

Estimación del *fore-aft* de un aerogenerador mediante Redes Neuronales Recurrentes

Marcos David Saavedra
Grupo de Control Aplicado (GCA)
Instituto LEICI (UNLP-CONICET)
Facultad de Ingeniería, UNLP
 La Plata, Argentina
 saavedramarcosdavid@ext.ing.unlp.edu.ar

Bernabé Ibáñez
Grupo de Control Aplicado (GCA)
Instituto LEICI (UNLP-CONICET)
Facultad de Ingeniería, UNLP
 La Plata, Argentina
 bernabe.ibanez@ing.unlp.edu.ar

Fernando Ariel Inthamoussou
Grupo de Control Aplicado (GCA)
Instituto LEICI (UNLP-CONICET)
Facultad de Ingeniería, UNLP
 La Plata, Argentina
 intha@ing.unlp.edu.ar

Fabrizio Garelli
Grupo de Control Aplicado (GCA)
Instituto LEICI (UNLP-CONICET)
Facultad de Ingeniería, UNLP
 La Plata, Argentina
 fabrizio@ing.unlp.edu.ar

Resumen—La estimación en línea y precisa del desplazamiento *fore-aft* en aerogeneradores es esencial para su control y monitoreo, representando un desafío debido a su complejo comportamiento dinámico. Los métodos analíticos tradicionales requieren modelos de alta fidelidad difíciles de obtener en sistemas no lineales y altamente complejos. En este trabajo, se presenta un estimador basado en una Red Neuronal Recurrente (RNN) entrenada con datos operativos de un aerogenerador simulado. La metodología propuesta utiliza únicamente cinco señales eléctricas de fácil medición como entrada para estimar el movimiento *fore-aft* de la torre. Con el propósito de determinar las variables a medir para este fin, se propone la realización de un análisis de matrices de correlación. Los resultados obtenidos son satisfactorios para todo el rango de operación del aerogenerador. Este enfoque, basado en Inteligencia Artificial y apoyado en el análisis de correlación para la asignación de variables de entrada, ofrece una alternativa prometedora para abordar la estimación dinámica en este tipo de sistemas complejos al aprender las relaciones temporales directamente de los datos.

Palabras Clave—Aerogenerador, Redes Neuronales Recurrentes, Estimación dinámica, *Fore-aft*, Aprendizaje Automático

I. INTRODUCCIÓN

El cambio climático asociado a la emisión de gases de efecto invernadero está teniendo un impacto aún más rápido de lo previsto. Debido a esto, los esfuerzos dedicados a incrementar la generación de energía a través de recursos renovables son cada vez mayores a lo largo de todo el planeta. Dentro de la generación renovable, la energía eólica es la más desarrollada de su tipo (junto a la solar fotovoltaica) con una potencia instalada global de 934 GW [1]. Particularmente en Argentina, las renovables han cubierto un 13,9 % de la generación durante 2022, alcanzando picos mensuales del 18 % [2].

La evolución de la energía eólica se caracteriza por un notable aumento en el tamaño de los aerogeneradores, lo cual ha generado la necesidad de emplear materiales cada vez más ligeros y, en consecuencia, estructuras más flexibles. Como resultado de este crecimiento, al objetivo clásico de maximizar la producción de energía se le ha añadido el de reducir las cargas mecánicas presentes en los aerogeneradores. Esto no solo prolonga su vida útil sino que también reduce el costo de la energía generada, por lo que resulta de suma importancia contar con medidas y/o estimaciones precisas de las cargas mecánicas que se producen en un aerogenerador. Dichas mediciones son fundamentales para llevar a cabo análisis detallados de cargas, el monitoreo durante el funcionamiento y el diseño de controladores eficaces [3], [4].

Los métodos convencionales de estimación, como los observadores de Luenberger o los filtros de Kalman extendidos, han sido tradicionalmente empleados en la estimación de variables en sistemas dinámicos complejos. Estas técnicas de estimación clásica han sido estudiadas exhaustivamente. Por ejemplo, en Ritter et al. [5], se investigan diversas técnicas de filtrado no lineal, incluyendo filtros de Kalman lineales y no lineales, como el filtro de Kalman extendido (EKF) y otros como el filtro de Kalman sin derivadas (UKF), el filtro de Kalman de diferencia central (CDKF) y el *Cubature Kalman Filter* (CKF). Además, se presenta un observador distribuido que combina técnicas de filtrado no lineal de bajo y alto orden para estimar la velocidad del viento, los estados dinámicos de la torre (oscilaciones y velocidades rotacionales), identificación en línea de parámetros inciertos y cargas de fatiga.

