



9th International Interdisciplinary Congress on Renewable Energies, Industrial Maintenance, Mechatronics and Informatics

Booklets



RENIECYT - LATINDEX - Research Gate - DULCINEA - CLASE - Sudoc - HISPANA - SHERPA UNIVERSIA - Google Scholar DOI - REDIB - Mendeley - DIALNET - ROAD - ORCID - VJLEX

Title: Wind speed forecasting one step ahead using different input vectors in a neural network

Authors: Cadenas, Erasmo, Méndez, Alma-Rosa, Arreola-Sixtos, Antonio and Campos, Rafael

Editorial label ECORFAN: 607-8695
BCIERMMI Control Number: 2024-01
BCIERMMI Classification (2024): 241024-0001
RNA: 03-2010-032610115700-14
Pages: 18

ROR Universidad Michoacana de San Nicolás de Hidalgo	8655-2023	ID	0000-0002-1553-0042	68542
ROR Universidad Autónoma de Coahuila	3038-2024	ID	0000-0002-4202-3804	557619
ROR Universidad Autónoma de Coahuila	4235-2022	ID	0000-0002-6348-0860	380076
ROR Centro Nacional de Investigación y Desarrollo Tecnológico	4152-2020	ID	0000-0003-3380-2598	44358

CONAHCYT classification:

Area: Engineering

Field: Engineering

Discipline: Mechanical Engineering

Subdiscipline: Energy

ECORFAN-México, S.C.

Park Pedregal Business. 3580,
Anillo Perif., San Jerónimo
Aculco, Álvaro Obregón,
01900 Ciudad de México, CDMX,
Phone: +52 1 55 6159 2296
Skype: ecorfan-mexico.s.c.
E-mail: contacto@ecorfan.org
Facebook: ECORFAN-México S. C.

Twitter: @EcorfanC

www.ecorfan.org

Holdings

Mexico	Colombia	Guatemala
Bolivia	Cameroon	Democratic
Spain	El Salvador	Republic
Ecuador	Taiwan	of Congo
Peru	Paraguay	Nicaragua




INTRODUCCIÓN




- La energía eólica es un tipo de energía intermitente y de alta variabilidad.
- La velocidad del viento se pronostica con la finalidad de conocer la cantidad de energía que se le podría extraer.
- Una vez que se tiene una estimación, los operadores de las granjas eólicas, hacen su programación de despacho de energía.
- En el pronóstico de la velocidad del viento existen diferentes horizontes:
 - A corto plazo (uno, dos o tres pasos adelante).
 - A mediano plazo (de seis horas y hasta 24 horas).
 - A largo plazo (días, semanas en incluso meses).
- Existen diversas técnicas para generar un modelo para pronosticar la velocidad del viento.
 - Técnicas estadísticas (ARIMA)
 - Modelos Numéricos (WRF)
 - Redes Neuronales Artificiales.
 - Modelos Híbridos (Combinan dos o mas técnicas)
- En el presente trabajo se configura una RNA con la finalidad de realizar pronóstico de la velocidad del viento un paso adelante.



ENERGÍA DEL VIENTO



Variación de la potencia entregada







METODOLOGÍA

DATOS UTILIZADOS

Para la realización del presente trabajo, se utilizaron los datos históricos de viento correspondientes a la serie de tiempo horaria medida en el estado de Baja California Sur, en el año 2016, cuyas características estadísticas así como su distribución de probabilidad (Weibull) se muestran a continuación:


Media: 4.45 m/s
Desviación estándar: 2.72 m/s
Número de datos: 744
Vel. Mínima: 0.00 m/s
Vel. Máxima: 12.05 m/s





SERIES DE TIEMPO DE LOS DATOS

Además de los datos de viento con los que se cuenta para realizar el modelo, se recolectaron datos de radiación solar, presión, temperatura y humedad relativa. De la misma manera se calculó la estadística descriptiva de los siguientes datos compuestos: Intensidad de Turbulencia, serie de retardos -1, serie de retardos -2, serie de retardos -12 y serie de retardos -13. Las series de tiempo de las Figuras se muestran a continuación:





ESTADÍSTICA DESCRIPTIVA DE LOS DATOS




En la Tabla se muestran las medidas estadísticas calculadas de las variables utilizadas.

