

PREDICCIÓN DIARIA DE GENERACIÓN DE ENERGÍA DE UN SISTEMA MICROEÓLICO EMPLEANDO REDES NEURONALES LONG SHORT-TERM MEMORY

Andrés Crespo¹, Claudio Reineri^{1,3}, Leonardo Sanchez¹, Daniel Anunziata², Eugenia Yorge¹, Gabriel Campetelli¹

¹Instituto de Protecciones de Sistemas Eléctricos de Potencia

²Grupo de Investigación e Innovación Tecnológica aplicada a la Ciencia de Datos
Facultad de Ingeniería

Universidad Nacional de Río Cuarto

Ruta Nacional 36 Km. 601, 5800 Río Cuarto

Tel. 0358-4676171 e-mail: creineri@ing.unrc.edu.ar

³Centro de Investigación, Desarrollo y Transferencia de Ingeniería Eléctrica
Universidad Tecnológica Nacional, Regional Córdoba
Maestro M. Lopez esq. Cruz Roja Argentina, S/N

RESUMEN: Este trabajo presenta un modelo de predicción a corto plazo (24 h) de la generación eléctrica de un sistema micro-eólico (ME) empleando redes neuronales recurrentes del tipo Long Short-Term Memory (LSTM). Como insumo se integran los pronósticos horarios de velocidad y dirección del viento obtenidos mediante el modelo WRF del Observatorio Hidro-Meteorológico de Córdoba (OHMC) con registros históricos de energía generada. Se efectúa un análisis estadístico del recurso eólico que permitió caracterizar el viento local. Previo al entrenamiento se aplica un proceso de selección, depuración y normalización de datos para reducir la influencia de mediciones atípicas y mejorar la calidad de las entradas. El modelo fue optimizado mediante ajuste de hiperparámetros claves (número de neuronas, tipo de optimizador, tasa de abandono, tamaño de lote), seleccionando la configuración que minimizó el RMSE en el conjunto de validación. Los resultados muestran que la arquitectura más profunda permitió extender el horizonte de predicción a 24 h con un error comparable al de un modelo de referencia de 8 h, aunque con mayor costo computacional. En conjunto, se confirma la viabilidad de las LSTM para sistemas ME, aportando precisión y generalización adecuadas para la planificación y gestión de microrredes o mercados eléctricos locales.

Palabras clave: Micro Turbina Eólica, Predicción, LSTM.

INTRODUCCIÓN

En las últimas décadas, el sector eléctrico ha atravesado una profunda transformación impulsada, tanto por el desarrollo de tecnologías de conversión de energía basadas en fuentes renovables, como por la electrificación de nuevos usos finales, tales como la movilidad eléctrica y el acondicionamiento térmico. Estos cambios intensifican la transición hacia una matriz energética con mayor participación de la electricidad (IEA, 2021).

En este nuevo escenario, las redes de distribución deben enfrentar desafíos asociados al incremento y variabilidad de la demanda, así como a la integración creciente de generación distribuida. Mantener el equilibrio entre oferta y demanda se torna más complejo, requiriendo soluciones innovadoras que aseguren la operación estable del sistema (Mehigan et al., 2018).



El avance de las Tecnologías de la Información y las Comunicaciones (TICs) ha facilitado la implementación de Redes Inteligentes (Smart Grids), capaces de gestionar en tiempo real el flujo de energía y la información asociada (Bani-Ahamed et al., 2018; Ayadi et al., 2020). La gestión de estas redes depende en gran medida de modelos precisos que permitan predecir tanto la generación como la demanda, de modo que las decisiones operativas puedan anticiparse a variaciones significativas (Khaleh y Laaksonen, 2022; Ahmada et al., 2020).

Las técnicas de predicción se pueden clasificar según distintos criterios, como el horizonte temporal (Kaur et al., 2015) o la metodología utilizada: modelos estadísticos clásicos (ARMA, ARIMA), de aprendizaje automático (SVM, SVR) y de aprendizaje profundo (FFNN, BPNN, RNN, LSTM, CNN) (Ahmada et al., 2020).

En este contexto, los sistemas ME han comenzado a cobrar relevancia, especialmente en entornos como microrredes o mercados eléctricos locales (Zahraoui et al., 2023; Sousa et al., 2019; Maturana et al., 2023). Sin embargo, la predicción de su producción presenta dificultades particulares debido a las turbulencias y variabilidad del viento en entornos urbanos o con obstáculos que alteran su flujo natural (Reja et al., 2022; Anup et al., 2019).

Diversos estudios han demostrado que los modelos basados en inteligencia artificial, en particular las redes neuronales de memoria a largo y corto plazo (LSTM), superan en capacidad predictiva a los métodos físicos tradicionales (Zhang et al., 2014; Xiong et al., 2022). No obstante, la literatura específica sobre predicción de generación eléctrica en sistemas ME mediante LSTM es aún escasa. Algunos trabajos, como el de Kumar et al. (2020), aplican LSTM-RNN para predecir velocidad del viento en microrredes aisladas, actualizando el estado del modelo con valores observados para mejorar la precisión, aunque sin predecir directamente la energía, lo que puede conducir a errores relevantes debido a la no linealidad entre viento y producción.