Sin embargo, estos métodos clásicos dependen de modelos matemáticos de alta fidelidad que pueden ser difíciles de obtener cuando la dinámica del sistema es intrínsecamente no lineal y altamente compleja. En contraste, el enfoque basado en datos permite aprender dicha dinámica directamente a partir de los datos operacionales, sin necesidad de un modelado analítico detallado. Se ha demostrado que es posible emplear alternativas basadas en datos para la estimación de cargas mecánicas de fatiga en aerogeneradores. Por ejemplo, en [6] se presenta un estimador de tasa de daño acumulativo por fatiga a largo plazo en aerogeneradores marinos. Este enfoque utiliza una Red Neuronal Feedforward que incorpora conocimiento físico del sistema durante el entrenamiento para mejorar su precisión. Asimismo, en [7] se presenta un método basado en *Support Vector Regression* para predecir cargas por fatiga (en la torre, las palas y el buje) y producción energética en aerogeneradores bajo control de yaw.

Si bien estas técnicas han demostrado ser efectivas, dependen puramente de datos actuales, sin considerar comportamientos temporales pasados. Debido a esto, la evolución de los métodos de estimación ha llevado a enfoques más sofisticados que pueden capturar las dependencias temporales existentes en los datos. Un ejemplo representativo se encuentra en [8], donde se propone un método basado en un tipo especial de Red Neuronal Recurrente (RNN) conocido como Redes Neuronales de Memoria a Corto y Largo Plazo (LSTM), para la estimación de la velocidad del viento en un aerogenerador.

En este trabajo se presenta un estimador basado en una RNN diseñado para reconstruir el desplazamiento *fore-aft*

en el extremo superior de la torre de un aerogenerador. Una característica distintiva del estimador desarrollado es su capacidad para funcionar efectivamente utilizando un conjunto reducido de señales de entrada fácilmente medibles, en su mayoría correspondientes a variables eléctricas. Se detalla el proceso de selección de dichas señales, fundamentado en el análisis de correlación de los posibles datos de entrada con respecto a la variable objetivo que se pretende estimar. Además, se demuestra que la RNN propuesta puede ofrecer estimaciones precisas en las distintas regiones de operación del aerogenerador, utilizando únicamente estas pocas señales indispensables, sin requerir un excesivo número de sensores adicionales a los comúnmente utilizados en el lazo de control de un aerogenerador. Los datos utilizados en el entrenamiento del estimador fueron generados a partir de un simulador de alta fidelidad ampliamente aceptado y certificado para la simulación de aerogeneradores [9].

El resto del artículo se organiza de la siguiente manera. En la Sección II, se detalla el sistema bajo estudio, donde se especifica el aerogenerador utilizado y la variable a estimar. A continuación, en la Sección III, se detalla la metodología y tipo de red neuronal empleada en el desarrollo del estimador. Los resultados del trabajo se presentan y discuten en la Sección IV. Finalmente, en la Sección V, se exponen las conclusiones de la propuesta, donde se destacan las principales fortalezas del enfoque y se plantean posibles líneas de trabajo futuro.

II. SISTEMA BAJO ESTUDIO

El sistema analizado en este trabajo corresponde al aerogenerador de referencia de 5MW desarrollado por el National Renewable Energy Laboratory (NREL) [10]. Este modelo de referencia provee una representación realista de un aerogenerador de gran tamaño de tres palas con eje horizontal. Su operación es regulada por el controlador de referencia cuyos detalles se encuentran definidos en [11]. Dicho esquema de control incluye un controlador de referencia de par que emplea una *look-up-table* o tabla de búsqueda (LUT), en conjunto con un controlador proporcional-integral (PI) de ganancia tabulada y su respectiva estrategia *anti-windup* para el control de *pitch*, mientras que la referencia de *yaw* se mantiene constante.