Descriptive statistics	W.S. (<i>m/s</i>)	R (<i>W/m²</i>)	T (°C)	Hr (%)	P (<i>Hg</i>)	I (%)
Mean	4.5	175.7	14.7	80.9	769.7	0.2
St. Dev.	2.7	254.8	3.9	28.2	1.8	0.1
Min.	0.0	0.0	2.0	12.0	766.6	0.0
Max.	12.1	789.8	28.2	100.0	776.7	0.6
Median	2.1	0.0	13.1	68.0	768.1	0.1
<i>Q</i>₁	4.6	0.0	15.0	98.0	768.9	0.2
<i>Q</i>₂	6.4	364.4	16.7	100.0	771.1	0.2



GRÁFICA TIPO VIOLÍN

- Una herramienta útil para conocer la distribución de las variables, es la gráfica tipo violín.
- La gráfica se traza con las variables normalizadas, es decir, las variables son transformadas para que sus valores se encuentren entre cero y uno.
- Es conveniente que los valores que alimenten la red se mantengan normalizados para facilitar su entrenamiento.






REDES NEURONALES ARTIFICIALES

¿Por qué utilizar RNA para realizar el pronóstico de la velocidad del viento?



1. Porque el horizonte propuesto es de una hora.
2. Porque el desempeño que tienen es sobresaliente de acuerdo con la bibliografía.





REDES NEURONALES ARTIFICIALES

- Las RNA se basan en la autonomía del cerebro como modelo.
- Actualmente se les asocia con el término Deep Learning.
- Una RNA multicapa (varias capas), es un buen replicador de funciones.

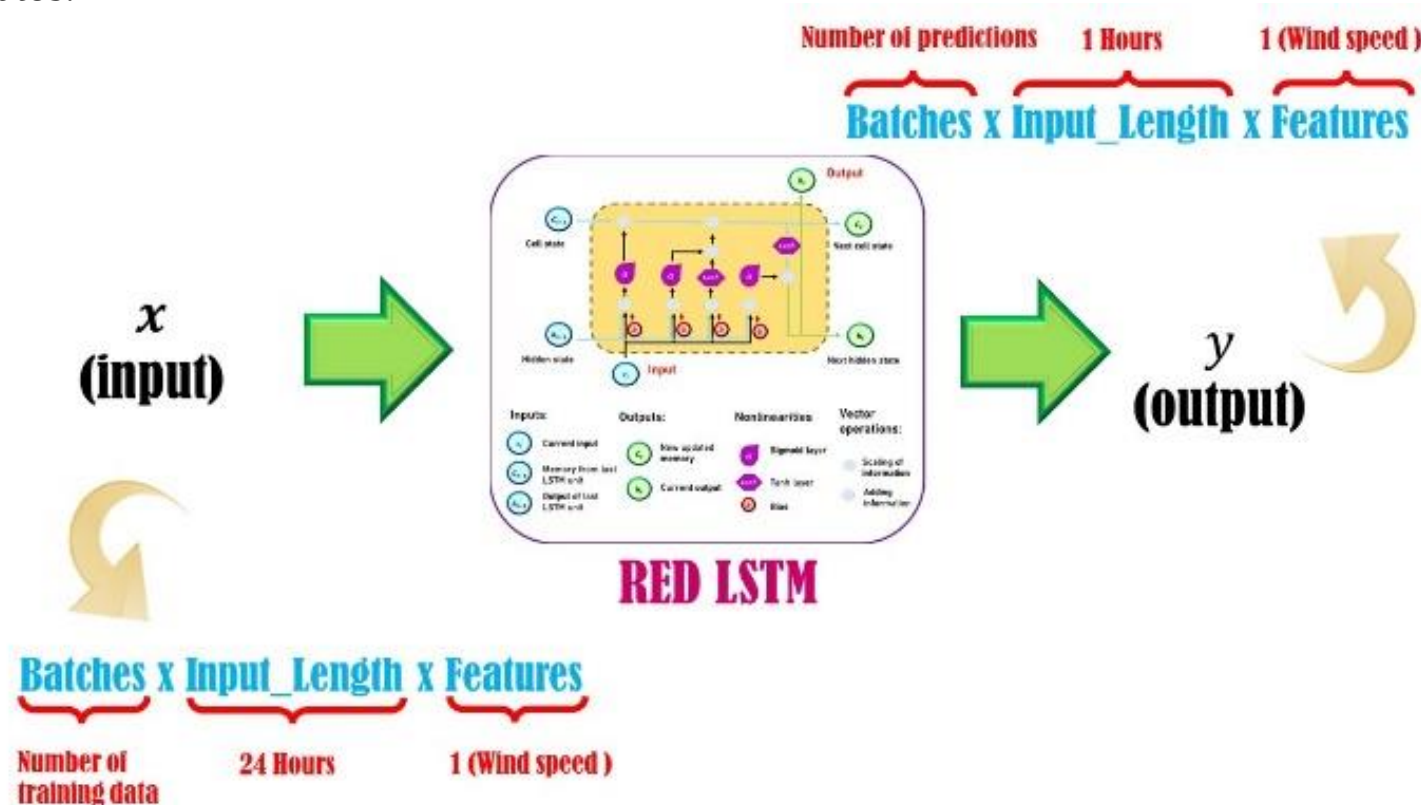


Modelo abstracto de una neurona artificial. (Berzal, F. (2018). Redes neuronales & deep learning. Granada: Fernando Berzal.)



