHI</i> , <i>Ta</i> , <i>Rh</i> y <i>Ppv</i> del conjunto de datos <i>D2</i> para la selección del número de rezagos.	101
5.8. Análisis de las funciones ACF y PACF aplicadas a la serie temporal de <i>Ppv</i> del conjunto de datos <i>D3</i> para la selección del número de rezagos.	102
5.9. Estructura general del modelo de pronóstico implementado para cada conjunto de datos analizado: (a) <i>D1</i> , (b) <i>D2</i> y (c) <i>D3</i>	102
5.10. Comparación entre los valores reales de <i>Ppv</i> y las predicciones determinísticas generadas por cada modelo en diferentes condiciones climáticas, para los conjuntos de datos: (a) <i>D1</i> , (b) <i>D2</i> y (c) <i>D3</i>	105
5.11. Gráficos de dispersión entre los valores reales de <i>Ppv</i> y las predicciones generadas por cada modelo, para los conjuntos de datos: (a) <i>D1</i> , (b) <i>D2</i> y (c) <i>D3</i>	106
5.12. Porcentaje de mejora alcanzado por el modelo propuesto con respecto a los modelos de referencia para cada conjunto de datos, tomando como base la métrica nMAE.	108

5.13. PIs obtenidos mediante el método de remuestreo bootstrap para diferentes valores de PINC (80 %, 90 % y 95 %) en días representativos de los conjuntos de datos: (a) <i>D1</i> , (b) <i>D2</i> y (c) <i>D3</i> .	111
5.14. Contribuciones estimadas de las variables de entrada al modelo de pronóstico propuesto, obtenidas mediante la técnica de XAI conocida como RFE.	114
5.15. Rendimiento del modelo propuesto ante la pérdida temporal de información en diferentes variables de entrada.	115
5.16. Rendimiento del modelo propuesto en la predicción de potencia PV tras un fallo temporal que afecta a todas las variables de entrada.	116
5.17. Representación de la serie temporal de <i>GHI</i> perteneciente a los datos de prueba del conjunto <i>D2</i> , considerando las mediciones originales y con ruido blanco añadido.	117
5.18. Rendimiento del modelo de pronóstico propuesto ante la presencia de ruido blanco en diferentes variables de entrada: (a) Considerando la métrica <i>nMAE</i> y (b) Considerando la métrica <i>R²</i> .	118
5.19. Comportamiento de los PIs en condiciones de operación atípicas asociadas al fallo temporal de todas las variables de entrada de manera simultánea.	119
6.1. Variación anual de la potencia eólica en función de la hora del día y del mes del año para los conjuntos de datos: (a) <i>DW1</i> y (b) <i>DW2</i> .	123
6.2. Resultados obtenidos en la detección y corrección de valores atípicos: (a) Serie temporal de <i>Wsg</i> del conjunto de datos <i>DW1</i> y (b) Serie temporal de <i>Pw</i> del conjunto de datos <i>DW2</i> .	124
6.3. Resultados obtenidos en la detección e imputación de valores ausentes: (a) Serie temporal de <i>Rh</i> del conjunto de datos <i>DW1</i> y (b) Serie temporal de <i>Pw</i> del conjunto de datos <i>DW2</i> .	125
6.4. Resultados obtenidos en la detección y corrección de valores anómalos en el conjunto de datos <i>DW1</i> : (a) Gráfico de dispersión inicial de <i>Wsg</i> vs. <i>Pw</i> , (b) Curva de tendencia estimada y (c) Gráfico de dispersión final de <i>Wsg</i> vs. <i>Pw</i> .	126
6.5. Resultados obtenidos en el proceso de FS para el conjunto de datos <i>DW1</i> : (a) Análisis de PCC y (b) Estimación de la importancia del predictor mediante la permutación de las observaciones fuera de la bolsa en un modelo RF.	127
6.6. Análisis de las funciones ACF y PACF de las series temporales <i>Wsg</i> , <i>Rsp</i> y <i>Pw</i> del conjunto de datos <i>DW1</i> para la selección del número de rezagos.	128
6.7. Análisis de las funciones ACF y PACF de la serie temporal <i>Pw</i> del conjunto de datos <i>DW2</i> para la selección del número de rezagos.	128
6.8. Estructura general del modelo de pronóstico implementado para cada conjunto de datos analizado: (a) <i>DW1</i> y (b) <i>DW2</i> .	129
6.9. Comparación entre los valores reales de <i>Pw</i> y las predicciones determinísticas generadas por cada modelo bajo diferentes condiciones climáticas, para los conjuntos de datos: (a) <i>DW1</i> y (b) <i>DW2</i> .	131
6.10. Gráficos de dispersión entre los valores reales de <i>Pw</i> y las predicciones generadas por cada modelo, para los conjuntos de datos: (a) <i>DW1</i> y (b) <i>DW2</i> .	132
6.11. Porcentaje de mejora alcanzado por el modelo propuesto con respecto a los modelos de referencia para cada conjunto de datos, tomando como base la métrica <i>nMAE</i> .	134

6.12. PIs generados mediante el método de remuestreo bootstrap para diferentes valores de PINC (80 %, 90 % y 95 %) en días representativos de los conjuntos de datos: (a) <i>DW1</i> y (b) <i>DW2</i> .	136
6.13. Contribuciones estimadas de las variables de entrada al modelo de pronóstico propuesto, obtenidas mediante la técnica de XAI conocida como RFE.	139
6.14. Rendimiento del modelo propuesto ante la pérdida temporal de diferentes variables de entrada.	140
6.15. Rendimiento del modelo propuesto en la predicción de potencia eólica después del fallo temporal de todas las variables de entrada.	140
6.16. Representación de la serie temporal de <i>Wsg</i> perteneciente a los datos de prueba del conjunto <i>DW1</i> considerando las mediciones originales y con ruido blanco añadido.	141
6.17. Rendimiento del modelo de pronóstico propuesto ante la presencia de ruido blanco en diferentes variables de entrada: (a) Considerando la métrica nMAE y (b) Considerando la métrica R^2 .	142
6.18. Comportamiento de los PIs bajo condiciones de operación atípicas asociadas con el fallo temporal de todas las variables de entrada de manera simultánea.	142
7.1. Estructura general de la metodología propuesta para analizar el impacto del pronóstico de las RES en el control de frecuencia de una microrred aislada con múltiples DER.	145
7.2. Topología eléctrica de la microrred híbrida implementada y distribución de los DER.	146
7.3. Modelo dinámico de pequeña señal de la microrred implementada, utilizado para el análisis de estabilidad y la regulación de frecuencia.	147
7.4. Curvas de convergencia de la función objetivo para los algoritmos PSO y GWO.	150
7.5. Comparación de la respuesta de frecuencia ante eventos transitorios: (a) Escenario de baja frecuencia (nadir) y (b) Escenario de alta frecuencia (cenit).	151
7.6. Análisis comparativo del error de pronóstico para un horizonte de 15 min: (a) Serie temporal del error PV; (b) Error residual vs. potencia PV real; (c) Serie temporal del error eólico; (d) Error residual vs. potencia eólica real.	153
7.7. Distribución del nMAE para los modelos evaluados en los conjuntos de datos: (a) Energía solar PV y (b) Energía eólica.	154
7.8. Evolución de la frecuencia de la microrred considerando un escenario base con control convencional y estrategias de control anticipativo basadas en los modelos BiLSTM-BO, SVR-BO y persistencia.	156
7.9. Histogramas de las desviaciones de frecuencia en la microrred para los diferentes escenarios evaluados.	158
7.10. Análisis de dispersión entre los errores de pronóstico de las RES y las desviaciones de frecuencia de la microrred.	159
7.11. Trayectorias de frecuencia frente a los umbrales de desconexión definidos en el estándar IEEE C37.117 (ECAR).	160

ÍNDICE DE TABLAS

2.1. Aplicaciones de los pronósticos de energía solar PV y eólica en función del horizonte de pronóstico utilizado.	27
4.1. Impacto de la integración de RES en las métricas operativas de distintos sistemas de potencia.	76
4.2. Estado del arte sobre el control de frecuencia en microrredes.	83
5.1. Principales características de los conjuntos de datos utilizados en el estudio.	94
5.2. Hiperparámetros, espacios de búsqueda definidos para la BO y ajustes obtenidos para cada modelo.	103
5.3. Desempeño de cada modelo en el pronóstico determinístico de potencia PV con 15 min de antelación.	107
5.4. Comparación de los resultados obtenidos en esta investigación para el pronóstico determinístico de potencia PV con respecto a otros estudios reportados en la literatura.	109
5.5. Evaluación de las predicciones probabilísticas de potencia PV considerando diferentes valores de PINC.	112
5.6. Comparación de los resultados obtenidos en esta investigación para el pronóstico probabilístico de potencia PV con respecto a otros estudios reportados en la literatura.	113
6.1. Principales características de los conjuntos de datos utilizados en el estudio.	122
6.2. Hiperparámetros, espacios de búsqueda definidos para la BO y ajustes obtenidos para cada modelo.	129
6.3. Desempeño de los modelos en el pronóstico determinístico de energía eólica con un horizonte de 15 min.	133
6.4. Comparación de los resultados obtenidos en esta investigación para el pronóstico determinístico de energía eólica con respecto a otros estudios reportados en la literatura.	134
6.5. Evaluación del desempeño de los pronósticos probabilísticos de energía eólica para distintos niveles de PINC.	137
6.6. Comparación de los pronósticos probabilísticos de energía eólica obtenidos en este trabajo con resultados reportados en otros estudios reportados en la literatura.	137
7.1. Principales parámetros que intervienen en el modelo de pequeña señal de la microrred.	148
7.2. Parámetros de configuración inicial para los algoritmos metaheurísticos.	150
7.3. Parámetros del controlador PID obtenidos mediante diferentes métodos de ajuste.	150
7.4. Desempeño del controlador PID al considerar diferentes métodos de ajuste.	152
7.5. Métricas de rendimiento obtenidas para cada modelo en el pronóstico determinístico de potencia PV y eólica con 15 min de antelación. (Período de evaluación de 72 horas).	152
7.6. Análisis estadístico de la frecuencia de la microrred al considerar diferentes escenarios de control.	157
7.7. Umbrales de desconexión de carga definidos para el análisis de robustez.	160
7.8. Análisis comparativo de los enfoques de control y su impacto en el suministro eléctrico.	161

LISTA DE ACRÓNIMOS

Acrónimo	Definition	Definición
AC	<i>Alternating Current</i>	Corriente alterna
ACE	<i>Average Coverage Error</i>	Error de cobertura promedio
ACF	<i>Autocorrelation Function</i>	Función de autocorrelación
ACO	<i>Ant Colony Optimization</i>	Optimización por colonia de hormigas
Adam	<i>Adaptive Moment Estimation</i>	Estimación adaptativa de momentos
AGC	<i>Automatic Generation Control</i>	Control automático de generación
ANN	<i>Artificial Neural Network</i>	Red neuronal artificial
ARIMA	<i>Autoregressive Integrated Moving Average</i>	Autorregresivo integrado de media móvil
ARMA	<i>Autoregressive Moving Average</i>	Autorregresivo de media móvil
ASHA	<i>Asynchronous Successive Halving</i>	Reducción sucesiva asíncrona
BESS	<i>Battery Energy Storage System</i>	Sistema de almacenamiento de energía en baterías
BiLSTM	<i>Bidirectional Long Short-Term Memory</i>	Memoria de largo y corto plazo bidireccional
BO	<i>Bayesian Optimization</i>	Optimización bayesiana
BP	<i>Backpropagation</i>	Retropropagación
BPNN	<i>Backpropagation Neural Network</i>	Red neuronal de retropropagación
BPTT	<i>Backpropagation Through Time</i>	Retropropagación a través del tiempo
CAESS	<i>Compressed Air Energy Storage System</i>	Sistema de almacenamiento de energía por aire comprimido
CEEMD	<i>Complementary Ensemble Empirical Mode Decomposition</i>	Descomposición empírica modal por conjuntos complementarios
CNN	<i>Convolutional Neural Network</i>	Red neuronal convolucional
CSSOA	<i>Chaotic Sparrow Search Optimization Algorithm</i>	Algoritmo de optimización de búsqueda caótica del gorrión
DA	<i>Dual Attention</i>	Atención dual
DBN	<i>Deep Belief Network</i>	Red de creencias profundas
DC	<i>Direct Current</i>	Corriente directa
DEG	<i>Diesel Engine Generator</i>	Generador con motor diésel
DER	<i>Distributed Energy Resources</i>	Recursos energéticos distribuidos
DIFPSO	<i>Particle Swarm Optimization Algorithm based on Dynamic Inertia Factor</i>	Algoritmo de optimización por enjambre de partículas basado en factor de inercia dinámico
DL	<i>Deep Learning</i>	Aprendizaje profundo
DNN	<i>Deep Neural Network</i>	Red neuronal profunda

Acrónimo	Definition	Definición
DT	<i>Decision Trees</i>	Árboles de decisión
EI	<i>Expected Improvement</i>	Mejora esperada
EIPS	<i>Expected Improvement Per Second</i>	Mejora esperada por segundo
ELM	<i>Extreme Learning Machine</i>	Máquina de aprendizaje extremo
EMD	<i>Empirical Mode Decomposition</i>	Descomposición en modos empíricos
ESS	<i>Energy Storage System</i>	Sistema de almacenamiento de energía
FCG	<i>Fuel Cell Generator</i>	Generador de celda de combustible
FESS	<i>Flywheel Energy Storage System</i>	Sistema de almacenamiento de energía por volante de inercia
FIG	<i>Fuzzy Information Granulation</i>	Granulación difusa de la información
FFNN	<i>Feedforward Neural Network</i>	Red neuronal de alimentación hacia adelante
FS	<i>Feature Selection</i>	Selección de características
GA	<i>Genetic Algorithm</i>	Algoritmo genético
GBM	<i>Gradient Boosting Machine</i>	Máquina de potenciación por gradiente
GFL	<i>Grid Following</i>	Seguimiento de red
GFM	<i>Grid Forming</i>	Formación de red
GP	<i>Gaussian Process</i>	Proceso gaussiano
GPR	<i>Gaussian Process Regression</i>	Regresión de procesos gaussianos
GRNN	<i>Generalized Regression Neural Network</i>	Red neuronal de regresión generalizada
GRU	<i>Gated Recurrent Unit</i>	Unidad recurrente con compuertas
GS	<i>Grid Search</i>	Búsqueda en cuadrícula
GWO	<i>Grey Wolf Optimization</i>	Optimización del lobo gris
HB	<i>Hyperband</i>	Hiperbanda
HPO	<i>Hyperparameters Optimization</i>	Optimización de hiperparámetros
%I	<i>Improvement Percentage</i>	Porcentaje de mejora
IA	<i>Artificial Intelligence</i>	Inteligencia artificial
IAE	<i>Integral Absolute Error</i>	Integral del error absoluto
IF	<i>Iterative Filtering</i>	Filtrado iterativo
IoT	<i>Internet of Things</i>	Internet de las cosas
IRENA	<i>International Renewable Energy Agency</i>	Agencia Internacional de Energías Renovables
ISE	<i>Integral Square Error</i>	Integral del error cuadrático

Acrónimo	Definition	Definición
ITAE	<i>Integral Time-Weighted Absolute Error</i>	Integral del error absoluto ponderado en el tiempo
KDE	<i>Kernel Density Estimation</i>	Estimación de densidad por núcleo
LCB	<i>Lower Confidence Bound</i>	Límite inferior de confianza
LCOE	<i>Levelized Cost of Energy</i>	Costo nivelado de la energía
LFC	<i>Load Frequency Control</i>	Control de frecuencia de carga
LIME	<i>Local Interpretable Model-Agnostic Explanations</i>	Explicaciones locales agnósticas de modelos interpretables
LR	<i>Linear Regression</i>	Regresión lineal
LSSVM	<i>Least Square Support Vector Machine</i>	Máquina de vectores de soporte de mínimos cuadrados
LSTM	<i>Long Short-Term Memory</i>	Memoria de largo y corto plazo
LUBE	<i>Lower Upper Bound Estimation</i>	Estimación de límites inferior y superior
MFOA	<i>Multi-fidelity Optimization Algorithm</i>	Algoritmo de optimización de multifidelidad
ML	<i>Machine Learning</i>	Aprendizaje automático
MLP	<i>Multilayer Perceptron</i>	Perceptrón multicapa
MOGOA	<i>Multi-objective Grasshopper Optimization Algorithm</i>	Algoritmo de optimización multiobjetivo de saltamontes
MPPT	<i>Maximum Power Point Tracking</i>	Seguimiento del punto de máxima potencia
MSE	<i>Mean Square Error</i>	Error cuadrático medio
NARX	<i>Nonlinear Autoregressive with Exogenous Inputs</i>	Autorregresivo no lineal con entradas exógenas
nMAE	<i>Normalized Mean Absolute Error</i>	Error absoluto medio normalizado
nRMSE	<i>Normalized Root Mean Square Error</i>	Raíz del error cuadrático medio normalizado
NWP	<i>Numerical Weather Prediction</i>	Predicción numérica del tiempo
OOB	<i>Out-of-Bag</i>	Observaciones fuera de la bolsa
PACF	<i>Partial Autocorrelation Function</i>	Función de autocorrelación parcial
PCA	<i>Principal Component Analysis</i>	Análisis de componentes principales
PCC	<i>Pearson Correlation Coefficient</i>	Coefficiente de correlación de Pearson
PCHIP	<i>Piecewise Cubic Hermite Interpolating Polynomial</i>	Polinomio interpolador cúbico de Hermite por tramos
PHES	<i>Pumped Hydro Energy Storage System</i>	Sistema de almacenamiento de energía hidráulica por bombeo
PID	<i>Proportional Integral Derivative</i>	Proporcional integral derivativo

Acrónimo	Definition	Definición
PICP	<i>Prediction Interval Coverage Probability</i>	Probabilidad de cobertura del intervalo de predicción
PINAW	<i>Prediction Interval Normalized Average Width</i>	Ancho promedio normalizado del intervalo de predicción
PINC	<i>Prediction Interval Nominal Confidence</i>	Confianza nominal del intervalo de predicción
PIs	<i>Prediction Intervals</i>	Intervalos de predicción
PLL	<i>Phase-Locked Loop</i>	Lazo de seguimiento de fase
PSE	<i>Predictive Search of Entropy</i>	Búsqueda predictiva de la entropía
PSO	<i>Particle Swarm Optimization</i>	Optimización por enjambre de partículas
PV	<i>Photovoltaic</i>	Fotovoltaico
QR	<i>Quantile Regression</i>	Regresión cuantílica
R ²	<i>Coefficient of Determination</i>	Coefficiente de determinación
RAS	<i>Remedial Action Schemes</i>	Esquemas de acción remedial
RBFN	<i>Radial Basis Function Network</i>	Red de funciones de base radial
ReLU	<i>Rectified Linear Unit</i>	Unidad lineal rectificada
RES	<i>Renewable Energy Sources</i>	Fuentes de energía renovable
RF	<i>Random Forest</i>	Bosque aleatorio
RFE	<i>Recursive Feature Elimination</i>	Eliminación recursiva de características
RNN	<i>Recurrent Neural Network</i>	Red neuronal recurrente
RMSProp	<i>Root Mean Square Propagation</i>	Propagación de la media cuadrática
RoCoF	<i>Rate of Change of Frequency</i>	Tasa de cambio de la frecuencia
RS	<i>Random Search</i>	Búsqueda aleatoria
SANN	<i>Self-Attention-Based Neural Network</i>	Red neuronal basada en autoatención
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i>	Autorregresivo integrado de media móvil estacional
SCADA	<i>Supervisory Control and Data Acquisition</i>	Control supervisado y adquisición de datos
SCESS	<i>Supercapacitor Energy Storage System</i>	Sistema de almacenamiento de energía por supercapacitor
SGDm	<i>Stochastic Gradient Descent with Momentum</i>	Descenso del gradiente estocástico con impulso
SHAP	<i>SHapley Additive exPlanations</i>	Explicaciones aditivas de Shapley
SREDNN	<i>Stochastic Recurrent Encoder Decoder Neural Network</i>	Red neuronal recurrente estocástica de tipo codificador-decodificador
ST	<i>Spatio-Temporal Analysis</i>	Análisis espacio-temporal
SVM	<i>Support Vector Machine</i>	Máquina de vectores de soporte
SVR	<i>Support Vector Regression</i>	Regresión de vectores de soporte

Acrónimo	Definition	Definición
TCN	<i>Temporal Convolutional Networks</i>	Redes convolucionales temporales
TLS	<i>T Location-Scale</i>	Distribución t de ubicación-escala
TPE	<i>Tree Parzen Estimator</i>	Estimador de árbol de Parzen
TSA	<i>Tabu Search Algorithm</i>	Algoritmo de búsqueda tabú
TSO	<i>Transmission System Operator</i>	Operador del sistema de transmisión
UFLS	<i>Under-Frequency Load Shedding</i>	Deslastre de carga por baja frecuencia
VMD	<i>Variational Mode Decomposition</i>	Descomposición en modos variacionales
VPP	<i>Virtual Power Plant</i>	Planta de potencia virtual
VSG	<i>Virtual Synchronous Generator</i>	Generador síncrono virtual
WD	<i>Wavelet Decomposition</i>	Descomposición de ondículas (<i>wavelets</i>)
XAI	<i>Explainable Artificial Intelligence</i>	Inteligencia artificial explicable

CAPÍTULO 1. INTRODUCCIÓN

1.1 Tendencias actuales de la energía renovable a nivel mundial

En las últimas décadas, la situación energética a nivel mundial ha experimentado una transformación sin precedentes, como resultado de la rápida expansión de las fuentes de energía renovable (*Renewable Energy Sources*, RES). Entre los factores que han resultado decisivos en este proceso se encuentran la necesidad urgente de reducir las emisiones de gases de efecto invernadero y mitigar los efectos del cambio climático, la reducción sostenida de los costos tecnológicos y la necesidad de diversificar las matrices energéticas [1], [2].

Un estudio presentado por la Agencia Internacional de Energías Renovables (*International Renewable Energy Agency*, IRENA), señala que, al cierre de 2024, la capacidad instalada de energía renovable a nivel mundial alcanzó los 4448 GW. Entre las tecnologías con mayor crecimiento destacan la energía solar fotovoltaica (*Photovoltaic*, PV) y la energía eólica, las cuales aportaron en conjunto el 96.6 % de todas las adiciones renovables durante ese año [3]. En la Figura 1.1 se muestra la evolución de la capacidad eléctrica instalada de las principales RES durante el período comprendido entre 2015 y 2024.




Figura 1.1. Evolución de la capacidad eléctrica instalada de las principales RES a nivel mundial desde 2015 hasta 2024.

Al cierre de 2024, la capacidad instalada de energía solar PV a nivel mundial alcanzó los 1858 GW. Durante ese año se incorporaron 452 GW de nueva capacidad, lo que representa el 77.3 % de las adiciones totales de energía renovable en dicho período. En el caso de la energía eólica, considerando tanto instalaciones terrestres como marinas, la capacidad instalada global ascendió a 1133 GW. El incremento registrado para esta fuente durante 2024 fue de 113 GW, equivalente al 19.3 % de las adiciones totales de energía renovable en ese año [3].

El notable crecimiento registrado en ambas tecnologías ha estado favorecido, en gran medida, por la reducción del costo nivelado de la energía (*Levelized Cost of Energy*, LCOE). De este modo, las fuentes renovables se han consolidado como alternativas económicamente competitivas frente a las fuentes de generación convencionales [2]. De hecho, el LCOE de los proyectos solares a gran escala se redujo de 0.417 USD/kWh en 2010 a 0.043 USD/kWh en 2024, lo que permitió que la energía solar PV fuera un 41 % más barata que las alternativas basadas en combustibles fósiles. En el caso de los proyectos eólicos terrestres, el LCOE descendió de 0.089 USD/kWh en 2010 a 0.034 USD/kWh en 2024, mientras que para los proyectos eólicos marinos este indicador disminuyó de 0.208 USD/kWh a 0.079 USD/kWh en el mismo período [3]. Además, es importante señalar que este proceso también ha sido impulsado por avances tecnológicos relevantes, entre los que se destacan las mejoras en los procesos de fabricación de módulos PV y la construcción de turbinas eólicas más eficientes [3], [4].

Esta transformación de la matriz energética no ocurre solamente en países con altos niveles de desarrollo, sino también en economías emergentes, donde la adopción de RES contribuye a reducir la dependencia de los combustibles fósiles y a fortalecer la seguridad energética [1]. Actualmente, más del 80 % de la nueva capacidad instalada de RES se concentra en China, Estados Unidos y la Unión Europea. No obstante, otras regiones como América Latina, Asia-Pacífico y África han comenzado a incrementar sus tasas de crecimiento, motivadas en gran medida por marcos regulatorios favorables y políticas de transición energética flexibles [3]. Según las proyecciones basadas en el escenario de 1.5 °C propuesto por la IRENA, la capacidad global de energía renovable podría triplicarse para el año 2030 y aumentar hasta nueve veces para el año 2050 [5]. Este escenario implica la necesidad de realizar importantes inversiones en tecnologías renovables y acelerar la transición energética hacia un futuro más sostenible.

1.2 Justificación y motivación de la investigación

La incorporación acelerada de RES variables, principalmente la energía eólica y la solar PV, constituye una de las transformaciones más relevantes del sector eléctrico contemporáneo. Aunque este proceso representa un paso de avance fundamental para lograr la independencia energética y la protección del medio ambiente, también introduce importantes desafíos técnicos y operativos que requieren atención especializada [3], [6]. El comportamiento de estas fuentes de energía se relaciona estrechamente con varios factores meteorológicos. También depende de la ubicación geográfica de cada instalación y de las variaciones estacionales que ocurren durante el año. La interacción de estos factores hace que la energía generada exhiba un comportamiento variable, intermitente y estocástico, lo que dificulta su integración a gran escala en las redes eléctricas actuales [4], [7].

Entre los problemas técnicos más relevantes asociados con la integración de energía eólica y solar PV se encuentra la estabilidad de frecuencia. En este caso, la alta variabilidad de estos recursos energéticos provoca mayores desequilibrios entre la oferta y la demanda de energía y, en consecuencia, desviaciones de frecuencia más pronunciadas. Este fenómeno se vuelve más crítico en redes eléctricas con alta penetración de RES, donde la sustitución progresiva de los generadores síncronos de gran inercia por sistemas basados en convertidores electrónicos (típicos de los sistemas PV y eólicos), reduce la capacidad natural del sistema

para amortiguar perturbaciones [4], [8]. También, pueden presentarse problemas relacionados con el voltaje, tales como bajo o sobre voltaje, fluctuaciones y desbalances de voltaje, los cuales se manifiestan con mayor intensidad a nivel de distribución, debido a la escasa presencia de dispositivos reguladores en esta parte del sistema. Además, pueden surgir altas tasas de rampa, dificultades en la planificación y el despacho económico de los generadores, así como incrementos en los niveles de reserva, los costos de operación y los requisitos de flexibilidad, entre otros aspectos. Algunos de estos problemas resultan aún más críticos en redes débiles, microrredes o sistemas aislados, donde generalmente el porcentaje de penetración de RES es elevado y la capacidad de compensación es limitada [9], [10].

Ante este escenario, los operadores del sistema eléctrico destacan la necesidad de reducir, en la medida de lo posible, el nivel de incertidumbre asociado a estas fuentes de energía para facilitar su integración en la red. En este contexto, el desarrollo de herramientas de pronóstico más avanzadas y eficientes resulta fundamental para enfrentar los problemas mencionados [6]. Un pronóstico preciso de la energía solar PV y eólica, en diferentes escalas temporales, puede impactar de manera positiva en la planificación del sistema, en la gestión adecuada de los niveles de reserva y en el despacho económico de los generadores. También resulta de gran utilidad desde el punto de vista operativo para garantizar la estabilidad de voltaje y frecuencia, así como para la regulación y el control de eventos de rampa, entre otros aspectos. En presencia de sistemas de almacenamiento de energía en baterías (*Battery Energy Storage System*, BESS), el pronóstico de las RES contribuye a una gestión más eficiente de la operación de dichos sistemas y a la mitigación de las fluctuaciones en la potencia de salida de las fuentes renovables [6], [11]. No obstante, a pesar de su gran importancia, la obtención de pronósticos precisos continúa siendo un desafío de elevada complejidad.

El desarrollo y la evolución de las técnicas de pronóstico han transitado desde los métodos físicos basados en predicciones meteorológicas numéricas (*Numerical Weather Prediction*, NWP), pasando por enfoques estadísticos, hasta estrategias modernas basadas en aprendizaje automático (*Machine Learning*, ML), aprendizaje profundo (*Deep Learning*, DL) y enfoques híbridos. Aunque todos estos métodos han sido utilizados en la literatura en mayor o menor medida, los enfoques de ML, DL e híbridos han mostrado un potencial significativo y una creciente adopción en los estudios recientes. De hecho, destacan por su buen desempeño, flexibilidad y capacidad de adaptación en el pronóstico de energías renovables, superando en muchos casos la precisión de los métodos físicos y estadísticos tradicionales [6], [12]. Dentro de este campo, la aplicación de redes neuronales profundas con memoria de largo y corto plazo (*Long Short-Term Memory*, LSTM) y memoria de largo y corto plazo bidireccional (*Bidirectional Long Short-Term Memory*, BiLSTM) ha mostrado resultados prometedores. Esto se debe principalmente a la capacidad de estos modelos para extraer patrones de comportamiento complejos y dependencias a largo plazo en series temporales y secuencias de datos no lineales [11], [13], [14]. Por otro lado, la utilización de enfoques híbridos, integrados por otros modelos más simples, ha ganado popularidad debido a sus notables ventajas en términos de precisión y robustez [4], [15]. Sin embargo, en algunos casos, estos enfoques pueden verse limitados por su elevada complejidad computacional y estructural. En este sentido, resulta necesario lograr un equilibrio adecuado entre precisión y complejidad, con el objetivo de desarrollar modelos de predicción de alta calidad que sean, al mismo tiempo, viables para aplicaciones prácticas.

Recientemente, los investigadores también han vinculado los métodos de ML y DL con diversos algoritmos de optimización de hiperparámetros (*Hyperparameters Optimization*, HPO), con el fin de lograr un ajuste más preciso de los modelos y mejorar la calidad de sus predicciones. Entre los algoritmos que han mostrado un desempeño destacado en esta tarea se encuentran la optimización Bayesiana (*Bayesian Optimization*, BO) y diversos algoritmos de optimización metaheurísticos [14], [16]. A pesar de estos avances, aún existen estudios que realizan este proceso mediante técnicas de ensayo y error o a través de enfoques de optimización menos eficientes, como la búsqueda en cuadrícula (*Grid Search*, GS) [17]. Por otro lado, aunque algunos trabajos han incorporado algoritmos de preprocesamiento de datos en sus estrategias predictivas, es necesario profundizar en el desarrollo de enfoques más robustos y eficientes. De este modo se puede mejorar la calidad de los datos disponibles y se incrementa la precisión de los modelos [15], [18]. De manera similar, la aplicación de técnicas de selección de características (*Feature Selection*, FS) continúa siendo un área con gran potencial de mejora para incrementar la calidad de los pronósticos y reducir la complejidad de los modelos [19], [20].

Otro aspecto de gran relevancia se relaciona con la adaptabilidad y la validación de los modelos predictivos en condiciones de operación atípicas, tales como el fallo temporal de sensores de medición o la presencia de ruido blanco en los datos. En ambos escenarios, el estudio delimita su alcance a las variables climáticas y a la potencia activa generada, factores esenciales en aplicaciones de predicción en tiempo real, donde la pérdida de información o la degradación de la calidad de los datos puede generar desafíos operativos significativos, a menos que el modelo sea capaz de adaptarse de forma eficaz a dichas condiciones. Sin embargo, a pesar de su gran importancia, este tema permanece en gran medida inexplorado en la literatura existente.

De igual forma, a pesar del uso extendido de los métodos basados en ML, DL e híbridos, se han realizado pocos esfuerzos orientados a mejorar la interpretabilidad y la comprensión de su funcionamiento mediante técnicas de inteligencia artificial explicable (*Explainable Artificial Intelligence*, XAI). Este aspecto también resulta fundamental para aplicaciones de pronóstico en tiempo real, donde cualquier anomalía en el proceso predictivo debe ser debidamente analizada y justificada [21]. Por otro lado, la mayoría de las investigaciones existentes evalúan los modelos de pronóstico con datos procedentes de una única instalación PV o eólica. Esto limita la validación de su rendimiento en otros conjuntos de datos con diferentes características y bajo diversas condiciones climáticas [22].

Adicionalmente, aunque muchos estudios se han enfocado en el desarrollo de métodos avanzados de pronóstico determinístico, solo un número limitado ha abordado de manera explícita las cuestiones asociadas al pronóstico probabilístico. Actualmente, los operadores de los sistemas eléctricos requieren predicciones que describan no solo el valor puntual esperado de la energía solar PV o eólica, sino también el rango de posibles escenarios. Algunas técnicas como la regresión cuantílica (*Quantile Regression*, QR), la estimación de densidad por núcleo (*Kernel Density Estimation*, KDE) y el remuestreo *bootstrap* permiten cuantificar la incertidumbre asociada a los pronósticos determinísticos de las RES. Además, contribuyen a mejorar la gestión de los riesgos operativos en el sistema eléctrico. Estas cuestiones resultan especialmente relevantes en aplicaciones de control, donde los márgenes de seguridad, la asignación de reservas y la

estabilidad del sistema dependen de una representación probabilística adecuada de la generación renovable [11], [23], [24].

Por último, es importante destacar que, si bien la mayoría de los trabajos publicados en este campo de investigación se han centrado en la obtención de pronósticos y en la mejora de su precisión, aún existen otros aspectos que requieren una evaluación más profunda [25], [26]. En particular, resulta muy importante analizar las cuestiones relacionadas con el posible impacto de los pronósticos de las RES en la operación y el control del sistema eléctrico. Dicho impacto se conceptualiza en esta investigación en términos del control y la seguridad del sistema eléctrico, evaluando específicamente su aporte a la regulación secundaria de frecuencia.

Con el objetivo de abordar los problemas mencionados, esta tesis propone nuevas contribuciones mediante la integración de un marco metodológico orientado al pronóstico avanzado de energía solar PV y eólica a muy corto plazo, así como al análisis de su impacto en el control de frecuencia. En particular, se desarrolla un enfoque híbrido que combina un preprocesamiento robusto de datos en múltiples etapas, una red neuronal profunda de tipo BiLSTM y un esquema de optimización automática de hiperparámetros basado en BO. Además, se incorpora el método de remuestreo *bootstrap* para la generación de predicciones probabilísticas. Aunque estos componentes han sido explorados de manera individual en la literatura, su integración en un marco metodológico coherente constituye una contribución original. Este enfoque permite mejorar la precisión y la robustez de los pronósticos en una amplia variedad de escenarios reales. Asimismo, el marco metodológico desarrollado integra mecanismos de resiliencia para operar con eficacia ante la degradación de la calidad de la información. Esto permite validar su desempeño bajo los escenarios atípicos identificados con anterioridad, reforzando su utilidad práctica para aplicaciones de pronóstico en tiempo real. En este contexto, también se integra una técnica de XAI basada en la eliminación recursiva de características (*Recursive Feature Elimination*, RFE). Esta técnica permite conocer la contribución de las variables de entrada en el modelo de predicción y evaluar el impacto causado por su pérdida o por su contaminación con ruido. Finalmente, la investigación no solo contribuye a mejorar la precisión de los pronósticos, sino que utiliza el control de frecuencia como una aplicación directa y un entorno de validación experimental para evaluar el impacto operativo de dicha precisión. En este caso, se utiliza como sistema de prueba una microrred aislada con múltiples recursos energéticos distribuidos (*Distributed Energy Resources*, DER). No obstante, es válido señalar que la metodología propuesta es aplicable en cualquier sistema eléctrico que disponga de los datos necesarios para su implementación.

1.3 Hipótesis

El desarrollo de un modelo de pronóstico avanzado basado en técnicas de aprendizaje profundo, combinado con un algoritmo eficiente de optimización de hiperparámetros, un preprocesamiento robusto de los datos y un enfoque de pronóstico probabilístico, permitirá incrementar la precisión de los pronósticos de energía solar PV y eólica, en comparación con los modelos tradicionales documentados en la literatura.

Bajo esta premisa, se plantea que la mejora en la precisión de estos pronósticos permitirá reducir las desviaciones de frecuencia y optimizar el desempeño dinámico en redes eléctricas con una alta penetración de RES.

1.4 Objetivos

Objetivo general:

Desarrollar un modelo híbrido avanzado para el pronóstico de energía solar PV y eólica mediante la integración de técnicas de aprendizaje profundo, optimización de hiperparámetros, un esquema robusto de preprocesamiento de datos y un enfoque de pronóstico probabilístico, con el propósito de evaluar su impacto en el control de frecuencia y en la operación en tiempo real de redes eléctricas con alta penetración de energías renovables.

Objetivos específicos:

- Analizar las bases teóricas del pronóstico de energía solar PV y eólica y seleccionar modelos basados en DL que resulten adecuados para su predicción.
- Implementar algoritmos eficientes de preprocesamiento de datos y optimización de hiperparámetros orientados a mejorar el desempeño del modelo propuesto.
- Desarrollar un enfoque de pronóstico probabilístico basado en el método de remuestreo *bootstrap* para generar intervalos de predicción confiables.
- Validar el desempeño y la capacidad de adaptación del modelo propuesto bajo escenarios de operación estándar y atípicos, incluyendo el fallo temporal de sensores de medición y la presencia de ruido blanco en los datos.
- Evaluar el impacto de la precisión de los pronósticos en la estabilidad del sistema mediante su aplicación al control secundario de frecuencia, utilizando una microrred con alta penetración de energías renovables como caso de estudio representativo.

1.5 Alcances y limitaciones

Alcances:

- Se implementa un esquema robusto de preprocesamiento de datos en múltiples etapas, que incluye la detección y corrección de valores atípicos y ausentes, el filtrado de anomalías y la selección de características, entre otros procedimientos.
- Se desarrolla un enfoque híbrido avanzado para el pronóstico determinístico y probabilístico de generación eólica y solar PV a muy corto plazo, integrando un modelo de red neuronal profunda de tipo BiLSTM, un esquema de optimización Bayesiana de hiperparámetros y el método de remuestreo *bootstrap*.
- Se valida la metodología propuesta utilizando datos reales, incorporando técnicas de XAI y escenarios atípicos que simulan fallos de sensores de medición y perturbaciones por ruido blanco, lo que permite demostrar su resiliencia y flexibilidad bajo diferentes condiciones operativas asociadas a la operación en tiempo real.

- Se compara exhaustivamente el modelo propuesto con diversos modelos de referencia y con estudios reportados en la literatura reciente, empleando métricas de evaluación determinísticas y probabilísticas, lo que permite analizar con precisión las mejoras alcanzadas.
- Se propone un marco de pronóstico coherente, replicable y adaptable, que puede extenderse a otros conjuntos de datos, horizontes de pronóstico o condiciones de operación, proporcionando una herramienta con potencial de aplicación en los sistemas eléctricos modernos.
- Se integran los pronósticos obtenidos en un esquema de control de frecuencia secundario de naturaleza proactiva, evaluando de forma directa el impacto de la precisión del pronóstico en la estabilidad y la operación de una microrred.

Limitaciones:

- A pesar de que se propone un esquema robusto de preprocesamiento de datos, la efectividad de la metodología de pronóstico desarrollada continúa dependiendo de la disponibilidad, calidad y representatividad de los datos históricos utilizados.
- El estudio se centra en un horizonte de pronóstico a muy corto plazo, ampliamente utilizado en aplicaciones de control en sistemas eléctricos. Sin embargo, no se abordan de manera directa los horizontes de corto, mediano o largo plazo.
- Aunque en el estudio se utilizan datos de energía solar PV y eólica procedentes de instalaciones con diferentes características y ubicaciones geográficas, la generalización de los resultados a otros contextos climáticos o geográficos podría requerir ajustes adicionales y nuevos procesos de entrenamiento del modelo.

1.6 Estructura de la tesis

La tesis se compone de un total de ocho capítulos, cuya estructura se describe a continuación. En el Capítulo 1 se presenta el contexto de la investigación, así como la motivación, la hipótesis planteada, los objetivos, los alcances y las limitaciones del estudio. En el Capítulo 2 se describen detalladamente las principales características de las fuentes de energía solar y eólica y se analizan los fundamentos del pronóstico y las técnicas más utilizadas en la literatura reciente.

En el Capítulo 3 se abordan los aspectos metodológicos del esquema de pronóstico propuesto, incluyendo el preprocesamiento de datos, la formulación de las redes neuronales LSTM y BiLSTM, la optimización de hiperparámetros mediante BO, la obtención de pronósticos probabilísticos y los algoritmos desarrollados para la obtención de pronósticos bajo condiciones de operación atípicas. En el Capítulo 4 se analizan los fundamentos y los principales aspectos del control de frecuencia en redes eléctricas, con especial énfasis en escenarios de alta penetración de recursos energéticos renovables y en microrredes.

En los Capítulos 5 y 6 se presentan y discuten los principales resultados obtenidos en el pronóstico determinístico y probabilístico de energía solar PV y eólica, respectivamente. En el Capítulo 7 se evalúa el impacto de los pronósticos realizados en el desempeño del control de frecuencia secundario, utilizando como caso de estudio una microrred aislada con múltiples DER. Por último, el Capítulo 8 sintetiza las conclusiones del trabajo, las principales contribuciones y las recomendaciones para trabajos futuros.

CAPÍTULO 2. PRONÓSTICOS DE ENERGÍA SOLAR PV Y EÓLICA

2.1 Introducción

Los pronósticos precisos de energía solar PV y eólica resultan esenciales para garantizar una integración eficiente de estas tecnologías en los sistemas eléctricos actuales. En este capítulo se abordan diversos aspectos generales relacionados con el pronóstico de estas fuentes de energía. En primer lugar, se presentan los modelos matemáticos representativos de ambas tecnologías y se analizan las variables más relevantes que influyen en su comportamiento. Posteriormente, se exponen las diferentes clasificaciones de los pronósticos a partir de varios criterios ampliamente utilizados en la literatura y se analiza su importancia para la planificación y operación del sistema eléctrico. Por último, se revisa el estado actual del tema de estudio y se identifican las principales tendencias, contribuciones y limitaciones en este campo de investigación.

2.2 Energía solar PV

La energía solar se encuentra entre las RES más utilizadas en la actualidad. La radiación solar suministra continuamente a la Tierra una potencia significativa, cuya magnitud se estima en aproximadamente en 1.8×10^5 TW [27]. Existen dos clasificaciones fundamentales asociadas a este tipo de energía: la energía solar térmica y la energía solar PV. Esta última utiliza los fotones provenientes de la luz del sol para excitar electrones libres en dispositivos semiconductores integrados y producir electricidad. Esta tecnología es altamente versátil y abarca desde pequeños sistemas PV a escala residencial o comercial, hasta grandes plantas PV conectadas a la red eléctrica. Entre las principales ventajas de la energía solar PV se pueden mencionar las siguientes: es una fuente de energía limpia y segura; se encuentra disponible prácticamente en cualquier lugar del planeta; resulta fácil de instalar y operar; posee un alto nivel de adaptabilidad y una vida útil prolongada. Además, los costos de esta tecnología se han reducido significativamente en los últimos años. Por estas razones, muchos países han mostrado un creciente interés en su implementación al considerarla una solución viable y sostenible para garantizar la seguridad energética de la sociedad humana [28], [29].

2.2.1 Modelo matemático de un sistema PV

Aunque la energía solar PV posee grandes ventajas y un elevado potencial, su integración en los sistemas eléctricos representa un gran desafío debido a su naturaleza dinámica e intermitente. Esta fuente de energía es afectada en gran medida por variables climáticas como la irradiancia solar, la temperatura ambiente, la nubosidad, el viento, la lluvia y la humedad relativa, entre otros factores. También se ve afectada por la alternancia entre el día y la noche, por la ubicación geográfica y por las variaciones estacionales que ocurren durante el año. Adicionalmente, parámetros como la temperatura de operación de los paneles, la acumulación de polvo o suciedad sobre su superficie, el nivel de degradación de los materiales y la presencia de sombras parciales o totales, constituyen elementos críticos que condicionan el comportamiento y la eficiencia de los sistemas PV [27], [30].

El modelo matemático que describe el funcionamiento de un sistema PV se representa mediante la ecuación (2.1) [10]:

$$P_{PV} = P_{PV,nom} \cdot \frac{G}{1000} \cdot (1 + \delta_p \cdot (T_p - 25)) \cdot \eta \cdot f_{PV} \quad (2.1)$$

donde P_{PV} y $P_{PV,nom}$ representan, respectivamente, la potencia generada y la potencia nominal de la instalación PV, expresadas en W; G es la irradiancia solar en W/m^2 ; δ_p representa el coeficiente de temperatura para máxima potencia, expresado en $\%/^{\circ}C$; η denota la eficiencia global del sistema (incluye la eficiencia del inversor, del cableado y de otros componentes asociados); T_p es la temperatura de los paneles PV en $^{\circ}C$; y f_{PV} es un factor de corrección que considera los efectos de degradación de los módulos, así como las pérdidas por sombreado y suciedad.

2.2.2 Análisis de las principales variables que influyen en el desempeño de los sistemas PV

A continuación, se presenta una breve descripción de un grupo de variables (meteorológicas, internas del sistema y otras de diversa índole) relacionadas con la operación de los sistemas PV.

- Irradiancia solar

La irradiancia solar se considera la variable de entrada más determinante en los sistemas PV y presenta el mayor nivel de correlación con respecto a la potencia generada [27]. En la Figura 2.1 se ilustran las curvas características de corriente-voltaje (I-V) y potencia-voltaje (P-V) de un módulo PV para diferentes niveles de irradiancia solar. En la Figura 2.1a se observa que, al aumentar el nivel de irradiancia se incrementa la corriente de cortocircuito y en menor medida el voltaje de circuito abierto. Por su parte, la Figura 2.1b evidencia que un aumento en la irradiancia solar conlleva a un incremento proporcional en la potencia de salida del sistema PV.




Figura 2.1. Curvas características de un sistema PV para diferentes niveles de irradiancia solar: (a) Curva de corriente-voltaje (I-V) y (b) Curva de potencia-voltaje (P-V).

Es importante mencionar que el comportamiento de la irradiancia solar se relaciona estrechamente con las condiciones climáticas locales, la hora del día, la estación del año y la ubicación geográfica [27], [30]. Además, la potencia PV experimenta un comportamiento muy similar al de la irradiancia solar como se

muestra en la Figura 2.2. Se observa que ambas variables presentan un valor nulo durante la noche, incrementan su valor al amanecer, alcanzan su valor máximo en torno al cenit solar, cercano al mediodía, y posteriormente comienzan a disminuir hasta retornar nuevamente a un valor nulo al finalizar la tarde.




Figura 2.2. Comportamiento de la irradiancia solar y la potencia PV en diferentes condiciones atmosféricas: (a) Día soleado y (b) Día nublado. *(Los datos de potencia corresponden a una instalación PV con potencia nominal de 2.97 kW).

- Temperatura ambiente

La temperatura ambiente también constituye una variable meteorológica de importancia para el funcionamiento de los sistemas PV. Un aumento de la temperatura ambiente conlleva a un incremento de la temperatura de los paneles y a una disminución de su eficiencia [10].

- Nubosidad

La nubosidad incide de manera directa en la cantidad de radiación solar que llega a la superficie terrestre. Varios procesos vinculados con la formación, el movimiento, la deformación y la disipación de las nubes conllevan a fluctuaciones frecuentes y cambios abruptos de la irradiancia solar y la producción de energía [27], [30]. Según lo reportado en [27], la generación eléctrica en dos sistemas PV con potencias nominales de 1.6 MW y 2 kW se redujo a la mitad en un lapso de 9 s y 3 s, respectivamente, debido al efecto de la nubosidad.

- Viento

El viento que incide sobre los paneles solares contribuye directamente a la disipación de calor y a la reducción de su temperatura. Por lo tanto, un incremento en los valores de velocidad del viento favorece la eficiencia de los paneles y, por ende, la generación de energía. Sin embargo, cuando la velocidad del viento es alta puede causar efectos negativos asociados principalmente a esfuerzos mecánicos y vibraciones que pueden dañar la integridad estructural de los sistemas PV [31].

- Lluvia y humedad relativa

La lluvia tiene un impacto significativo en el rendimiento de los sistemas PV debido a su contribución al enfriamiento de los paneles y a la eliminación del polvo en su superficie. El efecto de limpieza generado por las precipitaciones es más notable cuando el ángulo de inclinación de los paneles supera los 10°. En términos generales, las lluvias locales incrementan la humedad relativa debido al proceso de evaporación, lo que puede provocar fenómenos de corrosión en las celdas y, en consecuencia, una disminución de su vida

útil [31]. Adicionalmente, el aumento de la humedad relativa intensifica los procesos de reflexión, refracción y absorción de la luz solar, lo que reduce la irradiancia solar que incide sobre la superficie de los módulos [22], [32]. Por lo tanto, la generación eléctrica bajo estas condiciones disminuye. De hecho, un estudio reportado en [31] indica que un incremento de la humedad relativa del 60 % al 95 % puede ocasionar una reducción de hasta el 50 % en la potencia de salida de los sistemas PV.

- Temperatura de los paneles

Este parámetro influye de manera significativa en la eficiencia del sistema PV y en la producción de energía. La temperatura de los paneles depende de múltiples factores, entre ellos la irradiancia solar, la temperatura ambiente, la velocidad y la dirección del viento local, así como de algunas características propias de los paneles solares, tales como la transmitancia de la cubierta y el nivel de absorción de la radiación solar [33]. En la Figura 2.3 se representa el comportamiento del voltaje de circuito abierto y de la potencia de salida para diferentes valores de irradiancia solar y de temperatura de un panel PV. Se observa que un aumento en la temperatura del panel produce una disminución del voltaje de circuito abierto y de la potencia de salida. Un estudio reportado en [34] concluye que, para módulos PV de silicio cristalino, un incremento de 1°C en la temperatura del panel conlleva a una reducción de la eficiencia de 0.5 % aproximadamente. Considerando los aspectos anteriores, la temperatura de un panel PV se puede estimar mediante la ecuación (2.2) [33]:

$$T_p = T_a + f_c \cdot \left(\frac{G}{800} \right) \cdot (T_{NOCT} - 20) \quad (2.2)$$

donde T_a representa la temperatura ambiente, expresada en °C; f_c es un factor de corrección que caracteriza el coeficiente de transferencia de calor en función de las condiciones ambientales locales (irradiancia solar, temperatura ambiente y velocidad del viento); y T_{NOCT} representa la temperatura nominal de operación de la celda PV, expresada en °C.




Figura 2.3. Curva característica de potencia-voltaje (P-V) para distintos niveles de irradiancia solar y de temperatura del panel PV.

- Degradación de los paneles

Los paneles solares son dispositivos que poseen una vida útil prolongada que en muchos casos puede alcanzar los 25 años [32]. No obstante, durante este período de tiempo sus propiedades físicas pueden degradarse debido a diversos factores, entre los que se incluyen la penetración de humedad, la degradación de los materiales semiconductores, de las interconexiones eléctricas y de los materiales de encapsulado, entre otros. De acuerdo con los fabricantes, un módulo PV se considera degradado cuando su potencia resulta inferior al 80 % de su potencia inicial de diseño [34]. Además, varios estudios plantean que una tasa de degradación anual de 0.5 % resulta aceptable en la mayoría de los casos, aunque este valor puede variar según las condiciones climáticas y geográficas de cada región [32], [34].

- Polvo y suciedad

La acumulación de polvo y suciedad en la superficie de los paneles solares puede obstruir parcialmente la radiación solar incidente y provocar una reducción de la eficiencia del sistema. Este efecto varía significativamente en función de factores como la ubicación geográfica, las condiciones climáticas, el ángulo de inclinación de los paneles y la frecuencia de la lluvia en el sitio [30], [31]. De acuerdo con [31], a partir de un estudio realizado en la Ciudad de México se demuestra que después de 60 días sin lluvia, la eficiencia de los paneles PV se redujo aproximadamente en un 15 % debido al efecto de la deposición de polvo en la superficie. Aunque en ocasiones la superficie de los paneles se limpia por el efecto de la lluvia, ciertos residuos pueden permanecer adheridos, especialmente en el borde inferior de los paneles con poca inclinación. El fenómeno de la acumulación de polvo y suciedad es más frecuente en regiones con climas áridos y semiáridos. No obstante, en zonas de latitudes altas con climas fríos, la presencia de nieve y hielo también debe considerarse, ya que puede causar obstrucciones parciales o totales de la radiación solar, afectando negativamente la generación de energía. Por otro lado, cuando la superficie de los paneles se encuentra limpia, pero el terreno circundante está cubierto de nieve, la irradiancia efectiva puede incrementarse debido al efecto albedo, es decir, la radiación solar reflejada por la nieve [30].

- Sombras en los paneles

El fenómeno del sombreado que afecta a los paneles solares puede originarse por múltiples causas, tales como la nubosidad, la acumulación de suciedad, la presencia de árboles, edificaciones cercanas o estructuras de techo, entre otras. Cuando una o varias celdas PV se ven parcialmente sombreadas, se produce una disminución significativa en la corriente, el voltaje y, en consecuencia, en la potencia generada por el sistema. Este efecto se ve acentuado por las conexiones en serie entre las celdas solares [31], [34]. En general, las pérdidas por sombreado se relacionan con la cantidad de celdas sombreadas, el tipo de conexión eléctrica y el material de fabricación de las celdas [32]. Además, el sombreado de los paneles también puede provocar la aparición de puntos calientes, lo cual compromete la integridad estructural del módulo. Una solución técnica ampliamente utilizada para enfrentar este problema consiste en utilizar diodos de derivación (*bypass diodes*). Estos dispositivos se conectan en paralelo a un grupo específico de celdas conectadas en serie, para crear una ruta alternativa para la circulación de la corriente [31].

- Ubicación geográfica de la instalación

La ubicación geográfica de la instalación PV puede incidir en el comportamiento de las variables meteorológicas y en su relación con la potencia generada [30]. En la Figura 2.4 se ilustran los niveles de correlación existentes entre algunas variables meteorológicas y la potencia PV para diferentes ubicaciones geográficas. Se observa que la irradiancia solar es la variable más correlacionada con la potencia PV en todas las ubicaciones analizadas. Para las variables temperatura ambiente y humedad relativa se presentan menores niveles de magnitud de correlación en comparación con el caso anterior y una mayor dependencia de la ubicación geográfica. Por último, se observa que el nivel de correlación de la variable velocidad del viento es severamente afectado por la ubicación geográfica de la instalación PV, reflejando una dependencia notable del contexto local [30].



Figura 2.4. Correlación entre las variables meteorológicas y la potencia PV generada en distintas ubicaciones geográficas [30].

*(Aunque la correlación entre humedad relativa y potencia PV es típicamente negativa, en esta figura se representa su magnitud absoluta para facilitar la comparación directa con las demás variables meteorológicas).

2.3 Energía eólica

La energía solar provoca un calentamiento diferencial de la superficie terrestre, dando lugar a la aparición del viento. Los sistemas de generación eólica convierten la energía cinética del viento en energía eléctrica [35]. La disponibilidad de esta fuente de energía a nivel mundial es muy amplia y su potencial anual se estima en 5.3×10^7 GW [36]. La energía eólica se considera una fuente de energía limpia, segura y ambientalmente sostenible. Además, posee un alto nivel de flexibilidad, ya que puede instalarse en tierra firme o en entornos marinos. A diferencia de la energía solar, la generación eólica no está directamente ligada al ciclo de los días y las noches, lo que posibilita una mayor continuidad en la generación de energía. Por otra parte, esta tecnología se ha vuelto muy madura y económica en los últimos años, debido principalmente a su utilización a gran escala y a los avances tecnológicos alcanzados en este campo de investigación [35], [37].

