

PREDICCIÓN DE CORTO PLAZO DE GENERACION DE ENERGIA DE UN SISTEMA MICROEOLICO EMPLEANDO REDES NEURONALES LONG SHORT-TERM MEMORY

Andrés Crespo¹, Claudio Reineri^{1,2}, Juan Amatti¹, Gabriel Campetelli¹, Leonardo Sanchez¹,
Juan Amaya²

¹Instituto de Protecciones de Sistemas Eléctricos de Potencia – 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

²Centro de Investigación, Desarrollo y Transferencia de Ingeniería Eléctrica
Universidad Tecnológica Nacional, Regional Córdoba
Maestro M. López esq. Cruz Roja Argentina, S/N

RESUMEN: En primer lugar, se fundamenta la importancia de las Redes Inteligentes en el contexto de la Transición Energética. Las predicciones, de producción o demanda, juegan un rol clave para diferentes tipos de análisis y operación de este tipo de redes. Se describen las diferentes técnicas para la resolución de tal problema y se destacan las Redes Neuronales, particularmente las Long Short-Term Memory. A partir de esto se desarrolló una herramienta predictiva de corto plazo de producción de energía de una instalación MicroEólica basada en una Long Short-Term Memory. Para su entrenamiento se emplean datos de velocidad y dirección de viento, registrada por el Servicio Meteorológico Nacional y por el Observatorio Hidro-Meteorológico de Córdoba, en el primer caso registros de información histórica y en el segundo los pronósticos de tales parámetros para el día siguiente. Para complementar los datos de entrenamiento se dispone de la energía generada por una Microturbina. Se muestran resultados promisorios en las predicciones. También se relaciona la energía específica del recurso y la producción de energía según diferentes velocidades y direcciones de viento. Esto último se considera un aporte para la comprensión de la complejidad del modelado físico del viento y la producción de una Microturbina.

Palabras clave: Micro Turbina Eólica, Predicción, LSTM.

1.- INTRODUCCIÓN

En las últimas tres décadas en la industria eléctrica se han producido una serie de desarrollos tecnológicos que han provocado una verdadera revolución en el sector. Por un lado, diferentes procesos de producción/transformación de Energía Eléctrica (EE) a partir de recursos primarios renovables han alcanzado un gran desarrollo con un consecuente impacto en la reducción de costos asociados a su implantación (sistemas eólicos, fotovoltaicos, etc.). Por otro, se está produciendo una acelerada electrificación de diferentes usos finales en sectores que parecían destinados a ser satisfechos solo por recursos fósiles (en movilidad, el incipiente pero acelerado desarrollo de Vehículos Eléctricos; en acondicionamiento de ambientes, bombas de calor; etc.) donde además se alcanzan considerables mejoras en la eficiencia de los procesos de conversión respecto de los tradicionales (motores de combustión interna, calderas, etc.). Las anteriores son las razones fundamentales para inferir que el proceso de Transición Energética hacia un escenario de emisiones netas cero para el 2050 requerirá incrementar notablemente la participación de la energía eléctrica en los sectores de usos finales. En valores aproximados esto significará pasar de una participación actual de la energía eléctrica de un 20 % a un 50 % en la matriz energética global (IEA, 2021).

Si bien los requerimientos de transformación para el sector de la EE afectan tanto a los procesos de generación, transmisión y distribución, en este último es tal vez donde se estén produciendo, y seguramente se profundizarán, profundos cambios. Por un lado, la posibilidad de producir energía eléctrica a pequeña escala a partir de recursos primarios renovables, lo que permite que un usuario demandante de EE pueda generarla e inyectarla en la red. Por otro, la tendencia a electrificar ciertas demandas energéticas que resultan en un significativo incremento de la misma además de una variabilidad atípica para las redes de distribución tradicionales.

A partir de lo anterior es posible inferir la necesidad de mantener la oferta y demanda de energía en un grado de equilibrio que permita garantizar la operación en condiciones estables en aspectos técnicos básicos y otros relacionados con el concepto de operación óptima de la red (Mehigan et al., 2018).

Mientras lo anterior sucede en el sector de la EE, se observa un desarrollo extraordinario en el área de las Tecnologías de la Información y las Comunicaciones (TIC's) facilitando el manejo de grandes volúmenes de información y la posibilidad de gestión de diferentes tipos de sistemas, en particular los energéticos. Esencialmente la aplicación de las TIC's sobre esta nueva concepción de una red eléctrica de distribución actuando de manera inteligente como parte de un sistema de gestión de equilibrio entre generación, consumo y distribución, es lo que se ha dado en llamar Redes Inteligentes (RI) o Smart Grid (SG) (Bani-Ahamed et al., 2018; Ayadi et al., 2020).

La planificación, operación y el análisis del comportamiento de una RI requieren de detallados modelos de los sistemas y predictores de los comportamientos de la demanda y generación y, en determinadas circunstancias, sus respectivas incertidumbres (Khaleh y Laaksonen, 2022; Ahmada et al., 2020).