En su mayoría, las investigaciones con LSTM se han enfocado en grandes parques eólicos, explorando arquitecturas híbridas y combinadas con mecanismos de atención o redes convolucionales (Du, 2019; Xiong et al., 2022). Algunos autores han incorporado pronósticos meteorológicos de modelos numéricos como el WRF (Sierra et al., 2023; Xu et al., 2021), que provee predicciones de alta resolución espacial y temporal de variables atmosféricas claves.

Adomako et al. (2024) plantea modelos basados en LSTM para corregir los sesgos en sí de los modelos WRF. AbdElkader et al. (2025), incorpora elementos como validación cruzada procurando reducir sesgos de aprendizaje. Liu et al. (2024) introduce un modelo de filtro a un esquema que contiene a una LSTM en paralelo con una red de convolución temporal (TCN) para eliminar ruidos, suavizar las series temporales y mejorar el rendimiento de las predicciones del modelo. Por otro lado, Liu y Zhou (2011) presenta un modelo LSTM de múltiples variables de entrada con múltiples pasos de salida acompañado de un mecanismo de atención.

En el presente trabajo se emplean como variables de entrada las predicciones de velocidad y dirección del viento generadas por el modelo WRF y provistas por el Observatorio Hidro-Meteorológico de Córdoba (OHMC), integrándolas a un modelo LSTM entrenado para predecir directamente la energía generada por un sistema ME.

El objetivo central es el desarrollo de un sistema de predicción de 24 h que permita mejorar la planificación y operación de microrredes y facilitar la gestión de generación y carga en microrredes y/o la participación de estos sistemas en micromercados eléctricos (MME). Para ello se plantea combinar la robustez de los modelos de predicción meteorológica con la capacidad de las LSTM para modelar relaciones no lineales y dependencias temporales de largo alcance. También, se pretende comparar la arquitectura, los resultados obtenidos y el costo computacional frente a un modelo de referencia con horizonte temporal de 8 h.

METODOLOGÍA

La metodología empleada en este trabajo se basa en gran medida en la desarrollada en (Crespo et al., 2024). Sin embargo, se introducen modificaciones cruciales para abordar el nuevo horizonte de predicción de 24 h y para mejorar la calidad de los datos de entrada se introduce un proceso de limpieza.

Redes Neuronales

Para la comprensión detallada de las Redes Neuronales (NN) básicas y la evolución hacia las Redes Neuronales Recurrentes (RNN) y, en particular, las Long Short-Term Memory (LSTM), se remite al lector a (Crespo et al., 2024). Allí se describe el funcionamiento de una NN básica y sus limitaciones, tales como la falta de memoria y el problema del desvanecimiento del gradiente. También se detalla la mejora introducida por las RNN para manejar datos secuenciales, y el modo en que las LSTM superan estas limitaciones al incorporar un mecanismo de celda de memoria con puertas de entrada, salida y olvido. Esta capacidad de las LSTM para manejar dependencias temporales a largo plazo es lo que les confiere un gran potencial en aplicaciones para predicción de series temporales, como la producción de energía eólica. Las fortalezas de las LSTM frente a los modelos físicos, incluyendo su capacidad para modelar relaciones no lineales complejas y aprender directamente de los datos históricos sin necesidad de modelos explícitos, se mantienen como una justificación fundamental para su empleo en este contexto.

Instalación de la Turbina ME

La instalación de la Microturbina Eólica (ME) utilizada en este estudio es la misma que en (Crespo et al., 2024). Se encuentra ubicada en el Instituto de Protecciones de Sistemas Eléctricos de Potencias (IPSEP-UNRC), en la ciudad de Río Cuarto, provincia de Córdoba (coordenadas 33°06'38,3"S 64°17'50,6"O). En (Crespo et al., 2024) se presenta el emplazamiento donde se observan obstáculos naturales como líneas de arbolado en las direcciones Norte y Noreste, a aproximadamente 20 y 40 m de distancia, con alturas de copa que superan el eje horizontal de la turbina, lo que perturba el flujo normal del viento.

La turbina ME es un aerogenerador EOLUX 1200 48V con una potencia nominal de 1200 W a 14 m/s y una velocidad de arranque de 4,5 m/s. Posee un generador trifásico síncrono de imanes permanentes, un rotor de tres palas con un ángulo de 6 grados y un diámetro de 2,1 m. Se instala sobre un reticulado metálico de 12 m que se apoya en una cubierta de techo de 9 m. El acoplamiento a la red eléctrica se realiza mediante un inversor ABB UNO-2.0-I-W, y las variables eléctricas son registradas por un medidor inteligente Dimet-G (Discar Metering) gestionado por el sistema online Mr.Dims.

Selección y depuración de datos

En primer lugar, se decidió prescindir de los registros provistos por el Servicio Meteorológico Nacional (SMN), utilizados en (Crespo et al., 2024), ya que estaban restringidos a un rango horario (los equipos de medición se encontraban activados entre las 6:00 h y se apagan a las 22:00 h). Esta limitación reducía la base de datos combinada (OHMC + SMN + energía medida) a alrededor de 6.500 registros horarios, frente a los 10.200 registros disponibles al trabajar exclusivamente con el OHMC. Optar por esta última fuente permitió conservar la serie horaria completa, aumentar la cobertura temporal (24 h) y robustecer el entrenamiento del modelo al evitar sesgos asociados a la exclusión de los períodos nocturnos.

