

07-008

DEVELOPMENT OF A VIRTUAL SENSOR FOR THE PREDICTION OF ENVIRONMENTAL CONDITIONS IN SURFACE TREATMENT BOOTHS FOR METAL PRODUCTS

Rodríguez Montequín, Vicente ⁽¹⁾; García González, Javier ⁽¹⁾; Alonso Iglesias, Guillermo ⁽¹⁾;
Fernández Canadas, Miguel ⁽¹⁾

⁽¹⁾ Universidad de Oviedo

In the manufacture of metal structures, the surface treatment stages (shot blasting, metallising, painting, etc.) are key to ensuring that the products can withstand the environmental conditions where they are going to be installed, preventing corrosion, among other phenomena. In the production of large structures such as wind turbines, the treatments are applied in large booths. Quality standards require that the environmental conditions in which the work is carried out are within certain limits. The most important parameters are relative humidity and temperature, as they determine the possibility of condensation on the surface being treated. In order to keep the humidity below the tolerated threshold, powerful dehumidifiers are usually used, which are very energy-intensive. Optimising the running time of such equipment, reducing it to the minimum, can lead to significant cost savings. The combination of IoT and machine learning is an important way to do this. The work presented here describes the system developed to model the environmental conditions that a cabin would have to anticipate when dehumidification equipment needs to be activated. The system was validated at the premises of a major manufacturer of wind turbine structures.

Keywords: machine learning; energy efficiency; internet of things

DESARROLLO DE UN SENSOR VIRTUAL PARA LA PREDICCIÓN DE LAS CONDICIONES AMBIENTALES EN CABINAS DE TRATAMIENTO SUPERFICIAL DE PRODUCTOS METÁLICOS

En la fabricación de estructuras metálicas, las etapas de tratamiento superficial (granallado, metalizado, pintado, etc.) son claves para lograr que los productos puedan soportar las condiciones ambientales de donde vayan a ser instaladas, evitando, entre otros fenómenos, la corrosión. En la producción de grandes estructuras como las eólicas, los tratamientos se aplican en cabinas de grandes dimensiones. Las normas de calidad exigen que las condiciones ambientales en las que se desarrollen los trabajos estén dentro de unos límites. Los parámetros más importantes son la humedad relativa y la temperatura, ya que determinan la posibilidad de condensación sobre la superficie que está siendo tratada. Para mantener la humedad por debajo del umbral tolerado se emplean habitualmente potentes deshumidificadores que conllevan un elevado consumo energético. Optimizar el tiempo de utilización de estos equipos, reduciéndolo al mínimo imprescindible, puede suponer importantes ahorros de costes. La combinación del uso de IoT y aprendizaje automático supone una importante vía para realizarlo. El trabajo aquí presentado describe el sistema desarrollado para modelar las condiciones ambientales que tendría una cabina y así poder anticipar cuando será necesario activar los equipos de deshumidificación. El sistema fue validado en las instalaciones de un importante fabricante de estructuras eólicas.

Palabras clave: aprendizaje automático; eficiencia energética; internet de las cosas

Agradecimientos: Este trabajo se ha realizado con la financiación proporcionada por IDEPA (Instituto de Desarrollo Económico del Principado de Asturias) y Windar Technology and Innovation a través de las Primas Proof Of Concept (SV-PA-21-RIS3-2)



© 2023 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introducción

Los componentes fabricados en el sector eólico están sujetos a normas de calidad muy exigentes con el fin de garantizar su adecuado comportamiento y resistencia a lo largo de toda la vida útil. Dentro del proceso de fabricación, las etapas de tratamiento superficial son claves para lograr que los equipos fabricados puedan soportar las duras condiciones ambientales de donde serán instaladas, evitando entre otros fenómenos la corrosión.

Las torres para aerogeneradores están compuestas por segmentos denominados virolas cuyo tratamiento superficial se lleva a cabo en las plantas de producción. El proceso implica diferentes etapas: granallado, aplicación de tratamiento de metalizado, pintado y secado. Cada uno de estos tratamientos se aplica en cabinas especiales de grandes dimensiones en las que los trabajos se deben desarrollar dentro de unos límites concretos de temperatura y humedad relativa.