LONG SHORT-TERM MEMORY NETWORK (LSTM)

- En el pronóstico de series de tiempo, es conveniente usar el tipo de RNA denominado LSTM.
- La técnica funciona mejor en series de datos que exhiben dependencia temporal a largo plazo.
- LSTM es un tipo de RNA recurrente, con unidades especiales denominadas compuertas (Gates), que les permite aprender, cuales datos de la serie son importantes y guardarlos, y cuales no y descartarlos (Skenderi et al. 2023).
- LSTM tiene la habilidad de capturar patrones complejos, estacionalidad, tendencias y otras estructuras complejas de los datos.





CARACTERÍSTICAS DE LA LSTM



Es necesario ajustar varios parámetros para que el modelo funcione de manera efectiva (McDonough, 2024):

- **Número de capas.**
 - Una gran cantidad de capas pueden capturar estructuras más complejas, pero también puede llevar a sobreajustes.
- **Unidades por capas.**
 - Es el número de neuronas por capa, este número suele ser una potencia de dos.
- **Función de activación.**
 - Para el modelo propuesto se utilizó la función de activación ReLU, que se utiliza generalmente para introducir la no linealidad y permite que las redes aprendan estructuras más complejas.
- **Tasa de aprendizaje.**
 - Esta es la velocidad a la que el modelo ajusta sus pesos durante el entrenamiento, para minimizar el error.
- **Tamaño del lote (Batch size).**
 - Es importante hacer una buena elección ya que afecta la estabilidad del proceso de aprendizaje y la velocidad del entrenamiento.
- **Epocas (Epoch).**
 - Es el número de veces en que el algoritmo se entrenará con el conjunto de datos de prueba.
- **Dropout.**
 - Es una herramienta que ayuda en la prevención del sobreajuste.
- **Optimizador.**
 - Es un método de optimización como Adam, SGD, RMSprop, etc., que se utiliza para ajustar los pesos de la red reduciendo el error de la función de pérdida.
- **Función de pérdida.**



LSTM PROPUESTA



Las pruebas realizadas, demostraron que las características generales de la RNA que se va a utilizar para modificar las entradas, tiene las siguientes características:


1. **Neuronas de entrada: son las variables que se van a modificar, para encontrar el mejor vector de entrada**
2. Capas ocultas: 128
3. Neuronas por capa: 64
4. Función de Activación: ReLU
5. Batch size: 6
6. Epoch: 100
7. Dropout: 5e-5
8. Optimizador: Adam
9. Métrica de error: RMSE
10. Neuronas de salida : 1



DERMINACIÓN DEL MEJOR VECTOR DE ENTRADA

Para conocer el mejor vector de entrada para este caso, se configuraron 5 modelos, con diferentes entradas:

1. **Modelo 1:** retardo de la velocidad del viento (Y_{t-1}), temperatura del viento (T), humedad Relativa (Hr), intensidad de la turbulencia (I), presión atmosférica (P) y radiación solar (RS).
2. **Modelo 2:** Y_{t-1} , Y_{t-2} , Y_{t-12} y Y_{t-13} .
3. **Modelo 3:** Y_{t-1} , T y Hr.
4. **Modelo 4:** Y_{t-1} e I.
5. **Modelo 5:** Y_{t-1}





MÉTRICAS DE ERROR USADAS PARA COMPARAR LOS MODELOS



Para poder determinar que modelo se ajusta mejor a la serie de tiempo de viento, se utilizaron las siguientes métricas de error:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_t^2}$$

$$NRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n e_t^2}}{\overline{y_t}}$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |e_t|$$



RESULTADOS



La muestra la evolución de los errores en diferentes épocas durante el entrenamiento.