En segundo lugar, se implementaron límites para depurar las series temporales, logrando descartar un número significativo de muestras atípicas. Estos valores pueden atribuirse a errores de medición, como energía negativa, picos significativos por fallas en el medidor, errores en el modelo que genera las predicciones de velocidades de viento. La inclusión de estos datos afecta negativamente el desempeño y la precisión del modelo, por lo que se procedió a eliminarlos para garantizar una mejor calidad de entrenamiento.

Análisis del recurso eólico

Se analizaron dos años completos de la información provista por el OHMC, tanto el año 2022 como el 2023, se ha determinado el valor medio y la desviación estándar de velocidad de viento. Además de los parámetros de forma (k) y escala (c) de la distribución de Weibull, comúnmente utilizada para ajustar la

frecuencia de la velocidad del viento (Anup et al., 2019). Esto se muestra en la Tabla 1, es de interés tener en cuenta que a diferencia de (Crespo et al., 2024), aquí se analizó la totalidad del día, por lo que resultan coherente las discrepancias respecto a las magnitudes estadísticas presentadas en (Crespo et al., 2024).

Tabla 1: Magnitudes estadísticas de la velocidad del viento en km/h para 3 años de análisis

Año	Valor medio	Desviación Std.	c-Weibull	k-Weibull
2022	14,23	6,73	2,26	16,07
2023	13,46	6,413	2,24	15,2

En la Figura 1, se presenta la gráfica de distribución acumulada de probabilidades de velocidad de viento empleando un escalamiento de bins cada 5 km/h para los dos años analizados. Esto resulta en un buen indicador de la regularidad del recurso y se destaca que en más del 60% del tiempo no se alcanza la velocidad de arranque de la turbina ME (16,2 km/h).




Figura 1: Distribución acumulada de probabilidades de velocidad de viento para los años 2022-2023.

En la Figura 2, se presenta una rosa de vientos para todos los registros en donde se superó la velocidad de arranque de la turbina (16,2 km/h). Se observa claramente un comportamiento similar respecto a la energía específica estimada a partir de los registros de velocidad de viento provistos por el SMN en (Crespo et al., 2024). Los registros en general, y las velocidades importantes, predominan del sector Norte, Noreste, Sur y Suroeste. En (Crespo et al., 2024) se pudo visualizar que la generación de energía asociada a los sectores Norte y Noreste se ve afectada por la presencia de obstáculos descrita en la sección 2.2 de este trabajo.

Implementación del Modelo de Predicción

A continuación, se presenta una breve descripción de la implementación de un modelo basado en una red LSTM para la predicción de energía eléctrica en una ventana de 24 h. El desarrollo del modelo predictivo se realizó en Python, utilizando las librerías TensorFlow y Keras. La arquitectura empleada sigue una estructura de red LSTM similar a la utilizada en (Crespo et al., 2024), en el cual se abordó la predicción de energía eléctrica en una ventana de 8 h.




Figura 2: Rosa de vientos de velocidades mayores a la velocidad de arranque del aerogenerador ME.

Preparación de Datos

Las series de tiempo que se emplean para todas las variables están escaladas en pasos por hora: las velocidades y direcciones del viento son valores medios para cada hora y los de energía se corresponden con la producción total para cada hora. En función del horizonte de predicción se define la longitud temporal de ventanas de los conjuntos de entrenamiento, validación y predicción.

Las entradas del modelo son: (i) la energía generada medida durante las 0 h a 23 h del día previo, (ii) las velocidades del viento pronosticadas (OHMC) en componentes u y v (a partir de la dirección) para esas mismas horas del día previo, y (iii) las velocidades del viento pronosticadas (OHMC) en componentes u y v para las 24 h a 47 h, correspondientes al día siguiente. Con estos datos, el modelo estima la producción de energía para el periodo de 24 h a 47 h.

De la totalidad de los datos disponibles (agosto 2021-septiembre 2022), el 80% de los mismos se destinó al entrenamiento del modelo, un 10% para la validación y el último 10% para su evaluación. Los criterios generales para la asignación de estos porcentajes son, básicamente, que el modelo tenga suficiente información para aprender patrones y no se sobreajuste en relación al conjunto de validación y contar también con un volumen de datos para evaluar el modelo.

Para eliminar la dimensionalidad de las variables de entrada del modelo de predicción, que poseen diferentes rangos de valores, se realiza una normalización de cada una de ellas, como se expresa en la Ec. (1).

$$X_{nor} = \frac{X - X_{mín}}{X_{máx} - X_{mín}} \quad (1)$$

Función de Pérdida y Métodos de Evaluación

La función de pérdida empleada para cuantificar el error del modelo durante el entrenamiento y guiar el proceso de optimización, es el Error Cuadrático Medio (MSE). Esta métrica, se calcula como el promedio de los cuadrados de las diferencias entre las predicciones y los valores medidos.

Para evaluar el desempeño del modelo de predicción de energía eléctrica, se utilizaron dos métricas principales: el Error Absoluto Medio (MAE), que mide el promedio de las diferencias absolutas entre los valores reales y los predichos y la Raíz del Error Cuadrático Medio (RMSE), que calcula la raíz

cuadrada del promedio de los errores al cuadrado, penalizando más fuertemente los errores grandes y siendo sensible a desviaciones importantes.

Conformación del Modelo

El modelo está conformado por una arquitectura LSTM profunda con dos capas LSTM, una capa densa intermedia y una capa de salida con 24 neuronas, correspondiente al horizonte de predicción de 24 h. Es importante tener en cuenta que la parametrización completa del modelo se presenta en la sección resultados, luego de un proceso de optimización.