2.3.1 Modelo matemático de un sistema eólico

La energía eólica exhibe un comportamiento altamente variable e intermitente, determinado por varios factores climáticos como la velocidad y la dirección del viento, la densidad del aire, la temperatura, la presión atmosférica y la humedad relativa, entre otros [14]. También se relaciona con otros factores propios de la instalación como la altura de la torre, el coeficiente de potencia, el área de barrido y el ángulo de paso de las palas. Además, elementos como la topografía del terreno y la presencia de obstáculos cercanos pueden generar turbulencias que afectan el rendimiento del sistema [38]. Todos estos factores influyen, en mayor o menor grado, en el rendimiento de los sistemas eólicos y en su potencia eléctrica de salida.

El comportamiento de un sistema eólico puede modelarse mediante la ecuación (2.3) [37]:

$$P_w = \frac{1}{2} \cdot C_p \cdot \eta \cdot \rho \cdot A \cdot v^3 \quad (2.3)$$

donde P_w es la potencia eólica de salida, expresada en W; C_p es el coeficiente de potencia; η representa la eficiencia del sistema (incluye la eficiencia de la parte mecánica y del generador eléctrico); ρ corresponde a la densidad del aire, expresada en kg/m³; A es el área barrida por las palas del aerogenerador, expresada en m²; y v es la velocidad del viento, expresada en m/s.

2.3.2 Análisis de las principales variables que influyen en el desempeño de los sistemas eólicos

A continuación, se presenta una breve descripción de un grupo de variables (meteorológicas, internas del sistema y otras de diversa índole) relacionadas con la operación de los sistemas eólicos.

- Velocidad del viento

La velocidad del viento se considera la variable de mayor importancia para la generación de energía eólica debido a su relación aproximadamente cúbica con la potencia de salida del aerogenerador [38]. El funcionamiento de un aerogenerador se puede representar de manera general mediante una curva característica de potencia en función de la velocidad del viento, como se muestra en la Figura 2.5. Dicha curva describe el comportamiento típico de un aerogenerador de eje horizontal, comúnmente de tres palas y establece la relación entre la velocidad del viento incidente y la potencia eléctrica generada. Es importante destacar que los parámetros operativos (velocidades de corte y potencia nominal) pueden variar según el diseño y las especificaciones técnicas de cada fabricante.




Figura 2.5. Curva característica de la potencia de salida de un aerogenerador en función de la velocidad del viento [37].

La velocidad del viento requerida para activar un aerogenerador (o velocidad de corte de entrada) se encuentra típicamente en el rango de 3 m/s a 5 m/s; por debajo de ese valor la potencia generada es nula. Para velocidades comprendidas entre la velocidad de corte de entrada y la velocidad nominal, se observa una relación cúbica entre la velocidad del viento y la potencia de salida. En este rango, un pequeño cambio en la velocidad del viento conduce a grandes cambios en la potencia de salida de la máquina. Cuando la velocidad del viento se encuentra entre la velocidad nominal y la velocidad de corte de salida, se obtiene la máxima potencia de salida del aerogenerador. La operación en esta zona se regula mediante un control de potencia aerodinámico. Por último, si la velocidad del viento supera la velocidad de corte de salida (típicamente de 25 m/s), se produce la desconexión del equipo para garantizar su seguridad [37], [38].

Para comprender mejor la relación existente entre la velocidad del viento y la potencia eólica generada, es conveniente representar el comportamiento de ambas variables, como se muestra en la Figura 2.6. En este caso se observa que la potencia eólica tiene un comportamiento muy similar al de la velocidad del viento en cada período de tiempo y para cada condición de operación analizada.




Figura 2.6. Comportamiento de la velocidad del viento y la potencia eólica generada en diferentes tipos de días: (a) Día con mucho viento y (b) Día con poco viento. *(Los datos de potencia eólica corresponden a un aerogenerador con potencia nominal de 2350 kW).

- Dirección del viento

Cuando existe una diferencia angular entre la dirección del viento y el eje del rotor del aerogenerador, la potencia de salida se reduce. Los aerogeneradores de eje horizontal están equipados con un accionamiento de guiñada que se encarga de alinear automáticamente el rotor con la dirección predominante del viento. Sin embargo, este sistema presenta un retardo en su tiempo de respuesta, lo que puede afectar en cierta medida el rendimiento y la potencia de salida del aerogenerador [37].

- Densidad del aire

Tal como se indica en la ecuación (2.3), la potencia de salida de un aerogenerador es directamente proporcional a la densidad del aire. Esta variable se puede determinar mediante la ecuación (2.4) [37]:

$$\rho = 3.485 \cdot \frac{p}{T} \quad (2.4)$$

donde p representa la presión atmosférica, expresada en kPa y T representa la temperatura absoluta, expresada en K. Esta expresión constituye una aproximación comúnmente empleada bajo condiciones atmosféricas estándar, adecuada para análisis y modelado a nivel de sistema.

La densidad del aire es directamente proporcional a la presión e inversamente proporcional a la temperatura [37]. Además, puede verse afectada por la humedad relativa y la altitud sobre el nivel del mar, factores que modifican ligeramente su valor real [38].

- Altura de la torre

En las proximidades del suelo, la velocidad del viento se ve afectada por la fricción que se produce con la superficie del terreno. Al incrementar la altura de la torre, se accede a capas atmosféricas donde el viento es más estable y de mayor velocidad, lo que se traduce en una mayor velocidad efectiva del viento que incide sobre el rotor. Por lo tanto, un aumento en la altura de la torre equivale a un aumento en la potencia de salida del aerogenerador [38].

- Coeficiente de potencia, ángulo de pala y velocidad de punta

El coeficiente de potencia (C_p) es un parámetro físico que determina el nivel de aprovechamiento de la energía cinética del viento en un aerogenerador. Su valor máximo teórico es de 0.593, lo que indica que la eficiencia de conversión de una turbina eólica no puede superar el 59.3 % de la energía contenida en el viento. Este límite, conocido como el límite de *Betz*, fue establecido en 1919 por el científico alemán *Albert Betz* [38], [39]. El coeficiente C_p se puede expresar en función de la relación de la velocidad de punta (λ) y del ángulo de paso de las palas (β) mediante la ecuación (2.5) [38]:

$$C_p = f_{C_p}(\lambda, \beta) \quad (2.5)$$

Por su parte, la velocidad de punta se determina mediante la ecuación (2.6) [38]:

$$\lambda = \frac{\omega \cdot R}{v} \quad (2.6)$$

donde ω representa la velocidad angular del rotor, expresada en rad/s; y R es el radio del rotor, expresado en m.

Las relaciones anteriores evidencian que el valor de C_p puede variar en función de la velocidad del viento, la velocidad de giro del rotor y el ángulo de paso de las palas. Mediante una técnica de control conocida como punto de seguimiento de máxima potencia (*Maximum Power Point Tracking*, MPPT), es posible optimizar estos parámetros y mejorar el rendimiento de los sistemas eólicos [37], [38].

- Área de barrido de las palas

El área de barrido de las palas (A) es directamente proporcional al cuadrado del diámetro del rotor (D), como se indica en la ecuación (2.7). Un incremento en la longitud de las palas del aerogenerador provoca un aumento del área de barrido y, por ende, una mayor producción de energía [38].

$$A = \frac{\pi}{4} \cdot D^2 \quad (2.7)$$

- Turbulencias causadas por los obstáculos del terreno

Los obstáculos del terreno, como árboles y edificaciones, pueden generar turbulencias que afectan la velocidad y la calidad del viento que incide sobre los aerogeneradores. Cuando el viento entra en contacto con algún obstáculo, la zona de turbulencia puede extenderse hasta aproximadamente tres veces la altura del mismo. Por esta razón, es fundamental evitar la presencia de obstáculos delante de los aerogeneradores, especialmente en la dirección predominante de los vientos. Para mitigar estos efectos, se recomienda utilizar torres de mayor altura y mantener una separación mínima entre el aerogenerador y el obstáculo que sea superior a cinco veces la altura de dicho obstáculo [38].

En escalas de tiempo cortas, en el orden de segundos a minutos, las variaciones de la velocidad del viento asociadas a la turbulencia pueden tener un impacto muy significativo en el diseño y el rendimiento de las turbinas eólicas individuales, así como en la calidad de la energía entregada a la red. Para describir el fenómeno de la turbulencia, es necesario tomar en cuenta los siguientes parámetros: el espectro de la turbulencia, la intensidad de los componentes de turbulencia en dependencia de la altitud, las escalas integrales de turbulencia y la rugosidad de la superficie [40]. Es importante mencionar que, desde el punto de vista espectral, las turbulencias pueden ser analizadas mediante el espectro de Van der Hoven [41], como se ilustra en la Figura 2.7. Este espectro empírico describe la forma en que se distribuye la energía del viento en función de la frecuencia. Contiene tres picos fundamentales correspondientes a los efectos sinópticos (períodos de varios días), diurnos (períodos de varias horas) y turbulentos (períodos en el orden de segundos a minutos). No obstante, la naturaleza del régimen de viento en diferentes ubicaciones geográficas puede variar ampliamente, por lo que no se puede suponer que el espectro de Van der Hoven sea universalmente aplicable. Sin embargo, este concepto se utiliza muy a menudo en el modelado del viento en escalas de tiempo inferiores a 10 min [40]. Además, es importante precisar que la mención de dicho espectro en este estudio tiene un fin estrictamente teórico-descriptivo. Debido a que esta investigación emplea un enfoque basado en datos (*data-driven*), las condiciones de turbulencia y ráfagas rápidas se consideran implícitamente integradas en el conjunto de datos utilizado.




Figura 2.7. Espectro de Van der Hoven para la componente horizontal de la velocidad del viento [40].

2.4 Clasificación de los pronósticos

Los pronósticos de energía solar PV y eólica se consideran elementos esenciales para la gestión energética y el desarrollo de los sistemas eléctricos modernos. Este campo de investigación ha atraído la atención de académicos e investigadores de todo el mundo y se han propuesto diversas clasificaciones en la literatura. En la Figura 2.8 se resumen algunos aspectos generales vinculados a estos tipos de pronósticos.




Figura 2.8. Clasificación general de los pronósticos de energía solar PV y eólica.

2.4.1 Clasificación basada en el horizonte de pronóstico

El horizonte de pronóstico es el período de tiempo total que abarca la predicción realizada. En términos temporales, corresponde a la diferencia entre el instante de tiempo actual (t), en el que se emite la predicción y el instante de tiempo futuro ($t + h$), para el cual se estima el valor de la variable, tal como se ilustra en la Figura 2.9.

El horizonte de pronóstico se puede dividir en cuatro categorías fundamentales, específicamente: pronóstico a muy corto plazo (1 s – 1 h), pronóstico a corto plazo (1 h – 24 h), pronóstico a mediano plazo (1 día – 1 mes) y pronóstico a largo plazo (1 mes – 1 año). Los plazos de tiempo mencionados se utilizan con frecuencia para delimitar el horizonte de pronóstico, aunque es válido señalar que en la literatura no existe un criterio unificado al respecto y estos límites pueden variar. Como es de esperar, con el incremento del horizonte se produce un incremento en la incertidumbre y el error de pronóstico, debido principalmente a la naturaleza dinámica y a los cambios continuos de las variables climáticas que intervienen en este proceso [27], [42].




Figura 2.9. Representación gráfica del horizonte de pronóstico en la predicción de energía solar PV.

2.4.2 Clasificación basada en la variable a predecir

En función de la variable a predecir, los pronósticos de energía solar PV y eólica pueden clasificarse en enfoques directos e indirectos, como se muestra en la Figura 2.10.




Figura 2.10. Clasificación de los pronósticos en función de la variable a predecir: (a) Pronóstico directo y (b) Pronóstico indirecto.

En el primer caso (Figura 2.10a), se predice directamente la variable objetivo (potencia PV o potencia eólica) a partir de datos históricos de generación y/o condiciones meteorológicas. En el segundo caso (Figura 2.10b), se pronostica inicialmente la irradiancia solar o la velocidad del viento. Posteriormente, la potencia PV o eólica se determina utilizando curvas de potencia o modelos paramétricos específicos de cada instalación. Estos modelos consideran las características internas del sistema y algunos parámetros meteorológicos relevantes para cada fuente de energía [22], [28].

2.4.3 Clasificación basada en la escala espacial

Según la escala espacial, los pronósticos pueden clasificarse como pronósticos de una ubicación o pronósticos a escala regional, como se muestra en la Figura 2.11. Los pronósticos de una ubicación se centran en una instalación específica y, por lo general, presentan mayor precisión. Por su parte, los pronósticos a escala regional abarcan un área determinada e incluyen múltiples plantas de energía [30]. Para la obtención de pronósticos a escala regional se aplican diferentes métodos, entre los que se destacan el método de superposición y el método de ampliación. En el método de superposición, se predicen los valores de potencia para cada una de las instalaciones de la región y posteriormente se superponen estos valores para obtener un pronóstico a escala regional. La principal desventaja de este enfoque es que el tiempo de

cálculo y los errores de pronóstico aumentan al considerar un mayor número de plantas de energía en la región. En cuanto al método de ampliación, los autores establecen dos enfoques fundamentales para su implementación. En el primer enfoque, se agrupan varias plantas de energía de una región en una planta de potencia virtual (*Virtual Power Plant*, VPP) y mediante un pronóstico meteorológico agregado se obtiene la predicción de potencia a escala regional. En el segundo enfoque, se seleccionan cuidadosamente algunas plantas de energía representativas de la región bajo estudio para efectuar el pronóstico. Luego las predicciones obtenidas se combinan o extrapolan para obtener resultados a escala regional considerando la capacidad total del área [30], [43].




Figura 2.11. Clasificación de los pronósticos en función de la escala espacial considerada.

2.4.4 Clasificación basada en el método de pronóstico

Los métodos utilizados para el pronóstico de energía solar PV y eólica se clasifican en cuatro grupos principales: métodos físicos, métodos estadísticos, métodos de aprendizaje automático (ML) y métodos híbridos [27], [42]. La Figura 2.12 resume algunos de los enfoques más representativos dentro de cada grupo.

Los métodos físicos utilizan predicciones meteorológicas de distintas variables y modelos matemáticos de las plantas de energía para pronosticar la potencia de salida [27]. Estos métodos no requieren datos históricos para su funcionamiento, ya que se basan principalmente en la información detallada de la instalación bajo estudio y en los pronósticos meteorológicos obtenidos para una ubicación geográfica específica. Sin embargo, presentan una aplicabilidad limitada debido a que requieren varios datos de las instalaciones que en ocasiones se desconocen y deben estimarse de forma aproximada. Además, su precisión depende considerablemente de la calidad de las predicciones meteorológicas, que en algunos casos pueden contener un alto grado de incertidumbre, sobre todo en condiciones climáticas adversas. Entre los métodos

de pronóstico físicos más utilizados se encuentra la predicción meteorológica numérica (NWP) [14], [42]. En el ámbito de la energía solar se pueden utilizar pronósticos basados en imágenes del cielo. En este caso se utilizan cámaras especiales para analizar la formación y el movimiento de las nubes. Luego se obtiene un pronóstico de la potencia PV para una ubicación concreta y, generalmente, para un horizonte de muy corto plazo [44].




Figura 2.12. Clasificación de los métodos de pronóstico de energía solar PV y eólica.

Los métodos estadísticos establecen una relación matemática entre los datos históricos de entrada y salida, considerando el nivel de correlación, la estimación de parámetros y el ajuste de curvas. Estos métodos son generalmente más sencillos y fáciles de implementar que los métodos físicos. Sin embargo, su desempeño depende fuertemente de la cantidad y la calidad de los datos históricos disponibles. Además, pueden presentar ciertas limitaciones cuando se enfrentan a series temporales con dinámicas complejas y comportamientos no lineales, como es el caso de la energía solar PV y la eólica. Entre los métodos estadísticos más utilizados se encuentran la regresión lineal (*Linear Regression*, LR), las cadenas de *Markov* y el filtro de *Kalman*. También son ampliamente utilizados el modelo autorregresivo de media móvil (*Autoregressive Moving Average*, ARMA) y el modelo autorregresivo integrado de media móvil (*Autoregressive Integrated Moving Average*, ARIMA), entre otros [14], [22].

Con el avance de la inteligencia artificial (*Artificial Intelligence*, IA) y el incremento de las capacidades computacionales, los métodos de ML y DL han experimentado un notable crecimiento en el pronóstico de energía solar PV y eólica. Los métodos de ML se consideran un subconjunto dentro del amplio horizonte de la IA. A su vez los métodos de DL constituyen un subconjunto dentro del ML [45]. En la Figura 2.13 se muestra la relación existente entre IA, ML y DL mediante un diagrama de Venn.




Figura 2.13. Diagrama de Venn que muestra la relación entre IA, ML y DL.

Los métodos de ML han mostrado buen rendimiento y gran flexibilidad para el pronóstico de series temporales, gracias a su capacidad para identificar relaciones no lineales entre las variables de entrada y salida. De esta forma, pueden lograr un mejor desempeño en la predicción de energía solar PV y eólica, superando en muchos casos la precisión de los métodos físicos y estadísticos. Sin embargo, estos métodos pueden presentar limitaciones en su capacidad de generalización cuando se enfrentan a problemas de alta dimensionalidad, especialmente cuando se trabaja con grandes volúmenes de datos con estructuras complejas y no lineales [42], [46]. Entre los métodos de ML más utilizados se encuentran las redes neuronales artificiales (*Artificial Neural Networks*, ANN), que abarcan diversas arquitecturas según la forma en que fluye la información a través de la red. Destacan las redes de alimentación hacia adelante (*Feedforward Neural Networks*, FFNN), representadas por el perceptrón multicapa (*Multilayer Perceptron*, MLP) y la red de funciones de base radial (*Radial Basis Function Network*, RBFN). Por otro lado, para el manejo de dependencias secuenciales, se emplean las redes neuronales recurrentes (*Recurrent Neural Networks*, RNN). Otros métodos relevantes incluyen la máquina de vectores de soporte (*Support Vector Machine*, SVM), la máquina de aprendizaje extremo (*Extreme Learning Machine*, ELM) y los árboles de decisión (*Decision Trees*, DT). Además, se han empleado exitosamente técnicas de aprendizaje por conjuntos como el bosque aleatorio (*Random Forest*, RF) y la máquina de potenciación por gradiente (*Gradient Boosting Machine*, GBM) [45], [46].

Por su parte, los métodos de DL destacan por su capacidad para aprender patrones de comportamiento no lineales y altamente complejos en series temporales. Ofrecen alta robustez, buena capacidad de generalización y pueden procesar eficientemente grandes volúmenes de datos [46]. Entre los métodos de DL más utilizados se encuentran la red neuronal convolucional (*Convolutional Neural Network*, CNN), la unidad recurrente con compuertas (*Gated Recurrent Unit*, GRU) y arquitecturas de memoria de largo y corto plazo como la red neuronal LSTM y su variante bidireccional (BiLSTM). También se destacan las redes de creencias profundas (*Deep Belief Network*, DBN), las redes convolucionales temporales (*Temporal Convolutional Networks*, TCN) y los modelos basados en la arquitectura *Transformer*, entre otros [45], [46].

Los métodos híbridos combinan diferentes enfoques con el objetivo de aprovechar sus fortalezas individuales, incrementar la robustez y mejorar la calidad de los pronósticos [23], [28], [45]. Aunque estos métodos pueden obtener resultados altamente precisos, suelen tener un mayor costo computacional y tiempos de ejecución más prolongados que los métodos simples. Por lo tanto, resulta conveniente establecer un punto de equilibrio entre exactitud y complejidad, para obtener modelos de pronóstico eficientes que resulten aplicables en la práctica.

En la Figura 2.14 se presenta una clasificación general de los métodos híbridos que se utilizan con frecuencia en el pronóstico de energía solar PV y eólica. Algunos autores plantean que los métodos híbridos se basan solamente en la combinación de varios métodos de pronóstico simples. No obstante, en esta investigación se utiliza una visión más amplia, que también incluye dentro de esta categoría la integración de técnicas para la descomposición de series temporales, la selección de características y la aplicación de algoritmos de optimización [23]. De esta forma, se refleja con mayor fidelidad la tendencia actual que existe en la literatura referente al pronóstico de estas fuentes renovables.




Figura 2.14. Clasificación de los métodos de pronóstico híbridos.

Es común encontrar métodos híbridos que se nutren de la combinación de diferentes métodos de pronóstico simples, por ejemplo, métodos físicos y métodos de ML o DL, o algunos métodos de ML y DL, entre otros [46]. También existen otros enfoques que combinan los métodos de ML o DL con técnicas de descomposición de series temporales, entre las que se pueden mencionar: la descomposición de *wavelet* (*Wavelet Decomposition*, WD), la descomposición en modos variacionales (*Variational Mode Decomposition*, VMD) y la descomposición en modos empíricos (*Empirical Mode Decomposition*, EMD). El propósito de estas técnicas es descomponer la serie de tiempo original en varias subseries de frecuencia que presentan un comportamiento más estable y estructuras más suaves y predecibles [22]. Además, algunos métodos híbridos incorporan algoritmos de optimización para la inicialización de pesos y sesgos, el ajuste de parámetros internos en diferentes tipos de modelos, o para determinar coeficientes en la combinación de varios modelos simples. Todo esto con el objetivo de mejorar el rendimiento y la capacidad de adaptación de los modelos resultantes [23], [46].

Por otra parte, también se han desarrollado enfoques híbridos que integran métodos de selección de características (FS) con el objetivo de reducir la dimensionalidad de los datos, disminuir la carga computacional y mejorar la calidad de los pronósticos. Entre los métodos de FS más utilizados se encuentran

el análisis de componentes principales (*Principal Component Analysis*, PCA) y el coeficiente de correlación de Pearson (*Pearson Correlation Coefficient*, PCC), entre otros. Además, en algunos casos se combinan técnicas de diferentes grupos para obtener modelos híbridos más potentes y flexibles, capaces de capturar con precisión la dinámica del sistema. Estas posibles combinaciones representadas mediante líneas discontinuas en la Figura 2.14, constituyen un reflejo de la naturaleza diversa y adaptable de los enfoques híbridos modernos [22], [23].

2.4.5 Clasificación basada en el tipo de pronóstico

Por último, atendiendo al tipo de pronóstico se establecen dos posibles clasificaciones: métodos de pronóstico determinísticos y métodos de pronóstico probabilísticos. Los pronósticos determinísticos (o puntuales) se enfocan en obtener un único valor para cada instante de tiempo futuro. Sin embargo, estos pronósticos siempre contienen cierto grado de incertidumbre, lo que puede resultar perjudicial para la operación y el control eficiente de los sistemas eléctricos. Esta limitación ha impulsado el desarrollo de métodos de pronóstico probabilísticos para gestionar eficientemente dichas incertidumbres y mejorar la toma de decisiones en el sistema eléctrico. Según la forma en que se expresan sus resultados, los métodos de pronóstico probabilísticos se agrupan en varias categorías, que incluyen: las funciones de densidad de probabilidad, la regresión cuantílica (QR) y las predicciones de intervalo [24], [30], [46]. En esta última categoría, se establece un posible rango de valores que pueden contener tanto las predicciones como los valores reales de la variable objetivo con un determinado nivel de confianza previamente definido. Las predicciones de intervalo son ampliamente utilizadas debido a sus ventajas en términos de facilidad de implementación y de comprensión de los resultados obtenidos [47]. Para profundizar más en este tema, en la Figura 2.15 se ilustran los tipos de pronóstico mencionados para un caso de estudio asociado a la predicción de energía eólica.




Figura 2.15. Representación gráfica de los pronósticos determinísticos y probabilísticos de energía eólica.

Por otro lado, en dependencia del método de modelado utilizado, los pronósticos probabilísticos pueden dividirse en dos grupos principales: métodos paramétricos y métodos no paramétricos. En el primer caso se asume que los errores de pronóstico obtenidos se ajustan a una determinada distribución de probabilidad (por ejemplo, distribución normal, distribución beta, entre otras). Sin embargo, esto puede representar una limitación cuando la distribución seleccionada no caracteriza adecuadamente el comportamiento de los

errores derivados del pronóstico determinístico. Por su parte, los métodos no paramétricos no hacen suposiciones sobre la distribución de probabilidad de los errores de pronóstico. Estos métodos se basan en algoritmos como la QR, los métodos de estimación de límites inferior y superior (*Lower Upper Bound Estimation*, LUBE) y los métodos *bootstrap*, entre otros [23], [25], [47].

Es importante señalar que ambos tipos de pronóstico pueden llevarse a cabo para un único paso de tiempo o para múltiples pasos de tiempo en el futuro. Los pronósticos para un único paso de tiempo son generalmente más utilizados y resultan más simples y precisos. En el caso de los pronósticos para múltiples pasos de tiempo, pueden aplicarse dos posibles estrategias conocidas como estrategia directa y estrategia iterativa. La estrategia directa emplea un modelo específico para efectuar el pronóstico en cada horizonte temporal requerido, mientras que la estrategia iterativa utiliza un solo modelo y se basa en las predicciones de los instantes previos para obtener las predicciones de los instantes futuros. No obstante, aunque la estrategia iterativa es más simple desde el punto de vista computacional, puede verse afectada por la acumulación de errores en el transcurso del proceso predictivo [30].

Por otra parte, las características y la calidad de los datos utilizados en el estudio también influyen significativamente en el rendimiento del pronóstico. En el contexto de la energía solar PV y eólica, se pueden utilizar datos de distinta naturaleza, tales como series temporales, imágenes del cielo y datos espaciales. Estos datos pueden ser univariantes (series temporales de potencia PV o eólica) o multivariantes (cuando se combinan las series temporales de potencia con datos meteorológicos o con otras variables asociadas a cada fuente de energía) [46].

2.5 Métricas para evaluar la exactitud de los pronósticos

Para cuantificar la precisión y el desempeño de los pronósticos se ha seleccionado un conjunto de métricas de distinta naturaleza, ampliamente recomendadas en la literatura especializada. En el caso de los pronósticos determinísticos, se utilizan el error absoluto medio normalizado (*Normalized Mean Absolute Error*, nMAE) [48] y la raíz del error cuadrático medio normalizado (*Normalized Root Mean Square Error*, nRMSE) [48]. El uso de métricas normalizadas permite una comparación adecuada entre diferentes modelos y facilita la interpretación de los resultados obtenidos. Además, se emplean otras métricas complementarias que enriquecen la evaluación de los pronósticos realizados, específicamente el coeficiente de determinación (R^2) [49] y el porcentaje de mejora (*Improvement Percentage*, %I) [49]. Las métricas mencionadas se determinan mediante las ecuaciones siguientes:

$$nMAE = \frac{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|}{y_{i,max}} \cdot 100 \quad (2.8)$$

$$nRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{y_{i,max}} \cdot 100 \quad (2.9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.10)$$

$$\%I = \left(1 - \frac{\mathcal{E}_{\text{modelo propuesto}}}{\mathcal{E}_{\text{modelo de referencia}}}\right) \cdot 100 \quad (2.11)$$

donde y_i y $\hat{y}_i$ representan el valor real y el valor pronosticado de la variable de interés, respectivamente; $y_{i,\max}$ y $\bar{y}$ representan el valor máximo y el valor promedio del conjunto de datos de prueba, respectivamente; n corresponde al número total de observaciones; y $\mathcal{E}_*$ representa una métrica de error (nMAE o nRMSE) utilizada para evaluar el desempeño de cada modelo.

En el caso de los pronósticos probabilísticos, las métricas utilizadas incluyen la confianza nominal del intervalo de predicción (*Prediction Interval Nominal Confidence*, PINC) [48] y la probabilidad de cobertura del intervalo de predicción (*Prediction Interval Coverage Probability*, PICP) [48]. También se emplean el ancho promedio normalizado del intervalo de predicción (*Prediction Interval Normalized Average Width*, PINAW) [48] y el error de cobertura promedio (*Average Coverage Error*, ACE) [23]. Estas métricas se determinan como:

$$PINC = 100 \cdot (1 - \alpha)\% \quad (2.12)$$

$$PICP = \frac{1}{n} \sum_{i=1}^n \epsilon_i, \text{ donde } \epsilon_i = \begin{cases} 1 & \text{si } y_i \in [L_i, U_i] \\ 0 & \text{si } y_i \notin [L_i, U_i] \end{cases} \quad (2.13)$$

$$PINAW = \frac{1}{n \cdot R} \sum_{i=1}^n (U_i - L_i) \quad (2.14)$$

$$ACE = PICP - PINC \quad (2.15)$$

donde α denota el nivel de significancia (representa la probabilidad máxima permitida de que el valor real de la potencia se encuentre fuera de los límites del intervalo de predicción); ϵ_i representa una variable booleana que indica si el valor real se encuentra dentro del intervalo de predicción; L_i y U_i representan los límites inferior y superior del intervalo de predicción, respectivamente; y R corresponde al rango de la variable objetivo, definido como la diferencia entre su valor máximo y su valor mínimo.

Para evaluar el rendimiento de un modelo de pronóstico es recomendable utilizar diferentes métricas para obtener una caracterización más profunda y un mayor nivel de información sobre los errores cometidos. Cada una de las métricas mencionadas tiene sus propias características y contribuye de manera positiva a este proceso [22], [46]. Por ejemplo, el MAE es una medida de error promedio ampliamente utilizada, que le otorga igual importancia a todos los errores individuales. Por su parte, el RMSE resulta útil para identificar errores significativos que pueden afectar el rendimiento del modelo. Además, las versiones normalizadas de estas métricas (nMAE y nRMSE) se utilizan para eliminar las diferencias de escala con el fin de establecer las comparaciones pertinentes. Por otro lado, el R^2 es una medida de variabilidad que indica cómo el modelo se ajusta a los datos observados. Por último, el $\%I$ representa una mejora con respecto a un modelo de referencia o de línea base [22]. En general, para obtener un buen desempeño de un modelo de pronóstico, los valores de nMAE y nRMSE deben ser pequeños, el valor de R^2 debe estar cercano a la unidad y el valor de $\%I$ debe ser mayor que cero.

En cuanto a las métricas probabilísticas, la PICP indica la cantidad de valores que se encuentran contenidos dentro del intervalo de predicción para un cierto nivel de PINC. El PINAW representa el ancho del intervalo de predicción y es común que, a medida que aumente el nivel nominal de confianza, también aumente el ancho del intervalo para poder contener las predicciones y los valores reales. Mientras que el ACE cuantifica directamente los errores cometidos en la cobertura del intervalo de predicción calculado. En este tipo de pronóstico, es recomendable obtener valores de PICP iguales o muy cercanos a cada PINC definido, lo que conduce a una mejor cobertura de los intervalos de predicción (intervalos mejor calibrados) y valores ACE más bajos, garantizando así una mayor fiabilidad de las predicciones. Por su parte, la métrica PINAW sirve como un indicador de la nitidez de la predicción. En este caso se recomienda que los intervalos de predicción sean lo más estrechos posible para limitar adecuadamente los resultados del pronóstico, proporcionando una mejor información para la toma de decisiones [46], [48].

2.6 Importancia de los pronósticos de energía solar PV y eólica

El carácter intermitente y variable de las fuentes de energía solar y eólica dificulta su gestión energética y limita su integración a gran escala en los sistemas eléctricos [50]. Ante este desafío, el desarrollo de pronósticos precisos es fundamental para garantizar una integración eficiente de dichas fuentes. Estos pronósticos impactan significativamente en diversas áreas de la planeación y la operación de las redes eléctricas. Su aplicabilidad se relaciona con el horizonte de pronóstico definido, tal como se muestra en la Tabla 2.1.

Tabla 2.1. Aplicaciones de los pronósticos de energía solar PV y eólica en función del horizonte de pronóstico utilizado.

Horizonte de pronóstico	Aplicaciones en el sistema eléctrico
Muy corto plazo (1 s – 1 h)	Despacho de energía en tiempo real, control y regulación del sistema, suavizado de potencia, regulación de frecuencia, control de los sistemas de almacenamiento de energía, gestión de los eventos de rampa y determinación de las reservas óptimas [1], [24].
Corto plazo (1 h – 24 h)	Acciones de seguimiento de carga y control de zona, compromiso de unidades, programación del mercado de energía del día siguiente [17], [24].
Mediano plazo (1 día – 1 mes)	Programación del mantenimiento del sistema, planeación de recursos y capacidades [1], [17].
Largo plazo (1 mes – 1 año)	Planeación a largo plazo de recursos y capacidades del sistema, consideración de tendencias estacionales, estudios de factibilidad a largo plazo [1], [21].

2.7 Estado actual de los pronósticos de energía solar PV y eólica

En los últimos años, el número de publicaciones referentes al pronóstico de energía solar PV y eólica ha aumentado considerablemente debido a la importancia de este tema. Por lo tanto, resulta necesario identificar las principales tendencias y contribuciones, así como las lagunas que aún persisten en este campo de investigación.

2.7.1 Estado actual del pronóstico de energía solar PV

La última década ha sido testigo de un notable crecimiento en el campo de los pronósticos de energía solar PV. En [51] se emplean cadenas de modelos físicos calibrados mediante QR para obtener pronósticos determinísticos y probabilísticos de energía solar PV a corto plazo. El enfoque propuesto presenta un rendimiento satisfactorio en ambos tipos de pronóstico, aunque su efectividad depende de la calidad de las predicciones meteorológicas y de un conocimiento preciso de la instalación PV bajo estudio. Por otro lado, la referencia [52] utiliza un modelo híbrido (NWP-MLP) para efectuar un pronóstico determinístico de la potencia PV del día siguiente a escala regional. En este caso, el modelo propuesto logra una reducción del error del 29 % en comparación con otros modelos de referencia de la literatura. En [53] se combinan imágenes del cielo con un modelo basado en redes neuronales profundas tipo LSTM para efectuar un pronóstico determinístico de la potencia PV a muy corto plazo. Los resultados experimentales obtenidos evidencian que el modelo propuesto supera a otros modelos de ML y DL en términos de precisión. Sin embargo, la utilización de imágenes del cielo obtenidas mediante cámaras especiales puede limitar su aplicabilidad en otras instalaciones PV que no dispongan de esta tecnología.

La referencia [54] aplica un modelo estadístico basado en ARIMA para llevar a cabo un pronóstico determinístico a corto plazo de energía solar PV. El modelo implementado logra buenos resultados, aunque la naturaleza variable y no lineal de la serie temporal analizada influye considerablemente en la exactitud de los pronósticos obtenidos. En un estudio comparativo presentado en [55] se analiza la efectividad de varios modelos estadísticos (ARMA y ARIMA), de ML (MLP, FFNN y RNN) y de DL (LSTM y BiLSTM) en la predicción de potencia PV con una hora de antelación. Las comparaciones realizadas evidencian que los modelos de pronóstico basados en ANNs resultan superiores a los modelos estadísticos en términos de exactitud y calidad de las predicciones. En [56] se realiza una predicción determinística de la potencia PV de la hora siguiente mediante un modelo LSTM. Las pruebas del modelo se llevan a cabo en tres sistemas PV de diferente tecnología. La comparación de los resultados obtenidos con respecto a otros modelos de ML demuestra la superioridad del enfoque propuesto. En [57] se utiliza un modelo híbrido compuesto por WD y LSTM para una tarea similar. El uso del enfoque WD para la descomposición de series de tiempo, junto con las fortalezas del modelo LSTM en el manejo de datos complejos y no lineales, le otorgan al modelo híbrido una elevada capacidad de aprendizaje. Sin embargo, su costo computacional puede resultar elevado debido a la combinación en paralelo de cuatro modelos LSTM. Un estudio interesante se presenta en [58], donde los autores comparan cuatro arquitecturas del modelo LSTM (*vanilla*, *stacked*, BiLSTM y *encoder-decoder*) para obtener pronósticos determinísticos y probabilísticos de la potencia PV de la próxima hora. En particular, la arquitectura BiLSTM muestra la mayor exactitud en términos de MAE y RMSE.

En cuanto a la ingeniería de características, la referencia [59] combina un método de selección de características (*RReliefF*) con una red neuronal MLP para obtener una predicción de potencia PV con 15 min de antelación. Los resultados alcanzados demuestran la importancia de una adecuada selección de las variables de entrada para incrementar la exactitud de las predicciones realizadas. En [60] se pronostica la potencia PV del día siguiente mediante varios modelos de DL. Se demuestra que la arquitectura híbrida CNN-LSTM supera a otras arquitecturas más simples en términos de robustez y capacidad de adaptación.

Además, se evidencia que la longitud óptima de la secuencia de entrada es un factor importante para lograr un buen desempeño de los modelos de pronóstico basados en DL. Por su parte, en [61] se lleva a cabo un pronóstico determinístico de potencia PV para horizontes de muy corto plazo (de 5 min hasta 1 h adelante) utilizando un modelo de CNN con cuatro núcleos. Las pruebas realizadas reflejan que la calidad de los resultados se degrada con el aumento del horizonte de pronóstico. En [62] se propone un modelo GRU basado en conjuntos de datos univariados y multivariados para predecir la irradiancia solar de la próxima hora. Los resultados obtenidos demuestran que al utilizar información de la cobertura de nubes y de otras variables climáticas exógenas, se puede mejorar notablemente la exactitud del pronóstico.

Respecto a la optimización de hiperparámetros, la referencia [63] utiliza un algoritmo metaheurístico basado en la optimización por colonia de hormigas (*Ant Colony Optimization*, ACO) para ajustar los hiperparámetros más relevantes de un modelo SVM. Las predicciones realizadas para horizontes temporales de muy corto y corto plazo evidencian la efectividad del enfoque propuesto. En [64] se combina un modelo autorregresivo no lineal con entradas exógenas (*Nonlinear Autoregressive with Exogenous Inputs*, NARX) con un modelo LSTM para efectuar pronósticos determinísticos y probabilísticos de potencia PV a muy corto y corto plazo. Para ello, los hiperparámetros de la red LSTM se optimizan mediante un algoritmo de búsqueda tabú (*Tabu Search Algorithm*, TSA) y se observa que el desempeño general del modelo híbrido propuesto resulta satisfactorio. Sin embargo, el costo computacional es elevado, lo que puede representar una limitación para aplicaciones de pronóstico que requieran tiempos de ejecución reducidos o respuestas en tiempo real.

Los autores de [65] utilizan dos algoritmos de conjunto, específicamente GBM y RF, para efectuar pronósticos determinísticos de energía solar PV. El enfoque propuesto demuestra una buena flexibilidad y capacidad de adaptación en diferentes condiciones climáticas, por lo que se considera una opción factible para aplicaciones de pronóstico en tiempo real. En [66] se efectúa un pronóstico determinístico de la energía solar PV del próximo día a partir de métodos de DL y un enfoque de transferencia de aprendizaje (*Transfer Learning*). Las pruebas realizadas evidencian que este enfoque puede ser útil para pronosticar la producción de energía en nuevas plantas PV donde no se dispone de datos históricos extensos. Por su parte, las referencias [67] y [68] utilizan arquitecturas avanzadas de DL basadas en TCN y modelos *Transformer*, respectivamente. Ambos enfoques muestran un buen rendimiento en la predicción de energía solar PV, aunque suelen requerir grandes conjuntos de datos y altos recursos computacionales para su entrenamiento.

2.7.2 Estado actual del pronóstico de energía eólica

El tema de la predicción de energía eólica también ha sido abordado en un amplio número de publicaciones. En [69] se desarrolla un enfoque para el pronóstico determinístico de la energía eólica del día siguiente. En este caso se combina el agrupamiento de las predicciones del modelo NWP, un método basado en días similares y una red neuronal de regresión generalizada (*Generalized Regression Neural Network*, GRNN). Los resultados obtenidos en el estudio demuestran que el modelo propuesto mejora significativamente la precisión de los pronósticos realizados. Por su parte, en [70] se realiza un pronóstico de energía eólica a corto plazo, basado en el análisis de las predicciones NWP y su combinación con modelos

de DL como LSTM y CNN. El modelo híbrido propuesto se desempeña de manera favorable en diferentes condiciones climáticas y supera a otros modelos de referencia. Desde la perspectiva estadística, la referencia [71] reporta buenos resultados en el pronóstico determinístico de la velocidad del viento para un horizonte de muy corto plazo, mediante un modelo autorregresivo integrado de media móvil estacional (*Seasonal Autoregressive Integrated Moving Average*, SARIMA).

La hibridación de métodos clásicos y modernos se explora en [72], donde se compara un modelo ARIMA, una ANN y un modelo híbrido ARIMA-ANN en el pronóstico de la velocidad del viento con diferentes horizontes temporales. Las pruebas realizadas demuestran que el modelo híbrido supera a los modelos simples que lo conforman en términos de exactitud y flexibilidad. Sin embargo, la cantidad de datos históricos requerida para su aplicación es considerable. En términos de optimización, en [73] se comparan varios modelos de ML, que incluyen la regresión de procesos gaussianos (*Gaussian Process Regression*, GPR), SVM y varios algoritmos de conjunto, para obtener un pronóstico determinístico de la potencia eólica con una hora de antelación. Los resultados obtenidos evidencian que la optimización de hiperparámetros mediante BO puede incrementar en gran medida la calidad de las predicciones. Este efecto se potencia aún más al considerar los rezagos de la serie temporal de potencia eólica y al incluir variables exógenas. En esta misma línea, en [74] se emplea un modelo RF que refleja superioridad frente a otros enfoques de ML en diversos escenarios operativos.

La referencia [75] propone un modelo híbrido, basado en una red LSTM y un algoritmo de optimización de búsqueda caótica del gorrión (*Chaotic Sparrow Search Optimization Algorithm*, CSSOA), para el pronóstico determinístico de energía eólica. El modelo propuesto logra mejoras significativas en términos del RMSE para los pronósticos realizados en diferentes estaciones del año, aunque su complejidad computacional resulta elevada. Un enfoque análogo se aplica en [76], donde se hibridan una red LSTM y un GA para efectuar un pronóstico de potencia eólica a corto plazo. En este caso, el modelo híbrido también exhibe resultados favorables y logra un porcentaje de mejora del 29 % con respecto al modelo LSTM simple. También en [77], se combina una red LSTM con un algoritmo de optimización de hiperparámetros basado en BO. Los resultados alcanzados en el pronóstico de energía eólica con un día de antelación evidencian la flexibilidad del método propuesto. Además, resaltan las ventajas del algoritmo BO para la optimización de hiperparámetros, debido principalmente a su elevada precisión y su bajo costo computacional.

En [78] se realizan pronósticos determinísticos y probabilísticos de potencia eólica con una hora de antelación mediante un modelo de DL residual basado en BiLSTM. El modelo propuesto se desempeña adecuadamente en el pronóstico de series temporales altamente complejas y no lineales. En [79] se propone la integración de predicciones basadas en NWP con mediciones provenientes del sistema de control supervisado y adquisición de datos (*Supervisory Control and Data Acquisition*, SCADA) y una RNN apilada, para obtener un pronóstico de energía eólica con 90 h de antelación. Los resultados muestran que la selección adecuada de las características de entrada resulta esencial para garantizar un buen desempeño del modelo en el pronóstico de energía eólica. Por su parte, la referencia [80] se basa en la combinación de dos técnicas de descomposición de series temporales (WD y VMD) con una máquina de vectores de soporte de mínimos cuadrados (*Least Square Support Vector Machine*, LSSVM) para obtener una predicción

determinística de energía eólica a muy corto plazo. Se observa que, al utilizar dos enfoques de descomposición de series temporales se favorece el proceso de aprendizaje del modelo y se incrementa la exactitud de las predicciones.

En [81] se utilizan redes neuronales profundas para extraer patrones de comportamiento asociados a la velocidad del viento y predecir la potencia en parques eólicos que han operado durante cierto tiempo. Posteriormente, se realiza una transferencia de aprendizaje para aplicar el modelo previamente entrenado en parques eólicos recién instalados, donde no existe disponibilidad de datos históricos. Los resultados experimentales obtenidos muestran una reducción significativa de los errores en todos los casos analizados. En [82] se propone un modelo basado en CNN para predecir la velocidad del viento del próximo día en parques eólicos marinos. Además, se consideran las mediciones históricas de velocidad del viento en varias ubicaciones geográficas distantes. El modelo de pronóstico propuesto es capaz de extraer las relaciones espaciotemporales de los datos históricos disponibles y logra un desempeño favorable en esta tarea.

La referencia [83] utiliza un modelo GRU para efectuar un pronóstico determinístico, a corto plazo y a escala regional, de energía eólica en Alemania. Luego de realizar diferentes pruebas de desempeño, se concluye que el enfoque propuesto supera a los modelos ARIMA y de regresión de vectores de soporte (*Support Vector Regression*, SVR). Esta superioridad se evidencia tanto en la precisión como en la capacidad de aprendizaje sobre largas secuencias de datos. En [84] se realiza una predicción de energía eólica a muy corto plazo a partir de cuatro modelos de ML considerando 13 factores meteorológicos diversos. En este trabajo se aplica una técnica de XAI conocida como explicaciones aditivas de Shapley (SHAP), para determinar el grado de importancia de cada entrada para el modelo de pronóstico desarrollado. Los autores concluyen que la velocidad del viento y los aspectos relacionados con la turbulencia resultan determinantes para la predicción de energía eólica en este sistema de prueba.

2.7.3 Principales tendencias, contribuciones y limitaciones en el pronóstico de energía solar PV y eólica

El análisis realizado con anterioridad sobre el estado actual de los pronósticos de energía solar PV y eólica pone de manifiesto importantes aspectos sobre el tema. En primer lugar, se observa una tendencia clara hacia el uso de enfoques híbridos, los cuales integran métodos y algoritmos de distinta naturaleza para aprovechar las fortalezas individuales de cada componente. Los trabajos analizados demuestran que los pronósticos obtenidos a partir de enfoques híbridos resultan superiores en calidad y exactitud. Sin embargo, su complejidad computacional y sus tiempos de entrenamiento son mayores. Los métodos basados en ML y DL también se utilizan con mucha frecuencia, sobre todo las RNN profundas (LSTM en sus diferentes variantes y GRU), que han mostrado un desempeño excelente en el pronóstico de series temporales. Por otro lado, aunque se ha demostrado que la optimización de hiperparámetros puede mejorar la exactitud de los modelos de pronóstico, en muchos casos se ha realizado este ajuste mediante la técnica de prueba y error. De esta manera se invierte una gran cantidad de tiempo para ajustar los modelos, sin garantizar que el ajuste obtenido sea el más adecuado, lo que evidencia la necesidad de emplear métodos de optimización automatizados para seleccionar las configuraciones óptimas. También se observa que la mayor parte de los trabajos se concentra en pronósticos de una ubicación y muy pocos abordan pronósticos a escala regional,

ya que estos últimos requieren una gran cantidad de información que muchas veces no está disponible. Sin embargo, siempre que sea posible, es importante evaluar los modelos de pronóstico en diferentes ubicaciones geográficas y condiciones climáticas, para obtener pruebas más concluyentes respecto a su efectividad, robustez y capacidad de adaptación.

En cuanto al horizonte de pronóstico, predomina el uso de horizontes de muy corto y corto plazo, especialmente pronósticos intrahorarios, con una hora de antelación y para el día siguiente, debido a su importancia para la planeación y la operación del sistema eléctrico. También se observa que un gran número de trabajos realiza pronósticos directos de la potencia PV o eólica a partir de diferentes tipos de datos. Otros, en cambio, predicen inicialmente la irradiancia solar o la velocidad del viento para obtener posteriormente la potencia. La utilización de estos enfoques está estrechamente relacionada con la disponibilidad de datos y el tipo de aplicación que se desee implementar. Cuando se dispone de amplios conjuntos de datos de las instalaciones PV o eólicas, es común utilizar un enfoque de pronóstico directo. Sin embargo, cuando no se dispone de mediciones de potencia, o cuando se trata de instalaciones nuevas que han operado por un período relativamente corto, el enfoque indirecto puede resultar una buena opción. En este sentido, algunos autores han propuesto métodos basados en transferencia de aprendizaje, donde los modelos de pronóstico entrenados para una instalación específica pueden ser utilizados para realizar predicciones en otras instalaciones.

Con respecto al tipo de pronóstico, la tendencia indica que la mayor parte de los trabajos analizados se concentra en pronósticos determinísticos, mientras que un menor número de publicaciones aborda el pronóstico probabilístico. Se espera que en el futuro se incremente el uso de enfoques probabilísticos, debido a su gran importancia en la gestión energética del sistema, la evaluación de riesgos y el apoyo a la toma de decisiones. Por otra parte, aunque algunos trabajos han demostrado la gran importancia del preprocesamiento de los datos para mejorar el rendimiento de los modelos y la calidad de los pronósticos, este aspecto no ha sido abordado en la literatura con la profundidad requerida. También es importante señalar que, con el uso extendido de enfoques híbridos, así como de técnicas de ML y DL, debe incrementarse la utilización de técnicas de XAI para comprender mejor el funcionamiento de los modelos y mejorar su transparencia.

2.8 Conclusiones del capítulo

En este capítulo se han abordado los aspectos teóricos más importantes en el contexto de la predicción de energía solar PV y eólica. En primer lugar, se han analizado los modelos matemáticos que representan el comportamiento de los sistemas PV y eólicos. De igual manera, se ha explicado el impacto de un grupo de variables meteorológicas, físicas y de diversa naturaleza en el desempeño de dichos sistemas. El estudio de las relaciones existentes entre estas variables, así como el conocimiento preciso de su influencia en el comportamiento de los sistemas de energía renovable, resulta esencial para el desarrollo de aplicaciones de pronóstico eficientes y flexibles.

Además, se han establecido las clasificaciones generales de los pronósticos considerando varios aspectos relevantes dentro de este campo de estudio. Las clasificaciones realizadas son amplias y detalladas y su

objetivo fundamental es sentar las bases para las aplicaciones de pronóstico que se implementen en el marco de esta investigación. También se han definido las métricas necesarias para evaluar la exactitud y la calidad de los pronósticos de naturaleza determinística y probabilística. En este caso, se ha justificado adecuadamente la utilización de cada métrica propuesta y se ha resaltado su importancia para garantizar una evaluación integral y efectiva de los enfoques de pronóstico empleados.

Por otra parte, se ha analizado la importancia de los pronósticos para garantizar una integración eficiente de estas fuentes renovables en el sistema eléctrico. El análisis realizado revela que el nivel de aplicación de los pronósticos está estrechamente relacionado con el horizonte de pronóstico definido. En este sentido, los horizontes de muy corto y corto plazo son los que presentan una mayor utilidad para la planeación y operación de la red.

Por último, se han examinado algunas publicaciones relevantes relacionadas con la predicción de energía solar PV y eólica. La estrategia de clasificación propuesta con anterioridad ha resultado esencial para llevar a cabo un análisis efectivo de cada trabajo. Esto ha permitido identificar las principales tendencias, contribuciones y algunas limitaciones de los estudios analizados. Además, se han identificado algunas lagunas de investigación que aún no han sido abordadas con la profundidad requerida y que pueden ser analizadas adecuadamente en el marco de esta investigación.

CAPÍTULO 3. METODOLOGÍA PROPUESTA PARA EL PRONÓSTICO DE ENERGÍA SOLAR PV Y EÓLICA

3.1 Introducción

En este capítulo se presenta la metodología propuesta para el pronóstico de energía solar PV y eólica y se describen los principales componentes que la conforman, tal como se muestra en la Figura 3.1.




Figura 3.1. Estructura general de la metodología propuesta para el pronóstico de energía solar PV y eólica.

El proceso comienza con la adquisición de los datos históricos necesarios en las instalaciones bajo estudio, seguido de una etapa de preprocesamiento y preparación de los datos para mejorar su calidad y consistencia. Luego, se utilizan los datos del conjunto de entrenamiento para llevar a cabo la formulación del modelo de pronóstico, la optimización de sus hiperparámetros más relevantes y, por último, su entrenamiento. Posteriormente, se emplean los datos del conjunto de prueba para evaluar el desempeño del modelo propuesto a través de varias métricas robustas. Además, se compara su rendimiento con el de otros modelos de referencia ampliamente utilizados en este campo de investigación. Si el rendimiento no es

satisfactorio, se procede al reajuste del modelo; para ello, se retorna a la etapa anterior para realizar las modificaciones necesarias.

Por el contrario, si el modelo presenta un buen rendimiento, se procede a la etapa de obtención de pronósticos. En esta etapa, se generan inicialmente los pronósticos determinísticos para el horizonte definido y, a partir de estos resultados, se aplica el método de remuestreo *bootstrap* para obtener pronósticos probabilísticos en forma de intervalos de predicción. Por último, se valida el desempeño del modelo propuesto en escenarios atípicos que pueden presentarse durante la operación en tiempo real. Estos incluyen el fallo temporal de los sensores de medición y la presencia de ruido blanco en los datos. En esta fase, se utiliza la técnica de XAI conocida como RFE para determinar el nivel de importancia de las variables de entrada y su impacto en la salida del modelo. Las restantes secciones de este capítulo están enfocadas en describir los aspectos más relevantes de la metodología propuesta.

3.2 Adquisición de datos

La adquisición de datos representa el primer paso de la metodología propuesta y constituye su base fundamental. En este estudio, los datos utilizados están asociados a instalaciones PV y eólicas y su naturaleza puede ser diversa, como se muestra en la Figura 3.2. Por ejemplo, se pueden recopilar datos meteorológicos de diversas variables (irradiancia solar, temperatura ambiente, humedad relativa, velocidad y dirección del viento, presión atmosférica y densidad del aire, entre otras). Estos datos pueden ser medidos en estaciones meteorológicas ubicadas en las propias plantas de energía o cercanas a ellas, o pueden proceder de servicios meteorológicos especializados. También se pueden utilizar datos de otras variables relevantes asociadas a cada sistema de energía.




Figura 3.2. Representación general del proceso de adquisición de datos de energía solar PV y eólica.

En los sistemas de energía solar es posible obtener mediciones de la temperatura de los paneles y de la potencia PV generada, mientras que en los sistemas de energía eólica se pueden obtener mediciones del

ángulo de paso (*pitch*) de las palas del aerogenerador, la velocidad de giro del rotor y la potencia eólica generada, entre otras. Todos los datos mencionados se miden con una determinada resolución temporal, que depende de las características específicas del equipamiento instalado y de las configuraciones establecidas para cada instalación. En muchos casos, las mediciones presentan resoluciones temporales que van desde uno o varios minutos hasta una hora, aunque en algunos sistemas de monitoreo también pueden encontrarse registros con resoluciones de uno o varios segundos.

Otro aspecto importante está relacionado con la cantidad de datos disponibles. En este sentido, es recomendable recabar la mayor cantidad posible de información, para que la base de datos refleje con mayor fidelidad las variaciones climáticas y estacionales de ambas fuentes de energía. Además, en los modelos de DL, la cantidad de información disponible resulta crucial para garantizar un desempeño exitoso en la tarea asignada. Por otra parte, cuando se utilizan aplicaciones de pronóstico en tiempo real, es necesario contar con los medios adecuados para garantizar un suministro de información actualizada al modelo de pronóstico. Para ello, se pueden aprovechar las potencialidades de los sistemas SCADA, así como de los sistemas de internet de las cosas (*Internet of Things*, IoT), para facilitar este proceso.

