

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS
INDUSTRIALES Y DE TELECOMUNICACIÓN

UNIVERSIDAD DE CANTABRIA



Proyecto Fin de Grado

**Metodología de predicción para la gestión
dinámica de capacidad en líneas aéreas de
alta tensión**

**Prediction methodology for dynamic capacity
management in high voltage overhead lines**

Para acceder al Título de
GRADUADO EN INGENIERÍA ELÉCTRICA

Autor: Pablo Bolado Fernández

julio – 2025

En primer lugar, quiero expresar mi más profundo agradecimiento a mi familia, que ha sido y es lo más importante en mi vida. Ellos representan el pilar fundamental de todo lo que soy y todo lo que he conseguido. Gracias a su apoyo incondicional, hoy estoy donde estoy. Les estaré eternamente agradecido.

También quiero dedicar unas palabras a mis compañeros y amigos Alfonso y Santi, que, a lo largo de estos años, han sido un apoyo clave y una gran referencia. Sin duda, sin ellos este camino no habría sido tan llevadero, ni tan divertido. Me siento muy afortunado de haber compartido con ellos esta etapa y de haber forjado esta amistad.

Por último, quiero agradecer sinceramente a mi tutora, Raquel, por su dedicación, paciencia y ayuda durante estos últimos meses. Su implicación y profesionalidad han sido fundamentales para poder llevar a cabo este trabajo. Ha sido un privilegio contar con su guía.

RESUMEN

Este Trabajo de Fin de Grado desarrolla una metodología de predicción orientada a la gestión dinámica de la capacidad de transporte eléctrico ampacidad en líneas aéreas de alta tensión, considerando la influencia directa de las condiciones meteorológicas. Se emplea un enfoque híbrido que combina modelos térmicos normalizados CIGRE Y IEEE con técnicas de aprendizaje automático, particularmente Random Forest, para predecir tanto variables climáticas como la ampacidad de forma directa. Se construye una base de datos histórica de alta resolución a partir de registros meteorológicos reales gracias a unas estaciones meteorológicas instaladas en la línea de prueba, los cuales se utilizan para entrenar y validar modelos de predicción automática. Además, se compara el rendimiento del sistema propuesto frente a predicciones ofrecidas por servicios meteorológicos externos Open-Meteo, evaluando la precisión mediante métricas como RMSE y SMAPE. Los resultados obtenidos demuestran la viabilidad de utilizar predicciones locales para optimizar la operación de las líneas eléctricas, reduciendo restricciones y facilitando una mayor integración de generación renovable sin necesidad de ampliar infraestructuras. El sistema propuesto permite anticipar dinámicamente la capacidad disponible, mejorando así la eficiencia y flexibilidad operativa del sistema eléctrico.

ABSTRACT

This Final Degree Project develops a prediction methodology aimed at the dynamic management of the electrical transport capacity ampacity in high-voltage overhead lines, considering the direct influence of meteorological conditions. A hybrid approach is employed, combining standardized thermal models CIGRE and IEEE with machine learning techniques, specifically Random Forest, to predict both meteorological variables and ampacity directly. A high-resolution historical database is constructed from real meteorological records obtained through dedicated weather stations installed along the test line. These data are used to train and validate automatic prediction models. Furthermore, the performance of the proposed system is compared against forecasts provided by external meteorological services Open-Meteo, with accuracy evaluated using metrics such as RMSE and SMAPE. The results confirm the feasibility of using localized predictions to optimize the operation of power lines, reducing operational constraints and enabling greater integration of renewable generation without the need for infrastructure expansion. The proposed system allows for dynamic anticipation of the available capacity, thereby enhancing both the efficiency and operational flexibility of the electrical grid.

ÍNDICE DE LA MEMORIA

1	INTRODUCCIÓN	6
1.1	Gestión de las líneas eléctricas de alta tensión	6
1.1.1	Integración de energías renovables.....	6
1.1.2	Implicaciones Técnicas de la Alta Integración de Energías Renovables.....	7
1.1.3	Administración de las líneas eléctricas condicionada por la incorporación de energías renovables.	10
1.1.4	AMPACIDAD	14
1.1.5	Algoritmos de cálculo de ampacidad	15
	Parámetros y factores que considerar en IEEE:.....	17
	Diferencias principales entre CIGRE y IEEE	17
	Cálculo de la Ampacidad y Comparación	18
2	ALCANCE Y OBJETIVOS.....	19
2.1	Alcance	19
2.2	Objetivos	19
2.2.1	Objetivo general	19
2.2.2	Objetivos específicos.....	19
3	ESTADO DEL ARTE.....	21
3.1	Gestión dinámica actual	21
3.1.1	Ampacidad y sus Implicaciones.....	21
3.1.2	Monitorización en Tiempo Real	23
3.2	Instrumentos de gestión dinámica a corto plazo	24
3.2.1	Modelos de predicción meteorológica.....	24
3.2.2	Modelos de predicción basados en series temporales.....	26
4	METODOLOGÍA	37
4.1	Base de la metodología.....	37
4.2	Sistema para la predicción	42
4.2.1	Evaluación de los métodos para seleccionar el más adecuado	42
4.2.2	Pasos para el desarrollo del sistema de predicción	46

4.3	Comparativa sistema de predicción propio con variables medidas mediante estaciones meteorológicas en la línea	48
4.4	Comparativa servicios meteorológicos externos con variables medidas mediante estaciones meteorológicas en la línea	56
5	RESULTADOS.....	60
5.1	Resultados de mi sistema de predicción.....	60
5.1.1	Radiación	60
5.1.2	Temperatura ambiente	61
5.1.3	Viento	62
5.1.4	Dirección del viento	63
5.1.5	Ampacidad	64
5.2	Resultados del Servicio Open-Meteo	65
5.2.1	Radiación	65
5.2.2	Temperatura ambiente	67
5.2.3	Viento	68
5.2.4	Dirección del viento	69
5.2.5	Ampacidad	70
6	CONCLUSIÓN	72
7	BIBLIOGRAFÍA	74

1 INTRODUCCIÓN

1.1 Gestión de las líneas eléctricas de alta tensión

1.1.1 Integración de energías renovables

Hasta ahora el consumo energético en España ha enseñado una tendencia hacia un sistema más múltiple y equilibrado con una mayor participación de las energías renovables. La demanda eléctrica llegó a su máximo en 2008 y, posteriormente, experimentó una disminución, provocada inicialmente por la reducción en el consumo de productos petrolíferos y carbón, y, a partir de 2008, por la crisis económica. Este descenso en la demanda de fuentes convencionales ha sido parcialmente mantenido por el aumento de las energías renovables.

En 2023, las energías renovables mostraron un 50,8% de la generación eléctrica total en España, marcando un nuevo récord histórico.

Este incremento se debe, por una parte, al avance de la capacidad instalada en tecnologías como la solar fotovoltaica y la eólica. La energía solar fotovoltaica sufrió un crecimiento notable, con un incremento del 28% en su capacidad instalada durante 2023 sumando 5.594 MW y alcanzando un total de 25.549 MW.

Por otro lado, la energía eólica pasó los 30.000 MW de potencia instalada convirtiéndose como la principal fuente de generación eléctrica del país, abarcando más del 24% de la demanda en 2023.[1]

En cambio, la demanda de energía eléctrica en España en 2023 mostró una caída del 2,3% respecto al año anterior, llegando a un total de 244.665 GWh, el valor más reducido de toda la serie histórica desde 2007. [2]

Este bajón puede deberse a factores económicos y a mejoras en la eficiencia energética.

El aumento de las energías renovables en España está ampliamente vinculado a decisiones políticas y económicas. Aunque en ciertos países europeos las subvenciones e inversiones en proyectos de energías renovables se han visto reducidos debido a la situación económica, en España la implementación de estas fuentes de energía ha continuado, aunque a un ritmo más reducido. La inversión en infraestructuras es vital para adaptarse al aumento de instalaciones renovables. Red Eléctrica de España (REE) ha llevado a cabo grandes inversiones en la mejora y adecuación de la red. Según datos de la Comisión Nacional de los Mercados y la Competencia (CNMC), las empresas eléctricas en España invirtieron una media anual de 1.517 millones de euros en redes entre 2018 y 2022, con un máximo de 1.722 millones de euros en 2022. Es importante recalcar que las inversiones en redes eléctricas son de suma importancia para integrar las energías renovables en el sistema eléctrico y poder

llevar a cabo una transición energética eficiente. Las empresas del sector han mostrado la necesidad de aumentar estas inversiones para conseguir los retos de descarbonización y electrificación de la economía.[3]




Figura 1: Evolución anual de la generación de energía eléctrica (Gwh) [4]

En definitiva, el sistema eléctrico en España ha dado pasos importantes hacia una integración más amplia de las energías renovables, siendo la eólica y la solar fotovoltaica las que han asumido un papel protagonista en la producción de electricidad. Aun así, siguen existiendo retos, especialmente en lo que respecta a la inversión en infraestructuras y a la capacidad del sistema para adaptarse a las variaciones en la demanda energética.

1.1.2 Implicaciones Técnicas de la Alta Integración de Energías Renovables

La transición energética que está viviendo España, orientada hacia un modelo basado en fuentes renovables no gestionables como la solar fotovoltaica y la eólica, plantea retos importantes para garantizar la estabilidad y seguridad del sistema eléctrico. La progresiva desconexión de centrales de generación síncrona —como las nucleares, las térmicas de

carbón y las de ciclo combinado— está afectando a elementos clave para el funcionamiento de la red, como la inercia del sistema, la regulación de tensión y frecuencia, la disponibilidad de reservas operativas y la capacidad de respuesta ante incidencias.

A continuación, se van a analizar brevemente las principales implicaciones técnicas de este proceso de transformación para tener una vista general, poniendo el foco en la pérdida de soporte inercial y de control del flujo reactivo, y en cómo estas carencias pueden aumentar el riesgo de eventos críticos, incluidos apagones generalizados.

España está llevando a cabo una profunda reestructuración de su sistema eléctrico con el objetivo de alcanzar una generación completamente renovable en las próximas décadas, en línea con las directrices del Plan Nacional Integrado de Energía y Clima (PNIEC) y los compromisos asumidos a nivel europeo en materia de descarbonización. Como parte de este cambio, se ha venido desmantelando progresivamente el parque de centrales convencionales que durante décadas ha proporcionado estabilidad al sistema.[5]

Al mismo tiempo, la capacidad instalada de generación renovable intermitente ha crecido de forma muy significativa. A finales de 2024, la potencia combinada de la energía eólica y la solar supera los 80 GW, representando ya más del 60 % del total de capacidad del sistema eléctrico español. Esta transformación está dando lugar a un nuevo escenario técnico, con dinámicas diferentes a las del modelo tradicional, y que requiere una revisión profunda de las estrategias de operación y control de la red.[6]

Pérdida de generación síncrona: Consecuencias técnicas

Reducción de inercia del sistema

La inercia del sistema eléctrico, que aportan tradicionalmente los generadores síncronos mediante sus masas rotantes, desempeña un papel clave como amortiguador ante desequilibrios entre generación y consumo. Cuando se produce una pérdida súbita de carga o generación, la energía cinética almacenada en estos elementos permite mantener la frecuencia del sistema próxima a los 50 Hz, dando un margen de tiempo vital para que actúen las protecciones automáticas y las reservas de regulación.

Sin embargo, con la integración masiva de energías renovables conectadas mediante electrónica de potencia como por ejemplo inversores provoca que esta inercia física prácticamente desaparezca. Como consecuencia, la tasa de variación de frecuencia (RoCoF) aumenta de forma considerable, lo que reduce el tiempo de reacción y compromete la capacidad de respuesta de las reservas primarias. Si no se dispone de mecanismos alternativos bien coordinados, el sistema puede verse abocado a una caída de frecuencia que desemboque en apagones parciales o incluso totales.[7]

Debilitamiento del control de tensión

Los generadores síncronos también contribuyen de forma fundamental al control de tensión, gracias a su capacidad para suministrar o absorber potencia reactiva. Su progresiva retirada debilita el soporte de tensión en puntos clave de la red, especialmente en momentos de baja demanda o de alta penetración renovable.

Aunque los inversores actuales incorporan funciones como Volt-VAr o Volt-Watt para ofrecer cierto grado de regulación, su respuesta suele ser más lenta y menos robusta. Además, su comportamiento depende en gran medida del diseño interno del convertidor y del firmware que lo controla. En condiciones de sobrecarga o saturación térmica, estos dispositivos pueden priorizar su propia protección antes que aportar estabilidad al sistema, desconectándose automáticamente.[8]

Gestión de la Reserva Operativa y la Balanza Energética

La naturaleza intermitente de fuentes como la solar fotovoltaica o la eólica introduce una elevada variabilidad en los flujos de energía. Esta variabilidad complica la planificación del sistema y el despacho seguro de generación, sobre todo cuando una parte sustancial del mix energético proviene de tecnologías no gestionables.

La gestión de las reservas operativas, necesarias para corregir desviaciones inesperadas en escalas de minutos o segundos, se ve especialmente comprometida en este contexto. Además, el aumento de generación distribuida es decir el aumento en el uso de placas solares y pequeñas turbinas eólicas en los puntos de consumo reduce la capacidad del operador del sistema Red Eléctrica de España para monitorizar y controlar en tiempo real, lo que puede agravar los desequilibrios.[9]

Eventos de Contingencia y Riesgo Sistémico

En los últimos años, se han registrado situaciones críticas en el sistema eléctrico español, coincidiendo con momentos de alta generación renovable, baja demanda y congestión en las interconexiones internacionales. En escenarios de este tipo, una desconexión inesperada de un parque eólico o solar puede desencadenar una reacción en cadena si no existen suficientes reservas síncronas ni mecanismos de soporte dinámico, como baterías o compensadores síncronos.