Existen una serie de parámetros que se ajustan durante el entrenamiento del modelo. El primero es el número de unidades, o neuronas, de cada capa LSTM, que define la capacidad del modelo para aprender patrones complejos. El segundo parámetro son las epochs (épocas), que indican la cantidad de veces que el modelo procesa todo el conjunto de datos durante el entrenamiento. El tercero es el batch size (tamaño del lote), que corresponde a la cantidad de secuencias que se procesan simultáneamente antes de actualizar los pesos del modelo. Además, se utilizan capas de Dropout (Tasa de abandono) para evitar el sobreajuste, es decir, para atenuar la posibilidad que el modelo memorice los datos en lugar de generalizar. Para optimizar el aprendizaje y minimizar la función de pérdida se emplean optimizadores como RMSprop o Adam.

La Figura 3 muestra un esquema general del modelo, donde se representan las entradas, las salidas, las capas LSTM, de dropout, densas y la de salida.

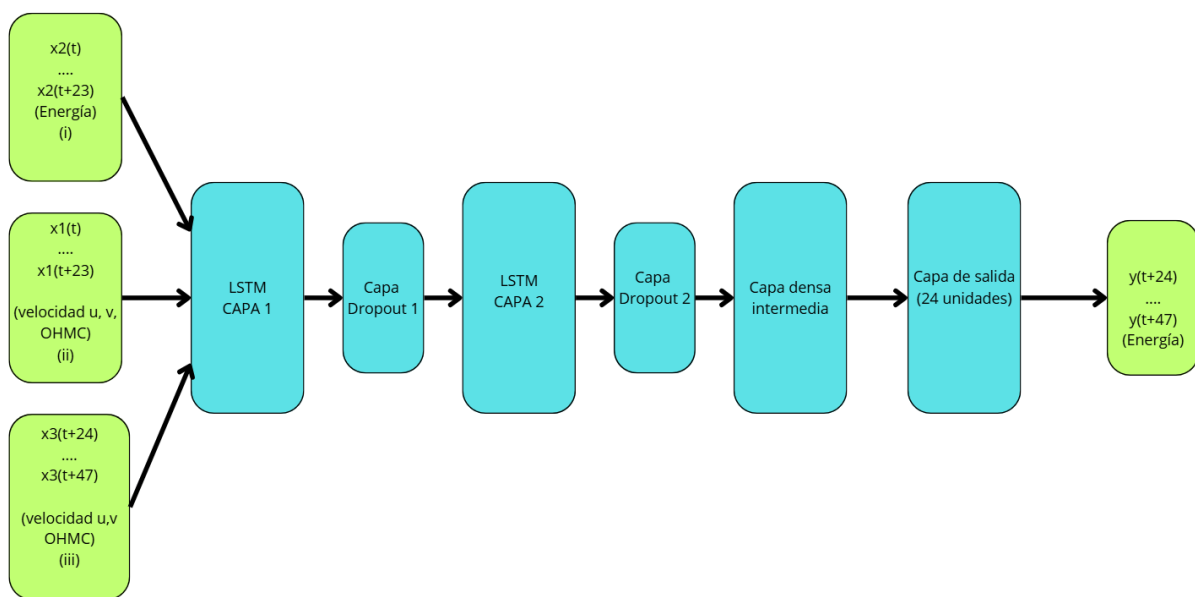


Figura 3: Esquema del modelo conformado.

RESULTADOS

Se realizó una optimización de hiperparámetros tomando como criterio principal la minimización del RMSE sobre el conjunto de validación, debido a su mayor sensibilidad a errores significativos, lo cual es relevante en predicción de energía. También se evaluaron métricas como el MAE con fines comparativos, para contar con una visión más completa del desempeño del modelo.

En la Tabla 2 se presentan los resultados de diversas configuraciones evaluadas durante el proceso de optimización del modelo LSTM. Se analizaron combinaciones de hiperparámetros clave como, la cantidad de unidades por capa, [A, B, C]), donde los dos primeros valores corresponden a capas LSTM secuenciales y el último a una capa densa previa a la salida, la tasa de abandono, el optimizador, el tamaño de lote y la cantidad de épocas. El objetivo principal fue minimizar el RMSE en el conjunto de validación.