Para garantizar esos valores se recurre a sistemas de acondicionamiento, principalmente deshumidificadores, con el propósito general de reducir la temperatura de punto de rocío. La aparición de este fenómeno debido a la cantidad de humedad en el aire implica la condensación de ésta sobre la superficie a tratar, lo que impide que se garantice la calidad de los revestimientos aplicados.

Las grandes dimensiones de estas cabinas hacen que se requieran equipos muy potentes, lo que conlleva un gasto energético significativo. Los sistemas de regulación clásicos en los que los deshumidificadores se activan al superar un determinado umbral no permiten minimizar el tiempo de funcionamiento de modo representativo, ya que el volumen de aire a tratar es muy elevado y el proceso se encuentra influenciado por la inercia térmica de las instalaciones.

Optimizar el tiempo de utilización de estos equipos, reduciéndolo al mínimo imprescindible, puede suponer importantes ahorros de costes, además de la consiguiente mejora medioambiental. La combinación del uso de IoT (Internet of Things) y aprendizaje automático supone una importante vía para anticipar las condiciones de temperatura y humedad relativa de la cabina y actuar sobre el deshumidificador con la antelación suficiente para mantener las condiciones de trabajo en los límites establecidos.

Para alcanzar este objetivo se desarrollan modelos con algoritmos de aprendizaje automático que permiten anticipar las condiciones ambientales que habrá en la cabina con horas de antelación, lo que permite desarrollar una estrategia inteligente para las consignas de control de los equipos de deshumidificación. Para ello se lleva a cabo una recogida de datos mediante la implementación de un sistema de monitorización en una cabina de trabajo y el uso de datos meteorológicos externos. Los modelos han sido entrenados y probados en las instalaciones de WINDAR Renovables en Avilés (Asturias), uno de los fabricantes más destacados a nivel internacional de torres eólicas, lo que ha permitido validar su eficacia.

2. Descripción del entorno y del sistema de captura de datos

Las cabinas objeto del estudio son estructuras de grandes dimensiones diseñadas para proporcionar un espacio protegido en el que operar sobre estructuras eólicas de gran tamaño. Estas cabinas pueden albergar segmentos de torres de varios metros de diámetro y de longitud. A modo de ejemplo, la cabina objeto de estudio tiene una capacidad aproximada de 3500 m³ y se encuentra situada en las instalaciones de WINDAR Renovables en el Parque Empresarial Principado de Asturias, en Avilés, una planta con una superficie de 20.000 m². Aunque estas cabinas están construidas con materiales aislantes, mantener las condiciones ambientales estables en volúmenes como estos resulta prácticamente imposible

ya que son afectadas por la inercia térmica de la nave, que a su vez es afectada por las condiciones meteorológicas externas. Además, las cabinas disponen de puertas de acceso para los operarios y portones de grandes dimensiones para la entrada y salida de las piezas a tratar.

Para monitorizar las condiciones ambientales se instalan sensores de temperatura y humedad en el interior y en el exterior de la cabina con un intervalo de registro de 10 minutos. Además, se registran también otros datos que pueden ser relevantes, como el estado de los portones de acceso (abiertos o cerrados) y si el deshumidificador se encuentra en funcionamiento.

Las mediciones registradas por las sondas de corriente conectadas directamente al deshumidificador permiten realizar un análisis de su consumo energético. El intervalo configurado para la toma de datos es de 5 minutos, siendo las siguientes variables las registradas para cada una de las fases del sistema trifásico: voltaje, corriente y potencia.

La información meteorológica del exterior de la nave resulta relevante también, pero esta se obtiene con frecuencia horaria de un proveedor externo de datos meteorológicos y por lo tanto no se requiere sensorización.


Por tanto, se disponen de tres fuentes de información principales:

- Bloque nave: Sensores meteorológicos y de contacto que permiten monitorizar la inercia de la nave.
- Servicio meteorológico externo: Servicio API (Application Programming Interface) REST (Representational State Transfer) que permite obtener predicciones de las condiciones del exterior de la nave con varias horas de antelación.
- Bloque deshumidificador: Sensores de consumo energético que posibilitan el estudio del comportamiento del deshumidificador.