Otro factor importante en las predicciones energéticas es el horizonte temporal, que está íntimamente ligado al problema abordado. Aunque no existe un acuerdo unánime sobre la categorización de las escalas temporales, es posible distinguir cuatro tipos: pronóstico a muy corto plazo (Very Short-Term Forecasting - VSTF), de minutos a pocas horas; previsión a corto plazo (Short-Term Forecasting - STF), de horas a un día o pocos días; previsión a medio plazo (Medium-Term Forecasting - MTF), de días a meses en un año; y previsión a largo plazo (Long-Term Forecasting - LTF), de varios meses a años (Kaur et al., 2015).

En la misma referencia se observa una pormenorizada clasificación y descripción a partir de cómo se entrenan los modelos y los métodos empleados en estas predicciones, distinguiéndose principalmente tres enfoques. En primer lugar, las técnicas determinísticas, que incluyen los métodos estadísticos tales como los Modelos de Media Móvil Autorregresiva (ARMA) y los de Media Móvil Integrada Autorregresiva (ARIMA), como los más conocidos. En segundo lugar, los métodos de aprendizaje automático (ML - Machine Learning) que abarcan tales como la máquina de vectores de soporte (SVM - Support Vector Machine) y Regresión de vector de soporte (SVR - Support Vector Regression). Y, por último, los métodos de aprendizaje profundo (DL - Deep Learning) que engloban a las Redes neuronales de retroalimentación (FFNN - Feed Forward Neural Networks), Redes neuronales de retropropagación (BPNN - Back-Propagation Neural Networks), Redes neuronales recurrentes (RNN - Recurrent Neural Networks) o Memoria larga a corto plazo (LSTM - Long Short-Term Memory) y Redes neuronales convolucionales (CNN - Convolutional Neural Networks).

Otra importante caracterización general en cuanto a estos métodos y aplicaciones particulares puede verse en (Ahmada et al. 2020).

La necesidad de disponer de herramientas predictivas en la producción de energía de parques eólicos es de gran interés. La posibilidad de participar mediante estas tecnologías compitiendo en un mercado eléctrico spot puede generar ingresos adicionales para los inversores incorporándose en el mercado de reservas. En tal contexto la confiabilidad de los sistemas predictivos es crucial (Jorgensen y Reza, 2020).

Los volúmenes de inversión, los tamaños de los mercados y los contextos geográficos (en general entornos urbanos) de los que pueden formar parte los sistemas MicroEólicos (ME) aún no están concentrando gran atención ya que desde lo económico resultan poco significativos. Sin embargo, el

potencial desarrollo de Micro Mercados Eléctricos (MME) o la gestión de cargas y producción de energía en SG aisladas, entre otras situaciones, permiten inferir un creciente interés en este tipo de aplicaciones orientados a sistemas ME (Zahraoui et al., 2023; Sousa et al., 2019; Maturana et al., 2023).

La predicción confiable de la generación de energía eólica es una tarea compleja, principalmente por su dependencia fundamentalmente de diferentes fenómenos climáticos. Hasta hace poco tiempo los sistemas predictivos estaban basados en modelados estadísticos y físicos del objeto de estudio. En la medida que los fenómenos que se modelan son de mayor complejidad los resultados obtenidos tienden a ser menos confiables. La posibilidad de predecir la producción de un sistema eólico implica la necesidad de modelar un fenómeno meteorológico, como la velocidad y dirección del viento, junto con un dispositivo de captación o conversión energética. En particular tal proceso incrementa su dificultad en el caso de sistemas ME ya que los mismos tienden a localizarse en entornos donde la presencia de diferentes objetos (edificios, arbolados, etc.) perturba notablemente los flujos de viento. Este problema ha sido tratado en (Reja et al., 2022). Las intensidades de las turbulencias ambientales en estos entornos pueden modificar sensiblemente la producción de la turbina según la velocidad o dirección del viento. Más aun, ha sido cuestionada la aptitud de la Norma IEC 61402 en ME ya que en general las condiciones de los vientos en sus entornos típicos de instalación no se corresponden con los asumidos por la referida normativa (Anup et al., 2019).

En la descripción anterior se encuentran en gran medida las razones por las cuales las técnicas basadas en modelados estadísticos y físicos resultan poco eficientes en procesos de predicción frente a los nuevos desarrollos en el campo del ML. Las limitaciones de los modelos físicos frente a métodos basados en Inteligencia Artificial, particularmente las LSTM, son puestas de manifiesto en (Zhang et al., 2014; Xiong et al., 2022)

Son escasos los avances en el área de las predicciones de sistemas ME y en particular cuando se emplea sistemas de ML. La implementación de un modelo LSTM-RNN para la predicción de la velocidad del viento aplicado en una micro red aislada puede verse en (Kumar et al., 2020). Allí se actualiza el estado del modelo con valores observados en lugar de valores predichos para mejorar la precisión. Sin embargo, el trabajo no realiza la predicción directa de energía, lo que puede llevar a errores importantes debido al efecto de las turbulencias en la producción de energía anteriormente mencionado. La mayoría de los estudios en este campo están orientados a grandes sistemas eólicos. Por ejemplo, (Xiong et al., 2022) trabaja con una LSTM híbrida en conjunto con un mecanismo de atención y una CNN. En dicho trabajo se evalúa el desempeño para distintos horizontes de tiempo, comparando varios modelos, incluyendo una red basada puramente en una LSTM. Otros trabajos como (Du, 2019) además, emplean el pronóstico de variables meteorológicas, lo que mejora el rendimiento de los modelos.