Tabla 2: Resultados de la Optimización de Hiperparámetros del Modelo LSTM

exp	layers_units	epochs	batch_size	dropout	optimizer	rmse_val, Wh	rmse_test, Wh
exp_16	[128, 96, 64]	30	20	0,3	rmsprop	31,55	44,32
exp_26	[330, 64, 64]	30	7	0,2	rmsprop	31,82	41,35
exp_10	[128, 96, 64]	30	7	0,2	rmsprop	31,91	42,78
exp_12	[128, 96, 64]	30	7	0,3	rmsprop	31,92	41,61
exp_29	[330, 64, 64]	30	20	0,2	adam	32,04	41,14
exp_24	[500, 150, 78]	30	20	0,3	rmsprop	32,10	42,13
exp_27	[330, 64, 64]	30	7	0,3	adam	32,30	43,98
exp_31	[330, 64, 64]	30	20	0,3	adam	32,31	42,70
exp_11	[128, 96, 64]	30	7	0,3	adam	32,36	42,89
exp_17	[500, 150, 78]	30	7	0,2	adam	32,39	42,29
exp_4	[64, 32, 32]	30	7	0,3	rmsprop	32,41	41,11
exp_8	[64, 32, 32]	30	20	0,3	rmsprop	32,54	42,92
exp_22	[500, 150, 78]	30	20	0,2	rmsprop	32,57	42,94
exp_3	[64, 32, 32]	30	7	0,3	adam	32,63	42,08
exp_18	[500, 150, 78]	30	7	0,2	rmsprop	32,73	42,41
exp_14	[128, 96, 64]	30	20	0,2	rmsprop	32,73	40,27
exp_6	[64, 32, 32]	30	20	0,2	rmsprop	32,90	46,03
exp_20	[500, 150, 78]	30	7	0,3	rmsprop	33,07	40,97
exp_2	[64, 32, 32]	30	7	0,2	rmsprop	33,11	41,80
exp_15	[128, 96, 64]	30	20	0,3	adam	33,20	43,46
exp_23	[500, 150, 78]	30	20	0,3	adam	33,28	43,29
exp_21	[500, 150, 78]	30	20	0,2	adam	33,35	45,39
exp_9	[128, 96, 64]	30	7	0,2	adam	33,70	43,04
exp_28	[330, 64, 64]	30	7	0,3	rmsprop	33,80	43,47
exp_25	[330, 64, 64]	30	7	0,2	adam	33,91	44,90
exp_19	[500, 150, 78]	30	7	0,3	adam	34,17	42,13
exp_30	[330, 64, 64]	30	20	0,2	rmsprop	34,35	45,09
exp_5	[64, 32, 32]	30	20	0,2	adam	34,70	47,65
exp_7	[64, 32, 32]	30	20	0,3	adam	34,75	43,88
exp_13	[128, 96, 64]	30	20	0,2	adam	34,85	47,65
exp_1	[64, 32, 32]	30	7	0,2	adam	35,06	45,33

En la Tabla 3 se muestran las métricas MAE y RMSE para el conjunto de validación y prueba correspondientes al modelo seleccionado como óptimo (exp 16). Además, en la Figura 4, se presenta la evolución de ambas métricas por hora para el conjunto validación.

Tabla 3: Métricas para los conjuntos de validación y prueba

Conjunto	MAE	RMSE
Validación	23,07	31,55
Prueba	30,26	44,32

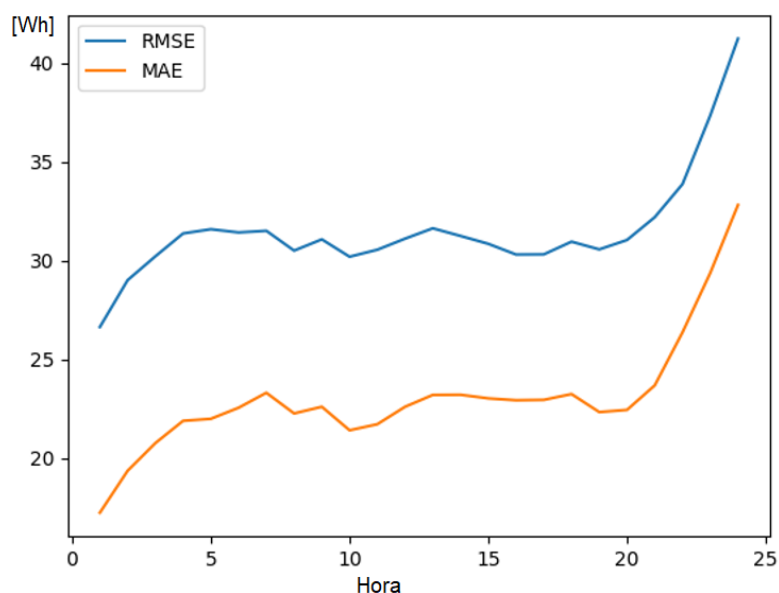


Figura 4: Evolución temporal de métricas para el conjunto de validación.

En la Figura 5 se puede apreciar la evolución temporal de los valores medidos y las predicciones durante parte del tramo de evaluación. Las predicciones se realizan con un horizonte de 24 h, los puntos verdes y amarillos representan el inicio de cada una de ellas.