La operación del aerogenerador usualmente se divide en tres regiones definidas por la velocidad del viento. En cada una de estas regiones los objetivos de control son distintos, lo que conlleva diferentes comportamientos de los controladores de par y de *pitch*. Para bajas velocidades de viento (Región 1), el *pitch* se fija en un ángulo óptimo, mientras que el control de par sigue la curva de máxima potencia. A altas velocidades de viento (Región 3), el control de *pitch* regula la velocidad de rotación en su valor nominal, con el par constante también en su valor nominal. Existe una región de transición (Región 2), donde interactúan ambos controladores. Dicha región resulta crítica debido a que es donde suelen producirse los mayores esfuerzos y transitorios.

La variable objetivo a estimar es el desplazamiento *fore-aft* (adelante-atrás) en la góndola del aerogenerador. Este movimiento se genera debido a las fuerzas aerodinámicas no




Figura 1: Esquema del movimiento *fore-aft* de la torre de un aerogenerador.

estacionarias sobre el rotor, que inducen vibraciones longitudinales en la torre. Debido a la naturaleza turbulenta del viento, estas fuerzas varían constantemente en magnitud y dirección [12]. Además, si la frecuencia de las cargas aerodinámicas se acerca a la frecuencia natural de la estructura en la dirección longitudinal, se puede inducir resonancia que amplifica el desplazamiento *fore-aft*.

En la Figura 1 se presenta un esquema del aerogenerador, donde se indica mediante flechas el movimiento que se desea estimar, específicamente, el desplazamiento *fore-aft*. Esta oscilación tiene un impacto directo en las cargas de fatiga y extremas del sistema, por lo que su estimación resulta relevante tanto para el control activo de oscilaciones como para el monitoreo estructural del aerogenerador.

III. ESTIMACIÓN MEDIANTE REDES NEURONALES

En esta sección se describen los principios detrás del estimador propuesto, la generación de los datos utilizados para sintonizarlo y el esquema de entrenamiento seguido.

III-A. Redes Neuronales Recurrentes

Dado el complejo comportamiento dinámico no lineal presente en el sistema bajo estudio, se ha optado por emplear una RNN como estimador. Las RNN son un tipo de Red Neuronal Artificial capaces de modelar relaciones secuenciales entre los datos. A diferencia de las redes *feedforward* convencionales, las RNN incorporan conexiones recurrentes en su capa oculta, permitiéndoles mantener un estado interno en cada neurona a lo largo del tiempo, tal como se ilustra en la Figura 2. Este estado funciona como una especie de memoria dinámica que puede capturar información relevante de pasos de tiempo previos, y no sólo del instante actual. De esta forma, se puede pensar a las neuronas de la capa oculta de una RNN como estados en un modelo de de Espacio de Estados No Lineal, cuya dinámica está determinada por [13]:

$$\begin{aligned} h_k &= \mathcal{H}(W_{uh}u_k + W_{hh}h_{k-1} + b_h), \\ y_k &= W_{hy}h_k + b_y, \end{aligned} \quad (1)$$

donde h_k , u_k e y_k denotan el vector de estados ocultos, la entrada y la salida en el instante k respectivamente, W_{uh} , W_{hh} , W_{hy} son matrices de pesos, b_h y b_y son términos de sesgo y \mathcal{H} es una función de activación no lineal.

La capacidad de las RNN para procesar información histórica es fundamental para estimar el *fore-aft*, ya que su valor en un punto dado depende fuertemente de los valores pasados




Figura 2: Diagrama esquemático de una RNN simple.

debido a la inercia del sistema. Cabe aclarar que, si bien el entrenamiento de las RNN puede resultar complejo debido a sus dinámicas no lineales, una vez que el modelo es adecuadamente ajustado y optimizado, la inferencia para nuevos datos no demanda un alto costo computacional ni de memoria. Es decir, la ejecución en tiempo real del modelo ya entrenado es sencilla, pese al comportamiento dinámico que replica.

III-B. Selección de las variables de entrada

Con el objetivo de lograr una estimación precisa del desplazamiento *fore-aft*, se ha llevado a cabo un análisis estratégico de las variables de entrada, seleccionando cuidadosamente aquellas que pueden proporcionar información relevante para este propósito. En el enfoque implementado se buscó utilizar variables que clásicamente están disponibles para el control del aerogenerador.

A partir de la disponibilidad de estas señales, se identificaron aquellas que demostraron una correlación significativa. Este proceso involucró la realización de un análisis de correlación, donde se evaluó la relación entre las diversas variables de entrada posibles y el desplazamiento *fore-aft* empleando los índices de correlación de Spearman. Esta elección se basó en la presencia de no linealidades inherentes en los datos, lo que respaldó la preferencia de este enfoque frente al que utiliza los índices de correlación de Pearson, que además asumen normalidad en la distribución de las variables utilizadas.