El objetivo del presente trabajo es el desarrollo de una herramienta predictiva de corto plazo de producción de energía de una instalación ME basada en una LSTM. El sistema que se propone emplea, por un lado, datos históricos y pronósticos meteorológicos de libre acceso, y por otro, los registros de energía inyectada a la red eléctrica de un sistema ME.

La estructura del trabajo contempla, en primer lugar, una descripción teórica de distintos tipos de redes neuronales y las ventajas del empleo de las LSTM en este tipo de aplicaciones, seguido de una descripción de las características principales del equipo ME y de su instalación: turbina, inversor y medición. Luego se presenta la información meteorológica, histórica y pronosticada, que se usará. Se incluye también una caracterización básica del recurso eólico en el lugar de instalación a partir de la serie histórica de información meteorológica. Posteriormente se describe el proceso para la implementación de un modelo basado en una LSTM y finalmente se muestran los resultados obtenidos.

2.- METODOLOGÍA

2.1.- Redes Neuronales

A continuación, se describe el funcionamiento de una Red Neuronal (NN - Neural Networks) básica y su evolución hasta la configuración y funcionamiento de una NN tipo LSTM que se empleará en el

presente trabajo. También se explicitarán los motivos por los cuales este tipo de herramientas resultan conceptualmente las más indicadas para el propósito en cuestión.

La Figura 1 muestra la topología de una NN básica. En tal representación, las neuronas/nodos son identificadas con círculos y representan la unidad fundamental de una red neuronal, estas reciben entradas, realizan una operación matemática y producen una salida. Las capas están compuestas por neuronas, existen distintos tipos, como la capa de entrada, la cual recibe las características del conjunto de datos, las ocultas, que realizan transformaciones intermedias de los datos (las redes con múltiples capas ocultas se conocen como redes neuronales profundas), y la capa de salida, la cual produce la predicción o resultado final.

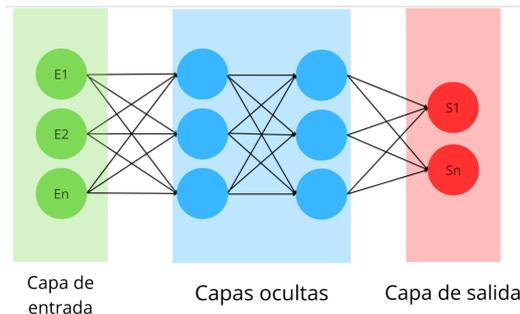


Figura 1: Estructura topológica de una NN.

Cada neurona en la red recibe una serie de entradas ponderadas, las suma y aplica una función de activación (por ejemplo, Sigmoidal) para producir una salida. Esta salida se propaga hacia adelante a través de la red, desde la capa de entrada, a través de las capas ocultas, hasta llegar a la capa de salida. Este proceso es conocido como propagación hacia adelante (Forward Propagation). Después de obtener una salida, se calcula la diferencia entre esta salida y el valor esperado (error) usando una función de pérdida. Luego, la red ajusta las ponderaciones mediante el algoritmo de retropropagación (Back Propagation), que usa el gradiente descendente para minimizar el error en las predicciones.

Esta configuración presenta un par de limitaciones. Por un lado, las NN básicas no tienen memoria, o sea, no pueden recordar la información previa de una secuencia de datos lo que constituye un problema para datos secuenciales, como series temporales. Por otro, durante la retropropagación el gradiente puede volverse muy pequeño dificultando el ajuste de los pesos de las primeras capas, lo que limita su capacidad para aprender dependencias a largo plazo.

Una primera mejora para la aplicación es la introducida por la RNN. Para manejar datos secuenciales la salida de una neurona se retroalimenta como entrada a la misma neurona en el siguiente paso temporal. Dicha topología se presenta en la Figura 2, donde “x” y “o” representan respectivamente la entrada y la salida de información, h representa el estado oculto, U, V Y W representan las matrices de pesos que describen las relaciones entre X-h, h-V y h-h. El estado oculto h es el componente clave para mantener la dependencia dentro de la serie temporal (Aslam et al., 2021).

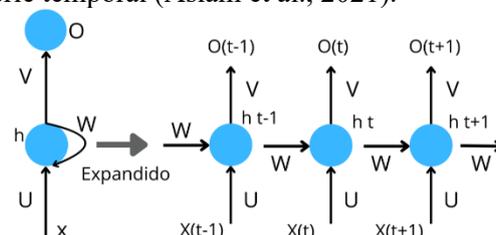


Figura 2: Estructura topológica de una RNN.

