

## **INVESTIGA I+D+i 2024/2025**

### **2. Línea de Energía y medioambiente:**

#### **GUÍA ESPECÍFICA DE TRABAJO SOBRE “Técnicas de predicción de los recursos renovables mediante Inteligencia Artificial”**

**Texto de D. Ignacio Cruz**

**Septiembre 2024**

### **Introducción.**

La producción de la energía eléctrica que consumimos va progresivamente basándose en la conversión de las distintas energías definidas como renovables (radiación solar, eólica, oceánica, hidráulica, geotérmica, materias orgánicas, etc.) hasta que logremos alcanzar el objetivo de un sistema energético sin emisiones en la segunda mitad de este siglo.


Para mitigar los impactos del cambio climático, un objetivo es alcanzar el 100% de la energía eléctrica sin producir emisiones de gases de efecto invernadero. En España, en la actualidad, más del 50%<sup>1</sup> de la energía eléctrica anual que consumimos, es de procedencia renovable (Eólica (23,5%), solar fotovoltaica (14%), hidráulica (9,5%), termosolar (1,8%) y el resto de renovables como biogás, biomasa, geotérmica, hidráulica marina, hidroeólica y residuos renovables (1,6%)) y el objetivo del

---

<sup>1</sup> [https://www.sistemaelectrico-ree.es/sites/default/files/2024-03/Informe\\_Renovables\\_2023.pdf](https://www.sistemaelectrico-ree.es/sites/default/files/2024-03/Informe_Renovables_2023.pdf)

nuevo borrador del Plan Nacional de Energía y Clima (PNIEC) es alcanzar el 81% en el año 2030.<sup>2</sup>

La clara decisión de la Comunidad Europea por preservar el medioambiente y luchar contra las emisiones de efecto invernadero provocadas en el uso de energía fósiles para la producción de energía se ha plasmado en una transición energética estratégica que está dando excelentes resultados tanto en reducción de importaciones de combustibles fósiles y sus correspondientes emisiones, así como a nivel industrial, laboral e incluso de reducción de precios de la energía.



**Figura 1.** Consumo de energía final total en el mundo clasificado por fuentes (2022). Fuentes: IEA, REN21

Pero todavía queda mucho por hacer, a nivel mundial por ejemplo, todavía las energías renovables solo suponen el 12,9% del suministro de

<sup>2</sup>

[https://www.miteco.gob.es/content/dam/miteco/es/energia/files-1/\\_layouts/15/Borrador%20para%20a%20actualizaci%C3%B3n%20del%20PNIEC%202023-2030-64347.pdf](https://www.miteco.gob.es/content/dam/miteco/es/energia/files-1/_layouts/15/Borrador%20para%20a%20actualizaci%C3%B3n%20del%20PNIEC%202023-2030-64347.pdf)

energía primaria (Figura 1) y si nos referimos a la producción de electricidad apenas se alcanza el 7%<sup>3</sup>

Además, teniendo en cuenta que la mayor parte de la energía renovable que se convierte en electricidad es solar y eólica y que ambas son variables e intermitentes y que la generación y el consumo de energía eléctrica tiene que coincidir en cada instante, nos vemos en la necesidad de predecir de la forma mas precisa posible la energía solar y eólica que podemos producir en cada instante por lo que las herramientas de predicción de los recursos tanto solares como eólicos son vitales para el éxito de la transición energética.

La predicción de la generación de la energía renovable es la metodología que permite prever cuanta energía de carácter renovable se va a generar en una determinada superficie o espacio (resolución espacial) y en un determinado plazo (resolución temporal) a través del procesamiento de datos procedentes de distintas fuentes.

Los usuarios de estas herramientas de predicción son todos los implicados en la gestión de la energía a distintos niveles como promotores de plantas de generación renovable, para poder ofertar su energía con garantías en el mercado energético; gestores del sistema energético, para conocer si disponen de toda la energía en cada instante para abastecer a la demanda o tiene que recurrir a sistemas de apoyo, etc. pero en cualquier caso las herramientas de predicción también nos ayudaran a contestar a preguntas claves como las que vemos a continuación:

¿Cuáles serán las fuentes de energía renovables disponibles en el futuro?

¿Qué impacto tendrá el calentamiento global en la generación de energía?

¿Qué impacto tendrá el calentamiento global en el consumo de energía?

---

<sup>3</sup> [https://www.ren21.net/gsr-2024/modules/global\\_overview](https://www.ren21.net/gsr-2024/modules/global_overview)

¿Cuál debería ser la combinación de fuentes de energía para limitar el calentamiento global?

## Qué es la predicción de la generación de energía renovable?

Una predicción o pronóstico de la generación de las energías renovables corresponde a una estimación de la producción esperada de una central fotovoltaica o de un parque eólico con múltiples aerogeneradores en el futuro cercano, hasta un año.

Las predicciones generalmente se expresan en términos de la potencia disponible de la central solar o del parque eólico, ocasionalmente en unidades de energía (vatios-hora), lo que indica el potencial de producción de energía durante un intervalo de tiempo.

Dependiendo del tipo de aplicación las escalas temporales de las previsiones de las energías renovables son diferentes:

- **Predicción a muy corto plazo** (desde segundos hasta minutos). Se utiliza para el control de la central solar o el parque eólico en tiempo real y la gestión de la red eléctrica, así como para equilibrar el mercado. Por ejemplo la generación de energía solar está intrínsecamente ligada a factores meteorológicos como la cobertura de nubes y la radiación solar, o en el caso del viento a ráfagas o rampas lo que puede conducir a fluctuaciones impredecibles en la producción de energía. Esta incertidumbre plantea desafíos para los operadores de la red eléctrica al intentar equilibrar la oferta y la demanda de energía tanto en el muy corto como en el corto plazo.

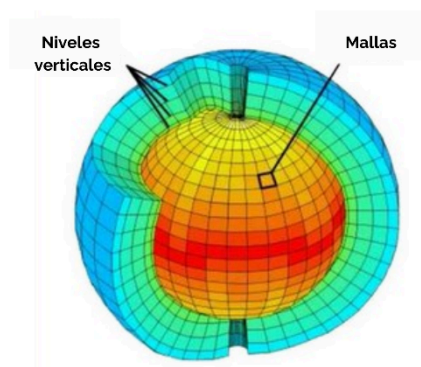
- **Predicción a corto plazo** (desde 30 minutos hasta horas). Se utiliza para la planificación de la gestión o despacho de la red eléctrica, también para tomar decisiones de desconexión de ciertas cargas o demandas eléctricas en el caso que sean necesarias para mantener la estabilidad de la red eléctrica.
- **Predicción a medio plazo** (desde 6 horas hasta un día). Se utilizan para tomar decisiones sobre el arranque/parada de la central solar o de algunos aerogeneradores o del parque eólico completo por razones de seguridad o por las condiciones del mercado.
- **Predicción a largo plazo** (desde un día hasta una semana o incluso un año). Se utilizan para la planificación a largo plazo (para programar el mantenimiento de la central solar/eólica especialmente en el caso de grandes sustituciones y para optimizar el coste de operación de los sistemas de generación renovables). En el caso del mantenimiento de los parques eólicos marinos la predicción precisa de las mejores condiciones para planificarla es vital ya que puede ser especialmente costoso.