Según simulaciones realizadas en el marco de ENTSO-E, una caída repentina de entre 3 y 5 GW de generación renovable podría provocar un colapso de frecuencia en menos de cinco segundos si no hay sistemas de respuesta rápida desplegados.[10], [11]

Soluciones Tecnológicas para mitigar el riesgo

Ante este nuevo contexto, será imprescindible dotar al sistema eléctrico español de herramientas tecnológicas capaces de garantizar su estabilidad. Algunas de las soluciones clave incluyen:

- Incorporación de inercia sintética o virtual, mediante inversores avanzados con control adaptativo.[12]
- Instalación de compensadores síncronos para mantener el control de tensión y frecuencia.
- Almacenamiento energético a gran escala, tanto mediante baterías como con sistemas de bombeo hidráulico.[13]
- Desarrollo de mercados de servicios de flexibilidad, que valoren económicamente la capacidad de respuesta rápida.[14][15]
- Aplicación de estrategias de redistribución de flujos y diseño de redes adaptativas.
- Uso de herramientas de supervisión y predicción en tiempo real para anticipar cambios en la producción renovable y la demanda.[16], [17]

1.1.3 Administración de las líneas eléctricas condicionada por la incorporación de energías renovables.


La creación de nuevas líneas eléctricas se enfrenta actualmente a importantes obstáculos, tanto de tipo económico como por cuestiones legales y medioambientales. Estas dificultades han llevado a que muchas nuevas instalaciones de generación tengan que conectarse a la red eléctrica ya existente, una infraestructura que en muchos casos no fue diseñada para soportar los volúmenes de energía actuales. Como consecuencia, es frecuente que se impongan limitaciones técnicas con el fin de evitar la saturación de líneas que, originalmente, estaban dimensionadas para una demanda significativamente menor.

En este contexto, el acceso a la red no siempre puede garantizarse, tal y como recoge el Procedimiento de Operación P.O. 12.1, titulado “Solicitudes de acceso para la conexión de nuevas instalaciones a la red de transporte”. Este documento establece que:

“El derecho de acceso solo podrá ser restringido por falta de capacidad necesaria, cuya justificación se deberá exclusivamente a criterios de seguridad, regularidad o calidad del suministro.”[18]

Además, el Procedimiento de Operación P.O. 3.7, referido a la “Programación de la generación de origen renovable no gestionable”, identifica una serie de condiciones técnicas que pueden forzar la reducción de la producción eléctrica. Una de las más relevantes es la congestión en la evacuación de generación, que ocurre cuando se producen sobrecargas

inadmisibles en la red, impidiendo que la energía generada pueda ser evacuada adecuadamente.[19]



(1) Incluye biogás, biomasa, geotérmica, hidráulica marina, hidroeólica y residuos renovables.

Figura 2: Evolución de la potencia instalada renovable (MW)[20]

Uno de los principales retos para la integración de energías renovables en el sistema eléctrico es la aparición de ciertas limitaciones técnicas que afectan directamente a la seguridad y estabilidad de la red. Entre los aspectos más relevantes se encuentran los siguientes:

- Estabilidad del sistema: En determinadas situaciones, pueden producirse inestabilidades provocadas por huecos de tensión que comprometen el comportamiento dinámico de la red.
- Potencia de cortocircuito: En algunos nodos de la red de transporte, los valores de potencia de cortocircuito pueden situarse por debajo de los niveles necesarios para garantizar un funcionamiento seguro, lo que pone en riesgo la fiabilidad del sistema.
- Equilibrio entre potencias activa y reactiva: El operador del sistema está obligado a mantener un balance continuo entre la generación y la demanda, no solo en términos de energía activa, sino también de potencia reactiva, respetando siempre las condiciones operativas y los límites técnicos establecidos.
- Excedentes de generación no integrables: Cuando la generación renovable supera significativamente la demanda prevista y no puede gestionarse ni almacenarse, se generan excedentes que el sistema no está preparado para absorber.

Todos estos factores están contemplados en el Procedimiento de Operación P.O. 3.7, que regula la programación de la generación no gestionable. Por un lado, las limitaciones físicas

de capacidad en las líneas de transporte pueden generar congestiones que impidan evacuar toda la energía renovable disponible. Por otro, en situaciones excepcionales, la prioridad habitual que tienen las renovables en el despacho eléctrico puede verse afectada si la estabilidad del sistema, la potencia de cortocircuito o el balance de potencias no están garantizados, o si existen excedentes que no pueden integrarse en condiciones seguras.[21]




Figura 3: Evolución anual de la generación de energía renovable (Gwh)[22]

En la actualidad, las líneas eléctricas operan bajo límites estáticos bastante conservadores, lo que se traduce en que muchas de ellas funcionen cerca de su capacidad máxima cuando se conectan nuevas plantas de generación. Estos límites se calculan utilizando valores fijos de viento, temperatura ambiente y radiación solar, seleccionados con criterios muy restrictivos para garantizar márgenes amplios de seguridad. Aunque este enfoque permite una operación segura del sistema eléctrico, también lo vuelve poco eficiente.

Red Eléctrica de España (REE) define estos límites a través del Procedimiento de Operación P.O. 1.2, titulado "Niveles admisibles de carga de la red", donde se establece tanto la metodología de cálculo como la distribución estacional de dichos límites térmicos. Este procedimiento emplea tres modelos térmicos distintos:

- Aparamenta: Se tienen en cuenta las ecuaciones de comportamiento térmico de los equipos, los registros históricos de temperatura ambiente y la temperatura máxima permitida por el fabricante.
- Conductores: Además de su comportamiento térmico, se consideran factores como la temperatura ambiente histórica y la radiación solar media mensual. En los cálculos, se fija una velocidad de viento efectiva de 0,6 m/s.[23]
- Transformadores: Se aplican los criterios recogidos en la norma UNE-20-110-75, "Guía de carga para transformadores en aceite".

El resultado de este proceso son valores que, si bien garantizan un alto nivel de seguridad operativa, también limitan la flexibilidad del sistema. Esto puede llevar, en determinadas situaciones, a la necesidad de restringir la generación de origen renovable con el consiguiente desperdicio de energía limpia.

Desde el punto de vista regulatorio, tanto la normativa española como la europea otorgan prioridad al despacho de generación renovable, especialmente a aquellas tecnologías integradas en el régimen especial. Sin embargo, esta prioridad está condicionada por una serie de limitaciones técnicas definidas en el Procedimiento de Operación P.O. 3.7. Debido a la naturaleza intermitente y no gestionable de estas fuentes, pueden ser desplazadas del despacho cuando, por razones de seguridad, el sistema no es capaz de absorber toda la generación prevista.[24]

Cuando esto ocurre, se produce lo que se conoce como un vertido de energía renovable que consiste en la energía generada que no puede ser aprovechada. Este fenómeno no solo representa una pérdida desde el punto de vista operativo, sino también un retroceso en términos de sostenibilidad, ya que se desperdicia energía limpia por falta de infraestructura y capacidad de gestión.

En el ámbito europeo, el término "tecnología verde" se ha utilizado de forma estratégica y, en algunos casos, más por intereses políticos que por criterios puramente técnicos. Un ejemplo claro es la inclusión de la energía nuclear dentro de esta categoría, fruto de la presión ejercida por algunos países, entre ellos Francia, que ha defendido su continuidad como fuente sostenible para atraer inversiones y garantizar su desarrollo. Este tipo de decisiones muestra cómo, en muchas ocasiones, la política energética está fuertemente influida por factores geopolíticos.

En el caso concreto de España, durante el año 2022 se vertieron alrededor de 715 GWh de energía renovable. Esta cifra se explica, en gran medida, por el hecho de que la red de transporte no ha crecido al mismo ritmo que la instalación de nuevas plantas renovables. Ese desajuste supuso un coste adicional para el sistema eléctrico de aproximadamente 1.300

millones de euros, gestionado a través el mercado de Restricciones Técnicas operado por REE.[25]

Si bien es poco realista pensar en eliminar completamente los vertidos de energía renovable, sí es posible reducirlos de forma considerable con ciertas medidas. Una de las estrategias más eficaces es aumentar la capacidad de las líneas eléctricas mediante su gestión dinámica.

Esta solución no solo permite operar las redes en tiempo real ajustando sus límites a las condiciones ambientales, sino que también abre la posibilidad de anticipar, mediante modelos predictivos, cuál será la capacidad disponible en distintos horizontes temporales. De este modo, se puede optimizar el uso de la infraestructura existente y facilitar una integración más eficiente de las energías renovables.

1.1.4 AMPACIDAD

En la actualidad, las líneas eléctricas funcionan con un límite máximo de intensidad definido por valores estáticos preestablecidos. Estos límites se calculan suponiendo condiciones ambientales muy adversas, como altas temperaturas, escasa ventilación y una radiación solar intensa. Aunque este planteamiento garantiza un elevado nivel de seguridad en la operación del sistema como ya se ha comentado anteriormente, lo cierto es que dichas condiciones extremas rara vez se producen todas al mismo tiempo, y su incidencia varía notablemente en función de la ubicación de las líneas.

La ampacidad, que es la corriente máxima que un conductor puede soportar de forma continua sin sufrir daños, está directamente condicionada por el entorno meteorológico. Por eso, si se dispone de información en tiempo real sobre variables como temperatura ambiente, viento y radiación, es posible recalcular esa capacidad de transporte de manera dinámica. Dado que en la mayoría de los casos las condiciones reales serán más benignas que las utilizadas en el diseño estático, esto abre la puerta a aumentar la capacidad operativa de las líneas sin comprometer la seguridad.

Para poder aplicar este modelo de forma eficaz, es fundamental que los operadores dispongan de una visión actualizada y precisa del estado de la red. En los centros de control de las empresas distribuidoras, la planificación y supervisión en tiempo real son aspectos esenciales para garantizar un servicio seguro y estable. De forma similar a lo que ocurre en la gestión de la generación eólica donde resulta clave prever el recurso disponible para ajustar el despacho energético, también es necesario que los operadores puedan estimar la ampacidad con antelación. Esta capacidad de predicción les permite tomar decisiones informadas, anticiparse a restricciones y actuar con mayor flexibilidad ante variaciones en la generación.

Además de optimizar la gestión del sistema eléctrico, este enfoque beneficia directamente a los promotores de energías renovables. Gracias a la gestión dinámica de la red, se reducen significativamente las restricciones técnicas, permitiendo una mayor integración de la generación renovable y un aprovechamiento más eficaz de su potencial.

1.1.5 Algoritmos de cálculo de ampacidad

La ampacidad se entiende como la corriente máxima que puede circular de forma continua por un conductor sin que esta sufra daños térmicos. Esta intensidad límite está directamente condicionada por la temperatura que alcanza el propio conductor, lo que significa que la ampacidad equivale a la corriente que se permite circular cuando se llega a la temperatura máxima admisible de diseño. Por tanto, el cálculo de la ampacidad no puede desligarse del análisis térmico: debe abordarse como un problema de equilibrio térmico.

Para realizar este cálculo, se emplea una ecuación que contempla todos los factores que intervienen en el comportamiento térmico del conductor, desde los elementos ambientales hasta las propiedades físicas del material. En este contexto, existen dos metodologías ampliamente reconocidas para estimar la ampacidad en líneas aéreas: los modelos propuestos por CIGRE y por IEEE.

Ambos enfoques se basan en el mismo principio: una ecuación de balance térmico que integra variables como las condiciones meteorológicas (temperatura ambiente, viento, radiación solar), las características del conductor, la configuración de la línea y la corriente que lo atraviesa. En las secciones siguientes se explicará en qué consiste cada uno de estos procedimientos y se presentará una comparación entre ellos, destacando sus principales diferencias.

CIGRE

El procedimiento desarrollado por el Consejo Internacional de Grandes Redes Eléctricas (CIGRE) se ha consolidado como uno de los estándares de referencia para el cálculo de la ampacidad en líneas aéreas de alta tensión. Su metodología se basa en un modelo térmico que tiene en cuenta distintos factores de tipo ambiental y meteorológico. El objetivo principal de este enfoque es establecer cuál es la intensidad máxima de corriente que puede circular por un conductor sin que su temperatura supere el límite de seguridad definido. Superar ese umbral podría comprometer la integridad del propio conductor e incluso afectar a la estabilidad global del sistema eléctrico.

Parámetros y factores que considerar en CIGRE:

- Propiedades del conductor:
 - Material del conductor (aluminio, cobre, etc.)

- Diámetro del conductor
- Resistividad térmica y conductividad del material.
- Condiciones de la superficie del conductor: El envejecimiento del conductor puede modificar la emisividad de la superficie, lo que afecta su capacidad para disipar el calor.
- Condiciones ambientales:
 - Temperatura ambiente T_a
 - Radiación solar directa e indirecta
 - Viento: su velocidad y dirección (afectan la capacidad de refrigeración por convección).
 - Humedad relativa, altitud, y otros factores locales.
- Corriente que atraviesa el conductor:
 - La intensidad de corriente eléctrica que pasa por el conductor genera calor debido al efecto Joule, lo que eleva su temperatura.
- Equilibrio térmico: La ecuación principal para el cálculo de la ampacidad involucra un balance entre el calor generado por la corriente eléctrica y el calor disipado por los mecanismos de radiación (de la superficie del conductor al entorno), convección (por el aire y el viento), y evaporación (si aplica). El equilibrio térmico se representa como:

$$\text{Calor generado} = \text{Calor disipado}$$

La fórmula de ampacidad, I , se calcula a partir de:

$$I = \sqrt{\frac{q_c + q_r - q_s}{R(T_{avg})}}$$

Donde:

- q_c es el calor disipado por convección,
- q_r es el calor disipado por radiación,
- q_s es el calentamiento debido a la radiación solar,
- $R(T_{avg})$ es la resistencia del conductor a temperatura media.
- Estado no estacionario: El cálculo de la temperatura y la ampacidad en condiciones no estacionarias toma en cuenta la inercia térmica del conductor, es decir, el conductor puede continuar calentándose o enfriándose después de cambios en las condiciones operativas, lo que requiere un modelo dinámico.[26]

IEEE

El procedimiento desarrollado por el Instituto de Ingenieros Eléctricos y Electrónicos (IEEE) es otro de los estándares más utilizados a nivel internacional para calcular la ampacidad de los conductores en líneas aéreas. Aunque comparte una base común con el método

propuesto por CIGRE, el enfoque del IEEE presenta algunas diferencias importantes, tanto en los parámetros considerados como en las fórmulas empleadas para realizar el cálculo térmico.