A pesar de esto, persiste el problema con dependencias a largo plazo debido al desvanecimiento del gradiente lo que limita su capacidad para recordar información pasada en secuencias largas. Si a una RNN se le introduce un mecanismo denominado celda de memoria, un nuevo estado oculto, junto con puertas de entrada, salida y olvido que controlan el flujo de información será lo que se denomina LSTM. Este esquema permite el manejo de dependencias a largo plazo gracias a estas puertas, pudiendo almacenar y recordar información durante largos periodos, superando el problema del desvanecimiento

del gradiente y mejorando significativamente la capacidad de modelar secuencias temporales complejas. Esta capacidad para manejar dependencias temporales a largo plazo es lo que le confiere un gran potencial en aplicaciones para predicción de series temporales como el caso predicción de producción de energía eólica (Aslam et al., 2021).

En la Figura 3 se describe la estructura topológica básica de una red LSTM: (a) hace referencia a una compuerta de olvido que determina cuanta información se conserva del último estado $C(t-1)$; (b) a una de entrada que determina qué información debe considerarse como entrada para el estado actual; (c) a una compuerta de salida, la cual calcula que información se trata como salida. Mientras que $f(t)$, $i(t)$, y $o(t)$ representan respectivamente los elementos de polarización de estas compuertas. El nuevo estado oculto C , está diseñado para mantener información a largo plazo, mientras que el “h” de la RNN se encarga de mantener información de corto plazo (Aslam et al., 2021).

Las celdas LSTM, como se muestra en la Figura 3, se interconectan para procesar secuencias temporales de una determinada longitud (cada celda corresponde a un instante temporal t). En cada instante de tiempo t , se introduce un conjunto de datos temporales de entrada $x(t)$. Cada celda LSTM procesa esa entrada junto con los estados anteriores $C(t-1)$ y $h(t-1)$, actualizando los valores de $C(t)$ y $h(t)$ en cada paso. De este modo, la información fluye a través de las celdas, capturando dependencias tanto a corto plazo, mediante $h(t)$, como a largo plazo, a través de $C(t)$.

Las fortalezas de las LSTM frente a los modelos físicos se resumen en la Tabla 1. Cabe destacar que las ventajas descritas adquieren mayor relevancia en instalaciones ME donde las condiciones son más desfavorables que las habituales a los emplazamientos de grandes parques eólicos.

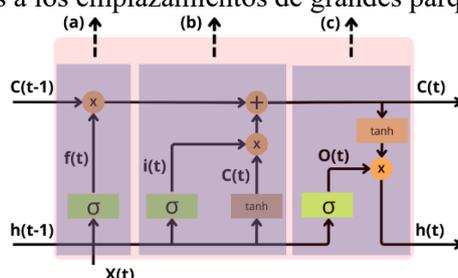


Figura 3: Estructura topológica básica de una red LSTM.

Tabla 1: Cuadro comparativo de fortalezas de las redes LSTM vs Modelos Físicos.

Modelos Físico	LSTM
Dependen de simplificaciones y suposiciones que no siempre reflejarán la naturaleza no lineal del viento y su interacción con las turbinas eólicas.	Capaces de modelar relaciones no lineales complejas, ofrecen una mejor representación de esta realidad.
	Capaces de aprender directamente de los datos históricos de producción de energía y condiciones meteorológicas, sin necesidad de modelar explícitamente todos los procesos físicos
Requieren ajustes específicos para diferentes ubicaciones o configuraciones de las turbinas.	Son más flexibles y pueden ser entrenadas en una variedad de conjuntos de datos facilitando su aplicación en diferentes contextos
Pueden ser muy detalladas, a menudo son computacionalmente intensivas y requieren mucho tiempo de cómputo.	Una vez entrenadas, pueden proporcionar predicciones en tiempo real de manera eficiente

2.2.- Instalación de la Turbina ME

En la Figura 4, se muestra una foto satelital del emplazamiento de la Turbina ME, identificándose la dirección Norte, y tres fotografías: una desde la dirección Norte, otra desde la Noreste y otra desde la Sur, el mismo se encuentra ubicado 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). El objetivo de estas imágenes es percibir los obstáculos que enfrenta el normal flujo del

viento según la dirección que se trate. Se observan dos líneas de arbolados en la dirección Norte y Noreste, a aproximadamente 20 y 40 m de distancia; una de ellas menos perceptible por ser una especie de hoja caduca, con una altura de copa superior en por lo menos 5 m del eje horizontal de la turbina.



Figura 4: Emplazamiento de la Turbina ME.

La turbina ME es aerogenerador EOLUX 1200 48V con potencia nominal de 1200 W a 14 m/s, velocidad de arranque de 4,5 m/s, tiene 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 encuentra sobre un reticulado metálico (12 m) que a su vez se apoya sobre una cubierta de techo (9 m) arriostrada por rienda metálicas. El acoplamiento a la red eléctrica se materializa mediante un inversor ABB UNO-2.0-I-W, cuya tensión de entrada máxima es de 520 V de CC, potencia de conexión a la red de CA 2000 W. Cabe destacar un dispositivo rectificador simple en la entrada. Las diferentes variables eléctricas (tensiones, corrientes, energías, etc.) son registradas por un medidor inteligente Dimet-G (Discar Metering) gestionado por el sistema on line Mr.Dims.