3.3 Algoritmo propuesto para el preprocesamiento y la preparación de los datos

El preprocesamiento de los datos resulta fundamental, ya que influye directamente en el rendimiento de los modelos de pronóstico y en la calidad de los resultados obtenidos. En la Figura 3.3 se describe el algoritmo de preprocesamiento y preparación de los datos propuesto en este trabajo. Dicho algoritmo abarca el análisis estadístico y gráfico, la limpieza de los datos y el ajuste de la resolución temporal. También incluye la selección de las características de entrada, la identificación de rezagos, la reestructuración del formato, la división de los datos y, por último, su normalización. A continuación, se presenta una descripción detallada de cada uno de estos aspectos.




Figura 3.3. Principales etapas que conforman el algoritmo propuesto para el preprocesamiento y la preparación de los datos.

3.3.1 Análisis estadístico y gráfico de los datos

Para comprender las principales características de los datos disponibles, es importante realizar un análisis estadístico y gráfico de los mismos. Algunos indicadores estadísticos, como la media, la desviación estándar y los valores máximos y mínimos, aportan información valiosa sobre el estado inicial de los datos y su intermitencia. Además, permiten identificar los límites lógicos y las posibles diferencias de escala entre las variables. Complementariamente, la representación gráfica, por su parte, ayuda a comprender la variación temporal de los datos (horas, días, meses y años) y a identificar tendencias y patrones relevantes para las aplicaciones de pronóstico [15].

3.3.2 Limpieza de los datos

En muchos casos, los datos recopilados presentan problemas derivados de errores en sensores y dispositivos de medición, lo que provoca la aparición de valores atípicos y anomalías. Además, pueden producirse fallos o desconexiones de dichos equipos durante ciertos períodos, lo que da lugar a una pérdida de información y a la presencia de valores ausentes en las series temporales. En estos casos, es fundamental detectar y corregir tales problemas para mejorar la calidad de los datos y, en consecuencia, el rendimiento de los modelos de pronóstico. Es importante señalar que las irregularidades en las mediciones pueden afectar directamente la capacidad del modelo para aprender patrones reales [46]. El algoritmo propuesto para abordar estas dificultades se ilustra en la Figura 3.4.




Figura 3.4. Estructura del algoritmo propuesto para la limpieza de los datos.

En este caso, se definen como valores atípicos aquellas observaciones que se alejan más de tres desviaciones estándar de la media local, calculada mediante una ventana móvil de n elementos. La longitud de la ventana se ajusta dinámicamente teniendo en cuenta el comportamiento específico de cada serie temporal y la variabilidad observada en los datos. Una vez identificados, estos valores se sustituyen mediante interpolación cúbica de Hermite por tramos (*Piecewise Cubic Hermite Interpolating Polynomial*, PCHIP). Este enfoque se caracteriza por mantener la monotonía de la serie, evitando la introducción de oscilaciones poco realistas y garantizando una curva suave que sigue naturalmente la tendencia de los datos.

En cuanto a los valores ausentes, su imputación también se realiza mediante el algoritmo PCHIP. Además, cuando el volumen de datos faltantes es considerable, se procede a eliminar los registros correspondientes para evitar que afecten la calidad de los datos disponibles.

Otro aspecto abordado dentro del algoritmo mencionado es la detección y corrección de valores anómalos. En los datos de energía eólica pueden presentarse valores de potencia nulos para velocidades de viento superiores a la velocidad de corte de entrada del aerogenerador, así como valores elevados de potencia asociados a velocidades de viento reducidas, entre otros casos. De manera análoga, en los datos de energía solar PV pueden observarse valores de potencia nulos con niveles elevados de irradiancia solar, o valores elevados de potencia con irradiancia reducida. La estrategia propuesta se basa en el análisis de gráficos de dispersión de velocidad del viento frente a potencia eólica o irradiancia solar frente a potencia PV, lo que permite identificar las regiones donde se concentran estas observaciones anómalas. Posteriormente, se utiliza la herramienta *Curve Fitting Toolbox* del software MATLAB para obtener la curva de tendencia estimada que mejor se ajusta a los datos disponibles. Para ello, se selecciona el modelo óptimo comparando distintos métodos de ajuste mediante métricas de desempeño como RMSE y R^2 , asegurando así que la estimación se alinee estrechamente con la tendencia central de los datos reales [85]. Finalmente, las anomalías identificadas se corrigen mediante dicha curva, lo que garantiza una estimación físicamente consistente de la potencia a partir de los valores de velocidad del viento o irradiancia solar.

3.3.3 Ajuste de la resolución temporal de los datos

En algunos casos, es necesario ajustar la resolución temporal de los datos para mejorar el desempeño del modelo y adaptarlo al horizonte de pronóstico deseado. Dependiendo de la resolución requerida pueden aplicarse dos enfoques fundamentales, detallados en el *Algoritmo 1* mediante pseudocódigo.

Algoritmo 1: Ajuste de la resolución temporal de los datos

```

1: function nueva_serie = Ajustar_resolucion_temporal (serie_original, resolucion_original, resolucion_deseada)
2:   if resolucion_deseada > resolucion_original then
     % Caso 1: Submuestreo (reducción de resolución temporal)
     tamaño_ventana = resolucion_deseada / resolucion_original;
     num_puntos = floor (length (serie_original) / tamaño_ventana);
     nueva_serie = zeros (1, num_puntos);
     indice = 1;
     for k = 1 to num_puntos do
       datos_ventana = serie_original (indice: indice + tamaño_ventana - 1);
       nueva_serie(k) = mean (datos_ventana);
       indice = indice + tamaño_ventana;
     end for
3:   elseif resolucion_deseada < resolucion_original then
     % Caso 2: Aumento de resolución mediante interpolación PCHIP
     t_original = 1: length (serie_original);
     t_deseado = linspace (1, length (serie_original), length (serie_original) * resolucion_original / resolucion_deseada);
     nueva_serie = interp1 (t_original, serie_original, t_deseado, 'pchip');
4:   else
     % No hay cambio en la resolución temporal
     nueva_serie = serie_original;
   end if
5: end function

```

*Para la implementación del algoritmo se utilizan algunas funciones disponibles en el software MATLAB.

En este contexto, una resolución temporal menor indica intervalos de tiempo más largos entre muestras (menos puntos por unidad de tiempo), mientras que una resolución temporal mayor corresponde a intervalos más cortos (más puntos por unidad de tiempo). El primer enfoque (submuestreo) se emplea cuando la resolución temporal deseada es menor que la original. En este caso, se calcula el promedio de los valores dentro de cada intervalo para reconstruir la serie temporal con la nueva resolución. Esta reducción suaviza los datos y reduce las fluctuaciones, aunque puede implicar la pérdida de información sobre fenómenos de corta duración. El segundo enfoque (sobremuestreo) se utiliza cuando la resolución temporal deseada es mayor que la original. Para ello, se aplica el método de interpolación PCHIP para generar los nuevos puntos de la serie, asegurando la preservación de la tendencia física de los datos. Por último, se recomienda realizar un análisis de sensibilidad para determinar la resolución temporal más adecuada, considerando el horizonte de pronóstico, las características dinámicas de los datos y la arquitectura del modelo implementado.

3.3.4 Selección de las características de entrada al modelo de pronóstico

En conjuntos de datos de alta dimensionalidad, pueden existir variables predictoras irrelevantes o redundantes. Su inclusión puede provocar una degradación en la calidad de los pronósticos y en el rendimiento del modelo, así como un aumento en la complejidad y en el tiempo requerido para su entrenamiento. En este contexto, la aplicación de métodos de FS resulta esencial para garantizar el desarrollo de modelos de pronóstico más simples y robustos. En general, los métodos de FS pueden agruparse en tres categorías principales: métodos de filtro, métodos de envoltura (*wrapper*) y métodos integrados [19], [86]. En la Figura 3.5 se muestra la estructura general del enfoque aplicado en esta investigación para seleccionar las características de entrada al modelo de pronóstico.




Figura 3.5. Estructura general del enfoque propuesto para llevar a cabo el proceso de FS.

Inicialmente, el proceso de FS se realiza mediante un método de tipo filtro, específicamente el análisis de PCC, cuya formulación matemática es [49]:

$$PCC_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.1)$$

donde x representa la variable independiente (predictor); y representa la variable objetivo (potencia PV o eólica); $\bar{x}$ y $\bar{y}$ indican el valor promedio de cada variable; y n corresponde al número total de observaciones.

Este método permite cuantificar la fuerza y la dirección de la relación lineal existente entre cada variable independiente y la variable objetivo (que en este trabajo corresponde a la potencia PV o eólica). Los valores del PCC oscilan en el intervalo de $[-1, 1]$, donde un valor entre 0 y 1 indica una correlación positiva entre

las variables (relación directa), mientras que un valor entre 0 y -1 refleja una correlación negativa (relación inversa). Los valores cercanos a ± 1 indican una fuerte relación lineal entre las variables, ya sea en sentido directo o inverso [87], [88]. El análisis de PCC presenta un bajo costo computacional y proporciona una primera aproximación fácilmente interpretable sobre las relaciones de las variables predictoras. Sin embargo, su principal limitación radica en que asume una relación lineal entre las variables, lo cual no refleja completamente la realidad en problemas de predicción no lineal, como es el caso de la energía solar PV y la eólica.

Con el fin de mejorar la precisión del proceso y superar las limitaciones previamente señaladas, se emplea también un método de FS de tipo integrado. Este se basa en estimar la importancia de los predictores mediante la permutación de las observaciones fuera de la bolsa (*Out-of-Bag*, OOB) de un modelo de bosque aleatorio (RF) (véase *Algoritmo 2*). Su propósito es evaluar la influencia de cada variable predictora en la respuesta del modelo de predicción. En este proceso, un predictor se considera influyente si, al permutar sus valores, se produce una variación significativa en el error del modelo. Por el contrario, si esta permutación genera poco o ningún cambio en dicho error, se considera poco relevante. Una de las principales ventajas de este enfoque es su capacidad para capturar relaciones no lineales y manejar adecuadamente la multicolinealidad entre las variables. Además, permite evaluar de forma conjunta las interacciones entre múltiples variables en la predicción de energía solar PV y eólica, abarcando globalmente todo el conjunto de datos. Otra ventaja importante es su aptitud para analizar variables categóricas, lo cual no es posible con el análisis de PCC, que se limita exclusivamente a variables continuas [89], [90].

Algoritmo 2: Estimación de la importancia del predictor por permutación fuera de la bolsa (OOB) en un RF

```

1: Inicialización: Sea  $R$  un RF con  $T$  aprendices y  $p$  predictores en el conjunto de entrenamiento
2: for  $t = 1$  to  $T$  do:
3:   Identificar el conjunto de observaciones fuera de la bolsa  $OOB_t$  y el subconjunto de predictores utilizados para dividir nodos en el árbol
      $t, s_t \subseteq \{1, \dots, p\}$ 
4:   Estimar el error fuera de la bolsa del árbol  $t$ ,  $\varepsilon_t$ , utilizando  $OOB_t$ 
5:   for cada predictor  $x_j$ ,  $j \in s_t$  do:
6:     Permutar aleatoriamente los valores de  $x_j$  en las observaciones  $OOB_t$ 
7:     Estimar el error del modelo,  $\varepsilon_{tj}$ , utilizando las observaciones  $OOB_t$  con los valores permutados de  $x_j$ 
8:     Calcular la diferencia  $d_{tj} = \varepsilon_{tj} - \varepsilon_t$ 
9:   end for
10: end for
11: for cada predictor  $x_j$ ,  $j = 1, \dots, p$  do:
12:   Calcular la media  $\bar{d}_j$  y la desviación estándar  $\sigma_j$ , de las diferencias  $d_{tj}$  para  $t = 1, \dots, T$ 
13:   La importancia por permutación OOB del predictor  $x_j$  se define como  $VI_j = \bar{d}_j / \sigma_j$ 
14: end for

```

* Los valores de VI_j son adimensionales y reflejan la influencia de cada variable en el modelo.

3.3.5 Identificación de los rezagos y reestructuración del formato de los datos

Para incluir un mayor nivel de información en las variables de entrada y mejorar la precisión de los pronósticos, se recomienda incorporar los rezagos (*lags*) de las series temporales. En este contexto, las

funciones de autocorrelación (*Autocorrelation Function*, ACF) y autocorrelación parcial (*Partial Autocorrelation Function*, PACF) resultan de gran utilidad para identificar relaciones temporales relevantes que favorezcan el pronóstico de la energía solar PV y eólica [52]. Estas funciones permiten detectar dependencias temporales significativas entre observaciones, facilitando la selección de rezagos que aporten información relevante al modelo, sin incluir datos redundantes o irrelevantes que puedan afectar la precisión del pronóstico. La ACF mide el grado de correlación entre las observaciones y_t y y_{t-k} de una serie temporal para $k = 0, \dots, K$, donde y_t representa un proceso estocástico. Por su parte, la PACF estima la correlación entre y_t y y_{t-k} , después de ajustar el efecto lineal de los rezagos intermedios $y_{t-1}, \dots, y_{t-k+1}$. Para obtener una descripción más detallada de ambas funciones se recomienda consultar la referencia [91].

También es importante analizar los aspectos relacionados con la reestructuración del formato de los datos. Para este propósito, se adopta el esquema general descrito en la Figura 3.6. En este esquema, la variable x representa el conjunto de características de entrada al modelo de pronóstico, mientras que $\hat{x}$ denota el valor pronosticado de la potencia PV o eólica. La variable n indica la cantidad de observaciones efectivas utilizadas en el estudio y debe cumplirse que $n \leq N - (l + d)$. En este contexto, N representa el número total de observaciones del conjunto de datos, l la cantidad de rezagos de tiempo considerados y d el número de pasos de tiempo entre los datos de entrada y de salida según el horizonte de pronóstico requerido. Esta condición garantiza que cada vector de entrada cuente con los rezagos necesarios y mantenga una correspondencia correcta con su valor de salida.




Figura 3.6. Esquema de reestructuración de los datos en función de las características de entrada, la salida del modelo y el horizonte de pronóstico.

3.3.6 División de los datos

En la fase previa al entrenamiento de un modelo de pronóstico, es necesario dividir los datos disponibles en dos conjuntos independientes: el conjunto de entrenamiento y el conjunto de prueba. El conjunto de entrenamiento se utiliza para ajustar los parámetros del modelo, permitiéndole aprender las relaciones existentes entre las variables, así como reconocer patrones de comportamiento y tendencias en las series temporales. Dentro de este conjunto, se recomienda reservar una porción más pequeña de los datos (10 %) para realizar la validación del proceso de aprendizaje. Por su parte, el conjunto de prueba se emplea para evaluar la capacidad predictiva y de generalización del modelo frente a nuevos datos no utilizados durante el entrenamiento. El porcentaje de datos asignado a cada conjunto puede variar en función de diversos factores, como la extensión de los datos históricos disponibles y el tipo de modelo utilizado, entre otros. Por ejemplo, cuando se dispone de una base de datos limitada, es recomendable reservar una mayor porción de

los datos para el entrenamiento (90 %) y una menor para la prueba (10 %). En cambio, cuando se cuenta con un volumen de datos relativamente amplio, estos valores pueden ajustarse, siendo común emplear un 75 % de los datos para entrenar el modelo y el 25 % restante para evaluar su desempeño [18].

No obstante, aunque la mayoría de los autores dividen los datos disponibles de acuerdo con los criterios anteriores, este enfoque puede presentar algunas limitaciones. Por ejemplo, los datos de prueba corresponden generalmente a la última parte del conjunto, coincidiendo con una estación del año específica. Esto dificulta una evaluación integral del rendimiento del modelo bajo diferentes condiciones climáticas y estacionales asociadas al comportamiento de las fuentes de energía solar y eólica. Para superar estas limitaciones, en esta investigación se ha implementado una estrategia alternativa, en la cual los datos se dividen en función de los meses del año, como se ilustra en la Figura 3.7. En este caso, el análisis se realiza sobre un conjunto de datos que abarca un período completo de un año. En primer lugar, se selecciona el 90 % de los datos de cada mes (aproximadamente los primeros 27 o 28 días), los cuales se unifican en orden cronológico para conformar el conjunto de entrenamiento. De manera similar, se toma el 10 % restante de los datos de cada mes (aproximadamente los últimos tres días) y se unifican cronológicamente para conformar el conjunto de prueba. Este enfoque permite capturar eficazmente las variaciones estacionales, ya que el modelo se entrena con información de todos los meses mientras conserva la secuencia temporal. Además, asegura que el conjunto de prueba sea representativo de toda la variabilidad climática anual, lo que permite una evaluación más robusta del desempeño del modelo.




Figura 3.7. Estrategia de división de los datos basada en los meses del año.

3.3.7 Normalización de los datos

La normalización es un proceso fundamental cuando los datos presentan diferentes rangos de valores. Desde el punto de vista del entrenamiento, resulta conveniente eliminar las diferencias de escala entre las variables, lo que favorece el rendimiento del modelo de pronóstico y acelera su convergencia [46]. Para este fin, se recomienda utilizar el método de normalización basado en los valores mínimos y máximos, que se expresa como:

$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3.2)$$

donde x_{norm} representa los valores normalizados de la variable; x_i los valores originales registrados; y x_{min} , x_{max} los valores mínimos y máximos observados en el conjunto de entrenamiento, respectivamente.

La aplicación de este método permite escalar los valores de cada variable en el rango $[0, 1]$ y reducir la dispersión de los datos. Además, es importante señalar que los valores mínimo y máximo utilizados en este proceso se obtienen directamente del conjunto de entrenamiento. Luego se utilizan para normalizar ambos conjuntos de datos, evitando de esta manera la fuga de información (*data leakage*). Al concluir la fase de pronóstico, se aplica un proceso inverso para desnormalizar las predicciones, lo que permite la comparación con las mediciones reales o con las predicciones generadas por otros modelos.

3.3.8 Descripción general del algoritmo propuesto para el preprocesamiento y la preparación de los datos

Para ofrecer una descripción lógica y secuencial del algoritmo propuesto para el preprocesamiento y la preparación de los datos (*Algoritmo 3*), se presenta a continuación su pseudocódigo.

Algoritmo 3: Preprocesamiento y preparación de los datos

```

1: Obtener los datos históricos necesarios
2: Realizar un análisis estadístico exploratorio
3: Visualizar los datos para detectar anomalías y tendencias globales
4: Determinar los límites físicos (valores mínimos y máximos permisibles) para cada serie temporal
5: Remover las mediciones fuera de rango:
    for  $i = 1$  to  $\text{length}(\text{serie\_tiempo})$  do
        if  $\text{serie\_tiempo}(i) < \text{valor\_mínimo\_permisible}$  then
             $\text{serie\_tiempo}(i) = \text{valor\_mínimo\_permisible}$ 
        elseif  $\text{serie\_tiempo}(i) > \text{valor\_máximo\_permisible}$  then
             $\text{serie\_tiempo}(i) = \text{valor\_máximo\_permisible}$ 
        end if
    end for
6: Identificar y reemplazar valores atípicos en cada serie temporal:
     $\text{serie\_tiempo} = \text{filloutliers}(\text{serie\_tiempo}, 'pchip', 'movmean', n)$ 
7: Identificar e imputar valores ausentes en cada serie temporal:
     $\text{serie\_tiempo} = \text{fillmissing}(\text{serie\_tiempo}, 'pchip')$ 
8: Detectar y corregir valores anómalos utilizando las curvas de potencia correspondientes
9: Ajustar la resolución temporal requerida para cada conjunto de datos mediante el método descrito en el Algoritmo 1
10: Seleccionar las características de entrada al modelo de pronóstico:
    Calcular el PCC mediante la ecuación (3.1)
    Evaluar la importancia de las variables predictoras utilizando el Algoritmo 2
    Seleccionar como variables de entrada aquellas con alta correlación e importancia
11: Identificar los rezagos significativos de cada serie temporal utilizando las funciones estadísticas ACF y PACF
12: Reestructurar el formato de los datos considerando las variables de entrada y salida, los rezagos seleccionados
    y el horizonte de pronóstico definido
13: Dividir los datos preprocesados en los conjuntos de entrenamiento y prueba
14: Normalizar los datos mediante el método de los valores mínimos y máximos descrito en la ecuación (3.2)

```

Este algoritmo integra todas las etapas descritas previamente y constituye la base de los experimentos presentados en los capítulos siguientes. Su aplicación contribuye a mejorar la calidad de los datos disponibles, así como a incrementar la robustez y la efectividad del modelo de pronóstico propuesto. La

implementación práctica del algoritmo se realiza utilizando algunas funciones disponibles en el *software* MATLAB.

3.4 Formulación de los modelos de pronóstico

El pronóstico de energía solar PV y eólica puede abordarse como un problema de predicción de series temporales, caracterizado por su alta variabilidad, complejidad y naturaleza no lineal. El análisis desarrollado en el Capítulo 2 pone de manifiesto que las ANN y en particular las RNN profundas en sus distintas topologías, constituyen herramientas eficaces para la resolución de este tipo de problemas. En esta sección se presenta la formulación básica de algunas variantes de redes neuronales ampliamente utilizadas en este campo de investigación, comenzando por las RNN simples y avanzando hacia arquitecturas más sofisticadas, como las redes LSTM y BiLSTM.

3.4.1 Redes neuronales recurrentes (RNN)

Las primeras RNN surgieron en la década de 1980, siendo la red de *Hopfield* una de las primeras arquitecturas recurrentes ampliamente estudiadas; no obstante, su enfoque original no estaba orientado al modelado secuencial [92]. En términos generales, las RNN conforman una familia de ANN diseñadas específicamente para el procesamiento de datos secuenciales. Por ello, se consideran herramientas eficaces para resolver problemas en los que existe una dependencia temporal entre las observaciones. En las redes neuronales tradicionales de tipo FFNN, se asume que las entradas y las salidas son independientes entre sí. Sin embargo, esta suposición no se cumple en muchas aplicaciones prácticas, lo que puede limitar la capacidad de generalización de dichos modelos. Por el contrario, las RNN poseen una memoria interna que permite incorporar información de estados previos en el procesamiento de instantes temporales posteriores. Este mecanismo se repite para cada elemento de la secuencia, lo que hace que las RNN sean especialmente adecuadas para el modelado de datos temporales [93], [94]. La Figura 3.8 muestra la estructura básica de una RNN, donde x_t , y_t y h_t representan la entrada, la salida y el estado oculto de la red en el paso de tiempo t , respectivamente.




Figura 3.8. Estructura básica de una RNN [93].

El término h_t , también denominado estado oculto o memoria de la RNN, se determina mediante la ecuación (3.3) [95]:

$$h_t = f(W_{xh} \cdot x_t + W_{hh} \cdot h_{t-1} + b_h) \quad (3.3)$$

donde W_{xh} denota la matriz de pesos entre la capa de entrada y la capa oculta; W_{hh} corresponde a la matriz de pesos recurrentes entre los estados ocultos sucesivos; b_h representa el vector de sesgos; y f es una función de activación de tipo no lineal.

La función de activación le permite al modelo capturar relaciones no lineales presentes en los datos de entrenamiento. Entre las más utilizadas se encuentran la sigmoide (*sigmoid*, σ), la tangente hiperbólica (*hyperbolic tangent*, $\tanh$) y la unidad lineal rectificadora (*Rectified Linear Unit*, *ReLU*) [95]. Las funciones de activación mencionadas se definen como:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.4)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.5)$$

$$ReLU(x) = \begin{cases} x, & \text{si } x > 0 \\ 0, & \text{si } x \leq 0 \end{cases} \quad (3.6)$$

Las funciones σ y $\tanh$ presentan transiciones suaves y están acotadas en los intervalos $[0, 1]$ y $[-1, 1]$, respectivamente. Por su parte, la función *ReLU* no está acotada superiormente y su derivada no está definida cuando $x = 0$, aunque en la práctica se emplea un subgradiente en dicho punto, lo que permite su uso en algoritmos de optimización basados en gradiente.

Una vez definida la arquitectura de la red neuronal y la función de activación, es necesario estimar los parámetros del modelo que mejor se ajusten a los datos de entrenamiento. Este proceso se lleva a cabo mediante técnicas de optimización cuyo objetivo es minimizar una función de pérdida (L). En problemas de regresión, una de las funciones de pérdida más utilizadas es el error cuadrático medio (*Mean Square Error*, *MSE*), definido como [93]:

$$L = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.7)$$

donde y_i y $\hat{y}_i$ representan los valores reales y las predicciones generadas por la RNN, respectivamente; y n representa el número total de observaciones.

A pesar de sus ventajas, las RNN simples presentan una capacidad de aprendizaje limitada cuando se enfrentan a problemas de predicción que implican secuencias temporales largas. A diferencia de las ANN tradicionales, que utilizan conjuntos de pesos distintos en cada capa, las RNN comparten los mismos pesos a lo largo del tiempo. Como resultado, el gradiente de error (es decir, la derivada parcial de la función de pérdida con respecto a los parámetros del modelo) en cada instante de tiempo depende del error acumulado en todos los pasos anteriores. Este proceso se conoce como retropropagación a través del tiempo (*Backpropagation Through Time*, *BPTT*). En este contexto, al considerar las contribuciones de cada paso temporal al cálculo del gradiente, pueden surgir dos problemas fundamentales: el desvanecimiento del

gradiente y la explosión del gradiente [94], [95]. En el primer caso, los gradientes se atenúan progresivamente a medida que se propagan por las capas de la red durante el proceso de retropropagación. Como consecuencia, los ajustes de los pesos en las capas ocultas se vuelven mínimos o incluso nulos, lo que conduce a una convergencia muy lenta o inexistente, reduciendo la capacidad de generalización del modelo y aumentando los errores de predicción. En el segundo caso, los gradientes crecen exponencialmente a medida que se propagan hacia atrás por las capas de la red. Este fenómeno resulta especialmente crítico cuando los pesos tienen valores grandes, debido a la acumulación multiplicativa de gradientes a lo largo de los pasos temporales. La explosión del gradiente puede provocar inestabilidad durante el entrenamiento, problemas de convergencia, saturación de las funciones de activación y, en consecuencia, un aprendizaje deficiente [94], [96].

3.4.2 Redes neuronales LSTM

Con el objetivo de superar las limitaciones de las RNN tradicionales, los investigadores *Sepp Hochreiter* y *Jürgen Schmidhuber* propusieron en 1997 el modelo de red neuronal recurrente LSTM [97]. Desde entonces, las redes LSTM han demostrado una notable efectividad en múltiples aplicaciones, como el procesamiento de lenguaje natural, el reconocimiento de voz, la detección de anomalías y la predicción de series temporales, entre muchas otras. En las RNN tradicionales, el elemento principal es la neurona artificial, mientras que en las redes LSTM el elemento básico es la celda de memoria. La Figura 3.9 muestra la estructura básica de una celda de memoria del modelo LSTM.




Figura 3.9. Estructura básica de una celda de memoria del modelo LSTM [98].

Cada celda de memoria presenta en su arquitectura tres compuertas principales, denominadas compuerta de entrada (i_t), compuerta de salida (o_t) y compuerta de olvido (f_t). Las compuertas de entrada y salida controlan la información que entra y sale de la celda de memoria. Por su parte, la compuerta de olvido determina si la información disponible debe ser olvidada o retenida durante el proceso de aprendizaje, regulando así el flujo de información en el estado interno de la celda. Estas características le permiten al modelo LSTM mitigar significativamente los problemas de desvanecimiento y explosión de los gradientes durante el entrenamiento. Al mismo tiempo, lo convierten en una herramienta poderosa para capturar dependencias a largo plazo en series temporales y secuencias de datos [97], [98].

De manera general, el funcionamiento de un modelo LSTM puede describirse mediante las ecuaciones siguientes [98]:

$$\tilde{C}_t = \tanh(W_{xc} \cdot x_t + W_{hc} \cdot h_{t-1} + b_c) \quad (3.8)$$

$$i_t = \sigma(W_{xi} \cdot x_t + W_{hi} \cdot h_{t-1} + b_i) \quad (3.9)$$

$$f_t = \sigma(W_{xf} \cdot x_t + W_{hf} \cdot h_{t-1} + b_f) \quad (3.10)$$

$$o_t = \sigma(W_{xo} \cdot x_t + W_{ho} \cdot h_{t-1} + b_o) \quad (3.11)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (3.12)$$

$$h_t = o_t \odot \tanh(C_t) \quad (3.13)$$

donde W_{xc} , W_{xi} , W_{xf} , W_{xo} , W_{hc} , W_{hi} , W_{hf} , W_{ho} y b_c , b_i , b_f , b_o representan los pesos y sesgos del modelo LSTM, respectivamente; h_{t-1} y h_t son los estados ocultos en los instantes de tiempo anterior y actual, respectivamente; C_{t-1} y C_t representan la celda de memoria del paso de tiempo anterior y actual, respectivamente; $\tilde{C}_t$ es la celda de memoria candidata; x_t denota la entrada del momento actual; y el símbolo $\odot$ representa una multiplicación elemento a elemento (producto de Hadamard).

3.4.3 Redes neuronales BiLSTM

En las redes LSTM, la información se transmite en una dirección y el procesamiento de la secuencia de datos se realiza hacia adelante. Por su parte, las redes BiLSTM constituyen una extensión de las redes LSTM en las que el procesamiento se efectúa de manera bidireccional (hacia adelante y hacia atrás). Esta particularidad les permite extraer con mayor eficacia las características implícitas en los datos, aprender con mayor profundidad las relaciones temporales y obtener un mejor rendimiento en la predicción de series temporales complejas y no lineales [99]. Por estas razones, las redes BiLSTM se consideran apropiadas para el problema de pronóstico abordado en este trabajo.

Cada unidad BiLSTM cuenta con dos estados ocultos que capturan la información pasada y futura de la secuencia de datos, como se muestra en la Figura 3.10.




Figura 3.10. Estructura básica del modelo BiLSTM.

En cada instante de tiempo t , se calcula simultáneamente el vector oculto LSTM en dirección hacia adelante ($\vec{h}_t$) y hacia atrás ($\tilde{h}_t$). Posteriormente, se establece un flujo de información que se propaga desde la capa de entrada, a través de la capa oculta, hasta llegar a la capa de salida. Finalmente, el vector de salida (y_t) se determina mediante la combinación de los estados ocultos obtenidos en ambas direcciones [99], [100].

Considerando los elementos anteriores, el funcionamiento del modelo BiLSTM puede representarse mediante las siguientes ecuaciones [100]:

$$\vec{h}_t = LSTM(x_t, \vec{h}_{t-1}) \quad (3.14)$$

$$\tilde{h}_t = LSTM(x_t, \tilde{h}_{t+1}) \quad (3.15)$$

$$y_t = W_{\vec{h}_y} \cdot \vec{h}_t + W_{\tilde{h}_y} \cdot \tilde{h}_t + b_y \quad (3.16)$$

donde $LSTM(\cdot)$ representa la función de una red LSTM; $W_{\vec{h}_y}$ y $W_{\tilde{h}_y}$ son los pesos del modelo en la dirección hacia adelante y hacia atrás, respectivamente; x_t y y_t representan la entrada y la salida en el instante de tiempo t ; y b_y corresponde al sesgo de la capa de salida.

3.5 Optimización de hiperparámetros

El ajuste adecuado de los hiperparámetros se considera un aspecto clave para construir modelos eficaces de ML y DL, así como para garantizar un desempeño favorable durante la etapa de entrenamiento. Este proceso no solo mejora considerablemente el rendimiento de los distintos tipos de modelos, sino que también reduce el tiempo requerido para su desarrollo. Además, favorece la obtención de soluciones más rápidas, eficientes y reproducibles [101], [102], [103]. En general, el término hiperparámetro se refiere a un conjunto de parámetros que no se actualizan durante el proceso de entrenamiento [103], [104]. El ajuste manual de hiperparámetros es un método tradicional que ha sido ampliamente utilizado para realizar esta tarea. Sin embargo, requiere una comprensión profunda del funcionamiento de cada modelo y puede resultar ineficaz en problemas complejos, especialmente aquellos que involucran múltiples hiperparámetros con relaciones no lineales. Estas limitaciones han motivado el desarrollo de diversos métodos que permiten realizar la optimización de hiperparámetros (HPO) de forma automática [105], [106]. En un contexto más amplio, el concepto de HPO puede entenderse como el último paso de la etapa de diseño de un modelo y, al mismo tiempo, el punto de partida del proceso de entrenamiento [104].

3.5.1 Tipos de hiperparámetros y su importancia

En el campo de las redes neuronales profundas (*Deep Neural Networks*, DNN), los hiperparámetros pueden clasificarse en dos grupos principales: aquellos utilizados en la etapa de diseño y los correspondientes a la etapa de entrenamiento. El primer grupo se relaciona directamente con la estructura de la red neuronal y determina tanto la complejidad del modelo como su capacidad de aprendizaje. El segundo grupo influye en la velocidad de convergencia, el proceso de aprendizaje y el rendimiento general del modelo [101], [104].

Los hiperparámetros utilizados en la etapa de diseño se refieren fundamentalmente a la cantidad de capas ocultas y al número de neuronas en dichas capas [104], como se muestra en la Figura 3.11.




Figura 3.11. Representación de una red neuronal que contiene dos capas ocultas con cuatro neuronas en cada capa.

A continuación, se describen brevemente las principales características de estos hiperparámetros:

- El número de capas ocultas se considera un hiperparámetro crítico en la definición de la arquitectura de una red neuronal. Un mayor número de capas ocultas permite que la red aprenda representaciones más complejas de los datos de entrenamiento, lo que puede mejorar la precisión del modelo. Sin embargo, también incrementa la carga computacional y la complejidad del entrenamiento [104], [107].
- El número de neuronas en las capas ocultas también influye significativamente en el rendimiento de una red neuronal. Un valor reducido de este hiperparámetro da lugar a un entrenamiento deficiente y una pobre capacidad de generalización. Por el contrario, un valor demasiado grande puede provocar problemas de sobreajuste (*overfitting*) y tiempos de entrenamiento elevados [104], [107].

Dentro de los hiperparámetros utilizados en la etapa de entrenamiento se encuentran el algoritmo de optimización (también conocido como optimizador), la tasa de aprendizaje inicial, la tasa de abandono, el factor de regularización L_2 , el tamaño del minilote y el número de épocas de entrenamiento, entre otros [104]. A continuación, se describen brevemente estos hiperparámetros:

- El algoritmo de optimización es fundamental para minimizar la tasa de error durante el entrenamiento, mejorar la precisión del modelo y acelerar la convergencia. Entre los algoritmos de optimización más empleados para el entrenamiento de DNN se encuentran el descenso del gradiente estocástico con impulso (*Stochastic Gradient Descent with momentum*, SGDM), la propagación de la media cuadrática (*Root Mean Square propagation*, RMSProp) y la estimación adaptativa de momentos (*Adaptive Moment Estimation*, Adam) [101]. El algoritmo SGDM mejora la convergencia del SGD estándar mediante el cálculo de los promedios ponderados exponencialmente de los gradientes. La inclusión del término de impulso (β) ayuda a dirigir el descenso del gradiente en la dirección correcta y a reducir la oscilación. Por su parte, el algoritmo RMSProp ajusta dinámicamente el tamaño del paso según la magnitud del gradiente: cuando el gradiente es grande, disminuye el tamaño del paso y viceversa [103], [104]. Mientras tanto, el algoritmo Adam combina

las ventajas de SGDM y RMSProp para obtener una alta eficiencia en el entrenamiento de DNN. Este algoritmo agrega una corrección de sesgo e impulso a RMSProp, lo que le permite superar su desempeño en la última etapa de la optimización. Además, conserva un promedio decreciente exponencial de los gradientes pasados al igual que SGDM [104], [108].

- La tasa de aprendizaje (*learning rate*) controla el tamaño del paso en la dirección del gradiente en cada iteración, favoreciendo la convergencia de la función objetivo. Una tasa de aprendizaje muy elevada puede acelerar el proceso de entrenamiento, pero también puede generar oscilaciones alrededor de un mínimo local o incluso impedir la convergencia. Por el contrario, una tasa de aprendizaje muy pequeña conduce a una convergencia muy lenta y a un aumento del tiempo de entrenamiento. Por lo tanto, se recomienda utilizar una tasa de aprendizaje adecuada que garantice la convergencia en un tiempo razonable [101].
- La tasa de abandono (*dropout*) regula la probabilidad de eliminar aleatoriamente ciertas neuronas durante el entrenamiento, como se ilustra en la Figura 3.12. Su función está encaminada a prevenir el sobreajuste y a aumentar la robustez del modelo. En general, una tasa de abandono muy grande simplifica demasiado el modelo, mientras que un valor muy pequeño puede tener un efecto despreciable [104].




Figura 3.12. Estructura de una red neuronal: (a) Antes de aplicar el *dropout* y (b) Después de aplicar el *dropout*.

- La regularización L_2 (regularización *Ridge* o norma L_2) es otro de los métodos aplicados durante el entrenamiento de redes neuronales para reducir la complejidad y los problemas de sobreajuste. Se basa en la penalización de la suma de los cuadrados de los pesos, regulada por el hiperparámetro (λ). Si el valor de λ es muy alto, la DNN puede volverse demasiado simple, ya que muchos pesos se acercan a cero. Por el contrario, si el valor de λ es muy bajo, su efecto regularizador resulta insignificante [104].
- El tamaño del minilote (*mini-batch size*) se refiere al número de ejemplos utilizados para entrenar la red en cada iteración. Un valor pequeño hace que la red tenga una pequeña cantidad de datos en su memoria. En estas condiciones, el entrenamiento es más rápido y la respuesta del modelo puede ser más inestable. Sin embargo, si el tamaño del minilote tiene un valor grande, se produce un efecto contrario [101].
- El número de épocas de entrenamiento indica la cantidad de pases completos del conjunto de datos de entrenamiento a través del modelo. Un valor muy bajo puede conducir a un rendimiento

deficiente, mientras que un valor demasiado alto puede provocar sobreajuste y elevados tiempos de entrenamiento. Se recomienda ajustar este hiperparámetro de forma gradual, aumentando su valor hasta que la precisión en el conjunto de validación comience a disminuir, lo que sugiere un posible sobreajuste del modelo. En estos casos, puede aplicarse un mecanismo de parada temprana (*early stopping*), que interrumpe el entrenamiento cuando el error en el conjunto de validación deja de disminuir después de un número determinado de épocas consecutivas [109].

3.5.2 Métodos para la optimización de hiperparámetros

Los métodos de HPO tienen como objetivo encontrar la configuración óptima de los hiperparámetros de un modelo dentro de un espacio de búsqueda determinado. Este escenario representa un problema de optimización altamente complejo, con múltiples restricciones, que en muchos casos involucra funciones objetivo no convexas, no diferenciables y no lineales. Además, los hiperparámetros pueden ser de distintos tipos, lo que incrementa aún más la dificultad del proceso. Por ejemplo, pueden ser continuos (como la tasa de aprendizaje, la tasa de abandono o el factor de regularización L_2), discretos (como el número de capas y neuronas ocultas, el tamaño del minilote o el número de épocas de entrenamiento) o categóricos (como el algoritmo de optimización). Estas características aumentan la complejidad de un problema ya difícil por naturaleza. Por lo tanto, se requieren métodos de optimización eficientes que puedan adaptarse a estas condiciones y superar las limitaciones mencionadas [102], [105].

En la literatura se han propuesto diversos métodos para la HPO, cada uno con sus propias ventajas y limitaciones. Entre los más utilizados se encuentran la búsqueda en cuadrícula (GS), la búsqueda aleatoria (*Random Search*, RS), los algoritmos metaheurísticos, los algoritmos de optimización de multifidelidad (*Multi-fidelity Optimization Algorithm*, MFOA) y la optimización bayesiana (BO) [74]-[79]. Las principales características de estos métodos se describen a continuación:

- La GS es un método de fuerza bruta que evalúa todas las posibles combinaciones de hiperparámetros dentro de una cuadrícula predefinida por el usuario, como se muestra en la Figura 3.13a. Este método resulta muy básico y es ampliamente utilizado por su simplicidad y facilidad de implementación. Sin embargo, presenta algunas limitaciones importantes, por ejemplo, no aprovecha la información sobre las regiones del espacio de búsqueda con mejor rendimiento. Además, resulta ineficiente en problemas de optimización con múltiples hiperparámetros y espacios de búsqueda extensos, debido a que el costo computacional se incrementa exponencialmente [101], [104].
- La RS se considera una alternativa más eficiente que la GS, ya que selecciona aleatoriamente los puntos del espacio de búsqueda a evaluar, como se muestra en la Figura 3.13b. Este enfoque puede ser más eficiente en términos de precisión y costo computacional. No obstante, al carecer de un criterio inteligente de muestreo, introduce una gran variabilidad en los resultados y puede realizar evaluaciones innecesarias en regiones poco prometedoras del espacio de búsqueda [103], [104].




Figura 3.13. Comparación de la exploración del espacio de búsqueda mediante: (a) GS y (b) RS [104]. *(En este caso las curvas en el lado izquierdo y en la parte superior de cada figura representan la exactitud del modelo en función de cada dimensión de búsqueda).

- Los algoritmos metaheurísticos se inspiran principalmente en procesos naturales, biológicos o comportamientos colectivos y tienen la capacidad de resolver problemas de optimización altamente complejos. Entre los más utilizados en la HPO se encuentran el algoritmo genético (*Genetic Algorithm*, GA) y la optimización por enjambre de partículas (*Particle Swarm Optimization*, PSO), entre otros [101]. El GA identifica combinaciones de hiperparámetros con buen rendimiento en cada generación y las transmite a la siguiente hasta alcanzar una solución óptima. Su principal limitación radica en la necesidad de ajustar un conjunto adicional de hiperparámetros (como el tamaño de la población, la tasa de cruzamiento, la tasa de mutación y la función de aptitud), lo que puede hacer más compleja su configuración [103], [110]. Por su parte, el algoritmo PSO utiliza un grupo de partículas que se desplazan de forma semialeatoria por el espacio de búsqueda. Para identificar la solución óptima, este algoritmo se basa en la cooperación y el intercambio de información entre las partículas individuales del grupo. En general, PSO presenta una alta velocidad de convergencia y buena robustez en problemas de HPO con espacios de búsqueda de alta dimensión. No obstante, uno de sus inconvenientes es que requiere una inicialización adecuada de la población para evitar la convergencia hacia mínimos locales, especialmente cuando se optimizan hiperparámetros discretos [101], [111].
- Los MFOA resultan útiles para abordar las limitaciones de tiempo y recursos computacionales en la HPO. En estos métodos, se utilizan subconjuntos de los datos originales para realizar evaluaciones de baja y alta fidelidad. Las evaluaciones de baja fidelidad se efectúan sobre subconjuntos relativamente pequeños, lo que reduce el costo computacional, aunque con un rendimiento predictivo más limitado. En cambio, las evaluaciones de alta fidelidad se realizan sobre subconjuntos de datos más grandes y ofrecen una mayor precisión, aunque con un mayor costo computacional. A lo largo del proceso, el algoritmo descarta las configuraciones de hiperparámetros con bajo rendimiento después de cada ronda de evaluación. Solo las configuraciones prometedoras se evalúan posteriormente utilizando el conjunto completo de datos de entrenamiento. Entre los métodos de multifidelidad más conocidos se encuentran los algoritmos basados en bandidos, como el hiperbanda (*Hyperband*, HB) y la reducción sucesiva asíncrona (*Asynchronous Successive Halving*, ASHA). No obstante, su principal limitación radica en que el subconjunto de datos

seleccionado aleatoriamente debe ser altamente representativo del conjunto total de entrenamiento para garantizar resultados fiables [101], [104], [106].

- La BO resulta adecuada en problemas de alta dimensionalidad y con funciones objetivo costosas de evaluar, como ocurre en la HPO de modelos de DL. El objetivo de este método es encontrar la solución del problema de optimización con el menor número posible de evaluaciones. Para esto se basa en el teorema de Bayes y utiliza dos elementos fundamentales: el modelo de probabilidad sustituto y la función de adquisición. La combinación de ambos elementos le otorga a la BO una naturaleza adaptativa y probabilística. Además, le permite encontrar soluciones eficientes en el espacio de búsqueda con una menor cantidad de evaluaciones de la función objetivo y adaptarse a recursos computacionales limitados. Su principal limitación radica en la dificultad para paralelizar el proceso debido a su carácter secuencial. Sin embargo, las versiones modernas del algoritmo han incorporado diversas estrategias para superar esta restricción [104], [112].

En las secciones anteriores se ha explicado que los modelos de pronóstico propuestos en este trabajo están basados en DNN de naturaleza recurrente, específicamente redes BiLSTM. En este tipo de redes es necesario ajustar varios hiperparámetros con espacios de búsqueda diversos, por lo que se requieren métodos eficientes y flexibles para llevar a cabo esta optimización. Diversos estudios han demostrado que los enfoques de HPO basados en algoritmos metaheurísticos, algoritmos de multifidelidad y BO, pueden ofrecer un rendimiento superior frente a otros métodos convencionales. Por ejemplo, las referencias [101], [102], [105] y [113] presentan comparaciones rigurosas entre distintos métodos de HPO aplicados a diferentes conjuntos de datos y modelos (incluidos modelos de ML y DL), destacando la eficacia de la BO en este tipo de tareas. En función de estos antecedentes, así como de los resultados experimentales obtenidos en el marco de esta investigación, se selecciona el algoritmo de BO para realizar la HPO del modelo BiLSTM. A continuación, se describe su funcionamiento general y sus principales características.

Para el caso de estudio que se presenta, el objetivo de la BO es encontrar una combinación de hiperparámetros que minimice una función objetivo definida sobre un espacio de búsqueda finito, en el cual se establece un límite inferior y superior para cada hiperparámetro [18], [101]. Este problema de optimización puede formularse como:

$$z^* = \underset{z \in Z}{\operatorname{argmin}} f(z) \quad (3.17)$$

donde Z representa el espacio de búsqueda definido para los hiperparámetros; z denota la combinación de hiperparámetros dentro de ese espacio; $f(z)$ corresponde a la función objetivo del problema de optimización; y z^* indica la combinación óptima de hiperparámetros.

El funcionamiento básico de la BO puede resumirse mediante los pasos siguientes [104], [105]:

- 1) Crear un modelo de probabilidad sustituto de la función objetivo.
- 2) Obtener el conjunto de hiperparámetros con mejor desempeño en el modelo de probabilidad sustituto.
- 3) Calcular la función de adquisición a partir del modelo sustituto actual.
- 4) Evaluar los hiperparámetros en la función objetivo.

- 5) Actualizar el modelo de probabilidad sustituto con los nuevos resultados.
- 6) Repetir los pasos 2-5 hasta que se cumpla algún criterio de parada (por ejemplo, el número máximo de iteraciones o el tiempo de ejecución).

Una de las ventajas de la BO es que determina los puntos de evaluación futuros a partir de los resultados obtenidos previamente. Como se ha mencionado, este proceso se basa en dos componentes esenciales: el modelo de probabilidad sustituto y la función de adquisición. El modelo de probabilidad sustituto aproxima la función objetivo mediante una distribución de probabilidad basada en las observaciones recogidas hasta el momento. Para ello, se aplica la regla de Bayes, empleando una distribución previa (*a priori*) que representa la creencia inicial sobre la función objetivo, la cual se actualiza a una distribución posterior (*a posteriori*) a medida que se incorporan nuevos datos [18], [105]. Este proceso se describe mediante la ecuación (3.18):

$$P(loss|D) \propto P(D|loss) \cdot P(loss) \quad (3.18)$$

donde $P(loss)$, $P(loss|D)$ y $P(D|loss)$ representan la distribución previa, la distribución posterior y una función de verosimilitud, respectivamente. En este caso, *loss* corresponde al valor de la función objetivo $f(z)$ evaluada para una determinada configuración de hiperparámetros.

En la BO se pueden utilizar varios tipos de modelos de probabilidad sustituto, entre los que se incluyen el proceso gaussiano (*Gaussian Process*, GP), el estimador de árbol Parzen (*Tree Parzen Estimator*, TPE) y el bosque aleatorio (RF). Esto da lugar a tres variantes comunes del método: BO-GP, BO-TPE y BO-RF. En general, el modelo de probabilidad sustituto basado en GP es uno de los más utilizados debido a su capacidad para proporcionar predicciones con incertidumbre bien calibrada [103], [105].

Por su parte, la función de adquisición determina el siguiente punto a evaluar. Esta función se ajusta cuidadosamente para lograr un equilibrio entre la exploración del espacio de búsqueda y la explotación de los resultados obtenidos, como se ilustra en la Figura 3.14. La exploración se orienta al muestreo de nuevas configuraciones de hiperparámetros en regiones aún no exploradas. En cambio, la explotación se encarga de muestrear configuraciones prometedoras, basadas en las observaciones anteriores [101], [104].




Figura 3.14. Representación del comportamiento de la BO orientada hacia: (a) Exploración (alta incertidumbre) y (b) Explotación (en regiones prometedoras) [104]. *(El área sombreada indica el nivel de incertidumbre del modelo sustituto).

Existen diferentes tipos de funciones de adquisición, entre las que se pueden mencionar el límite inferior de confianza (*Lower Confidence Bound*, LCB), la búsqueda predictiva de la entropía (*Predictive Search of*

Entropy, PSE) y la mejora esperada (*Expected Improvement*, EI), entre otras. La función de adquisición EI ha demostrado un buen desempeño y es ampliamente utilizada en la práctica [104], [113]. En general, las funciones de adquisición evalúan la utilidad de un punto x con base en una distribución posterior Q . En el caso de la función EI, se evalúa la cantidad de mejora esperada en la función objetivo, ignorando los valores que no producen una mejora respecto al mejor valor observado. Luego, el punto con el mayor valor de mejora esperada se selecciona como el siguiente punto a evaluar. Este enfoque permite que la BO combine de manera eficiente la exploración de nuevas regiones del espacio de búsqueda con la explotación de regiones prometedoras, lo que facilita la convergencia hacia la solución óptima del problema [102]. La formulación matemática de esta función de adquisición se puede representar como:

$$EI(x, Q) = E_Q \left[\max \left(0, \mu_Q(x_{best}) - f(x) \right) \right] \quad (3.19)$$

donde x_{best} representa la ubicación correspondiente al valor más bajo de la media posterior y $\mu_Q(x_{best})$ es el valor más bajo de la media posterior.

Además, se han propuesto otras versiones más avanzadas y eficientes de funciones de adquisición derivadas de EI, como la mejora esperada por segundo (*Expected Improvement Per Second*, EIPS). Esta función de adquisición incorpora otro modelo sustituto, cuyo objetivo es establecer un equilibrio entre el tiempo de ejecución requerido para evaluar cada configuración de hiperparámetros y la mejora esperada [104], [106].

La Figura 3.15 describe los aspectos fundamentales que intervienen en el proceso de HPO mediante el algoritmo de BO. Una cuestión importante que se debe destacar es lo relacionado con la definición del espacio de búsqueda para cada hiperparámetro. En este sentido, resulta conveniente establecer ciertos límites dentro de los cuales se lleva a cabo la exploración. De esta manera se establece una guía inicial sobre los posibles valores de los hiperparámetros y se evita que la optimización se desvíe hacia valores extremos o no deseados. Además, al restringir el espacio de búsqueda, se reduce el tiempo de ejecución del algoritmo y su costo computacional. En cuanto a la función objetivo, para problemas de regresión es común utilizar métricas como el MSE o el RMSE [15], [18].




Figura 3.15. Principales aspectos que intervienen en el proceso de HPO mediante el algoritmo de BO.

3.6 Modelos de referencia utilizados para la comparación

Para evaluar la capacidad predictiva del modelo propuesto (BiLSTM-BO) se considera apropiado comparar su desempeño con otros modelos de referencia ampliamente utilizados en el ámbito del

pronóstico. Para ello, se seleccionan tres enfoques representativos: una red neuronal MLP, un modelo SVR y un modelo de persistencia. Los principales hiperparámetros de los modelos MLP y SVR también se ajustan mediante BO, con el objetivo de asegurar una comparación justa y equilibrada. A continuación, se describen brevemente las principales características de los modelos seleccionados.

3.6.1 Modelo MLP

Las redes neuronales MLP son un tipo de red neuronal de alimentación hacia adelante (*feedforward*) que puede contener tres o más capas de neuronas, denominadas: capa de entrada, capa(s) oculta(s) y capa de salida. Las neuronas de las distintas capas se interconectan mediante conexiones que tienen asignado un valor numérico modificable llamado peso. La Figura 3.16 muestra un esquema típico de una red neuronal MLP, compuesta por una capa de entrada, una capa oculta y una capa de salida. En este tipo de modelo se utilizan funciones de activación no lineales y diferenciables para las neuronas ocultas, lo que le otorga a la red la capacidad necesaria para aprender las relaciones no lineales entre los datos de entrada y salida. En el caso de la capa de salida, si la red se emplea para resolver problemas de regresión, generalmente se aplica una función de activación de tipo lineal. Además, es importante mencionar que el entrenamiento de este tipo de redes se realiza comúnmente mediante el algoritmo de retropropagación del error (*Backpropagation*, BP), que ajusta los pesos sinápticos con base en el error cometido en la salida [22], [30].




Figura 3.16. Representación esquemática simplificada de una red neuronal MLP.

El procesamiento que realiza cada neurona con la información que recibe consiste en generar un valor de salida a partir de una combinación lineal de sus entradas [49]. Este comportamiento se describe como:

$$y_i = f_i \left(\sum_{j=1}^n w_{ij} \cdot x_j + \theta_i \right) \quad (3.20)$$

donde y_i representa el valor de salida de la neurona i ; f_i corresponde a la función de activación; w_{ij} indica el peso de la conexión entre las neuronas i y j ; x_j denota el valor de la entrada j (o la salida de otra neurona j); y θ_i es el umbral o sesgo de la neurona i .

3.6.2 Modelo SVR

El modelo SVM se considera un enfoque de ML supervisado ampliamente utilizado para resolver problemas de clasificación y regresión. En este último caso, se emplea la variante conocida como SVR. Para obtener predicciones mediante SVR, es necesario transformar los datos de entrada a un espacio de

características de mayor dimensión, posiblemente implícito, con el objetivo de facilitar la separación o aproximación funcional en problemas no lineales. Esta transformación se logra mediante la aplicación de una función de núcleo (*kernel*), siendo las más comunes la lineal, la polinomial y la de base radial [22], [30]. La función de núcleo de base radial (RBF) es ampliamente utilizada y su formulación matemática es la siguiente [114]:

$$K(x_1, x_2) = \exp\left(-\frac{\|x_1 - x_2\|^2}{2 \cdot \sigma^2}\right) \quad (3.21)$$

donde $K(x_1, x_2)$ denota la función de núcleo aplicada sobre las variables de entrada; $\|x_1 - x_2\|$ corresponde a la distancia euclidiana entre dos muestras; y σ representa un parámetro que controla el ancho del núcleo y está relacionado con la varianza.

También es necesario definir una función de pérdida para medir las diferencias entre las predicciones y los valores reales. En el modelo SVR se introduce además un margen de tolerancia (ϵ) en forma de tubo alrededor de la función objetivo, lo que permite aceptar pequeños errores en las predicciones sin penalización. En este contexto, los vectores de soporte corresponden a las muestras que se encuentran en los límites de dicho tubo o fuera de él. Estas muestras son las únicas que contribuyen a definir la forma de la función de regresión (ver Figura 3.17). Este modelo se considera una herramienta efectiva para abordar problemas de regresión complejos y no lineales [22].




Figura 3.17. Representación esquemática simplificada del modelo SVR para la predicción de la potencia PV ($\hat{P}$) en función del núcleo aplicado a la irradiancia $\phi(I)$ [22].

3.6.3 Modelo de persistencia

El modelo de persistencia asume que las condiciones observadas en el instante de tiempo actual (t) persisten en el instante de tiempo futuro ($t + h$), de manera que [48]:

$$\hat{y}_{t+h} = y_t \quad (3.22)$$

donde $\hat{y}_{t+h}$ representa el valor pronosticado para el horizonte h y y_t corresponde al valor medido de la variable de interés en el instante actual.