Parámetros y factores que considerar en IEEE:

- Propiedades del conductor:
 - Material y dimensiones del conductor.
 - Resistencia térmica y conductividad.
- Condiciones ambientales:
 - Temperatura ambiente, viento, y radiación solar directa e indirecta, al igual que en el estándar CIGRE.
 - La radiación solar se calcula de forma simplificada, y la temperatura del conductor se calcula utilizando una ecuación de equilibrio térmico muy similar a la de CIGRE, pero con menos detalle en la interacción entre las radiaciones directa y difusa.
- Corriente eléctrica:
 - El efecto Joule sigue siendo el principal factor de calentamiento, calculándose con la misma fórmula:

$$q_j = I^2 R(T_{avg})$$

- Ecuación de Equilibrio Térmico: El procedimiento IEEE también se basa en una ecuación de equilibrio térmico para determinar la temperatura máxima alcanzable en el conductor. Sin embargo, en IEEE, la forma en que se calcula la radiación solar es más directa y considera una estimación simplificada de los efectos atmosféricos. En resumen:

$$I = \sqrt{\frac{q_c + q_r - q_s}{R(T_{avg})}}$$

Al igual que en CIGRE, q_c , q_r , y q_s representan la disipación de calor por convección, radiación y radiación solar respectivamente, mientras que $R(T_{avg})$ es la resistencia del conductor a la temperatura media.

- Estado no estacionario: Al igual que CIGRE, IEEE considera el efecto no estacionario en el que las condiciones del conductor cambian dinámicamente en función de los cambios en la intensidad de corriente y las condiciones ambientales.[27]

Diferencias principales entre CIGRE y IEEE

El método CIGRE se caracteriza por ofrecer un análisis más detallado de las variaciones de temperatura a lo largo de la línea, un aspecto especialmente relevante en líneas de transmisión de gran longitud. Además, este enfoque incorpora de forma más explícita el efecto del envejecimiento del conductor y la variación de la emisividad con el paso del tiempo, lo que permite una estimación más realista de su comportamiento térmico.

En cambio, el procedimiento del IEEE tiende a simplificar el cálculo de la radiación solar y adopta una aproximación más directa para estimar la disipación térmica. Este enfoque, aunque menos preciso en condiciones complejas, puede resultar adecuado para líneas de menor longitud o para entornos donde la variabilidad ambiental es más limitada.

Cálculo de la Ampacidad y Comparación

Tanto el procedimiento CIGRE como el de IEEE se basan en un modelo de equilibrio térmico, que considera la disipación de calor a través de mecanismos de convección y radiación, así como el calentamiento provocado por el paso de la corriente eléctrica. La diferencia principal entre ambos enfoques radica en el nivel de complejidad con el que tratan la radiación solar y en cómo abordan las condiciones no estacionarias del sistema.

Al comparar ambos métodos, el enfoque CIGRE suele ofrecer mayor precisión en la estimación de la temperatura del conductor, sobre todo cuando se analizan situaciones fuera del estado estacionario. No obstante, el procedimiento IEEE destaca por su simplicidad de aplicación, siendo una opción más práctica en contextos menos exigentes o cuando se dispone de datos limitados.

Ambos métodos son herramientas válidas y robustas para calcular la ampacidad de conductores en líneas aéreas. Sin embargo, CIGRE se presenta como una alternativa más detallada y precisa, especialmente útil en sistemas de mayor escala y complejidad, el método IEEE sigue siendo ampliamente utilizado por su facilidad de implementación, sobre todo en entornos donde las condiciones ambientales son más estables y previsibles. Teniendo en cuenta esto, el método aplicado para llevar a cabo el cálculo de la ampacidad para poder utilizar los datos de esta variable fue el de CIGRE 601.

2 ALCANCE Y OBJETIVOS

2.1 Alcance

El presente trabajo de fin de grado se centra en el desarrollo e implementación de una metodología predictiva para la estimación dinámica de la capacidad de transporte (ampacidad) en líneas eléctricas aéreas de alta tensión, en función de las condiciones meteorológicas. Este enfoque pretende dar respuesta a los retos que plantea la creciente penetración de energías renovables en el sistema eléctrico, que exige una gestión más flexible y precisa de la infraestructura existente para evitar vertidos de energía no aprovechada y mejorar la eficiencia operativa de la red.

El alcance del proyecto abarca tanto la parte teórica como la aplicación práctica del modelo, incluyendo el análisis de los principales factores que condicionan térmicamente a los conductores, la construcción de una base de datos histórica de alta resolución, el entrenamiento de modelos de predicción con algoritmos de aprendizaje automático, y la validación cuantitativa del sistema desarrollado frente a datos reales registrados por estaciones meteorológicas.

El trabajo no aborda el diseño físico de sensores ni el desarrollo de nuevas infraestructuras, sino que se centra en maximizar el uso de la red existente mediante herramientas de análisis y predicción basadas en datos. De forma complementaria, también se realiza una comparación del sistema propuesto con servicios meteorológicos comerciales, evaluando su fiabilidad en condiciones reales de operación.

2.2 Objetivos

2.2.1 Objetivo general

Desarrollar un sistema de predicción robusto y eficiente, basado en aprendizaje automático, que permita estimar con antelación la ampacidad de líneas eléctricas aéreas en función de variables meteorológicas, facilitando así una gestión dinámica y optimizada de la capacidad de transporte de energía.

2.2.2 Objetivos específicos

Caracterizar el entorno experimental:

-
- Seleccionar una línea de ensayo equipada con instrumentación adecuada para registrar en tiempo real las variables meteorológicas clave (temperatura ambiente, velocidad y dirección del viento, y radiación solar).
 - Generar una base de datos histórica con resolución de un minuto para los años 2023 y 2024.
 - Diseñar e implementar una base de datos estructurada
 - Organizar eficientemente los datos meteorológicos y operacionales, garantizando su accesibilidad desde entornos de programación como MATLAB®, facilitando así el entrenamiento y la validación de modelos.
 - Obtener la ampacidad a partir de datos históricos
 - Emplear modelos normalizados CIGRE e IEEE para determinar la capacidad térmica de los conductores bajo distintas condiciones ambientales, considerando su formulación en equilibrio térmico.
 - Entrenar modelos de predicción utilizando algoritmos de machine learning
 - Implementar modelos basados en Random Forest para distintos horizontes temporales de predicción.
 - Evaluar tanto modelos con entrada meteorológica como aquellos contruidos únicamente a partir del historial de ampacidad.
 - Evaluar y validar el rendimiento del sistema de predicción
 - Comparar los valores predichos con los registros reales mediante métricas estándar como SMAPE, RMSE e histogramas de error.
 - Realizar simulaciones masivas para asegurar la consistencia estadística de los resultados.
 - Estimar la ampacidad utilizando predicciones horarias ofrecidas por OpenMeteo
 - Evaluar el impacto de la resolución temporal y de las fuentes de datos en la precisión de las estimaciones.

3 ESTADO DEL ARTE

3.1 Gestión dinámica actual

Las redes de transporte y distribución de energía eléctrica están afrontando nuevos retos operativos debido, principalmente, al crecimiento de las energías renovables en especial, la energía eólica y a la alteración de los flujos tradicionales de energía. Este cambio ha provocado que muchas líneas funcionen habitualmente cerca de sus límites estáticos, generando congestiones que reducen la eficiencia del sistema e impiden, en muchas ocasiones, aprovechar toda la energía producida. Como consecuencia, las empresas generadoras se ven obligadas a restringir su producción, lo que supone una pérdida de rendimiento y competitividad.

Aunque la solución más evidente podría parecer la construcción de nuevas infraestructuras, lo cierto es que las dificultades económicas, normativas y medioambientales hacen que esta opción no siempre sea viable. Por eso, los operadores del sistema han puesto el foco en optimizar al máximo las infraestructuras existentes, lo que se puede abordar desde tres líneas principales de actuación:

Revisión de los márgenes de seguridad y reclasificación de líneas

Los límites estáticos que actualmente regulan la operación de las líneas suelen ser muy conservadores, establecidos para garantizar la máxima seguridad del sistema. Sin embargo, en muchos casos es posible ajustar estos márgenes de forma que reflejen mejor la capacidad real de las instalaciones, permitiendo operar más cerca de sus verdaderos límites dinámicos sin comprometer la estabilidad.

Mejoras en puntos críticos de la infraestructura

Otra vía consiste en modificar elementos estructurales clave, como puede ser el aumento de la altura de los apoyos o la instalación de sistemas de monitorización en tiempo real, que permiten conocer con precisión el estado operativo de la red y tomar decisiones más eficientes.

Modernización y actualización de la red

Esta estrategia incluye actuaciones como el retensado de conductores, la sustitución de cables por otros de mayor capacidad, el incremento del número de circuitos o incluso la reconstrucción parcial de estructuras, todo ello orientado a mejorar el rendimiento de la red sin necesidad de ampliaciones extensivas.

3.1.1 Ampacidad y sus Implicaciones

La ampacidad se refiere a la máxima corriente eléctrica que puede circular por un conductor sin que este supere la temperatura límite para la que ha sido diseñado. Esta capacidad está determinada por varios factores, como el tipo de material del conductor, las condiciones meteorológicas del entorno y la ubicación geográfica de la línea. Si se excede ese límite, el conductor puede sufrir sobrecalentamientos, lo que puede dañar sus propiedades físicas, provocar elongaciones excesivas y, en consecuencia, afectar tanto a la seguridad como a la estabilidad de la red eléctrica.

Con el objetivo de aumentar la capacidad de transporte de las líneas existentes, se han propuesto diferentes soluciones técnicas:

Retensionado de las líneas

Esta técnica resulta especialmente útil en instalaciones más antiguas o en aquellas donde la flecha la curvatura del cable es el principal factor limitante. Al incrementar la tensión mecánica de los conductores, se permite operar a temperaturas más elevadas que las originalmente contempladas. No obstante, esta solución puede acortar la vida útil del material y requiere un estudio estructural previo que garantice la viabilidad del refuerzo.

Sustitución de conductores y mejora de componentes

Existen múltiples tipos de conductores con mejores prestaciones térmicas y eléctricas, cuya elección depende de las condiciones ambientales y de operación. Además, sustituir las cadenas de aisladores convencionales por configuraciones flotantes permite aumentar la distancia de seguridad respecto al suelo, reduciendo el riesgo de descargas y mejorando la capacidad de transmisión.

Métodos deterministas para el cálculo de ampacidad

Frente al enfoque tradicional, que fija los límites térmicos usando condiciones meteorológicas extremas y poco frecuentes, los métodos deterministas aprovechan datos históricos para ajustar los márgenes de seguridad en función de la estacionalidad y de las variaciones diurnas o nocturnas. Esto permite utilizar con mayor eficiencia la infraestructura existente sin comprometer la seguridad operativa.

Métodos probabilísticos

Este enfoque utiliza modelos estadísticos que representan de forma más realista las condiciones ambientales. Por ejemplo:

- La temperatura ambiente suele modelarse mediante una distribución normal, debido a su variabilidad diaria y estacional.
- La radiación solar se ajusta mejor a distribuciones Beta o Gamma, ya que su comportamiento depende de factores como la latitud o la nubosidad.

- La velocidad del viento se representa comúnmente con una distribución Weibull, adecuada para describir la variabilidad del viento en distintos emplazamientos.
- Finalmente, la dirección del viento, al tratarse de una variable circular, se modela eficazmente mediante una distribución de Von Mises, que permite capturar de forma precisa el comportamiento angular del viento en torno a la línea.

3.1.2 Monitorización en Tiempo Real

La monitorización de variables críticas se ha convertido en una herramienta fundamental dentro del proceso de transformación de las redes eléctricas hacia modelos más inteligentes y eficientes. Existen distintos niveles de monitorización, cada uno con su propio grado de precisión y complejidad tecnológica:

Monitorización meteorológica

Este nivel se basa en datos recogidos por estaciones meteorológicas, que estiman la temperatura del conductor a partir de variables como la temperatura ambiente, la radiación solar y la velocidad del viento. Aunque es una solución ampliamente utilizada, su precisión puede verse limitada, ya que parte de la suposición de que las condiciones climáticas son uniformes a lo largo de toda la línea, lo cual no siempre se ajusta a la realidad.

Monitorización directa de la temperatura del conductor

Para mejorar la operación de las líneas, se han desarrollado tecnologías que permiten medir directamente la temperatura del cable. Un ejemplo es el Power Donut, un dispositivo autónomo que se instala sobre el conductor y mide en tiempo real temperatura, corriente y tensión mecánica, enviando los datos al centro de control.

Otra tecnología emergente es el SAW (Surface Acoustic Wave), que utiliza sensores pasivos basados en ondas acústicas de superficie para medir la temperatura sin necesidad de alimentación externa. Aunque prometedora, su aplicación práctica en líneas de transmisión aún es limitada.[28]

También destaca el sistema DTS (Distributed Temperature Sensing), que emplea fibra óptica integrada en la línea para obtener un perfil térmico continuo del conductor. Basado en el efecto Raman, permite detectar con gran precisión variaciones de temperatura a lo largo de todo el trazado. No obstante, debido a su alto coste, este sistema suele utilizarse principalmente en líneas nuevas, especialmente en redes subterráneas o aéreas equipadas con cables OPGW (Optical Ground Wire).[29]

Monitorización de la tensión mecánica

Este método permite obtener la temperatura del conductor mediante la medición de su tensión mecánica. Comparando los datos obtenidos con modelos de calibración térmica, se puede estimar con bastante precisión el estado térmico del conductor.

Monitorización de la flecha del conductor

En este caso, se utilizan técnicas como el análisis de imágenes, sensores de vibración o inclinómetros para determinar la flecha (la curvatura del cable), lo cual permite calcular la temperatura del conductor de forma indirecta, pero efectiva.

En un contexto donde la expansión de nuevas infraestructuras eléctricas se enfrenta a importantes limitaciones económicas y regulatorias, resulta clave optimizar al máximo las líneas ya existentes. La aplicación de estrategias como la gestión dinámica de la ampacidad, la modernización de los conductores y la monitorización en tiempo real permiten no solo mejorar la eficiencia operativa del sistema, sino también facilitar una mayor integración de energías renovables, reduciendo así la necesidad de imponer restricciones a la generación.

3.2 Instrumentos de gestión dinámica a corto plazo

Los operadores del sistema eléctrico no solo necesitan disponer de información en tiempo real sobre el estado de las líneas, sino que también deben anticiparse a su comportamiento en el corto plazo. Esto se debe a que la operación segura y eficiente de la red requiere una planificación anticipada, algo que la gestión dinámica basada únicamente en datos instantáneos no puede cubrir por sí sola.