AJUSTE DEL MODELO PROPUESTOS



Es importante que el ajuste del modelo se refleje de manera cualitativa, como se muestra en la figura






CÁLCULO DE LAS MÉTRICAS DE ERROR



El cálculo de las métricas de error refleja la parte cuantitativa del modelo y la que tiene más peso en la elección del modelo, es la que indica que modelo se ajusta mejor al comportamiento de los datos medidos.

Models	MAE	RMSE	NRMSE
Test Data Set			
LSTM, 5l, 10	0.852	1.011	0.183
LSTM, 4l, 10	0.720	0.923	0.161
LSTM, 3l, 10	0.843	1.019	0.188
LSTM, 2l, 10	0.852	1.016	0.186
LSTM, 1l, 10	0.852	1.014	0.185





CONCLUSIONES

Las conclusiones que se arrojan del presente trabajo son:

1. La selección de las variables de entrada modifican la exactitud de los modelos.
2. En el caso de la velocidad del viento, un metro por segundo incrementa la potencia de salida con un factor de la velocidad elevado al cubo, por lo anterior es importante que se conformen y elijan modelos lo más precisos posibles.
3. El modelo que mejor desempeño tuvo en éste caso fue el que se conformó con solamente retardos de la velocidad del viento.
4. Además de que el modelo seleccionado es cuantitativamente mejor, de la misma manera, su desempeño cualitativo es adecuado, pues captura de manera destacada estructuras de la serie como picos y valles.



REFERENCIAS



Basics.

Council, G. W. E. Global wind energy council. GWEC, (2024, July 25). Available: <http://www.gwec.net/>.

Activation Functions in Neural Networks: What You May Not Know. (2022, August 4). <https://towardsdatascience.com/activation-functions-in-neural-networks-what-you-may-not-know-2d99ad093246>

Asociación Mexicana de Energía Eólica. Asociación mexicana de energía eólica. (2024, August 1). AMDEE. <https://amdee.org>

Pachot, A., & Patisserie, C. (2022). Towards Sustainable Artificial Intelligence: An Overview of Environmental Protection Uses and Issues. Cornell University. <https://doi.org/10.48550/arxiv.2212.11738>

Kumar, A. (2023, April 5). Large language models: Concepts & Examples. <https://vitalflux.com/large-language-models-concepts-examples/>

Nurhambali, M. R., Angraini, Y., & Fitrianto, A. (2024). Implementation of Long Short-Term Memory for Gold Prices Forecasting. Malaysian Journal of Mathematical Sciences, 18(2). <https://doi.org/10.47836/mjms.18.2.11>

Javier, G M B F. (2023). The predictive power of the Blockchain transaction networks: Towards a new generation of network science market indicators. <http://arxiv.org/abs/2401.01379>

Saeed, B P O A. (2023, September 10). A compendium of data sources for data science, machine learning, and artificial intelligence. <https://arxiv.org/abs/2309.05682>

Larson, A. (2023). The Importance of Accurate Weather Prediction for Power Operations. <https://www.powermag.com/the-importance-of-accurate-weather-prediction-for-power-operations/>

Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. Elsevier BV, 404, 132306-132306. <https://doi.org/10.1016/j.physd.2019.132306>

Skenderi, G., Joppi, C., Denitto, M., & Cristani, M. (2023). On the Use of Learning-Based Forecasting Methods for Ameliorating Fashion Business Processes: A Position Paper. https://doi.org/10.1007/978-3-031-37742-6_50

Time Series Analysis Homework Help. (2023, February 6). <https://www.statisticshomeworkhelper.com/time-series-analysis/>

Supports.

McDonough, M. (2024). Large language model. <https://www.britannica.com/topic/large-language-model>

Deep Learning – What Is It and Why Does It Matter?. (2023, February 27). <https://www.nvidia.com/en-us/glossary/data-science/deep-learning/>



ECORFAN®

© Ecorfan-Mexico, S.C.

No part of this document covered by the Federal Copyright Law may be reproduced, transmitted or used in any form or medium, whether graphic, electronic or mechanical, including but not limited to the following: Citations in articles and comments Bibliographical, compilation of radio or electronic journalistic data. For the effects of articles 13, 162, 163 fraction I, 164 fraction I, 168, 169, 209 fraction III and other relative of the Federal Law of Copyright. Violations: Be forced to prosecute under Mexican copyright law. The use of general descriptive names, registered names, trademarks, in this publication do not imply, uniformly in the absence of a specific statement, that such names are exempt from the relevant protector in laws and regulations of Mexico and therefore free for General use of the international scientific community. BCIERMMI is part of the media of Ecorfan-Mexico, S.C., E: 94-443.F: 008- (www.ecorfan.org/ booklets)