2.3.- Información meteorológica

Uno de las premisas claves de este trabajo ha sido utilizar información de acceso público, histórica como predictiva, para caracterizar las velocidades y direcciones del viento procurando que tales registros sean lo más cercanos posible al emplazamiento de la instalación en cuestión. En tal sentido, se han empleado series históricas de variables meteorológicas como así también sus pronósticos diarios considerando que esta información puede resultar una importante contribución en el proceso de entrenamiento del modelo.

Servicio Meteorológico Nacional (SMN): Desde el Centro de Información Meteorológica dependientes del SMN se han obtenido diversos parámetros registrados en el Aeropuerto Río Cuarto en una estación situada a 2,6 km del emplazamiento de la ME (velocidad y dirección del viento para cada hora de los años 2021 a 2023, medidos a 10 m), SMN (2024).

Observatorio Hidro-Meteorológico de la Provincia de Córdoba (OHMC): Entre otras tareas, este organismo produce cada 12 h una serie de pronósticos hidro-meteorológicos empleando tanto la información del SMN como la brindada por los distintos modelos de pronóstico numérico disponibles. Para la Región Centro, utiliza el modelo WRF (Weather Research and Forecasting) el cual brinda una mejor resolución espacial (menor a 4 km) y es configurable por el usuario. El OHMC emite dos pronósticos diarios: uno a las 6 h y otro a las 18 h. El primero de ellos es a partir de la hora 12 del presente día y por 24 h (este es el utilizado en el trabajo). El pronóstico de velocidad y dirección de viento (bajo el tipo de "Parametrización A" según la denominación del OHMC), para cada hora de los años 2021 a 2023, se emplea en este trabajo, OHMC (2024).

2.4.- Caracterización básica del recurso y su relación con la producción de energía

A partir de la información suministrada por el SMN para cada hora en los años 2021, 2022 y 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 2.

Tabla 2: Magnitudes estadísticas de la velocidad del viento en km/h para 3 años de análisis

Año	Valor medio	Desviación Std.	c-Weibull	k-Weibull
2021	19,32	10,70	1,90	21,77
2022	20,41	11,79	1,81	22,96
2023	18,04	9,61	1,98	20,35

En la Figura 5 se muestra la gráfica de distribución acumulada de probabilidades empleando un escalamiento de bins cada 5 km/h y para los 3 años analizados. También resultan un buen indicador de la regularidad del recurso en el tiempo y que aproximadamente durante la mitad del tiempo no se alcanza la velocidad de arranque de la turbina.

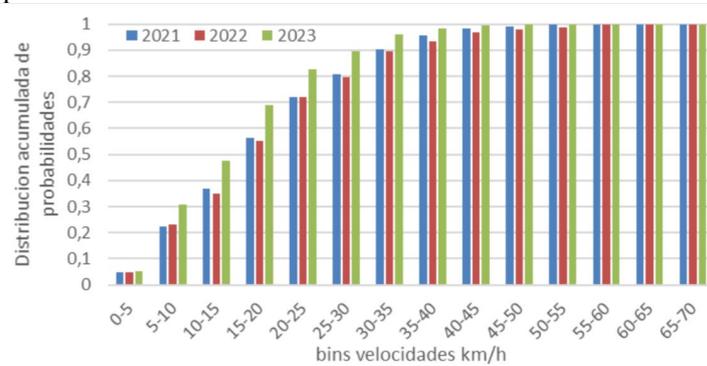


Figura 5: Frecuencia acumulada de velocidad de viento para los tres años.

Procurando identificar el eventual impacto de las condiciones que impone el contorno de la instalación (arbolado y otros aspectos que alteran el normal flujo del viento) se analizarán la energía específica y la EE medida en función de los ocho semivientos. El análisis se basa en la combinación de los datos proporcionados por el SMN con los registros de energía eléctrica del medidor Dimet-G. En una primera instancia la representación gráfica se divide según la velocidad del viento medida se encuentre por debajo o por encima de la velocidad de arranque de la turbina (16,2 km/h). La Figura 6 muestra la producción de energía eléctrica según las diferentes direcciones y según la anterior clasificación respecto a las velocidades. Se puede observar la predominancia de producción en la dirección Norte (aproximadamente 60%) acompañada, en muy menor medida, por las direcciones Sud y Sudoeste (prácticamente el 30% restante). Si bien resulta poco significativo, aproximadamente un 8% del volumen total de energía se corresponde con velocidades del viento medidas que no alcanzan la velocidad de arranque de la turbina.

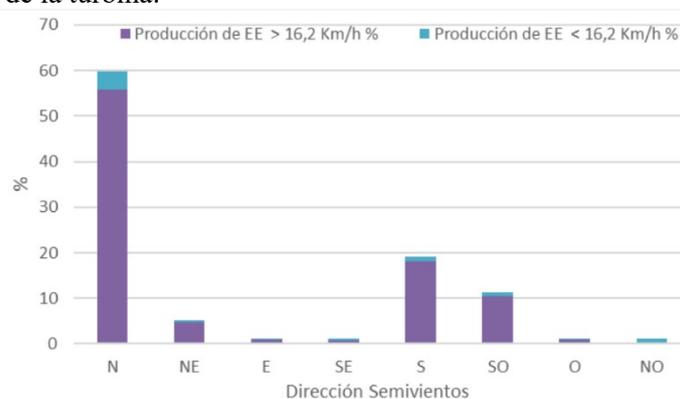


Figura 6: Producción de energía según la dirección y velocidad del viento.