Toda la información recopilada por los sensores es almacenada en la nube mediante comunicación 4G para su posterior tratamiento en la fase de entrenamiento de modelos.

El esquema general de la instalación necesaria para los elementos mencionados se refleja en la Figura 1.

Figura 1: Esquema general de captación de datos



3. Metodología

Los datos recopilados mediante el sistema de captura descrito previamente se tratan como series temporales registradas en intervalos de tiempo regulares. Estas series son una herramienta útil para el análisis y la predicción de patrones y tendencias en datos que varían con el tiempo.


La predicción con este tipo de series supone un desafío debido a la naturaleza dinámica y estocástica de los datos (Baghban et al., 2016; Mehdizadeh et al., 2017; Mohammadi et al., 2015). Las series pueden estar influenciadas por diversos factores, como tendencias, estacionalidad, efectos de calendario y eventos aleatorios.

Entre las mejores técnicas disponibles, las redes neuronales recurrentes (RNN) son una variante de las redes neuronales que se utilizan habitualmente para la predicción con series temporales (Hewamalage et al., 2021; Kisi et al., 2013; Shank et al., 2008). Concretamente, se considera que, dentro de esta clase, una de las que mejor se puede adaptar a la problemática planteada son las redes LSTM (Long Short-Term Memory) (Karevan & Suykens, 2020; Yadav et al., 2020).

La característica principal de las redes recurrentes es que la información puede persistir introduciendo bucles en el diagrama de la red, por lo que, básicamente, pueden recordar estados previos y utilizar esta información para decidir cuál será el siguiente. Esta característica las hace muy adecuadas para manejar series temporales. Mientras las redes recurrentes estándar pueden modelar dependencias a corto plazo (es decir, relaciones cercanas en la serie cronológica), las LSTM pueden aprender dependencias más largas mediante el uso de celdas de memoria, en cuyo interior el flujo de información se controla mediante tres puertas (entrada, salida y olvido). La puerta de entrada controla la cantidad de información nueva que se introduce en la celda, la puerta de salida controla la cantidad de información que se envía a la siguiente celda o a la salida de la red y la puerta de olvido controla la cantidad de información antigua que se retiene o se descarta.

Dentro de LSTM, se dispone de dos posibles enfoques: single-step o multi-step. Mientras que single-step realiza una sola predicción para el siguiente punto en una serie temporal utilizando como entrada los datos previos, multi-step predice una secuencia de puntos consecutivos futuros utilizando la misma entrada previa, lo que puede suponer una pérdida de precisión en situaciones donde los datos cambian con rapidez o en los que una mala predicción puede retroalimentar los siguientes puntos consecutivos de la serie predicha. Con el objetivo de disminuir este riesgo y bajo la prioridad de predecir a corto plazo el enfoque elegido para la arquitectura finalmente es single-step.

Figura 2: Enfoque single-step en redes LSTM



Durante el entrenamiento, la red aprende a ajustar los pesos de las conexiones entre las capas de la red y las unidades de memoria para minimizar el error entre las predicciones y los valores reales de la serie temporal. Una vez entrenada, en cada paso de predicción, se alimenta a la red el vector de características de la observación actual y se obtiene la predicción del siguiente punto en la secuencia.

Se utilizan diversas herramientas para la implementación de esta metodología, pero entre las principales se destacan TensorFlow v 2.9.1 y Keras v 2.9.0 (TensorFlow, s. f.), las cuales se ejecutan en un entorno de programación Python.

3.1 Descripción de los datos

El conocimiento en detalle de los datos sobre los que se ha realizado el trabajo juega un papel fundamental en los resultados obtenidos en el modelado. Para la consecución del objetivo fijado resulta imprescindible la obtención de datos meteorológicos correspondientes al exterior y al interior de la nave. Los datos del interior de la nave fueron proporcionados por el equipamiento descrito anteriormente, mientras que para la previsión de las condiciones meteorológicas externas fue necesario hacer usos de servicios de terceros de confianza. Para el presente caso de estudio se analizaron datos durante una ventana temporal de seis meses.