Este modelo de referencia o de línea base es ampliamente utilizado en los pronósticos de energía solar PV y eólica, sobre todo para horizontes de predicción de muy corto plazo. No obstante, es importante

mencionar que, debido a su simplicidad, la calidad de sus predicciones decrece significativamente a medida que se incrementa el horizonte de pronóstico [48].

3.7 Implementación de los modelos de pronóstico

La implementación de los modelos de pronóstico se basa en los resultados obtenidos durante el preprocesamiento de los datos y la HPO. Tal como se definió en la Sección 2.4.5, los pronósticos de energía solar PV y eólica se clasifican en dos categorías principales: pronósticos determinísticos (o puntuales) y pronósticos probabilísticos. En esta sección se abordan los principales aspectos que deben considerarse para la obtención de ambos tipos de pronósticos.

3.7.1 Pronósticos determinísticos

Los pronósticos determinísticos se obtienen como un resultado directo de la aplicación del modelo de pronóstico propuesto a los datos disponibles. Aunque estos pronósticos presentan un cierto nivel de incertidumbre, constituyen la base del proceso predictivo al proporcionar información sobre el comportamiento esperado de las variables de interés para un horizonte temporal determinado. Para facilitar la comprensión de este proceso, se presenta a continuación su descripción lógica en forma de pseudocódigo (*Algoritmo 4*), implementado con funciones disponibles en el *software* MATLAB.

Algoritmo 4: Obtención de los pronósticos determinísticos

1: Cargar los datos de entrenamiento (*XTrain*, *YTrain*) y de prueba (*XTest*, *YTest*) obtenidos al finalizar la etapa de preprocesamiento y preparación de los datos

2: Definir la estructura general del modelo BiLSTM:

```
layers = [ sequenceInputLayer (número_características_entrada)
           bilstmLayer (número_unidades_ocultas*)
           dropoutLayer (valor_tasa_abandono*)
           fullyConnectedLayer (número_salidas)
           regressionLayer]
```

3: Configurar las opciones de entrenamiento del modelo BiLSTM:

```
options = trainingOptions ('optimizador*', ...
                           'MaxEpochs', valor*, ...
                           'GradientThreshold', valor, ...
                           'InitialLearnRate', valor*, ...
                           'LearnRateSchedule', 'piecewise', ...
                           'LearnRateDropPeriod', valor*, ...
                           'LearnRateDropFactor', valor*, ...
                           'Verbose', valor, ...
                           'MiniBatchSize', valor*, ...
                           'L2Regularization', valor*, ...
                           'Plots', 'training-progress')
```

4: Entrenar el modelo:

```
model = trainNetwork (XTrain, YTrain, layers, options)
```

5: Obtener el pronóstico determinístico para el conjunto de datos de prueba:

```
YPred = predict (model, XTest)
```

* Indica que el hiperparámetro puede ser optimizado mediante BO

Además, debido a su importancia, se considera necesario profundizar en los aspectos relacionados con la estructura del modelo de pronóstico. En la Figura 3.18 se observa que el modelo propuesto está integrado por los siguientes elementos: entradas, capa secuencial de entrada, capa BiLSTM, capa de abandono, capa totalmente conectada, capa de regresión de salida y salida. Las entradas del modelo se definen a partir del análisis de FS descrito en el apartado 3.3.4. La capa secuencial de entrada se encarga de preparar los datos para alimentar la capa BiLSTM y su configuración depende del número de características de entrada definidas previamente. La capa BiLSTM está formada por un determinado número de unidades ocultas, lo que le otorga al modelo la capacidad de aprendizaje necesaria [15].




Figura 3.18. Estructura general del modelo utilizado para la obtención de pronósticos determinísticos.

También es importante mencionar que la introducción de la capa de abandono en las redes BiLSTM ha demostrado ser eficaz para evitar el sobreajuste. Esta capa contribuye a que las representaciones aprendidas no se vuelvan demasiado dependientes de las características particulares de la secuencia de datos. Además, ayuda a distribuir el proceso de aprendizaje de manera más uniforme entre las unidades ocultas de la red, mejorando su capacidad de generalización y su robustez [115]. Luego, la capa totalmente conectada realiza algunas operaciones de transformación lineal y no lineal y se encarga de aplanar la salida de la capa anterior. Su configuración depende de la cantidad de salidas del modelo. Posteriormente, la capa de regresión de salida genera la predicción numérica final, correspondiente a la potencia PV o eólica para el horizonte temporal definido [15].

3.7.2 Pronósticos probabilísticos

La obtención de pronósticos probabilísticos constituye un enfoque adecuado para caracterizar de manera efectiva las incertidumbres inherentes a las predicciones determinísticas generadas por el modelo propuesto. En redes eléctricas con una penetración significativa de energía solar PV y eólica, estas incertidumbres pueden afectar de manera importante la planificación y el funcionamiento de la red. Los pronósticos probabilísticos ofrecen una solución viable a estos desafíos, ya que permiten estimar un rango de valores dentro del cual se espera que se ubiquen las predicciones y los valores reales de la variable objetivo, para

un nivel de confianza determinado. El enfoque implementado para obtener los pronósticos probabilísticos se basa en la combinación de las predicciones determinísticas del modelo propuesto con el método de remuestreo *bootstrap* [15], [116], con el objetivo de obtener los intervalos de predicción (*Prediction Intervals*, PIs) para diferentes niveles de confianza.

A continuación, se presenta el pseudocódigo del procedimiento propuesto (*Algoritmo 5*). Se debe mencionar que los pronósticos probabilísticos proporcionan información adicional de gran utilidad para mejorar la gestión energética y respaldar la toma de decisiones. Su uso contribuye a prevenir problemas asociados a déficits o excesos de energía, favoreciendo de esta forma el funcionamiento estable y seguro del sistema eléctrico.

Algoritmo 5: Construcción de PIs utilizando el método de remuestreo *bootstrap*

- 1: Obtener los pronósticos determinísticos ($\hat{P}$) mediante el modelo propuesto (donde n es el número de predicciones)
 - 2: Calcular los errores entre los valores reales de potencia (P) y los pronósticos determinísticos ($\hat{P}$) $\rightarrow (e_d = P - \hat{P})$
 - 3: Establecer el número de muestras *bootstrap* que se deben generar (por ejemplo, $B = 10\,000$)
 - 4: Definir una matriz de ceros de tamaño ($n \times B$) para almacenar las predicciones *bootstrap* (denotada como *predicciones_bootstrap*)
 - 5: Obtener las predicciones *bootstrap*:

for $i = 1$ **to** B **do**
 Generar muestras aleatorias de los errores de predicción (e_d) con reemplazo para obtener los errores de predicción *bootstrap* (e_{bp})
 Sumar e_{bp} con $\hat{P}$ y almacenar los resultados en la matriz *predicciones_bootstrap*
end for
 - 6: Definir el nivel de confianza deseado (por ejemplo, $PINC = 95\%$)
 - 7: Ordenar las predicciones *bootstrap* en orden ascendente para cada paso de tiempo
 - 8: Estimar los intervalos de predicción inferior y superior en función del nivel de confianza definido $\rightarrow$ (por ejemplo, para un nivel de confianza del 95 %, el límite inferior corresponde al percentil 2.5 y el límite superior al percentil 97.5 de la matriz calculada)
 - 9: Graficar los valores reales de energía solar PV o eólica, las predicciones determinísticas generadas por el modelo propuesto y los intervalos de predicción obtenidos en el paso anterior
-

3.8 Técnicas de inteligencia artificial explicable (XAI)

En los últimos años, se ha producido un gran aumento en la aplicación de métodos de ML y DL, debido a su alta efectividad y excelente rendimiento en la resolución de tareas complejas. No obstante, muchos de estos enfoques suelen considerarse “cajas negras” y se ven limitados en cierta medida por su falta de interpretabilidad y transparencia. Para superar esta limitación, ha surgido el campo de la inteligencia artificial explicable (XAI). Las técnicas de XAI permiten cuantificar el impacto de las características de entrada en el modelo de pronóstico, facilitando así una comprensión más profunda de su funcionamiento interno. Este tipo de análisis resulta particularmente útil en el pronóstico de energía solar PV y eólica, donde las predicciones del modelo dependen de múltiples factores y pueden tener un impacto considerable en la planificación y la operación del sistema eléctrico. En la literatura especializada se han propuesto varias técnicas de XAI, entre las que se pueden mencionar las derivadas parciales y la importancia del predictor fuera de la bolsa (OOB). También se han utilizado las explicaciones locales agnósticas de modelos interpretables (*Local Interpretable Model-Agnostic exPlanations*, LIME), las técnicas basadas en SHAP y la RFE, entre otras [21], [117].

Entre las técnicas mencionadas, la RFE se considera un enfoque efectivo y relativamente fácil de implementar, que permite evaluar de forma global la importancia de las distintas variables de entrada en el rendimiento del modelo. Además, ofrece un equilibrio adecuado entre interpretabilidad, eficiencia computacional y aplicabilidad, lo que lo convierte en una alternativa viable para los propósitos de esta investigación. Su funcionamiento se basa en calcular inicialmente el RMSE del modelo propuesto cuando todas las características de entrada se encuentran activas ($RMSE_{inicial}$). Posteriormente, se eliminan las características de entrada de manera individual y se determina el RMSE correspondiente ($RMSE_i$) [117]. De este modo, la contribución de cada característica (CF_i) en la salida del modelo se estima como:

$$CF_i = 1 - \frac{RMSE_{inicial}}{RMSE_i} \quad (3.23)$$

En esta formulación, valores positivos de CF_i indican una contribución relevante de la variable al modelo, valores cercanos a cero reflejan un impacto reducido, mientras que valores negativos sugieren que su inclusión puede degradar el rendimiento predictivo.

3.9 Pronóstico de energía solar PV y eólica en condiciones de operación atípicas

En aplicaciones de pronóstico en tiempo real pueden presentarse condiciones de operación atípicas, como fallos en sensores de medición o presencia de ruido en los datos, que afectan negativamente la calidad del proceso predictivo. Aunque estas condiciones de operación atípicas suelen ocurrir de forma esporádica, resulta importante garantizar la estabilidad y la resiliencia del modelo de pronóstico para evitar problemas en la gestión energética y la operación del sistema eléctrico.

En la Figura 3.19 se describe la metodología propuesta para generar los pronósticos en condiciones de operación atípicas, específicamente aquellas relacionadas con fallos temporales o pérdidas de información de uno o más sensores de medición. En este caso, el proceso comienza con la obtención de la información actualizada de las variables de entrada en cada paso de tiempo y continúa con la comprobación de su estado para detectar posibles fallos en los sensores de medición. Es importante mencionar que, cuando se presenta la condición atípica, debe aparecer un valor NaN en las mediciones registradas. Si no se detectan condiciones atípicas durante este proceso, el modelo continúa operando de manera normal y generando sus pronósticos de la forma establecida. Por el contrario, si se identifica alguna condición atípica, es necesario determinar la(s) variable(s) afectada(s). En el caso de que todas las variables de entrada se vean comprometidas al mismo tiempo (escenario más crítico), se recomienda aplicar la estrategia directa descrita en la Sección 2.4.5 para obtener los pronósticos mientras persistan las condiciones atípicas. En esta estrategia se reentrena un modelo específico para cada horizonte de pronóstico requerido, utilizando únicamente la información disponible hasta el instante en que se produce la interrupción. Aunque este enfoque puede ser más costoso desde el punto de vista computacional, garantiza una mayor precisión que el enfoque iterativo, en el que se utilizan predicciones de instantes anteriores para obtener predicciones de instantes futuros. Esto provoca una acumulación de errores durante el proceso de predicción.




Figura 3.19. Metodología propuesta para asegurar la operatividad del modelo de pronóstico en condiciones de operación atípicas derivadas de fallos temporales en los sensores de medición.

Sin embargo, cuando no se afectan todas las variables de entrada de forma simultánea, es decir, cuando la condición atípica afecta solo a una o varias variables, la estrategia a seguir resulta diferente. Se debe recordar que la metodología general descrita en la Sección 3.1 incluye la validación del nivel de importancia de cada variable de entrada mediante una técnica de XAI conocida como RFE. Por lo tanto, al considerar la(s) variable(s) afectada(s) y su respectivo nivel de importancia, es posible determinar si las condiciones de operación son favorables (cuando el nivel de importancia de la(s) variable(s) afectada(s) es bajo), o críticas (cuando su nivel de importancia es alto). Cuando las condiciones se consideran favorables, se selecciona una arquitectura del modelo de pronóstico que excluya las variables afectadas, se realizan los ajustes necesarios y se lleva a cabo su entrenamiento. Posteriormente, se genera el pronóstico de la variable objetivo para el siguiente paso de tiempo utilizando la información disponible. En caso contrario (condiciones críticas), el usuario puede elegir la estrategia de pronóstico (estrategia directa o la que excluye la(s) variable(s) afectada(s)) para generar el pronóstico mientras persistan las condiciones atípicas.

También es importante evaluar el desempeño y la capacidad predictiva del modelo propuesto ante otra condición de operación atípica que puede presentarse durante el proceso predictivo: la presencia de ruido

blanco en las mediciones disponibles. La metodología propuesta para este propósito se ilustra en la Figura 3.20. Para simular esta condición atípica, se utilizan los datos de prueba correspondientes a los conjuntos de energía solar PV y eólica, a los que se añade un cierto nivel de ruido blanco gaussiano mediante la función ‘*add white Gaussian noise to signal (awgn)*’ del *software* MATLAB [118]. Esta función recibe como argumentos la señal original en forma de vector (‘*in*’), el parámetro ‘*signal-to-noise ratio (snr)*’ que controla el nivel de ruido introducido en la señal. Además, recibe el parámetro ‘*signal power*’, que se ajusta con la opción ‘*measured*’ para determinar un nivel adecuado de ruido blanco según el valor de ‘*snr*’.

Luego, se introducen los datos de prueba con ruido blanco al modelo de pronóstico propuesto, el cual ha sido previamente entrenado. A continuación, se evalúa su rendimiento en estas condiciones utilizando diferentes métricas. Si el modelo demuestra un desempeño satisfactorio ante esta condición atípica, se procede a realizar las predicciones necesarias para el horizonte temporal definido. Por el contrario, si el modelo no funciona bien, se deben considerar otras estrategias para tratar este problema, por ejemplo, reentrenar el modelo utilizando un conjunto de datos que contenga ruido blanco, o modificar el ajuste de los hiperparámetros a través de nuevas ejecuciones del algoritmo de BO.




Figura 3.20. Metodología propuesta para evaluar la capacidad de adaptación del modelo de pronóstico y obtener las predicciones necesarias en condiciones de operación atípicas relacionadas con la presencia de ruido blanco en las mediciones.

3.10 Conclusiones del capítulo

En este capítulo se ha descrito de forma detallada la metodología propuesta para efectuar el pronóstico de energía solar PV y eólica. Esta metodología integra un grupo de aspectos relevantes y aborda los desafíos inherentes a la variabilidad y la intermitencia de estos recursos energéticos. En este contexto, se ha propuesto un método robusto de preprocesamiento y preparación de los datos, con el objetivo de mejorar su calidad e incrementar el rendimiento del modelo de pronóstico. Por otra parte, se ha seleccionado una red neuronal de DL de tipo BiLSTM para realizar los pronósticos, considerando su alto rendimiento en el trabajo con series temporales, así como su capacidad para capturar patrones complejos y no lineales. Además, se han

explorado varios métodos de optimización de hiperparámetros y a partir del análisis realizado, se ha seleccionado la BO debido a su efectividad y robustez en la solución de este tipo de problemas. Para respaldar la efectividad del modelo de pronóstico propuesto, se han seleccionado varios modelos de referencia ampliamente utilizados en este campo, para realizar las comparaciones pertinentes.

También se han abordado los aspectos relacionados con la obtención de los pronósticos determinísticos y probabilísticos, proporcionando en cada caso los pseudocódigos correspondientes y la explicación precisa de cada procedimiento aplicado. Otra de las cuestiones analizadas ha sido la aplicación de una técnica de XAI con la finalidad de mejorar la interpretabilidad y la transparencia del modelo de pronóstico propuesto. Esta herramienta permite analizar la importancia de cada variable de entrada y mejorar la comprensión del funcionamiento interno del modelo.

Además, se ha propuesto una metodología viable para la obtención de pronósticos en condiciones de operación atípicas, asociadas a fallos temporales de sensores de medición y a la presencia de ruido blanco en los datos. De esta forma se favorece una operación más resiliente del modelo de pronóstico y se reducen posibles problemas en la planeación y operación del sistema eléctrico. De manera general, la metodología presentada en este capítulo sienta las bases para la validación y el desarrollo de enfoques de pronóstico viables e innovadores en el campo de las energías renovables.

CAPÍTULO 4. CONTROL DE FRECUENCIA EN REDES ELÉCTRICAS

4.1 Introducción

En este capítulo se analizan varios aspectos importantes relacionados con el control de frecuencia en redes eléctricas. Inicialmente, se abordan algunos conceptos fundamentales en este campo de investigación, incluyendo la estabilidad de frecuencia y los principales indicadores utilizados para su análisis. Debido a su relevancia, también se profundiza en el control de frecuencia mediante generadores síncronos, describiendo detalladamente los elementos que intervienen en este proceso. Por otra parte, se examina el impacto causado por la integración de las RES en la frecuencia de la red. Asimismo, se presentan algunas de las técnicas de control utilizadas en las RES, así como el funcionamiento de ciertos tipos de inversores. Estos temas se abordan con fines descriptivos y de contextualización, sin abordar directamente su implementación. Por último, se analizan varias consideraciones importantes relacionadas con el control de frecuencia en microrredes, así como algunas acciones remediales que se aplican para evitar el colapso de la red cuando se presentan grandes desviaciones de frecuencia.

4.2 Conceptos fundamentales

La frecuencia es una magnitud fundamental utilizada en diversos campos de la ciencia y la ingeniería para caracterizar fenómenos oscilatorios y periódicos. En el caso de los sistemas eléctricos, la frecuencia corresponde al número de ciclos completos que realiza la onda sinusoidal de corriente alterna (*Alternating Current*, AC) cada segundo y se expresa en hertz (Hz) [119], [120].

La estabilidad de frecuencia se define a grandes rasgos como la capacidad del sistema de potencia para mantener la frecuencia en equilibrio después de una perturbación que provoca un desbalance entre la generación de energía y la demanda de las cargas [121], [122]. En general, los sistemas eléctricos operan a frecuencias nominales de 50 o 60 Hz, según la red. Sin embargo, las cargas conectadas al sistema cambian de manera continua, por lo que resulta difícil igualar la generación de energía con la demanda de las cargas en cada instante de tiempo. Este fenómeno se ha agudizado aún más en los sistemas eléctricos modernos, donde la introducción acelerada de las RES provoca variaciones continuas e intermitentes de la generación, así como a un aumento de los desequilibrios entre la oferta y la demanda de energía [120]. En la Figura 4.1 se muestra una analogía del balance entre carga y generación y su relación con la frecuencia del sistema eléctrico. En este contexto, cuando la generación coincide con la carga del sistema, la frecuencia se mantiene en su valor nominal. Por el contrario, cuando la generación se encuentra por encima o por debajo de la carga, la frecuencia del sistema aumenta o disminuye respectivamente, lo que provoca desviaciones respecto al valor de referencia.

Las desviaciones de frecuencia se consideran normales cuando se encuentran dentro de una banda estrecha alrededor de la frecuencia nominal de operación. Estas desviaciones están asociadas fundamentalmente con los cambios continuos en la demanda de las cargas y en la producción de energía de las RES. No obstante, cuando se producen eventos críticos asociados a la pérdida de una línea de transmisión o de un generador de gran capacidad, se pueden presentar desviaciones de frecuencia anormales. Esto

también puede ocurrir debido a la conexión o desconexión repentina de una carga de gran magnitud, afectando la operación segura y estable de la red. Las grandes desviaciones de frecuencia pueden dañar el equipamiento, deteriorar el desempeño de las cargas, sobrecargar las líneas de transmisión, provocar el disparo de los relés de protección y, en el peor de los casos, ocasionar el colapso del sistema eléctrico [120], [123].




Figura 4.1. Analogía del balance entre generación y carga y su relación con la frecuencia del sistema eléctrico.

4.3 Indicadores utilizados para evaluar la estabilidad de frecuencia

Para evaluar la estabilidad de frecuencia de un sistema eléctrico se utilizan varios indicadores relevantes, que incluyen la inercia del sistema, la tasa de cambio de la frecuencia (*Rate of Change of Frequency*, RoCoF) y la desviación máxima de frecuencia (*nadir* o *cenit*) [124]. El análisis de estos indicadores, así como de las relaciones existentes entre ellos, favorece considerablemente la comprensión de los problemas de estabilidad de frecuencia en los sistemas eléctricos.

4.3.1 Inercia del sistema

En los sistemas eléctricos de potencia, se produce un almacenamiento de energía en todos los elementos giratorios (generadores y cargas motoras). Esta energía se conoce como energía inercial, almacenada o rotacional y resulta muy importante en el proceso de control de frecuencia. De manera general, la inercia se define como la propiedad de un objeto que resiste un cambio en su velocidad y dirección actuales. En el caso particular de los generadores, la inercia se refiere a la resistencia natural de este dispositivo a los cambios en su velocidad de rotación. Además, es importante mencionar que la energía inercial de un determinado objeto depende de tres parámetros esenciales: su masa, su diámetro y su velocidad de rotación. Por ejemplo, las grandes unidades turbina/generador que integran las plantas generadoras del sistema poseen gran tamaño y masa. Al girar a alta velocidad, estas unidades almacenan una gran cantidad de energía inercial, lo que les permite resistir cambios de velocidad de manera natural y contribuir significativamente al control de la frecuencia [120], [125].

Desde el punto de vista matemático, el momento de inercia de un generador síncrono se puede expresar mediante la ecuación (4.1) [125]:

$$J = \int r^2 dm = r^2 \cdot m \quad (4.1)$$

donde J representa el momento de inercia del generador, expresado en $\text{kg}\cdot\text{m}^2$; m corresponde a la masa del rotor, expresada en kg ; y r denota el radio del rotor, expresado en m .

La energía cinética (E_c) que se almacena en el rotor se define mediante la ecuación (4.2) [125]:

$$E_c = \frac{1}{2} \cdot J \cdot \omega^2 \quad (4.2)$$

donde ω representa la velocidad de rotación del rotor, expresada en rad/s .

Además, es posible obtener la constante de inercia del generador (H) expresada en $\text{MW}\cdot\text{s/MVA}$ mediante la ecuación (4.3) [125]:

$$H = \frac{E_c}{S} = \frac{\frac{1}{2} \cdot J \cdot \omega^2}{S} \quad (4.3)$$

donde S corresponde a la potencia aparente del generador, expresada en MVA .

En el caso de un sistema de potencia que contenga varios generadores síncronos conectados a la red, la constante de inercia total (H_t) se determina como [125]:

$$H_t = \frac{\sum_{i=1}^n S_i \cdot H_i}{\sum_{i=1}^n S_i} = \frac{E_{c,t}}{S_t} \quad (4.4)$$

donde S_i y H_i representan, respectivamente, la potencia aparente y la constante de inercia de cada generador conectado a la red; mientras que $E_{c,t}$ y S_t representan los valores totales de energía cinética y potencia aparente del sistema.

4.3.2 Tasa de cambio de la frecuencia (RoCoF)

La H_t disponible en el sistema eléctrico tiene un impacto significativo en la magnitud de las oscilaciones provocadas por cambios bruscos en el balance de potencia activa y, por lo tanto, en la frecuencia de la red. El RoCoF se define como el valor de la tasa de cambio de la frecuencia $\left(\frac{df}{dt}\right)$ de dichas oscilaciones en un instante de tiempo posterior al inicio de la contingencia. Este indicador ha adquirido especial relevancia en los sistemas eléctricos modernos con baja inercia equivalente. En estos sistemas, las variaciones de frecuencia pueden desarrollarse con mayor rapidez debido a la alta penetración de recursos energéticos basados en electrónica de potencia. En ocasiones, para simplificar el proceso de cálculo, los operadores del sistema estiman el RoCoF mediante la expresión (4.5) [122]:

$$RoCoF = \frac{f(t_0 + T) - f(t_0)}{T} \quad (4.5)$$

donde $f(t_0)$ es un valor de frecuencia cercano al valor nominal, expresado en Hz ; y T es el intervalo de tiempo que abarca la ventana de cálculo, expresado en s .

En este caso, la precisión en el cálculo del RoCoF depende estrechamente de la calidad de los datos medidos y de la precisión con que se detecte el inicio de la contingencia. Además, depende del valor de T ,

que varía según el código de red de cada país, aunque en muchos casos se selecciona un valor menor o igual a 500 ms para efectuar los cálculos [122], [124].

4.3.3 Desviación máxima de frecuencia (*nadir* o *cenit*)

La desviación máxima de frecuencia (*nadir* o *cenit*) es otro indicador importante para evaluar la estabilidad de frecuencia. Este indicador ha sido ampliamente utilizado debido a su facilidad de medición e interpretación. El *nadir* se define como el valor de frecuencia más bajo registrado durante la respuesta del sistema, mientras que el *cenit* corresponde al valor de frecuencia más alto. En ambos casos, el valor registrado es equivalente a la desviación máxima de la frecuencia del sistema [124].

Además, es importante precisar que cuando se produce una desviación de frecuencia, todo el sistema de energía interconectado debe responder para restablecer las condiciones de equilibrio. Sin embargo, la distancia eléctrica entre cada generador del sistema y el punto donde ocurre la contingencia es un factor importante en este proceso. Es decir, cuanto más lejos se encuentre un generador del lugar de la contingencia, menor será la desviación de frecuencia inicial que se detecte. Por lo tanto, su respuesta inicial también será de menor magnitud [120].

4.4 Respuesta de frecuencia del sistema eléctrico

La respuesta de frecuencia del sistema eléctrico transita típicamente por varias etapas, que incluyen la respuesta inercial, primaria, secundaria y terciaria, como se muestra en la Figura 4.2. Cabe señalar que los tiempos de estas etapas son aproximados y dependen de las dimensiones y características de cada sistema eléctrico.




Figura 4.2. Etapas de la respuesta de frecuencia de un sistema eléctrico.

La respuesta inercial está vinculada con la inercia de los generadores síncronos y con los procesos de absorción o liberación de energía cinética para contrarrestar la desviación inicial de frecuencia cuando

ocurre una contingencia. La duración de esta respuesta es muy breve y, generalmente, abarca un rango de tiempo que puede llegar hasta los 10 s [123], [125]. Por su parte, la respuesta de frecuencia primaria está asociada con el control de la potencia activa de salida de los generadores síncronos mediante la acción de los gobernadores de velocidad. Esta respuesta se activa de forma automática pocos segundos después de iniciarse la contingencia y puede extenderse aproximadamente entre 10 y 30 s [125]. Es importante mencionar que tanto la magnitud como la duración de las respuestas inercial y primaria influyen directamente en el RoCoF, así como en el valor mínimo (*nadir*) o máximo (*cenit*) de la frecuencia del sistema. La función principal de la respuesta de frecuencia primaria es estabilizar la frecuencia; sin embargo, no tiene la capacidad de restablecerla a su valor nominal [126].

Por lo tanto, inmediatamente después de que termina la respuesta primaria, se activa la respuesta de frecuencia secundaria para restablecer la frecuencia del sistema a su valor nominal [125]. La respuesta de frecuencia secundaria también se conoce como control automático de generación (*Automatic Generation Control*, AGC) o control de frecuencia de carga (*Load Frequency Control*, LFC) y tiene una duración aproximada de 15 min [127]. Por último, se activa la respuesta de frecuencia terciaria con el objetivo de gestionar las congestiones eventuales, recuperar las reservas de control secundario y restaurar la frecuencia a un valor adecuado cuando las reservas secundarias son insuficientes. Este servicio se realiza de forma manual mediante la conexión y desconexión de potencia, relocalizando la salida de las unidades generadoras que participan en el control de frecuencia y la regulación en el lado de la demanda [123], [127].

La capacidad del sistema eléctrico para controlar las desviaciones normales de frecuencia y sobrevivir a grandes perturbaciones está relacionada directamente con las reservas de potencia disponibles. De manera general, estas reservas se clasifican en dos grupos fundamentales: reservas rodantes (o giratorias) y reservas no giratorias (fuera de línea). Las reservas giratorias corresponden a la capacidad adicional de potencia disponible en las unidades generadoras que ya se encuentran sincronizadas a la red, las cuales pueden modular su producción rápidamente para el control de frecuencia y la gestión del desequilibrio energético. Por su parte, las reservas no giratorias provienen de recursos que no se encuentran acoplados sincrónicamente a la red, pero que pueden entrar en servicio o modificar su consumo en un horizonte temporal determinado. Estas incluyen unidades de arranque rápido (capaces de sincronizarse típicamente en un margen de 10 a 15 minutos ante contingencias severas) y recursos de sustitución o reemplazo con tiempos de respuesta más desahogados, de 30 minutos o superiores, destinados a restaurar las reservas rodantes tras un evento [120], [123].

4.5 Control de frecuencia mediante generadores síncronos

4.5.1 Necesidad de los sistemas de control de frecuencia

A medida que las expectativas sobre el rendimiento de los sistemas eléctricos han aumentado, ha sido necesario desarrollar sistemas de control de frecuencia más complejos y precisos para mejorar su operación. De manera general, un sistema de control se define como un medio para efectuar un control automático de la salida, basándose en mediciones de varias de sus entradas y salidas [120]. En la Figura 4.3 se muestra un esquema simplificado para el control de frecuencia en un generador síncrono.




Figura 4.3. Esquema simple para el control de frecuencia en un generador síncrono.

En la primera etapa de este control, se realiza la medición de la frecuencia en la salida del generador. Luego, se compara el valor real de frecuencia con un valor objetivo o programado, obteniéndose el error de frecuencia. Posteriormente, el controlador de velocidad calcula los ajustes necesarios para corregir dicho error y devolver la frecuencia real a un valor adecuado. Finalmente, el controlador de velocidad ajusta la entrada de energía a la turbina, regulando la potencia de salida del generador [120].

4.5.2 Modelo equivalente del generador síncrono

En estudios de control de frecuencia, el modelo matemático que se utiliza para representar el comportamiento de un generador síncrono se basa en la ecuación de oscilación, cuya formulación es la siguiente [123]:

$$\frac{d\Delta f(t)}{dt} = \frac{1}{2H} \cdot (\Delta P_m(t) - \Delta P_e(t)) \quad (4.6)$$

donde $\Delta P_m(t)$ y $\Delta P_e(t)$ indican los cambios en la potencia mecánica y en la potencia eléctrica del generador, respectivamente, expresados en (pu o MW); y Δf representa la desviación de frecuencia, expresada en Hz.

El significado físico de la ecuación de oscilación es que, cuando no existe diferencia entre la potencia mecánica generada y la potencia eléctrica absorbida, la frecuencia del sistema se mantiene constante, lo que permite un funcionamiento estable de la red [123], [125].

Aplicando la transformada de Laplace a la ecuación (4.6) se obtiene:

$$\Delta f(s) = \frac{1}{2Hs} \cdot (\Delta P_m(s) - \Delta P_e(s)) \quad (4.7)$$

La ecuación anterior se puede representar en forma de diagrama de bloques, como se ilustra en la Figura 4.4.




Figura 4.4. Modelo del generador síncrono para estudios de control de frecuencia.

4.5.3 Modelo equivalente de la carga

La carga del sistema está integrada por una gran variedad de dispositivos eléctricos. En este caso, es importante considerar que existen algunas cargas que son sensibles a la frecuencia y otras que no lo son. Para simplificar este análisis, la carga del sistema se divide en dos grupos fundamentales: cargas no motoras y cargas motoras. Las cargas no motoras (por ejemplo, cargas resistivas puras) dependen del voltaje de la red, pero no son sensibles a la frecuencia. Por el contrario, las cargas motoras (por ejemplo, motores de inducción utilizados para fines domésticos, comerciales e industriales) sí varían con la frecuencia de la red [120], [128]. Considerando los elementos mencionados, es posible establecer un modelo generalizado para la carga del sistema:

$$\Delta P_e = \Delta P_L - D \cdot \Delta f \quad (4.8)$$

donde ΔP_L y $D \cdot \Delta f$ representan, respectivamente, las porciones de carga no sensible y sensible a la frecuencia de la red, expresadas en MW. El término D se conoce como coeficiente de amortiguamiento y se expresa en pu/Hz, indicando el cambio relativo de la carga sensible por cada Hz de desviación de frecuencia.

Al aplicar la transformada de Laplace a la ecuación (4.8) y combinarla con el modelo del generador síncrono presentado en la sección anterior, se obtiene el diagrama en bloques del conjunto carga-generador representado en la Figura 4.5.




Figura 4.5. Modelo del generador síncrono y la carga para estudios de control de frecuencia.

4.5.4 Modelo equivalente de la turbina mecánica

La turbina mecánica se encarga de proporcionar energía al eje del generador eléctrico en forma de giro mecánico. Dependiendo de la fuente de energía, las turbinas pueden clasificarse como de vapor, hidráulicas o de gas, entre otras. En todos los casos, la potencia de salida de la turbina depende de la posición del elemento de control que regula el flujo de energía primaria hacia la turbina. Por ejemplo, para el caso específico de una turbina de vapor sin recalentamiento, su comportamiento dinámico puede modelarse mediante una función de transferencia de primer orden [128]:

$$\Delta P_m(s) = \frac{1}{1 + \tau_T s} \cdot \Delta P_v(s) \quad (4.9)$$

donde τ_T representa la constante de tiempo de la turbina, es decir, el retardo de tiempo que existe en la respuesta de la turbina debido a los cambios en la posición de la válvula; y ΔP_v representa la posición de la válvula mecánica.

Esta ecuación puede representarse en forma de diagrama de bloques, como se muestra en la Figura 4.6.




Figura 4.6. Modelo de una turbina de vapor sin recalentamiento para estudios de control de frecuencia.

4.5.5 Modelo equivalente del gobernador de velocidad

El gobernador de velocidad tiene la función de reajustar la posición de la válvula de entrada de la turbina para regular la entrada de potencia mecánica al generador y limitar las desviaciones de frecuencia en el sistema. El funcionamiento del gobernador de velocidad se representa mediante la ecuación (4.10) [128]:

$$\Delta P_g = \Delta P_{ref} - \frac{1}{R} \cdot \Delta f \quad (4.10)$$

donde ΔP_g y ΔP_{ref} representan, respectivamente, la potencia proporcionada por el gobernador y la potencia de referencia, expresadas en MW; y R corresponde a la característica de caída del gobernador, expresada en Hz/pu.

Luego, al aplicar la transformada de Laplace a la ecuación (4.10) se obtiene:

$$\Delta P_g(s) = \Delta P_{ref}(s) - \frac{1}{R} \cdot \Delta f(s) \quad (4.11)$$

Es importante mencionar que cuando el gobernador cambia la posición de la válvula que regula la entrada de combustible a la turbina (ΔP_v), este proceso tiene asociado un cierto retardo de tiempo (τ_g). Este comportamiento se representa matemáticamente mediante la ecuación (4.12) [128]:

$$\Delta P_v(s) = \frac{1}{1 + \tau_g s} \cdot \Delta P_g(s) \quad (4.12)$$

Por último, al integrar las ecuaciones (4.11) y (4.12) se obtiene el modelo del gobernador de velocidad en forma de diagrama de bloques, como se muestra en la Figura 4.7a. Además, en la Figura 4.7b se representa la característica de caída típica de un gobernador de velocidad. Esta característica garantiza que los generadores del sistema respondan a las desviaciones de frecuencia en proporción a su tamaño. La característica de caída se expresa como un porcentaje del cambio de frecuencia requerido para que un gobernador mueva una unidad desde el estado sin carga al estado de carga completa, o viceversa. Evidentemente, los gobernadores solo realizan este ajuste cuando disponen de suficiente capacidad de reserva giratoria. En la práctica, particularmente en plantas de generación convencional, se suelen utilizar valores de la característica de caída del gobernador en el rango de 3 % a 7 %. Por otro lado, es importante mencionar que en los gobernadores existe una banda muerta alrededor de la frecuencia nominal, dentro de la cual el sistema de control no actúa. El objetivo de esta banda muerta es evitar que el gobernador opere constantemente para tratar de corregir pequeñas desviaciones de frecuencia, previniendo el desgaste excesivo de sus componentes. Para sistemas de energía interconectados, los valores de la banda muerta del gobernador se encuentran típicamente en el rango de 0.03 Hz a 0.04 Hz [120], [123].




Figura 4.7. Gobernador de velocidad: (a) Modelo para estudios de control de frecuencia y (b) Característica de caída.

4.5.6 Modelo equivalente de un sistema de potencia aislado

Al combinar los modelos analizados en las secciones previas para el generador síncrono, la carga, la turbina mecánica y el gobernador de velocidad, se obtiene un modelo dinámico agregado para estudios de control de frecuencia de un sistema de potencia aislado. Dicho modelo se representa mediante un diagrama de bloques en la Figura 4.8 y es ampliamente utilizado en estudios de control de frecuencia y análisis de pequeña señal. En este caso, el lazo de control de frecuencia primario opera de acuerdo con la característica de caída del gobernador. También se ha representado un lazo de control de frecuencia secundario que actúa de acuerdo con las señales generadas por el controlador $k(s)$, con el objetivo de mejorar la regulación de frecuencia y reducir el error en estado estacionario. En el contexto de esta investigación, este modelo servirá como punto de partida para la representación de la microrred analizada.




Figura 4.8. Modelo para el control de frecuencia en un sistema de potencia aislado.

4.6 Efectos de la integración de RES en el control de frecuencia

La estructura de los sistemas eléctricos ha evolucionado significativamente en las últimas décadas. Estos cambios han tenido un impacto directo en el comportamiento de diversos indicadores, incluyendo la frecuencia de la red. En la Figura 4.9 se compara, en términos generales, la estructura de los sistemas eléctricos tradicionales (Figura 4.9a) con la de los sistemas eléctricos modernos (Figura 4.9b).




Figura 4.9. Estructura general de los sistemas eléctricos: (a) Sistemas tradicionales y (b) Sistemas modernos.

Los sistemas eléctricos tradicionales están integrados fundamentalmente por diferentes tipos de plantas generadoras basadas en generadores síncronos, así como por varios tipos de cargas (motoras, resistivas, entre otras). La gran cantidad de elementos giratorios en estos sistemas contribuye a incrementar la inercia de la red y favorece el desarrollo natural de una respuesta de frecuencia más robusta en caso de

contingencias. Por otro lado, los sistemas eléctricos modernos muestran una tendencia creciente hacia la incorporación de RES (fundamentalmente sistemas PV y eólicos), así como de otros dispositivos que utilizan interfaces de electrónica de potencia para su conexión a la red [125]. Es importante destacar que los sistemas PV carecen de componentes giratorios que contribuyan a la inercia del sistema y se conectan a la red eléctrica mediante convertidores electrónicos. Por este motivo, no presentan una respuesta inercial inherente ante las desviaciones de frecuencia. En el caso de los sistemas eólicos modernos, aunque existen partes rotatorias, la presencia de convertidores electrónicos desacopla dinámicamente el aerogenerador de la red, lo que limita significativamente su contribución natural a la inercia del sistema. Por lo tanto, la introducción acelerada de estas tecnologías renovables desplaza progresivamente las unidades generadoras convencionales, reduciendo la inercia equivalente del sistema y las reservas de energía disponibles. En estas condiciones, el sistema eléctrico se vuelve mucho más sensible a los desequilibrios entre generación y carga, agravando los problemas asociados a la estabilidad de frecuencia [129], [130].

El impacto de las RES en la dinámica del sistema se vuelve más significativo a medida que aumenta su nivel de penetración. Este indicador puede estimarse mediante la ecuación (4.13) [125]:

$$\%RES_{pen} = \left(\frac{P_{RES}}{P_{m\acute{a}x_carga}} \right) \cdot 100 \quad (4.13)$$

donde $\%RES_{pen}$ representa el nivel de penetración de las RES, expresado en porcentaje; mientras que P_{RES} y $P_{m\acute{a}x_carga}$ corresponden a la potencia total instalada en fuentes renovables y a la demanda máxima del sistema, respectivamente, ambas expresadas en MW.

En la Figura 4.10 se compara de forma general la respuesta de frecuencia de un sistema eléctrico tradicional (dominado por generadores síncronos), con la de un sistema moderno (con alto nivel de penetración de RES).




Figura 4.10. Comparación de la respuesta de frecuencia de un sistema eléctrico convencional (dominado por generadores síncronos) y de un sistema eléctrico con baja inercia (alta penetración de RES).

Se observa que, ante una misma contingencia, la respuesta de frecuencia del sistema dominado por fuentes convencionales es más favorable y presenta una mayor resiliencia. En cambio, en los sistemas con alta penetración de RES, la reducción de la inercia equivalente provoca un incremento del RoCoF y un deterioro del nadir de frecuencia. Esto, en términos generales, se traduce en una respuesta de frecuencia más desfavorable. En estas condiciones, el sistema es más propenso a problemas de estabilidad de frecuencia y, en algunos casos críticos, pueden ocurrir fallos en cascada e incluso apagones generalizados [123], [125].

Debido a estos desafíos, los operadores de los sistemas de transmisión (*Transmission System Operator*, TSO) de varios países han actualizado sus códigos de red para lograr una operación más segura y estable. En la Tabla 4.1 se resumen algunos de los cambios introducidos en las principales métricas operativas relacionadas con el control de frecuencia, incluyendo los límites permisibles de RoCoF en distintos sistemas eléctricos [125].

Tabla 4.1. Impacto de la integración de RES en las métricas operativas de distintos sistemas de potencia.

País	TSO	Límite previo del RoCoF (Hz/s)	Límite revisado del RoCoF (Hz/s)	Rango operativo permitido (Hz)
Australia	AEMO	1	3	49.5 – 50.5
Irlanda	EirGrid	0.5	1	49.5 – 50.5
Gran Bretaña	National Grid	0.125	0.5	49.5 – 50.5
Dinamarca	Energinet	2	2.5	49.0 – 51.0

Además, en estas circunstancias aparecen otros desafíos importantes relacionados con el control de la frecuencia. Por ejemplo, la estimación de la inercia del sistema puede verse afectada por las incertidumbres en la potencia de salida de las RES. También se generan inexactitudes en las mediciones de la frecuencia y el RoCoF debido a la mayor rapidez en la dinámica de la red, lo cual perjudica su operación. Asimismo, aumenta el riesgo de desconexión de ciertos recursos energéticos distribuidos (DER) que operan bajo determinados límites de frecuencia y RoCoF, como es el caso de los sistemas PV. La desconexión masiva de estos recursos puede agravar las desviaciones de frecuencia y comprometer seriamente la estabilidad del sistema [123], [125].

4.7 Control de frecuencia mediante RES

Para minimizar los impactos negativos asociados a la integración de RES, en los últimos años se han propuesto diferentes técnicas de control que permiten que los sistemas PV y eólicos puedan contribuir al control de la frecuencia de la red.

4.7.1 Control de frecuencia mediante fuentes PV

Aunque los sistemas PV carecen de partes móviles y no aportan inercia mecánica a la red, pueden contribuir al control de la frecuencia mediante distintas técnicas de control. Entre las técnicas más utilizadas se encuentran la descarga PV (*deloading* PV) y la emulación de la respuesta inercial equivalente mediante el capacitor de enlace de corriente directa (*Direct Current*, DC) [125]. A continuación, se describen brevemente las principales características de estas técnicas.

4.7.1.1 Descarga PV

Los sistemas PV tradicionales utilizan un algoritmo de MPPT para maximizar la producción de energía durante su operación, pero en estas condiciones no disponen de las reservas necesarias para apoyar la red en caso de una contingencia. Sin embargo, si los sistemas PV se configuran para operar a un voltaje superior al voltaje del punto de máxima potencia (V_{MPP}), se produce una reducción de la potencia de salida y se obtiene una potencia de reserva ($P_{reserva}$) que se determina como [9], [125]:

$$P_{reserva} = P_{MPP} - P_{salida} \quad (4.14)$$

donde P_{MPP} representa la potencia extraída en el punto de máxima potencia; y P_{salida} corresponde a la potencia de salida en una condición operativa específica.

Esta energía de reserva solo se libera cuando ocurre una desviación de frecuencia en el sistema. Para controlar este proceso, el voltaje de operación del sistema PV (V_{DCref}) se reduce utilizando señales de control basadas en la desviación de frecuencia ($V_{DC\Delta f}$) que tiene lugar al ocurrir la contingencia [9]:

$$V_{DCref} = V_{MPP} + V_{descarga} - V_{DC\Delta f} \quad (4.15)$$

donde $V_{descarga}$ es un voltaje que se adiciona al V_{MPP} durante condiciones normales de operación.

De esta forma, el sistema PV puede contribuir a la estabilidad de frecuencia proporcionando energía adicional con gran rapidez. Sin embargo, un aspecto crítico a considerar es que el aporte del sistema PV puede estar presente o no, o manifestarse en diferentes magnitudes dependiendo de las condiciones climáticas. Desde el punto de vista del control, esta naturaleza estocástica representa una desventaja significativa, ya que introduce una incertidumbre directa en la efectividad de la acción de control y en la disponibilidad real de las reservas para la regulación. Para facilitar la comprensión de los aspectos mencionados, en la Figura 4.11a se ilustra la estructura del bloque de control utilizado para implementar esta técnica y en la Figura 4.11b se muestra su representación gráfica. No obstante, es importante mencionar que esta técnica introduce un margen constante de pérdida, al operar continuamente por debajo del punto de máxima potencia [125].




Figura 4.11. Descripción de la técnica de descarga PV: (a) Estructura del bloque de control y (b) Representación gráfica.

4.7.1.2 Capacitor de enlace de DC

Esta técnica de control utiliza la energía eléctrica almacenada en el capacitor de enlace de DC del convertidor electrónico (ver Figura 4.12) para emular una respuesta inercial equivalente. El proceso consiste en controlar la carga y la descarga del capacitor dentro de un rango predefinido, ajustando posteriormente la potencia de salida del inversor PV. Esta técnica se puede expresar matemáticamente mediante la ecuación (4.16) [125], [131]:

$$\Delta P_{DC-enlace} = \frac{C_{DC} \cdot V_{DCref}^2}{2 \cdot S_{nom}} \cdot \frac{dV_{DC}}{dt} = 2H_c \cdot \frac{dV_{DC}}{dt} \quad (4.16)$$

donde $\Delta P_{DC-enlace}$ representa la cantidad de potencia emulada por el capacitor de enlace de DC; C_{DC} es su capacitancia; V_{DCref} es el voltaje de referencia en el bus de DC; S_{nom} es la potencia nominal del sistema inversor; y H_c corresponde a la inercia emulada mediante el almacenamiento de energía en dicho enlace.

La aplicación de esta técnica de control mejora la respuesta inercial del sistema eléctrico y reduce el RoCoF y las Δf después de una contingencia. No obstante, una de sus principales limitaciones es que el capacitor de enlace de DC experimenta una reducción de su eficiencia y de su ciclo de vida debido al uso continuo [125].




Figura 4.12. Diagrama general de un sistema PV que muestra la ubicación del capacitor de enlace de DC.

4.7.2 Control de frecuencia mediante fuentes eólicas

Los aerogeneradores utilizados en las plantas de energía eólica se pueden clasificar en dos tipos principales: de velocidad fija y de velocidad variable. Los aerogeneradores de velocidad fija se conectan directamente a la red eléctrica. Esto produce una respuesta inercial pequeña a las variaciones de frecuencia en comparación con los generadores síncronos convencionales. Por otro lado, los aerogeneradores de velocidad variable se conectan a la red mediante un convertidor electrónico, por lo que no contribuyen directamente a la inercia mecánica del sistema. Sin embargo, esta limitación puede ser superada mediante diversas técnicas de control, como el control de inercia y el control de descarga [9]. A continuación, se describen brevemente las principales características de estas técnicas.

4.7.2.1 Control de inercia

La inercia de los aerogeneradores de velocidad variable debe emularse para contribuir a la estabilidad de frecuencia del sistema, especialmente en escenarios con alta penetración de energía eólica. Dentro de esta técnica existen dos clasificaciones fundamentales: la emulación de inercia oculta y la reserva de potencia rápida [132].

- *Emulación de inercia oculta*

En la emulación de inercia oculta se introducen nuevos lazos de control para liberar la energía cinética almacenada en las palas giratorias del aerogenerador cuando ocurre una desviación de frecuencia significativa. En este caso, la energía cinética almacenada contribuye a la respuesta inercial en un rango de tiempo de 2 a 6 s. Existen dos enfoques fundamentales asociados a esta técnica: el primero utiliza un único lazo de control basado en el RoCoF, mientras que el segundo utiliza dos lazos de control, uno basado en el RoCoF y otro en las desviaciones de frecuencia. En la Figura 4.13 se ilustra el diagrama en bloques para la técnica de emulación de inercia oculta con un lazo de control basado en el RoCoF. En este proceso, la potencia activa (P_{in}) que se obtiene desde el lazo de control de inercia se determina como [9], [132]:

$$P_{in} = 2H_{in} \cdot \frac{d\omega_{sys}}{dt} \cdot \omega_{sys} \quad (4.17)$$

donde H_{in} y ω_{sys} representan la constante de inercia sintética y la frecuencia angular del sistema, respectivamente.

No obstante, es importante considerar que la liberación de energía cinética del rotor puede provocar una reducción temporal en la velocidad del aerogenerador, lo que requiere una estrategia de recuperación posterior para restablecer las condiciones normales de operación.




Figura 4.13. Diagrama en bloques de la técnica de emulación de inercia oculta con un lazo de control.

- *Reserva de potencia rápida*

En esta técnica, la reserva de potencia rápida se logra controlando el punto de ajuste de la velocidad del rotor, como se muestra en la Figura 4.14. En este proceso, la cantidad de potencia activa constante (P_{const}) y el tiempo de duración de la reserva de potencia rápida (t) son esenciales para determinar la velocidad de referencia del rotor ($\omega_{r,ref}$) según la ecuación (4.18) [9], [132]:

$$\omega_{r,ref} = \sqrt{\omega_{r0}^2 - \frac{P_{const}}{J} \cdot t} \quad (4.18)$$

donde ω_{r0} representa la velocidad de rotación inicial y J representa el momento de inercia.




Figura 4.14. Diagrama en bloques de la técnica de control de reserva de potencia rápida.

4.7.2.2 Control de descarga

Al igual que en los sistemas PV, la operación de los aerogeneradores de velocidad variable está controlada por un algoritmo de MPPT y, por lo tanto, no disponen de reservas de energía para contribuir al control de la frecuencia. En la técnica de control de descarga se selecciona un punto de operación por debajo del punto de operación óptimo, lo que permite disponer de una reserva de potencia para contribuir al control de la frecuencia del sistema. Existen dos enfoques fundamentales dentro de esta técnica: el control del ángulo de paso y el control de la velocidad. En el control del ángulo de paso se modifica el ángulo de las palas del aerogenerador manteniendo constante la velocidad del rotor, con el propósito de ajustar la potencia activa de salida. Por su parte, en el control de velocidad se varía la velocidad del rotor mientras se mantiene constante el ángulo de paso, para un propósito similar. En este caso se incluyen controles de baja velocidad y de sobrevelocidad, capaces de soportar el control de frecuencia del aerogenerador bajo una amplia gama de perturbaciones. Además, es importante mencionar que, al igual que en la técnica de descarga PV, la descarga eólica también se ve afectada por un cierto margen de pérdida al desviarse continuamente del punto de máxima potencia [9], [132].

4.8 Control de frecuencia mediante inversores

Los inversores se consideran actualmente elementos esenciales para garantizar la operación de redes eléctricas y microrredes con una presencia marcada de RES en su matriz energética. De manera general, se clasifican en dos grupos fundamentales: inversores de seguimiento de red (*Grid Following*, GFL) e inversores de formación de red (*Grid Forming*, GFM) [133].

Desde el punto de vista del control, el funcionamiento de los inversores GFL se representa de manera aproximada mediante una fuente controlada de corriente con una impedancia en paralelo de alto valor, como se ilustra en la Figura 4.15a. Este tipo de inversores regula su potencia de salida midiendo el ángulo del voltaje de la red en el punto de acoplamiento común mediante un lazo de seguimiento de fase (*Phase-Locked Loop*, PLL). Es decir, los inversores GFL siguen el voltaje y la frecuencia de la red, e inyectan corriente para regular la salida de potencia activa y reactiva. Por su parte, los inversores GFM se representan de forma aproximada mediante una fuente controlada de voltaje con una impedancia en serie de bajo valor, como se ilustra en la Figura 4.15b. Estos inversores tienen la capacidad de formar su propio voltaje para regular la potencia de salida. De esta forma pueden operar de manera aislada, estableciendo sus propias referencias de voltaje y frecuencia en ausencia de la red principal [133], [134].




Figura 4.15. Representación aproximada de los inversores: (a) GFL y (b) GFM.

En los últimos años se han desarrollado algunas técnicas de control mediante las cuales los inversores GFM adquieren la capacidad de proporcionar inercia virtual y contribuir a la regulación de la frecuencia de la red. Entre las técnicas más reconocidas en este contexto se encuentran los generadores síncronos virtuales (*Virtual Synchronous Generators*, VSG), los sincroconvertidores (*Synchronverters*) y la técnica de caída (*droop*) [123], [125], [133].

4.9 Control de frecuencia mediante sistemas de almacenamiento de energía

Los sistemas de almacenamiento de energía (*Energy Storage Systems*, ESS) se consideran una solución eficaz para mejorar la estabilidad de frecuencia en redes eléctricas con altos niveles de penetración de RES. Entre los ESS aplicados con éxito en esta tarea se incluyen el sistema de almacenamiento de energía hidráulica por bombeo (*Pumped Hydro Energy Storage System*, PHESS), el sistema de almacenamiento de energía por aire comprimido (*Compressed Air Energy Storage System*, CAESS) y el sistema de almacenamiento de energía por volante de inercia (*Flywheel Energy Storage System*, FESS). También se incluyen el sistema de almacenamiento de energía por supercapacitor (*Supercapacitor Energy Storage System*, SCESS) y el sistema de almacenamiento de energía en baterías (BESS), entre otros [125].

Aunque existe una amplia variedad de ESS, el análisis de esta sección se centra en dos de ellos (FESS y BESS) que se han utilizado ampliamente para el control de frecuencia en microrredes con alta penetración de RES. Sus principales características se describen a continuación.

- *FESS*

Un FESS está integrado típicamente por tres componentes fundamentales: una masa giratoria, un motor/generador eléctrico y un convertidor electrónico. La energía de la red eléctrica se utiliza para acelerar la masa giratoria en períodos de baja demanda y almacenar energía cinética. Posteriormente, esta energía se libera a la red cuando ocurre una desviación de frecuencia. Estos dispositivos ofrecen una alta eficiencia de ida y vuelta en el orden del 93 % - 95 %, así como capacidad de respuesta rápida y alta densidad de potencia. Los FESS se consideran una tecnología prometedora para la regulación de frecuencia en redes eléctricas y microrredes con alta penetración de fuentes PV y eólicas. Además, sus aplicaciones incluyen la regulación de voltaje, así como la reducción de picos y de intermitencias en RES. Sin embargo, es importante mencionar que tienen una mayor tasa de autodescarga en comparación con otros ESS [125], [135].