En lo sigue se procura analizar la relación que existe entre la Energía Específica del viento por m² (la mitad del cubo de la velocidad del viento asumiendo una densidad del aire de 1kg/ m³) y la producción de energía eléctrica. La Figura 7 muestra su representación gráfica para velocidades de viento superiores a 16,2 m/s. Puede deducirse que la conversión energética en las direcciones Norte y Noreste es menos eficiente que en las Sud y Sudoeste. Esto podría explicarse a partir de la descripción de las condiciones del entorno del emplazamiento de la turbina a las que se refirió la Figura 4.

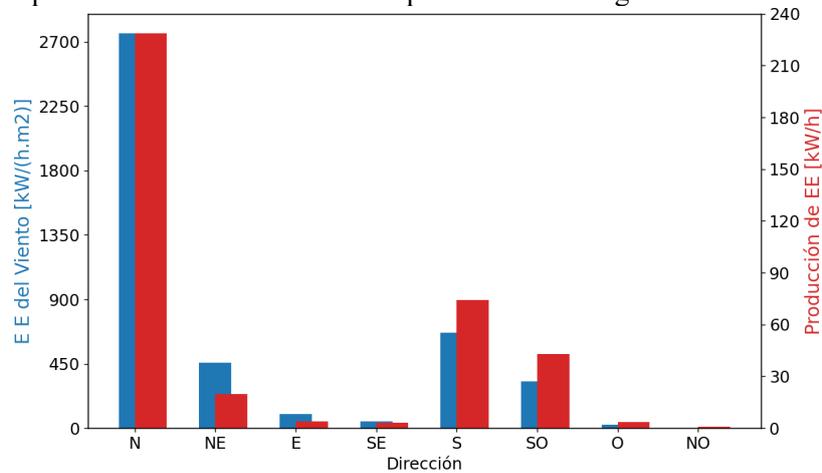


Figura 7: Energía eléctrica y específica del viento para diferentes direcciones.

2.5.- 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 8 h. Este desarrollo se implementó en Python con el uso de las librerías TensorFlow y Keras.

2.5.1.- 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. Se asume un horizonte de predicción de 8 h lo que define la longitud temporal de ventanas de entrenamiento, validación y predicción. Las entradas del modelo son, ventanas de 8 h que cuentan, por un lado, las velocidades y direcciones de viento medidas (SMN) y las producciones de energía sincronizadas medidas, y por otro, las velocidades y direcciones de viento pronosticadas (OHMC).

Las velocidades del viento de las dos fuentes de datos fueron descompuestas en sus componentes x e y. También se empleó como entrada la hora del día codificada, cuya descripción se presentará en la próxima sección.

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. La energía eléctrica para todo el periodo, según la separación presentada anteriormente, se visualiza en la Figura 8.

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).

$$X_{nor} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Para utilizar la variable temporal como entrada y evitar discontinuidades en el modelo, se codificó el tiempo utilizando dos funciones: una senoidal y otra cosenoidal, ambas con un período de 24 h. Esto le

permite al modelo capturar la ciclicidad diaria de los eventos temporales. En las Ecs. (2,3) se presentan dichas codificaciones.

$$dia_sin = \sin\left(\frac{2*\pi*tiempo_s}{dia}\right) \quad (2)$$

$$dia_cos = \cos\left(\frac{2*\pi*tiempo_s}{dia}\right) \quad (3)$$

donde:

tiempo_s = tiempo en segundos desde el inicio de la serie temporal.

dia = 24×60×60 es el número de segundos en un día.

dia_sin = variable temporal codificada.

dia_cos = variable temporal codificada.

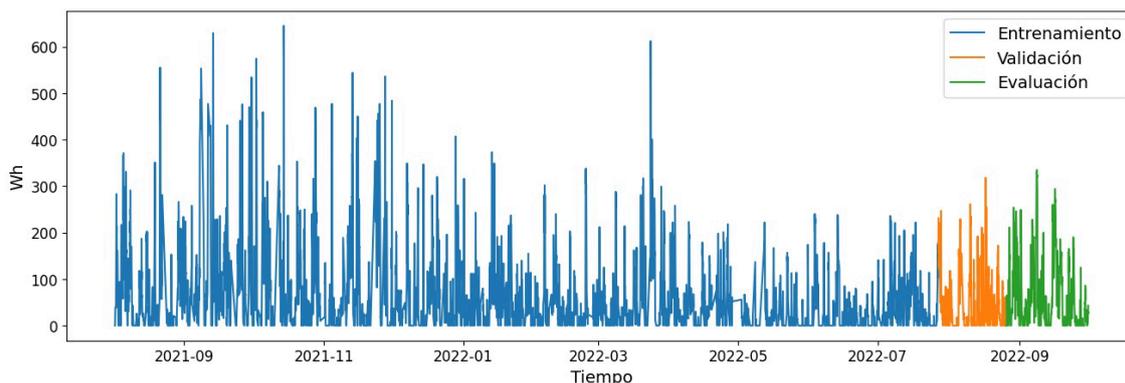


Figura 8: Representación gráfica de la serie temporal de energía eléctrica.