Se examinaron las matrices de coeficientes de correlación para las tres regiones de operación del aerogenerador. Dichas matrices proporcionaron una visión detallada de cómo las variables de entrada se relacionan entre sí y con el desplazamiento *fore-aft* en cada una de estas regiones.

De esta manera, se seleccionaron cinco variables de entrada que contienen información de la respuesta ante las condiciones aerodinámicas y estructurales del aerogenerador. Entre estas variables se incluyen aquellas que provienen directamente del sistema de control, como la velocidad de rotación del generador, el par eléctrico generado y el ángulo de *pitch* de las palas, que desempeñan un papel fundamental al brindar información útil en las distintas regiones de operación del aerogenerador. Además, se han incorporado mediciones del anemómetro en la góndola para capturar la velocidad del viento y la aceleración (absoluta) registrada en la parte superior de la torre, una magnitud estrechamente vinculada con el desplazamiento que se pretende estimar.

Acrónimo	Significado
GenTq	Par eléctrico del generador.
GenSpeed	Velocidad angular del generador.
BldPitch	Ángulo de paso de las palas.
WindVxi	Componente del viento en dirección frontal.
YawBrTAXp	Aceleración absoluta en la parte superior de la torre, orientación longitudinal.
TTDspFA	Deflexión (relativa a la posición no deformada) en la parte superior de la torre (en el eje del fore-aft).

Tabla I: Acrónimos y sus significados en español.

En la Tabla I se detallan los acrónimos utilizados para las variables que intervienen en la estimación, tanto las entradas como la salida, acompañados de sus respectivos significados.

La Figura 3 muestra las matrices de correlación que reflejan las relaciones y tendencias observadas. Se debe prestar especial atención a la última fila (o columna) de cada matriz, ya que refleja la correlación frente a la variable objetivo (*TTDspFA*). Cabe destacar que el análisis de correlación no implica causalidad. Cuando dos variables están correlacionadas, simplemente significa que existe una relación estadística entre ellas, pero no se puede afirmar que una variable cause cambios en la otra. El vínculo que encuentran estas observaciones se refiere a la tendencia de ambas variables de cambiar conjuntamente. Una correlación positiva entre dos variables indica que tienden a aumentar o disminuir al mismo tiempo, mientras que una correlación negativa sugiere que cuando una variable aumenta, la otra tiende a disminuir, y viceversa. Sin embargo, esta perspectiva proporciona una indicación inicial de la importancia de cada característica al establecer relaciones con la señal a estimar.

Se puede observar que en la Región 1 existe una correlación fuerte (de -0,74) entre la variable de aceleración en la góndola (*YawBrTAXp*) y el *fore-aft*, demostrando que dicha señal aporta información relevante sobre la oscilación en estudio. Luego se presentan correlaciones moderadas con las demás variables, a excepción del *pitch*, que en esta región se encuentra inactivo. En la Región 2, las correlaciones son en general fuertes, con coeficientes altos (mayores a 0,70) para las variables relacionadas al generador y al viento. Además, se puede señalar una correlación débil para las variables de *pitch* y la aceleración *YawBrTAXp*. Finalmente en la Región 3, la inactividad del control de par resulta en una baja correlación de las variables relacionadas. A diferencia del *pitch*, que tiene el coeficiente más significativo, seguido de la aceleración *YawBrTAXp* y la velocidad del viento.

Si bien en la Figura 3 se presentan los valores de los coeficientes de Spearman relacionados a la señal a estimar, también se han analizado las matrices de correlación calculadas para las componentes de baja frecuencia y para las componentes cercanas a la frecuencia de resonancia de la torre. Como era de esperar, para las componentes de baja frecuencia las variables con mayor influencia están relacionadas con el par del generador, el *pitch* y la velocidad del viento, teniendo éstas además distinta incidencia según la región de operación. Por ejemplo, el par del generador consigue un coeficiente

de 0,96 en la Región 1 y -0,09 en la Región 3. Por su parte, el *pitch* que se encuentra inactivo en la Región 1 no presenta correlación alguna, llegando a -0,5 en la Región 3. Esto marca la importancia de estas variables para identificar la región de operación del aerogenerador. En cambio, para las componentes cercanas a la resonancia, sólo presenta una correlación significativa la aceleración *YawBrTExp*. El análisis más detallado de estas interacciones en los distintos rangos de frecuencia queda fuera del alcance de este trabajo.