Para lograrlo, es imprescindible contar con estimaciones fiables de las variables que afectan a la capacidad de las líneas, en particular las condiciones meteorológicas. La predicción del tiempo es un área que ha evolucionado considerablemente a lo largo del tiempo, gracias al desarrollo de modelos numéricos avanzados. Estos modelos integran datos atmosféricos con ecuaciones físicas que describen el comportamiento de los fluidos y los procesos termodinámicos, permitiendo anticipar la evolución del clima con un grado creciente de precisión.

Junto a estos enfoques basados en física, también se utilizan modelos predictivos apoyados en datos históricos, que analizan series temporales mediante algoritmos especializados. Estos sistemas buscan patrones en el comportamiento pasado de variables clave como temperatura, viento o radiación solar para realizar estimaciones futuras.

Ambas metodologías, tanto la física como la estadística, desempeñan un papel crucial en la planificación y gestión de la red eléctrica, ya que permiten ajustar la operación del sistema de forma más eficiente y segura en función de las condiciones previstas.

3.2.1 Modelos de predicción meteorológica

El conocimiento del comportamiento de la atmósfera es fundamental para un amplio abanico de actividades humanas, desde la gestión energética hasta la agricultura o el transporte. Para

mejorar esta comprensión, se combinan distintas fuentes de información, como mediciones meteorológicas, observaciones satelitales y modelos numéricos de predicción.

Realizar una predicción del clima implica estimar cómo evolucionarán los procesos atmosféricos a partir de un estado inicial conocido. Para ello, se utilizan modelos matemáticos complejos que simulan el comportamiento de la atmósfera resolviendo un conjunto de ecuaciones diferenciales. Estas ecuaciones están basadas en principios físicos fundamentales, como la segunda ley de Newton, la conservación de la masa y la ecuación de estado del aire. Dado que estas ecuaciones no pueden resolverse de forma analítica, se recurre a métodos numéricos aproximados, que permiten obtener soluciones viables a través del uso de supercomputadores.

Las condiciones iniciales del modelo se establecen a partir de mediciones en tiempo real de diversas variables meteorológicas, como la temperatura, la presión, la velocidad del viento o la humedad. Con estos datos, los modelos numéricos procesan enormes volúmenes de información para generar predicciones detalladas que se calculan para cada celda del modelo, tanto en superficie como en distintos niveles de la atmósfera, y para diferentes horizontes temporales.

A lo largo del tiempo, se han desarrollado numerosos modelos de predicción del tiempo, cada uno con enfoques y metodologías propias para estimar las condiciones futuras del clima. Dado el gran número de modelos existentes, a continuación, se mencionarán únicamente algunos de los más representativos.

HIRLAM (High Resolution Limited Area Model)

HIRLAM es un modelo numérico desarrollado por un consorcio europeo que reúne a los servicios meteorológicos de países como Dinamarca, Finlandia, Noruega, España o Suecia, entre otros. Está diseñado para la predicción meteorológica a corto plazo y se caracteriza por su alta resolución espacial, lo que permite representar con precisión fenómenos locales como tormentas o nieblas. Su arquitectura flexible permite ajustar la malla horizontal, el número de niveles verticales y los esquemas físicos como convección o microfísica de nubes en función de las necesidades de la simulación. Gracias a su adaptabilidad, es especialmente útil para estudios regionales y predicciones operativas detalladas.[30], [31]

GFS (Global Forecast System)

El GFS es el modelo de predicción global desarrollado por la NOAA (Administración Nacional Oceánica y Atmosférica) de Estados Unidos. Su cobertura es planetaria y está diseñado para ofrecer pronósticos a medio plazo, de hasta unos 10 días. El modelo simula el comportamiento de la atmósfera resolviendo las ecuaciones de dinámica de fluidos y

termodinámica, utilizando una malla global con resolución moderada. Es ampliamente empleado para el seguimiento de sistemas meteorológicos de gran escala, y sirve como base para muchos otros modelos regionales y herramientas de pronóstico. [32], [33]

WRF (Weather Research and Forecasting)

El WRF es un modelo de predicción meteorológica de mesoescala, desarrollado en colaboración por varias instituciones, entre ellas el NCAR (Centro Nacional de Investigación Atmosférica) y el NWS (Servicio Meteorológico Nacional de EE. UU.). Se trata de un modelo muy versátil, utilizado tanto en el ámbito operativo como en la investigación atmosférica. Ofrece múltiples opciones de parametrización física, como convección, radiación o microfísica de nubes, y su diseño modular permite adaptarlo a diferentes escalas espaciales y temporales. Es especialmente útil para simulaciones de alta resolución o estudios de clima regional.[33], [34]

MetUM (Met Office Unified Model)

El MetUM es el modelo numérico del tiempo desarrollado por el Met Office del Reino Unido. Su característica principal es su diseño unificado, que permite utilizar el mismo modelo para diferentes escalas: desde predicciones a corto plazo hasta proyecciones climáticas a largo plazo. Resuelve las ecuaciones de la atmósfera con técnicas numéricas avanzadas y esquemas físicos detallados, y se emplea tanto en operaciones meteorológicas rutinarias como en investigación climática. Su coherencia entre escalas lo convierte en una herramienta muy robusta.[35]

GEFS (Global Ensemble Forecast System)

El GEFS es un sistema de predicción por conjuntos también desarrollado por la NOAA, que permite estimar la incertidumbre asociada a los pronósticos. Se basa en la ejecución repetida del modelo GFS, partiendo de condiciones iniciales ligeramente diferentes en cada simulación. Esto genera un abanico de posibles escenarios atmosféricos futuros, lo que resulta especialmente valioso para anticipar fenómenos extremos o situaciones de alta variabilidad. El GEFS es clave para evaluar probabilidades y tomar decisiones en situaciones meteorológicas críticas.[36]

3.2.2 Modelos de predicción basados en series temporales

Los modelos de predicción basados en series temporales se apoyan en el análisis de datos recogidos a lo largo del tiempo en intervalos regulares, con el objetivo de identificar patrones históricos que permitan anticipar el comportamiento futuro de la variable de interés.

Las series temporales presentan una serie de características propias que condicionan la elección del modelo más adecuado para su análisis:

- Autocorrelación: Describe la dependencia entre los valores pasados y futuros de la serie. Captar esta relación es esencial para poder hacer predicciones precisas.
- Estacionalidad: Hace referencia a las fluctuaciones que se repiten de forma regular a lo largo del tiempo, como pueden ser los ciclos diarios, semanales o estacionales.
- Tendencia: Representa la dirección general del comportamiento de la serie a largo plazo, que puede ser creciente, decreciente o mantenerse estable.
- Ciclos: Se trata de patrones de largo plazo, pero sin una periodicidad fija, como por ejemplo los vinculados a fenómenos económicos.
- Ruido aleatorio: Es la parte impredecible de la serie, no asociada a ningún patrón concreto. Los modelos deben minimizar su influencia para mejorar la fiabilidad de las predicciones.

Para que un modelo de predicción funcione correctamente, la serie temporal debe cumplir ciertas condiciones, entre ellas la estacionariedad. Esto significa que sus propiedades estadísticas, como la media y la varianza, se mantengan constantes en el tiempo. Si la serie no es estacionaria, se pueden aplicar transformaciones, como la diferenciación, para estabilizarla antes de construir el modelo.

Antes de seleccionar un modelo, es fundamental llevar a cabo un análisis exploratorio de la serie. Esto incluye la representación gráfica de los datos y el cálculo de funciones como la autocorrelación ACF y la autocorrelación parcial PACF, que permiten detectar dependencias y estructuras repetitivas en los datos.[37]

Desde el punto de vista matemático, los modelos de series temporales se expresan habitualmente mediante ecuaciones de diferencias o regresiones sobre valores pasados de la serie y sus errores de predicción. Según la naturaleza de los datos y el comportamiento de la serie, estos modelos pueden agruparse en tres grandes categorías:

Modelos estadísticos

- **AR (AutoRegressive):** Un modelo AR define el valor actual de una variable basándose en una combinación lineal de sus valores pasados y un término de error. Matemáticamente, un modelo autorregresivo de orden p , denotado como AR(p), se da de la siguiente manera:

$$X_t = c + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \epsilon_t$$

Donde:

- X_t es el valor de la variable en el tiempo t .

- c es una constante.
- $\phi_1, \phi_2, \dots, \phi_p$ son los coeficientes del modelo.
- ϵ_t es el término de error en el tiempo t , entendido como ruido blanco con media cero y varianza constante.

La base de este enfoque es la idea de que los valores históricos de la serie contienen información relevante que puede utilizarse para anticipar su evolución futura. Por tanto, el modelo aprovecha la estructura temporal del conjunto de datos para generar predicciones más precisas.[37]

- **MA (Moving Average):** Un modelo MA de orden q , expresado como MA(q), muestra el valor actual de una serie temporal como una combinación lineal de errores aleatorios presentes y pasados. Matemáticamente, viene dada de la siguiente manera:

$$X_t = \mu + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q}$$

Donde:

- X_t es el valor de la variable en el tiempo t .
- μ es la media de la serie.
- ϵ_t es el término de error en el tiempo t , asumido como ruido blanco con media cero y varianza constante.
- $\theta_1, \theta_2, \dots, \theta_q$ son los coeficientes del modelo que determinan la influencia de los errores pasados.

A diferencia de los modelos autorregresivos AR, que se apoyan en los valores pasados de la propia serie para hacer predicciones, los modelos de media móvil (MA) se centran en los errores de predicción anteriores. Este enfoque permite capturar y modelar las fluctuaciones inesperadas que no siguen un patrón definido, ofreciendo una representación más precisa de la parte aleatoria o impredecible del comportamiento de la serie temporal.[37], [38], [39]

- **ARMA (AutoRegressive Moving Average):** Un modelo ARMA (p, q) viene dada por dos parámetros: p , que representan el orden de la parte autorregresiva, y q , que define el orden de la parte de media móvil. La formulación matemática de un modelo ARMA (p, q) es:

$$X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \epsilon_t + \sum_{j=1}^q \theta_j \epsilon_{t-j}$$

Donde:

- X_t es el valor de la serie en el tiempo t .
- c es una constante.
- ϕ_i son los coeficientes de la parte autorregresiva.
- ϵ_t representa un término de error en el tiempo t , asumido como ruido blanco con media cero y varianza constante.
- θ_j son los coeficientes de la parte de media móvil.

La componente autorregresiva AR representa la influencia que ejercen los valores pasados de la serie sobre su valor actual. Por otro lado, la componente de media móvil MA recoge el efecto de los errores de predicción cometidos en periodos anteriores. Al combinar ambas, se obtiene un modelo capaz de capturar una gran variedad de patrones en series temporales que presentan comportamiento estacionario, ofreciendo así una herramienta más flexible y precisa para el análisis y la predicción.[37], [39], [40]

- **ARIMA (AutoRegressive Integrated Moving Average):** Son mecanismos estadísticos muy utilizados para el análisis y la predicción de series temporales. Estos sistemas son una extensión de los modelos ARMA, modificados para controlar series no estacionarias mediante la adición de una componente de integración.

Un modelo ARIMA se denota como ARIMA (p, d, q), donde:

- **p:** Orden de la parte autorregresiva (AR).
- **d:** Número de diferenciaciones necesarias para lograr la estacionariedad.

- **q:** Orden de la parte de media móvil (MA).

La formulación matemática de un modelo ARIMA (p, d, q) es:

$$\left(1 - \sum_{i=1}^p \phi_i L^i\right) (1 - L)^d X_t = \left(1 + \sum_{j=1}^q \theta_j L^j\right) \epsilon_t$$

Donde:

- X_t es el valor de la serie en el tiempo t .
- ϕ_i son los coeficientes de la parte autorregresiva.
- L es el operador de rezago (lag operator).
- θ_j son los coeficientes de la parte de media móvil.
- ϵ_t es el término de error en el tiempo t , asumido como ruido blanco.

La componente $(1 - L)^d$ representa la diferenciación de orden d , usada para convertir una serie no estacionaria en estacionaria.[37], [41]

Modelos de Aprendizaje Automático

- **Redes Neuronales Recurrentes (RNN):** Las redes neuronales recurrentes RNN se distinguen por incorporar conexiones internas que permiten retroalimentar información, lo que les da la capacidad de mantener memoria de estados anteriores durante el procesamiento. Esta arquitectura se puede imaginar como una sucesión de módulos idénticos que transmiten información de uno a otro, formando un bucle que resulta especialmente útil para trabajar con datos secuenciales, como series temporales o texto.

En una RNN, el estado oculto h_t en el tiempo t se actualiza según la entrada actual x_t y el estado oculto anterior h_{t-1} mediante la función:

$$h_t = \sigma(W_h h_{t-1} + W_x x_t + b)$$

Donde:

- W_h y W_x son matrices de pesos.

- b es el vector de sesgo.
- σ es una función de activación no lineal, como tanh o ReLU.

Gracias a esta estructura, la red es capaz de retener información sobre estados anteriores, lo cual es fundamental en tareas donde el contexto varía con el tiempo y las dependencias temporales son relevantes.

Sin embargo, durante el proceso de entrenamiento de las RNN, que se realiza mediante el método de retropropagación a través del tiempo BPTT, suelen surgir dificultades relacionadas con el desvanecimiento o la explosión del gradiente. Estos problemas afectan a la actualización adecuada de los pesos de la red, y se agravan cuando se intenta capturar dependencias a largo plazo dentro de las secuencias, lo que puede limitar el rendimiento del modelo en tareas más complejas.[42], [43]

- **LSTM (Long Short-Term Memory):** Con el objetivo de superar los problemas asociados al entrenamiento de las RNN, especialmente el desvanecimiento del gradiente, surgieron las LSTM (Long Short-Term Memory). Esta variante fue diseñada específicamente para capturar relaciones a largo plazo dentro de las secuencias de datos, sin perder información relevante en el camino.

Su principal innovación radica en una arquitectura basada en celdas de memoria, que controlan el flujo de información mediante un conjunto de puertas. Estas puertas actúan como filtros que determinan qué información debe conservarse, cuál debe actualizarse y qué datos pueden descartarse, lo que permite que la red mantenga un equilibrio efectivo entre memoria a corto y largo plazo.