- *BESS*

En un BESS, la energía eléctrica se almacena en forma de energía química mediante procesos electroquímicos. Entre los principales tipos de BESS se encuentran las baterías de plomo-ácido, las de níquel-cadmio y las de iones de litio, entre otras. Estos sistemas se caracterizan por su capacidad de almacenamiento energético y su idoneidad para suministrar energía durante periodos prolongados, aunque sus prestaciones dependen de la tecnología empleada. Actualmente, los BESS se consideran una de las tecnologías de almacenamiento de energía más maduras y se han aplicado exitosamente para el control de frecuencia en redes eléctricas de todo el mundo. También es importante destacar su utilidad en microrredes aisladas, donde la variabilidad en la generación es elevada debido a la intermitencia de las RES [125], [136].

4.10 Consideraciones importantes para el control de frecuencia en microrredes

4.10.1 Principales características de las microrredes

De manera general, una microrred se define como un grupo de cargas interconectadas y DER (generadores distribuidos, dispositivos de almacenamiento de energía o cargas controlables) con características eléctricas claramente definidas. Estos elementos actúan como una única entidad controlable con respecto a la red eléctrica principal. Además, una microrred puede operar conectada o aislada de la red principal, garantizando en ambos casos un suministro de energía estable a los diferentes usuarios. Cuando opera en modo conectado, comparte energía con la red principal a través del punto de acoplamiento común. En este caso, la red principal se considera un nodo *slack* (es decir, una fuente de generación infinita) que se encarga de balancear la oferta y la demanda de energía. Por otro lado, en el modo de operación aislado, la microrred debe ser capaz de balancear por sí misma la oferta y la demanda de energía sin el apoyo de la red principal [137], [138].

La generación de energía en una microrred se sustenta principalmente en RES no controlables (fuentes PV y eólicas). También puede disponer de fuentes controlables, como generadores con motor diésel (*Diesel Engine Generator*, DEG), microturbinas o generadores de celda de combustible (*Fuel Cell Generator*, FCG), que se utilizan con fines de respaldo. Además, puede incluir algunos ESS para contribuir al equilibrio energético y a la operación eficiente del sistema [138]. También se debe mencionar que las microrredes presentan varias diferencias importantes con respecto a los sistemas eléctricos de potencia. Por ejemplo, tienen menor tamaño y una mayor relación de resistencia a reactancia (R/X). Además, presentan un mayor nivel de incertidumbre operacional y una inercia mucho más reducida, debido principalmente a la intermitencia de las RES y a la presencia de convertidores electrónicos [137].

Por otro lado, según el tipo de corriente utilizada, las microrredes se clasifican en microrredes de AC, microrredes de DC y microrredes híbridas AC/DC. Las microrredes de AC se encuentran entre las más utilizadas. En este caso, las fuentes PV y eólicas, así como los ESS, utilizan un inversor de potencia para su conexión a la red de AC. En las microrredes de DC, las RES y los ESS se conectan a un nodo común de DC. Debido a la ausencia de potencia reactiva y de frecuencia en las microrredes de DC puras, su control resulta relativamente más sencillo en comparación con su contraparte de AC. Por su parte, las microrredes

híbridas AC/DC combinan ambas configuraciones y se consideran una solución viable para la integración de RES en la red eléctrica [137], [139].

Para garantizar que los parámetros eléctricos de la microrred (incluida la frecuencia) se mantengan dentro de rangos adecuados, es necesario utilizar un sistema de control. Dicho sistema se encarga de gestionar el equilibrio energético de la microrred en sus distintos modos de operación. Los tipos de control utilizados en microrredes se agrupan en tres categorías principales: control centralizado, control descentralizado y control jerárquico. En el control centralizado se utiliza un único controlador que recibe toda la información y se comunica con los componentes de la red. En cambio, el control descentralizado no requiere de una infraestructura de comunicaciones tan amplia como en el caso anterior, ya que se basa únicamente en mediciones locales para la toma de decisiones. Por último, el control jerárquico ofrece un compromiso entre las estructuras de control centralizadas y descentralizadas, e incluye controles primarios, secundarios y terciarios [137], [138], [139].

4.10.2 Enfoques utilizados para el control de frecuencia en microrredes

El control de frecuencia en microrredes se considera una tarea desafiante debido a las particularidades de este tipo de sistemas. Para facilitar la comprensión de este tema, en la Tabla 4.2 se resumen las principales características de algunas investigaciones relevantes realizadas en este campo.

Tabla 4.2. Estado del arte sobre el control de frecuencia en microrredes.

Ref.	Sistema de prueba	Modelo utilizado	Tipo de controlador	Plataforma de simulación	Aspectos relevantes
[140]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal	Controlador robusto H_{∞}	Matlab/Simulink y <i>hardware</i> en lazo en tiempo real (HIL)	El método de control aplicado resulta adecuado para reducir las desviaciones de frecuencia ante variaciones repentinas en la producción de energía de las RES y en la demanda de las cargas.
[141]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal	Controlador proporcional integral (PI) combinado con lógica difusa y PSO	No se indica	Las simulaciones realizadas demuestran la efectividad del controlador inteligente (PSO-Fuzzy PI) en comparación con los controladores PI y Fuzzy PI.
[142]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal	Controlador de inercia virtual H_{∞}	Matlab/Simulink	El enfoque de control propuesto regula adecuadamente la frecuencia de la microrred. Además, exhibe un desempeño robusto ante fluctuaciones en la potencia de las RES, las cargas y variaciones en la inercia del sistema.
[143]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal	Controlador robusto H_{∞}	Matlab/Simulink y simulador en tiempo real Opal-RT	Este estudio incorpora una sección para el pronóstico de las RES utilizando redes neuronales LSTM. Posteriormente, integra los errores de pronóstico en un esquema de control secundario para mejorar el desempeño general de la frecuencia de la microrred.

Tabla 4.2. Continuación

[144]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal	Control de inercia virtual robusto basado en el método de diagrama de coeficientes (CDM)	Matlab/Simulink	La estrategia propuesta muestra un buen desempeño en condiciones de baja inercia del sistema, así como ante incertidumbres provocadas por la variación de las cargas y las RES.
[145]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal y modelo discreto de espacio de estados	Control predictivo de modelo de orden fraccional (FOMPC)	Matlab	El enfoque propuesto se compara satisfactoriamente con otros métodos de la literatura. El sistema demuestra robustez bajo disturbios en la carga, parámetros del sistema y fluctuaciones eólicas aleatorias.
[146]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal	Controlador basado en el método de control predictivo (MPC) optimizado mediante PSO	No se indica	El método de control muestra un desempeño satisfactorio en un amplio rango de condiciones de operación. Además, se logra una reducción efectiva de las desviaciones de frecuencia en comparación con otros métodos de referencia.
[147]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal	Controlador PI ajustado mediante un modelo GA-ANN	Matlab/Simulink	En este estudio, el modelo GA-ANN se utiliza para lograr un mejor ajuste de los parámetros del controlador PI. Las simulaciones realizadas evidencian un desempeño satisfactorio ante diferentes tipos de perturbaciones.
[148]	Microrred de AC en modo aislado con múltiples DER	Modelo de pequeña señal	Controlador inteligente basado en un sistema de inferencia neuro-difuso adaptativo recurrente (RANFIS) combinado con un algoritmo de optimización de ballenas (WOA)	Matlab/Simulink	La incorporación del controlador inteligente propuesto contribuye a mejorar el control de frecuencia de la microrred bajo diversas condiciones. El enfoque considera incertidumbres en la demanda y variaciones en la irradiancia solar del sistema PV.

El análisis realizado indica que las microrredes de AC en modo de operación aislado, con múltiples DER, constituyen un sistema de prueba ampliamente utilizado para este tipo de estudios. Además, el modelo de pequeña señal de bajo orden se considera una herramienta adecuada para analizar el control de frecuencia en este tipo de microrredes. Respecto al tipo de controlador, existe una amplia diversidad de enfoques. Sin embargo, los resultados muestran que la combinación de controladores tradicionales con técnicas de IA puede mejorar significativamente el rendimiento y la adaptabilidad en múltiples escenarios operativos. Es importante destacar el enfoque de la referencia [143], donde utilizan los pronósticos de las RES como una herramienta para mejorar el control de frecuencia. No obstante, en la literatura revisada no se han encontrado estudios que analicen de manera directa y cuantitativa cómo la precisión de los pronósticos de energía solar PV y eólica impacta la respuesta de frecuencia en microrredes aisladas. La presente tesis aborda este vacío investigativo, demostrando las ventajas que ofrece un pronóstico preciso para la operación y la estabilidad de una microrred aislada.

4.10.3 Modelo de los elementos de la microrred para estudios de control de frecuencia

El control de frecuencia en microrredes aisladas se considera una tarea desafiante dentro del campo de los sistemas eléctricos modernos. Las características de los diferentes elementos que integran una microrred suelen ser variables en el tiempo y con dinámicas no lineales de alto orden, lo que aumenta la complejidad del problema [140], [143], [146]. Por lo tanto, para llevar a cabo este tipo de estudios, es necesario disponer de un modelo que sea lo suficientemente preciso y que, al mismo tiempo, resulte fácil de implementar e interpretar. Como se ha demostrado en la sección anterior, los modelos de pequeña señal se han aplicado con éxito en varias investigaciones. Estos modelos resultan adecuados para analizar el control de frecuencia en microrredes aisladas, considerando variaciones en la carga y en la generación renovable alrededor del punto de operación.

En esta tesis, se emplea un modelo de bajo orden de pequeña señal para representar los diferentes elementos que integran la microrred, incluyendo las RES (sistemas PV y eólico), los ESS (BESS y FESS) y las fuentes de generación controladas (DEG y FCG). Los modelos se expresan en forma normalizada, priorizando la representación de las dinámicas dominantes del sistema sobre la magnitud absoluta de las variables. Además, se incluyen lazos de control inercial y primario, cuya función es evitar el colapso de la frecuencia del sistema antes de que actúe el control secundario. No obstante, el análisis se centra en la respuesta de frecuencia secundaria, por ser la más relevante para compensar desequilibrios energéticos en horizontes de predicción de varios minutos, cuya efectividad se valida en esta tesis mediante el análisis de la respuesta dinámica transitoria (escala de segundos) ante cada variación del recurso.

4.10.3.1 Modelo de las RES

La generación de las RES no se controla directamente, ya que depende de las condiciones climáticas y su naturaleza es altamente estocástica e intermitente. Para realizar un estudio de control de frecuencia, el comportamiento de las RES conectadas a la microrred (representadas en este caso por un sistema PV y un sistema eólico) se puede modelar mediante las ecuaciones (4.19) y (4.20) [140], [143]:

$$\Delta P_{PV}(s) = \frac{1}{1 + sT_{PV}} \cdot \Delta P_{solar}(s) \quad (4.19)$$

$$\Delta P_w(s) = \frac{1}{1 + sT_{wtg}} \cdot \Delta P_{eólica}(s) \quad (4.20)$$

donde $\Delta P_{solar}(s)$ y $\Delta P_{eólica}(s)$ representan las variaciones en la potencia solar y la eólica; T_{PV} y T_{wtg} representan las constantes de retardo de tiempo para el sistema PV y el sistema eólico; mientras que $\Delta P_{PV}(s)$ y $\Delta P_w(s)$ corresponden a la potencia extraída de dichas RES.

Estos modelos se pueden representar mediante diagrama de bloques, como se ilustra en la Figura 4.16, lo que facilita la comprensión de la dinámica de las RES dentro del esquema de control de frecuencia.



Figura 4.16. Modelo de pequeña señal de las RES para estudios de control de frecuencia: (a) Sistema PV y (b) Sistema eólico.

4.10.3.2 Modelo de las fuentes de generación controladas

Debido a la variabilidad de la generación renovable y de la demanda eléctrica, se requieren fuentes de generación controlables que puedan participar en la regulación de la potencia activa y la frecuencia de la microrred [143]. En este trabajo, dichas fuentes están representadas por un DEG y un FCG. El funcionamiento del DEG y su modelo de pequeña señal son similares a los del generador síncrono analizado en la Sección 4.5 de este capítulo. Es importante destacar que el DEG puede participar en las etapas de respuesta inercial y control primario, mediante la acción de su inercia rotatoria y del gobernador de velocidad, así como en el control secundario a través del controlador central de la microrred. Por su parte, el FCG participa solamente en la etapa de control secundario.

El FCG se considera un dispositivo de conversión electroquímica de energía que transforma la energía química almacenada en forma de hidrógeno en energía eléctrica de DC. Cuando el hidrógeno proviene de fuentes renovables como la energía solar o la eólica se denomina hidrógeno verde. El modelo del FCG considera dos subsistemas principales: la celda de combustible y el inversor. El FCG contribuye al equilibrio entre generación y demanda mediante las señales del controlador principal de la microrred, regulando así la frecuencia del sistema. Considerando estos aspectos, el comportamiento dinámico del FCG se puede representar mediante las ecuaciones (4.21) y (4.22) [140], [141]:

$$\Delta P_{FCG}(s) = \frac{1}{(1 + sT_{FC})(1 + sT_{inv})} \cdot \Delta PCE(s) \quad (4.21)$$

$$\Delta PCE(s) = k(s) \cdot \Delta f(s) \quad (4.22)$$

donde $\Delta P_{FCG}(s)$ representa la variación en la potencia de salida del FCG; T_{FC} y T_{inv} son las constantes de retardo de tiempo asociadas a la celda de combustible y al inversor, respectivamente; y $\Delta PCE(s)$ representa la señal de error de potencia generada por el controlador de la microrred $k(s)$ en respuesta a las desviaciones de frecuencia.

La representación del modelo del FCG en forma de diagrama de bloques se muestra en la Figura 4.17.



Figura 4.17. Modelo de pequeña señal del FCG para estudios de control de frecuencia.

4.10.3.3 Modelo de los ESS

Las fuentes de generación controladas necesitan un margen de tiempo definido para responder y entregar energía a la microrred. Debido a esto, surge la necesidad de disponer de otras fuentes de respaldo capaces de sostener la operación del sistema hasta que las fuentes controladas comiencen a operar. Para este propósito se utilizan los ESS, representados en este caso por un BESS y un FESS, cuyo comportamiento se puede modelar mediante las ecuaciones (4.23) y (4.24) [140], [146]:

$$\Delta P_{BESS}(s) = \frac{1}{1 + sT_{BESS}} \cdot \Delta f(s) \quad (4.23)$$

$$\Delta P_{FESS}(s) = \frac{1}{1 + sT_{FESS}} \cdot \Delta f(s) \quad (4.24)$$

donde $\Delta P_{BESS}(s)$ y $\Delta P_{FESS}(s)$ representan el cambio en la potencia del BESS y el FESS, respectivamente; mientras que T_{BESS} y T_{FESS} corresponden a las constantes de retardo de tiempo de cada ESS.

En este caso, es importante mencionar que la operación de estos dispositivos se regula de manera tal que, cuando la generación supera a la demanda ($\Delta f > 0$), los ESS absorben energía de la microrred para cargarse; en caso contrario ($\Delta f < 0$), aportan energía a la microrred. Por lo tanto, los ESS presentan un carácter dual, adoptando un signo negativo cuando absorben energía de la microrred y un signo positivo cuando la suministran.

Los modelos descritos anteriormente se pueden representar en forma de diagrama de bloques, como se muestra en la Figura 4.18.




Figura 4.18. Modelo de pequeña señal de los ESS para estudios de control de frecuencia: (a) BESS y (b) FESS.

4.10.3.4 Modelo para analizar las desviaciones de frecuencia

El modelo de las desviaciones de frecuencia de la microrred se basa en la ecuación de oscilación del generador síncrono presentada en la Sección 4.5.2. Esta ecuación relaciona la potencia neta del sistema con la variación de frecuencia a través de la inercia total (H) y el amortiguamiento de la carga equivalente (D). En este caso, el análisis se extiende para considerar la potencia neta (ΔP_{neta}) de todos los elementos de la microrred (RES, DEG, FCG y ESS) y la variación de la carga. La ΔP_{neta} de la microrred se determina como la suma algebraica de la potencia generada (positiva) y la potencia absorbida (negativa), como se observa en la ecuación (4.25) [146], [149]:

$$\Delta P_{neta}(s) = \Delta P_{PV}(s) + \Delta P_w(s) + \Delta P_{DEG}(s) + \Delta P_{FCG}(s) \pm \Delta P_{BESS}(s) \pm \Delta P_{FESS}(s) - \Delta P_{carga}(s) \quad (4.25)$$

El modelo considera tres entradas externas que actúan como disturbios: los cambios en la potencia de las RES ($\Delta P_{PV}(s)$ y $\Delta P_w(s)$) y los cambios en la demanda de las cargas ($\Delta P_{carga}(s)$).

Para cuantificar las variaciones de frecuencia y evaluar el desempeño del sistema de control frente a los disturbios, se emplean diversos índices de desempeño. Entre los más utilizados se encuentran la integral del error absoluto (*Integral Absolute Error*, IAE), la integral del error cuadrático (*Integral of Squared Error*, ISE) y la integral del error absoluto ponderado en el tiempo (*Integral Time-Weighted Absolute Error*, ITAE), definidos mediante las ecuaciones (4.26–4.28) [149]:

$$IAE = \int_0^{t_{sim}} |\Delta f| \cdot dt \quad (4.26)$$

$$ISE = \int_0^{t_{sim}} |\Delta f|^2 \cdot dt \quad (4.27)$$

$$ITAE = \int_0^{t_{sim}} |\Delta f| \cdot t \cdot dt \quad (4.28)$$

donde Δf representa la desviación de frecuencia de la microrred (en Hz o pu) y t es el período de tiempo de la simulación en s.

4.10.4 Diseño del controlador de la microrred

En el contexto del control de frecuencia en microrredes aisladas, cuando existen DEG o microturbinas, es común emplear el método de control basado en la característica de caída del gobernador de velocidad. Este enfoque es eficiente para el control de frecuencia primario, pero no logra restaurar la frecuencia a su valor nominal. Por lo tanto, siempre es necesario implementar un controlador de frecuencia secundario que garantice una operación estable y segura de la microrred [148].

De manera general, un controlador genera señales para reducir la desviación de una variable real respecto a su valor deseado [149]. Como se ha analizado en secciones anteriores, existen diferentes tipos de controladores ampliamente utilizados en la literatura para el control de frecuencia en microrredes, cada uno con ventajas y limitaciones. Entre ellos, los controladores de tipo proporcional integral derivativo (*Proportional Integral Derivative*, PID) han demostrado un buen desempeño y son relativamente fáciles de implementar. Además, la combinación de los controladores PID con técnicas de IA, como los algoritmos de optimización metaheurísticos, puede mejorar significativamente su rendimiento y flexibilidad.

4.10.4.1 Descripción del controlador de tipo PID

La estructura de un controlador PID combina tres acciones de control fundamentales: proporcional, integral y derivativa. La acción proporcional actúa sobre el error, proporcionando una respuesta proporcional a su magnitud. Por su parte, la acción integral se encarga de eliminar el error residual acumulado en el tiempo, garantizando que la señal de salida alcance el valor deseado. Finalmente, la acción derivativa mejora el desempeño del controlador durante la operación transitoria, anticipándose a cambios rápidos en el error y contribuyendo a estabilizar la respuesta del sistema. El funcionamiento de un controlador PID se puede representar matemáticamente mediante la ecuación (4.29) [123], [149]:

$$G_{PID}(s) = K_p + \frac{K_i}{s} + K_d \cdot s \quad (4.29)$$

donde K_p , K_i y K_d representan las ganancias proporcional, integral y derivativa del controlador, respectivamente.

La estructura del controlador PID se muestra en forma de diagrama de bloques en la Figura 4.19.




Figura 4.19. Estructura del controlador PID.

4.10.4.2 Optimización de los parámetros del controlador

El principal desafío en la implementación de un controlador PID radica en el ajuste adecuado de los valores de K_p , K_i y K_d . Para determinar estos valores pueden emplearse distintos métodos, como prueba y error, *Ziegler-Nichols* o técnicas basadas en algoritmos de IA [123]. En este trabajo se utiliza este último enfoque, optimizando los parámetros mediante algoritmos metaheurísticos como PSO y optimización del lobo gris (*Grey Wolf Optimization*, GWO). Estos algoritmos se seleccionan por su efectividad en la sintonización de controladores, su rápida convergencia y la calidad de las soluciones obtenidas [141], [143], [146].

En este caso, el vector de variables de decisión del problema de optimización se define como:

$$x = [K_p, K_i, K_d] \quad (4.30)$$

Este vector representa las ganancias del PID que deben ser ajustadas por los algoritmos mencionados. Un aspecto esencial en este proceso es la definición de la función objetivo y de las restricciones del problema de optimización. En control de frecuencia, la función objetivo suele definirse mediante alguno de los índices de desempeño descritos previamente, como IAE, ISE o ITAE [123], [149]. En este estudio se selecciona el índice ITAE como función objetivo, ya que penaliza de manera efectiva las desviaciones de frecuencia prolongadas y es ampliamente utilizado en el control de microrredes. Por lo tanto, el problema de optimización consiste en minimizar esta métrica, definida previamente en la ecuación (4.28), cuyos valores se obtienen directamente durante la simulación del modelo de la microrred.

Formalmente, el problema de optimización se expresa como:

$$\min_{K_p, K_i, K_d} ITAE \quad (4.31)$$

Además, en este proceso se consideran algunas restricciones relacionadas con los límites inferior (L_b) y superior (U_b) del espacio de búsqueda definido para las variables, de manera que:

$$L_b = [K_{p,min} \quad K_{i,min} \quad K_{d,min}] \quad (4.32)$$

$$U_b = [K_{p,max} \quad K_{i,max} \quad K_{d,max}] \quad (4.33)$$

Para delimitar el espacio de búsqueda de los algoritmos de optimización y garantizar la obtención de soluciones dentro de rangos operativos adecuados, se establecen los siguientes límites para los parámetros del controlador PID [150], [151]:

$$L_b = [0.1 \ 0.1 \ 0] \quad (4.34)$$

$$U_b = [20 \ 20 \ 5] \quad (4.35)$$

Estos límites se establecen con base en la literatura especializada y en pruebas preliminares del sistema, asegurando que los valores obtenidos sean implementables en la práctica. Los valores finales obtenidos mediante cada algoritmo se analizan detalladamente en la Sección 7.6 del Capítulo 7.

4.11 Acciones remediales en el sistema eléctrico

La ocurrencia de eventos críticos dentro del sistema eléctrico puede provocar grandes desviaciones de frecuencia, lo que pone en riesgo la estabilidad del sistema y afecta significativamente su operación. Para enfrentar estos problemas se han propuesto diferentes esquemas de acción remedial (*Remedial Action Schemes*, RAS), tales como la desconexión de carga y la desconexión de generación [149]. Entre los RAS más utilizados en los sistemas eléctricos modernos se encuentra el deslastre de carga por baja frecuencia (*Under-Frequency Load Shedding*, UFLS). Este esquema consiste en desconectar cantidades predeterminadas de carga cuando la frecuencia cae por debajo de un umbral establecido. El esquema UFLS se aplica en situaciones de emergencia, cuando la respuesta inercial y la respuesta de frecuencia primaria proporcionada por los gobernadores no son suficientes para detener la caída de frecuencia [123], [149].

Los esquemas UFLS se pueden clasificar en tres categorías principales: estático, adaptativo y semiadaptativo. Generalmente, el término UFLS se asocia con el esquema estático, en el cual las cargas a desconectar en cada etapa están previamente definidas [123]. Como se muestra en la Figura 4.20a, el deslastre se divide en varias etapas para hacer frente al desequilibrio entre generación y carga después de una perturbación. En este caso, f_1 , f_2 y f_3 representan los umbrales de frecuencia de desconexión correspondientes a cada etapa. Cuando la frecuencia cae por debajo de un umbral durante un retardo de tiempo específico, se desconectan las cargas predeterminadas para evitar mayores disminuciones. Los retardos de tiempo se ajustan en función del comportamiento de frecuencia para mejorar la capacidad de respuesta del esquema.

En la Figura 4.20b se comparan algunos esquemas UFLS de tipo estático con diferente número de etapas. Se observa que el esquema de 12 etapas presenta una mejor capacidad de adaptación frente a diferentes condiciones de operación que el esquema de 5 etapas. Profundizando aún más en este análisis, si el número de etapas del esquema UFLS tiende a infinito, la curva de desconexión de carga se vuelve continua. De esta forma, la cantidad de carga desconectada (P_{LS}) se puede determinar mediante la ecuación (4.36) [149]:

$$P_{LS} = -K_{LS} \cdot \Delta f \quad (4.36)$$

donde K_{LS} representa un factor de escala para la desconexión de carga, que debe ajustarse adecuadamente.




Figura 4.20. Esquema UFLS de tipo estático: (a) Representación general y (b) Efecto de la variación del número de etapas [123].

En cambio, en el esquema adaptativo, las cargas se desconectan en función de la magnitud del disturbio y de la respuesta de frecuencia del sistema. En este contexto, es común utilizar el RoCoF para su diseño. Por otro lado, el esquema semiadaptativo combina características de ambos enfoques. En una primera etapa, las cargas a desconectar se determinan de manera similar al esquema adaptativo, mientras que para las etapas posteriores la desconexión se realiza de manera predefinida, como en el esquema estático [123], [149].

4.12 Conclusiones del capítulo

En este capítulo se han abordado los aspectos fundamentales del control de frecuencia en redes eléctricas. Para establecer las bases del estudio, se han revisado conceptos generales sobre la estabilidad de frecuencia, las desviaciones de frecuencia y algunos de los indicadores utilizados para su evaluación. También se ha profundizado en cuestiones relacionadas con la respuesta de frecuencia del sistema, ofreciendo una descripción precisa de cada una de las etapas que la integran. Además, se ha analizado el modelo del generador síncrono y de sus principales componentes para este tipo de estudios. Este enfoque puede servir como referencia para extender el análisis a sistemas eléctricos modernos de mayor complejidad.

Por otro lado, se han identificado los principales impactos que provoca la integración a gran escala de las RES sobre el comportamiento de la frecuencia del sistema. Asimismo, se han discutido algunas de las técnicas propuestas en los últimos años para garantizar que los sistemas PV y eólicos, los inversores GFM y los ESS puedan contribuir al control de la frecuencia de la red. También se han estudiado las particularidades del control de frecuencia en microrredes, identificando tendencias actuales, desafíos técnicos y oportunidades de investigación. Además, se han formulado los modelos en pequeña señal de los principales componentes de la microrred, adoptando una representación basada en ganancias unitarias y variables normalizadas. Por otro lado, se ha profundizado en cuestiones relacionadas con el diseño y el ajuste de los parámetros del controlador de frecuencia mediante algoritmos de optimización metaheurísticos, utilizando la métrica ITAE como criterio de desempeño. Finalmente, se han analizado estrategias remediales, como los esquemas UFLS, orientadas a preservar la estabilidad del sistema ante perturbaciones severas.

Los aspectos que se han abordado en este capítulo constituyen el soporte teórico y metodológico para el esquema de control de frecuencia presentado en el Capítulo 7, donde se evalúa el impacto del pronóstico de las RES sobre la estabilidad de frecuencia de una microrred aislada.

CAPÍTULO 5. PRINCIPALES RESULTADOS OBTENIDOS EN EL PRONÓSTICO DE ENERGÍA SOLAR PV

5.1 Introducción

En este capítulo se presentan y discuten los resultados más relevantes obtenidos en el pronóstico de energía solar PV. Inicialmente, se describen las principales características de cada conjunto de datos utilizado en el estudio. Posteriormente, se analizan los resultados obtenidos en la etapa de preprocesamiento y preparación de los datos. Esto incluye el análisis estadístico y gráfico, la limpieza de los datos, la selección de las características de entrada al modelo de predicción y la identificación de rezagos en las series temporales. También se describen los aspectos fundamentales del modelo de pronóstico propuesto y de los modelos de referencia utilizados para fines comparativos. Además, se analizan detalladamente los resultados obtenidos en el pronóstico determinístico y probabilístico de energía solar PV para un horizonte de muy corto plazo. Por último, se examina el nivel de importancia de cada variable de entrada para el modelo de pronóstico propuesto y se evalúa su desempeño en condiciones de operación atípicas asociadas con la pérdida de información y la presencia de ruido blanco en las mediciones disponibles.

5.2 Descripción de los datos utilizados

La mayoría de las investigaciones existentes en el campo de la predicción de energía solar evalúan sus modelos utilizando datos de una sola instalación PV. De este modo, no validan el rendimiento y la adaptabilidad de los modelos desarrollados en otros conjuntos de datos con diferentes características y bajo diversas condiciones climáticas. Para superar estas limitaciones, este estudio utiliza datos de tres sistemas PV con diferentes características y ubicaciones geográficas.

El primer conjunto de datos, denominado *D1*, proviene de una instalación PV ubicada en la Escuela Politécnica Superior de la Universidad de Alcalá en España, con una capacidad instalada de 2.97 kW [152]. La instalación cuenta con nueve módulos solares de silicio policristalino de 330 W cada uno y dispone de una estación meteorológica equipada con diversos dispositivos de medición. Estos dispositivos registran variables cruciales como la irradiancia solar, la velocidad y la dirección del viento, la humedad relativa y la temperatura ambiente. Además, se dispone de mediciones de la temperatura de los paneles y de la potencia PV generada en la instalación. Es importante señalar que la resolución temporal de los datos se establece en intervalos de 15 min, abarcando el período comprendido entre el 1 de enero y el 31 de diciembre de 2021.

El segundo conjunto de datos, denominado *D2*, está públicamente disponible y corresponde a una instalación solar llamada ‘eco-Kinetics’, con una capacidad instalada de 26.52 kW. Este sistema está situado en el *Desert Knowledge Australia Solar Centre (DKASC)* en *Alice Springs*, Australia [153]. Se trata de un sistema PV con seguimiento solar en dos ejes, integrado por 156 paneles solares de silicio monocristalino de 170 W cada uno. El conjunto de datos recopilado abarca mediciones de irradiancia solar, temperatura ambiente, velocidad y dirección del viento, humedad relativa, precipitación y potencia PV generada. Estos datos se registraron con una resolución temporal de 5 min desde el 1 de enero al 31 de diciembre de 2022.

Finalmente, el tercer conjunto de datos, denominado *D3*, también está públicamente disponible y se origina en la región de Flandes en Bélgica [154]. Este conjunto incluye mediciones de la potencia PV generada a escala regional, con una capacidad total instalada en la región de 5468.82 MW. Las mediciones se registraron con una resolución temporal de 15 min y abarcan el período comprendido entre el 1 de enero de 2022 y el 14 de marzo de 2023.

5.3 Resultados obtenidos en el preprocesamiento y la preparación de los datos

El preprocesamiento y la preparación de los datos se consideran etapas cruciales dentro de la estrategia de pronóstico propuesta, ya que permiten mejorar la calidad de los datos históricos disponibles. El algoritmo propuesto para este propósito es riguroso y abarca una amplia variedad de aspectos. En las secciones siguientes, se resumen algunos resultados relevantes que se obtienen al aplicar dicho algoritmo a los datos disponibles.

5.3.1 Resultados obtenidos en el análisis estadístico y gráfico de los datos

En la Tabla 5.1 se describen las principales características de cada conjunto de datos, incluyendo algunos indicadores estadísticos que favorecen la comprensión inicial de su comportamiento. En general, se evidencia que los límites lógicos de cada una de las variables analizadas son apropiados. Además, es importante reconocer la presencia de variaciones de escala dentro de los conjuntos de datos *D1* y *D2*. Este aspecto se aborda mediante la normalización de las variables de entrada al modelo de predicción.

Tabla 5.1. Principales características de los conjuntos de datos utilizados en el estudio.

Conjunto de datos	Variables disponibles	Unidad de medida	Media	Std.	Valor mín.	Valor máx.
<i>D1</i>	Irradiancia global horizontal (<i>GHI</i>)	[W/m ²]	266.45	296.65	0	1144.01
	Velocidad del viento (<i>Ws</i>)	[m/s]	0.14	0.75	0	14.88
	Dirección del viento (<i>Wd</i>)	[°]	35.38	73.65	0	266.02
	Humedad relativa (<i>Rh</i>)	[%]	47.02	18.75	6.01	86.75
	Temperatura ambiente (<i>Ta</i>)	[°C]	19.49	9.49	-7.65	43.17
	Temperatura del panel (<i>Tp</i>)	[°C]	22.96	14.54	-10.02	61.03
	Presión atmosférica (<i>Ps</i>)	[hPa]	947.14	5.54	924.56	962.68
	Potencia PV generada (<i>Ppv</i>)	[kW]	0.68	0.72	0	2.87
<i>D2</i>	Irradiancia global horizontal (<i>GHI</i>)	[W/m ²]	259.06	336.44	0	1297.30
	Temperatura ambiente (<i>Ta</i>)	[°C]	20.38	9.14	-4.36	43.65
	Velocidad del viento (<i>Ws</i>)	[m/s]	3.59	1.46	0	8.06
	Dirección del viento (<i>Wd</i>)	[°]	34.09	14.47	0.03	77.35
	Humedad relativa (<i>Rh</i>)	[%]	32.56	21.71	1.01	91.33
	Precipitación (<i>Pt</i>)	[mm]	0.63	3.08	0	47.40
	Potencia PV generada (<i>Ppv</i>)	[kW]	4.36	5.98	0	22.06
<i>D3</i>	Potencia PV generada (<i>Ppv</i>)	[MW]	654.65	1087.50	0	4582.40

También es importante mencionar que los datos seleccionados para el estudio provienen de tres regiones con diferente comportamiento climático. De acuerdo con la clasificación climática de Köppen [155], el clima de Alcalá de Henares se clasifica como mediterráneo, el de *Alice Springs* como árido o desértico y el de Flandes como marítimo templado. La Figura 5.1 muestra el comportamiento anual de la potencia PV en función de la hora del día y del mes del año para estas tres ubicaciones. La potencia PV para los conjuntos de datos *D1* y *D3* (Figuras 5.1a y 5.1c) presenta una mayor variabilidad a lo largo del año y patrones estacionales bien definidos. Por el contrario, para el conjunto de datos *D2* (Figura 5.1b), esta variable exhibe un comportamiento prácticamente estable a lo largo del año, con variaciones estacionales poco significativas.




Figura 5.1. Variación anual de la potencia PV según la hora del día y el mes del año para los conjuntos de datos: (a) *D1*, (b) *D2* y (c) *D3*.

5.3.2 Resultados obtenidos en la limpieza de los datos

La limpieza de los datos constituye un aspecto esencial dentro de la etapa de preprocesamiento y contribuye en buena medida a mejorar el rendimiento de los modelos de pronóstico. A modo de ejemplo, las Figuras 5.2a y 5.2b muestran los resultados obtenidos en la detección y corrección de valores atípicos en las series temporales de T_p y GHI de los conjuntos de datos *D1* y *D2*, respectivamente. En estas figuras,

la línea cian representa los valores originales de cada variable analizada; mientras que los marcadores amarillos indican los valores atípicos identificados por el algoritmo implementado, considerando los umbrales de detección (líneas puntuadas grises). Además, los marcadores rojos muestran los valores atípicos corregidos y la línea azul representa los valores finales obtenidos para cada serie temporal. Los resultados expuestos evidencian la efectividad del algoritmo propuesto para la solución de este tipo de problemas en cada uno de los casos analizados.




Figura 5.2. Resultados obtenidos en la detección y corrección de valores atípicos: (a) Serie temporal de T_p del conjunto de datos D1 y (b) Serie temporal de GHI del conjunto de datos D2.

Por otro lado, las Figuras 5.3a y 5.3b ilustran algunos resultados asociados con la detección e imputación de valores ausentes en las series temporales de T_a y P_{pv} de los conjuntos de datos D2 y D3, respectivamente. En este caso, la línea azul representa los valores originales de cada variable analizada y la línea roja, los

valores ausentes imputados. Se observa que el método implementado funciona adecuadamente, logrando correcciones precisas que se ajustan satisfactoriamente a la dinámica de comportamiento de cada serie temporal.




Figura 5.3. Resultados obtenidos en la detección e imputación de valores ausentes: (a) Serie temporal de T_a del conjunto de datos $D2$ y (b) Serie temporal de P_{pv} del conjunto de datos $D3$.

Otro aspecto analizado en la etapa de limpieza de los datos está vinculado con la detección y corrección de valores anómalos. En la Figura 5.4a se muestra el gráfico de dispersión inicial de GHI vs. P_{pv} utilizado para la detección de estos valores en el conjunto de datos $D1$. Se observa la presencia de un patrón bien definido que concentra la mayoría de las observaciones, así como de otros grupos de datos más reducidos que no coinciden con el patrón principal. Estos últimos indican la presencia de valores anómalos y se han señalado con líneas discontinuas de color naranja en dicha figura.

Tras identificar los valores anómalos, las series temporales de GHI y P_{pv} se procesan mediante la herramienta *Curve Fitting Toolbox* de MATLAB para obtener una función que modele la tendencia de los datos. Los resultados expuestos en la Figura 5.4b indican que el ajuste polinomial de primer orden proporciona una alta fidelidad y un nivel de ajuste satisfactorio, logrando valores de $RMSE = 0.054$ kW y $R^2 = 0.9944$.

Es importante señalar que no es posible corregir al mismo tiempo todos los valores anómalos detectados, debido a que se ubican en diversas regiones del gráfico de dispersión. Por lo tanto, es necesario aplicar

diferentes filtrados estableciendo límites adecuados para cada una de las regiones señaladas mediante la inspección visual experta. En la Figura 5.4c se ilustran los resultados obtenidos al concluir el proceso de corrección de anomalías. Se observa que el algoritmo propuesto corrige adecuadamente los problemas identificados, lo que conduce a un patrón de comportamiento bien definido, con una buena coherencia en las observaciones.




Figura 5.4. Resultados obtenidos en la detección y corrección de valores anómalos en el conjunto de datos *D1*: (a) Gráfico de dispersión inicial de *GHI* vs. *Ppv*, (b) Curva de tendencia estimada y (c) Gráfico de dispersión final de *GHI* vs. *Ppv*.

5.3.3 Resultados obtenidos en la selección de las características de entrada al modelo de predicción

En este estudio, el proceso de selección de características (FS) se realiza inicialmente mediante un análisis de coeficientes de correlación de Pearson (PCC) entre las variables predictoras y la variable objetivo, representada por la *Ppv*. Los resultados presentados en la Figura 5.5a para el conjunto de datos *D1* revelan una correlación notablemente fuerte entre la variable predictora *GHI* y la *Ppv*, con un valor de 0.9976. Además, la variable *Tp* muestra un nivel de correlación fuerte de 0.8053, seguido por la variable *Ta*, que presenta una correlación moderada de 0.4408. En el caso de las variables *Ws*, *Wd* y *Ps*, sus niveles de correlación son muy bajos (prácticamente cero), lo que indica una relación despreciable con respecto a la variable objetivo. Por último, la variable *Rh* presenta una correlación moderada y negativa de -0.4640, lo

que refleja una relación inversa entre esta variable y la Ppv . Al realizar un análisis similar para el conjunto de datos $D2$, se obtienen los resultados expuestos en la Figura 5.5b. En este caso, el mayor nivel de correlación también corresponde a la variable GHI (0.9806), seguida por las variables Ta y Rh , que presentan correlaciones moderadas de 0.4446 y -0.4248, respectivamente. La variable Ws muestra una correlación débil con un valor de 0.2068, mientras que las restantes variables (Pt y Wd) exhiben valores muy cercanos a cero.




Figura 5.5. Resultados obtenidos en el proceso de FS: (a) Análisis de PCC para el conjunto de datos $D1$, (b) Análisis de PCC para el conjunto de datos $D2$, (c) Estimación de la importancia del predictor mediante un modelo RF para el conjunto de datos $D1$, y (d) Estimación de la importancia del predictor mediante un modelo RF para el conjunto de datos $D2$.

Para obtener una visión más precisa sobre la relevancia de las variables predictoras, se aplica un algoritmo basado en las estimaciones de la importancia del predictor al permutar las observaciones fuera de la bolsa (OOB) en un modelo RF. La descripción detallada de este algoritmo se presenta en la Sección 3.3.4. Los resultados obtenidos para el conjunto de datos $D1$ se ilustran en la Figura 5.5c, donde se evidencia que la variable predictora más relevante es GHI , con un nivel de importancia de 106.92. Además, se observa

que la variable Ta también resulta de utilidad para el modelo, con un nivel de importancia de 29.41. En el caso de las variables Tp y Rh , este indicador se reduce considerablemente a 4.92 y 3.69, respectivamente, a pesar de los niveles de correlación obtenidos para dichas variables mediante el análisis de PCC. Esto se debe principalmente a que el modelo RF maneja adecuadamente la multicolinealidad entre las variables; es decir, tiende a reducir la importancia de las variables predictoras redundantes. Con respecto a las restantes variables (Ws , Wd y Ps), se observa que su nivel de importancia es muy bajo, por lo que se descartan como entradas al modelo de pronóstico.

Al realizar un análisis similar para el conjunto de datos $D2$, se obtienen los resultados expuestos en la Figura 5.5d. En este caso, se observa que la variable GHI presenta nuevamente el mayor nivel de importancia con un valor de 102.74. Además, las variables predictoras Ta y Rh también poseen cierta utilidad, con niveles de importancia de 21.25 y 18.71, respectivamente. En el caso de las variables Pt , Ws y Wd se obtienen niveles de importancia muy bajos, por lo que no se consideran de utilidad para el modelo.

Considerando los resultados obtenidos, se decide utilizar las combinaciones de variables predictoras (GHI y Ta) y (GHI , Ta y Rh) como entradas al modelo de pronóstico desarrollado para los conjuntos de datos $D1$ y $D2$, respectivamente. Otras variables físicamente relevantes, pero con baja contribución predictiva, fueron descartadas para optimizar el desempeño del modelo. De esta forma, la dimensionalidad de los datos iniciales se reduce notablemente al concluir el proceso de FS. Además, se propone la utilización de la variable Ppv como una entrada adicional. En este sentido, al emplear la información de las variables predictoras seleccionadas y de la variable objetivo en el instante de tiempo actual y en varios instantes anteriores (rezagos temporales), es posible incrementar el nivel de información disponible y mejorar la calidad de las predicciones. Por otro lado, se debe mencionar que para el conjunto de datos $D3$ no ha sido necesario aplicar el análisis de FS, debido a que se dispone solamente de mediciones de la Ppv .

5.3.4 Resultados obtenidos en la identificación de rezagos en las series temporales

Otro aspecto importante dentro del algoritmo propuesto para el preprocesamiento y la preparación de los datos es la determinación del número de rezagos (*lags*) en las variables de entrada seleccionadas en la sección anterior. Este proceso se lleva a cabo a través del análisis de las funciones estadísticas ACF y PACF, descritas en la Sección 3.3.5. Los resultados obtenidos para los conjuntos de datos $D1$, $D2$ y $D3$ se muestran en las Figuras 5.6, 5.7 y 5.8, respectivamente. De manera general, en todos los casos analizados se observa que las series temporales bajo estudio presentan un comportamiento aproximadamente autorregresivo, caracterizado por un decaimiento suave de los valores de la ACF y un corte abrupto en la PACF. Esto indica que los valores actuales de las series analizadas dependen fundamentalmente de los primeros rezagos, mientras que la influencia de rezagos más lejanos es despreciable.

Además, los gráficos de PACF correspondientes a los conjuntos de datos $D1$ y $D2$ indican que solo el primer rezago de las series temporales analizadas muestra una fuerte relación con el valor actual de cada una de ellas. Por lo tanto, en estos casos se utiliza el valor actual y el primer rezago de dichas series temporales como entradas al modelo de pronóstico. Para el conjunto de datos $D3$, el gráfico de PACF refleja una fuerte relación entre el valor actual de la serie temporal de Ppv y los dos primeros rezagos, lo que

justifica su inclusión como nuevas entradas del modelo de pronóstico implementado para este conjunto de datos.




Figura 5.6. Análisis de las funciones ACF y PACF aplicadas a las series temporales de *GHI*, *Ta* y *Ppv* del conjunto de datos *D1* para la selección del número de rezagos.




Figura 5.7. Análisis de las funciones ACF y PACF aplicadas a las series temporales de *GHI*, *Ta*, *Rh* y *Ppv* del conjunto de datos *D2* para la selección del número de rezagos.




Figura 5.8. Análisis de las funciones ACF y PACF aplicadas a la serie temporal de P_{pv} del conjunto de datos $D3$ para la selección del número de rezagos.

Considerando los resultados anteriores y la información derivada del proceso de FS, es posible formular la estructura general del modelo de pronóstico para cada uno de los conjuntos de datos analizados, tal como se muestra en la Figura 5.9. Cabe mencionar que para los conjuntos de datos $D1$ y $D3$ se mantiene la resolución temporal original de los datos, mientras que para el conjunto de datos $D2$ la resolución temporal se ha transformado de 5 min a 15 min, después de realizar un análisis de sensibilidad. En todos los casos se considera un horizonte de pronóstico de 15 min (es decir, un paso de tiempo por delante).




Figura 5.9. Estructura general del modelo de pronóstico implementado para cada conjunto de datos analizado: (a) $D1$, (b) $D2$ y (c) $D3$.

5.4 Consideraciones generales para el pronóstico

Para efectuar el pronóstico de la potencia PV para el horizonte temporal requerido, se utiliza un modelo BiLSTM optimizado mediante el algoritmo BO, tal como se describió en la Sección 3.5. Para evaluar su

desempeño, se compara con tres modelos de referencia: una red neuronal MLP, un modelo SVR y un modelo de persistencia, cuyos principales hiperparámetros también se ajustan mediante BO para garantizar una comparación justa (ver Sección 3.6). Las pruebas de desempeño se llevan a cabo en tres conjuntos de datos de diferentes características (conjuntos de datos $D1$, $D2$ y $D3$), lo que aporta mayor solidez al análisis. Todos los experimentos se ejecutan en el *software* MATLAB, utilizando como estación de trabajo un ordenador con *CPU Intel(R) Core (TM) i5-1135G7* a 2.40 GHz y 8 GB de RAM.

En la Tabla 5.2 se resumen los hiperparámetros optimizados mediante BO, sus correspondientes espacios de búsqueda y los valores finales obtenidos para cada modelo y conjunto de datos.

Tabla 5.2. Hiperparámetros, espacios de búsqueda definidos para la BO y ajustes obtenidos para cada modelo.

Modelos	Hiperparámetros	Espacios de búsqueda definidos	Ajustes obtenidos ($D1$)	Ajustes obtenidos ($D2$)	Ajustes obtenidos ($D3$)
BiLSTM	Número de unidades en la capa oculta (<i>NumberOfUnits</i>)	[20 a 200]	91	73	52
	Tasa de aprendizaje inicial (<i>InitialLearnRate</i>)	[0.0001 a 0.01]	0.0099	0.0022	0.0074
	Tamaño del minilote (<i>MiniBatchSize</i>)	[16 a 256]	128	90	58
	Factor de regularización L_2 (<i>L2Regularization</i>)	[10^{-5} a 10^{-2}]	3.3741×10^{-4}	1.0486×10^{-4}	2.2813×10^{-5}
	Tasa de abandono (<i>dropoutVal</i>)	[0.1 a 0.3]	0.1753	0.1426	0.1173
MLP	Número de capas ocultas (<i>NumLayers</i>)	[1 o 2]	1	1	1
	Número de unidades en la capa oculta (<i>hiddenLayersSize</i>)	[3 a 100]	29	26	32
	Función de activación de la capa oculta (<i>transferFcn</i>)	{‘logsig’ ‘tansig’}	tansig	tansig	logsig
	Tasa de aprendizaje (<i>LearningRate</i>)	[0.0001 a 0.01]	1.0333×10^{-4}	9.6821×10^{-3}	1.0719×10^{-4}
SVR	Restricción de caja (<i>BoxConstraint</i>)	[0.001 a 1000]	31.8760	1.8631	26.2770
	Escala del núcleo (<i>KernelScale</i>)	[0.001 a 1000]	0.7094	0.5048	0.6053
	Parámetro de pérdida (<i>Epsilon</i>)	[0.001 a 100]	0.0027	0.0006	0.0012
	Función del núcleo (<i>KernelFunction</i>)	{‘gaussian’ ‘linear’ ‘polynomial’}	gaussian	gaussian	gaussian
	Orden polinomial (<i>PolynomialOrder</i>)	[2 a 4]	-	-	-

* Los términos expresados en idioma inglés corresponden a la denominación utilizada para cada hiperparámetro en el *software* MATLAB.

También es importante precisar el ajuste realizado para otros hiperparámetros que no han formado parte del proceso de optimización, siguiendo las consideraciones presentadas en la Sección 3.5. Por ejemplo, para el modelo BiLSTM, el entrenamiento se lleva a cabo durante 200 épocas, se utiliza como optimizador el algoritmo *Adam* y el umbral del gradiente (*GradientThreshold*) se establece en 1. Además, la programación de la tasa de aprendizaje (*LearnRateSchedule*) se realiza por partes (*piecewise*), mientras que el período de

caída (*LearnRateDropPeriod*) y el factor de caída (*LearnRateDropFactor*) de dicha tasa se ajustan a 120 y 0.2, respectivamente.

Para el modelo MLP, el entrenamiento se realiza mediante el algoritmo *Levenberg-Marquardt* y el número máximo de iteraciones se establece en 1000. Además, se utiliza como función de desempeño (*performFcn*) el MSE y se aplica una función de activación de tipo lineal (*'purelin'*) para la capa de salida. En cuanto al modelo SVR, la mayoría de sus hiperparámetros se ajustan mediante el proceso de optimización descrito previamente, mientras que los restantes hiperparámetros se mantienen con los valores por defecto que proporciona MATLAB.

5.5 Resultados obtenidos en el pronóstico determinístico de energía solar PV a muy corto plazo

Los pronósticos determinísticos de energía PV a muy corto plazo son fundamentales para la gestión energética y la operación del sistema eléctrico en tiempo real. En la Figura 5.10 se presenta una comparación entre los valores reales de P_{pv} y las predicciones generadas con 15 min de antelación por los modelos de referencia (persistencia, MLP-BO y SVR-BO) y por el modelo propuesto (BiLSTM-BO). Estas comparaciones se realizan en períodos seleccionados aleatoriamente dentro del conjunto de prueba, el cual fue conformado siguiendo el criterio de muestreo mensual ilustrado en la Figura 3.7. De esta forma, se garantiza la evaluación de los modelos en diversos escenarios operativos asociados a distintas condiciones climáticas (días soleados, parcialmente nublados, nublados, lluviosos, entre otros). Se observa que, en todos los casos analizados, las predicciones del modelo propuesto se ajustan adecuadamente a los patrones reales de la P_{pv} , lo que evidencia su alta capacidad predictiva y su robustez. Por el contrario, las predicciones de los modelos de referencia muestran una mayor discrepancia y una menor precisión, especialmente bajo condiciones climáticas variables.

Adicionalmente, se utilizan gráficos de dispersión para analizar la relación entre las predicciones y los valores reales de P_{pv} del conjunto de prueba (Figura 5.11). En general, se observa que el modelo propuesto muestra un desempeño superior en cada caso analizado, ya que sus predicciones se encuentran próximas a la línea de regresión ideal. Esto evidencia su elevada capacidad de adaptación a diferentes condiciones operativas. Por otro lado, los modelos de referencia presentan una mayor dispersión de las observaciones, lo que indica un menor nivel de correlación y, por ende, una menor calidad de las predicciones. Es importante mencionar que las escalas de los ejes difieren entre los gráficos debido a los distintos rangos de potencia de cada conjunto de datos (kW en $D1$ y $D2$ y MW en $D3$). Por esta razón, la dispersión visual de los puntos no es directamente comparable entre los casos analizados. No obstante, estos gráficos permiten analizar la relación entre los valores reales de potencia PV y las predicciones generadas por los diferentes modelos dentro de cada conjunto de datos.




Figura 5.10. Comparación entre los valores reales de P_{pv} y las predicciones determinísticas generadas por cada modelo en diferentes condiciones climáticas, para los conjuntos de datos: (a) D1, (b) D2 y (c) D3.




Figura 5.11. Gráficos de dispersión entre los valores reales de P_{pv} y las predicciones generadas por cada modelo, para los conjuntos de datos: (a) $D1$, (b) $D2$ y (c) $D3$.

Para cuantificar los errores cometidos, se emplean métricas de desempeño ampliamente recomendadas en la literatura, específicamente $nMAE$, $nRMSE$ y R^2 . Los valores obtenidos para cada conjunto de datos y para cada modelo se resumen en la Tabla 5.3, donde se presentan también los tiempos de entrenamiento e inferencia. La interpretación de estas métricas indica que el desempeño de un modelo mejora cuando presenta valores reducidos de $nMAE$ y $nRMSE$ y valores cercanos a la unidad del coeficiente R^2 . A partir del análisis de los resultados numéricos, se concluye que el modelo BiLSTM-BO presenta el mejor desempeño en todos los casos evaluados. En cuanto a los modelos de referencia, SVR-BO y el MLP-BO presentan un desempeño intermedio y resultados bastante similares. Por último, los valores más elevados de las métricas de error y el valor más reducido del coeficiente R^2 se obtienen para el modelo de persistencia, ya que este modelo no logra adaptarse adecuadamente a la alta variabilidad de la potencia PV.

Tabla 5.3. Desempeño de cada modelo en el pronóstico determinístico de potencia PV con 15 min de antelación.

Conjunto de datos	Métricas	Modelos de predicción			
		Persistencia	MLP-BO	SVR-BO	BiLSTM-BO
D1	nMAE (%)	2.2021	1.2672	1.2284	0.5627
	nRMSE (%)	4.0298	2.7225	2.7047	1.0102
	R ²	0.9808	0.9902	0.9904	0.9990
	Tiempo de entrenamiento (s)	-	30.42	94.60	552.1221
	Tiempo de inferencia (s)	0.0143	0.0160	0.0203	0.0211
D2	nMAE (%)	2.0205	1.1816	1.1602	0.4658
	nRMSE (%)	3.8617	2.5848	2.5664	0.8311
	R ²	0.9842	0.9912	0.9914	0.9992
	Tiempo de entrenamiento (s)	-	27.87	88.53	591.7243
	Tiempo de inferencia (s)	0.0147	0.0221	0.0211	0.0201
D3	nMAE (%)	2.3241	1.3839	1.4045	0.6472
	nRMSE (%)	4.1658	2.9874	2.9948	1.1106
	R ²	0.9781	0.9899	0.9898	0.9987
	Tiempo de entrenamiento (s)	-	37.5328	104.6925	716.8216
	Tiempo de inferencia (s)	0.0160	0.0180	0.0221	0.0192

Los tiempos de entrenamiento reportados corresponden al entrenamiento de cada modelo con los hiperparámetros ya ajustados mediante BO. Como se observa, BiLSTM-BO requiere un tiempo de entrenamiento mayor debido a su arquitectura recurrente. Sin embargo, su tiempo de inferencia por predicción es muy reducido (aproximadamente 0.02 s), por lo que se considera adecuado para aplicaciones de pronóstico a muy corto plazo. Los modelos MLP-BO y SVR-BO presentan tiempos de entrenamiento más cortos y tiempos de inferencia similares, mientras que el modelo de persistencia es prácticamente instantáneo debido a su simplicidad. La variación de los tiempos entre conjuntos de datos está asociada con el tamaño y la complejidad de cada uno de ellos. Los resultados demuestran que el modelo BiLSTM-BO ofrece una elevada precisión y mantiene un nivel de eficiencia suficiente para aplicaciones en tiempo real, aunque su entrenamiento inicial sea más costoso en términos computacionales.