Para el bloque de la nave, las variables a las que se obtiene acceso a través de esta fuente de información son: temperatura y humedad relativa en la nave, temperatura y humedad relativa en la cabina, y detección de apertura o cierre de puertas de acceso a la cabina. En la Tabla 1 se muestran los principales estadísticos descriptivos de las variables de estudio.

Tabla 1. Valores estadísticos del bloque nave

Variable	Mínimo	Percentil 25	Mediana	Media	Desviación típica	Percentil 75	Máximo	Vacíos
Temperatura nave (°C)	12,30	18,60	20,60	21,29	3,95	22,80	34,30	0
Humedad nave (%)	28,00	60,80	72,00	68,98	13,89	79,70	94,20	0
Temperatura cabina (°C)	13,70	18,90	20,40	20,67	2,56	22,10	28,60	0
Humedad cabina (%)	42,10	63,50	71,40	69,93	9,31	77,00	92,70	0

Los datos meteorológicos externos correspondientes a la localización en la que se encuentra la nave en estudio descargados a través del servicio de terceros ofrecen las siguientes variables: intensidad de precipitación, probabilidad de precipitación, temperatura, humedad relativa, presión, velocidad del viento y dirección del viento. En la Tabla 2 se muestran los principales estadísticos descriptivos de las variables durante el periodo de estudio.

Tabla 2. Valores estadísticos del servicio web externo

Variable	Mínimo	Percentil 25	Mediana	Media	Desviación típica	Percentil 75	Máximo	Vacíos
Intensidad de precipitación (mm/h)	0,00	0,00	0,00	0,04	0,07	0,04	0,45	0
Probabilidad de precipitación (%)	0,00	0,00	1,00	3,98	6,46	5,00	32,00	0
Temperatura (°C)	10,19	16,20	18,27	18,38	3,13	20,23	27,90	0
Humedad (%)	61,00	80,00	88,00	85,83	8,51	93,00	100,00	0

Presión (Pa)	1008,00	1015,50	1019,10	1018,90	4,35	1022,20	1029,90	0
Velocidad del viento (m/s)	0,71	1,79	2,53	2,67	1,11	3,35	6,18	0

Los datos referentes al bloque deshumidificador no se utilizan para el entrenamiento de los modelos, su uso se encuentra orientado a validar el correcto funcionamiento del deshumidificador y facilitar el cálculo del ahorro energético de la solución propuesta.

3.2 Tratamiento de los datos

El objetivo del tratamiento de datos es la transformación del conjunto de datos original en un nuevo conjunto de datos más significativo y fiable. Es una de las etapas más importantes en el desarrollo de modelos de aprendizaje automático (Maharana et al., 2022). Las siguientes tareas principales se llevaron a cabo en la fase de preparación de los datos: transformación de los datos en otras variables, rellenado o eliminación de valores vacíos o erróneos y reducción de la dimensionalidad.

Como resultado de dichas tareas, destacan las siguientes acciones:

- Se unifican los intervalos de tiempo presentes en las diferentes fuentes de información en periodos de una hora.
- En las variables del servicio externo se toma la decisión de hacer una división sobre los valores de las variables que era necesario utilizar: sus valores recientes, sus valores futuros (predicciones), ambos o ninguno.
- Se descartan las variables relacionadas con el viento. La decisión tomada tiene su justificación en que el problema está centrado en el interior de la nave y su inercia es mucho más lenta que en el exterior de la misma, siendo los valores de humedad relativa lo suficientemente representativos para el modelo.

El entrenamiento de modelos es un proceso iterativo formado por fases independientes, pero también interrelacionadas (Chai et al., 2023). Es por ello por lo que algunas de las situaciones anteriormente descritas, aunque se tratasen de hipótesis previamente fijadas, entra siempre dentro de lo previsto que sea necesaria su revisión durante la fase de modelado.

3.3 Entrenamiento de los modelos

Los modelos se enfocan en predecir las dos variables clave que influyen en el punto de rocío: la humedad relativa y la temperatura. Para ambas variables, el modelo LSTM con enfoque single-step utiliza una ventana de 24 horas al pasado y de 3 horas al futuro.