## Que es la resolución espacial y temporal de un modelo de predicción de energía renovable?

La discretización de las ecuaciones fundamentales a una resolución espacio-temporal dada está limitada por la capacidad computacional. La resolución típica de los modelos climáticos (actualmente entre 100 y 150 km. para los modelos globales) ha aumentado en paralelo con el aumento de los recursos computacionales a lo largo del tiempo. Un aspecto muy importante es que a cualquier resolución espacial siempre habrá procesos que el modelo resolverá explícitamente y otros que no, por ocurrir a escalas inferiores a la resolución del modelo. Estos procesos

no pueden ignorarse por ser fundamentales desde el punto de vista físico y afectar a los campos resueltos explícitamente por el modelo.

La resolución espacial describe el número de celdas de la retícula en un modelo de predicción, tal como se define por la distancia entre dos celdas dentro del modelo. A través de una alta resolución espacial, es decir, pequeña distancia entre las celdas, una previsión local puede mostrar los efectos de las corrientes de aire locales, de la topografía y de la cubierta del suelo. Las previsiones producidas de esta manera muestran diferencias meteorológicas locales en forma más precisa. Cada modelo divide la atmósfera en una malla tridimensional, en la que cada celda de la malla representa un pequeño volumen de aire. Éstas se conocen como "mallas", y su tamaño varía de un modelo meteorológico a otro. Por eso cada modelo tiene una resolución diferente. Para tener una mayor resolución espacial, el tamaño de la malla deberá ser menor. Lograremos una mayor precisión, pero también será mayor la potencia de cálculo necesaria.



**Figura 2.** Esquema de resolución espacial con la malla tridimensional.

La resolución temporal representa el horizonte de tiempo de la predicción y puede variar entre minutos hasta años dependiendo del plazo. Según aumenta el horizonte de tiempo la precisión de la predicción se reduce y aumenta el requerimiento computacional.

## Qué tipos de herramientas de predicción de recursos renovables existen?

Las herramientas de predicción de los recursos renovables no son algo nuevo, existiendo ya múltiples soluciones comerciales en el mercado.

En función del horizonte de tiempo, se aplican distintos métodos de predicción en función de sus resultados.

	<b>Tipo de predicción</b>	<b>Horizonte de tiempo</b>	<b>Métodos</b>
<b>Generación de energía</b>	Intrahoraria	5-60 minutos	Persistencia Estadístico
	Corto plazo	1-6 horas en adelante	Combinación de estadístico y modelos NWP (Numerical Weather Prediction)
	Medio Plazo	Día/s en adelante	NWP con correcciones para evitar sesgos sistémicos
	Largo plazo	Semana/s estacional 1 año o mas	Predicción climatológica basada en modelos de predicción numérica del tiempo meteorológico (NWP)

**Tabla 1.** Métodos mas apropiados en función del horizonte de tiempo.

Por ejemplo, para la predicción eólica a muy corto plazo se utilizan varias técnicas de distintos grados de sofisticación:

- **Métodos de persistencia:** En estos métodos se supone que la potencia eólica en el siguiente intervalo de tiempo se mantendrá igual que la potencia instantánea medida en cada momento. El error de estas predicciones aumenta rápidamente con el paso del tiempo y, por lo general, este método solo se utiliza como un conjunto de números de nivel base para comparar con las predicciones obtenidas mediante otros métodos.

- **Métodos estadísticos:** A diferencia de los métodos anteriores, en estos se hace la predicción en base a las series temporales de energías generadas o, en los modelos mas sofisticados, combinando estas con predicciones de las condiciones meteorológicas. Cabe destacar que estos métodos solo son buenos para predicciones a corto plazo ya que a medida que aumenta el tiempo en el que queremos predecir, el error de la predicción tiende de a crecer. La base de estos modelos es suponer una relación lineal o no lineal entre los resultados de la predicción numérica del tiempo meteorológico y la potencia eólica, y los coeficientes se entrenan utilizando los datos históricos.

Existen dos grandes subclases de modelos estadísticos que son:

- **Los modelos basados en series temporales de datos.**  
Por ejemplo los Modelos Autorregresivos (AR) que son una representación de un proceso aleatorio, en el que la variable de interés depende de sus observaciones pasadas. Específicamente, la variable de interés o de salida, depende linealmente de sus valores anteriores. Por esto decimos que existe dependencia lineal entre las distintas observaciones de la variable. Existen los modelos autorregresivos de media móvil (ARMA- Autoregressive Moving Average models) o los autoregresivos integrados de media móvil (ARIMA- Autoregressive Integrated Moving Average)
- **Los modelos basados en Redes Neuronales Artificiales (ANN)** <sup>4</sup> que consisten en un conjunto de neuronas artificiales conectadas entre sí para transmitirse señales. La información de entrada atraviesa la red neuronal

---

4

<https://www.ibm.com/es-es/topics/neural-networks#:~:text=%C2%BFQu%C3%A9%20son%20las%20redes%20neuronales,opciones%20y%20llegar%20a%20conclusiones.>



(donde se somete a diversas operaciones) produciendo unos valores de salida.

Cada neurona está conectada con otras a través de unos enlaces. En estos enlaces, el valor de salida de la neurona anterior está multiplicado por un valor de peso. Estos pesos en los enlaces pueden incrementar o inhibir el estado de activación de las neuronas adyacentes. Del mismo modo, a la salida de la neurona, puede existir una función limitadora o umbral, que modifica el valor resultado o impone un límite que no se debe sobrepasar antes de propagarse a otra neurona. Estos sistemas aprenden y se forman a sí mismos mediante técnicas de aprendizaje automático a partir de datos existentes.

### **Como es el enfoque estadístico para la predicción de la energía renovable?**

Los métodos de predicción estadística se basan en uno o varios modelos que establecen la relación entre los valores históricos de potencia, así como los valores históricos y previstos de las variables meteorológicas, y las mediciones de la energía eólica. Los fenómenos físicos no se descomponen ni se tienen en cuenta, aunque el conocimiento del problema es crucial para elegir las variables meteorológicas correctas y diseñar modelos adecuados. Los parámetros del modelo se estiman a partir de un conjunto de datos anteriores disponibles y se actualizan periódicamente durante la operación en línea teniendo en cuenta cualquier información nueva disponible (es decir, previsiones meteorológicas y mediciones de potencia).

Los modelos estadísticos incluyen modelos lineales y no lineales, pero también modelos estructurales y de caja negra. Los modelos estructurales se basan en la experiencia del analista sobre el

fenómeno de interés, mientras que los modelos de caja negra requieren poco conocimiento de la materia y se construyen a partir de datos de una manera bastante mecánica. En lo que respecta a la previsión de energía eólica, los modelos estructurales serían aquellos que incluyen un modelado de las variaciones diurnas de la velocidad del viento o una función explícita de las predicciones de las variables meteorológicas. Los modelos de caja negra incluyen la mayoría de los modelos basados en inteligencia artificial, como las redes neuronales (En inglés Neural Networks - NN) y las máquinas de vectores de soporte (Support Vector Machines - SVM). Sin embargo, algunos modelos están "entre" los dos extremos de ser completamente de caja negra o estructurales. Este es el caso de los sistemas expertos, que aprenden de la experiencia (de un conjunto de datos) y para los que se puede inyectar conocimiento previo. Hablamos entonces de modelado de caja gris. Los modelos estadísticos suelen estar compuestos por una parte autorregresiva, que permite captar el comportamiento persistente del viento, y por una parte "meteorológica", que consiste en la transformación no lineal de las previsiones de las variables meteorológicas. La parte autorregresiva permite mejorar significativamente la precisión de las previsiones para horizontes de hasta 6-10 horas de antelación, es decir, para un periodo durante el cual el uso exclusivo de la información de las previsiones meteorológicas puede no ser suficiente para superar a la persistencia.