La RNN implementada utiliza únicamente las cinco señales seleccionadas para aprender y estimar la dinámica que relaciona dichas variables de entrada con el desplazamiento *fore-aft*. Es importante señalar que se trata de un conjunto de variables fácilmente medibles obtenidas, en su mayoría, directamente desde el sistema de control del aerogenerador, eliminando la necesidad de sensores adicionales.

III-C. Generación de datos y esquema de entrenamiento

Los datos fueron generados mediante el software Fatigue, Aerodynamics, Structures, and Turbulence (FAST) desarrollado por NREL [9]. FAST permite realizar simulaciones dinámicas, resolviendo las ecuaciones complejas de movimiento acoplado entre aerodinámica, elasticidad, controles y turbulencia. Se trata de un software de alta fidelidad que posibilita la obtención de respuestas realistas para el entrenamiento de modelos basados en datos.


El conjunto de datos de entrenamiento se obtuvo a partir de 6 simulaciones, cada una de 10 minutos de duración. Estas simulaciones comprendieron dos semillas diferentes con la misma media de viento para cada región de operación del aerogenerador, con velocidades medias de 6 m/s, 11 m/s y 16 m/s. La generación de vientos realistas se realizó utilizando Turbsim [14] con una clase de turbulencia B.

El conjunto de validación, por su parte, se generó con 3 simulaciones adicionales de 10 minutos por región no usadas en el entrenamiento, con medias de velocidad de 7 m/s, 12 m/s y 17 m/s. Mediante esta estrategia, se pretende evaluar la capacidad de la RNN entrenada para realizar estimaciones precisas en presencia de datos totalmente nuevos, los cuales son representativos de cada región de operación.


De este modo, el conjunto de entrenamiento abarca múltiples condiciones operativas, permitiendo que la red neuronal aprenda las relaciones dinámicas independientemente del régimen de funcionamiento actual.

Cabe aclarar que ambos conjuntos de datos provienen de la simulación del comportamiento del aerogenerador descrito en la Sección II, ante las variaciones del flujo de aire correspondiente a los vientos realistas generados. La dinámica presente en los resultados de estas simulaciones refleja la interacción del viento con el aerogenerador y los modos propios de la estructura contemplados en el modelo utilizado por el simulador.


Además, con el objetivo de facilitar el entrenamiento de la red neuronal, los datos de las variables de entrada fueron normalizados utilizando el método min-max para escalar los datos



(a) Región 1 (6 m/s).



(b) Región 2 (11 m/s).



(c) Región 3 (16 m/s).

Figura 3: Matrices de Correlación para las tres regiones de operación del aerogenerador.

entre 0 y 1. De esta forma, se evitan problemas numéricos asociados a explosiones o desvanecimientos del gradiente durante el entrenamiento del modelo, mejorando la convergencia del proceso de optimización de los pesos sinápticos de la red. La operación se aplicó de forma independiente a cada señal de entrada en los conjuntos de entrenamiento y prueba, utilizando exclusivamente los datos de entrenamiento como base. Así, la operación de normalización para cada señal de entrada x de ambos conjuntos de datos se realizó según la fórmula:

$$\text{Señal normalizada} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (2)$$




Figura 4: Esquema del estimador RNN desarrollado.

donde x_{\min} y x_{\max} representan respectivamente los valores máximo y mínimo obtenidos de la señal x de los datos de entrenamiento.

III-D. Modelo del estimador

El modelo de RNN para la estimación del desplazamiento *fore-aft* se implementó utilizando el *toolbox* de Deep Learning de Matlab®. Este conjunto de herramientas proporciona funciones y arquitecturas diseñadas para el desarrollo de redes neuronales profundas.

Particularmente, se utilizó la función *layrnet* para construir una RNN completamente conectada con una capa recurrente oculta que emplea funciones de activación tangente hiperbólica (TanH). En este caso, solo fueron necesarias 8 neuronas ocultas y se consideraron las últimas 4 muestras temporales para retroalimentar el estado oculto. Dicha configuración permitió capturar las dependencias temporales necesarias para estimar con una precisión aceptable el comportamiento del *fore-aft*. En la Figura 4 se muestra un diagrama esquemático del modelo, el cual fue generado utilizando las herramientas de visualización del *toolbox*.