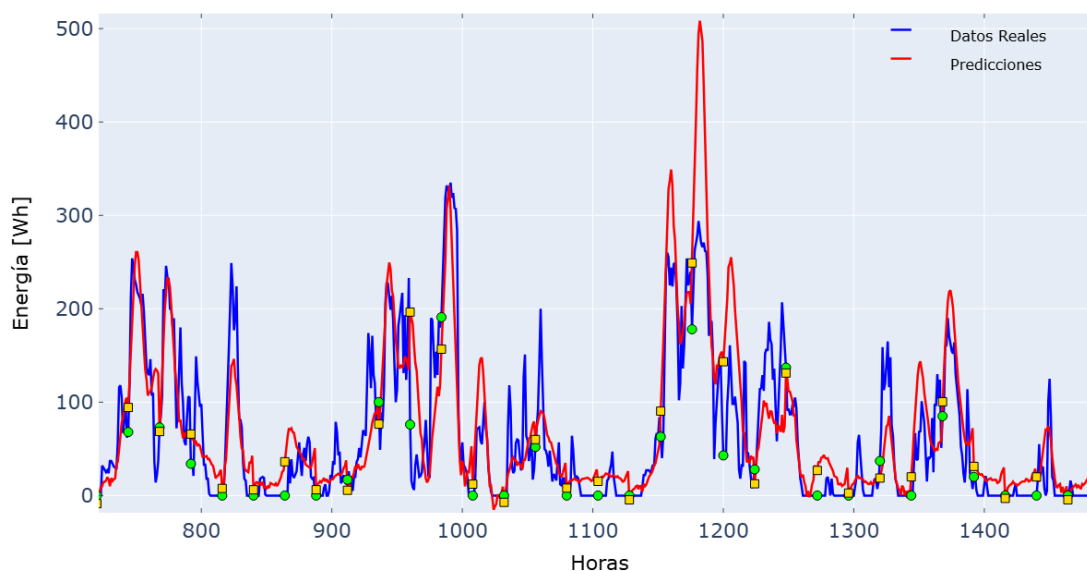


Figura 5: Evolución temporal de predicciones y datos medidos.

En relación con (Crespo et al., 2024), el modelo optimizado de este estudio se configuró con dos capas LSTM, una capa densa intermedia, capas de dropout y una capa densa de salida; mientras que en (Crespo et al., 2024) el modelo optimizado se obtuvo con una sola capa LSTM y una capa densa de salida.

Realizando la desnormalización del error RMSE del conjunto de validación del modelo optimizado en (Crespo et al., 2024), se obtiene un valor en torno a los 55 Wh, energéticamente similar a los 31,6 Wh que se obtuvo para el conjunto de validación con el modelo seleccionado.

Los resultados expuestos en la Tabla 3, se obtuvieron con un batchsize pequeño en relación al batchsize de 250 utilizado en el modelo optimizado en (Crespo et al., 2024).

DISCUSIONES

Para alcanzar errores de predicción aceptables fue necesario incrementar la complejidad del modelo, incorporando dos capas LSTM, una capa densa intermedia y mecanismos de dropout, además de una capa densa de salida. Estas modificaciones estructurales, en conjunto, permitieron captar patrones temporales más amplios, aunque con un costo computacional más elevado debido a la mayor complejidad del modelo.

Un aspecto destacado fue el uso de un batchsize muy reducido respecto al valor empleado en (Crespo et al., 2024). Esta estrategia también aumentó el costo computacional, ya que al procesar menos muestras por lote es necesario ejecutar un número considerablemente mayor de iteraciones en cada época.

En cuanto al desempeño, el modelo alcanzó un error ligeramente menor al reportado en Crespo et al. (2024). Aunque la diferencia en magnitud pueda parecer moderada, resulta relevante desde una perspectiva energética, ya que implica una mejora tangible en la precisión de la estimación horaria de generación. Cabe subrayar que la comparación debe interpretarse con cautela, dado que existen disparidades en los conjuntos de datos y en los horizontes de predicción considerados en ambos estudios; no obstante, la reducción del error confirma un avance significativo.

El proceso de optimización de hiperparámetros mostró que, aunque se evaluaron diversas configuraciones de capas, unidades, tasas de abandono, optimizadores y tamaños de lote, los mejores resultados de validación se mantuvieron en un rango estrecho de RMSE (entre 31 y 35 Wh). En este contexto, el modelo seleccionado (exp_16) logró un RMSE de validación de 31,55 Wh y un RMSE de prueba de 44,32 Wh, acompañado de un MAE de 23,07 Wh y 30,26 Wh respectivamente. La diferencia entre los errores de validación y prueba indica una adecuada capacidad de generalización, aunque el incremento en RMSE en el conjunto de prueba podría estar relacionado con condiciones no representadas completamente en el entrenamiento.

Asimismo, el análisis horario (Figura 4) evidenció un aumento progresivo del error hacia las últimas horas del horizonte de 24 h, lo que refleja la complejidad adicional de extender las predicciones en el tiempo. De manera complementaria, la comparación visual entre valores medidos y predichos (Figura 5) mostró que, aunque el modelo reproduce adecuadamente las tendencias generales y las variaciones de corto plazo, persisten desviaciones puntuales en magnitudes específicas.

La mayor profundidad arquitectónica, la introducción de dropout y el empleo de un batchsize reducido se consolidaron como estrategias efectivas para mejorar la representación de patrones temporales y reducir el error. Los resultados en conjunto demuestran que el modelo optimizado ofrece un equilibrio adecuado entre precisión y capacidad de generalización. No obstante, la reducción del error en las últimas horas del horizonte de predicción y la mejora de la robustez ante condiciones no contempladas en el entrenamiento continúan siendo desafíos abiertos, que podrían abordarse mediante enfoques híbridos o técnicas de corrección de sesgo.

CONCLUSIONES

Los resultados obtenidos muestran que el modelo de predicción implementado, basado en el uso de series temporales de velocidad y dirección del viento como predictores, logra estimar con buena aproximación la generación de energía eléctrica de un sistema eólico a corto plazo (24 h). Las métricas de evaluación empleadas, RMSE y MAE, permiten cuantificar el desempeño y muestran valores que se

consideran aceptables para aplicaciones operativas, aunque revelan que persisten discrepancias en situaciones de alta variabilidad del recurso eólico.