### **Cuál es la evolución de los métodos estadísticos de predicción de las energías renovables?**

En la actualidad, por ejemplo los principales avances en los enfoques estadísticos para la predicción de la energía eólica se centran en el uso de múltiples predicciones meteorológicas (de diferentes institutos meteorológicos) como entrada y mediante la

combinación de varias predicciones, así como en el uso óptimo de datos de medición distribuidos espacialmente para la corrección de errores de predicción o, alternativamente, para emitir advertencias sobre incertidumbres potencialmente grandes.

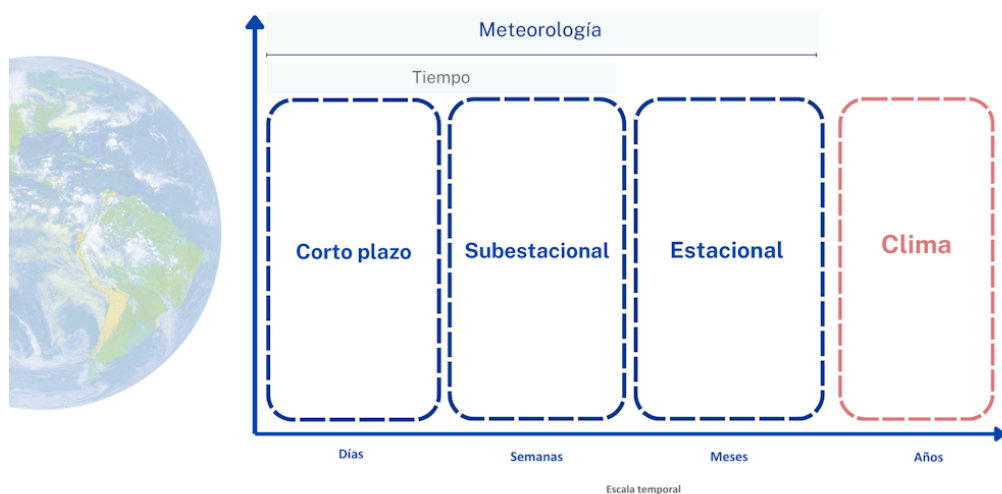
- **Métodos físicos:** En los métodos físicos no se utilizan los valores de energía directamente para obtener la predicción, sino que se utilizan los resultados de la predicción numérica del tiempo meteorológico, por ejemplo a partir de modelos numéricos globales mesoescalares como el modelo del Centro Europeo de Predicción Meteorológica a Plazo Medio (*ECMWF-European Center for Medium-Range Weather Forecast* <https://www.ecmwf.int/>) para predecir el recurso eólico o solar y, posteriormente, relacionarlos con las curvas de producción de los diferentes parques para poder modelizar la generación de energía. Por ejemplo, en estos métodos se utilizan los resultados de la predicción numérica del tiempo meteorológico, los recalculan en la velocidad del viento en el sitio de generación utilizando las características físicas del área alrededor del parque eólico y se convierte la velocidad del viento en predicciones de potencia eléctrica utilizando la curva de potencia del aerogenerador. Estos son especialmente buenos para la predicción a medio y largo plazo.

La generación de energía eólica está directamente relacionada con las condiciones meteorológicas y, por lo tanto, el primer aspecto de la previsión de energía eólica es la predicción de los valores futuros de las variables meteorológicas necesarias a nivel del parque eólico.

Esto se hace mediante modelos de predicción numérica del tiempo meteorológico (NWP-Numerical Weather Prediction). Estos

modelos se basan en ecuaciones que rigen los movimientos y las fuerzas que afectan al movimiento de los fluidos.

A partir del conocimiento del estado real de la atmósfera, el sistema de ecuaciones permite estimar cuál será la evolución de las variables de estado, por ejemplo, la temperatura, la velocidad, la humedad y la presión, en una serie de puntos de la cuadrícula. Las variables meteorológicas que se necesitan como entrada para la predicción de la energía eólica incluyen obviamente la velocidad y la dirección del viento, pero también posiblemente la temperatura, la presión y la humedad. La distancia entre los puntos de la cuadrícula se denomina resolución espacial de los NWP. La malla suele tener un espaciado que varía entre unos pocos kilómetros y hasta 50 kilómetros para los modelos de mesoescala. Con respecto al eje temporal, la longitud de previsión de la mayoría de los modelos operativos actuales es de entre 48 y 172 horas, lo que se ajusta a los requisitos de la aplicación de la energía eólica. La resolución temporal suele estar comprendida entre 1 y 3 horas. Los modelos NWP imponen su resolución temporal a los métodos de previsión de energía eólica a corto plazo, ya que se utilizan como entrada directa.



**Figura 3.** Escala temporal de predicciones meteorológicas. CC BY-SA.  
Revista RETEMA

Los institutos meteorológicos proporcionan predicciones de variables meteorológicas. Los meteorólogos emplean modelos atmosféricos, o modelos regionales o de área limitada para realizar predicciones meteorológicas a medio, corto y muy corto plazo. Un modelo atmosférico es una aproximación numérica de la descripción física del estado de la atmósfera en el futuro cercano y, por lo general, se ejecuta en un superordenador. Cada cálculo comienza con las condiciones iniciales que se originan a partir de mediciones recientes. El resultado consiste en el valor instantáneo esperado de las magnitudes físicas en varios niveles verticales en una cuadrícula horizontal y en pasos de tiempo de hasta varias horas después del inicio. Hay varias razones por las que los modelos atmosféricos solo se aproximan a la realidad. En primer lugar, no todos los procesos atmosféricos relevantes están incluidos en el modelo. Además, las condiciones iniciales pueden contener errores (que, en el peor de los casos, se propagan) y el resultado solo está disponible para puntos discretos en el espacio (tanto horizontal como vertical) y en el tiempo. Finalmente, las condiciones iniciales envejecen con el tiempo: ya son antiguas cuando comienza el cálculo, y más aún cuando se publica el resultado. Las predicciones de las variables meteorológicas se emiten varias veces al día (normalmente entre 2 y 4 veces al día) y están disponibles pocas horas después del comienzo del período de previsión. Esto se debe a que se necesita un tiempo para adquirir y analizar la gran cantidad de mediciones utilizadas como entrada para los modelos NWP, luego ejecutar el modelo y verificar y distribuir la serie de predicciones de salida. Esta brecha es un punto ciego en las predicciones de un modelo atmosférico. Como ejemplo en los Países Bajos, KNMI publica 4 veces al día los valores esperados de velocidad del viento, dirección del viento, temperatura y presión para el período comprendido entre 0 y 48

horas después de la inicialización del modelo atmosférico HIRLAM<sup>5</sup> con los datos medidos, y luego el período antes de la entrega de la previsión es de 4 horas.

Existen muchos modelos atmosféricos diferentes, desde herramientas de investigación académica hasta modelos completamente operativos. Además de la naturaleza misma del modelo (procesos físicos o esquemas numéricos), existen algunas diferencias claras entre ellos: dominio temporal (desde varias horas hasta 6 días de antelación), área (desde varios miles de km<sup>2</sup> hasta un área que cubre la mitad del planeta), resolución horizontal (desde 1 km hasta 100 km) y resolución temporal (desde 1 hora hasta varias horas).

Uno de los modelos atmosféricos es el modelo de área limitada de alta resolución, abreviado HIRLAM, que se utiliza con frecuencia en Europa. HIRLAM se presenta en muchas versiones; por eso es mejor hablar de "un" HIRLAM en lugar de "el" HIRLAM. Cada versión es mantenida por un instituto nacional y cada instituto tiene varias versiones bajo su tutela, divididas en categorías como: operativa, preoperativa, semioperativa y para fines de investigación.