Una celda LSTM típica consta de los siguientes componentes:

- Puerta de Olvido: Determina qué información del estado anterior debe ser desechada.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

- Puerta de Entrada: Decide qué nueva información será almacenada en el estado de la celda.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

- Estado de la Celda: Genera una nueva candidata a ser añadida al estado de la celda.

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

- **Actualización del Estado de la Celda:** Actualiza el estado de la celda combinando el estado anterior modulado por la puerta de olvido y la nueva candidata escalada por la puerta de entrada.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

- **Puerta de Salida:** Decide qué parte del estado de la celda se enviará como salida.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

- **Estado Oculto:** Salida final de la celda LSTM.

$$h_t = o_t \cdot \tanh(C_t)$$

En estas ecuaciones, σ representa la función sigmoide, $\tanh$ corresponde a la tangente hiperbólica, W son las matrices de pesos, b los vectores de sesgo, y el símbolo $*$ indica la multiplicación elemento a elemento.

Gracias a esta arquitectura, las LSTM son capaces de conservar y actualizar información relevante a lo largo de secuencias extensas, superando así las limitaciones que presentan las RNN tradicionales a la hora de capturar dependencias de largo plazo.

El entrenamiento de las LSTM se lleva a cabo utilizando algoritmos de optimización, como el descenso de gradiente, aplicando el método de retropropagación a través del tiempo (BPTT) para ajustar los pesos y sesgos de la red. Su diseño interno, basado en puertas de control, permite a las LSTM mitigar de forma efectiva los problemas de desvanecimiento y explosión del gradiente, facilitando así el aprendizaje en tareas con secuencias largas y estructuras complejas.[42], [44]

- **Random Forest:** Random Forest es un algoritmo de aprendizaje automático que se basa en el principio de aprendizaje en conjunto ensemble learning. Su funcionamiento se apoya en la creación de múltiples árboles de decisión, cuyos resultados se combinan para generar predicciones más precisas y estables.

Este enfoque permite mejorar la robustez del modelo y reducir el riesgo de sobreajuste, una de las principales limitaciones de los árboles individuales. Además, Random Forest se adapta especialmente bien al trabajo con grandes volúmenes de datos y ofrece un rendimiento destacado tanto en tareas de clasificación como de

regresión, lo que lo convierte en uno de los modelos más utilizados en el ámbito del aprendizaje supervisado.

Dado un conjunto de datos de entrenamiento $D = \{(x_i, y_i)\}_{i=1}^N$, donde:

- x_i representa el vector de características de la muestra i ,
- y_i es la variable objetivo (categoría en clasificación o valor numérico en regresión),
- N es el número total de muestras,

El objetivo de Random Forest es construir un conjunto de B árboles de decisión $\{T_b\}_{b=1}^B$ para realizar una predicción combinada. La predicción final para una nueva entrada x' se obtiene de la siguiente manera:

- Para clasificación (votación por mayoría):

$$\hat{y} = \text{mode}\{T_1(x'), T_2(x'), \dots, T_B(x')\}$$

donde cada árbol individual T_b emite un voto y se selecciona la clase más frecuente.

- Para regresión (promedio de predicciones):

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B T_b(x')$$

donde se toma el promedio de las predicciones individuales de cada árbol.

El algoritmo Random Forest se apoya en una técnica conocida como bootstrap aggregating, o simplemente *bagging*, que consiste en generar múltiples subconjuntos de datos de entrenamiento a partir del conjunto original mediante muestreo con reemplazo.

Para cada árbol del conjunto denotado como T_b , se crea un subconjunto D_b del mismo tamaño que el conjunto original D , seleccionando aleatoriamente ejemplos con la posibilidad de que algunos se repitan y otros queden fuera. Estas muestras no seleccionadas se conocen como out-of-bag (OOB) y son útiles para validar el modelo sin necesidad de recurrir a un conjunto de prueba externo.

El objetivo del bagging es reducir la varianza del modelo, ya que, al combinar múltiples árboles construidos sobre datos ligeramente diferentes, se suavizan las fluctuaciones aleatorias y se mejora la capacidad de generalización del modelo.

A diferencia de los árboles de decisión tradicionales, donde cada nodo se construye evaluando todas las variables disponibles, en Random Forest se selecciona aleatoriamente un subconjunto de características en cada nodo. Si M es el número total de variables en el conjunto de datos, en cada división se escogen aleatoriamente m de ellas, donde típicamente:

- ✓ Para clasificación: $m \approx \sqrt{M}$
- ✓ Para regresión: $m \approx \frac{M}{3}$

Esta estrategia evita la dominancia de ciertas características y reduce la correlación entre los árboles individuales. Cada árbol en Random Forest crece de manera independiente y sin podas. Para dividir un nodo, se selecciona aleatoriamente m características de entre las M disponibles. Se elige la mejor característica para la división en función de una métrica como:

- ❖ Gini impurity para clasificación:

$$G = 1 - \sum_{i=1}^C p_i^2$$

donde p_i es la proporción de muestras en la clase i .

- ❖ Reducción de la varianza en regresión:

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2$$

donde $\bar{y}$ es la media de las etiquetas en el nodo.

Este proceso de construcción de árboles se repite hasta que se cumple un criterio de parada, como puede ser alcanzar un número mínimo de muestras en un nodo hoja.

Una de las ventajas del enfoque de bagging en Random Forest es que, al entrenar cada árbol con un subconjunto diferente del conjunto de datos original, las muestras que no han sido utilizadas conocidas como out-of-bag o OOB pueden emplearse para evaluar el rendimiento del modelo sin necesidad de disponer de un conjunto de

validación externo. El error OOB se calcula como el porcentaje de predicciones incorrectas sobre estas muestras, proporcionando así una estimación fiable de la precisión del modelo.

Además, Random Forest ofrece la posibilidad de evaluar la importancia de cada variable en la predicción. Esto se puede hacer principalmente de dos formas:

1.Reducción de la impureza: Se cuantifica el impacto que tiene cada variable en la mejora del modelo, midiendo la disminución del índice de Gini para clasificación o la varianza para regresión al realizar divisiones en los nodos.

2.Permutación aleatoria: Consiste en modificar aleatoriamente los valores de una variable concreta y observar cómo cambia la precisión del modelo. Cuanto mayor sea la degradación del rendimiento, mayor será la relevancia de esa variable.

Estos métodos permiten obtener una visión clara de qué características tienen más peso en las decisiones del modelo, lo cual resulta especialmente útil en tareas de interpretación y análisis de datos complejos.[45], [46]

Modelos Basados en Descomposición de Series

Los modelos basados en la descomposición de series temporales son herramientas clave en el análisis de datos que evolucionan en el tiempo. Su principal utilidad radica en la capacidad de separar una serie compleja en componentes más simples, lo que facilita su estudio e interpretación de manera más detallada. Existen varias técnicas para llevar a cabo esta descomposición, entre las que destacan:

- Descomposición clásica: Se basa en el uso de promedios móviles para estimar la tendencia y la estacionalidad de la serie. Puede aplicarse de forma aditiva o multiplicativa, dependiendo de si la variabilidad de los componentes se mantiene constante o cambia proporcionalmente con el nivel de la serie.
- Descomposición STL (Seasonal-Trend decomposition using Loess): Es una técnica más robusta y flexible, que emplea suavizamiento local para separar la serie en sus tres componentes principales: tendencia, estacionalidad y ruido. Es especialmente útil cuando se trabaja con series que presentan comportamientos estacionales no lineales o que varían a lo largo del tiempo.

- Modelos de suavizamiento exponencial: Como el método de Holt-Winters, que permite modelar series con tendencia y estacionalidad, asignando más peso a los valores recientes mediante factores de ajuste exponencialmente decrecientes.

El proceso de descomposición de una serie temporal suele implicar varias etapas:

- Identificación del modelo más adecuado: Se analiza la naturaleza de la serie para determinar si presenta un comportamiento aditivo o multiplicativo, lo que orienta la elección de la técnica a emplear.
- Estimación de los componentes: Una vez seleccionada la metodología, se aplica para extraer las tres partes fundamentales de la serie: tendencia, estacionalidad y componente aleatorio o residual.
- Análisis de los componentes: Se examina cada uno de los elementos extraídos para entender mejor el comportamiento del fenómeno que se está estudiando, como puede ser la evolución de la demanda o la generación eléctrica.
- Predicción y apoyo a la toma de decisiones: A partir de los componentes descompuestos, es posible realizar pronósticos más precisos y tomar decisiones más fundamentadas en el ámbito de la gestión y operación de sistemas eléctricos u otros entornos dinámicos.[47], [48], [49]



UC Universidad de Cantabria		TRABAJO DE FIN DE GRADO
		GESTIÓN DINÁMICA DE LÍNEA ELÉCTRICAS DE AT
		TUTOR: RAQUEL MARTÍNEZ TORRE
Formato A4	EMPLAZAMIENTO LÍNEA DE PRUEBA	El alumno de la Universidad de Cantabria Pablo Bolado Fernández
Escala: 1/2.000		EMPLAZAMIENTO ESTACIÓN METEOROLÓGICA
		En Santander, a 15 de mayo de 2025.

4 METODOLOGÍA

4.1 Base de la metodología

Antes de exponer en detalle la metodología empleada en este trabajo, es importante contextualizar el entorno experimental donde se ha llevado a cabo la validación del sistema de predicción. Para ello, se ha utilizado una línea de ensayo de corta longitud, instalada sobre la cubierta de la Escuela Técnica Superior de Ingenieros Industriales y de Telecomunicación. Esta infraestructura es utilizada de forma habitual por el personal investigador del centro para el desarrollo de diferentes experimentos relacionados con sistemas eléctricos. Por consiguiente, el conductor empelado es el 400 mm² DRAKE 26/7 ACSR, acto seguido se muestran sus características:

- Diámetro total: 28.12 mm
- Diámetro de los hilos de aluminio= 4.44 mm
- Resistencia a 25°C=0.07284 Ohmios/km
- Resistencia a 75 °C=0.08689 Ohmios/km
- Emisividad=0.5
- Absortibidad=0.5
- Temperatura máxima=85 °C



Figura 4: Conductor 400 mm² DRAKE 26/7 ACSR



Figura 5: Línea de prueba vista desde abajo



Figura 6: Línea de prueba vista a la misma altura

Además de la propia línea eléctrica, el entorno cuenta con un sistema de monitorización meteorológica situado en la misma ubicación. Este sistema permite registrar en tiempo real una serie de variables ambientales clave, como la radiación solar, la temperatura ambiente, la velocidad del viento y su dirección. Las mediciones se realizan con una resolución temporal de un minuto, lo que permite generar una base de datos detallada, almacenada en formato Excel, que incluye tanto la marca temporal exacta como el valor registrado para cada variable.



Figura 7: Sondas PT100

En la figura 7 se pueden observar unas sondas PT100 que miden la temperatura del conductor.




Figura 8: Estación meteorológica

En la figura 8 se ve una estación meteorológica compuesta por los siguientes elementos:

- En la parte superior: Anemoveleta ultrasónica: Mide velocidad y dirección del viento usando ondas ultrasónicas, sin partes móviles. Da como salida, velocidad del viento en m/s o km/h y dirección en grados.
- Barra horizontal intermedia: Piranómetro: Mide la radiación solar global en W/m^2
- Parte inferior (blanca): Termohigrómetro: Es un sensor combinado que mide tanto la temperatura del aire ($^{\circ}C$) como la humedad relativa (%).

*Figura 9: Estación meteorológica compacta*

Para concluir, en la figura 9 nos encontramos con una estación meteorológica compacta que está formado por lo siguiente:

- Piranómetro
- Anemovoleta ultrasónica:
- Termohigrómetro

Estos elementos corresponden a los mismos sensores ya descritos previamente en la estación meteorológica mostrada en la Figura 8, cumpliendo exactamente la misma función. La única diferencia radica en que, en este caso, se encuentran integrados en una única estructura compacta y de menor tamaño.

Gracias a este sistema de adquisición de datos, se dispone de un conjunto meteorológico continuo y de alta resolución, correspondiente a los años 2023 y 2024. Esta base de datos resulta especialmente valiosa para el desarrollo y la validación precisa de los modelos predictivos, cuya implementación y resultados se describen en los apartados posteriores de este trabajo.

La herramienta de programación seleccionada para este trabajo es MATLAB, una plataforma ampliamente reconocida en los ámbitos científico y de ingeniería. Su elección se basa en su solidez computacional, su extenso ecosistema de herramientas especializadas y su eficiencia en el manejo de grandes volúmenes de datos, especialmente cuando se trabaja con registros que superan el medio millón de observaciones.

Uno de los puntos fuertes de MATLAB es su arquitectura optimizada para operaciones matriciales y vectorizadas, lo que permite procesar grandes cantidades de datos de forma rápida y eficiente, sin necesidad de recurrir a bucles explícitos. Esta característica resulta especialmente útil en entornos donde el tiempo de cómputo es un factor crítico, como ocurre en la predicción de variables en tiempo real o casi en tiempo real.

Además, MATLAB ofrece acceso directo a paquetes especializados como el Statistics and Machine Learning Toolbox o el Deep Learning Toolbox, que incluyen algoritmos avanzados para tareas de regresión, clasificación, reducción de dimensionalidad o redes neuronales. Estas herramientas permiten aplicar modelos tanto supervisados como no supervisados y están diseñadas para trabajar con grandes conjuntos de datos, optimizando el rendimiento a través de técnicas como la validación cruzada, el ajuste automático de hiperparámetros o el análisis de sensibilidad.

Otro aspecto destacable es su capacidad para realizar, de forma integrada, tareas de limpieza, transformación y visualización de datos. Esto facilita la exploración de los conjuntos de datos, la detección de patrones y anomalías, y el entendimiento profundo de las relaciones entre variables. Una buena fase de preprocesamiento de datos es clave para construir modelos predictivos de calidad, y MATLAB proporciona las herramientas necesarias para abordar esta etapa de forma eficaz y ordenada.

4.2 Sistema para la predicción

A continuación, se presenta una evaluación crítica de los métodos descritos en el estado del arte, con el objetivo de identificar el enfoque más adecuado para su implementación en el presente trabajo. Una vez seleccionado el modelo óptimo, se detallan las etapas llevadas a cabo para el desarrollo e implementación del sistema de predicción.