El uso de un enfoque single-step en las redes LSTM para la predicción de estas variables tiene varias ventajas:

- Permite la predicción en tiempo real, lo que resulta fundamental en este caso de estudio.
- Reduce la complejidad computacional al eliminar la necesidad de ejecutar múltiples pasos de predicción, lo que permite que el modelo se ejecute más rápido y con menos recursos computacionales.
- Este enfoque mejora la precisión de la predicción al reducir la propagación del error y permitir una actualización más rápida del estado interno de la red LSTM.

En general, el enfoque single-step en las redes LSTM es un enfoque prometedor para la predicción basada en series temporales con los datos recopilados. Este enfoque se aplica para la predicción del siguiente valor a 1, 2 y 3 horas vista mediante el entrenamiento de

diferentes modelos como se puede observar en la Figura 3. No se considera necesario un plazo más amplio de antelación en la predicción, ya que el deshumidificador pueda actuar con la suficiente garantía en los plazos indicados.

Figura 3: Ventanas utilizadas en el enfoque single-step a 1,2 y 3 horas



En la configuración de los modelos LSTM se opta por el uso de la optimización de Adam (Kingma & Ba, 2017) y una función de pérdida basada en el cálculo del error cuadrático medio entre los valores reales y las predicciones, Para la fase de entrenamiento se introducen a la red en cada iteración de aprendizaje agrupaciones o lotes de 32 muestras y se establece 20 como el número máximo de ciclos. La métrica de parada anticipada utilizada para que los modelos finalicen el entrenamiento cuando su monitorización deja de mejorar es el error medio absoluto (MAE), que debe superar la cantidad absoluta de 0.1 en un máximo de 3 ciclos.

Como indicadores del error para todo el conjunto de datos se utilizan el MAE y error medio cuadrático (RMSE). Los datos obtenidos de cada una de las 3 horas predichas producen unos resultados de error medio absoluto ascendente desde la primera a tercera hora, como se podría esperar.

4. Resultados

A continuación, se presentan los resultados obtenidos para el conjunto de datos de entrenamiento y validación en ambas magnitudes a predecir.

4.1 Modelos de temperatura

En primer lugar, se muestran las estadísticas de error obtenidas en los modelos de predicción de temperatura para una, dos y tres horas con los conjuntos de datos de entrenamiento (Tabla 3) y de validación (Tabla 4).

Tabla 3. Estadísticas de error de temperatura en el conjunto de entrenamiento

Horas	MAE	RMSE
1	0,45	0,58
2	0,53	0,69
3	0,56	0,72

Tabla 4. Estadísticas de error de temperatura en el conjunto de validación

Horas	MAE	RMSE
1	0,51	0,68
2	0,66	0,84
3	0,72	0,91

En el caso de los modelos de temperatura, se observa que prácticamente los errores de los diferentes modelos se mantienen inferiores a 1 °C.

A modo de ejemplo, se destacan en la figura el comportamiento del modelo en la mejor y peor situación. En ambas situaciones los modelos a 1 (rojo), 2 (amarillo) y 3 (azul) horas de anticipación se adaptan a la tendencia ofrecida por la medición real del sensor (verde).

Figura 4: Predicciones mejor caso ofrecidas por los modelos de temperatura





Figura 5: Predicciones peor caso ofrecidas por los modelos de temperatura



4.2 Modelos de humedad relativa

Las estadísticas de error obtenidas en los modelos de predicción de humedad relativa para una, dos y tres horas se recogen a continuación para los conjuntos de datos de entrenamiento (Tabla 5) y validación (Tabla 6).

Tabla 5. Estadísticas de error humedad en el conjunto de entrenamiento

Horas	MAE	RMSE
1	1,77	2,31
2	2,69	3,50
3	3,31	4,27

Tabla 6. Estadísticas de error humedad en el conjunto de validación

Horas	MAE	RMSE
1	1,89	2,47
2	2,98	3,69
3	3,73	4,56

En el caso de la humedad relativa los valores obtenidos en cada una de las 3 horas predichas también producen unos resultados de error medio absoluto ascendente desde la primera a tercera hora. Se observa que prácticamente los errores de los diferentes modelos se mantienen en valores similares a los ofrecidos por cualquier sensor.