Para entrenar la RNN, se empleó el algoritmo de retropropagación a través del tiempo. El método calcula los gradientes de la función de pérdida a lo largo de los pasos de tiempo elegidos, con el propósito de optimizar los pesos sinápticos. El objetivo de esta optimización es minimizar el Error Cuadrático Medio (MSE) utilizado como funcional de costo.

El modelo resultante constituye un estimador dinámico no lineal que, en cada instante de tiempo, estima el desplazamiento *fore-aft* a partir de las variables de entrada mencionadas en la Sección III-B.

IV. RESULTADOS

A continuación se presentan los resultados del desempeño alcanzado por el estimador basado en RNN propuesto para la predicción del desplazamiento *fore-aft*. Se analizan las estimaciones generadas a partir de los datos de validación para evaluar la calidad de la generalización del modelo.

En la Figura 5a se presentan los resultados correspondientes a la región de baja velocidad de viento (7 m/s). En el cuadro superior se compara el *fore-aft* obtenido mediante simulación (en azul) con la estimación realizada por la RNN (en naranja). En el cuadro inferior se ilustra el error de predicción.

De manera similar, en las Figuras 5b y 5c se exponen los resultados para las regiones de velocidad media (12 m/s) y alta (17 m/s) de viento, respectivamente.

Métrica	Regiones		
	Región 1 (7 m/s)	Región 2 (12 m/s)	Región 3 (17 m/s)
MSE	0,00030	0,00027	0,00028
MAE	0,01328	0,01213	0,01310
MAPE	7,69500	5,18305	5,90142
R^2	0,83211	0,96428	0,81115

Tabla II: Métricas de evaluación del modelo en las tres regiones de operación.

Cabe aclarar que, si bien en dichas figuras se muestran solo 100 segundos para cada región de operación a fin de mejorar la comparación visual, el análisis de desempeño del estimador efectivamente consideró la totalidad de los datos de validación de 10 minutos por región.

Además, en la Tabla II se resumen las métricas de desempeño obtenidas por el estimador en cada región: MSE, Error Absoluto Medio (MAE), Error porcentual absoluto medio (MAPE) y Coeficiente de Determinación (R^2).

Como se puede observar, el estimador propuesto funciona satisfactoriamente para todas las regiones de operación. Tanto los valores del MSE como del MAE son reducidos, lo que indica que las diferencias entre las predicciones y los valores reales son mínimas. La métrica MAPE también es baja en todas las regiones, señalando un error porcentual mínimo en relación a los valores reales medidos (entre un 5,2 % y un 7,7 %). Por otro lado, el coeficiente de determinación R^2 alcanza valores cercanos a 1, indicando que logra explicar de manera satisfactoria la variabilidad de la señal objetivo.


Se destaca un mejor comportamiento para la Región 2, seguido de la Región 3, debido a que el estimador cuenta con mayor información en la entrada. En el primer caso, se encuentran activos los controladores de *pitch* y de par reflejándose esta información en las entradas asociadas. Mientras que para la Región 3, solo el controlador de *pitch* está activo. Por último, se puede señalar que en la Región 1, la RNN dispone de una menor cantidad de información disponible al estar el *pitch* inactivo y existir una relación de dependencia entre la velocidad de rotación y el par del generador.

De este modo, el esquema de entrenamiento y validación permitió evaluar la habilidad del modelo para estimar adecuadamente el *fore-aft* en condiciones variadas, más allá de los datos específicos de entrenamiento.


CONCLUSIONES

En este trabajo se ha presentado un estimador del desplazamiento *fore-aft* en aerogeneradores basado en Redes Neuronales Recurrentes. La metodología propuesta aprovecha la capacidad de las RNN para modelar relaciones temporales complejas entre variables, lo cual resulta idóneo para estimar el comportamiento dinámico del *fore-aft*.


A diferencia de estimadores analíticos tradicionales, la solución basada en RNN evita la necesidad de modelos matemáticos de alta precisión, aprendiendo directamente la dinámica del sistema a partir de los datos operacionales. Además, la propuesta posee el potencial para continuar el entrenamiento en línea, lo que permitiría adaptar la red y



(a) Resultados en Región 1, velocidad media de viento 7 m/s.