4.2.1 Evaluación de los métodos para seleccionar el más adecuado

El estado del arte examina diversos enfoques predictivos aplicables al cálculo dinámico de la ampacidad en líneas eléctricas, incluyendo modelos físicos, estadísticos, basados en series temporales, aprendizaje automático y técnicas híbridas. Cada metodología ofrece ventajas particulares en función del horizonte temporal de predicción, la calidad de los datos disponibles y la complejidad computacional aceptable en aplicaciones operativas.

Modelos Basados en Predicción Meteorológica Numérica (NWP)

Los modelos numéricos de predicción meteorológica NWP, como HIRLAM, GFS y WRF, son herramientas ampliamente utilizadas para estimar variables ambientales clave que influyen directamente en la ampacidad de las líneas eléctricas, tales como la temperatura ambiente, la velocidad del viento o la radiación solar. No obstante, a pesar de su utilidad general, presentan limitaciones importantes cuando se trata de aplicarlos a escalas locales o en contextos operativos de tiempo real:

- Resolución espacial y temporal limitada: Estos modelos no siempre logran captar con suficiente detalle las variaciones microclimáticas locales, que pueden tener un impacto directo y significativo sobre el comportamiento térmico de las líneas de transmisión.
- Incertidumbre en pronósticos a corto plazo: La precisión de las predicciones suele disminuir notablemente cuando se trata de horizontes temporales muy reducidos, lo que limita su fiabilidad en aplicaciones que requieren estimaciones de ampacidad en tiempo real o cuasi-tiempo real.

- Elevado coste computacional: Ejecutar estos modelos implica un consumo considerable de recursos computacionales, lo que puede suponer una barrera en entornos donde se requiere una respuesta ágil o en sistemas que no disponen de infraestructuras de procesamiento avanzadas.

En resumen, aunque los modelos NWP son herramientas valiosas para generar información meteorológica general, su uso directo en la estimación dinámica de la ampacidad presenta ciertas limitaciones. Estas se deben, principalmente, a su falta de resolución en escalas locales y a su capacidad reducida para ofrecer predicciones precisas en plazos de tiempo muy cortos.

Modelos Estadísticos de Series Temporales (ARIMA, SARIMA)

Los modelos estadísticos como ARIMA y SARIMA son herramientas ampliamente utilizadas en el análisis y la predicción de series temporales, especialmente eficaces para identificar y modelar patrones lineales y estacionales en los datos. No obstante, cuando se aplican al contexto específico de la ampacidad dinámica, presentan ciertas limitaciones importantes:

- Dificultad para capturar relaciones no lineales: La relación entre las variables meteorológicas como temperatura, viento o radiación y la ampacidad es, por naturaleza, no lineal, lo que hace que estos modelos, basados en supuestos lineales, no siempre puedan representar el sistema con precisión.
- Falta de adaptabilidad ante cambios bruscos: Estos enfoques pueden tener problemas para adaptarse a variaciones abruptas en las condiciones ambientales, lo que reduce la fiabilidad de las predicciones en entornos altamente variables.
- Requisitos de estacionariedad: ARIMA y SARIMA requieren que las series temporales sean estacionarias, es decir, que sus propiedades estadísticas no cambien con el tiempo. Si esto no se cumple, es necesario aplicar transformaciones adicionales (como diferenciación), lo que complica el proceso de modelado y puede introducir errores adicionales.

En definitiva, aunque ARIMA y SARIMA son muy útiles en contextos donde las series presentan estructuras estables y comportamientos previsibles, su capacidad para representar la complejidad y variabilidad de la ampacidad dinámica es limitada. En este tipo de aplicaciones, puede ser más adecuado recurrir a modelos que integren relaciones no lineales y se adapten mejor a cambios rápidos en los datos.

Modelos de Aprendizaje Automático

1.Redes Neuronales Recurrentes RNN y LSTM: Las redes neuronales recurrentes, y en particular las LSTM (Long Short-Term Memory), se han consolidado como una herramienta eficaz para modelar dependencias temporales de largo plazo y trabajar con datos secuenciales, lo que las hace especialmente adecuadas para problemas como la predicción de ampacidad dinámica.

Entre sus principales ventajas destaca su capacidad para capturar relaciones no lineales complejas, permitiendo modelar con precisión la interacción entre variables meteorológicas (como temperatura, viento o radiación solar) y la ampacidad de una línea eléctrica. Sin embargo, este tipo de redes también presenta algunas limitaciones:

- Altos requerimientos de datos y recursos computacionales: Las LSTM necesitan grandes volúmenes de datos históricos para entrenarse correctamente y, además, requieren una capacidad computacional considerable, lo que puede dificultar su implementación en entornos con recursos limitados.
- Dificultades de interpretabilidad: Al tratarse de modelos con una estructura interna compleja, su funcionamiento es en gran medida opaco. Esta característica de “caja negra” puede representar un inconveniente en aplicaciones críticas, donde es importante entender cómo y por qué se generan determinadas predicciones.

En resumen, las redes LSTM aportan un gran potencial para abordar la complejidad de las series temporales en el contexto de la ampacidad dinámica. No obstante, su aplicación práctica puede verse condicionada por los requisitos técnicos y de interpretación, especialmente en aquellos casos en los que la trazabilidad y la comprensión del modelo son factores clave.

2.Random Forest: El algoritmo Random Forest es una técnica de aprendizaje en conjunto que basa su funcionamiento en la construcción de múltiples árboles de decisión, cuyos resultados se combinan para mejorar la precisión y reducir el riesgo de sobreajuste. En el contexto de la predicción de la ampacidad dinámica, este enfoque ofrece varias ventajas relevantes:

- Capacidad para modelar relaciones no lineales e interacciones complejas: A diferencia de otros métodos más restrictivos, Random Forest puede capturar interacciones entre variables sin necesidad de establecer suposiciones paramétricas previas, lo que lo hace especialmente útil en escenarios con relaciones no evidentes o datos de naturaleza heterogénea.

- Precisión y robustez ante datos ruidosos: Este algoritmo es conocido por su resistencia al sobreajuste, incluso cuando se trabaja con datos incompletos o con ruido, manteniendo un alto nivel de fiabilidad en las predicciones.
- Interpretabilidad razonable: Aunque no es tan transparente como los modelos lineales, Random Forest permite analizar la importancia relativa de cada variable, lo que facilita la comprensión de cómo se generan los resultados y aporta valor en contextos donde la trazabilidad es importante.
- Eficiencia computacional: En comparación con redes neuronales profundas, Random Forest requiere menores recursos computacionales, lo que lo convierte en una opción más accesible en términos de implementación, especialmente cuando se busca un buen equilibrio entre rendimiento y coste.

En resumen, Random Forest representa una solución robusta y eficiente para la predicción de la ampacidad dinámica en líneas eléctricas aéreas, combinando precisión, capacidad de generalización y una interpretabilidad aceptable, lo que lo posiciona como una herramienta muy adecuada en este tipo de aplicaciones.

3. Modelos Híbridos y Técnicas Avanzadas: En los últimos años, han surgido enfoques híbridos que combinan distintas técnicas de modelado con el objetivo de mejorar la predicción de la ampacidad dinámica. Un ejemplo destacado son los modelos que integran redes neuronales LSTM con técnicas de convolución gráfica, lo que permite captar de forma más precisa tanto las correlaciones espaciales como temporales dentro de redes eléctricas complejas. No obstante, este tipo de soluciones suelen implicar una mayor complejidad computacional y requieren infraestructuras avanzadas, lo que puede dificultar su aplicación en entornos operativos reales.

En resumen, si bien los modelos híbridos muestran un alto potencial en términos de precisión, su elevado coste computacional y dificultad de implementación pueden convertirse en obstáculos importantes a la hora de adoptarlos en sistemas eléctricos que exigen eficiencia y operatividad.

Selección del método más adecuado:

Teniendo en cuenta los factores clave para una predicción eficaz de la ampacidad dinámica como la capacidad para modelar relaciones no lineales, la robustez frente a datos ruidosos, la interpretabilidad de los resultados y la eficiencia computacional, el algoritmo Random Forest destaca como la opción más equilibrada y adecuada.

A partir del análisis realizado en este trabajo, se concluye que Random Forest ofrece un excelente compromiso entre precisión, fiabilidad, facilidad de interpretación y requisitos computacionales razonables. Estas características lo convierten en la mejor alternativa para desarrollar el sistema de predicción propuesto, especialmente considerando que se dispone de datos meteorológicos detallados y que se requiere una herramienta capaz de ofrecer resultados sólidos y operativamente viables.

4.2.2 Pasos para el desarrollo del sistema de predicción

En este apartado se expone, de forma detallada, cómo se desarrolló el código del sistema de predicción, incluyendo las diferentes etapas que se siguieron, las pruebas realizadas y el proceso de verificación llevado a cabo.

Todo comenzó con la necesidad de entender a fondo el problema que se quería resolver. Dado que el objetivo del proyecto implicaba integrar varias partes y herramientas diferentes, lo primero fue asentar bien los conceptos clave. Solo así era posible empezar a programar con una idea clara de hacia dónde se quería llegar. A partir de esa base, y aprovechando la experiencia previa con MATLAB, junto con la consulta de documentación técnica y métodos existentes, se diseñaron las primeras versiones del código. Sin embargo, los primeros resultados estuvieron lejos de lo esperado, lo que provocó que se reconsiderara el enfoque por completo.

Tras analizar los errores, se decide empezar desde cero, esta vez incorporando un planteamiento nuevo: la predicción autorregresiva. Este método consiste en utilizar cada predicción como punto de partida para calcular la siguiente. En este caso, como se quiere predecir el estado de una variable con una hora de antelación, el sistema generaba una predicción para el primer minuto, usaba ese valor para predecir el segundo, y así sucesivamente hasta completar los 60 minutos. Gracias a esta mejora, se consiguió una versión más robusta del código, lista para comenzar a probarse.

Las primeras pruebas se realizaron con un conjunto de datos pequeño, lo que permitió confirmar que el sistema funcionaba, aunque se detectó un gran inconveniente: el tiempo de ejecución era demasiado largo. Esta lentitud tenía dos causas principales. Por un lado, el entrenamiento del modelo se hacía con un año completo de datos históricos, lo que ya suponía una carga considerable. Por otro, el propio proceso de predicción autorregresiva, al ser secuencial, incrementaba todavía más el tiempo necesario.

Con esto en mente, se opta por separar el código en dos partes: una dedicada al entrenamiento y otra a la predicción. Esta división mejoró el rendimiento general, aunque el entrenamiento siguió siendo una parte especialmente lenta.

A partir de ahí, se fueron realizando pruebas individuales de predicción, dedicando mucho tiempo a cada una, pero obteniendo resultados cada vez más prometedores. Como se quería tener una base estadística sólida, era necesario aumentar el número de pruebas. Para agilizar esta parte, se hicieron varios ajustes al código, añadiendo la automatización de los cálculos de error: el SMAPE, el RMSE y un histograma para visualizar cómo se distribuían los errores.

Con estas mejoras llegaron nuevos problemas, especialmente relacionados con la aparición de valores nulos o negativos en algunas variables, que impedían la correcta ejecución del código. Solventados estos obstáculos, se intentó ejecutar la predicción con todos los datos disponibles. No obstante, el tiempo necesario era tan elevado que la ejecución no llegaba a completarse.

Se pensó que quizás reduciendo la cantidad de datos se podría acortar el tiempo de ejecución, pero no resultó satisfactorio, el cambio fue mínimo. Tras revisar el código y confirmar que no había errores de programación, se concluyó que el principal problema era la naturaleza misma de la predicción autorregresiva. De hecho, para predecir un año entero, el sistema podía tardar hasta 15 días. Algo claramente inviable.

Como consecuencia de las limitaciones computacionales detectadas durante la fase de implementación, se evaluaron distintas estrategias de optimización sobre el sistema de predicción autorregresivo basado en Random Forest con 100 árboles. En una primera etapa, se procedió a reducir el número de árboles del modelo de 100 a 30, lo cual permitió disminuir el tiempo de ejecución total a aproximadamente cinco días. Si bien esta reducción temporal seguía resultando considerable en términos operativos, representó un avance significativo respecto a la situación inicial. Esta simplificación implicó una ligera pérdida de precisión predictiva, aunque los resultados obtenidos continuaban siendo estadísticamente aceptables. En una segunda fase de ajuste, se modificó el criterio de selección de los datos de entrada empleados en el proceso de inferencia. El objetivo principal de esta reestructuración fue obtener una representación más general del comportamiento dinámico de la variable objetivo, al tiempo que se buscaba reducir los tiempos de ejecución derivados del proceso autorregresivo. Estas medidas se orientaron a mejorar la escalabilidad del sistema sin comprometer sustancialmente su capacidad predictiva.

Hasta ese momento, lo que se hacía era mover la ventana de datos minuto a minuto: se tomaban, por ejemplo, los datos desde las 10:00 hasta las 12:00 y con eso se predecía el valor de las 13:00. Luego, el programa repetía el mismo proceso, pero empezando un minuto más tarde de 10:01 a 12:01 para predecir las 13:01, y así sucesivamente. Aunque este sistema ofrecía mucho detalle, tenía como inconveniente principal que hacía que las predicciones fueran muy lentas, especialmente al aplicarlo sobre grandes volúmenes de datos.

Por eso se optó por simplificar el proceso. En lugar de avanzar minuto a minuto, se decidió que las ventanas de entrada se movieran en tramos de una hora. Por ejemplo, ahora el sistema toma los datos entre las 11:00 y las 13:00 para predecir lo que ocurrirá a las 14:00. Después se avanza una hora: de 12:00 a 14:00 para predecir las 15:00, y así sucesivamente. Gracias a este ajuste, se consiguió reducir mucho el número total de ejecuciones, manteniendo la lógica temporal del modelo y haciendo que todo el proceso fuese mucho más ágil.

La solución más eficaz vino después: eliminar por completo la parte autorregresiva, pero conservar el entrenamiento con 100 árboles. Esta modificación permitió reducir drásticamente los tiempos de ejecución sin perder calidad de predicción. Las pruebas iniciales, con pocos datos, ofrecieron resultados muy positivos, lo que animó a probar con un conjunto de datos más amplio. También en este caso, los resultados fueron buenos y el tiempo de cómputo se redujo significativamente.