En cuanto al desempeño predictivo registrado en los diferentes conjuntos de datos, se observa que los modelos presentan mejor desempeño para el conjunto *D2*, seguido por *D1* y *D3*. Este comportamiento puede explicarse por las características de los datos utilizados. En primer lugar, *D2* corresponde a un área geográfica con clima árido, donde las condiciones meteorológicas presentan una menor variabilidad temporal, lo que da lugar a una serie de potencia PV más estable y facilita la obtención de predicciones más precisas. Además, tanto *D1* como *D2* incluyen información de algunas variables meteorológicas que actúan como variables explicativas, lo cual contribuye a mejorar la capacidad predictiva de los modelos. En el caso del conjunto *D3*, se dispone únicamente de información de la potencia PV, mientras que las condiciones meteorológicas asociadas a su ubicación geográfica presentan un comportamiento más variable. A pesar de

ello, el modelo propuesto logra generar predicciones satisfactorias, como se evidencia en los resultados gráficos y numéricos presentados previamente.

Para complementar este análisis, es posible determinar el porcentaje de mejora ($%I$) del modelo propuesto con respecto a los modelos de referencia analizados, tomando como base la métrica nMAE (Figura 5.12). Se observa que el modelo propuesto presenta mejoras en los tres conjuntos de datos evaluados. Estas mejoras alcanzan valores cercanos al 72 % respecto al modelo de persistencia y al 53 % en comparación con los modelos MLP-BO y SVR-BO en todos los escenarios. Estos resultados destacan la efectividad del modelo BiLSTM-BO y su capacidad para capturar patrones complejos en los datos históricos.




Figura 5.12. Porcentaje de mejora alcanzado por el modelo propuesto con respecto a los modelos de referencia para cada conjunto de datos, tomando como base la métrica nMAE.

Para obtener una visión más profunda sobre la efectividad del modelo propuesto, se lleva a cabo una comparación de sus resultados con respecto a los reportados en la literatura. Para facilitar esta comparación, se seleccionan varios estudios que aplican enfoques avanzados para el pronóstico determinístico de energía solar PV y que han analizado un horizonte similar (15 min en adelante). No obstante, establecer este tipo de comparaciones representa un desafío debido a diversos factores que influyen en el desempeño de cada modelo. Por lo tanto, aunque este análisis puede aportar una idea general, no debe ser considerado como una prueba totalmente concluyente.

Los principales resultados obtenidos en cada trabajo analizado se resumen de manera concisa en la Tabla 5.4. Al analizar las métricas reportadas en cada caso, se observa que el modelo propuesto ocupa una posición destacada en términos de precisión, con valores reducidos de nMAE y nRMSE, así como valores de R^2 cercanos a la unidad. Estos hallazgos indican que la combinación del modelo BiLSTM con un preprocesamiento adecuado de los datos, un análisis detallado de FS y un método robusto para el ajuste automático de hiperparámetros constituye una estrategia de pronóstico efectiva. Como resultado, este enfoque es capaz de mejorar significativamente la calidad y la exactitud de las predicciones determinísticas de energía solar PV.

Tabla 5.4. Comparación de los resultados obtenidos en esta investigación para el pronóstico determinístico de potencia PV con respecto a otros estudios reportados en la literatura.

Ref. y año	Modelo de pronóstico	Características de los datos utilizados	Entradas al modelo de pronóstico	Horizonte de pronóstico	Métricas de desempeño
[156], 2020	RF – Descomposición empírica modal por conjuntos complementarios (<i>Complementary Ensemble Empirical Mode Decomposition</i> , CEEMD) – PSO – BPNN	Datos de una planta PV en Canadá, medidos desde el 03-03-2016 hasta el 03-03-2017 con resolución temporal de 5 min, Pnom = 800 kW	Datos de fecha y hora, irradiancia global horizontal y difusa horizontal, temperatura ambiente, humedad relativa, velocidad del viento y precipitación diaria	15 min	RMSE = [14.5 – 17.3] kW nRMSE* = [1.81 – 2.16] % R ² = 0.99
[157], 2021	Filtrado iterativo (<i>Iterative Filtering</i> , IF) – ELM	Sitio 1: Datos de una planta PV en la ciudad de Adrar, Argelia, medidos de 2017 a 2018 con resolución temporal de 15 min, Pnom = 20 MW Sitio 2: Datos de una planta PV en <i>Broken Hill</i> , Australia, medidos de 2016 a 2017 con resolución temporal de 15 min, Pnom = 53 MW	Para ambos conjuntos de datos: potencia PV desde el instante de tiempo $t-1$ hasta el instante de tiempo $t-8$	(15 min – 1 h)	Para un horizonte de 15 min: Sitio 1: nMAE = 0.5229 % nRMSE = 0.8276 % R ² = 0.9997 Sitio 2: nMAE = 0.4416 % nRMSE = 1.0880 % R ² = 0.9996
[61], 2022	CNN de cuatro núcleos (QK_CNN)	Datos de una instalación PV (sitio 2) ubicada en <i>Alice Spring</i> , Australia, medidos durante el año 2019 con resolución temporal de 5 min, Pnom = 26.52 kW	Potencia PV, corriente promedio de fase, irradiancia global horizontal, temperatura ambiente y humedad relativa	(5 min – 20 min)	Para un horizonte de 15 min: MAE = 0.191 kW RMSE = 0.493 kW nMAE* = 0.720 % nRMSE* = 1.855 %
[158], 2023	Sistema de pronóstico combinado integrado por: preprocesamiento de datos, múltiples modelos de ML y DL, módulo de selección de submodelos y GWO	Datos de una instalación PV en Bélgica. Estos datos se obtienen con una resolución temporal de 15 min y se agrupan en tres conjuntos principales	Potencia PV	(15 min – 45 min)	Para un horizonte de 15 min: Caso 1: nMAE* = 0.5265 % nRMSE* = 0.8565 % Caso 2: nMAE* = 1.9477 % nRMSE* = 2.6618 % Caso 3: nMAE* = 0.7521 % nRMSE* = 1.3287 %
[159], 2025	Mecanismo de atención dual (<i>Dual Attention</i> , DA) – GRU	Datos de una instalación PV en <i>Alice Spring</i> , Australia, medidos desde el 19-05-2016 hasta el 21-10-2018 con una resolución temporal de 5 min, Pnom = 45.78 kW	Potencia PV, corriente promedio de fase, temperatura ambiente, irradiancia global horizontal, velocidad y dirección del viento	15 min	MAE = 0.598 kW nMAE* = 1.306 % R ² = 0.991

Tabla 5.4. Continuación


Este trabajo	Algoritmo de preprocesamiento de datos – FS – BiLSTM – BO	Conjuntos de datos D1, D2 y D3 descritos en la Sección 5.2	Para D1: GHI, Ta y Ppv en el instante de tiempo t y en $t-1$	15 min	Para D1: nMAE = 0.5627 % nRMSE = 1.0102 % R ² = 0.9990
			Para D2: GHI, Ta, Rh y Ppv en el instante de tiempo t y $t-1$		Para D2: nMAE = 0.4658 % nRMSE = 0.8311 % R ² = 0.9992
			Para D3: Ppv en el instante de tiempo t , $t-1$ y $t-2$		Para D3: nMAE = 0.6472 % nRMSE = 1.1106 % R ² = 0.9987

*Indica que la métrica fue normalizada para establecer una comparación mediante indicadores independientes de la escala. En los estudios donde las métricas se reportan en unidades absolutas, la normalización se realiza utilizando los valores máximos de potencia informados (referencia [158]) o la capacidad nominal de la planta PV (referencias [61], [156] y [159]). Este enfoque garantiza una comparación equitativa al expresar los errores de predicción en términos porcentuales, lo que facilita la evaluación del desempeño entre sistemas de distintas capacidades.


5.6 Resultados obtenidos en el pronóstico probabilístico de energía solar PV a muy corto plazo

La obtención de pronósticos probabilísticos en forma de intervalos de predicción (PIs) constituye un método eficaz para abordar las incertidumbres inherentes a la predicción de energía solar PV. Al combinar los pronósticos determinísticos del modelo propuesto con los PIs generados mediante el método de remuestreo *bootstrap*, los resultados se vuelven más robustos frente a la variabilidad a corto plazo.


En la Figura 5.13 se muestran los valores reales de Ppv , las predicciones determinísticas generadas por el modelo propuesto y los PIs obtenidos para diferentes valores de PINC (80 %, 90 % y 95 %). Los resultados gráficos evidencian que los PIs representan de manera efectiva los niveles de confianza especificados. Además, se observa que, a medida que se reduce el nivel de confianza, también se reduce el ancho de los PIs generados. Otro aspecto relevante es que, en días con diferente comportamiento climático, donde existen diferentes niveles de incertidumbre asociados al pronóstico determinístico, tanto los valores reales como las predicciones se encuentran dentro de los límites inferior y superior de los PIs. Esto valida la flexibilidad y la precisión de las predicciones probabilísticas realizadas, destacando su utilidad en la gestión de las incertidumbres inherentes a la generación PV.



(a)



(b)



(c)

Figura 5.13. PIs obtenidos mediante el método de remuestreo *bootstrap* para diferentes valores de PINC (80 %, 90 % y 95 %) en días representativos de los conjuntos de datos: (a) D1, (b) D2 y (c) D3.

Para evaluar la calidad de las predicciones probabilísticas se emplean las métricas PICP, PINAW y ACE. Los valores obtenidos, considerando diferentes niveles de PINC, se resumen en la Tabla 5.5. Los resultados numéricos indican que, en todos los casos, los valores de PICP están muy cerca de sus respectivos valores de PINC, lo que refleja un nivel de cobertura adecuado, con valores reducidos del ACE y un grado satisfactorio de fiabilidad. Además, al disminuir los valores de PINC, los valores de PINAW y el ancho de los PIs también disminuyen, lo que se traduce en predicciones más precisas y con mayor nitidez. Este refinamiento conduce a un rango de potencia más restringido en el que caen las predicciones y los valores reales. De esta manera, se proporciona información más precisa que ayuda a los operadores de la red en la toma de decisiones informadas y en el control eficiente del sistema.

Tabla 5.5. Evaluación de las predicciones probabilísticas de potencia PV considerando diferentes valores de PINC.

Conjunto de datos	Métricas	Valores de PINC		
		PINC = 80 %	PINC = 90 %	PINC = 95 %
<i>D1</i>	PICP (%)	80.3269	90.5323	95.7204
	ACE (%)	0.3269	0.5323	0.7204
	PINAW (%)	3.2078	4.3714	6.0872
<i>D2</i>	PICP (%)	79.9858	90.4103	95.6124
	ACE (%)	0.0142	0.4103	0.6124
	PINAW (%)	3.1285	4.2839	5.9891
<i>D3</i>	PICP (%)	80.4218	90.6204	95.8903
	ACE (%)	0.4218	0.6204	0.8903
	PINAW (%)	3.3141	4.5002	6.1542

Para realizar una evaluación más exhaustiva del desempeño del método propuesto, se compara su rendimiento con estudios recientes de la literatura (Tabla 5.6). En este caso, se han seleccionado trabajos que analizan horizontes de pronóstico a muy corto plazo y utilizan diferentes enfoques para generar los pronósticos probabilísticos. No obstante, es importante mencionar que cada trabajo analizado utiliza diferentes conjuntos de datos, lo que puede tener influencia sobre los resultados obtenidos.

En términos de fiabilidad, el modelo propuesto muestra un desempeño favorable, logrando una buena cobertura de los PIs con bajos valores del ACE. No obstante, los modelos reportados en [162] y [164] presentan valores del ACE ligeramente menores. En cuanto a la nitidez de las predicciones, el modelo propuesto obtiene los valores más bajos del PINAW entre todos los estudios analizados, lo que se traduce en PIs mejor calibrados sin necesidad de sobrestimar los límites inferior y superior de los intervalos. De manera general, aunque algunas de las referencias analizadas presentan un mejor desempeño en métricas individuales (como el ACE), el modelo propuesto resulta competitivo y eficaz, logrando un equilibrio satisfactorio entre fiabilidad y nitidez, con resultados adecuados para cada conjunto de datos analizado.

Tabla 5.6. Comparación de los resultados obtenidos en esta investigación para el pronóstico probabilístico de potencia PV con respecto a otros estudios reportados en la literatura.

Ref. y año	Descripción del estudio	Métricas obtenidas en la predicción probabilística (PINC = 95 %)
[160], 2021	Red LSTM con capa probabilística (Gaussiana). Datos de instalaciones PV en Singapur y Australia.	Para los datos de Singapur: PICP = 96.07 %, ACE = 1.07 %, PINAW = 21.23 %
		Para los datos de Australia: PICP = 96.72 %, ACE = 1.72 %, PINAW = 19.84 %
[161], 2022	Modelo ELM combinado con un método no paramétrico basado en KDE y optimización de ventana mediante PSO. Datos de una instalación PV en el norte de China.	PICP = 98.43 % ACE = 3.43 % PINAW = 12.39 %
[162], 2023	Modelo híbrido no paramétrico con descomposición de series, granulación de información difusa (<i>Fuzzy Information Granulation</i> , FIG), LSTM mejorado y ARIMA. Datos de una instalación PV en Massachusetts, EE. UU.	Valores promedio de las diferentes estaciones del año: PICP* = 95.21 % ACE* = 0.21 % PINAW* = 10.31 %
[163], 2024	Modelo híbrido integrado por cuatro modelos de ML/DL, optimizados mediante un algoritmo de optimización multiobjetivo de saltamontes (<i>Multi-objective Grasshopper Optimization Algorithm</i> , MOGOA) y combinado con QR para generar pronósticos probabilísticos. Datos de instalaciones PV en Alice Spring, Australia.	Para el sitio 1-B: PICP = 98.18 % ACE = 3.18 % PINAW = 13.87 %
[164], 2025	Descomposición de series de tiempo combinada con cuatro modelos de DL y un método no paramétrico EQN para pronósticos probabilísticos. Datos de una instalación PV en Hong Kong, China.	PICP = 95.10 % ACE = 0.10 %
Este trabajo	Predicciones determinísticas del modelo BiLSTM-BO combinadas con el método de remuestreo <i>bootstrap</i> para generar predicciones probabilísticas en forma de PIs. Datos de instalaciones PV en España (D1), Australia (D2) y Bélgica (D3).	Para D1: PICP = 95.7204 %, ACE = 0.7204 %, PINAW = 6.0872 %
		Para D2: PICP = 95.6124 %, ACE = 0.6124 %, PINAW = 5.9891 %
		Para D3: PICP = 95.8903 %, ACE = 0.8903 %, PINAW = 6.1542 %

* Indica el valor promedio de la métrica para todas las estaciones del año analizadas.

5.7 Pronóstico de energía solar PV en condiciones de operación atípicas

Hasta ahora, el desempeño del modelo de pronóstico propuesto se ha analizado en condiciones de operación estables. Sin embargo, en aplicaciones de pronóstico en tiempo real, pueden surgir escenarios atípicos debido a fallos en los sensores, errores en la transmisión de los datos o presencia de ruido blanco, factores que comprometen el rendimiento predictivo del modelo. Por lo tanto, es fundamental que el modelo propuesto se adapte a estas condiciones y mantenga la mayor precisión posible, asegurando su efectividad en diferentes entornos operativos. Aunque en este estudio se analizan tres conjuntos de datos de distinta

naturaleza, el análisis en condiciones atípicas se centra específicamente en el conjunto $D2$, ya que incluye un espectro más amplio de variables de entrada al modelo de pronóstico.

5.7.1 Explicabilidad del modelo de pronóstico

La explicabilidad resulta esencial para comprender cómo influyen las distintas variables de entrada en las predicciones del modelo. Para efectuar este análisis, se aplica una técnica de XAI conocida como RFE, descrita en la Sección 3.8 del Capítulo 3. Los resultados obtenidos se ilustran en la Figura 5.14.




Figura 5.14. Contribuciones estimadas de las variables de entrada al modelo de pronóstico propuesto, obtenidas mediante la técnica de XAI conocida como RFE.

En este caso, las variables Ppv_t y GHI_t presentan las mayores contribuciones, alcanzando valores de 41.96 % y 37.93 %, respectivamente. Los valores rezagados de dichas variables (Ppv_{t-1} y GHI_{t-1}) también resultan de utilidad, contribuyendo en un 32.08 % y un 28.11 % a la predicción. Además, las variables meteorológicas Rh_t y Ta_t también exhiben cierta importancia, con contribuciones estimadas de 18.05 % y 14.92 %. Finalmente, los aportes más reducidos se obtienen para las variables Rh_{t-1} y Ta_{t-1} , con valores de 11.64 % y 8.71 %, respectivamente. En general, el análisis de explicabilidad realizado proporciona información valiosa para comprender mejor el funcionamiento del modelo. Al mismo tiempo, sirve como un referente para el desarrollo de estudios posteriores vinculados con la ocurrencia de condiciones de operación atípicas.

5.7.2 Pérdida de información en las variables de entrada

En aplicaciones de predicción en tiempo real, pueden ocurrir fallos temporales en los sensores de medición. Si esta condición atípica persiste durante un tiempo determinado, el modelo puede fallar a la hora de entregar sus predicciones, lo que representa un desafío operativo significativo. Para enfrentar estas limitaciones y garantizar la continuidad del proceso predictivo, se aplica la metodología descrita en la Sección 3.9. En este proceso resulta esencial conocer con precisión la(s) variable(s) de entrada afectada(s) y su respectivo nivel de importancia, para poder definir la estrategia de pronóstico más adecuada. Para evaluar el desempeño del modelo propuesto en estas condiciones, se han seleccionado dos casos de estudio

fundamentales. Un primer caso, donde se considera que las variables de entrada fallan una a una, y un segundo caso, en el que se asume que todas las variables de entrada fallan simultáneamente. No obstante, es válido señalar que en la práctica pueden presentarse otros casos diferentes, dependiendo del número de entradas que aportan información al modelo de pronóstico.

Además, es importante destacar que en este estudio se adopta un enfoque global para evaluar el impacto causado por la pérdida de información de cada variable de entrada (GHI , Ta , Rh y Ppv) sobre el modelo propuesto. Cuando se pierde la información de una determinada variable en el instante de tiempo t , la información en el instante de tiempo $t-1$ se vuelve irrelevante en los pasos de tiempo posteriores, debido a la falta de actualización de las mediciones. Por esta razón, se considera el impacto causado por la pérdida de cada variable de manera global. De este modo, se establece una evaluación simplificada y precisa de la sensibilidad del modelo, facilitando la identificación de variables críticas y el diseño de estrategias efectivas para enfrentar esta condición atípica en el pronóstico de energía solar PV.

Los resultados obtenidos para el primer caso de estudio se ilustran en la Figura 5.15. Para facilitar la comprensión de estos resultados, también se ha representado el comportamiento del modelo de pronóstico cuando todas las variables de entrada se encuentran activas, es decir, en condiciones de operación estables. Los escenarios más críticos se presentan ante la pérdida de información en las variables Ppv y GHI debido a su elevado nivel de importancia para el modelo. En particular, la pérdida de información en estas variables provoca un incremento relativo del nMAE de 64.41 % y 55.71 %, respectivamente, en comparación con el escenario de referencia. Por otro lado, la pérdida de información en las variables Rh y Ta , aunque menos crítica debido a su menor relevancia, también genera un aumento de los errores de pronóstico de 20.54 % y 14.41 %, respectivamente, con respecto al escenario de referencia.




Figura 5.15. Rendimiento del modelo propuesto ante la pérdida temporal de información en diferentes variables de entrada.

El análisis precedente aborda específicamente la pérdida temporal de una sola variable de entrada en cada escenario. Sin embargo, en ciertas situaciones puede ocurrir una pérdida temporal de información en más de una variable al mismo tiempo, lo que conduce a condiciones de operación aún más complejas. Para enfrentar la pérdida parcial de variables de entrada, se pueden emplear varios modelos con distintas

combinaciones de entradas durante la fase de entrenamiento. De esta manera, se selecciona un modelo apropiado según las variables disponibles y su nivel de importancia cuando ocurre la pérdida temporal de uno o más sensores, garantizando la continuidad de las predicciones. No obstante, si las variables afectadas poseen un alto nivel de importancia (como en el caso de *Ppv* y *GHI*), la precisión y la calidad de las predicciones utilizando esta estrategia pueden verse comprometidas.

En el escenario más crítico (representado por el segundo caso de estudio), donde todas las variables de entrada se ven afectadas simultáneamente, la estrategia mencionada anteriormente no resulta viable. Para enfrentar este problema, se utiliza un enfoque de pronóstico directo, en el cual se reentrena el modelo propuesto para predecir horizontes temporales extendidos, generando modelos específicos para cada horizonte de predicción requerido. Para ello, es necesario ajustar la estructura de los datos de entrada y salida, introduciendo un desplazamiento que corresponda al horizonte de predicción deseado. En consecuencia, el modelo puede generar predicciones de potencia PV para horizontes futuros utilizando únicamente los datos registrados hasta el momento de la interrupción. De esta forma, se garantiza la continuidad del proceso predictivo durante un determinado período de tiempo, hasta que se restauren nuevamente las condiciones normales de operación. En la Figura 5.16 se muestra la evolución de las métricas nMAE y R^2 cuando el modelo propuesto se emplea para predecir la potencia PV durante un período de cuatro horas, a pesar de la falta de información actualizada debido a un fallo temporal en todos los sensores de medición.




Figura 5.16. Rendimiento del modelo propuesto en la predicción de potencia PV tras un fallo temporal que afecta a todas las variables de entrada.

Se observa que, a medida que se incrementa el período de tiempo sin información actualizada, se produce una disminución en la precisión del modelo, asociada con un incremento en los valores de nMAE y una reducción en los valores de R^2 . Por ejemplo, al predecir la potencia PV para un horizonte temporal de cuatro horas en el que no se dispone de información actualizada, se registra un incremento absoluto del nMAE de 1.85 % y una reducción del coeficiente de determinación de 1.67 %. Estos resultados demuestran que el

modelo propuesto posee buena capacidad de adaptación y puede predecir la potencia PV durante varias horas con una precisión razonable, aunque no disponga de información actualizada de sus variables de entrada.

5.7.3 Presencia de ruido blanco en las mediciones disponibles

La presencia de ruido blanco en las mediciones es otra condición atípica que puede ocurrir durante la operación del modelo de pronóstico. Para representar este escenario, se ha agregado intencionalmente ruido blanco a las variables de entrada mediante la metodología descrita en la Sección 3.9. Para este propósito, se ajusta el parámetro ‘*snr*’ de la función ‘*awgn*’ a un valor de 18 dB. Este nivel de ruido moderado simula una condición de operación realista sin distorsionar excesivamente las señales originales. En la Figura 5.17 se muestra la serie temporal de *GHI* bajo condiciones normales (datos originales) y bajo condiciones atípicas vinculadas a la presencia de ruido blanco. Se observa que la adición de ruido altera el comportamiento de la serie, incrementando la variabilidad, la intermitencia y la complejidad de la señal.




Figura 5.17. Representación de la serie temporal de *GHI* perteneciente a los datos de prueba del conjunto *D2*, considerando las mediciones originales y con ruido blanco añadido.

Es importante mencionar que el entrenamiento del modelo se ha realizado utilizando datos en condiciones estables. Posteriormente, su rendimiento y capacidad de generalización se han evaluado frente a un nuevo conjunto de datos (datos de prueba) que no ha formado parte del entrenamiento. Por lo tanto, al introducir los datos con ruido blanco al modelo previamente entrenado, es posible evaluar su habilidad para adaptarse a esta nueva condición. Para llevar a cabo este análisis, es necesario definir varios casos de estudio. El Caso 1 se considera un escenario de referencia donde no se ha introducido ruido blanco en las entradas del modelo. Los Casos 2, 3, 4 y 5 están asociados con la presencia de ruido blanco en las variables *GHI*, *Ta*, *Rh* y *Ppv*, respectivamente. Por último, el Caso 6 considera la presencia de ruido blanco en todas las variables de entrada. Las Figuras 5.18a y 5.18b ilustran los resultados experimentales obtenidos, considerando un horizonte de pronóstico de 15 min y las métricas nMAE y R^2 .




Figura 5.18. Rendimiento del modelo de pronóstico ante la presencia de ruido blanco en diferentes variables de entrada: (a) Considerando la métrica nMAE y (b) Considerando la métrica R^2 .

Al comparar los resultados de los Casos 2 y 5 con respecto al escenario de referencia, se observa un incremento en los valores del nMAE y una disminución en el coeficiente R^2 , lo que indica un deterioro en la calidad de las predicciones. De manera similar, los Casos 3 y 4 también muestran un impacto negativo en el rendimiento del modelo, aunque de menor magnitud debido a la menor importancia de estas variables en el proceso predictivo. Los resultados más críticos se producen en el Caso 6, donde se registra el mayor aumento en la métrica nMAE y la mayor disminución en el coeficiente R^2 debido a la presencia simultánea de ruido blanco en todas las variables de entrada.

El análisis anterior demuestra que existe una relación directa entre el nivel de importancia de las variables afectadas y el rendimiento del modelo propuesto. Además, aunque hay diferencias en todos los casos analizados, el desempeño y la capacidad de adaptación del modelo ante esta nueva condición atípica pueden considerarse satisfactorios. Esto se debe en gran medida a la capacidad del modelo BiLSTM-BO para aprender patrones altamente complejos y no lineales. Estas características le permiten adaptarse a diversas condiciones que pueden surgir durante el proceso predictivo, consolidándose como una herramienta viable para la predicción de energía solar PV en tiempo real.

5.7.4 Predicción probabilística en escenarios de operación atípicos

Los análisis previos indican que, bajo condiciones de operación atípicas, se produce un aumento de los errores derivados de las predicciones determinísticas. Por lo tanto, es importante extender este análisis al ámbito de las predicciones probabilísticas. La Figura 5.19 ilustra la evolución de la métrica PINAW cuando ocurre un fallo simultáneo de todos los sensores de medición durante un período de cuatro horas. En este análisis, se ha considerado un valor de PINC del 95 %.




Figura 5.19. Comportamiento de los PIs en condiciones de operación atípicas asociadas al fallo temporal de todas las variables de entrada de manera simultánea.

Se observa que, a medida que aumenta el período de tiempo sin información actualizada, también se incrementan las incertidumbres asociadas al pronóstico determinístico. Como consecuencia, los PIs se amplían para poder adaptarse de manera efectiva a las nuevas condiciones de operación. Además, al correlacionar los pronósticos determinísticos de potencia PV con sus respectivos PIs, se puede establecer una estrategia de gestión de energía más adaptable y resiliente para los sistemas PV analizados.

5.8 Conclusiones del capítulo

En este capítulo se han analizado detalladamente los principales resultados obtenidos en el pronóstico de energía solar PV para un horizonte temporal de muy corto plazo. El enfoque de pronóstico propuesto se basa en una red neuronal BiLSTM, integrada con un algoritmo de BO para el ajuste automático de hiperparámetros y un esquema eficiente de preprocesamiento de datos. Los resultados demuestran que la combinación de estos componentes mejora la capacidad predictiva del modelo. Además, aumenta su habilidad para adaptarse a la naturaleza dinámica e intermitente de la potencia PV. El modelo propuesto se ha validado utilizando conjuntos de datos con diferentes características, recopilados de instalaciones PV ubicadas en diversas localizaciones geográficas y condiciones climáticas. Este enfoque ha facilitado una comprensión más profunda de la eficacia del modelo en diversos escenarios, asegurando la reproducibilidad de los experimentos y facilitando la comparación con la literatura existente. Por otro lado, se han realizado múltiples pruebas comparativas para evaluar el rendimiento y la adaptabilidad del modelo propuesto en el contexto de la predicción determinística de potencia PV. Los resultados evidencian un desempeño superior frente a varios modelos de referencia comúnmente utilizados en este campo de investigación (persistencia, MLP-BO y SVR-BO).

Por otra parte, las predicciones probabilísticas obtenidas mediante el método de remuestreo *bootstrap* han mostrado una alta concordancia con los niveles de confianza establecidos en todos los casos analizados. Asimismo, se ha demostrado que la combinación de ambos tipos de predicciones mejora la flexibilidad del sistema y permite gestionar de manera eficiente las incertidumbres inherentes a la predicción determinística de potencia PV. De esta forma, se facilita la planificación y la operación de los sistemas eléctricos con alta penetración de RES.

Otro aspecto esencial que se ha analizado es el rendimiento y la capacidad de adaptación del modelo frente a diversas condiciones atípicas. Estas condiciones están asociadas con la pérdida de información y la presencia de ruido blanco en las mediciones disponibles. La metodología propuesta para cada una de las condiciones atípicas mencionadas ha permitido definir la estrategia de pronóstico más apropiada, asegurando la continuidad del proceso predictivo con una precisión adecuada. En este sentido, la técnica de XAI conocida como RFE ha sido fundamental, tanto para validar la importancia de cada variable de entrada en el modelo de pronóstico, como para evaluar el impacto de cualquier condición atípica que pueda presentarse. La flexibilidad y resiliencia demostradas frente a estas condiciones justifican plenamente la viabilidad del modelo. Esto es especialmente relevante para aplicaciones de pronóstico en tiempo real, donde se requiere un flujo ininterrumpido de predicciones. En general, los resultados expuestos muestran que el marco de trabajo propuesto es efectivo para la predicción de potencia PV y puede aplicarse con éxito en diferentes escenarios operativos.

CAPÍTULO 6. PRINCIPALES RESULTADOS OBTENIDOS EN EL PRONÓSTICO DE ENERGÍA EÓLICA

6.1 Introducción

En este capítulo se presentan y analizan los resultados más relevantes obtenidos en el pronóstico de energía eólica. Siguiendo la estructura definida en el capítulo anterior, se describen, en primer lugar, las características fundamentales de los datos utilizados en el estudio. Posteriormente, se muestran los resultados derivados del proceso de preprocesamiento y preparación de los datos, así como aquellos asociados con los pronósticos determinísticos y probabilísticos generados para un horizonte de muy corto plazo. Por último, se evalúa el desempeño y la capacidad de adaptación del modelo propuesto frente a condiciones de operación atípicas, relacionadas nuevamente con la pérdida temporal de información y la presencia de ruido blanco en los datos.

6.2 Descripción de los datos utilizados

A diferencia de un gran número de estudios en el campo de la predicción eólica, que suelen centrarse en un único aerogenerador o parque eólico, en este trabajo se emplean datos de dos instalaciones eólicas con características y ubicaciones geográficas diferentes. Este enfoque permite analizar múltiples condiciones de operación, proporcionando una evaluación más amplia y diversa de la efectividad del modelo de pronóstico desarrollado.

El primer conjunto de datos, denominado *DW1*, pertenece a un aerogenerador ubicado en la isla de Tenerife, España, con una potencia nominal de 2350 kW. Este aerogenerador está instalado a una altura de 92 m y cuenta con varios dispositivos de medición para registrar datos eléctricos y operativos. Los datos eléctricos comprenden la potencia eólica activa y reactiva, la energía exportada, el factor de potencia y la frecuencia. Por su parte, los datos de operación incluyen la velocidad y la dirección del viento en la góndola, la velocidad de giro del rotor, las horas de funcionamiento, la posición de la góndola, el estado principal del aerogenerador y el código de estado detallado. Además, se dispone de mediciones procedentes de una estación meteorológica situada a 1 km de distancia del aerogenerador. En este grupo se incluyen la irradiancia solar, la temperatura ambiente, la humedad relativa, la precipitación y la velocidad del viento medida a una altura de 40 m. Todas las mediciones se han tomado con una resolución temporal de 15 min durante el período comprendido entre mayo de 2023 y abril de 2024.

El segundo conjunto de datos, denominado *DW2*, procede de varios parques eólicos terrestres situados en Bélgica, con una capacidad total instalada de 531.85 MW [165]. Se trata de una base de datos de acceso abierto que contiene mediciones de potencia eólica a escala regional. En este caso, los datos presentan una resolución temporal de 15 min y abarcan el período comprendido entre el 1 de enero y el 31 de diciembre de 2021.

6.3 Resultados obtenidos en el preprocesamiento y la preparación de los datos

La etapa de preprocesamiento y preparación es esencial para mejorar la calidad de los datos recopilados y, en consecuencia, el rendimiento del modelo de pronóstico. A continuación, se describen los principales resultados obtenidos en este proceso para cada uno de los conjuntos de datos disponibles.

6.3.1 Resultados obtenidos en el análisis estadístico y gráfico de los datos

La Tabla 6.1 presenta las principales características de cada conjunto de datos, incluyendo indicadores estadísticos relevantes como la media, la desviación estándar y los valores máximos y mínimos de cada variable. De manera general, se observa que los límites lógicos de las variables analizadas son adecuados. También se evidencia la presencia de variaciones de escala en el conjunto de datos *DW1*, debido al gran número de variables de distinta naturaleza que lo componen.

Tabla 6.1. Principales características de los conjuntos de datos utilizados en el estudio.

Conjunto de datos	Variables disponibles	Unidad de medida	Media	Std.	Valor mín.	Valor máx.
<i>DW1</i>	Potencia eólica activa (<i>Pw</i>)	[kW]	681.37	798.04	0	2365
	Potencia eólica reactiva (<i>Qw</i>)	[kVAr]	-182.11	104.24	-603.43	9.99
	Energía exportada (<i>Eexp</i>)	[kWh]	30193529	1474137	27767634	32626477
	Factor de potencia (<i>fp</i>)	-	0.42	0.67	-1.00	1.00
	Frecuencia (<i>f</i>)	[Hz]	49.91	1.56	0	50.25
	Velocidad del viento en la góndola (<i>Wsg</i>)	[m/s]	6.11	3.82	0	20.54
	Dirección del viento en la góndola (<i>Wdg</i>)	[°]	-0.33	15.84	-162.92	159.95
	Velocidad de giro del rotor (<i>Rsp</i>)	[rpm]	10.04	5.39	0	17.09
	Horas de funcionamiento (<i>Hop</i>)	[h]	35198	1869	31988	38360
	Posición de la góndola (<i>Gpo</i>)	[°]	85.87	89.38	0	359
	Estado principal del aerogenerador (<i>Mst</i>)	-	2.80	24.16	0	240
	Código de estado detallado (<i>Dsc</i>)	-	2.65	24.63	0	246
	Irradiancia solar (<i>Irs</i>)	[W/m ²]	229.39	314.65	0	1194
	Temperatura ambiente (<i>Ta</i>)	[°C]	22.01	3.47	13.50	37.80
	Humedad relativa (<i>Rh</i>)	[%]	68.99	15.37	22.55	97.60
	Precipitación (<i>Pt</i>)	[mm]	0.03	0.09	0	10.60
	Velocidad del viento (<i>Ws</i>)	[m/s]	3.69	2.60	0	12.80
<i>DW2</i>	Potencia eólica activa (<i>Pw</i>)	[MW]	85.18	83.90	0	385.22

Además, es importante mencionar que los datos seleccionados para el estudio provienen de dos regiones con diferente comportamiento climático. Según la clasificación climática de Köppen [155], el clima de Tenerife se clasifica como semiárido cálido, mientras que el de Bélgica se considera marítimo templado. En la Figura 6.1 se ilustra el comportamiento anual de la potencia eólica activa (*Pw*) en función de la hora del día y del mes del año para ambas ubicaciones. Para el conjunto de datos *DW1* (Figura 6.1a), se aprecia una

marcada variabilidad de la P_w tanto en la escala diaria como en la anual, con cambios estacionales bastante significativos. De manera similar, en el conjunto de datos $DW2$ (Figura 6.1b), también se evidencia la alta variabilidad e intermitencia de esta variable durante el período analizado.




Figura 6.1. Variación anual de la potencia eólica en función de la hora del día y del mes del año para los conjuntos de datos: (a) $DW1$ y (b) $DW2$.

6.3.2 Resultados obtenidos en la limpieza de los datos

El algoritmo propuesto para realizar la limpieza de los datos toma en cuenta tres aspectos fundamentales: la detección y corrección de valores atípicos, la detección e imputación de valores ausentes, y la detección y corrección de valores anómalos.

En la Figura 6.2 se presentan los resultados obtenidos en el proceso de detección y corrección de valores atípicos en las series temporales de W_{sg} del conjunto de datos $DW1$ (Figura 6.2a) y de P_w del conjunto de datos $DW2$ (Figura 6.2b). En ambos casos, la línea cian representa los valores originales de cada serie

temporal, mientras que los marcadores amarillos indican los valores atípicos identificados según los umbrales de detección (líneas punteadas grises). Además, los marcadores rojos señalan las correcciones realizadas para cada valor atípico identificado y la línea azul representa los valores finales obtenidos para cada serie temporal analizada. Se observa que el algoritmo propuesto presenta un buen desempeño en ambos casos, mejorando notablemente la calidad de los datos disponibles y contribuyendo, en consecuencia, a un mejor desempeño de los modelos de pronóstico.




Figura 6.2. Resultados obtenidos en la detección y corrección de valores atípicos: (a) Serie temporal de W_{sg} del conjunto de datos DW1 y (b) Serie temporal de P_w del conjunto de datos DW2.

Por su parte, en la Figura 6.3 se presentan los resultados obtenidos en el proceso de detección e imputación de valores ausentes en las series temporales de R_h del conjunto de datos DW1 (Figura 6.3a) y de P_w del conjunto de datos DW2 (Figura 6.3b). En ambos casos, la línea azul representa los valores originales de cada variable, mientras que la línea roja indica los valores ausentes imputados por el algoritmo propuesto. Los resultados experimentales demuestran que el algoritmo presenta un comportamiento

adecuado en esta tarea, logrando una reconstrucción precisa de las series temporales analizadas, la cual sigue de manera coherente la tendencia de los datos originales.




Figura 6.3. Resultados obtenidos en la detección e imputación de valores ausentes: (a) Serie temporal de R_h del conjunto de datos DW1 y (b) Serie temporal de P_w del conjunto de datos DW2.

Por otro lado, en la Figura 6.4 se muestran los resultados derivados del proceso de detección y corrección de valores anómalos mediante el gráfico de dispersión de W_{sg} vs. P_w . En la Figura 6.4a se representa el gráfico de dispersión inicial obtenido para estas series temporales. Se observa la presencia de un patrón bien definido que contiene la mayoría de las observaciones, así como otros grupos de datos más reducidos que no se ajustan al comportamiento descrito. Estos últimos indican la presencia de valores anómalos y se han señalado mediante líneas discontinuas de color rojo en dicha figura.

Una vez que se han identificado los valores anómalos existentes, se utiliza la herramienta de ajuste de curvas del software MATLAB para obtener una función que se ajuste adecuadamente a los datos disponibles. Los resultados experimentales derivados de este proceso se ilustran en la Figura 6.4b. En esta se evidencia que el ajuste de tipo '*Smoothing Spline*' con un parámetro de suavizado $p = 0.0108$, proporciona un nivel de ajuste satisfactorio y una buena capacidad de adaptación. Las métricas de bondad de ajuste obtenidas en este proceso ($R^2 = 0.983$ y $RMSE = 103.9$ kW) confirman que el modelo captura con fidelidad la tendencia central de los datos. De esta manera, se pueden realizar correcciones precisas que garantizan la coherencia física de la base de datos final.

Posteriormente, se aplican diferentes filtrados estableciendo límites adecuados para cada una de las regiones señaladas mediante inspección visual experta. Una vez que se han corregido todos los valores anómalos detectados, se obtiene el gráfico de dispersión representado en la Figura 6.4c. De esta forma, se logra una estimación acertada de los valores de P_w a partir de valores específicos de W_{sg} , lo que conduce a un patrón de comportamiento bien definido y a una mayor coherencia en las observaciones.




Figura 6.4. Resultados obtenidos en la detección y corrección de valores anómalos en el conjunto de datos DWI: (a) Gráfico de dispersión inicial de W_{sg} vs. P_w , (b) Curva de tendencia estimada y (c) Gráfico de dispersión final de W_{sg} vs. P_w .

6.3.3 Resultados obtenidos en la selección de características de entrada al modelo de predicción

Al igual que en el capítulo anterior, el proceso de FS se inicia mediante un análisis de PCC entre las variables predictoras y la variable objetivo, representada en este caso por la P_w . Los resultados presentados en la Figura 6.5a evidencian que existen tres variables predictoras (W_{sg} , W_s y R_{sp}) fuertemente correlacionadas con P_w , con coeficientes de 0.96, 0.88 y 0.81, respectivamente. A continuación, se encuentra la variable f_p , con un nivel de correlación moderado de 0.64. Otras variables como I_{rs} y T_a presentan correlaciones débiles, situadas en el rango de 0.1 a 0.2. En el caso de las variables (W_{dg} , H_{op} , E_{exp} , f , P_t , M_{st} y D_{sc}), los niveles de correlación obtenidos son muy cercanos a cero, lo que indica una

correlación despreciable entre estas y la variable objetivo. Por último, se debe señalar que las variables (Qw , Gpo y Rh) presentan valores de correlación negativos con magnitudes de -0.64 , -0.42 y -0.11 , respectivamente. Estas correlaciones oscilan entre moderadas y débiles e indican una relación inversa entre dichas variables y la Pw .

Por otro lado, en la Figura 6.5b se muestran los niveles de importancia obtenidos para cada uno de los predictores utilizando un modelo RF. Se observa que la variable Wsg posee el mayor nivel de importancia, alcanzando un valor de 64.12. Además, la variable Rsp también conserva cierta importancia para el modelo (13.28), mientras que para la variable Ws este indicador se reduce significativamente a 1.79, a pesar del alto nivel de correlación obtenido mediante el análisis de PCC. Esto se debe a que la variable Ws , medida a 1 km de distancia del aerogenerador y a una menor altura, aporta información redundante para el modelo; por esta razón el algoritmo le asigna un bajo valor de importancia. Para las restantes variables que integran el conjunto de datos, se observa que sus niveles de importancia son muy bajos, o incluso despreciables en algunos casos. Por lo tanto, no se recomienda utilizarlas como entradas al modelo de pronóstico.




Figura 6.5. Resultados obtenidos en el proceso de FS para el conjunto de datos $DW1$: (a) Análisis de PCC y (b) Estimación de la importancia del predictor mediante la permutación de las observaciones fuera de la bolsa en un modelo RF.

Considerando los resultados obtenidos en el proceso de FS, se recomienda utilizar las variables predictorias (Wsg y Rsp) como entradas al modelo de pronóstico desarrollado para el conjunto de datos $DW1$. De esta forma, la dimensionalidad del conjunto de datos original, integrado por un total de 16 variables predictorias, se reduce a dos variables al finalizar el proceso de FS. Adicionalmente, se propone utilizar la propia variable Pw como una nueva entrada para el modelo de pronóstico. Por lo tanto, al incorporar la información de las variables predictorias (Wsg y Rsp) y de la variable objetivo en el instante de tiempo actual, así como en varios instantes previos, se incrementa el nivel de información disponible para el modelo y se contribuye a mejorar la calidad de las predicciones de energía eólica. Este enfoque permite aprovechar la dependencia temporal presente en la serie de tiempo de Pw , la cual constituye una fuente relevante de información para el pronóstico a muy corto plazo. Por otro lado, se debe mencionar que para el conjunto de datos $DW2$ no ha sido necesario aplicar el análisis de FS, ya que únicamente se dispone de mediciones de la variable Pw .

6.3.4 Resultados obtenidos en la identificación de rezagos en las series temporales

La determinación del número de rezagos (*lags*) en las variables de entrada previamente seleccionadas se realiza mediante las funciones estadísticas ACF y PACF, descritas en la Sección 3.3.5. Los resultados obtenidos en este proceso para los conjuntos de datos *DW1* y *DW2* se ilustran en las Figuras 6.6 y 6.7, respectivamente. En ambos casos, se observa que las series temporales analizadas exhiben un comportamiento aproximadamente autorregresivo, caracterizado por un decaimiento suave de los valores ACF y un corte abrupto de los valores PACF. Además, el gráfico PACF indica que únicamente el primer rezago presenta una fuerte relación con el valor actual de cada serie temporal, mientras que la influencia de rezagos más lejanos es despreciable. A partir de estos resultados, se recomienda utilizar el valor actual y el primer rezago de las series temporales de *Wsg*, *Rsp* y *Pw* como entradas al modelo de pronóstico implementado para el conjunto de datos *DW1*. De manera similar, se recomienda emplear el valor actual y el primer rezago de la serie temporal de *Pw* como entradas al modelo de pronóstico implementado para el conjunto de datos *DW2*.




Figura 6.6. Análisis de las funciones ACF y PACF de las series temporales *Wsg*, *Rsp* y *Pw* del conjunto de datos *DW1* para la selección del número de rezagos.




Figura 6.7. Análisis de las funciones ACF y PACF de la serie temporal *Pw* del conjunto de datos *DW2* para la selección del número de rezagos.

A partir de los resultados obtenidos en el proceso de FS y en la determinación del número de rezagos, es posible definir la estructura general de cada modelo de pronóstico, tal como se muestra en la Figura 6.8. En ambos casos, la resolución temporal de los datos históricos es de 15 min, y se considera un horizonte de pronóstico de similar magnitud, correspondiente a un paso de tiempo por delante ($t+1$).




Figura 6.8. Estructura general del modelo de pronóstico implementado para cada conjunto de datos analizado: (a) DW1 y (b) DW2.

6.4 Consideraciones generales para el pronóstico

Las consideraciones relativas al modelo de pronóstico propuesto, los modelos de referencia seleccionados para fines comparativos y el entorno de ejecución de los experimentos, son similares a las del capítulo anterior. En este caso, se utilizan dos conjuntos de datos con diversas características (DW1 y DW2) para el desarrollo de los modelos predictivos, lo que aporta mayor flexibilidad y robustez al análisis realizado.

En la Tabla 6.2 se resumen los principales hiperparámetros involucrados en el proceso de optimización, sus correspondientes espacios de búsqueda y los valores de ajuste obtenidos para cada modelo mediante BO. Los restantes hiperparámetros, que no han formado parte del proceso de optimización, se ajustan siguiendo el mismo criterio que en el capítulo anterior, con base en la literatura y la experiencia del usuario.

Tabla 6.2. Hiperparámetros, espacios de búsqueda definidos para la BO y ajustes obtenidos para cada modelo.

Modelos	Hiperparámetros	Espacios de búsqueda definidos	Ajustes obtenidos (DW1)	Ajustes obtenidos (DW2)
BiLSTM	Número de unidades en la capa oculta (<i>NumberOfUnits</i>)	[20 a 200]	82	101
	Tasa de aprendizaje inicial (<i>InitialLearnRate</i>)	[0.0001 a 0.01]	0.0058	0.0099
	Tamaño del minilote (<i>MiniBatchSize</i>)	[16 a 256]	108	40
	Factor de regularización L ₂ (<i>L2Regularization</i>)	[10 ⁻⁵ a 10 ⁻²]	8.8405 × 10 ⁻⁴	1.0274 × 10 ⁻⁴
	Tasa de abandono (<i>dropoutVal</i>)	[0.1 a 0.3]	0.2074	0.1015

Tabla 6.2. Continuación

MLP	Número de capas ocultas (<i>NumLayers</i>)	[1 o 2]	1	1
	Número de unidades en la capa oculta (<i>hiddenLayersSize</i>)	[3 a 100]	39	79
	Función de activación de la capa oculta (<i>transferFcn</i>)	{‘logsig’ ‘tansig’}	tansig	logsig
	Tasa de aprendizaje (<i>LearningRate</i>)	[0.0001 a 0.01]	7.4922×10^{-3}	5.5920×10^{-3}
SVR	Restricción de caja (<i>BoxConstraint</i>)	[0.001 a 1000]	2.8226	12.7600
	Escala del núcleo (<i>KernelScale</i>)	[0.001 a 1000]	0.7214	6.9350
	Parámetro de pérdida (<i>Epsilon</i>)	[0.001 a 100]	0.0058	0.0561
	Función del núcleo (<i>KernelFunction</i>)	{‘gaussian’ ‘linear’ ‘polynomial’}	gaussian	gaussian
	Orden polinomial (<i>PolynomialOrder</i>)	[2 a 4]	-	-

* Los términos en inglés corresponden a la denominación utilizada para cada hiperparámetro en el *software* MATLAB.

6.5 Resultados obtenidos en el pronóstico determinístico de energía eólica a muy corto plazo

En redes eléctricas con una penetración significativa de energía eólica, la obtención de predicciones precisas de la potencia generada resulta esencial para garantizar una operación eficiente y un control adecuado del sistema. En la Figura 6.9 se comparan los valores reales de P_w con las predicciones determinísticas generadas por el modelo propuesto (BiLSTM-BO) y por los modelos de referencia (persistencia, MLP-BO y SVR-BO) para un horizonte de 15 min. Al igual que en el capítulo anterior, estas comparaciones se realizan en diferentes épocas del año y bajo distintas condiciones de operación, utilizando el conjunto de prueba conformado mediante el criterio de división mensual ilustrado en la Figura 3.7. Este enfoque permite una evaluación más amplia y representativa del comportamiento de cada modelo frente a la variabilidad estacional del viento. En todos los escenarios analizados, las predicciones del modelo propuesto muestran una buena correspondencia con los valores reales de P_w , lo que evidencia una elevada capacidad de adaptación y una adecuada robustez. En cuanto a los modelos de referencia, se observa una mayor divergencia entre los valores reales y las predicciones realizadas, lo que indica una degradación en la calidad de los pronósticos y una menor capacidad de adaptación a la dinámica del proceso eólico.

Para obtener una visión más profunda de la relación existente entre las predicciones de potencia eólica generadas por cada modelo y los valores reales registrados, se emplean gráficos de dispersión. Los resultados experimentales obtenidos al aplicar esta herramienta a cada uno de los conjuntos de datos analizados se muestran en la Figura 6.10. En todos los casos, las predicciones del modelo propuesto se encuentran muy próximas a la línea de regresión ideal, lo que evidencia una alta capacidad predictiva y un buen desempeño frente a las diversas condiciones operativas presentes en los datos de prueba. Por otro lado, los modelos de referencia presentan una mayor dispersión de los puntos, lo que refleja una degradación en su capacidad predictiva y un incremento de la incertidumbre con respecto al caso anterior. Cabe señalar que las escalas de los ejes difieren entre los gráficos debido a los distintos rangos de potencia presentes en los conjuntos de datos analizados (kW y MW).




Figura 6.9. Comparación entre los valores reales de P_w y las predicciones determinísticas generadas por cada modelo bajo diferentes condiciones climáticas, para los conjuntos de datos: (a) $DW1$ y (b) $DW2$.




Figura 6.10. Gráficos de dispersión entre los valores reales de P_w y las predicciones generadas por cada modelo, para los conjuntos de datos: (a) $DW1$ y (b) $DW2$.

En cuanto a la evaluación cuantitativa del desempeño, las predicciones determinísticas se analizan mediante las métricas $nMAE$, $nRMSE$ y R^2 . En la Tabla 6.3 se presentan los resultados obtenidos para cada modelo implementado y para cada conjunto de datos, incluyendo también los tiempos de entrenamiento e inferencia de cada modelo. A partir de estos resultados, se observa que el modelo propuesto alcanza los valores más bajos en las métricas de error y el valor más elevado del coeficiente R^2 en cada escenario analizado, lo que evidencia un rendimiento superior en comparación con los modelos de referencia. Por su parte, los modelos MLP-BO y SVR-BO ocupan una posición intermedia en términos de precisión y calidad

de sus predicciones, con un rendimiento bastante similar. En cuanto al modelo de persistencia, se observan los valores más elevados de las métricas de error y los más reducidos para el coeficiente de determinación. Este comportamiento se debe a la incapacidad de este modelo para adaptarse a la naturaleza intermitente y aleatoria de la serie temporal de P_w . Como es de esperar, el modelo BiLSTM-BO requiere un mayor tiempo de entrenamiento debido a su mayor complejidad. Sin embargo, los tiempos de inferencia son muy reducidos para todos los modelos, lo que permite su uso en aplicaciones de pronósticos a muy corto plazo.

Tabla 6.3. Desempeño de los modelos en el pronóstico determinístico de energía eólica con un horizonte de 15 min.

Conjunto de datos	Métricas	Modelos de predicción			
		Persistencia	MLP-BO	SVR-BO	BiLSTM-BO
DW1	nMAE (%)	3.4988	2.0268	2.0234	0.9768
	nRMSE (%)	7.4325	4.0159	4.0112	1.3494
	R ²	0.9455	0.9815	0.9816	0.9982
	Tiempo de entrenamiento (s)	-	31.4216	96.1521	671.6294
	Tiempo de inferencia (s)	0.0141	0.0173	0.0204	0.0210
DW2	nMAE (%)	3.7207	2.3930	2.3127	1.1047
	nRMSE (%)	7.6308	4.3678	4.2901	1.6176
	R ²	0.9442	0.9811	0.9810	0.9979
	Tiempo de entrenamiento (s)	-	34.8051	102.5318	705.3945
	Tiempo de inferencia (s)	0.0150	0.0184	0.0216	0.0202

De manera general, se observa que los modelos de pronóstico presentan un mejor desempeño en el conjunto de datos *DW1*. En este caso, se dispone de información adicional correspondiente a las variables *Wsg* y *Rsp*, lo que contribuye a incrementar la calidad de las predicciones obtenidas. No obstante, el modelo propuesto es capaz de lograr predicciones satisfactorias en ambos conjuntos de datos, tal como lo demuestran los resultados gráficos y numéricos presentados.

Para complementar la evaluación, se cuantifica el porcentaje de mejora ($\%I$) del modelo propuesto con respecto a cada modelo de referencia, tomando como base la métrica nMAE (Figura 6.11). En ambos conjuntos de datos se observa una tendencia consistente: el modelo BiLSTM-BO logra mejoras en torno al 70 % respecto al modelo de persistencia y cercanas al 50 % en comparación con los modelos MLP-BO y SVR-BO. Estos resultados confirman nuevamente la robustez y la capacidad de generalización del modelo propuesto en la predicción de energía eólica a muy corto plazo.




Figura 6.11. Porcentaje de mejora alcanzado por el modelo propuesto con respecto a los modelos de referencia para cada conjunto de datos, tomando como base la métrica nMAE.

Al igual que en el capítulo anterior, resulta pertinente comparar el rendimiento del modelo propuesto en el contexto de la predicción determinística de energía eólica con respecto a otros modelos de la literatura. En este caso, también se han seleccionado estudios que abordan un horizonte de pronóstico similar y que, al mismo tiempo, utilizan enfoques de pronóstico avanzados. De esta forma, se ofrece una visión general del desempeño relativo de cada modelo analizado. Sin embargo, realizar comparaciones directas entre diferentes estudios resulta una tarea compleja, debido principalmente a las particularidades de cada ubicación, la resolución temporal de los datos y las características de cada conjunto de datos analizado. Por lo tanto, estos resultados solo aportan una idea general para enmarcar la efectividad del modelo propuesto en un contexto más amplio y no deben considerarse como una prueba experimental concluyente.

En la Tabla 6.4 se presentan los principales resultados reportados en cada uno de los trabajos analizados. Se observa que el modelo propuesto exhibe un desempeño satisfactorio en términos de precisión, caracterizado por errores de predicción reducidos y altos valores del coeficiente de determinación. Estos resultados sugieren que la integración de las capacidades del modelo BiLSTM con técnicas avanzadas de preprocesamiento y manejo de datos constituye un factor clave para mejorar la calidad de los pronósticos de energía eólica a muy corto plazo. Además, la incorporación de un algoritmo eficiente de optimización de hiperparámetros permite mejorar de manera significativa la precisión de los pronósticos.

Tabla 6.4. Comparación de los resultados obtenidos en esta investigación para el pronóstico determinístico de energía eólica con respecto a otros estudios reportados en la literatura.