Otros modelos atmosféricos son:

- UM<sup>6</sup> en el Reino Unido, administrado por Met Office,
- COSMO<sup>7</sup> e ICON<sup>8</sup> en Alemania, administrados por DWD,
- ALADIN<sup>9</sup> en Francia, administrado por Météo-France,

---

<sup>5</sup>[https://www.aemet.es/documentos/es/conocerlas/recursos\\_en\\_linea/publicaciones\\_y\\_estudios/publicaciones/Fisica\\_del\\_caos\\_en\\_la\\_predicc\\_meteo/20\\_El\\_consortio\\_HIRLAM\\_y\\_el\\_SPC\\_GLAMEPS.pdf](https://www.aemet.es/documentos/es/conocerlas/recursos_en_linea/publicaciones_y_estudios/publicaciones/Fisica_del_caos_en_la_predicc_meteo/20_El_consortio_HIRLAM_y_el_SPC_GLAMEPS.pdf)

<sup>6</sup> <https://www.metoffice.gov.uk/research/approach/collaboration/unified-model/partnership>

<sup>7</sup>

[https://www.dwd.de/EN/research/weatherforecasting/num\\_modelling/01\\_num\\_weather\\_prediction\\_modells/regional\\_model\\_cosmo\\_eu.html](https://www.dwd.de/EN/research/weatherforecasting/num_modelling/01_num_weather_prediction_modells/regional_model_cosmo_eu.html)

<sup>8</sup> <https://open-meteo.com/en/docs/dwd-api>

<sup>9</sup> <https://www.umr-cnrm.fr/aladin/>

- GFS (Global Forecast System) <sup>10</sup>en los EE. UU., administrado por NCEP.

Cabe señalar que ALADIN y COSMO también se utilizan en otros países de Europa como AEMET<sup>11</sup> en España, mientras que UM ha sido utilizado por BOM en Australia.

## **Como es el enfoque físico de estos modelos para la previsión de la energía renovable?**

Las predicciones meteorológicas se dan en nodos específicos de una cuadrícula que cubre un área. Dado que normalmente los parques eólicos o las centrales solares fotovoltaicas no están situadas en estos nodos, es necesario extrapolar estas predicciones a la ubicación deseada de la central y en el caso de la eólica a la altura del eje del rotor o buje del aerogenerador. Los métodos de predicción basados en la física constan de varios submodelos que en conjunto entregan la traducción de la predicción del viento en un cierto punto de la cuadrícula y nivel de modelo, a la predicción de la energía en el sitio considerado. Cada submodelo contiene la descripción matemática de los procesos físicos relevantes para la traducción. Por lo tanto, el conocimiento de todos los procesos relevantes es crucial al desarrollar un método de predicción puramente físico, como las primeras versiones del Prediktor danés <sup>12</sup>(Ahora TGS). La idea central de los enfoques físicos es refinar (Hacer el downscaling) de los modelos de predicción numérica del tiempo meteorológico (NWP) utilizando

---

<sup>10</sup>

[https://catalog.data.gov/dataset/global-forecast-system-gfs-1-deg2#:~:text=The%20Global%20Forecast%20System%20\(GFS,moisture%20and%20atmospheric%20ozone%20concentration.](https://catalog.data.gov/dataset/global-forecast-system-gfs-1-deg2#:~:text=The%20Global%20Forecast%20System%20(GFS,moisture%20and%20atmospheric%20ozone%20concentration.)

<sup>11</sup>

[https://www.aemet.es/documentos/es/conocermas/recursos\\_en\\_linea/publicaciones\\_y\\_estudios/publicaciones/Fisica\\_del\\_caos\\_en\\_la\\_predicc\\_meteo/10\\_Modelos\\_atmosfericos.pdf](https://www.aemet.es/documentos/es/conocermas/recursos_en_linea/publicaciones_y_estudios/publicaciones/Fisica_del_caos_en_la_predicc_meteo/10_Modelos_atmosfericos.pdf)

<sup>12</sup> <https://www.prediktor.com/>

consideraciones físicas sobre el terreno, como la rugosidad, la orografía y los obstáculos, y modelando el perfil del viento local posiblemente teniendo en cuenta la estabilidad atmosférica.

Los vientos cercanos a la superficie sobre terrenos complejos generalmente presentan una gran variabilidad a escala local. La predicción de estos vientos requiere modelos numéricos de predicción meteorológica (NWP) de alta resolución, que aumentan drásticamente la duración de las simulaciones y dificultan su ejecución de forma rutinaria. Sin embargo, los métodos de reducción de escala pueden ayudar a pronosticar estos flujos de viento con un costo numérico limitado.

Las dos alternativas principales para hacerlo son: (i) combinar el modelado del perfil del viento (con un supuesto logarítmico en la mayoría de los casos) y la ley de arrastre geostrófico para obtener vientos de superficie; (ii) mediante métodos estadísticos como por ejemplo mediante el uso de redes neuronales convolucionales (CNN) <sup>13</sup>a partir de las predicciones del modelo de investigación WRF<sup>14</sup> (Weather Research Forecasting) desarrollado por el National Center for Atmospheric Research (NCAR) en EEUU, desde su resolución original de 9 km a una cuadrícula de resolución de 1 km y utilizando los resultados del modelo NWP de 1 km para ajustarlo. (iii) utilizar un código de simulación fluido dinámica, denominados en inglés CFD (Computational Fluid Dynamics), que permita calcular con precisión el campo de viento que verá el parque eólico, considerando una descripción completa del terreno.

Una vez que ya logramos predecir la velocidad y dirección del viento a nivel del parque eólico y a la altura de eje del rotor (buje) de los aerogeneradores, el segundo paso consiste en convertir la velocidad del viento en potencia. Por lo general, ésta tarea se lleva a cabo con curvas de potencia<sup>15</sup> teóricas proporcionadas por los

---

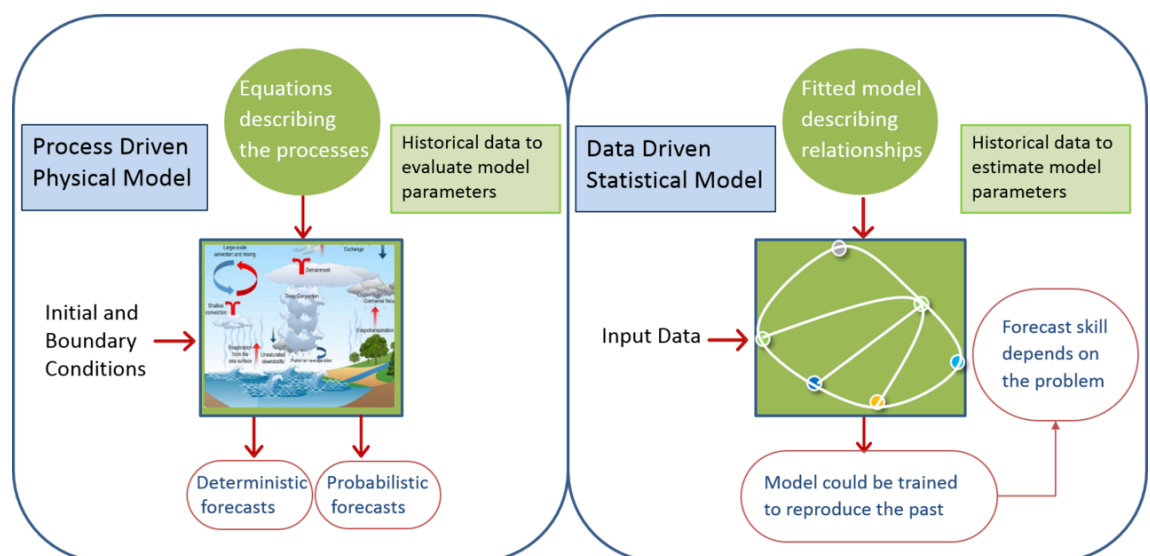
<sup>13</sup> <https://www.ibm.com/es-es/topics/convolutional-neural-networks>