Finalmente, al comparar ambos métodos con y sin autorregresión se vio que el segundo ofrecía una mejor relación entre precisión y eficiencia. Por tanto, se optó por esta última versión como la definitiva para completar el desarrollo del proyecto.

Luego en este trabajo se plantea una doble aproximación para la estimación de la ampacidad en líneas aéreas de alta tensión. La primera vía consiste en predecir previamente las variables meteorológicas relevantes como la temperatura ambiente, la velocidad del viento, la dirección del viento y la radiación solar y, a partir de dichas predicciones, calcular la ampacidad. La segunda estrategia se basa en la predicción directa de la ampacidad utilizando el modelo descrito. Esta comparación tiene como objetivo evaluar cuál de los dos enfoques ofrece una mayor precisión y fiabilidad en el contexto operativo,

4.3 Comparativa sistema de predicción propio con variables medidas mediante estaciones meteorológicas en la línea

En este apartado se explican los datos utilizados para validar el modelo de predicción y el método seguido para comparar los resultados obtenidos por el sistema con los valores reales registrados por la estación meteorológica durante el año 2024.

Para comprobar la fiabilidad del sistema, se trabajó con cinco variables meteorológicas fundamentales: radiación solar, temperatura ambiente, velocidad y dirección del viento, y ampacidad. Cada una de ellas se trató por separado, utilizando el modelo individualmente con cada una. El proceso de entrenamiento se realizó utilizando los datos recogidos durante todo el año 2023, con una frecuencia de muestreo de un dato por minuto. Estos datos históricos permitieron construir modelos sólidos que se guardaron posteriormente para facilitar futuras pruebas sin necesidad de repetir el entrenamiento.

Una vez entrenados los modelos, se pasó a la fase de validación. En ella, se utilizó el módulo de predicción sobre los datos reales del año 2024. El funcionamiento era el siguiente: se proporcionaban al sistema dos horas continuas de datos previos, y este generaba una predicción de lo que ocurriría durante la siguiente hora. Es decir, partiendo del último dato conocido, el modelo proyectaba cómo evolucionaría la variable durante los siguientes 60 minutos. Este mismo proceso se repetía de manera continua para poder generar una gran cantidad de predicciones consecutivas, lo que permitía una evaluación más robusta del rendimiento.

Para valorar la precisión de las predicciones, se aplicaron tres herramientas clave, el SMAPE (Error porcentual absoluto medio simétrico), que ofrece una medida del error en porcentaje, teniendo en cuenta tanto sobreestimaciones como subestimaciones, el RMSE (Raíz del error cuadrático medio), que refleja cuánto se alejan, en promedio, los valores predichos de los reales, y los histogramas del error, que permiten ver de forma gráfica cómo se distribuyen los errores a lo largo de todas las predicciones.

Este procedimiento se siguió de forma idéntica para cada una de las variables, lo que permitió obtener una evaluación precisa del funcionamiento del sistema en cada caso concreto. El uso de datos reales, medidos a lo largo del año 2024, fue clave para garantizar que las pruebas se ajustaran a situaciones reales de funcionamiento, lo que da mayor fiabilidad a los resultados obtenidos. Por consiguiente, se muestran los códigos desarrollados para llevar a cabo esta parte.

Código MATLAB entrenamiento

```
% entrenar_modelo.m

% Cargar datos históricos

historico = readtable('datos_historicos.xlsx');

% Extraer la variable y convertirla a vector

y_historico = historico.variable;

% Parámetros

n_lags = 120;

n_muestras = length(y_historico) - n_lags;

% Preallocar matrices

X = zeros(n_muestras, n_lags);

Y = zeros(n_muestras, 1);

% Construir matriz de entrenamiento con rezagos

for i = 1:n_muestras

    X(i, :) = y_historico(i:i + n_lags - 1);

    Y(i) = y_historico(i + n_lags);

end

% Entrenar modelo Random Forest

modelo = TreeBagger(100, X, Y, 'Method', 'regression');

% Guardar el modelo entrenado

save('modelo_entrenadoConRetroDirViento.mat', 'modelo');
```

1. Carga e interpretación de datos históricos

En primer lugar, se procede a la importación de la base de datos mediante la función `readtable`, accediendo a la variable de interés (por ejemplo, velocidad del viento, temperatura o ampacidad) a través del campo `historico.variable`. Esta variable se extrae como un vector unidimensional, compatible con las estructuras requeridas para el entrenamiento supervisado.

2. Definición de parámetros estructurales del modelo

Se establece un número fijo de rezagos (`n_lags = 120`), lo cual implica que cada muestra de entrenamiento estará compuesta por una secuencia de 120 valores consecutivos previos al instante objetivo de predicción. Este planteamiento permite capturar la dinámica temporal de la serie, asumiendo que los estados pasados contienen información predictiva relevante sobre el futuro inmediato.

3. Construcción de matrices predictoras (X) y respuesta (Y)

Para cada instante de predicción posible dentro del conjunto histórico, se genera una ventana deslizante de tamaño fijo (`n_lags`), la cual se almacena en la matriz de características X. El valor real inmediatamente posterior a dicha ventana se almacena en el vector Y, constituyendo así el objetivo de la predicción para cada fila de X. Este procedimiento genera una base de datos de entrenamiento de tipo autoregresiva de una sola variable, sin incorporar entradas meteorológicas externas.

4. Entrenamiento del modelo de Random Forest

Se emplea el algoritmo `TreeBagger` con 100 árboles (`n_estimators = 100`) y con el método configurado para regresión ('Method', 'regression'). Esta técnica se basa en la generación de un conjunto de árboles de decisión independientes contruidos sobre subconjuntos aleatorios del conjunto de entrenamiento (bagging), lo que garantiza una elevada robustez frente a ruido y evita el sobreajuste.

5. Persistencia del modelo entrenado

Finalmente, el objeto resultante del entrenamiento (conteniendo toda la información de los árboles, reglas de decisión y estructuras internas del modelo) se guarda en un archivo mediante la función `save`, bajo el nombre 'modelo_entrenadoConRetroDirViento.mat'. Este archivo puede ser posteriormente cargado y reutilizado para llevar a cabo predicciones en tiempo real: Este mismo código se utilizó para llevar a cabo los entrenamientos para cada variable por separado.

Código MATLAB predicción

```
% Cargar modelo previamente entrenado

load('modelo_entrenadoTemperatura.mat', 'modelo');

% Cargar datos

datos = readtable('datos_actuales.xlsx');

fechas = datos.fecha;

y = datos.variable;

% Parámetros

n_lags = 120;

n_pred = 60;

total_muestras = length(y);

num_iteraciones = total_muestras - n_lags - n_pred;

% Preasignar matrices

valores_predichos = zeros(num_iteraciones, 1);

valores_reales = zeros(num_iteraciones, 1);

fechas_predichas = NaT(num_iteraciones, 1);

% Se preparan entradas para predicción

X = zeros(num_iteraciones, n_lags);

for i = 1:num_iteraciones

    X(i, :) = y(i:i + n_lags - 1);

    valores_reales(i) = y(i + n_lags + n_pred - 1); % Valor real a 60 minutos
```

```
    fechas_predichas(i) = fechas(i + n_lags + n_pred - 1); % Fecha asociada

end

% Predicción en bloque

Y_pred = predict(modelo, X);

valores_predichos = Y_pred;

% Tabla de resultados

tabla_resultados_sin_retro = table(fechas_predichas, valores_predichos, valores_reales,
...

    'VariableNames', {'fecha_predicha', 'valor_predicho', 'valor_real'});

disp(head(tabla_resultados_sin_retro));

% Cálculo de errores

errores = valores_predichos - valores_reales;

rmse = sqrt(mean(errores.^2));

% SMAPE (Symmetric Mean Absolute Percentage Error)

numerador = abs(valores_reales - valores_predichos);

denominador = (abs(valores_reales) + abs(valores_predichos)) / 2;

% Proteger contra divisiones por 0

denominador(denominador < eps) = eps;

smape = mean(numerador ./ denominador) * 100;

% Mostrar métricas

fprintf('RMSE: %.4f\n', rmse);
```

```
fprintf('SMAPE (Error porcentual absoluto simétrico): %.2f %%\n', smape);

% Histograma

figure;

histogramerrores, 30, 'Normalization', 'percentage', ...

    'FaceColor', [0 0 0.6], 'EdgeColor', 'black');

xlabel('Error de predicción');

ylabel('% de ocurrencia');

title('Histograma del error de predicción a 60 minutos');

grid on;

ax = gca;

ax.XAxis.LineWidth = 1.5;

ax.YAxis.LineWidth = 1.5;
```

1. Carga del modelo entrenado y de los datos a utilizar para la predicción

Se carga desde un archivo .mat el objeto modelo, que contiene el modelo predictivo previamente entrenado que en este caso corresponde a la temperatura, pero si quisiera hacer el de la radiación tendría que poner su modelo entrenado y así con el resto de variables. A continuación, se leen los datos reales desde un archivo Excel (.xlsx) que contiene dos columnas relevantes: la variable temporal de interés (datos.variable) y la marca temporal correspondiente (datos.fecha).

2. Configuración de parámetros y preasignación de variables

Se definen los parámetros clave del modelo:

- n_lags: número de observaciones pasadas usadas como entrada del modelo.
- n_pred: número de pasos (minutos) hacia adelante que se desea predecir.

- `num_iteraciones`: número de muestras útiles para la evaluación, en función del tamaño total de la serie y los parámetros definidos.

Se preasignan vectores y matrices para almacenar resultados (valores reales, predichos y fechas correspondientes), lo cual permite una ejecución eficiente y evita la sobrecarga computacional por redimensionamiento dinámico.

3. Generación del conjunto de prueba y preparación del input

Se genera la matriz de entrada X , donde cada fila contiene una secuencia de 120 observaciones pasadas, utilizadas como input para el modelo. Para cada entrada, se guarda el valor real que corresponde a 60 minutos después, el cual será comparado con la predicción. También se almacena la fecha de dicha predicción para trazabilidad temporal.

4. Evaluación del modelo

Se realiza la predicción en bloque para todas las muestras utilizando el método `predict` del modelo cargado, y se almacenan los resultados en `valores_predichos`.

5. Creación de una tabla resumen de resultados

Se construye una tabla resumen de unos pocos datos que permite visualizar de manera ordenada las predicciones generadas junto con los valores reales correspondientes y sus marcas temporales simplemente para ver rápidamente que resultados hay y poder comprobar si tienen sentido los resultados finales.

6. Cálculo de métricas de error

Se calcula el Error Cuadrático Medio (RMSE), que mide la desviación típica de los errores de predicción. Esta métrica penaliza más fuertemente los errores grandes y se expresa en las mismas unidades que la variable predicha.

Se computa el sMAPE, una métrica porcentual que evalúa el error relativo entre valores reales y predichos de manera simétrica. Se añade un control para evitar divisiones por cero (`eps`, el menor número positivo representable en coma flotante), lo que garantiza la estabilidad numérica del cálculo.

7. Visualización del error: histograma

Se genera un histograma de los errores de predicción, normalizado en porcentaje, que permite visualizar la distribución del error. Esta representación facilita la detección de sesgos sistemáticos, valores atípicos y la evaluación global del rendimiento del modelo.

8. Resultados finales

Se muestran las métricas principales en la consola.

4.4 Comparativa servicios meteorológicos externos con variables medidas mediante estaciones meteorológicas en la línea

Por último, se ha llevado a cabo una comparación entre los resultados ofrecidos por un sistema meteorológico externo de tipo comercial (OpenMeteo) y los datos reales registrados por la estación meteorológica utilizada como referencia.

Esta comparación se ha centrado en las siguientes variables: radiación solar, temperatura del aire, velocidad del viento y dirección del viento, tomando como base los datos reales correspondientes al año 2024. En el caso particular de la ampacidad, como OpenMeteo no proporciona una estimación directa de esta variable, se recurrió a un cálculo adicional. Para ello, se utilizó un script en Python proporcionado por la tutora del proyecto, que permite estimar la ampacidad por hora a partir de las predicciones meteorológicas suministradas por OpenMeteo. Este mismo procedimiento se había empleado previamente para obtener los valores reales de ampacidad en los años 2023 y 2024, ya que el objetivo del trabajo no es desarrollar un modelo de cálculo para esta magnitud.

Conviene señalar que las predicciones de OpenMeteo tienen una resolución temporal de una hora, mientras que los datos registrados por la estación meteorológica están disponibles con un detalle mucho mayor, a razón de un dato por minuto. Por este motivo, ha sido necesario realizar una adecuación temporal de los datos, alineando ambos conjuntos para asegurar una comparación precisa y coherente.

Con el fin de llevar a cabo esta comparación de forma ordenada y eficaz, se diseñó un script específico en MATLAB destinado exclusivamente al cálculo de las métricas de error. Las herramientas empleadas para valorar la calidad de las predicciones fueron las siguientes, SMAPE (Error porcentual absoluto medio simétrico), que permite analizar el error de forma equilibrada en valores altos y bajos, RMSE (Raíz del error cuadrático medio), que cuantifica cuánto se desvían los valores predichos respecto a los reales, y el histograma del error, que

permite observar visualmente cómo se distribuyen los errores a lo largo de toda la serie de predicciones.

A continuación, se incluye el código desarrollado en MATLAB para la obtención de estas métricas.