(b) Resultados en Región 2, velocidad media de viento 12 m/s.



(c) Resultados en Región 3, velocidad media de viento 17 m/s.

Figura 5: Visualización de la estimación *fore-aft* de la RNN para cada región de operación. Cuadro superior: comparación de la señal original (azul) con la estimada (naranja). Cuadro inferior: error de estimación.

capturar las posibles variaciones entre aerogeneradores, como así también diferencias que puedan surgir debido a los distintos emplazamientos. Esto representa una ventaja significativa en términos de flexibilidad y robustez.

Otra contribución relevante ha sido el análisis basado en índices de correlación de Spearman para la cuidadosa selección del conjunto de variables empleadas en el entrenamiento de estimadores basados en RNN. De esta manera, al seleccionar las señales más relevantes y sencillas de medir, se prescindió del uso de sensores adicionales a los comúnmente utilizados para el control, lo que podría facilitar la implementación en aplicaciones reales.

Los resultados alcanzados demuestran la efectividad del estimador para reconstruir la oscilación *fore-aft* en todo el rango de operación del aerogenerador, a partir de solo cinco señales de entrada.

Como trabajos futuros, podría explorarse la posibilidad de extender el enfoque a la estimación del movimiento lateral de la torre y posteriormente, a las deflexiones de las palas. Dicha ampliación contribuiría a lograr una estimación más completa de las cargas aerodinámicas del aerogenerador.

AGRADECIMIENTOS

Este trabajo fue financiado por Universidad Nacional de La Plata (UNLP) (Proyecto I258/I253) y CONICET (PIP112-202001-00331/02595).

REFERENCIAS

- [1] "Wwea annual report 2022," https://wwindea.org/wp-content/uploads/2023/03/WWEA_WPR2022.pdf, 2022, documento en línea.
- [2] "Cammesa informe anual 2022," <https://cammesaweb.cammesa.com/?wpdmdl=45057>, 2022, documento en línea.
- [3] Y. Yuan, X. Chen, and J. Tang, "Multivariable robust blade pitch control design to reject periodic loads on wind turbines," *Renewable Energy*, vol. 146, pp. 329–341, 2020.
- [4] B. Ibáñez, F. Inthamoussou, and H. De Battista, "Wind turbine load analysis of a full range lpv controller," *Renewable Energy*, vol. 145, pp. 2741–2753, 2020.
- [5] B. Ritter, A. Schild *et al.*, "The design of nonlinear observers for wind turbine dynamic state and parameter estimation," *Journal of Physics: Conference Series*, vol. 753, no. 5, p. 052029, sep 2016.
- [6] F. de N Santos, P. D'Antuono *et al.*, "Long-term fatigue estimation on offshore wind turbines interface loads through loss function physics-guided learning of neural networks," *Renewable Energy*, vol. 205, pp. 461–474, 2023.
- [7] R. He, H. Yang *et al.*, "A machine learning-based fatigue loads and power prediction method for wind turbines under yaw control," *Applied Energy*, vol. 326, p. 120013, 2022.
- [8] P. Chen and D. Han, "Effective wind speed estimation study of the wind turbine based on deep learning," *Energy*, vol. 247, p. 123491, 2022.
- [9] J. M. Jonkman, M. L. Buhl *et al.*, *FAST user's guide*. National Renewable Energy Laboratory Golden, CO, USA, 2005, vol. 365.
- [10] J. Jonkman, S. Butterfield *et al.*, "Definition of a 5-mw reference wind turbine for offshore system development," National Renewable Energy Lab.(NREL), Golden, CO (United States), Tech. Rep., 2009.
- [11] M. H. Hansen, A. D. Hansen *et al.*, "Control design for a pitch-regulated, variable speed wind turbine," Tech. Rep., 2005.
- [12] M. H. Hansen, "Aeroelastic instability problems for wind turbines," *Wind Energy*, vol. 10, no. 6, pp. 551–577, 2007.
- [13] O. P. Ogunmolu, X. Gu *et al.*, "Nonlinear systems identification using deep dynamic neural networks," *CoRR*, vol. abs/1610.01439, 2016.
- [14] B. Jonkman, "Turbsim," National Renewable Energy Laboratory (NREL), Tech. Rep., 2016.