<sup>14</sup> <https://www.mmm.ucar.edu/models/wrf>

<sup>15</sup> <https://www.dekra.es/es/curva-de-potencia-medicion-recurso-eolico/>



fabricantes de los aerogeneradores. Sin embargo, dado que varios estudios han demostrado el interés de utilizar curvas de potencia derivadas empíricamente en lugar de teóricas, las curvas de potencia teóricas se tienen cada vez menos en cuenta. Al aplicar una metodología física, el modelado de la función que da la generación eólica de los modelos de predicción numérica del tiempo meteorológico NWP en ubicaciones dadas alrededor del parque eólico se realiza de una vez por todas. Luego, la función de transferencia estimada se aplica en consecuencia a las predicciones meteorológicas disponibles en un momento dado. Para tener en cuenta los errores sistemáticos de predicción que pueden deberse al modelo de predicción numérica del tiempo meteorológico NWP o a su enfoque de modelado, los modeladores físicos a menudo integran estadísticas de salida del modelo (MOS- Model Output Statistics) para el posprocesamiento de las predicciones de potencia. Las estadísticas de salida del modelo (MOS) es un método que utiliza un modelo de regresión para relacionar la salida del modelo y los datos observados y, a continuación, aplica los coeficientes de regresión para corregir la salida del modelo.



**Figura 2** Comparación entre métodos de predicción basados en modelos estadísticos y modelos físicos. (Fuente: Process Driven Physical Models vs Data Driven Statistical Models. Balakrishnan Bhaskaran. Imperial College London.)

- **Métodos híbridos:** Los métodos avanzados para la predicción de la energía eólica a corto plazo requieren predicciones de variables meteorológicas como entrada. Luego, difieren en la forma en que las predicciones de las variables meteorológicas se convierten en predicciones de la producción de energía eólica, a través de la llamada curva de potencia. Estos **métodos avanzados** se dividen tradicionalmente en dos grupos.
  - El primer grupo, conocido como **enfoque físico**, se centra en la descripción del flujo de viento alrededor y dentro del parque eólico, y utiliza la curva de potencia del fabricante del aerogenerador para proponer una estimación de la producción de energía eólica.
  - Paralelamente, el segundo grupo, conocido como **enfoque estadístico**, se concentra en capturar la relación entre las predicciones meteorológicas (y posiblemente las mediciones históricas) y la producción de energía a través de modelos estadísticos cuyos parámetros deben estimarse a partir de los datos, sin hacer ninguna suposición sobre los fenómenos físicos.

### Que es la incertidumbre de las previsiones de energías renovables?

Los diseños actuales son óptimos sólo para condiciones estables y no turbulentas. Las herramientas de diseño que tienen en cuenta la inestabilidad y la turbulencia están mucho menos desarrolladas.

Las predicciones de la producción de energía eólica se proporcionan tradicionalmente en forma de previsiones puntuales, es decir, un único valor para cada tiempo de previsión, que corresponde a la expectativa o al resultado más probable. Tienen la ventaja de ser fácilmente comprensibles porque se espera que este único valor diga todo sobre la generación de energía futura.

Hoy en día, una parte importante de los esfuerzos de investigación sobre la previsión de energía eólica todavía se centran sólo en la predicción puntual, con el objetivo de asimilar cada vez más observaciones en los modelos o refinar la resolución de los modelos físicos para representar mejor los campos de viento a escala muy local, por ejemplo. Estos esfuerzos pueden conducir a una disminución significativa del nivel de error de predicción.

Sin embargo, incluso mediante una mejor comprensión y modelización de los procesos meteorológicos y de conversión de energía, siempre habrá una incertidumbre inherente e irreducible en cada predicción.

Esta incertidumbre epistémica corresponde al conocimiento incompleto que uno tiene de los procesos que influyen en los eventos futuros, normalmente debido a la falta de suficientes datos

Por lo tanto, además de las predicciones puntuales de la generación eólica para las próximas horas o días, es de gran importancia proporcionar medios para evaluar en línea la precisión de estas predicciones. En la práctica, hoy en día, la incertidumbre se expresa en forma de pronósticos probabilísticos o con índices de riesgo proporcionados junto con las predicciones puntuales tradicionales. Se ha demostrado que algunas decisiones relacionadas con la gestión y el comercio de energía eólica son más óptimas cuando se tiene en cuenta la incertidumbre de predicción. Para el ejemplo de la aplicación comercial, los estudios han demostrado que la estimación confiable de la incertidumbre de predicción permite al productor de energía eólica aumentar significativamente sus ingresos en comparación con el uso exclusivo de un método avanzado de pronóstico puntual. Otros estudios de este tipo tratan sobre la cuantificación dinámica óptima de los requisitos de reserva, el funcionamiento óptimo de sistemas combinados que incluyen la energía eólica, o la regulación multietapa multiárea. Se esperan cada vez más esfuerzos de investigación sobre la incertidumbre de predicción y temas relacionados.

## **Como se puede mejorar la predicción de los recursos renovables**

Las vías para mejorar la predicción de los recursos renovables se han centrado en utilizar más datos, a poder ser de la mayor calidad posible y contrastada, como entrada para los modelos utilizados y también proporcionar estimaciones de la incertidumbre junto con las predicciones proporcionadas tradicionalmente.

Hoy en día, la aplicación de nuevas técnicas de Inteligencia Artificial con algoritmos entrenados con datos medidos tanto históricos como continuos de múltiples variables, datos obtenidos a partir de modelos físicos o reanálisis, datos de satélite, etc. están dando lugar a resultados sorprendentes. Una de las mayores barreras es la accesibilidad a los datos de calidad por problemas de seguridad, confidencialidad, etc.

## **Predicción de recursos renovables con Inteligencia Artificial (IA).**

Los programas de IA pueden combinar modelos meteorológicos de aprendizaje automático, conjuntos de datos históricos, información en tiempo real de estaciones meteorológicas locales, imágenes satelitales, cámaras y redes de sensores.

Cuando no se prevé que no haya suficiente producción con fuentes renovables, una predicción optimizada puede dar lugar a una gestión más eficaz de las centrales de generación eléctrica basadas en fuentes de energía convencionales o de los sistemas de almacenamiento de energía (hidráulica reversible, baterías, etc.) y reducir el coste de arranque y parada de dichas unidades cuando operan respaldando al sistema, haciendo un uso óptimo de dichas plantas adaptando la producción a las condiciones climáticas cambiantes que van a influir en

la producción de las centrales basadas en fuentes renovables. La predicción también puede ayudar a reducir de forma decisiva el coste de los denominados vertidos (curtailment) de energía renovable como la energía eólica y la solar fotovoltaica cuando por distintas razones no puede evacuarse toda la energía disponible por la red eléctrica (congestión por exceso de generación simultánea o por reducción de la demanda y por lo tanto del precio de la energía eléctrica). La predicción también puede ayudar de forma crítica a obtener mejores precios de la energía la reducción de los costes de operación y mantenimiento de las centrales renovables al facilitar la aplicación de mantenimiento predictivo. También una previsión más precisa de la producción de energías renovables permite a los generadores y comercializadores de energía ofertar en los mercados mayorista y de balance, evitando penalizaciones por posibles desvíos frente a la energía ofertada.