Se presentan a continuación algunas gráficas que permiten comprobar visualmente el comportamiento de los modelos. A modo de ejemplo se muestran los resultados de los modelos en un día con variaciones suaves de humedad relativa y de otro donde, pese a sufrirse un cambio drástico del porcentaje de humedad, los modelos los modelos a 1 (rojo), 2 (amarillo) y 3 (azul) horas de anticipación continúan adaptándose a la tendencia real (verde).

Figura 6: Predicciones mejor caso ofrecidas por los modelos de humedad relativa





Figura 7: Predicciones peor caso ofrecidas por los modelos de humedad relativa



5. Conclusiones

El sistema de captura de datos instalado ha demostrado ser una herramienta muy útil para estudiar tanto la dinámica de la cabina como el comportamiento del equipo de deshumidificación y desarrollar modelos que anticipen las condiciones ambientales.

La anticipación en el encendido o apagado de los equipos deshumidificadores atendiendo a las predicciones de los modelos desarrollados puede suponer un importante ahorro energético, y por ende económico y ambiental, que debe ser tenido en cuenta dentro de los objetivos de desarrollo sostenible de las empresas del sector.

Los algoritmos empleados para el desarrollo de los modelos, las redes LSTM, han demostrado su eficacia para predecir la humedad relativa y la temperatura con las series temporales disponibles. Los resultados muestran una buena capacidad de los modelos para

predecir en diferentes horizontes de tiempo, superando en muchas ocasiones el grado de precisión ofrecido por la mayoría de los sensores del mercado.

Además, la monitorización de las condiciones operativas de un equipo permite detectar anomalías en el funcionamiento y/o desgaste prematuro de los componentes, lo que permite tomar medidas preventivas antes de que se produzca una avería. Asimismo, resulta posible identificar los momentos óptimos para el mantenimiento y reparación de los equipos, lo que reduce el tiempo de inactividad y el costo asociado a las reparaciones esperadas.

6. Referencias

- Baghban, A., Bahadori, M., Rozyn, J., Lee, M., Abbas, A., Bahadori, A., & Rahimali, A. (2016). Estimation of air dew point temperature using computational intelligence schemes. *Applied Thermal Engineering*, 93, 1043-1052.
- Chai, C., Wang, J., Luo, Y., Niu, Z., & Li, G. (2023). Data Management for Machine Learning: A Survey. *IEEE Transactions on Knowledge and Data Engineering*, 35(5), 4646-4667.
- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current status and future directions. *International Journal of Forecasting*, 37(1), 388-427.
- Karevan, Z., & Suykens, J. A. K. (2020). Transductive LSTM for time-series prediction: An application to weather forecasting. *Neural Networks*, 125, 1-9.
- Kingma, D. P., & Ba, J. (2017). Adam: A Method for Stochastic Optimization (arXiv:1412.6980). arXiv.
- Kisi, O., Kim, S., & Shiri, J. (2013). Estimation of dew point temperature using neuro-fuzzy and neural network techniques. *Theoretical and Applied Climatology*, 114(3), 365-373.
- Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. *Global Transitions Proceedings*, 3(1), 91-99.
- Mehdizadeh, S., Behmanesh, J., & Khalili, K. (2017). Application of gene expression programming to predict daily dew point temperature. *Applied Thermal Engineering*, 112, 1097-1107.
- Mohammadi, K., Shamshirband, S., Motamedi, S., Petković, D., Hashim, R., & Gocic, M. (2015). Extreme learning machine based prediction of daily dew point temperature. *Computers and Electronics in Agriculture*, 117, 214-225.
- Shank, D. B., Hoogenboom, G., & McClendon, R. W. (2008). Dewpoint Temperature Prediction Using Artificial Neural Networks. *Journal of Applied Meteorology and Climatology*, 47(6), 1757-1769.
- TensorFlow (n.d.). TensorFlow. Obtenido el 19 de abril de 2023, desde <https://www.tensorflow.org/>
- Yadav, A., Jha, C. K., & Sharan, A. (2020). Optimizing LSTM for time series prediction in Indian stock market. *Procedia Computer Science*, 167, 2091-2100.

**Comunicación alineada con los
Objetivos de Desarrollo Sostenible**