El análisis comparativo frente a un modelo de referencia con horizonte de 8 h evidenció que extender las predicciones a 24 h exigió incrementar la complejidad arquitectónica y el costo computacional, en particular por el uso de tamaños de lote reducidos (batchsize). Para alcanzar un desempeño adecuado fue necesario pasar de una arquitectura simple (basada en una sola capa LSTM y una capa de salida) a un modelo más profundo, compuesto por dos capas LSTM secuenciales, una capa densa intermedia y la incorporación de mecanismos de dropout. Estas modificaciones estructurales, si bien incrementaron el tiempo de entrenamiento y la demanda de recursos, permitieron mantener errores de predicción similares a los obtenidos en el horizonte temporal de referencia, lo que constituye un avance significativo al ampliar la ventana de estimación sin sacrificar precisión.

El análisis comparativo entre valores medidos y predichos confirma que la tendencia general de la producción horaria es capturada adecuadamente a pesar que la magnitud de los picos de generación presenta ligeras desviaciones. Este comportamiento resultaría consistente con las limitaciones inherentes a los modelos que dependen de pronósticos meteorológicos como entrada, donde pequeños errores en la predicción de la velocidad del viento se amplifican al estimar la potencia.

La inspección temporal de las métricas mostró que el error tiende a incrementarse hacia las últimas horas del horizonte de 24 h, lo que confirma la mayor dificultad de capturar dependencias de largo alcance.

En el marco del estado del arte, la metodología utilizada se alinea con las estrategias de predicción probabilística y determinística aplicadas en entornos con datos limitados, representando una alternativa viable frente a los modelos físicos tradicionales, que suelen requerir información topográfica y de turbulencia más detallada. Asimismo, el uso de métricas estándar como RMSE y MAE permite la comparación con otros trabajos reportados en la literatura, fortaleciendo la validación del enfoque.

Finalmente, los resultados sugieren que una optimización adicional podría lograrse incorporando algunas variables meteorológicas adicionales (por ejemplo, presión atmosférica o temperatura), afinando la calibración del modelo y evaluando su comportamiento bajo distintos horizontes temporales de predicción. Persisten, sin embargo, desafíos vinculados a la reducción del error en las últimas horas del horizonte y a la mejora de la robustez del modelo, aspectos que podrían abordarse mediante enfoques híbridos o técnicas de corrección de sesgo. Estas mejoras, junto con un análisis probabilístico más detallado, permitirían incrementar la confiabilidad del sistema para su uso en la planificación y gestión operativa de la generación ME.

AGRADECIMIENTOS

Al Observatorio Hidro-Meteorológico de la Provincia de Córdoba (OHMC) por facilitar el acceso a sus series históricas de información meteorológica. A la Secretaría de Ciencia y Técnica de la UNRC por el financiamiento al proyecto en cuyo marco se realizó este trabajo.

REFERENCIAS

- AbdElkader A. G., ZainEldin H., Saafan M. M., (2025). Optimizing wind power forecasting with RNN-LSTM models through grid search cross-validation. *Sustainable Computing: Informatics and Systems* 45, 101054.
- Adomako A., Jamshidi E. J., Yusup Y., Elsebakhi E., Jaafar M. H., Ishak M. I. S., Lim H. S., Ahmad M. Y. (2024). Deep learning approaches for bias correction in WRF model outputs for enhanced solar and wind energy estimation: A case study in East and West Malaysia. *Ecological Informatics* 84, 102898, 1-17.
- Ahmada T., Zhanga H. y Yana B. (2020). A review on renewable energy and electricity requirement forecasting models for smart grid and buildings. *Sustainable Cities and Society*, Elsevier, Vol. 55.
- Anup K.C., Whale J. y Urme T. (2019). Urban Wind Conditions and Small Wind Turbines in the BuiltEnvironment: A Review. *Renewable Energy*, Elsevier. Vol. 131, pp. 268-283.