La comercialización de la energía en España está hoy en día liberalizada. Existen multitud de empresas comercializadoras de energía que necesitan conocer la generación y la demanda de energía prevista a corto plazo para hacer sus ofertas en el mercado de la energía.

Como todos sabemos las fuentes de energía renovables con mayor capacidad instalada como es la energía eólica y la solar fotovoltaica son variables y dependen del recurso existente en cada instante.

En ambos casos, la predicción precisa es vital para conocer cuanta energía somos capaces de suministrar en cada instante.

Las técnicas de predicción del tiempo meteorológico mediante inteligencia artificial no utilizan los modelos numéricos basados en ecuaciones que pretenden representar la física de la atmósfera. En la predicción numérica del tiempo meteorológico tradicional se utilizan cada vez mayores recursos informáticos para poder mejorar la precisión y la

rapidez de la predicción meteorológica, pero no utiliza directamente datos meteorológicos históricos para mejorar el modelo subyacente.

En cambio la predicción del tiempo meteorológico con IA se basa en algoritmos basados en el aprendizaje automático, en inglés *Machine Learning ML* entrenado directamente a partir de múltiples fuentes de datos aunque los mas utilizados son los datos obtenidos a partir de técnicas de reanálisis.

### **Que son los datos de reanálisis meteorológico?**

Los datos de reanálisis meteorológico se producen a partir de la combinación de datos de medición, observación, simulación y aplicando técnicas de asimilación de datos, para obtener la descripción más realista de las ocurrencias climáticas. Estos conjuntos de datos sólo están disponibles para los períodos históricos y con un retraso sustancial de varias semanas o meses. El ms utilizado es el denominado ERA5<sup>16</sup> desarrollado por el Centro Europeo de Previsiones Meteorológicas a Plazo Medio (ECMWF), con datos globales horarios con una resolución espacial de 31 km. Dispone de series de datos desde 1940.

La técnica del aprendizaje automático a partir de datos de reanálisis permite predecir cientos de variables meteorológicas por ejemplo para los próximos 10 días con una resolución de 0,25° a nivel mundial en menos de 1 minuto con niveles de error muy reducidos. Por ejemplo Google está desarrollando el programa *GraphCast*<sup>17</sup>, que supera significativamente a los sistemas deterministas operativos más precisos en el 90 % de los 1380 objetivos de verificación, y sus previsiones respaldan una mejor predicción de eventos severos, incluido el

---

<sup>16</sup> <https://cds.climate.copernicus.eu/datasets/reanalysis-era5-single-levels?tab=overview>

<sup>17</sup>

<https://deepmind.google/discover/blog/graphcast-ai-model-for-faster-and-more-accurate-global-weather-forecasting/>

seguimiento de ciclones tropicales, ríos atmosféricos y temperaturas extremas. GraphCast es un avance clave en la previsión meteorológica precisa y eficiente y ayuda a hacer realidad la promesa del aprendizaje automático para modelar sistemas dinámicos complejos.

También para la predicción a muy corto y corto plazo de fluctuaciones de potencia renovable provocadas por ejemplo por la aparición de nubes o variaciones de dirección de viento o rampas, se utiliza la combinación de datos instantáneos (medidas, satélites, cámaras, etc.) junto con salidas de varios modelos numéricos y técnicas de aprendizaje automático permite aumentar el grado de precisión en la predicción instantánea de eventos vitales para la gestión del sistema eléctrico. Esta técnica denominada *nowcasting* se está imponiendo en la gestión de plantas de generación renovable. En este sentido la herramienta EA3<sup>18</sup> desarrollada en España por el Instituto de Ingeniería del Conocimiento (IIC) está teniendo bastante aceptación en la optimización de plantas renovables tanto solares, eólica como híbridas.

Por lo tanto, las técnicas de inteligencia artificial en especial el aprendizaje automático (en inglés Machine Learning ML) son muy útiles para reducir el error en la predicción tanto de la generación renovable variable a partir de los datos meteorológicos como también se puede aplicar a la demanda de energía a partir de los datos de consumo de energía.

El aprendizaje automático es probablemente la tecnología más precisa para llevar a cabo la predicción de la demanda. Se basa en la aplicación de un análisis avanzado mediante la cual se entrena el modelo estadístico con los datos de demanda de un sistema energético concreto, puede ser una vivienda, una fábrica, una ciudad, una región o incluso un país y se establecen variables que puedan impactar en dicha demanda.

---

18

<https://www.iic.uam.es/soluciones/energia/prediccion-generacion-energia-renovable/sistema-prediccion-energia-renovable/>

Después se comparan varios modelos distintos de predicción para ver cuál se ajusta más al modelo de demanda de la empresa. La precisión de esta técnica normalmente es mayor que con otros métodos y permite extraer muchas conclusiones útiles a partir de los datos obtenidos.

Para hacer un estudio de predicción de la demanda de energía o del recurso se necesita disponer del mayor número de series temporales de consumo de energía (Potencia demandada en kilovatios en función del tiempo) o de recurso solar o eólico.

Por ejemplo, cuando se trata de predecir el comportamiento del viento, normalmente la velocidad y la dirección del viento es fundamental introducir los datos a intervalos regulares de tiempo, para que el modelo pueda aprender por la evolución de estos datos a lo largo del tiempo.

Ya se ha comentado que en la predicción de series temporales se utilizan técnicas como la autorregresiva, la autorregresiva vectorial, (autoregressive, moving average, autoregressive moving average, vector autoregressive), entre otras, las cuales permiten predecir la producción de las fuentes de energía basándose en la observación del pasado.

Las redes neuronales artificiales RNA (En inglés ANN Artificial Neural Networks) incluyen lo que se denomina el *aprendizaje profundo* (En inglés *Deep Learning DL*), una forma avanzada de aprendizaje automático o de máquina inspirada en la forma en la que funciona el cerebro. El procesamiento de los datos se realiza mediante capas que forman parte de la red neuronal. Hacen falta un mínimo de tres capas, la capa de entrada, la capa oculta y la capa de salida, las cuales mediante procesos matemáticos entregan valores continuos que representan el resultado. El desarrollo de los resultados se obtiene mediante varias etapas, las cuales consisten en: entrenamiento de la RNA con el 85% de los datos históricos, prueba de la red neuronal artificial RNA bajo el



criterio de evaluación denominado "Error Porcentual Absoluto Medio EPAM (en inglés Mean Absolute Percentage Error- MAPE) entre el 15% de los valores no utilizados en el entrenamiento frente a la proyección para dicha cantidad de históricos, esta etapa permite demostrar la confiabilidad del modelo en base al porcentaje de error, y así realizar una proyección con mayor horizonte de tiempo.

El aprendizaje profundo es muy valioso en la industria de la energía, ya que los algoritmos son adecuados para grandes conjuntos de datos. En el caso de los datos históricos de generación y consumo de energía, los datos tienden a ser bastante masivos, y requieren técnicas específicas para ser procesados y analizados de manera eficiente.

## **Que métodos de validación de los modelos de predicción existen?**

Tenemos claro que los usuarios quieren que las previsiones sean buenas, robustas y estables en el tiempo, pero como verificarlo. Cualquier predicción meteorológica tiene que verificarse mediante un proceso de control de calidad. En el procedimiento de verificación se utilizan tanto los datos observados como la información preprocesada.