2.5.2.- Función de Pérdida y método de evaluación

Se ha definido como función de pérdida para el entrenamiento a el error cuadrático medio (RMSE). Esta métrica se calcula como la raíz cuadrada del promedio de los cuadrados de las diferencias entre las predicciones y los valores medidos. Este método, también es el utilizado luego para evaluar los resultados con los datos de evaluación y también por los datos de validación para operar durante el entrenamiento.

2.5.3.- Conformación del modelo

El modelo está conformado por una capa LSTM de una determinada cantidad de unidades y una capa densa con activación lineal del tamaño de la secuencia de salida (8 neuronas). Es importante tener en cuenta que la parametrización completa del modelo se presentará en la sección resultados, luego de un proceso de optimización.

Existen una serie de parámetros que se ajustan en la ejecución del modelo. El primero es el número de unidades, o neuronas de la propia LSTM, el segundo, las Epochs (épocas) que refiere a la cantidad de veces que el modelo pasa todo el conjunto de datos en el entrenamiento, el tercero, el BatchSize (o tamaño del lote) que refiere a la cantidad de secuencias que se ejecutarán conjuntamente antes de actualizar los parámetros del modelo. Las unidades son las propias de la capa LSTM, mientras que el optimizador del algoritmo utilizado para minimizar la función de pérdida durante el entrenamiento, fue el Root Mean Square Propagation (RMSprop), el cual requiere la asignación de una tasa de aprendizaje, que define cuanto se ajustan los pesos en cada iteración.

3.- RESULTADOS

Se realizó una optimización del modelo haciendo ajustes sobre los parámetros descritos en la sección anterior con la premisa de reducir el RMSE del conjunto de datos de validación. En la Tabla 3 se presenta la parametrización del modelo seleccionado y los resultados obtenidos. Se destacan valores de RMSE concordantes para los tres conjuntos de datos. Los valores están en por unidad ya que se evaluaron sobre datos normalizados.

En la Tabla 4 se presentan variaciones de los parámetros del modelo y su impacto en los resultados. En relación con el modelo seleccionado (Tabla 3), para el caso 1, se observa que el número de iteraciones o Epochs en el entrenamiento no le permite al modelo converger adecuadamente, lo que conlleva a mayores errores. Una situación similar ocurre en el caso 2, en el que un elevado número de Epochs, logró reducir el RMSE de los datos de entrenamiento, pero generó un sobreajuste, visible en el mayor error sobre los datos de validación y evaluación. En cuanto al cambio en la cantidad de Units, en los casos 3 y 4, se observa que al aumentar o reducir el número de estas respecto al caso testigo aumenta el RMSE de los datos de validación como el de los datos de evaluación. Por último, en el caso 5, al aumentar el tamaño del BatchSize puede estar causando una reducción en la precisión a la hora de actualizar las ponderaciones durante el entrenamiento, lo que conlleva a un incremento del RMSE de los tres conjuntos.

Tabla 3: Parámetros de ajustes y resultados para el modelo seleccionado

Parámetros		Resultados	
Units	150	RMSE Train[pu]	0,193
Optimizer	Rmsprop (lr=4x10 ⁻⁴)	RMSE Vali[pu]	0,173
Epochs	50	RMSE Eval[pu]	0,172
Batch Size	250		

Tabla 4: Variantes de los parámetros del modelo seleccionado

Caso	Units	Epochs	BatchSize	RMSE Train[pu]	RMSE Vali[pu]	RMSE Eval[pu]
1	150	10	250	0,210	0,220	0,184
2	150	600	250	0,168	0,205	0,210
3	130	50	250	0,191	0,174	0,173
4	170	50	250	0,192	0,175	0,173
5	150	50	900	0,209	0,209	0,183

Para una observación visual entre los valores medidos y las predicciones, en la Figura 9 se muestra gráficamente la evolución temporal de ambas magnitudes durante el tramo de evaluación (ultimo 10 % del total de la serie temporal empleada). Naturalmente las predicciones son efectuadas a 8 h.