Ref. y año	Modelo de pronóstico	Características de los datos utilizados	Entradas al modelo de pronóstico	Horizonte de pronóstico	Métricas de desempeño
[166], 2020	Análisis espaciotemporal (<i>Spatio-temporal analysis, ST</i>) – SVM de salida múltiple (<i>Multi-output SVM, MSVM</i>) – GWO	Datos de potencia de 15 parques eólicos en una región, medidos durante el mes de junio de 2016, con resolución temporal de 15 min	Potencia eólica en el instante de tiempo t y en 3 instantes anteriores	(15 min – 45 min)	Para un horizonte de 15 min: nMAE = 2.10 % nRMSE = 4.17 %

Tabla 6.4. Continuación

[167], 2021	CNN – LSTM	Datos de un parque eólico ubicado en China, medidos durante el año 2017 con resolución temporal de 5 min, Pnom = 49.5 MW	Velocidad y dirección del viento en el instante de tiempo t y en 11 instantes anteriores	(5 min – 1 h)	Para un horizonte de 15 min: nMAE = 2.602 % nRMSE = 3.996 %
[168], 2022	FS – GWO – VMD – BiLSTM con mecanismo de atención	Datos de un parque eólico en Yanchi County, Ningxia, China, medidos en los meses de marzo, mayo, agosto y noviembre con resolución temporal de 15 min, Pnom = 100 MW	Velocidad y dirección del viento, temperatura y humedad	15 min	Valor promedio de las métricas: MAE = 1.323 MW RMSE = 1.923 MW nMAE* = 1.323 % nRMSE* = 1.923 % R ² = 0.9895
[169], 2023	Red neuronal basada en la autoatención (<i>Self-attention-based neural network</i> , SANN) – GS	Caso 1: Datos de potencia eólica a escala regional obtenidos del TSO de Alemania, medidos durante el año 2020 con resolución de 15 min, Pnom = 463 MW Caso 2: Datos de un parque eólico en China, medidos de marzo a mayo de 2021 con resolución temporal de 15 min, Pnom = 99.5 MW	Para ambos conjuntos de datos: Potencia eólica en el instante de tiempo t y en 15 instantes anteriores	(15 min, 1 h y 2 h)	Para un horizonte de 15 min: Caso 1: MAE = 1.88 MW RMSE = 3.27 MW nMAE* = 0.406 % nRMSE* = 0.706 % R ² = 0.997 Caso 2: MAE = 2.17 MW RMSE = 3.11 MW nMAE* = 2.181 % nRMSE* = 3.126 % R ² = 0.980
[170], 2024	FS – GA – ANN	Datos de un aerogenerador medidos desde enero de 2018 hasta marzo de 2020 con resolución temporal de 10 min	Temperatura ambiente, temperatura del eje, ángulo de paso de las palas, RPM del generador, temperatura de los devanados del generador, posición de la góndola, potencia reactiva, RPM del rotor y velocidad del viento	10 min	nMAE = 1.03 % nRMSE = 2.05 %
Este trabajo	Algoritmo de preprocesamiento de datos – FS – BiLSTM – BO	Conjuntos de datos DW1 y DW2 descritos en la Sección 6.2	Para DW1: Wsg, Rsp y Pw en el instante de tiempo t y en $t-1$ Para DW2: Pw en el instante de tiempo t y en $t-1$	15 min	Para DW1: nMAE = 0.9768 % nRMSE = 1.3494 % R ² = 0.9982 Para DW2: nMAE = 1.1047 % nRMSE = 1.6176 % R ² = 0.9979

*Indica que la métrica ha sido normalizada para establecer la comparación utilizando métricas independientes de la escala. Para las referencias [168] y [169] las métricas se normalizan considerando la potencia nominal de cada instalación. Además, en el caso de

la referencia [168], donde los resultados se reportan por estaciones del año, se emplea el valor promedio de las cuatro estaciones para efectuar la comparación.

6.6 Resultados obtenidos en el pronóstico probabilístico de energía eólica a muy corto plazo

La obtención de pronósticos probabilísticos resulta esencial para caracterizar adecuadamente las incertidumbres del pronóstico determinístico de energía eólica. En la Figura 6.12 se muestran los valores reales de potencia eólica, las predicciones determinísticas del modelo propuesto para un horizonte de 15 min y los correspondientes PIs generados mediante el método de remuestreo *bootstrap* para diferentes valores de PINC (80 %, 90 % y 95 %).




Figura 6.12. PIs generados mediante el método de remuestreo bootstrap para diferentes valores de PINC (80 %, 90 % y 95 %) en días representativos de los conjuntos de datos: (a) DW1 y (b) DW2.

Se observa que para ambos conjuntos de datos los PIs se ajustan de manera satisfactoria a los niveles de confianza establecidos, lo que demuestra la efectividad del método implementado. Incluso bajo condiciones climáticas de alta variabilidad, que conducen a mayores errores en las predicciones determinísticas, el

enfoque propuesto mantiene un desempeño adecuado. Estos resultados confirman la viabilidad del método *bootstrap* para la gestión de incertidumbres y para apoyar la operación eficiente del sistema eléctrico.

Al igual que en el capítulo anterior, la evaluación de las predicciones probabilísticas se sustenta en las métricas PICP, PINAW y ACE. En la Tabla 6.5 se presentan los resultados obtenidos para cada conjunto de datos disponible, considerando distintos valores de PINC. Se observa que, en todos los casos, los valores de PICP se encuentran muy próximos a cada PINC definido, lo que conduce a valores reducidos del ACE. Esto indica una buena cobertura de los PIs y un alto nivel de fiabilidad. Por otra parte, se aprecia que al disminuir el nivel de PINC, también disminuyen los valores de la métrica PINAW y el ancho de los PIs obtenidos. De esta forma, se obtiene un rango de potencia más ajustado y una mayor nitidez de las predicciones probabilísticas.

Tabla 6.5. Evaluación del desempeño de los pronósticos probabilísticos de energía eólica para distintos niveles de PINC.

Conjunto de datos	Métricas	Valores de PINC		
		PINC = 80 %	PINC = 90 %	PINC = 95 %
DW1	PICP (%)	80.4161	90.3420	95.5201
	ACE (%)	0.4161	0.3420	0.5201
	PINAW (%)	4.2370	4.9806	6.2847
DW2	PICP (%)	80.6354	90.4423	95.5008
	ACE (%)	0.6354	0.4423	0.5008
	PINAW (%)	4.6372	5.5061	6.8645

Para obtener una visión más completa sobre la efectividad de los pronósticos probabilísticos realizados, resulta conveniente compararlos con varios estudios recientes de la literatura. Los estudios seleccionados emplean distintos métodos, tanto paramétricos como no paramétricos, para generar los pronósticos probabilísticos a muy corto plazo. No obstante, es importante señalar que las comparaciones resultan complejas debido a la diversidad de factores que influyen en el proceso de pronóstico. En la Tabla 6.6 se presentan los principales resultados obtenidos en cada uno de los trabajos analizados.

Tabla 6.6. Comparación de los pronósticos probabilísticos de energía eólica obtenidos en este trabajo con resultados reportados en otros estudios reportados en la literatura.

Ref. y año	Descripción general del estudio	Métricas obtenidas en la predicción probabilística (PINC = 90 %)
[171], 2020	Modelo híbrido paramétrico (<i>T Location-Scale</i> , TLS). Datos de una instalación eólica en España.	PICP = 90.94 % ACE = 0.94 % PINAW = 23.83 %
[168], 2022	Modelo híbrido no paramétrico basado en KDE con función del núcleo Gaussiana (KDE-Gaussian). Datos de una instalación eólica en China.	PICP = 90.28 % ACE = 0.28 % PINAW = 9.67 %

Tabla 6.6. Continuación

		Para los datos de Austria: PICP = 92.11 %, ACE = 2.11 %, PINAW = 3.50 %
		Para los datos de Hungría: PICP = 91.89 %, ACE = 1.89 %, PINAW = 4.88 %
		Para los datos de Reino Unido: PICP = 92.29 %, ACE = 2.29 %, PINAW = 6.04 %
[172], 2023	Modelo skip-GRU combinado con remuestreo <i>bootstrap</i> por bloques. Datos de Austria, Hungría y Reino Unido.	PICP = 93.75 % ACE = 3.75 % PINAW = 18.34 %
[173], 2023	Modelo híbrido integrado por simulaciones de Monte Carlo - ELM - VMD. Datos de una instalación eólica en Galicia, España.	PICP = 88.77 % ACE = -1.23 % PINAW = 22.28 %
[174], 2024	Modelo de red neuronal recurrente estocástica con codificador decodificador (<i>Stochastic recurrent encoder decoder neural network</i> , SREDNN). Datos de una instalación eólica en Turquía.	
Este trabajo	Predicciones determinísticas del modelo BiLSTM-BO combinadas con el método de remuestreo <i>bootstrap</i> para generar predicciones probabilísticas en forma de PIs. Datos de dos instalaciones eólicas en Tenerife (DW1) y Bélgica (DW2).	Para DW1: PICP = 90.3420 %, ACE = 0.3420 %, PINAW = 4.9806 %
		Para DW2: PICP = 90.4423 %, ACE = 0.4423 %, PINAW = 5.5061 %

Los resultados anteriores indican que el modelo propuesto presenta un buen desempeño en términos de fiabilidad, mostrando una cobertura adecuada de los PIs con valores reducidos del ACE. En este caso, solamente el modelo presentado en la referencia [168] obtiene un valor ligeramente menor para esta métrica. Por otra parte, al analizar los valores de la métrica PINAW, se observa que el modelo propuesto mantiene una posición favorable, siendo superado únicamente por la referencia [172]. Sin embargo, en esta última, se registran valores más elevados para la métrica ACE. Por lo tanto, aunque algunos trabajos analizados presentan mejor desempeño en métricas individuales, es evidente que el modelo propuesto logra un desempeño satisfactorio en términos generales. Esto se debe al equilibrio alcanzado entre fiabilidad y nitidez de los PIs para cada conjunto de datos, lo que reafirma su viabilidad para la gestión de incertidumbres y la toma de decisiones en el sistema eléctrico.

6.7 Pronóstico de energía eólica en condiciones de operación atípicas

Resulta fundamental evaluar el rendimiento y la capacidad de adaptación del modelo propuesto en condiciones de operación atípicas. Estas condiciones se asocian principalmente con el fallo temporal de los sensores de medición y con la presencia de ruido blanco en los datos durante la operación en tiempo real. Para efectuar este análisis, se selecciona el conjunto de datos DW1, el cual cuenta con un mayor número de variables de entrada para el modelo de pronóstico, lo que permite realizar experimentos más diversos y flexibles.

6.7.1 Explicabilidad del modelo de pronóstico

La información derivada del análisis de explicabilidad constituye un elemento fundamental para evaluar el pronóstico de energía eólica en condiciones de operación atípicas. En la Figura 6.13 se muestra la contribución de cada variable de entrada utilizando la técnica de XAI denominada RFE. Se observa que las variables P_{w_t} y W_{sg_t} son las más relevantes para el modelo, con contribuciones de 51.80 % y 46.22 %, respectivamente. Asimismo, sus valores rezagados ($P_{w_{t-1}}$ y $W_{sg_{t-1}}$) también exhiben contribuciones relevantes, con valores de 36.57 % y 31.39 %, respectivamente. En el caso de la variable R_{sp_t} , aunque posee cierta importancia para el modelo propuesto, su contribución resulta más reducida, con un valor de 14.44 %. Por último, la menor contribución se obtiene para la variable $R_{sp_{t-1}}$, con un valor de 5.42 %. Es importante destacar que el análisis anterior favorece la comprensión del funcionamiento del modelo y proporciona información valiosa para garantizar un desempeño adecuado bajo condiciones atípicas.




Figura 6.13. Contribuciones estimadas de las variables de entrada al modelo de pronóstico propuesto, obtenidas mediante la técnica de XAI conocida como RFE.

6.7.2 Pérdida de información en las variables de entrada

El fallo temporal de uno o varios sensores de medición representa una condición atípica relevante que puede ocurrir durante la operación en tiempo real del modelo de pronóstico. Al igual que en el capítulo anterior, se consideran dos casos de estudio para evaluar esta situación: en el primero, las variables de entrada fallan de manera individual; en el segundo, todas fallan simultáneamente, representando el peor escenario posible. Para simplificar el análisis, se adopta un enfoque global que permite medir el impacto de la pérdida de cada variable sobre el rendimiento del modelo.

En la Figura 6.14 se presentan los resultados obtenidos para el primer caso de estudio. Cuando ocurre un fallo temporal en las variables de mayor influencia (Pw y Wsg), la calidad de las predicciones tiende a disminuir, lo que se refleja en un aumento del nMAE y en una disminución del coeficiente R^2 . En términos relativos, el nMAE aumenta un 72.18 % y un 65.53 %, respectivamente, respecto al escenario de referencia, donde las condiciones de operación permanecen estables. Por el contrario, la pérdida de la variable Rsp tiene un impacto menor, con un incremento del nMAE cercano al 17.21 %, debido a su menor relevancia para el modelo.




Figura 6.14. Rendimiento del modelo propuesto ante la pérdida temporal de diferentes variables de entrada.

En la Figura 6.15 se presentan los resultados correspondientes al segundo caso de estudio. En este escenario, el modelo propuesto predice la potencia eólica durante un período de cuatro horas sin información actualizada debido al fallo simultáneo de todos los sensores de medición. Se observa que, a medida que se prolonga la duración del fallo, el nMAE aumenta y el coeficiente R^2 disminuye, indicando una pérdida gradual de precisión. Al transcurrir un período de cuatro horas, el nMAE se incrementa en 2.83 % y el R^2 se reduce en 1.93 % respecto al escenario inicial. A pesar de esta degradación esperada, el modelo demuestra un desempeño satisfactorio y una buena capacidad de adaptación. Esto lo posiciona como una herramienta efectiva para aplicaciones de predicción en tiempo real que requieren continuidad del proceso predictivo.




Figura 6.15. Rendimiento del modelo propuesto en la predicción de potencia eólica después del fallo temporal de todas las variables de entrada.

6.7.3 Presencia de ruido blanco en las mediciones disponibles

Para evaluar de manera más integral el rendimiento del modelo propuesto bajo escenarios atípicos, se analiza su comportamiento frente a la presencia de ruido blanco en las mediciones. En este caso, el enfoque

metodológico y las consideraciones establecidas son similares a las aplicadas en el capítulo anterior, incluyendo el nivel de ruido blanco añadido a cada variable de entrada (18 dB). A modo de ejemplo, en la Figura 6.16 se muestra el comportamiento de la serie temporal de Wsg en condiciones de operación estables y ante la presencia de ruido blanco añadido. Se observa que la introducción de un nivel controlado de ruido blanco aumenta la variabilidad de la variable analizada, lo que aumenta la incertidumbre para la obtención de pronósticos precisos.




Figura 6.16. Representación de la serie temporal de Wsg perteneciente a los datos de prueba del conjunto $DW1$ considerando las mediciones originales y con ruido blanco añadido.

Para evaluar el rendimiento y la capacidad de adaptación en esta condición, se introducen los datos de prueba con ruido blanco añadido en el modelo de pronóstico previamente entrenado. Además, es necesario definir varios casos de estudio para facilitar la comprensión del análisis realizado. El caso 1 corresponde al escenario de referencia, sin ruido blanco añadido. Los casos 2, 3 y 4 introducen ruido blanco en las variables Wsg , Rsp y Pw , respectivamente, mientras que el caso 5 considera ruido blanco simultáneo en todas las variables de entrada.

En las Figuras 6.17a y 6.17b se muestran los resultados derivados de este análisis, considerando las métricas $nMAE$ y R^2 para un horizonte de pronóstico de 15 min. Al analizar los casos 2 y 4, se observa un incremento en los valores del $nMAE$ y una disminución en los valores del coeficiente R^2 con respecto al escenario de referencia. Este deterioro en la calidad de las predicciones se atribuye a la sensibilidad del modelo hacia las variables afectadas, debido a su nivel de relevancia en el proceso predictivo. En el caso 3, se identifica una tendencia similar en el comportamiento de las métricas, aunque con un impacto considerablemente menor debido al menor nivel de importancia de la variable Rsp . Por último, el caso 5 presenta los resultados más críticos, caracterizados por el mayor incremento en el $nMAE$ y la mayor reducción en el coeficiente R^2 , debido a la presencia de ruido blanco en todas las variables de entrada al modelo. En términos generales, aunque se evidencian diferencias en el rendimiento del modelo entre los casos analizados, su robustez y capacidad de adaptación frente a esta condición atípica pueden considerarse satisfactorias. Estos resultados reafirman el potencial del enfoque propuesto para la predicción de energía eólica bajo diversas condiciones de operación durante el proceso predictivo.




Figura 6.17. Rendimiento del modelo de pronóstico propuesto ante la presencia de ruido blanco en diferentes variables de entrada:

(a) Considerando la métrica nMAE y (b) Considerando la métrica R^2 .

6.7.4 Predicción probabilística en escenarios de operación atípicos

También resulta importante analizar el comportamiento de las predicciones probabilísticas en condiciones de operación atípicas. Para este propósito, se selecciona un caso de estudio asociado con el fallo simultáneo de todos los sensores de medición que suministran información al modelo durante un período de cuatro horas. Como referencia para la evaluación se emplea la métrica PINAW, considerando un valor de PINC del 95 %. Los resultados obtenidos se presentan en la Figura 6.18.




Figura 6.18. Comportamiento de los PIs bajo condiciones de operación atípicas asociadas con el fallo temporal de todas las variables de entrada de manera simultánea.

Se observa que, a medida que aumenta el período de tiempo sin información actualizada, se incrementan los valores del PINAW y, en consecuencia, se amplía la cobertura de los PIs generados. Esta ampliación de los PIs es necesaria para garantizar una información confiable, que resulte de utilidad para la planeación y la operación del sistema eléctrico. De esta manera, se aporta una base sólida para apoyar la toma de decisiones ante contingencias en los sistemas de medición.

6.8 Conclusiones del capítulo

En este capítulo se han analizado de manera detallada los principales resultados obtenidos en la predicción de energía eólica para un horizonte temporal de muy corto plazo. El enfoque de pronóstico propuesto resulta similar al del capítulo anterior. Los experimentos realizados confirman nuevamente su efectividad en el pronóstico de series temporales complejas y no lineales, como es el caso de la potencia eólica. Además, en este estudio se han utilizado dos conjuntos de datos de diferente naturaleza para evaluar con mayor profundidad el desempeño de la metodología implementada en diferentes condiciones operativas. En el contexto de los pronósticos determinísticos, el modelo ha demostrado un desempeño satisfactorio en comparación con varios modelos de referencia y con diversos estudios de la literatura.

Por otra parte, las predicciones probabilísticas generadas mediante el método de remuestreo *bootstrap* han permitido caracterizar de manera eficiente las incertidumbres inherentes al pronóstico determinístico. En este sentido, se obtuvieron valores adecuados de las métricas PICP, PINAW y ACE en cada caso analizado, lo que demuestra un equilibrio favorable entre fiabilidad y nitidez en comparación con otros enfoques existentes. Una de las ventajas más relevantes del enfoque utilizado es que no requiere asumir una distribución de probabilidad específica para los errores de pronóstico, lo que lo convierte en una herramienta eficaz para el tratamiento de este tipo de problemas.

En cuanto a la operación en condiciones atípicas, vinculadas con la pérdida temporal de información y la presencia de ruido blanco, se ha demostrado la capacidad de adaptación de la metodología propuesta. Estos resultados confirman que el enfoque mantiene un desempeño adecuado incluso ante escenarios adversos, siendo útil para aplicaciones de pronóstico en tiempo real. En general, los resultados presentados en este capítulo confirman que la metodología propuesta resulta efectiva y viable para el pronóstico de energía eólica a muy corto plazo. Además, su flexibilidad permite adaptarla con facilidad a otros conjuntos de datos y a diferentes horizontes de pronóstico según se requiera. Asimismo, constituye un recurso valioso para la planificación y la operación de sistemas eléctricos con altos niveles de penetración de RES.

CAPÍTULO 7. IMPACTO DE LOS PRONÓSTICOS DE ENERGÍA SOLAR PV Y EÓLICA EN EL CONTROL DE FRECUENCIA

7.1 Introducción

En este capítulo se presentan y discuten los resultados más relevantes asociados al impacto del pronóstico de las RES en la regulación de frecuencia de una microrred, bajo un enfoque de control proactivo. En primer lugar, se describe la metodología de trabajo empleada, destacando la integración de términos de compensación anticipativa (*feed-forward*) en la consigna del lazo de control secundario del DEG. Posteriormente, se definen las consideraciones generales del estudio y las principales características del modelo de microrred implementado. También se abordan los aspectos relacionados con la obtención del modelo de pequeña señal, el análisis detallado de los errores de pronóstico, así como el diseño y la optimización del controlador correspondiente. Finalmente, se analiza cómo los pronósticos generados por diferentes modelos influyen en el comportamiento del sistema y se realiza una evaluación de la robustez del sistema ante contingencias severas.

7.2 Descripción de la metodología propuesta

En la Figura 7.1 se muestra la estructura general de la metodología propuesta para llevar a cabo el estudio mencionado. El proceso comienza con la implementación del modelo de la microrred, considerando las características técnicas de cada elemento y las posibles condiciones de operación. En el siguiente paso se obtiene el modelo de pequeña señal de cada elemento y, posteriormente, se procede a su integración para obtener un modelo equivalente del sistema bajo estudio. Paralelamente, se generan los pronósticos de las RES mediante los modelos descritos en los Capítulos 5 y 6, y se cuantifican detalladamente los errores asociados a cada fuente de energía y a cada modelo analizado.

A diferencia de los esquemas reactivos convencionales que se utilizan frecuentemente en la literatura, en este estudio los pronósticos se utilizan para generar una señal de compensación de potencia anticipativa. Este enfoque se alinea con investigaciones recientes, como las presentadas en [175] y [176], donde se demuestra que la integración de valores pronosticados favorece el desempeño del sistema de control. Según la lógica descrita en [176], la señal proactiva permite pre-ajustar dinámicamente la referencia de potencia de las fuentes controladas antes de que las variaciones en la potencia neta produzcan desviaciones de frecuencia. En el presente estudio, esta señal se integra directamente en el lazo secundario mediante una ganancia proactiva (K_{pro}) establecida como unitaria. De este modo, el esquema implementado combina la respuesta típica del controlador PID (basada en la desviación física de frecuencia de la microrred) con la acción proactiva derivada del pronóstico. Esta combinación ayuda a mitigar con mayor efectividad los efectos de la baja inercia y la intermitencia de las fuentes renovables.

En el modelo implementado, los parámetros del controlador se ajustan mediante algoritmos de optimización metaheurísticos (específicamente PSO y GWO) para mejorar el rendimiento dinámico bajo condiciones críticas. Posteriormente, se analizan los resultados obtenidos para determinar cómo impacta la

precisión de los pronósticos en la estabilidad de la red. Además, se incluye la evaluación de la robustez operativa del sistema ante contingencias severas, analizando escenarios de desconexión de carga por baja frecuencia (UFLS).




Figura 7.1. Estructura general de la metodología propuesta para analizar el impacto del pronóstico de las RES en el control de frecuencia de una microrred aislada con múltiples DER.

7.3 Consideraciones generales para el estudio

Para llevar a cabo el estudio, se ha implementado una microrred de AC que opera aislada de la red eléctrica principal e integra múltiples DER, como se muestra en la Figura 7.2. En este modo de operación, la estabilidad de frecuencia representa un desafío debido a la baja inercia del sistema y a la naturaleza estocástica de las RES y la demanda [140]. Estas características hacen de la microrred seleccionada un entorno adecuado para el desarrollo de este tipo de análisis. Además, esta infraestructura eléctrica constituye la base para el modelado dinámico y el esquema de control presentados en la Sección 7.4.




Figura 7.2. Topología eléctrica de la microrred híbrida implementada y distribución de los DER.

Para el análisis dinámico, se han seleccionado perfiles de potencia basados en mediciones reales para caracterizar las perturbaciones del sistema. Específicamente, para el sistema PV se emplean los datos del conjunto *D1* (Capítulo 5), mientras que para el sistema eólico se utilizan los datos de *DW1* (Capítulo 6). En ambos casos, los datos pertenecen a la ventana de evaluación del conjunto de prueba, la cual fue seleccionada mediante el criterio de muestreo mensual ilustrado en la Figura 3.7. Por su parte, la demanda se incorpora como un perfil de carga aleatorio y determinístico, basado en registros reales de entornos rurales. Es importante destacar que, a diferencia de las RES, la carga se asume como un perfil de perturbación conocido. Esta delimitación permite aislar el estudio de la incertidumbre de los pronósticos de energía solar PV y eólica, evaluando su impacto directo en la estabilidad de frecuencia del sistema.

Se debe precisar que todos los perfiles seleccionados poseen una resolución temporal de 15 min y abarcan un período de 3 días (288 observaciones). Estos perfiles fueron normalizados y escalados para asegurar la coherencia operativa entre los niveles de generación renovable y carga. Además, es importante mencionar que, en el modelo de pequeña señal no se asignan potencias nominales fijas, sino que se trabaja con estos perfiles normalizados. Este enfoque garantiza que el comportamiento dinámico sea coherente con el punto de operación y permite evaluar la estabilidad frente a perturbaciones sin depender de valores absolutos. Bajo esta configuración, las unidades controladas (DEG y FCG) responden a las variaciones del sistema a través de un controlador PID que regula la frecuencia en el punto de acoplamiento común. Por último, este esquema se complementa con la acción proactiva asistida por IA descrita anteriormente, orientada a anticipar las variaciones de las RES de la microrred.

Aunque los perfiles de entrada poseen una resolución de 15 min, el modelo dinámico está diseñado para evaluar la convergencia y las respuestas inerciales en una escala de segundos. Bajo esta lógica, cada variación en los datos se analiza como una perturbación tipo escalón, lo que permite validar si el controlador

es capaz de estabilizar la frecuencia antes del siguiente intervalo de muestreo. Para optimizar el tiempo de cómputo, se establece una ventana de simulación (ΔT_{sim}) de 40 s por evento, período suficiente para capturar la dinámica transitoria y el asentamiento de la frecuencia antes de la siguiente transición. Aunque en este estudio se emplean intervalos de 15 min, la metodología es escalable a resoluciones más finas, manteniendo la misma filosofía de mitigación de perturbaciones. Este esquema de simulación por eventos busca que la microrred mantenga su robustez al garantizar que la frecuencia del sistema se mantenga dentro del límite permisible de $\pm 0.5\%$ (± 0.3 Hz) respecto a su valor nominal de 60 Hz. El umbral seleccionado, aunque más restrictivo que los estándares convencionales, se define de acuerdo con los criterios de estabilidad para sistemas de baja inercia [143], [176]. Esto favorece que las desviaciones de frecuencia permanezcan, en la medida de lo posible, dentro de una región de linealidad segura, lo que valida el uso de la expansión por series de Taylor para el análisis de pequeña señal bajo perturbaciones moderadas.

7.4 Modelo de pequeña señal de la microrred

El modelo de pequeña señal se considera una herramienta eficaz para estudiar la estabilidad de frecuencia en microrredes aisladas frente a condiciones de carga y generación variables [140]. De acuerdo con lo planteado en la Sección 4.3.10, para este tipo de estudios los elementos de la microrred se modelan mediante funciones de transferencia de bajo orden, especificando el valor de la constante de tiempo de cada elemento. Además, se han definido los valores correspondientes a la constante de inercia (H) y el coeficiente de amortiguamiento de la carga (D). En la Figura 7.3 se muestra el modelo dinámico de pequeña señal obtenido para la microrred analizada, considerando las especificaciones anteriores.




Figura 7.3. Modelo dinámico de pequeña señal de la microrred implementada, utilizado para el análisis de estabilidad y la regulación de frecuencia.

La inclusión de múltiples DER responde a la necesidad de representar una arquitectura de microrred moderna y resiliente, donde la diversidad de fuentes actúa como una medida de seguridad para garantizar la estabilidad frente a la naturaleza estocástica de las RES. En la Tabla 7.1 se presentan los valores de los principales parámetros del modelo implementado, los cuales se han seleccionado según las recomendaciones presentadas en las referencias [141], [142], [143]. En este caso, los valores seleccionados para las constantes de tiempo corresponden a modelos validados para microrredes de baja inercia. En estos entornos, la respuesta de los inversores y gobernadores electrónicos debe ocurrir en escalas temporales rápidas para contrarrestar el alto valor del RoCoF inherente a sistemas con baja constante de inercia ($H = 0.1$ s). De esta manera, se evita que la frecuencia alcance niveles críticos de deslastre de carga.

También se debe mencionar que en este estudio se distinguen tres etapas fundamentales del control de frecuencia: la respuesta inercial, la respuesta primaria y la respuesta secundaria. La respuesta inercial se desarrolla de forma natural tras una perturbación, apoyada por la contribución del BESS y el FESS. La respuesta primaria involucra al DEG a través de su característica de caída (R) para limitar la tasa de cambio de la frecuencia. Por último, actúa la respuesta secundaria, que regula la potencia de salida de las fuentes controladas (DEG y FCG) bajo la acción del controlador PID para restaurar la frecuencia a su valor nominal.

Tabla 7.1. Principales parámetros que intervienen en el modelo de pequeña señal de la microrred.

Parámetro	Unidad de medida	Valor utilizado
Constante de amortiguamiento de la carga (D)	[pu/Hz]	0.015
Constante de inercia (H)	[s]	0.1
Constante de tiempo del sistema PV (T_{pv})	[s]	1.5
Constante de tiempo del sistema eólico (T_{wtg})	[s]	1.8
Constante de tiempo del gobernador de velocidad (T_g)	[s]	0.08
Constante de tiempo de la turbina mecánica (T_t)	[s]	0.4
Constante de tiempo del BESS (T_{bess})	[s]	0.1
Constante de tiempo del FESS (T_{fess})	[s]	0.1
Constante de tiempo del FCG (T_{fcg})	[s]	0.26
Constante de tiempo del inversor (T_{inv})	[s]	0.04
Característica de caída del gobernador (R)	[Hz/pu]	3
Tiempo de preparación de las reservas (T_{ant})	[s]	0.5
Ganancia proactiva de acoplamiento (K_{pro})	-	1

Para mejorar el desempeño del control secundario frente a la intermitencia renovable, se introduce un lazo de control proactivo (cuya arquitectura se presenta en el diagrama de bloques de la Figura 7.3) basado en el enfoque de la referencia [176]. A diferencia del PID tradicional, que reacciona a la desviación de frecuencia ya ocurrida, este lazo inyecta una señal de compensación anticipativa directamente en la consigna del DEG. Un aspecto fundamental en la implementación de este enfoque es la sincronización temporal entre el modelo dinámico y los perfiles de datos. Bajo el esquema de simulación por eventos detallado en la

Sección 7.3, se valida la capacidad del sistema para alcanzar un nuevo estado estacionario tras cada perturbación, lo cual optimiza el esfuerzo computacional.

A partir de la lógica de control discutida en la sección 7.2, la señal de consigna de potencia total enviada al DEG (P_c) se expresa en el dominio de Laplace como:

$$P_c(s) = \left(k_p + \frac{k_i}{s} + k_d \cdot s \right) \cdot \Delta f(s) + k_{pro} \cdot P_{pro}(s) \cdot e^{s \cdot T_{ant}} \quad (7.1)$$

donde $P_c(s)$ representa la consigna de potencia total; $\Delta f(s)$ representa la desviación de frecuencia; $P_{pro}(s)$ corresponde a la señal de compensación derivada del pronóstico; k_{pro} es la ganancia proactiva de acoplamiento (definida como unitaria); y $e^{s \cdot T_{ant}}$ representa el operador de anticipación temporal para la preparación de las reservas.

Para la ejecución práctica de este control, el término ($P_{pro}(s)$) se implementa mediante un algoritmo de compensación dinámica dentro del lazo de control secundario. Con el objetivo de mitigar el estrés operativo en el DEG, dicha señal no se aplica como una función escalón, sino a través de una transición lineal (rampa) que inicia con un tiempo de preparación de las reservas (T_{ant}) de 0.5 s respecto al instante previsto del disturbio. Este valor se selecciona en función de las constantes de tiempo mecánicas combinadas del gobernador y la turbina ($T_g + T_t$). De esta manera, se compensan los retardos físicos de dichos elementos para que el movimiento de las reservas se desarrolle de manera progresiva y en sincronismo con el desbalance físico real. Si bien la respuesta inicial del DEG es puramente reactiva y regida por el estatismo (R), la rampa de anticipación permite coordinar el aporte de potencia pronosticada para optimizar la restauración de la frecuencia desde el inicio del evento. Este enfoque evita el retraso característico de la regulación secundaria convencional y mejora la estabilidad de la microrred ante la intermitencia de las RES.

7.5 Diseño del controlador de la microrred

De acuerdo con el marco teórico establecido en la Sección 4.10.4, en este estudio se adopta una estrategia de control centralizada basada en un controlador PID para la regulación de frecuencia. Para determinar sus parámetros de ajuste, se comparan la herramienta *PID Tuner* de MATLAB y los algoritmos de optimización metaheurísticos PSO y GWO. Es importante destacar que este ajuste inicial se realiza sobre la estructura de control convencional, sin incluir la señal de compensación anticipativa. Esto permite establecer el desempeño base del sistema, que servirá como punto de referencia para cuantificar las mejoras introducidas posteriormente por la estrategia propuesta.

En la Tabla 7.2 se resumen las configuraciones iniciales utilizadas para el ajuste de los algoritmos metaheurísticos. Los valores seleccionados buscan un equilibrio entre la velocidad de convergencia y el tiempo de cómputo requerido para las simulaciones.

Tabla 7.2. Parámetros de configuración inicial para los algoritmos metaheurísticos.

Parámetro	PSO	GWO
Tamaño de la población (partículas/agentes)	30	30
Número máximo de iteraciones	30	30
Coefficientes de aceleración (c_1, c_2)	(1.49, 1.49)	-
Factor de convergencia (α)	-	Linealmente decreciente (2 a 0)
Función objetivo	ITAE	ITAE

Para el ajuste de los parámetros del controlador, la herramienta *PID Tuner* se basa en algunos criterios de desempeño transitorio como el tiempo de estabilización y el sobreimpulso máximo, entre otros [143]. Por su parte, los algoritmos PSO y GWO optimizan el desempeño de forma integral mediante la minimización de la función objetivo ITAE. Como se observa en la Figura 7.4, ambos algoritmos convergen hacia una solución favorable durante el proceso de optimización. No obstante, el algoritmo PSO exhibe una mayor estabilidad y una convergencia más temprana hacia un valor mínimo estable de la función objetivo en el espacio de búsqueda explorado. Los parámetros del controlador PID obtenidos mediante cada método de ajuste analizado se presentan en la Tabla 7.3.




Figura 7.4. Curvas de convergencia de la función objetivo para los algoritmos PSO y GWO.

Tabla 7.3. Parámetros del controlador PID obtenidos mediante diferentes métodos de ajuste.

Parámetros	Métodos de ajuste utilizados		
	<i>PID Tuner</i>	PSO	GWO
K_p	4.15	17.06	17.59
K_i	2.21	14.40	15.10
K_d	0.64	4.88	4.85

Para validar la robustez del controlador sintonizado, se evalúa la respuesta de frecuencia frente a eventos representativos de la operación real del sistema. En la Figura 7.5 se comparan los tres métodos de ajuste

bajo dos escenarios de perturbación identificados dentro del período de estudio. Como se observa en la Figura 7.5a, ante un evento de baja frecuencia, los ajustes obtenidos por PSO y GWO logran reducir significativamente la profundidad del nadir y estabilizan el sistema en un tiempo menor que el ajuste obtenido mediante *PID Tuner*. Este último presenta una respuesta más oscilatoria y una caída de frecuencia más pronunciada, lo cual es indeseable incluso ante perturbaciones moderadas en sistemas de muy baja inercia. De manera similar, en el escenario de alta frecuencia (Figura 7.5b), los métodos metaheurísticos reducen el sobreimpulso (*overshoot*) y el tiempo de establecimiento. Esta simetría en el desempeño confirma que la optimización mediante algoritmos metaheurísticos proporciona una regulación de frecuencia más efectiva. Además, resulta necesaria para gestionar la variabilidad intrínseca de la microrred antes de integrar la capa de compensación proactiva.




Figura 7.5. Comparación de la respuesta de frecuencia ante eventos transitorios: (a) Escenario de baja frecuencia (nadir). y (b) Escenario de alta frecuencia (cenit).

Para cuantificar el impacto de cada método de ajuste en el desempeño global del sistema, se analizan diversas métricas de error y algunos indicadores estadísticos de la frecuencia. En la Tabla 7.4 se presenta el desempeño comparativo del controlador PID bajo los tres métodos de ajuste analizados, considerando los valores promedio obtenidos tras evaluar los 288 escenarios (correspondientes a los tres días de estudio) descritos en la Sección 7.3. Para este análisis se han seleccionado las métricas IAE e ISE, junto con la desviación máxima de frecuencia ($\Delta f_{\max}$) y la desviación estándar de la frecuencia (σ_f). Este conjunto de indicadores permite evaluar de manera integral la severidad de las oscilaciones y el error acumulado, así como el comportamiento en el peor caso y la variabilidad del sistema.

Los resultados evidencian que los algoritmos metaheurísticos logran una mayor reducción en todas las métricas de error en comparación con el ajuste convencional basado en *PID Tuner*. El desempeño superior

de PSO y GWO se traduce en una respuesta más robusta, que minimiza tanto el impacto del evento más crítico como la dispersión de los datos en el tiempo. Entre los métodos evaluados, se selecciona el algoritmo PSO como la configuración base para el resto del estudio. Esto se debe a que presenta un equilibrio ligeramente mejor entre la mitigación de las desviaciones de frecuencia y la reducción de la variabilidad de la señal, factores críticos para la operación estable y segura de la microrred.

Tabla 7.4. Desempeño del controlador PID al considerar diferentes métodos de ajuste.

Métricas	Métodos de ajuste utilizados		
	PID Tuner	PSO	GWO
IAE (Hz·s)	$5.410 \cdot 10^{-3}$	$1.162 \cdot 10^{-3}$	$1.221 \cdot 10^{-3}$
ISE (Hz ² ·s)	$1.023 \cdot 10^{-4}$	$1.824 \cdot 10^{-6}$	$1.906 \cdot 10^{-6}$
$\Delta f_{\max}$ (Hz)	1.1520	0.9570	0.9621
σ_f (Hz)	0.0450	0.0276	0.0285

7.6 Análisis de los errores derivados del pronóstico de las RES

Para analizar el impacto de los errores asociados al pronóstico de las RES en el control de frecuencia se evalúan los modelos BiLSTM-BO, SVR-BO y persistencia. En este análisis no se incluye el modelo MLP-BO dado que su rendimiento no presenta diferencias estadísticamente significativas respecto al modelo SVR-BO, lo que permite simplificar el análisis sin pérdida de rigor. En la Tabla 7.5 se resumen las métricas de rendimiento obtenidas en el pronóstico determinístico de potencia PV y eólica con un horizonte de 15 min. Para garantizar una comparación equitativa entre los errores de pronóstico de las diferentes fuentes renovables, las métricas nMAE y nRMSE se han normalizado utilizando el valor máximo de potencia ($y_{i,\max}$) observado en el conjunto de datos de prueba como base de referencia. Este procedimiento permite expresar las desviaciones en términos porcentuales, asegurando que la evaluación del desempeño sea independiente de la capacidad nominal o la escala absoluta de cada sistema.

Tabla 7.5. Métricas de rendimiento obtenidas para cada modelo en el pronóstico determinístico de potencia PV y eólica para un horizonte de 15 min. (Período de evaluación de 72 horas).

Tipo de RES	Métricas	Modelos de pronóstico		
		Persistencia	SVR-BO	BiLSTM-BO
PV	nMAE (%)	2.6228	1.4102	0.6014
	nRMSE (%)	4.3154	2.8221	1.1624
	R ²	0.9786	0.9897	0.9984
Eólica	nMAE (%)	3.8423	2.2418	1.0825
	nRMSE (%)	7.5332	4.1119	1.5471
	R ²	0.9426	0.9806	0.9973

Además, estas métricas son fundamentales para el análisis dinámico posterior, ya que la magnitud y la dispersión de los errores de pronóstico condicionan la precisión de la señal de compensación anticipativa y, por ende, la estabilidad frecuencial del sistema. Los resultados expuestos confirman la superioridad del modelo BiLSTM-BO en la predicción de ambas fuentes de energía, seguido por el modelo SVR-BO y, finalmente, por el modelo de persistencia, cuyo desempeño limitado ya fue discutido en capítulos anteriores.

La Figura 7.6 presenta un análisis detallado del comportamiento de los errores de pronóstico durante el período de tiempo seleccionado para la simulación. Es importante destacar que estos errores se calculan mediante la definición clásica de error residual, es decir, como la diferencia entre el valor real y el valor pronosticado ($e = y_i - \hat{y}_i$). Además, estos errores se han normalizado en por unidad (pu) tomando como base de referencia el valor máximo de potencia ($y_{i,max}$) de cada conjunto de datos.




Figura 7.6. Análisis comparativo del error de pronóstico para un horizonte de 15 min: (a) Serie temporal del error PV; (b) Error residual vs. potencia PV real; (c) Serie temporal del error eólico; (d) Error residual vs. potencia eólica real.

En las Figuras 7.6a y 7.6c se ilustra la evolución temporal de los errores, donde se evidencia la robustez del modelo BiLSTM-BO al mantener una desviación mínima y estable frente a la alta variabilidad de las fuentes. Por el contrario, el modelo de persistencia exhibe picos de error considerables, superando en varios instantes el valor de 0.1 pu, lo que representa un desafío crítico para la regulación de frecuencia.

Por otro lado, las Figuras 7.6b y 7.6d muestran el análisis de los errores residuales en función de la potencia real generada. En estos gráficos de dispersión se observa que, mientras los errores de la persistencia y del modelo SVR-BO tienden a aumentar su dispersión conforme se incrementa la disponibilidad del recurso (especialmente visible en el caso eólico), el modelo BiLSTM-BO mantiene una nube de puntos altamente concentrada en torno al eje de error cero. Esta consistencia operativa demuestra que la precisión del modelo propuesto es independiente del punto de operación de la microrred, lo que favorece que la señal de compensación anticipativa sea fiable tanto en condiciones de baja como de alta generación.

Para profundizar en la fiabilidad del pronóstico, se analiza la distribución del error mediante la evolución temporal del nMAE. Los valores obtenidos se clasifican en cuatro rangos de magnitud: [0-1] %, [1-2] %, [2-3] % y superiores al 3 %, como se muestra en la Figura 7.7. Esta clasificación facilita la cuantificación de la precisión del modelo frente a la variabilidad de las RES durante el período de tiempo analizado.




Figura 7.7. Distribución del nMAE para los modelos evaluados en los conjuntos de datos: (a) Energía solar PV y (b) Energía eólica.

En el análisis de la Figura 7.7a (para la fuente solar PV), se observa que el modelo BiLSTM-BO concentra más del 90 % de sus errores en el rango inferior al 1 % y elimina las desviaciones superiores al 3 %. El modelo SVR-BO muestra un desempeño intermedio, aunque todavía presenta una cierta proporción de errores en rangos elevados. Por su parte, el modelo de persistencia presenta una mayor incidencia en

rangos elevados, lo que sugiere una capacidad más limitada para seguir la variabilidad de la energía solar PV. Un comportamiento similar se observa en la Figura 7.7b para la energía eólica. En este escenario, la capacidad de la red BiLSTM-BO para capturar dependencias temporales complejas resulta determinante para mantener los errores bajo control. En este caso, el modelo propuesto concentra más del 80 % de los valores del nMAE en el rango de [0-1] %, mientras que la persistencia muestra que más de un 18 % de estos valores superan el límite del 3 %.

Este análisis estadístico permite inferir que una menor incertidumbre en el pronóstico favorece un comportamiento más estable del sistema. La ausencia de errores de gran magnitud en el modelo propuesto resulta esencial para que la compensación anticipativa sea fiel al desbalance real, lo que ayuda a minimizar las desviaciones de frecuencia y permite evitar situaciones críticas de operación ante contingencias severas.

7.7 Impacto de los pronósticos realizados en el control de frecuencia

En esta sección se evalúa el impacto de los pronósticos de energía solar PV y eólica en el control de frecuencia de la microrred mediante una estrategia de compensación anticipativa. Para efectuar este análisis, se utilizan como entradas al modelo los perfiles reales de carga y generación descritos en la Sección 7.3. Además, se incorporan las predicciones de los modelos BiLSTM-BO, SVR-BO y persistencia para generar la señal de compensación anticipativa en cada escenario, considerando también un caso convencional sin dicha señal para fines comparativos. Las simulaciones se ejecutan en MATLAB/Simulink manteniendo constantes los parámetros del modelo de pequeña señal y los ajustes del controlador PID obtenidos mediante PSO. Bajo esta configuración, se garantiza que las diferencias observadas en la respuesta de frecuencia se deban exclusivamente a la precisión de los pronósticos empleados y a su capacidad para mitigar los desequilibrios de potencia de forma anticipada.

En la Figura 7.8 se comparan los resultados obtenidos en cada una de las simulaciones realizadas durante el período de estudio. Para facilitar la visualización de los 288 intervalos analizados, se ha representado la evolución temporal de la frecuencia en cada evento, junto con los límites permisibles de operación (± 0.3 Hz). También se incluyen ampliaciones detalladas de los escenarios más críticos identificados (nadir y cenit de frecuencia) para analizar con mayor profundidad el desempeño de cada escenario. Al analizar los resultados, se observa un fenómeno crítico: el modelo de persistencia arroja, en múltiples instantes, un desempeño incluso inferior al control convencional. Esto se debe a que el modelo de persistencia genera en algunos casos una señal de compensación errónea, inyectando potencia en el sentido equivocado cuando el sistema ya ha iniciado su recuperación natural. De esta forma, empeora el desempeño de la frecuencia y desestabiliza el lazo de control en lugar de favorecer el amortiguamiento del sistema. Por el contrario, la integración de modelos de IA contribuye a revertir esta tendencia. En este contexto, el modelo SVR-BO logra una mejora apreciable respecto al control convencional, mientras que el modelo BiLSTM-BO exhibe el comportamiento dinámico más estable entre los casos analizados. Debido a su alta precisión, esta última estrategia logra sincronizar de forma efectiva la compensación anticipativa con el desbalance real, manteniendo las excursiones de frecuencia dentro del umbral de seguridad durante prácticamente todo el horizonte evaluado.




Figura 7.8. Evolución de la frecuencia de la microrred considerando un escenario base con control convencional y estrategias de control anticipativo basadas en las predicciones de los modelos BiLSTM-BO, SVR-BO y persistencia.

Para complementar la información anterior, en la Tabla 7.6 se presenta un análisis estadístico de la frecuencia de la microrred a partir de diferentes indicadores. Se observa que mientras que el control convencional y la persistencia permiten excursiones que superan los límites de seguridad, los modelos basados en IA logran estrechar el margen de operación. Específicamente, el modelo BiLSTM-BO mantiene los valores máximos y mínimos (60.34 Hz y 59.63 Hz) muy cerca de la banda de tolerancia de ± 0.3 Hz, con una desviación estándar bastante reducida (0.0092 Hz). Por su parte, el modelo SVR-BO logra situarse en un punto intermedio, mejorando la respuesta del escenario base, pero sin alcanzar la robustez de la

arquitectura BiLSTM. Estos indicadores numéricos ratifican la necesidad de una predicción precisa para minimizar el impacto de la variabilidad renovable en la microrred.

Tabla 7.6. Análisis estadístico de la frecuencia de la microrred al considerar diferentes escenarios de control.

Parámetros	Escenarios de control evaluados			
	Escenario base (sin compensación)	Persistencia	SVR-BO	BiLSTM-BO
Valor mínimo (Hz)	59.0430	59.1577	59.4792	59.6783
Valor máximo (Hz)	60.8599	60.7917	60.4919	60.3421
Desviación estándar (Hz)	0.0276	0.0218	0.0131	0.0092

El análisis anterior aborda de manera general y simplificada el comportamiento de la frecuencia en la microrred. Sin embargo, resulta necesario efectuar un análisis más detallado que proporcione una visión más profunda de las cuestiones bajo estudio. Para este propósito, se propone la utilización de histogramas de frecuencia. Esta herramienta permite desglosar los rangos de operación y cuantificar la distribución de las observaciones respecto a los márgenes de seguridad. En la Figura 7.9 se presentan los resultados obtenidos para las cuatro estrategias de control evaluadas, considerando los puntos críticos (nadir y cenit) de los 288 escenarios de operación.

Los histogramas confirman la existencia de una relación directa entre la precisión del pronóstico y las desviaciones de frecuencia que tienen lugar en la microrred. Al disponer de una información predictiva precisa, el controlador secundario logra realizar ajustes preventivos que mantienen la frecuencia en torno a los 60 Hz, minimizando el esfuerzo de la acción de control. Como punto de comparación, el escenario de control convencional evidencia las limitaciones de un esquema puramente reactivo, donde el 81.92 % de las observaciones se mantienen dentro de la norma. Para el modelo de persistencia, el cumplimiento se sitúa en un 85.83 %. Este resultado, aunque resulta superior al caso convencional, refleja también la dispersión de sus errores (base ancha del histograma). Esto reafirma que un pronóstico con rezago temporal dificulta la compensación efectiva ante las rampas de potencia propias de las RES.

También se observa que la integración de modelos de IA permite mejorar la operación del sistema. En este caso, el modelo SVR-BO eleva el cumplimiento al 93.45 %, mientras que la compensación basada en el modelo BiLSTM-BO logra que el 98.62 % de las observaciones permanezcan dentro del rango de seguridad. Es importante destacar que las predicciones del modelo BiLSTM-BO contribuyen a mejorar significativamente la estabilidad del sistema. No obstante, aún existe un 1.38 % de valores fuera de los límites de seguridad, lo que evidencia la imposibilidad técnica de mitigar completamente la variabilidad renovable en sistemas de muy baja inercia ($H = 0.1$ s). Por lo tanto, aunque el pronóstico preciso de la IA constituye un pilar fundamental para la estabilidad de la microrred, los esquemas UFLS permanecen como el último recurso de seguridad ante eventos de gran magnitud.




Figura 7.9. Histogramas de las desviaciones de frecuencia en la microrred para los diferentes escenarios evaluados.

Para concluir esta sección, en la Figura 7.10 se presenta mediante un gráfico de dispersión la relación entre los errores residuales de predicción y las desviaciones de frecuencia resultantes. Se observa que, en el modelo de persistencia, a medida que el error de predicción aumenta en magnitud (ya sea por subestimación o sobreestimación de la generación neta), las desviaciones de frecuencia se alejan proporcionalmente de la región de seguridad. Un comportamiento similar se observa para el modelo SVR-BO, aunque con una dispersión más reducida. En el caso del modelo BiLSTM-BO, la alta densidad de puntos en torno al origen evidencia su capacidad para confinar el impacto de las perturbaciones y mantener la frecuencia en límites seguros. Este comportamiento indica que la alta precisión del pronóstico ayuda al esquema de control secundario a neutralizar las perturbaciones de las RES antes de que se traduzcan en inestabilidad de frecuencia. Por lo tanto, se puede decir que la reducción de la incertidumbre en el pronóstico de las RES constituye un factor de gran importancia para mejorar la regulación de frecuencia en sistemas de baja inercia.




Figura 7.10. Análisis de dispersión entre los errores de pronóstico de las RES y las desviaciones de frecuencia de la microrred.

7.8 Evaluación de la robustez del sistema ante contingencias severas

Desde el punto de vista operativo, es fundamental mantener la frecuencia de la microrred dentro del rango permisible. No obstante, ante escenarios de alta incertidumbre en la producción de las RES y grandes desbalances de potencia neta, las desviaciones de frecuencia pueden exceder los límites operativos. En estos casos, resulta necesaria la aplicación de esquemas de acción remedial (RAS), como por ejemplo el deslastre de carga por baja frecuencia (UFLS), para evitar el colapso del sistema.

Para llevar a cabo este análisis se ha seleccionado la contingencia más severa identificada en el período analizado (escenario 138, Figura 7.8). En este evento, se produce un desbalance de potencia neta debido a la coincidencia de una reducción de la generación PV con un escenario de baja producción eólica y un perfil de carga relativamente constante. Además, para cuantificar el beneficio del control proactivo, se define un esquema UFLS de referencia basado en los criterios del *East Central Area Reliability coordination agreement* (ECAR), recogidos en la norma IEEE Std C37.117 [177]. De este modo, se puede evaluar la cantidad de carga que se debería desconectar bajo condiciones reales de operación debido a la baja inercia del sistema. En la Tabla 7.7 se detallan las tres etapas de desconexión preventiva definidas para este propósito. Es importante destacar que dicho esquema UFLS se utiliza solamente como un marco de referencia para evaluar la severidad de los transitorios y la efectividad de la respuesta de control. El presente estudio no pretende modelar la dinámica de recuperación post-deslastre ni los tiempos de operación de los relés físicos. Fundamentalmente, se busca demostrar la capacidad de la estrategia propuesta para mitigar el nadir de frecuencia y evitar la necesidad de recurrir a dichas acciones remediales.

Tabla 7.7. Umbrales de desconexión de carga definidos para el análisis de robustez.

Etapa de desconexión	Umbral de frecuencia (Hz)	Carga comprometida (%)
1ª etapa	59.5	5
2ª etapa	59.3	5
3ª etapa	59.1	5

La Figura 7.11 ilustra cómo influye la precisión del pronóstico en la cantidad de carga preservada ante una contingencia severa en el sistema. Se observa que el control convencional, al ser puramente reactivo, permite que la frecuencia caiga profundamente en las zonas de disparo definidas en la Tabla 7.7. Por el contrario, el enfoque de control proactivo basado en el modelo BiLSTM-BO evita que el transitorio alcance niveles críticos, logrando estabilizar la frecuencia en 59.6783 Hz. Este comportamiento sitúa la operación dentro del margen de seguridad operativa y garantiza la integridad del sistema sin necesidad de activar las etapas de desastre.




Figura 7.11. Trayectorias de frecuencia frente a los umbrales de desconexión definidos en el estándar IEEE C37.117 (ECAR).

Para complementar este análisis, en la Tabla 7.8 se resume la cantidad de carga desconectada en función del enfoque de control aplicado. Se observa que, para el enfoque convencional, sería necesario desconectar el 15 % de la carga total, mientras que para el enfoque proactivo basado en el pronóstico de persistencia este indicador se reduce a 10 %. Para los enfoques basados en IA los resultados son aún más favorables. Al utilizar las predicciones del modelo SVR-BO, se debería desconectar únicamente un 5 % de la carga, mientras que con el modelo BiLSTM-BO no sería necesaria la interrupción del suministro. Estos resultados evidencian que una mejora en la precisión del pronóstico no representa únicamente un avance estadístico, sino que constituye una contribución directa a la seguridad de la red y a la calidad del suministro eléctrico.

Tabla 7.8. Análisis comparativo de los enfoques de control y su impacto en el suministro eléctrico.

Enfoque de control	Nadir de frecuencia (Hz)	Carga desconectada (%)
Convencional	59.0430	15
Proactivo (Persistencia)	59.1577	10
Proactivo (SVR-BO)	59.4782	5
Proactivo (BiLSTM-BO)	59.6783	0

7.9 Conclusiones del capítulo

En este capítulo se ha analizado el control de frecuencia en una microrred aislada con múltiples DER, considerando la variabilidad presente en la generación y la carga. Esta tarea resulta desafiante debido a la naturaleza estocástica y altamente variable de los elementos mencionados. Como una vía de solución eficaz para enfrentar estos problemas, se han aplicado diferentes modelos de pronóstico para determinar con antelación la producción energética de las RES. Sin embargo, aunque estos pronósticos pueden alcanzar un grado de exactitud elevado, es inevitable la ocurrencia de errores en el proceso predictivo asociados a múltiples causas.