- Aslam S, Herodotou H, Mohsin S., Javaid N., Ashraf N. y Aslam S. (2021). A Survey on Deep Learning Methods for Power Load and Renewable Energy Forecasting in Smart Microgrids. *Renewable and Sustainable Energy Reviews*, Elsevier, Vol. 144.
- Ayadi F., Colak I., Garip I. y Bulbul H. (2020). Impacts of Renewable Energy Resources in Smart Grid. 8th IEEE International Conference on Smart Grid, Paris, France.
- Bani-Ahmed A., Nasiri A. y Stamenkovic I. (2020). Foundational Support Systems of the Smart Grid: State of the Art and Future Trends. *International Journal of Smart Grid*, Vol. 2, No. 1.
- Crespo, A., Reineri, C., Amatti J., Campetelli, G., Sanchez, L. y Amaya J. (2024). Predicción de corto plazo de generación de energía de un sistema microeólico empleando redes neuronales long short-term memory. *Energías Renovables Y Medio Ambiente - AVERMA*, Vol 28, 150–161.
- Du M. (2019). Improving LSTM Neural Networks for Better Short-Term Wind Power Predictions. 2nd International Conference on Renewable Energy and Power Engineering (REPE), Toronto, Canada.
- International Energy Agency (2021). Net Zero by 2050: A Roadmap for the Global Energy Sector. Revised version, (4th revision).
- Duffie J. A. y Beckman W. A. (1991). *Solar Engineering of Thermal Processes*, 2^a edición, pp. 54-59. Wiley Interscience, New York.
- Jørgensen K.L. y Reza C. H. (2020), Wind Power Forecasting Using Machine Learning: State of the Art, Trends and Challenges. *IEEE 8th International Conference on Smart Energy Grid Engineering*, pp. 44–59.
- Kaur D., Islam S. N., Mahmud M. A., Haque M. E. y Dong Z. Y. (2015). “Energy Forecasting in Smart Grid Systems: Recent Advancements in Probabilistic Deep Learning”, *The Institution of Engineering and Technology. Research Journals*, pp. 1–15.
- Khajeh H. y Laaksonen H. (2022). Applications of Probabilistic Forecasting in Smart Grids: A Review. *Appl. Sci.* Vol. 12.
- Kumar, D., Mathur, H. D., Bhanot, S. y Bansal, R. C. (2020). Forecasting of solar and wind power using LSTM RNN for load frequency control in isolated microgrid. *International Journal of Modelling and Simulation*, 41(4), 311–323.
- Liu S., Xu T., Du X., Zhang Y., Wu J., (2024). A hybrid deep learning model based on parallel architecture TCN-LSTM with Savitzky-Golay filter for wind power prediction. *Energy Conversion and Management* 302, 118122.
- Liu X. y Zhou J. (2024). Short-term wind power forecasting based on multivariate/multi-step LSTM with temporal feature attention mechanism. *Applied Soft Computing* 150, 111050.
- Maturana J.B., Aguilera F. y Oggier G. (2023), Dimensionamiento del Sistema de Almacenamiento de Energía de una Microred Híbrida para Reducir el Consumo de Energía de la Red Eléctrica, XX Reunión de Trabajo en Procesamiento de la Información y Control – RPIC.
- Mehigan L., Deane J.P., Gallachóir B.P. y Bertesh V. (2018). A Review of the Role of Distributed Generation in Future Electricity Systems. *Energy*, Elsevier, Vol. 163, pp. 822-836.
- OHMC [en línea] Pronósticos hidro-meteorológicos para la Región Centro (2021-2023). Observatorio Hidro-Meteorológico de la Provincia de Córdoba. Dirección URL: <https://ohmc.ar/> [consulta: de 5 julio de 2025].
- Parag Y. y Ainspan M. (2019). Sustainable microgrids: Economic, environmental and social costs and benefits of microgrid deployment. *Energy for Sustainable Development*, Elsevier. Vol 52, pp. 72-81.
- Reja R., Amin R., Tasneem Z., Ali M. F., Islam M. R., Saha D., Badal F., Ahamed M. H. y Moyeen, S (2022). A Review of the Evaluation of Urban Wind Resources: Challenges and Perspectives. *Energy y Building*, Elsevier. Vol. 257. pp. 1-19.
- Sierra Lorenzo, M., Fuentes Barrios, A., Roque Rodríguez, A. E., Rosquete Estevez, A., & Patiño Avila, D. M. (2023). Comparison of the wind nowcasting generated by the WRF model and an two LSTM models *Revista Cubana de Meteorología*, Vol. 29 Núm. 3.
- Sousa T., Soares T., Pinson P., Moret F., Baroche T. y Sorin E. (2019). Peer-to-peer and communitybased markets: A comprehensive review. *Renewable and Sustainable Energy Reviews*, Elsevier, 104, pp. 367-378.
- Xiong B., Lou L., Meng X., Wang X., Ma H. y Wang Z. (2022). Short-term wind power forecasting based on Attention Mechanism and Deep Learning. *Electric Power Systems Research*, Vol. 206.
- Xu, W., Liu, P., Cheng, L., Zhou, Y., Xia, Q., Gong, Y., & Liu, Y. (2021). Multi-step wind speed prediction by combining a WRF simulation and an error correction strategy. *Renewable Energy*, 163, 772–782. <https://doi.org/10.1016/j.renene.2020.09.032>

- Zahraoui Y, Korötko T., Rosin A. y Agabus H. (2023). Market Market Mechanisms and Trading in Microgrid Local Electricity Markets: A Comprehensive Review. *Energies* (MDPI), Vol. 16.
- Zhang Y., Wang J., Wang X. (2014). Review on probabilistic forecasting of wind power generation. *Renewable and Sustainable Energy Reviews*, Volume 32, pp. 255-270.

DAILY PREDICTION OF ENERGY GENERATION IN A MICRO WIND SYSTEM USING LONG SHORT-TERM MEMORY NEURAL NETWORKS

ABSTRACT: This work presents a short-term (24 h) prediction model for the electricity generation of a micro wind system (ME) using recurrent neural networks of the Long Short-Term Memory (LSTM) type. As inputs, hourly forecasts of wind speed and direction obtained through the WRF model from the Hydro-Meteorological Observatory of Córdoba (OHMC) are integrated with historical records of generated energy. A statistical analysis of the wind resource was carried out, which allowed the characterization of the local wind conditions. Before training, a process of data selection, cleaning, and normalization was applied to reduce the influence of outlier measurements and improve input quality. The model was optimized by tuning key hyperparameters (number of neurons, optimizer type, dropout rate, batch size), selecting the configuration that minimized RMSE on the validation set. The results show that the deeper architecture made it possible to extend the prediction horizon to 24 h with an error comparable to that of a reference 8 h model, albeit with higher computational cost. Overall, the feasibility of LSTM networks for ME systems is confirmed, providing adequate accuracy and generalization for the planning and management of microgrids or local electricity markets.

Keywords: Micro Wind Turbine, Prediction, LSTM.