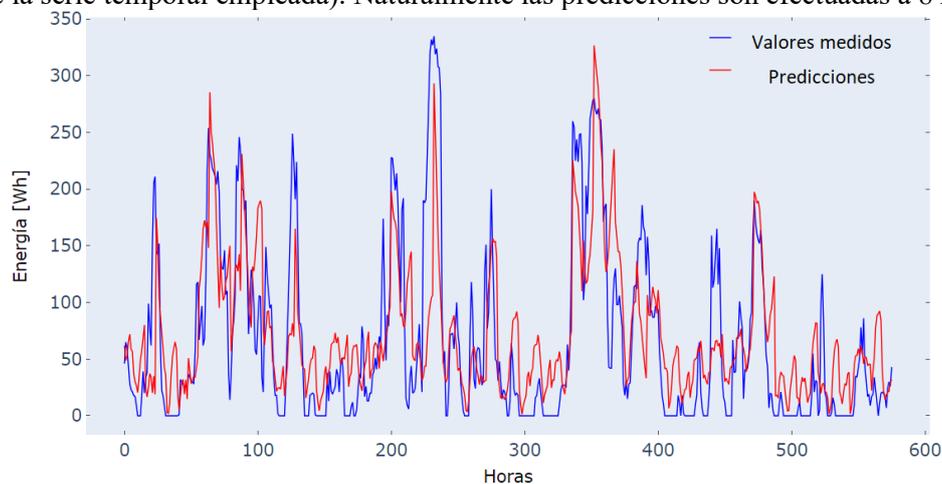


Figura 9: Comparación entre datos medidos y predicciones.

Lo presentado en la Figura 9 permite considerar a los resultados como satisfactorios observándose una clara tendencia de las predicciones a seguir a los datos reales aún en la importante variabilidad de la energía, propia de la del recurso eólico. Por otro lado, en relación al RMSE del conjunto de evaluación, la posibilidad de predecir con un error del 17% la producción de energía de un ME para las próximas 8 h se considera aceptable y presenta un amplio campo de aplicaciones. Por ejemplo, en la administración y gestión de una RI aislada o de un esquema de MME.

4.- CONCLUSIONES

Se ha planteado el rol de la energía eléctrica en el proceso de Transición Energética y el de las RI en la gestión y operación de estos sistemas. Se ha fundamentado la necesidad de disponer de herramientas confiables para la predicción de las distintas variables eléctricas involucradas: las que se refieren a la demanda y, muy especialmente, a las de generación. Se ha argumentado respecto a las limitaciones de los métodos clásicos de predicción y fundamentado la aptitud de las Redes Neuronales tipo LSTM cuando el objeto de estudio es el de las instalaciones ME.

Se ha presentado la implementación de un modelo basado en una red LSTM para la predicción de generación eléctrica de una turbina ME cuyo entrenamiento emplea una serie de datos medidos y pronosticados (ambos de libre acceso), de velocidad y dirección del viento, conjuntamente con datos medidos de generación de energía del sistema ME. Para el entrenamiento, validación y evaluación del modelo se ha empleado la información anterior para cada hora durante 13 meses consecutivos. La posibilidad de predecir con un error del 17% la producción de energía de un ME para las próximas 8 h es muy importante y presenta un amplio campo de aplicaciones, típicamente en la administración y/o gestión de una RI aislada o de un esquema de MME.

Cabe destacar que analizando el recurso con datos de velocidad y dirección del viento asociado a los de energía producida, se consolidan las suposiciones sobre la complejidad que significa un modelado físico de la interacción viento-maquina en los contextos ambientales y geográficos de este tipo de instalaciones. Esto también refuerza la potencial aptitud de los modelos que contengan redes LSTM en estas aplicaciones.

El avance alcanzado, y los resultados obtenidos, permiten considerar la posibilidad de profundizar la línea de trabajo procurando incrementar el horizonte de predicción (por lo menos a 24 h), así como evaluar otras herramientas, técnicas y configuraciones asociadas al ML.

AGRADECIMIENTOS

Al Centro de Información Meteorológica dependientes del Servicio Meteorológico Nacional por facilitar el acceso a sus series históricas de información meteorológica.

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

- 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 Urmee T. (2019). Urban Wind Conditions and Small Wind Turbines in the Built Environment: 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.
- 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).

- 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. <https://doi.org/10.1080/02286203.2020.1767840>.
- 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: 4 de julio de 2024].
- 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.
- SMN [en línea] Parámetros meteorológicos del Aeropuerto Río Cuarto (2021-2023). Servicio Meteorológico Nacional. Dirección URL: <https://www.smn.gob.ar/> [consulta: 6 de agosto de 2024].
- Sousa T., Soares T., Pinson P., Moret F., Baroche T. y Sorin E. (2019). Peer-to-peer and community-based 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.
- 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.

SHORT-TERM PREDICTION OF ENERGY GENERATION OF A MICROWIND TURBINE USING LONG SHORT-TERM MEMORY NEURAL NETWORKS

ABSTRACT The importance of Smart Grids in the context of the Energy Transition is justified. Forecasting, of production or demand, play a key role for different types of analysis or operation of this type of networks. The different techniques used to solve this problem are described and Neural Networks, particularly Long Short-Term Memory, are highlighted. From this, the objective is to develop a short-term predictive tool for energy production of a MicroWind installation based on a Long Short-Term Memory. For training, data on wind speed and direction are used, recorded by the National Meteorological Service and by the Hydro-Meteorological Observatory of Córdoba, in the first case records of historical information and in the second, forecasts of such parameters for the following day. In both cases, the information is freely available. The energy generated by a MicroWind is used to complement the training data. Promising results are shown in the predictions. The specific energy of the resource and the energy production according to different wind speeds and directions are also related. The latter is considered a contribution to the understanding of the complexity of physical modeling of the wind and the production of a MicroWind.

Keywords: MicroWind, Forecasting, LSTM.