Normalmente se dispone de múltiples fuentes de datos observacionales. Estaciones con medidas de múltiples variables como la temperatura, el viento, la humedad, nubes, precipitaciones además de perfiles verticales de temperatura, viento y humedad. También a partir de los datos satelitales es posible obtener información sobre la cobertura de nubes, el tipo de nubes, la temperatura y el viento con una resolución muy alta en el tiempo y el espacio. Esta resolución muy alta proporciona información sobre objetos individuales (patrones de lluvia, distribución de nubes), lo que puede permitir el estudio de las propiedades de estos elementos

meteorológicos, algo que no es posible cuando se utilizan solo observaciones de superficie.

En general, los modelos numéricos de predicción meteorológica producen predicciones que representan un promedio para el área alrededor de un punto de la cuadrícula. Las observaciones son más o menos representativas del área que rodea el sitio de observación y no son necesariamente representativas de la media del área alrededor de un punto de la cuadrícula. Este problema significa que las predicciones del modelo y las observaciones de superficie no se pueden comparar directamente. Si hay muchas observaciones disponibles dentro de una celda de la cuadrícula, es posible calcular una media del área a partir de estas observaciones, lo que da una mejor estimación del valor de la predicción que una sola observación. Otra posibilidad es calcular valores representativos para la celda de la cuadrícula a partir de muchas mediciones utilizando algoritmos de interpolación refinados. Este denominado análisis numérico es una herramienta muy importante para la verificación y es particularmente adecuado para la verificación de modelos numéricos de predicción meteorológica. En algunos casos tiene sentido calcular medias del área para regiones que son más grandes que un punto de la cuadrícula, tanto para observaciones como para pronósticos (por ejemplo, áreas de captación de ríos o regiones con condiciones meteorológicas significativas). Además de las incertidumbres resultantes de las discrepancias en la ubicación de las observaciones y los puntos de la cuadrícula del modelo, también existen incertidumbres fundamentales relacionadas con la predicción en sí. Por ejemplo, algunos fenómenos meteorológicos tienen una escala horizontal que no se puede modelar con modelos numéricos porque su resolución no es lo suficientemente alta como para simular un fenómeno de escala tan pequeña. Además, no es posible simular todos los aspectos del clima real con un modelo numérico. En respuesta a estas incertidumbres, se han desarrollado métodos que permiten calcular la probabilidad de ocurrencia de un determinado fenómeno meteorológico. Estos enfoques

de conjunto son cada vez más importantes a medida que la resolución horizontal de los modelos se vuelve cada vez más precisa.

Para evaluar la calidad de las predicciones se utilizan varias medidas conocidas como "puntuaciones". Estas puntuaciones deben identificar las diferencias típicas entre las predicciones y las observaciones. También deben mostrar posibles correlaciones entre los valores previstos y observados, y cuán precisas son las predicciones cuando se comparan con predicciones alternativas. Los métodos de verificación más avanzados permiten la evaluación de los resultados del modelo en condiciones específicas (verificación condicional).

Al aplicar la verificación objetiva, donde las predicciones en puntos de cuadrícula individuales se comparan con los valores de observación o análisis correspondientes, se hace una distinción entre medidas de calidad continuas y categóricas.

Las medidas de calidad continuas incluyen el "Error Medio" de predicción (Mean Error - ME), el "Error Medio Absoluto" de predicción (Mean Absolute Error-MAE), el "Error Cuadrático Medio" (Root Mean Squared Error - RMSE) y la desviación estándar (Estándar Deviation - STDEV).

El ME no mide la correspondencia entre la predicción y las observaciones, sino que muestra desviaciones sistemáticas, mientras que el MAE proporciona el tamaño medio del error. El RMSE y el STDEV crecen más rápidamente con grandes desviaciones porque están elevados al cuadrado; el STDEV contiene RMSE y ME, y es una medida de la varianza del error de predicción: si ME es cero, STDEV y RMSE son iguales.

**¿En qué medida las técnicas de predicción de los recursos renovables mediante Inteligencia**

## **Artificial, pueden contribuir a la mejora del medioambiente en su relación con el cambio climático?**

Las técnicas de predicción de recursos renovables mediante IA contribuirán de forma definitiva a la mejora del medioambiente al facilitar la optimización de los sistemas energéticos mediante la mejora de la modelización y la predicción climática.

La variabilidad e intermitencia de las fuentes de energía renovable, como la solar y la eólica, plantean desafíos en su integración en las redes de energía existentes. La IA ofrece soluciones para realizar predicciones precisas de energía renovable y mejorar las estrategias de integración. Los algoritmos de IA pueden analizar datos históricos y en tiempo real, incluidos los patrones climáticos, la radiación solar, la velocidad del viento y los datos de generación de energía, para predecir y optimizar la producción de energía renovable. Las predicciones precisas permiten a los operadores de la red equilibrar la oferta y la demanda, reducir las restricciones y optimizar el almacenamiento y la distribución de energía.

## **Cuál es el potencial que la inteligencia artificial para la predicción del clima y de los recursos renovables?**

La prestigiosa revista de ciencia Nature<sup>19</sup> publicó recientemente un artículo donde se explicaba el enorme potencial que la inteligencia artificial supone para la predicción del clima. En este artículo se describe cómo el modelo de predicción climática a nivel global *Pangu Weather* de la compañía china Huawei ofrece una muy alta precisión mediante el uso de la IA basada en el aprendizaje profundo de información recopilada durante 43 años.

*Pangu Weather* es el primer modelo de predicción de IA que demuestra una mayor precisión que los métodos numéricos tradicionales de pronóstico del tiempo. *Pangu* permite una mejora del orden de 10.000

---

<sup>19</sup> <https://www.nature.com/articles/s41586-023-06185-3>

veces en la velocidad para obtener la predicción, reduciendo el tiempo de predicción del clima global a solo unos segundos. El modelo se centra en los elementos clave y en intervalos de tiempo comunes, lo cual hace posibles predicciones climáticas sean más exactas. De hecho, esta solución con IA predijo con precisión las trayectorias y los horarios de la llegada a tierra de algunos tifones, incluido el reciente llamado Mawar en mayo de este año, lo cual demuestra sus capacidades excepcionales.

También la empresa norteamericana NVIDIA ha desarrollado el modelo de predicción del tiempo meteorológico FourCastNet<sup>20</sup> basado en IA generativa y datos. Este modelo transforma las predicciones meteorológicas y climáticas mediante grandes conjuntos masivos de predicciones de alta resolución generados por Inteligencia Artificial.

También en la revista Science<sup>21</sup> se habla del modelo GraphCast<sup>22</sup> basado en IA y desarrollado por Google DeepMind es capaz de obtener predicciones meteorológicas muy precisas en muy corto plazo de tiempo y además advertir sobre fenómenos extremos de manera temprana con lo que eso supone en ahorro de costes en múltiples situaciones meteorológicas críticas.

## **Modelos de predicción basados en datos o en modelos físicos? Cual es mejor?**

Sabemos que los modelos de circulación general (GCM), que llevan dominando la predicción meteorológica en los últimos 50 años, utilizan complejas ecuaciones para modelizar los cambios en la atmósfera y ofrecer previsiones precisas, pero su ejecución es excesivamente lenta y costosa.