Una contribución relevante de la metodología implementada es la integración directa de la etapa de predicción en el lazo de control secundario. De esta manera, ha sido posible evaluar el impacto de la precisión del pronóstico en la estabilidad de frecuencia del sistema. Los resultados obtenidos han demostrado que existe una relación directa entre la calidad de las predicciones y la reducción de las desviaciones de frecuencia. Se ha demostrado que la metodología proactiva basada en el modelo BiLSTM-BO permite mantener la frecuencia dentro del rango permisible en la mayoría de los escenarios críticos, limitando las excursiones fuera de norma a solo un 1.38 % de los casos. Por el contrario, un pronóstico deficiente, como el basado en el modelo de persistencia, genera respuestas desfavorables que pueden conducir incluso a la activación de los esquemas UFLS para garantizar la estabilidad del sistema. Por otra parte, se evidencia que, si bien la IA optimiza la respuesta dinámica, la presencia de esquemas de protección tradicionales sigue siendo indispensable como una medida de seguridad en sistemas de baja inercia.

Otro de los aspectos abordados ha sido el ajuste del controlador PID encargado de regular la operación de las fuentes controladas en la microrred. En este caso, se demuestra que la aplicación de algoritmos de optimización metaheurísticos conduce a una sintonía robusta de los controladores. En general, los estudios desarrollados en este capítulo demuestran que la aplicación de pronósticos avanzados de energía solar PV y eólica mejora significativamente la operación de la microrred. Además, la aplicabilidad de la metodología propuesta no se limita únicamente a este tipo de sistema, sino que puede extenderse a redes eléctricas de mayor tamaño y con diversas características.

CAPÍTULO 8. CONCLUSIONES, CONTRIBUCIONES Y RECOMENDACIONES

8.1 Conclusiones

En esta tesis se han abordado de una manera integral y profunda los aspectos relacionados con el pronóstico de energía solar PV y eólica, así como su impacto directo en el control de frecuencia en microrredes aisladas. A continuación, se describen los principales resultados y aportes obtenidos en el marco de la investigación.

El análisis de la dinámica física de las fuentes solar PV y eólica ha permitido identificar su carácter estocástico y las elevadas tasas de rampa como desafíos críticos para la estabilidad de redes modernas. Se ha evidenciado que la variabilidad de estos recursos, sujeta a factores meteorológicos y geográficos complejos, limita la fiabilidad de los modelos de pronóstico convencionales en escenarios operativos diversos. En este contexto, se ha validado que la identificación precisa de factores determinantes constituye la base física esencial para el diseño de modelos predictivos de alto desempeño. Estos hallazgos han justificado la adopción de arquitecturas de aprendizaje profundo capaces de modelar dependencias no lineales complejas, estableciendo un marco teórico que supera las limitaciones de los métodos convencionales y promueve una gestión energética más resiliente.

A partir de este fundamento teórico, se ha validado el desarrollo de una metodología de pronóstico avanzada que aporta una mejora medible en el desempeño respecto a los enfoques tradicionales de la literatura. Este marco integral ha implementado un algoritmo de preprocesamiento robusto que mejora la consistencia de los datos mediante la corrección de anomalías físicas y una selección inteligente de características, optimizando la convergencia y reduciendo la complejidad estructural de los modelos. La arquitectura resultante, basada en una red BiLSTM tuneada mediante un algoritmo de optimización Bayesiana, ha alcanzado mejoras en la precisión (nMAE) de hasta el 72 % en el pronóstico solar y el 70 % en el eólico respecto al modelo de persistencia. Asimismo, se han obtenido reducciones del error de aproximadamente 53 % (solar) y 50 % (eólica) en comparación con arquitecturas MLP y SVR optimizadas, logrando en todos los escenarios coeficientes de determinación (R^2) superiores a 0.998.

Complementando lo anterior, la incorporación de pronósticos probabilísticos mediante remuestreo *bootstrap* ha garantizado una cuantificación adecuada de la incertidumbre. Los resultados experimentales han demostrado que los valores de PICP se sitúan muy cercanos a cada nivel de PINC definido (80 %, 90 % y 95 %), obteniéndose errores de cobertura promedio (ACE) inferiores al 0.9 % en todos los casos evaluados. Además, se han alcanzado valores de PINAW reducidos (en el orden del 6 %), lo que garantiza intervalos de predicción nítidos y bien calibrados que proporcionan información precisa para la toma de decisiones sin sobreestimar la incertidumbre. Estos hallazgos han posicionado la propuesta en un nivel de desempeño competitivo frente a arquitecturas recientes y avanzadas del estado del arte, manteniendo una alta eficiencia operativa con tiempos de inferencia en torno a 0.02 s.

En esta misma línea, la integración de técnicas de explicabilidad (XAI-RFE) ha permitido identificar variables críticas y ha facilitado el diseño de un sistema resiliente ante la degradación de la información.

Bajo condiciones operativas atípicas severas, como la pérdida total de sensores durante 4 horas, el modelo propuesto ha limitado el incremento del error nMAE a solo un 1.88 % en el pronóstico solar y un 2.83 % en el eólico. De igual forma, ante la presencia de ruido blanco (18 dB) en las variables, la propuesta ha mantenido una buena estabilidad operativa al restringir el aumento del error a valores de 0.70 % para la fuente solar PV y 1.31 % para la eólica. Los resultados obtenidos han confirmado la alta fiabilidad de la metodología desarrollada y su capacidad para garantizar la continuidad de los pronósticos en entornos de operación real.

Tras verificar la calidad del pronóstico, también se ha validado la efectividad de una arquitectura de control proactivo (*feed-forward*) que ha integrado dinámicamente las predicciones de energía solar PV y eólica para la regulación de frecuencia en microrredes de baja inercia ($H = 0.1$ s en este caso de estudio). Los resultados han confirmado que la calidad del pronóstico ha sido un factor determinante en la estabilidad del sistema: mientras el control basado en el modelo de persistencia ha generado en varios instantes señales de compensación erróneas que han degradado el control de la frecuencia, la estrategia basada en BiLSTM-BO ha logrado que el 98.62 % de las desviaciones de frecuencia se mantengan dentro de los límites de seguridad (± 0.3 Hz), superando ampliamente el 81.92 % del control convencional. Además, se ha demostrado una mejora notable en la estabilidad operativa al reducir la desviación estándar de la frecuencia de 0.0276 Hz en el caso puramente reactivo a solo 0.0092 Hz mediante el enfoque propuesto, lo que ha representado una mitigación de la variabilidad frecuencial del sistema superior al 66 %.

De manera general, se ha demostrado que una mayor precisión en el pronóstico se traduce de forma medible en una operación más segura y flexible de la infraestructura de red. Una contribución operativa de gran relevancia ha radicado en la respuesta ante contingencias severas, donde el esquema proactivo propuesto ha logrado confinar el cenit de frecuencia en 60.34 Hz y estabilizar el nadir en 59.67 Hz (frente a los 60.85 Hz y 59.04 Hz del escenario base), evitando por completo la activación de esquemas de deslastre de carga (UFLS basados en el estándar IEEE C37.117). Ante el evento más crítico de pérdida de generación analizado, la aplicación del enfoque propuesto ha permitido preservar el 15 % de la carga total del sistema que el control reactivo convencional habría desconectado forzosamente para evitar el colapso. En conjunto, la evidencia experimental ha confirmado que el marco metodológico desarrollado no solo incrementa el desempeño predictivo, sino que garantiza la integridad del suministro eléctrico en escenarios de elevada incertidumbre y alta penetración de energías renovables.

8.2 Contribuciones

Las contribuciones derivadas de esta tesis son las siguientes:

- Propuesta de un algoritmo robusto de preprocesamiento de datos, capaz de mejorar la calidad y la consistencia de los datos originales, contribuyendo de esta forma a mejorar el rendimiento del modelo de pronóstico y la calidad de sus predicciones.
- Implementación de un enfoque de pronóstico avanzado basado en una red neuronal BiLSTM, ajustada mediante un algoritmo de optimización Bayesiana, complementado con el método de remuestreo *bootstrap* para generar pronósticos probabilísticos.

- Desarrollo de una metodología de pronóstico flexible, robusta y escalable, capaz de operar eficientemente en condiciones atípicas (pérdida de información y ruido blanco) y adaptable a diferentes conjuntos de datos y escenarios operativos.
- Aplicación de técnicas de explicabilidad (XAI-RFE) para determinar la relevancia de las variables de entrada, lo que favorece el desarrollo de modelos de pronóstico más eficientes, interpretables y ajustados a los requerimientos del sistema.
- Integración de los pronósticos obtenidos en un esquema de control proactivo de frecuencia de una microrred, junto con la optimización del controlador PID mediante algoritmos metaheurísticos, estableciendo así un vínculo directo entre la calidad de las predicciones y la estabilidad dinámica del sistema.
- Evaluación de la robustez operativa del sistema ante contingencias severas, utilizando estándares internacionales de deslastre de carga (UFLS) como marco de referencia para demostrar la capacidad del control proactivo de evitar la desconexión de usuarios y garantizar la estabilidad bajo escenarios de alta incertidumbre.

8.3 Recomendaciones y trabajos futuros

A partir del trabajo realizado en esta tesis, se plantean las recomendaciones siguientes:

- Para aplicaciones de pronóstico que impliquen grandes volúmenes de datos o modelos de aprendizaje profundo de alta complejidad, se recomienda el uso de equipos con alta capacidad de procesamiento o el empleo de plataformas con aceleración por GPU. Esto permite reducir los tiempos de entrenamiento, lo cual es muy importante en aplicaciones de predicción en tiempo real o en contextos donde se requieren actualizaciones frecuentes del modelo.
- En la tesis se han considerado aplicaciones de pronóstico para horizontes temporales de muy corto plazo, específicamente 15 min. No obstante, sería conveniente extender este análisis hacia otros horizontes de pronóstico, por ejemplo, 1 hora, varias horas o un día de antelación. De esta forma se pueden cubrir otras necesidades operativas del sistema eléctrico, como por ejemplo la gestión de las reservas y la programación de la generación.
- Los modelos de predicción utilizados en esta tesis se basan únicamente en datos históricos. Sin embargo, siempre que se disponga de predicciones meteorológicas provenientes de servicios meteorológicos especializados, es recomendable considerar esta información para mejorar aún más la capacidad del modelo para anticipar variaciones abruptas en los datos.

Como líneas de investigación futura se propone lo siguiente:

- Explorar enfoques basados en transferencia de aprendizaje, de manera que los modelos entrenados para ubicaciones con amplia disponibilidad de datos puedan adaptarse adecuadamente a otros sitios donde la información resulte limitada.
- Analizar microrredes con topologías más complejas (por ejemplo, topologías en lazo o sistemas altamente interconectados), con el fin de estudiar escenarios de operación donde exista una mayor interacción entre los elementos del sistema.

REFERENCIAS

- [1] “IEA, “World Energy Outlook 2022,” International Energy Agency, 2022.
- [2] A. R. Singh, R. S. Kumar, M. Bajaj, C. B. Khadse, and I. Zaitsev, “Machine learning-based energy management and power forecasting in grid-connected microgrids with multiple distributed energy sources,” *Scientific Reports*, vol. 14, 2024, doi: 10.1038/s41598-024-70336-3.
- [3] “IRENA 2025, “Renewable Capacity Statistics 2025, International Renewable Energy Agency, Abu Dhabi,” 2025.
- [4] B. Loza, L. I. Minchala, D. Ochoa-Correa, and S. Martinez, “Grid-Friendly Integration of Wind Energy: A Review of Power Forecasting and Frequency Control Techniques,” *Sustainability*, vol. 16, 2024, doi: 10.3390/su16219535.
- [5] “IRENA (2024), World Energy Transitions Outlook 2024: 1.5°C Pathway, International Renewable Energy Agency, Abu Dhabi,” 2024.
- [6] I. B. Benitez and J. G. Singh, “A comprehensive review of machine learning applications in forecasting solar PV and wind turbine power output,” *Journal of Electrical Systems and Information Technology*, vol. 12, no. 54, 2025, doi: 10.1186/s43067-025-00239-4.
- [7] M. Lafuente-Cacho et.al., “State of the Art for Solar and Wind Energy-Forecasting Methods for Sustainable Grid Integration,” *Current Sustainable/Renewable Energy Reports*, vol. 12, no. 13, 2025, doi: 10.1007/s40518-025-00262-z.
- [8] O. Gandhi et. al., “The value of solar forecasts and the cost of their errors: A review,” *Renewable and Sustainable Energy Reviews*, vol. 189, 2024, doi: 10.1016/j.rser.2023.113915.
- [9] M. Dreidy, H. Mokhlis, and S. Mekhilef, “Inertia response and frequency control techniques for renewable energy sources: A review,” *Renewable and Sustainable Energy Reviews*, vol. 69, pp. 144–155, 2017, doi: 10.1016/j.rser.2016.11.170.
- [10] O. Gandhi, D. S. Kumar, C. D. Rodríguez-Gallegos, and D. Srinivasan, “Review of power system impacts at high PV penetration Part I: Factors limiting PV penetration,” *Solar Energy*, vol. 210, pp. 181–201, 2020, doi: 10.1016/j.solener.2020.06.097.
- [11] R. Teixeira, A. Cerveira, E. J. S. Pires, and J. Baptista, “Advancing Renewable Energy Forecasting: A Comprehensive Review of Renewable Energy Forecasting Methods,” *Energies*, vol. 17, 2024, doi: 10.3390/en17143480.
- [12] L. Visser, T. AlSkaif, J. Hu, A. Louwen, and W. van Sark, “On the value of expert knowledge in estimation and forecasting of solar photovoltaic power generation,” *Solar Energy*, vol. 251, pp. 86–105, 2023, doi: 10.1016/j.solener.2023.01.019.

-
- [13] S. S. Subbiah, et al., “Deep Learning for Wind Speed Forecasting Using Bi-LSTM with Selected Features,” *Intell. Autom. Soft Comput.*, vol. 35, pp. 3829–3844, 2023, doi: 10.32604/iasc.2023.030480.
 - [14] W.-C. Tsai, C.-M. Hong, C.-S. Tu, W.-M. Lin, and C.-H. Chen, “A Review of Modern Wind Power Generation Forecasting Technologies,” *Sustainability*, vol. 15, p. 10757, 2023, doi: 10.3390/su15141075.
 - [15] R. Herrera-Casanova, A. Conde, and C. Santos-Perez, “Hour-Ahead Photovoltaic Power Prediction Combining BiLSTM and Bayesian Optimization Algorithm, with Bootstrap Resampling for Interval Predictions,” *Sensors*, vol. 24, no. 882, 2024, doi: 10.3390/s24030882.
 - [16] K. R. S. Preethaa, A. Muthuramalingam, Y. Natarajan, G. Wadhwa, A. A. Y. Ali, “A Comprehensive Review on Machine Learning Techniques for Forecasting Wind Flow Pattern,” *Sustainability*, vol. 15, 2023, doi: 10.3390/su151712914.
 - [17] Z. Niu, Z. Yu, W. Tang, Q. Wu, M. Reformat, “Wind power forecasting using attention-based gated recurrent unit network,” *Energy*, vol. 196, 2020, doi: 10.1016/j.energy.2020.117081.
 - [18] R. Herrera Casanova and A. Conde, “Enhancement of LSTM models based on data pre-processing and optimization of Bayesian hyperparameters for day-ahead photovoltaic generation prediction,” *Computers and Electrical Engineering*, vol. 116, p. 109162, 2024, doi: 10.1016/j.compeleceng.2024.109162.
 - [19] B. Jiang, et al., “A Holistic Feature Selection Method for Enhanced Short-Term Load Forecasting of Power System,” *IEEE Transactions on Instrumentation and Measurement*, vol. 72, 2023, doi: 10.1109/TIM.2022.3219499.
 - [20] Y. Wang, et al., “Prediction method of wind farm power generation capacity based on feature clustering and correlation analysis,” *Electr. Power Syst. Res.*, vol. 212, 2022, doi: 10.1016/j.epsr.2022.108634.
 - [21] R. Machlev, L. Heistrene, M. Perl, K.Y. Levy, J. Belikov, S. Mannor, and Y. Levron, “Explainable Artificial Intelligence (XAI) techniques for energy and power systems: Review, challenges and opportunities,” *Energy and AI*, vol. 9, p. 100169, 2022, doi: 10.1016/j.egyai.2022.100169.
 - [22] A. Alcañiz, D. Grzebyk, H. Ziar, and O. Isabella, “Trends and gaps in photovoltaic power forecasting with machine learning,” *Energy Reports*, vol. 9, pp. 447–471, 2023, doi: 10.1016/j.egy.2022.11.208.
 - [23] Y. Xie, C. Li, M. Li, F. Liu, and M. Taukenova, “An overview of deterministic and probabilistic forecasting methods of wind energy,” *iScience*, vol. 26, 2023, doi: 10.1016/j.isci.2022.105804.
 - [24] J. Che, F. Yuan, D. Deng, Z. Jiang, “Ultra-short-term probabilistic wind power forecasting with spatial-temporal multi-scale features and K-FSDW based weight,” *Applied Energy*, vol. 331, 2023, doi: 10.1016/j.apenergy.2022.120479.

- [25] H. Wang, et al., “A comprehensive review for wind, solar, and electrical load forecasting methods,” *Global Energy Interconnection*, vol. 5, no. 1, pp. 9–30, 2022, doi: 10.1016/j.gloi.2022.04.002.
- [26] T.R. Vedhavathy, et al., “Spatial-temporal learning using GCN-BiLSTM for accurate renewable energy power prediction,” *Electric Power Systems Research*, vol. 251, 2026, doi: 10.1016/j.epr.2025.112251.
- [27] R. Ahmed, V. Sreeram, Y. Mishra, and M. D. Arif, “A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization,” *Renewable and Sustainable Energy Reviews*, vol. 124, p. 109792, 2020, doi: 10.1016/j.solener.2020.08.047.
- [28] U. K. Das, et al., “Forecasting of photovoltaic power generation and model optimization: A review,” *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 912–918, 2018, doi: 10.1016/j.rser.2017.08.017.
- [29] F. H. Gandoman, S. A. Abdel, N. Omar N, A. Ahmadi, and F. Q. Alenezi, “Short-term solar power forecasting considering cloud coverage and ambient temperature variation effects,” *Renewable Energy*, vol. 123, pp. 793–805, doi: 10.1016/j.renene.2018.02.102.
- [30] B. D. Dimd, S. Völler, U. Cali, and O.-M. Midtgård, “A Review of Machine Learning-Based Photovoltaic Output Power Forecasting: Nordic Context,” *IEEE Access*, vol. 10, pp. 26404–26425, 2022, doi: 10.1109/ACCESS.2022.3156942.
- [31] M. Tanrioven, *Photovoltaic Systems Engineering for Students and Professionals: Solved Examples and Applications*, 1st ed. Boca Raton, FL, USA: CRC Press Taylor & Francis Group, 2024.
- [32] F. Kaya, G. Sahin, and M. H. Alma, “Investigation effects of environmental and operating factors on PV panel efficiency using by multivariate linear regression,” *International Journal of Energy Research*, pp. 1–14, 2020, doi: 10.1002/er.5717.
- [33] X.-J. Dong, J.-N. Shen, G.-X. He, Z.-F. Ma, and Y.-J. He, “A general radial basis function neural network assisted hybrid modeling method for photovoltaic cell operating temperature prediction,” *Energy*, vol. 234, p. 121212, 2021, doi: 10.1016/j.energy.2021.121212.
- [34] M. M. Fouada, L. A. Shihata, and E. I. Morgan, “An integrated review of factors influencing the performance of photovoltaic panels,” *Renewable and Sustainable Energy Reviews*, vol. 80, pp. 1499–1511, 2017, doi: 10.1016/j.rser.2017.05.141.
- [35] G. M. J. Herbert, S. Iniyan, E. Sreevalsan, and S. Rajapandian, “A review of wind energy technologies,” *Renewable and Sustainable Energy Reviews*, vol. 11, pp. 1117–1145, 2007, doi: 10.1016/j.rser.2005.08.004.
- [36] “Wind Europe: Wind Energy in Europe–2020 Statistics and the Outlook for 2021–2025.” [Online]. Available: https://s1.eestatic.com/2021/02/24/actualidad/210224_windeurope_combined_2020_stats.pdf

-
- [37] Y. Xing, "Development of a Multi-Hour Ahead Wind Power Forecasting System," A thesis presented to the University of Waterloo in fulfilment of the thesis requirement for the degree of Doctor of Philosophy in Mechanical and Mechatronics Engineering, University of Waterloo, Waterloo, Ontario, Canada, 2022.
- [38] M. H. El-Ahmar, A.-H. M. El-Sayed, and A. M. Hemeida, "Evaluation of Factors affecting Wind Turbine Output Power" In *2017 Nineteenth International Middle East Power Systems Conference (MEPCON)*. IEEE, 2017. p. 1471-1476.
- [39] M. R. Patel, and O. Beik, *Wind and solar power systems: design, analysis, and operation*. CRC Press, 2021.
- [40] T. Burton, N. Jenkins, D. Sharpe, and E. Bossanyi, *Wind Energy Handbook*, 2nd ed. Wiley, 2011.
- [41] I. Van der Hoven, "Power spectrum of horizontal wind speed in the frequency range from 0.0007 to 900 cycles per hour," *Journal of Meteorology*, vol. 14, no. 2, pp. 160–164, 1957, doi: 10.1175/1520-0469(1957)014<0160:PSOHWS>2.0.CO;2.
- [42] M. N. Akhter, S. Mekhilef, H. Mokhlis, and N. M. Shah, "Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques," *IET Renewable Power Generation*, vol. 13, no. 7, pp. 1009–1023, 2019, doi: 10.1049/iet-rpg.2018.5649.
- [43] W. Wang, et al., "New energy regional power prediction algorithm based on statistical upscaling in Ningbo region," *Electric Power*, vol. 53, no. 5, pp. 100–111, 2020.
- [44] J. A.-M., F. J. Batlles, C. Portillo, "Solar irradiance forecasting at one-minute intervals for different sky conditions using sky camera images," *Energy Conversion and Management*, vol. 105, pp. 1166–1177, 2015, doi: 10.1016/j.enconman.2015.09.001.
- [45] A. Mellit, and S. Kalogirou, *Handbook of artificial intelligence techniques in photovoltaic systems*. Academic Press, Elsevier, 2022.
- [46] G. Alkhayat, and R. Mehmood, "A review and taxonomy of wind and solar energy forecasting methods based on deep learning," *Energy and AI*, vol. 4, p. 100060, 2021, doi: 10.1016/j.egyai.2021.100060.
- [47] M. Zhou, B. Wang, S. Guo, J. Watada, "Multi-objective prediction intervals for wind power forecast based on deep neural networks," *Information Sciences*, vol. 550, pp. 207–220, 2020, doi: 10.1016/j.ins.2020.10.034.
- [48] D. W. Van der Meer, J. Widén, and J. Munkhammar, "Review on probabilistic forecasting of photovoltaic power production and electricity consumption," *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 1484–1512, 2018, doi: 10.1016/j.rser.2017.05.212.
- [49] M. Alrashidi and S. Rahman, "Short-term photovoltaic power production forecasting based on novel hybrid data-driven models," *Journal of Big Data*, vol. 10, no. 26, 2023, doi: 10.1186/s40537-023-00706-7.

-
- [50] D. S. Kumar, O. Gandhi, C. D. Rodríguez-Gallegos, D. Srinivasan, “Review of power system impacts at high PV penetration Part II: Potential solutions and the way forward,” *Solar Energy*, vol. 210, pp. 202–221, 2020, doi: 10.1016/j.solener.2020.08.047.
- [51] M. J. Mayer and D. Yang, “Probabilistic photovoltaic power forecasting using a calibrated ensemble of model chains,” *Renewable and Sustainable Energy Reviews*, vol. 168, p. 112821, 2022, doi: 10.1016/j.rser.2022.11282.
- [52] E. C. Asiri, C. Y. Chung, and X. Liang, “Day-Ahead Prediction of Distributed Regional-Scale Photovoltaic Power,” *IEEE Access*, vol. 11, pp. 27303–27316, 2023, doi: 10.1109/ACCESS.2023.3258449.
- [53] J. Zhang, R. Verschae, S. Nobuhara, and J. F. Lalonde, “Deep photovoltaic nowcasting,” *Solar Energy*, vol. 176, pp. 267–276, 2018, doi: 10.1016/j.solener.2018.10.024.
- [54] S. Atique, et al., “Forecasting of total daily solar energy generation using ARIMA: A case study,” presented at the *2019 IEEE 9th Annual Computing and Communication Workshop and Conference (CCWC)*, Las Vegas, NV, USA, 2019. doi: 10.1109/CCWC.2019.8666481.
- [55] H. Sharadga, S. Hajimirza, and R. S. Balog, “Time series forecasting of solar power generation for large-scale photovoltaic plants,” *Renewable Energy*, vol. 150, pp. 797–807, 2020, doi: 10.1016/j.renene.2019.12.131.
- [56] M. N. Akhter, et al., “An Hour-Ahead PV Power Forecasting Method Based on an RNN-LSTM Model for Three Different PV Plants,” *Energies*, vol. 15, p. 2243, 2022, doi: 10.3390/en15062243.
- [57] P. Li, et al., “A hybrid deep learning model for short-term PV power forecasting,” *Applied Energy*, vol. 259, p. 114216, 2020, doi: 10.1016/j.apenergy.2019.114216.
- [58] V. Suresh, et al., “Probabilistic LSTM-Autoencoder Based Hour-Ahead Solar Power Forecasting Model for Intra-Day Electricity Market Participation: A Polish Case Study,” *IEEE Access*, vol. 10, pp. 110628–110638, 2022, doi: 10.1109/ACCESS.2022.3215080.
- [59] A. Rafati, M. Joorabian, E. Mashhour, and H. R. Shaker, “High dimensional very short-term solar power forecasting based on a data-driven heuristic method,” *Energy*, vol. 219, p. 119647, doi: 10.1016/j.energy.2020.119647.
- [60] K. Wang, X. Qi, and H. Liu, “A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network,” *Applied Energy*, vol. 251, p. 113315, 2019, doi: 10.1016/j.apenergy.2019.113315.
- [61] X. Ren, et al., “Quad-kernel deep convolutional neural network for intra-hour photovoltaic power forecasting,” *Applied Energy*, vol. 323, p. 119682, 2022, doi: 10.1016/j.apenergy.2022.119682.
- [62] J. Wojtkiewicz, et al., “Hour-ahead solar irradiance forecasting using multivariate gated recurrent units,” *Energies*, vol. 12, no. 21, p. 4055, 2019, doi: 10.3390/en12214055.

-
- [63] M. Pan et al., "Photovoltaic power forecasting based on a support vector machine with improved ant colony optimization," *Journal of Cleaner Production*, vol. 227, p. 123948, 2020, doi: 10.1016/j.jclepro.2020.123948.
- [64] M. Massaoudi, et al., "An effective hybrid NARX-LSTM model for point and interval PV power forecasting," *IEEE Access*, vol. 9, pp. 36571–36588, 2021, doi: 10.1109/ACCESS.2021.3062776.
- [65] V. Raj, et al., "Ensemble Machine Learning for Predicting the Power Output from Different Solar Photovoltaic Systems," *Energies*, vol. 16, no. 671, 2023, doi: 10.3390/en16020671.
- [66] S. M. Miraftabzadeh, et al., "A Day-Ahead Photovoltaic Power Prediction via Transfer Learning and Deep Neural Networks," *Forecasting*, vol. 5, no. 1, pp. 213–228, 2023, doi: 10.3390/forecast5010012.
- [67] X. Xiang, X. Li, Y. Zhang, and J. Hu, "A short-term forecasting method for photovoltaic power generation based on the TCN-ECANet-GRU hybrid model," *Scientific Report*, vol. 14, 2024, doi: 10.1038/s41598-024-56751-6.
- [68] V. Suresh, "Benchmarking Transformer Variants for Hour-Ahead PV Forecasting: PatchTST with Adaptive Conformal Inference," *Energies*, vol. 18, 2025, doi: 10.3390/en18185000.
- [69] L. Dong, et al., "Wind power day-ahead prediction with cluster analysis of NWP," *Renewable and Sustainable Energy Reviews*, vol. 60, pp. 1206–1212, 2016, doi: 10.1016/j.rser.2016.01.106.
- [70] B. He, et al., "A combined model for short-term wind power forecasting based on the analysis of numerical weather prediction data," *Energy Reports*, vol. 8, pp. 929–939, 2022, doi: 10.1016/j.egyr.2021.10.102.
- [71] I. Tyass, et al., "Wind speed prediction based on seasonal ARIMA model," presented at the E3S Web of Conferences, EDP Sciences, 2022. doi: 10.1051/e3sconf/202233600034.
- [72] K. R. Nair, V. Vanitha and M. Jisma, "Forecasting of wind speed using ANN, ARIMA and Hybrid models," presented at the 2017 International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICICT), Kerala, India, 2017, pp. 170–175. doi: 10.1109/ICICICT1.2017.8342555.
- [73] A. Alkesaiberi, F. Harrou, and Y. Sun, "Efficient wind power prediction using machine learning methods: A comparative study," *Energies*, vol. 15, no. 7, p. 2327, 2022, doi: 10.3390/en15072327.
- [74] A. Chaudhary, et al., "Short term wind power forecasting using machine learning techniques," *Journal of Statistics and Management Systems*, vol. 23, no. 1, pp. 145–156, 2020, doi: 10.1080/09720510.2020.1721632.
- [75] J. Wang, et al., "A novel prediction model for wind power based on improved long short-term memory neural network," *Energy*, vol. 265, p. 126283, 2023, doi: 10.1016/j.energy.2022.126283.
- [76] F. Shahid, et al., "A novel genetic LSTM model for wind power forecast," *Energy*, vol. 223, p. 120069, 2021, doi: 10.1016/j.energy.2021.120069.

- [77] E. T. Habtemariam, K. Kekeba, M. Martínez-Ballesteros, and F. Martínez-Álvarez, “A Bayesian Optimization-Based LSTM Model for Wind Power Forecasting in the Adama District, Ethiopia,” *Energies*, vol. 16, p. 2317, doi: 10.3390/en16052317.
- [78] M. -S. Ko, K. Lee, J. -K. Kim, C. W. Hong, Z. Y. Dong and K. Hur, “Deep Concatenated Residual Network with Bidirectional LSTM for One-Hour-Ahead Wind Power Forecasting,” *IEEE Transactions on Sustainable Energy*, vol. 12, no. 2, pp. 1321–1335, 2021, doi: 10.1109/TSTE.2020.3043884.
- [79] E. S. Miele, N. Ludwig, and A. Corsini, “Multi-Horizon Wind Power Forecasting Using Multi-Modal Spatio-temporal Neural Networks,” *Energies*, vol. 16, no. 3522, 2023, doi: 10.3390/en16083522.
- [80] B. Qin, X. Huang, X. Wang, L. Guo, “Ultra-short-term wind power prediction based on double decomposition and LSSVM,” *Transactions of the Institute of Measurement and Control*, vol. 45, no. 14, pp. 2627–2636, 2023, doi: 10.1177/01423312231153258.
- [81] Q. Hu, R. Zhang, and Y. Zhou, “Transfer learning for short-term wind speed prediction with deep neural networks,” *Renewable Energy*, vol. 85, pp. 83–95, 2016, doi: 10.1016/j.renene.2015.06.034.
- [82] Y. Y. Hong, and T. R. A. Satriani, “Day-ahead spatiotemporal wind speed forecasting using robust design-based deep learning neural network,” *Energy*, vol. 209, p. 118441, 2020, doi: 10.1016/j.energy.2020.118441.
- [83] S. Farah, et al., “Short-term multi-hour ahead country-wide wind power prediction for Germany using gated recurrent unit deep learning,” *Renewable and Sustainable Energy Reviews*, vol. 167, p. 112700, 2022, doi: 10.1016/j.rser.2022.112700.
- [84] D.-Y. Kim, and B.-S. Kim, “Contribution of meteorological factors based on explainable artificial intelligence in predicting wind farm power production using machine learning algorithms,” *Journal of Renewable and Sustainable Energy*, vol. 15, no. 1, 2023, doi: 10.1063/5.0127519.
- [85] MathWorks, 2024. Polynomial Curve Fitting. [online] Available: <https://es.mathworks.com/help/curvefit/polynomial-curvefitting.html> [Accessed 8 February 2025].
- [86] J. Zhao, L. Chen, W. Pedrycz, and W. Wang, “Variational Inference-Based Automatic Relevance Determination Kernel for Embedded Feature Selection of Noisy Industrial Data,” *IEEE Transactions on Industrial Electronics*, vol. 66, no. 1, pp. 416–428, 2019, doi: 10.1109/TIE.2018.2815997.
- [87] M. S. Hossain and H. Mahmood, “Short-Term Photovoltaic Power Forecasting Using an LSTM Neural Network and Synthetic Weather Forecast,” *IEEE Access*, vol. 8, pp. 172524–172533, 2020, doi: 10.1109/ACCESS.2020.3024901.
- [88] Y. Zhou, et al., “Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine,” *Energy*, vol. 204, p. 117894, 2020, doi: 10.1016/j.energy.2020.117894.

-
- [89] Z. Wang, B. Nie, Y. W. Du, H. Li, J. Q. Du, and Y. F. Chen, "Feature selection using different evaluate strategy and random forests," *2021 International Conference on Computer Engineering and Artificial Intelligence (ICCEAI)*, Shanghai, China, 2021, doi: 10.1109/ICCEAI52939.2021.00062.
- [90] H. Wang, J. Sun, J. Sun and J. Wang, "Using Random Forests to Select Optimal Input Variables for Short-Term Wind Speed Forecasting Models," *Energies*, vol. 10, p. 1522, 2017, doi: 10.3390/en10101522.
- [91] G. E. P. Box, G. M. Jenkins, and G. C. Reinsel, *Time Series Analysis: Forecasting and Control*, 3rd ed. Englewood Cliffs. NJ: Prentice Hall, 1994.
- [92] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proceedings of the national academy of sciences*, vol. 79, no. 8, pp. 2554–2558, 1982, doi: 10.1073/pnas.79.8.2554.
- [93] Z. Pang, F. Niu, and Z. O'Neill, "Solar radiation prediction using recurrent neural network and artificial neural network: A case study with comparisons," *Renewable Energy*, vol. 156, pp. 279–289, 2020, doi: 10.1016/j.renene.2020.04.042.
- [94] A. Sherstinsky, "Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network," *Physica D: Nonlinear Phenomena*, vol. 404, p. 132306, 2020, doi: 10.1016/j.physd.2019.132306.
- [95] G. Li, et al., "Recurrent neural networks based photovoltaic power forecasting approach," *Energies*, vol. 12, no. 13, p. 2538, 2019, doi: 10.3390/en12132538.
- [96] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," *IEEE transactions on neural networks*, vol. 5, no. 2, pp. 157–166, 1994, doi: 10.1109/72.279181.
- [97] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
- [98] Y. Jung, et al., "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," *Journal of Cleaner Production*, vol. 250, p. 119476, 2020, doi: 10.1016/j.jclepro.2019.119476.
- [99] W. Lin, et al., "Multi-step prediction of photovoltaic power based on two-stage decomposition and BiLSTM," *Neurocomputing*, vol. 504, pp. 56–67, 2022, doi: 10.1016/j.neucom.2022.06.117.
- [100] H. Zhen, et al., "Photovoltaic power forecasting based on GA improved Bi-LSTM in microgrid without meteorological information," *Energy*, vol. 231, p. 120908, 2021, doi: 10.1016/j.energy.2021.120908.
- [101] L. Yang and A. Shami, "On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice," *Neurocomputing*, vol. 415, pp. 295–316, 2020, doi: 10.1016/j.neucom.2020.07.061.

-
- [102] A. A. Chowdhury, A. Das, K. K. S. Hoque, and D. Karmaker, "A Comparative Study of Hyperparameter Optimization Techniques for Deep Learning," In *Proceedings of International Joint Conference on Advances in Computational Intelligence: IJCACI 2021* (pp. 509-521). Singapore: Springer Nature, doi: 10.1007/978-981-19-0332-8_38.
- [103] A. Jafar and M. Lee, "Comparative Performance Evaluation of State-of-the-Art Hyperparameter Optimization Frameworks," *The Transactions of the Korean Institute of Electrical Engineers*, vol. 72, no. 5, pp. 607–619, 2023, doi: 10.5370/KIEE.2023.72.5.607.
- [104] T. Yu and H. Zhu, "Hyper-Parameter Optimization: A Review of Algorithms and Applications," arXiv preprint arXiv:2003.05689, 2020.
- [105] F. Abbas et al., "Optimizing Machine Learning Algorithms for Landslide Susceptibility Mapping along the Karakoram Highway, Gilgit Baltistan, Pakistan: A Comparative Study of Baseline, Bayesian, and Metaheuristic Hyperparameter Optimization Techniques," *Sensors*, vol. 23, no. 6843, 2023, doi: 10.3390/s23156843.
- [106] B. Bischl et al., "Hyperparameter optimization: Foundations, algorithms, best practices, and open challenges," *WIREs Data Mining and Knowledge Discovery*, vol. 13, no. 2, 2023, doi: 10.1002/widm.1484.
- [107] A. Koutsoukas, K.J. Monaghan, X. Li, and J. Huan, "Deep-learning: Investigating deep neural networks hyper-parameters and comparison of performance to shallow methods for modeling bioactivity data," *J. Cheminform*, vol. 9, pp. 1–13, 2017, doi: 10.1186/s13321-017-0226-y.
- [108] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," presented at the 3rd *International Conference on Learning Representations*, San Diego, CA, USA, May 2015.
- [109] F.C. Soon, H.Y. Khaw, J.H. Chuah, and J. Kanesan, "Hyper-parameters optimisation of deep CNN architecture for vehicle logo recognition," *IET Intell. Transp. Syst.*, vol. 12, pp. 939–946, 2018, doi: 10.1049/ietits.2018.5127.
- [110] A. S. Wicaksono and A. A. Supianto, "Hyper Parameter Optimization using Genetic Algorithm on Machine Learning Methods for Online News Popularity Prediction," *Int. J. Adv. Comput. Sci. Appl. IJACSA*, vol. 9, no. 12, 2018, doi: 10.14569/IJACSA.2018.091238.
- [111] M. A. Elaziz et al., "Advanced metaheuristic optimization techniques in applications of deep neural networks: a review," *Neural Computing and Applications*, 2021, doi: 10.1007/s00521-021-05960-5.
- [112] B. Shahriari, K. Swersky, Z. Wang, R. P. Adams, and N. de Freitas, "Taking the Human Out of the Loop: A Review of Bayesian Optimization," *Proceedings of the IEEE*, vol. 104, no. 1, pp. 148–175, 2016, doi: 10.1109/JPROC.2015.2494218.
- [113] W. Mikolaj et al., "Improving classification accuracy of fine-tuned CNN models: Impact of hyperparameter optimization," *Heliyon*, vol. 10, p. 26586, 2024, doi: 10.1016/j.heliyon.2024.e26586.

-
- [114] C. Scott, M. Ahsan, and A. Albarbar, "Machine learning for forecasting a photovoltaic (PV) generation system," *Energy*, vol. 278, p. 127807, 2023, doi: 10.1016/j.energy.2023.127807.
- [115] T. Yang, Z. Yang, F. Li, H. Wang, "A short-term wind power forecasting method based on multivariate signal decomposition and variable selection," *Applied Energy*, vol. 360, 2024, doi: 10.1016/j.apenergy.2024.122759.
- [116] B. Efron and R. J. Tibshirani, *An Introduction to the Bootstrap*. New York, NY, USA: CRC Press, 1993.
- [117] T. C. T. Chen, *Explainable Artificial Intelligence (XAI) in Manufacturing: Methodology, Tools, and Applications*, 1st ed. Cham, Switzerland: Springer International Publishing, 2023.
- [118] MathWorks, 2024. Add white Gaussian noise to signal. [online] Available: <https://www.mathworks.com/help/comm/ref/awgn.html> [accessed 22 March 2025].
- [119] F. Milano and A. O. Manjavacas, *Frequency variations in power systems: modeling, state estimation and control*, 1st ed. Hoboken, NJ: Wiley-IEEE Press, 2020.
- [120] J. Bucciero and M. Terbrueggen, *Interconnected Power System Dynamics Tutorial*, 3rd ed. Electric Power Research Institute, 1998.
- [121] P. Kundur, *Power System Stability and Control*, 7th reprint. New York, USA: McGraw-Hill, 2009.
- [122] X. Deng, R. Mo, P. Wang, J. Chen, D. Nan, and M. Liu, "Review of RoCoF Estimation Techniques for Low-Inertia Power Systems," *Energies*, vol. 16, 2023, doi: 10.3390/en16093708.
- [123] T. Kerdphol, F. S. Rahman, M. Watanabe, and Y. Mitani, *Virtual inertia synthesis and control*. Springer, 2021.
- [124] Y. Zhao, "Deep Learning based Power System Stability Assessment for reduced WECC System," PhD diss., University of Tennessee, 2023.
- [125] Md. N. H. Shazon, N.-A.-Masood, and A. Jawad, "Frequency control challenges and potential countermeasures in future low-inertia power systems: A review," *Energy Reports*, vol. 8, pp. 6191–6219, 2022, doi: 10.1016/j.egy.2022.04.063.
- [126] A. S. Alsharafi, A. H. Besheer, and H. M. Emara, "Primary frequency response enhancement for future low inertia power systems using hybrid control technique," *Energies*, vol. 11, no. 4, 2018, doi: 10.3390/EN11040699.
- [127] A. Azis, A. T. Oo, and A. Stojcevski, "Frequency regulation capabilities in wind power plant," *Sustainable Energy Technologies and Assessments*, 2017, doi: 10.1016/j.seta.2017.10.002.
- [128] H. Saadat, *Power System Analysis*, Third Edition. PSA Publishing, 2010.
- [129] A. Fernández-Guillamón, G. Martínez-Lucas, A. Molina-García, and J.-I. Sarasua, "Hybrid Wind–PV Frequency Control Strategy under Variable Weather Conditions in Isolated Power Systems," *Sustainability*, vol. 12, no. 7750, 2020, doi: 10.3390/su12187750.

-
- [130] C. Wang and J. D. McCalley, "Impact of wind power on control performance standards," *Electrical Power and Energy Systems*, vol. 47, pp. 225–234, 2013, doi: 10.1016/j.ijepes.2012.11.010.
- [131] K. Guo, J. Fang, Y. Tang, "Autonomous DC-link voltage restoration for grid-connected power converters providing virtual inertia," presented at the *2018 IEEE Energy Conversion Congress and Exposition. ECCE 2018*, 2018, pp. 6837–6391. doi: 10.1109/ECCE.2018.8557440.
- [132] G. V. B. Kumar, R. K Sarojini, K. Palanisamy, S. Padmanaban, and J. B. Holm-Nielsen, "Large Scale Renewable Energy Integration: Issues and Solutions," *Energies*, vol. 12, 2019, doi: 10.3390/en12101996.
- [133] E. A. S. Ducoin, Y. Gu, B. Chaudhuri, and T. C. Green, "Analytical Design of Contributions of Grid-Forming and Grid-Following Inverters to Frequency Stability," *IEEE Transactions on Power Systems*, vol. 39, no. 5, 2024, doi: 10.1109/TPWRS.2024.3351530.
- [134] Y. Li, Y. Gu, and T. C. Green, "Revisiting Grid-Forming and Grid-Following Inverters: A Duality Theory," *IEEE Transactions on Power Systems*, vol. 37, no. 6, 2022, doi: 10.1109/TPWRS.2022.3151851.
- [135] G. Mousavi G, F. Faraji, A. Majazi, and K. Al-Haddad, "A comprehensive review of flywheel energy storage system technology," *Renew. Sustain. Energy Rev.*, vol. 67, pp. 477–490, 2017, doi: 10.1016/J.RSER.2016.09.060.
- [136] S. Sitompul, and G. Fujita, "Implementation of BESS load frequency control in islanded microgrid system by considering SOC," presented at the *IEEE PES Innovative Smart Grid Technologies Conference Europe*, 2020, pp. 980–984. doi: 10.1109/ISGT-EUROPE47291.2020.9248945.
- [137] Y. Xu, Y. Wang, C. Zhang, and Z. Li, *Coordination of Distributed Energy Resources in Microgrids: Optimization, control, and hardware-in-the-loop validation*. London, United Kingdom: The Institution of Engineering and Technology, 2022.
- [138] J. Ma and X. Ma, "A review of forecasting algorithms and energy management strategies for microgrids," *Systems Science & Control Engineering*, vol. 6, no. 1, pp. 237–248, 2018, doi: 10.1080/21642583.2018.1480979.
- [139] S. Vinothine, L. N. W. Arachchige, A. D. Rajapakse, and R. Kaluthanthrige, "Microgrid Energy Management and Methods for Managing Forecast Uncertainties," *Energies*, vol. 15, 2022, doi: 10.3390/en15228525.
- [140] D. Kumar, H. D. Mathur, S. Bhanot, and R. C. Bansal, "Modeling and frequency control of community micro-grids under stochastic solar and wind sources," *Engineering Science and Technology, an International Journal*, vol. 23, pp. 1084–1099, 2020, doi: 10.1016/j.jestch.2020.02.005.

-
- [141] H. Bevrani, F. Habibi, P. Babahajyani, M. Watanabe, and Y. Mitani, "Intelligent Frequency Control in an AC Microgrid: Online PSO-Based Fuzzy Tuning Approach," *IEEE Transactions on Smart Grid*, 2012, doi: 10.1109/TSG.2012.2196806.
- [142] T. Kerdphol, F. S. Rahman, Y. Mitani, M. Watanabe, and S. Küfeoğlu, "Robust Virtual Inertia Control of an Islanded Microgrid Considering High Penetration of Renewable Energy," *IEEE Access*, 2017, doi: 10.1109/ACCESS.2017.2773486.
- [143] D. Kumar, B. K. Mukherjee, H. D. Mathur, H. Siguerdidjane, and S. Bhanot, "Forecast-based modeling and robust frequency control of standalone microgrids considering high penetration of renewable sources," *International Transactions on Electrical Energy Systems*, vol. 31, 2021, doi: 10.1002/2050-7038.12759.
- [144] H. Ali, G. Magdy, B. Li, G. Shabib, A. A. Elbaset, D. Xu, and Y. Mitani, "A New Frequency Control Strategy in an Islanded Microgrid Using Virtual Inertia Control-Based Coefficient Diagram Method," *IEEE Access*, vol. 7, 2019, doi: 10.1109/ACCESS.2019.2894840.
- [145] M.-R. Chen, G.-Q. Zeng, Y.-X. Dai, K.-D. Lu, and D.-Q. Bi, "Fractional-Order Model Predictive Frequency Control of an Islanded Microgrid," *Energies*, vol. 12, no. 84, 2019, doi: 10.3390/en12010084.
- [146] M. Dashtdar, A. Flah, C. Z. El-Bayeh, M. Tostado-Véliz, A. A. Durra, S. H. E. A. Aleem, and Z. M. Ali, "Frequency control of the islanded microgrid based on optimized model predictive control by PSO," *IET Renewable Power Generation*, vol. 16, pp. 2088–2100, 2022, doi: 10.1049/rpg2.12492.
- [147] M. Dashtdar, A. Flah, S. M. S. Hosseinimoghadam, and A. EL-Fergani, "Frequency control of the islanded microgrid including energy storage using soft computing," *Scientific Reports*, vol. 12, 2022, doi: 10.1038/s41598-022-24758-6.
- [148] E. Alipour, A. Dejamkhooy, M. Hosseinpour, and A. Vahidnia, "Enhanced frequency control of a hybrid microgrid using RANFIS for partially shaded photovoltaic systems under uncertainties," *Scientific Reports*, vol. 14, 2024, doi: 10.1038/s41598-024-73233-x.
- [149] D. K. Mishra, L. Li, J. Zhang, and M. J. Hossain, *Power System Frequency Control: Modeling and Advances*. Academic Press, Elsevier, 2023.
- [150] A. O'dwyer, *Handbook of PI and PID controller tuning rules*. World Scientific, 2008.
- [151] S. B. Joseph, E. G. Dada, A. Abidemi, D. O. Oyewola and B. M. Khammas, "Metaheuristic algorithms for PID controller parameters tuning: review, approaches and open problems," *Heliyon*, vol. 8, 2022, doi: 10.1016/j.heliyon.2022.e09399.
- [152] M. Tradacete, C. Santos, J. A. Jiménez, F. J. Rodríguez, P. Martín, E. Santiso, and M. Gayo, "Turning Base Transceiver Stations into Scalable and Controllable DC Microgrids Based on a Smart Sensing Strategy," *Sensors*, vol. 21, no. 1202, 2021, doi: 10.3390/s21041202.

-
- [153] “Desert Knowledge Australia Centre.” Jun. 2023. Accessed: Jun. 09, 2023. [Online]. Available: <https://dkasolarcentre.com.au/download?location=alice-springs>
- [154] “ELIA, Jul. 2023, ‘Solar-PV Power Generation Data.’ Accessed: Jul. 23, 2023. [Online]. Available: <https://www.elia.be/en/grid-data/power-generation/solar-pv-power-generation-data>
- [155] D. Chen and H. W. Chen, “Using the Köppen classification to quantify climate variation and change: An example for 1901–2010,” *Environmental Development*, vol. 6, pp. 69–79, 2013, doi: 10.1016/j.envdev.2013.03.007.
- [156] D. Niu, K. Wang, L. Sun, J. Wu, and X. Xu., “Short-term photovoltaic power generation forecasting based on random forest feature selection and CEEMD: A case study,” *Applied Soft Computing Journal*, vol. 93, no. 106839, 2020, doi: 10.1016/j.asoc.2020.106389.
- [157] M. Guermoui, K. Bouchouicha, N. Bailek, and J. W. Boland, “Forecasting intra-hour variance of photovoltaic power using a new integrated model,” *Energy Conversion and Management*, vol. 245, no. 114569, 2021, doi: 10.1016/j.enconman.2021.114569.
- [158] Z. Liu, P. Li, D. Wei, J. Wang, L. Zhang, X. Niu, “Forecasting system with sub-model selection strategy for photovoltaic power output forecasting,” *Earth Science Informatics*, vol. 16, pp. 287–313, 2023, doi: 10.1007/s12145-023-00938-4.
- [159] Z. Su, S. Gu, J. Wang, and P. D. Lund, “Improving ultra-short-term photovoltaic power forecasting using advanced deep-learning approach,” *Measurement*, vol. 239, no. 115405, 2025, doi: 10.1016/j.measurement.2024.115405.
- [160] Q. Li, Y. Xu, B. Chew, H. Ding, G. Zhao, “An Integrated Missing-Data Tolerant Model for Probabilistic PV Power Generation Forecasting,” *IEEE Transaction on Power Systems*, 2021, doi: 10.1109/TPWRS.2022.3146982.
- [161] M. Ma, B. He, R. Shen, Y. Wang, and N. Wang, “An adaptive interval power forecasting method for photovoltaic plant and its optimization,” *Sustainable Energy Technologies and Assessments*, vol. 52, no. 102360, 2022, doi: 10.1016/j.seta.2022.102360.
- [162] J. Zhang, Z. Liu, and T. Chen, “Interval prediction of ultra-short-term photovoltaic power based on a hybrid model,” *Electric Power Systems Research*, vol. 216, no. 109035, 2023, doi: 10.1016/j.epsr.2022.109035.
- [163] J. Wang, Y. Yu, B. Zeng, and H. Lu, “Hybrid ultra-short-term PV power forecasting system for deterministic forecasting and uncertainty analysis,” *Energy*, vol. 288, no. 129898, 2024, doi: 10.1016/j.energy.2023.129898.
- [164] J. Wang, J. Liu, S. Zhang, and X. Ma, “Ultra-short-term solar power forecasting by deep learning and data reconstruction,” arXiv:2509.17095v1, 2025.
- [165] “ELIA, Nov. 2023, ‘Wind Power Generation Data.’ Accessed: Nov. 01, 2023. [Online]. Available: <https://www.elia.be/en/grid-data/power-generation/wind-powergeneration>

-
- [166] P. Lu, L. Ye, W. Zhong, Y. Qu, B. Zhai, Y. Tang, and Y. Zhao, "A novel spatio-temporal wind power forecasting framework based on multi-output support vector machine and optimization strategy," *Journal of Cleaner Production*, vol. 254, p. 119993, 2020, doi: 10.1016/j.jclepro.2020.119993.
- [167] Q. Wu, F. Guan, C. Lv, and Y. Huang, "Ultra-short-term multi-step wind power forecasting based on CNN-LSTM," *IET Renewable Power Generation*, vol. 15, pp. 1019–1029, 2021, doi: 10.1049/rpg2.12085.
- [168] D. Niu, L. Sun, M. Yu, and K. Wang, "Point and interval forecasting of ultra-short-term wind power based on a data-driven method and hybrid deep learning model," *Energy*, vol. 254, p. 124384, 2022, doi: 10.1016/j.energy.2022.124384.
- [169] X. Dai, G.-P. Liu, and W. Hu, "An online-learning-enabled self-attention-based model for ultra-short-term wind power forecasting," *Energy*, vol. 272, p. 127173, 2023, doi: 10.1016/j.energy.2023.127173.
- [170] M. H. Sulaiman, Z. Mustaffa, M. M. Saari, and M. F. Abas, "Wind power forecasting with metaheuristic-based feature selection and neural networks," *Cleaner Energy Systems*, vol. 9, p. 100149, 2024, doi: 10.1016/j.cles.2024.100149.
- [171] J. Wang, T. Niu, H. Lu, W. Yang, and P. Du, "A Novel Framework of Reservoir Computing for Deterministic and Probabilistic Wind Power Forecasting," *IEEE Transactions on Sustainable Energy*, vol. 11, no. 1, pp. 337–349, 2020, doi: 10.1109/TSTE.2019.2890875.
- [172] H. Quan, W. Zhang, W. Zhang, Z. Li, and T. Zhou, "An Interval Prediction Approach of Wind Power Based on Skip-GRU and Block-Bootstrap Techniques," *IEEE Transactions on Industry Applications*, vol. 59, no. 4, pp. 4710–4719, 2023, doi: 10.1109/TIA.2023.3270114.
- [173] A. A. Abdoos, H. Abdoos, J. Kazemitabar, M. M. Mobashsher, and H. Khaloo, "An intelligent hybrid method based on Monte Carlo simulation for short-term probabilistic wind power prediction," *Energy*, vol. 278, p. 127914, 2023, doi: 10.1016/j.energy.2023.127914.
- [174] Z. Zheng and Z. Zhang, "A Stochastic Recurrent Encoder Decoder Network for Multistep Probabilistic Wind Power Predictions," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 35, no. 7, 2024, doi: 10.1109/TNNLS.2023.3234130.
- [175] S. Murali, P. Saini, K. Abhinav, R. Shankar, and S. K. Parida, "Improved LSTM-Based Load Forecasting Embedded 3DOF (FOPI)-FOPD Controller for Proactive Frequency Regulation in Power System," *IEEE Transactions on Industry Applications*, vol. 60, no. 6, 2024, doi: 10.1109/TIA.2024.3443243.
- [176] S. Wen, Y. Wang, Y. Tang, Y. Xu, and P. Li, "Proactive frequency control based on ultrashort-term power fluctuation forecasting for high renewables penetrated power systems," *IET Renewable Power Generation*, vol. 13, no. 12, pp. 2166–2173, 2019, doi: 10.1049/iet-rpg.2019.0234.

-
- [177] IEEE Guide for the Application of Protective Relays Used for Abnormal Frequency Load Shedding and Restoration," in *IEEE Std C37.117-2007*, pp.1-55, 24 Aug. 2007, doi: 10.1109/IEEESTD.2007.4299516.