Aunque los expertos en meteorología discrepan sobre si el aprendizaje automático o los métodos más tradicionales son más efectivos a la hora de predecir el tiempo, los nuevos modelos basados en la combinación del aprendizaje automático con otras técnicas convencionales parece que está dando lugar a predicciones precisas y rápidas con un coste menor.

---

<sup>20</sup> <https://resources.nvidia.com/en-us-hpc-ai/weather-prediction>

<sup>21</sup> <https://www.science.org/stoken/author-tokens/ST-1550/full>

<sup>22</sup>

<https://www.esmartcity.es/2024/02/29/predicciones-meteorologicas-modelo-basado-ia-graphcast-advirten-fenomenos-extremos-manera-temprana>

Por otro lado, los modelos de aprendizaje automático entrenados a partir años pasados con datos de reanálisis han logrado una habilidad comparable o mejor que los GCM para la predicción meteorológica determinista, sin embargo estos modelos no han demostrado predicciones de conjunto mejoradas ni han mostrado suficiente estabilidad para simulaciones meteorológicas y climáticas a largo plazo.

En la revista Nature<sup>23</sup> se habla de los nuevos modelos neuronales de la circulación general como el NeuralGCM<sup>24</sup> desarrollado por Google Research para predecir el clima y el tiempo meteorológico. El modelo NeuralGCM combina un solucionador diferenciable para dinámicas atmosféricas con componentes de aprendizaje automático y puede generar predicciones de clima y tiempo deterministas igual que los mejores métodos basados en física y aprendizaje automático. NeuralGCM es competitivo con los modelos de aprendizaje automático para predicciones de uno a diez días, y con la predicción de conjunto del Centro Europeo de Previsiones Meteorológicas a Plazo Medio para predicciones de uno a quince días.

Por lo tanto se trata de juntar los modelos físicos y la inteligencia artificial. El sistema sigue utilizando un modelo convencional para calcular algunos de los grandes cambios atmosféricos necesarios para hacer una predicción. A continuación, incorpora la IA, que suele dar buenos resultados allí donde esos modelos de mayor envergadura fallan, normalmente para predicciones a escalas inferiores a unos 25 kilómetros, como las que tienen que ver con formaciones nubosas o microclimas regionales. El resultado es un modelo que puede producir predicciones de calidad más rápidamente con menos potencia de cálculo. La inteligencia artificial por lo tanto puede utilizarse en

---

<sup>23</sup> <https://www.nature.com/articles/s41586-024-07744-y>

<sup>24</sup>

<https://www.technologyreview.es/s/16556/ia-y-fisica-la-mezcla-perfecta-para-predecir-el-tiempo-segun-google>

determinados elementos de la modelización meteorológica para hacer el modelo más ágil sin perder los puntos fuertes de los sistemas convencionales.

## **Bibliografía.**

### **Instituto de Ingeniería del Conocimiento (IIC)**

Explica la herramienta de predicción de energía renovable

<https://www.iic.uam.es/soluciones/energia/prediccion-generacion-energia-renovable/sistema-prediccion-energia-renovable/>

### **Red Eléctrica de España (REE)**

El operador del sistema realiza una previsión de la demanda eléctrica y de la generación renovable. (anual, diario e intradiario)

<https://www.esios.ree.es/es/pagina/previsiones-demanda-renovable>

### **Modelos de predicción meteorológica. Cual elegir?**

<https://es.blog.sencrop.com/modelos-de-prevision-meteorologica-cual-elegir/>

### **Proyecto IA4TES “Inteligencia artificial para la transición energética sostenible”**

El objetivo del proyecto IA4TES es el desarrollo y aplicación innovadora de tecnologías de Inteligencia Artificial a la resolución de los retos de la transición Energética sostenible, habilitando un nuevo paradigma de sistema eléctrico.

<https://www.ia4tes.org/>

### **Proyecto Smart4RES. “Next Generation modelling and forecasting of variable renewable generation for large scale integration in energy systems and markets”**

En este proyecto se mejoran los modelos numéricos de predicción meteorológica para las fuentes de energías renovables, mediante la integración de datos de satélites e imágenes.

<https://cordis.europa.eu/article/id/449485-new-tools-boost-short-term-forecasting-accuracy-of-renewable-energy-sources/es>

### **Universidad de la Laguna**

Tesis de grado sobre técnicas de inteligencia artificial para la predicción de energía renovable

<https://riull.ull.es/xmlui/handle/915/25009>

**FLOBERS** Empresa que ayuda a tomar decisiones de inversión en renovables basándose en predicciones con IA

<https://www.flobers.com/blog/inteligencia-artificial-y-energias-renovables>

**ENERGY SpaceWell.** Empresa proveedora de predicción del consumo de la energía mediante machine learning y la IA

<https://www.dexma.com/es/blog-es/prediccion-del-consumo-de-energia-mediante-el-machine-learning-y-la-ia/>

**Proyecto ORCA-DEEP** de la Universidad de Cordoba

<https://www.uco.es/ucci/es/noticias-gen/item/4017-en-busca-de-nuevos-modelos-para-predecir-la-produccion-de-energia-en-parques-renovables>

**Barcelona Supercomputing Center** - Centro Nacional de Supercomputación (BSC-CNS)

<https://www.elimparcial.es/noticia/238060/>

**Cómo se utiliza la IA para pronosticar los recursos de energía renovable?**

<https://www.linkedin.com/advice/3/how-do-you-use-ai-forecast-renewable-energy?lang=es&originalSubdomain=es>

**IA360.** Aprendizaje automático en el campo de la energía: predicción y optimización

<https://inteligenciaartificial360.com/fundamentos-ia/aprendizaje-automatico-en-el-campo-de-la-energia-prediccion-y-optimizacion/>

**Asociación Empresarial Eólica (AEE)**

<https://aeeolica.org/que-hay-de-inteligencia-artificial-en-la-gestion-de-las-energias-renovables/>

**GRAPHCAST by Google DeepMind**

<https://deepmind.google/discover/blog/graphcast-ai-model-for-faster-and-more-accurate-global-weather-forecasting/>

**Agencia Internacional de la Energía IEA Wind TCP. Tarea 51** "Forecasting for the weather-driven Energy System"/ Predicción para el sistema energético impulsado por el clima

<https://iea-wind.org/task51/>

## VIDEOS

**Instituto de Ingeniería del Conocimiento IIR**

Seminario: La meteorología en el sector de la energía: un paso más allá por Carlos Ribero Honegger (Catedra de Ciencia de Datos y Aprendizaje Automático) (En Español)

<https://www.youtube.com/watch?v=pwcy8piMJul>

**SPE EV GAIA - Uso de la Inteligencia Artificial en la Predicción de Energías Renovables.**

Presentación de Roderick Perez (Universidad de Viena) (Español)

<https://www.youtube.com/watch?v=gg4L20wAnDA&t=1680s>

**Integrando Energías Renovables Variables en el SENI (Sistema Eléctrico Nacional Interconectado de República Dominicana) con Pronósticos Confiables de Energía Eólica y Solar**

Mesa redonda sobre predicción de energías renovables en islas (En Español)

<https://www.youtube.com/watch?v=gDxmKXVpJrA>

**Lesson 1: Introduction to renewable energy forecasting**

Curso introductorio de H. Madsen (DTU) sobre Predicción de energía renovables (En inglés).

<https://www.youtube.com/watch?v=RZi5RjDKAH0>

**Masterclass by Gregor Giebel - Forecasting Wind Power**



Masterclass de Gregor Giebel (DTU) sobre Predicción de la potencia eólica. (En inglés)  
<https://www.youtube.com/watch?v=j-5xq3ZyMk0>