Código MATLAB Open Meteo

```
% Carga de datos reales minuto a minuto

reales = readtable('datos_actuales.xlsx');

reales.fecha = datetime(reales.fecha);

% Carga de datos predichos hora a hora

predichos = readtable('CompOpenMeteo.xlsx');

% Corrección del nombre de la columna de fecha

nombre_columna_fecha = predichos.Properties.VariableNames{1};

predichos.(nombre_columna_fecha) = datetime(predichos.(nombre_columna_fecha));

predichos.fecha = predichos.(nombre_columna_fecha);

% Filtrado de registros exactos por hora (HH:00)

reales_hora = reales(minute(reales.fecha) == 0, :);

% Alineación por fechas comunes entre reales y predichos

[fechas_comunes, idx_real, idx_pred] = intersect(reales_hora.fecha, predichos.fecha);

valores_reales = reales_hora.variable(idx_real);

valores_predichos = predichos.variable(idx_pred);

% Cálculo de errores y métricas
```

```
errores = valores_predichos - valores_reales;

rmse = sqrt(mean(errores.^2));

% SMAPE (Error porcentual absoluto simétrico)

numerador = abs(valores_reales - valores_predichos);

denominador = (abs(valores_reales) + abs(valores_predichos)) / 2;

denominador(denominador < eps) = eps;

smape = mean(numerador ./ denominador) * 100;

% Impresión de resultados

fprintf('RMSE: %.4f\n', rmse);

fprintf('sMAPE (Error porcentual absoluto simétrico): %.2f %%\n', smape);

fprintf('Total de comparaciones: %d\n', length(errores));

% Generación del histograma del error

figure;

histogram(errores, 30, 'Normalization', 'percentage', ...

    'FaceColor', [0 0 0.6], 'EdgeColor', 'black');

xlabel('Error de predicción');

ylabel('% de ocurrencia');

title('Histograma del error de predicción a 60 minutos');

grid on;

% Ajustes visuales
```

```
ax = gca;  
  
ax.XAxis.LineWidth = 1.5;  
  
ax.YAxis.LineWidth = 1.5;
```

1. Carga de los datos reales y predichos

Se cargan los datos reales minuto a minuto desde un archivo Excel. Se convierte la columna de fechas a tipo `datetime`, lo que permite operar posteriormente con fechas de forma precisa.

De manera similar, se importan los datos de predicción proporcionados por Open-Meteo, corrigiendo dinámicamente el nombre de la columna de fechas. Esto asegura la compatibilidad incluso si el archivo presenta ligeras variaciones en la estructura del encabezado.

2. Filtrado de datos reales a resolución horaria

Dado que los datos reales tienen resolución minuto a minuto y las predicciones son horarias, se filtran únicamente los registros cuya marca temporal coincide con el inicio de cada hora (HH:00). Esto permite igualar la granularidad temporal de ambos conjuntos de datos y garantizar comparabilidad directa.

3. Alineación por fechas comunes

Se identifican las fechas comunes entre ambos conjuntos de datos mediante la función `intersect`. Esto garantiza que la comparación se realice únicamente sobre registros coincidentes temporalmente, descartando datos faltantes o desalineados. Luego, se extraen los valores reales y predichos asociados a esas fechas.

4. Cálculo de métricas de error

Este paso y su explicación es igual al código anterior se utiliza exactamente lo mismo.

5. Visualización estadística de los errores e impresión de resultados

De nuevo, se utiliza el mismo formato que en el código anterior.

5 RESULTADOS

5.1 Resultados de mi sistema de predicción

5.1.1 Radiación

Con el objetivo de que se evalúe la precisión del sistema de predicción propio en la estimación de la radiación solar, se llevó a cabo una comparación de las predicciones con todos los valores correspondientes al año 2024.

La distribución del error de predicción se representa en la Figura X mediante un histograma que muestra el porcentaje de ocurrencias frente al error absoluto cometido en cada predicción horaria. Se observa que la mayoría de los errores se concentran en torno al valor cero, lo que sugiere que, en general, el modelo presenta un comportamiento simétrico sin sesgos sistemáticos marcados. No obstante, se evidencian colas más pronunciadas en ambos extremos, reflejo de casos puntuales en los que el modelo incurre en errores elevados, posiblemente asociados a condiciones atmosféricas inestables o transiciones bruscas de nubosidad.

Desde el punto de vista cuantitativo, se han obtenido los siguientes indicadores de rendimiento:

- RMSE (Root Mean Square Error): 134,22 W/m²
- SMAPE (Symmetric Mean Absolute Percentage Error): 58,57 %




Figura 10: Histograma del error de la radiación

Estos valores reflejan un desempeño moderado del modelo para la predicción de la radiación solar, siendo el SMAPE relativamente alto. Este comportamiento es coherente con la dificultad inherente a la predicción de esta variable, muy sensible a variaciones repentinas en la cobertura nubosa que no siempre se reflejan en los datos previos utilizados como entrada. A pesar de ello, la baja dispersión del histograma y la forma aproximadamente gaussiana de la distribución central apoyan la utilidad del modelo en contextos donde se requiera una estimación general de la evolución solar.

5.1.2 Temperatura ambiente

La validación del sistema para esta variable se ha llevado a cabo comparando los valores estimados con los registros reales correspondientes al año 2024. Se muestran a continuación, los siguientes resultados:

- RMSE (Root Mean Square Error): 0,9292 °C
- SMAPE (Symmetric Mean Absolute Percentage Error): 4,05 %




Figura 11: Histograma del error de la temperatura

La Figura 11 presenta el histograma del error de predicción, que muestra una distribución claramente centrada en torno a cero y con una dispersión muy limitada. Más del 70 % de los errores se concentran entre ± 1 °C, demostrando un muy buen ajuste de este sistema a la hora de predecir este tipo de variable.

5.1.3 Viento

La capacidad predictiva del sistema propuesto ha sido también evaluada para la variable velocidad del viento, donde se ha hecho una comparación con todos los datos del año 2024. De esta manera, se presentan las siguientes métricas:

- RMSE (Root Mean Square Error): 1,0198 m/s
- SMAPE (Symmetric Mean Absolute Percentage Error): 38,49 %.




Figura 12: Histograma del error del viento

La Figura 12 muestra la distribución del error de predicción. Como se observa, el histograma presenta una forma aproximadamente simétrica, con una clara concentración de errores en el entorno de 0 m/s, y una ligera asimetría hacia errores negativos. Alrededor del 75 % de las predicciones se sitúan en el rango comprendido entre -1,5 m/s y +1,5 m/s, lo que revela una adecuada capacidad de generalización del modelo en situaciones ordinarias, aunque ciertas desviaciones puntuales aún son observables en condiciones más inestables.

Este comportamiento es coherente con la complejidad intrínseca de la predicción del viento, una variable altamente sensible a fenómenos microclimáticos, turbulencias locales y discontinuidades orográficas.

5.1.4 Dirección del viento

Con el objetivo de evaluar la precisión del sistema de predicción propio en la estimación de la dirección del viento, se llevó a cabo una comparación de las predicciones hechas con todos los valores correspondientes al año 2024. Los indicadores cuantitativos obtenidos en este caso son los siguientes:

- RMSE (Root Mean Square Error): 59,57°
- SMAPE (Symmetric Mean Absolute Percentage Error): 23,89 %




Figura 13: Histograma de la dirección del viento

La Figura 13 muestra el histograma de errores correspondientes a las predicciones horarias, expresados en grados y agrupados según su porcentaje de ocurrencia. Se observa una distribución claramente centrada en torno al valor cero, con un marcado pico en ese entorno y una dispersión simétrica a ambos lados. Este patrón indica una buena estabilidad del modelo y una baja presencia de errores extremos.

5.1.5 Ampacidad

En este estudio, se ha evaluado la capacidad del sistema de predicción para predecir esta variable, la ampacidad y poder ver qué resultados se obtienen al predecir directamente esta variable que al final es la más importante. Los valores cuantitativos obtenidos en este análisis son:

- RMSE (Root Mean Square Error): 220,78 A

- SMAPE (Symmetric Mean Absolute Percentage Error): 11,13 %




Figura 14: Histograma del error de la ampacidad

La Figura 14 muestra el histograma de los errores cometidos en la predicción de la ampacidad, expresados en amperios, representando su distribución en términos de porcentaje de ocurrencia. Se observa una distribución centrada en torno al valor cero, con una forma claramente simétrica y campaniforme. Aunque existen errores dispersos de mayor magnitud, la mayoría de los valores se concentran en una región relativamente estrecha, lo que indica una buena capacidad del modelo para aproximar el valor real en la mayoría de los casos teniendo en cuenta que, la media de ampacidad que hay tanto para el año 2023 como para el 2024 es de alrededor de 1500 A, es importante marcar que la ampacidad del conductor antes de aplicar la gestión dinámica se encuentra alrededor de los 900 A para ciertas condiciones ambientales bastante desfavorables, mas concretamente las siguientes: temperatura de 35 °, viento de 0.6 perpendicular y radiación de 1000.

5.2 Resultados del Servicio Open-Meteo

5.2.1 Radiación

Para evaluar la fiabilidad del servicio meteorológico externo Open-Meteo en la estimación de la radiación solar, se compararon las predicciones horarias obtenidas durante todo el año 2024 con los datos reales registrados por la estación meteorológica situada en la línea de ensayo.

Los resultados se analizaron mediante tres herramientas fundamentales: el error porcentual absoluto medio simétrico sMAPE, la raíz del error cuadrático medio RMSE y la distribución gráfica de errores a través de un histograma. Mostrando lo siguiente:

- RMSE: 139,69 W/m²
- sMAPE: 149,89 %
- Total de comparaciones: 8.582




Figura 15: Histograma del error de la radiación

Como se observa en la Figura 15, el histograma del error muestra una fuerte concentración en torno al cero, aunque con una notable dispersión hacia valores negativos, lo que revela una tendencia sistemática a la subestimación de la radiación en ciertos tramos temporales por parte del modelo de Open-Meteo.

El valor elevado del RMSE refleja que, en términos absolutos, las desviaciones entre los valores predichos y medidos son amplias, mientras que el valor del sMAPE, superior al 100 %, indica una inestabilidad relativa importante, lo que compromete la fiabilidad del sistema.

5.2.2 Temperatura ambiente

En este apartado se analiza el rendimiento del servicio meteorológico comercial Open-Meteo en la predicción de la temperatura ambiente, utilizando como referencia los valores registrados por los sensores instalados en la línea de ensayo. Las métricas empleadas para cuantificar el rendimiento han sido:

- RMSE: 1,9547 °C
- sMAPE: 10,98 %
- Total de comparaciones: 8.582




Figura 16: Histograma del error de la temperatura

La Figura 16 muestra el histograma de los errores de predicción. En él se observa una distribución simétrica y centrada en torno al cero, con un alto porcentaje de errores agrupados en un rango estrecho de ± 2 °C. Esta forma de la distribución es un claro indicativo de estabilidad y fiabilidad en la predicción de esta variable por parte del servicio.

El bajo valor del RMSE, inferior a 2 grados centígrados, respalda este resultado, reflejando que, en términos absolutos, el modelo tiene una desviación media muy contenida. Asimismo, el sMAPE del 10,98 % corrobora que el error relativo es también reducido, situándose dentro de los umbrales aceptables para ciertas aplicaciones energéticas.

5.2.3 Viento

En este apartado se analiza el rendimiento del servicio meteorológico Open-Meteo en la estimación de la velocidad del viento, utilizando como base los registros reales obtenidos en la estación meteorológica instalada en la línea de ensayo. Para valorar la precisión del modelo se han utilizado dos métricas estándar:

- RMSE: 2,035 m/s
- sMAPE: 55,08 %
- Total de comparaciones: 8.582




Figura 17: Histograma del error del viento

En la Figura 17 se presenta el histograma del error de predicción, expresado como la diferencia entre los valores predichos por Open-Meteo y las mediciones reales. La distribución

muestra un perfil aproximadamente simétrico, con un sesgo ligeramente positivo hacia errores sobreestimados en la zona derecha del histograma. La mayor concentración de errores se encuentra en el entorno de ± 2 m/s, representando más del 60 % de las predicciones realizadas, lo que sugiere una cierta capacidad del modelo para capturar la dinámica general del viento, aunque con limitaciones claras en la precisión fina.

Estos resultados ponen de manifiesto las limitaciones de los servicios meteorológicos externos en predicciones locales de alta resolución temporal. En particular, el viento es una variable altamente dependiente del microclima y de las condiciones topográficas, lo que dificulta su estimación precisa mediante modelos numéricos globales con resolución espacial limitada.

5.2.4 Dirección del viento

En esta sección se analiza el rendimiento del servicio meteorológico Open-Meteo en la estimación de la dirección del viento. El análisis se ha llevado a cabo sobre los datos correspondientes a todo el año 2024. Las métricas de evaluación empleadas han sido:

- RMSE: 79,83°
- sMAPE: 33,38 %
- Total de comparaciones: 8.582




Figura 18: Histograma del error de la dirección el viento

La Figura 18 presenta el histograma de errores. Se observa una distribución centrada en torno al valor cero, aunque con una notable dispersión, en particular hacia valores positivos. El 25 % de las predicciones tienen errores dentro del rango $[-50^\circ, +50^\circ]$, aunque también se registran errores superiores a $\pm 200^\circ$ en un número no despreciable de casos.

El valor del RMSE, cercano a los 80 grados, refleja una alta variabilidad en la precisión del modelo, lo que puede estar asociado a la complejidad de la dinámica direccional del viento, especialmente en zonas con orografía irregular o cambios locales de presión.

5.2.5 Ampacidad

La ampacidad dinámica, entendida como la corriente máxima que puede circular por un conductor sin superar su temperatura límite, depende directamente de variables ambientales como la temperatura, la radiación solar, la velocidad y la dirección del viento. En este estudio, se ha evaluado la capacidad del servicio meteorológico Open-Meteo para predecir esta variable, combinando sus datos con un modelo físico de cálculo de ampacidad como

comentamos anteriormente. La evaluación se realizó sobre un conjunto de datos correspondiente a todo el año 2024. Los resultados obtenidos son:

- RMSE: 368,81 A
- sMAPE: 18,03 %
- Total de comparaciones: 8.582




Figura 19: Histograma del error de la ampacidad

La Figura 19 presenta el histograma del error de predicción. En él se observa una distribución simétrica, con el grueso de los errores concentrado entre -500 y $+500$ A. La forma acampanada y centrada del histograma sugiere una tendencia neutra sin sesgo sistemático, lo cual es una propiedad deseable para modelos de predicción que deben ajustarse a condiciones dinámicas. De nuevo, se deben tener presentes los valores comentados anteriormente, los cuales, comentamos en los resultados de la ampacidad del sistema de predicción.

6 CONCLUSIÓN

A lo largo de este trabajo se ha desarrollado, implementado y validado un sistema propio de predicción meteorológica orientado a la estimación de variables críticas para el cálculo de la ampacidad en líneas eléctricas. El modelo, basado en la técnica de Random Forest y entrenado con datos históricos de alta resolución (un dato por minuto durante todo 2023), ha demostrado un comportamiento robusto y eficaz, especialmente en contextos donde se requiere granularidad temporal y precisión en entornos operativos reales.

Los resultados obtenidos con el sistema propuesto muestran un rendimiento especialmente notable en variables como la temperatura ambiente y la ampacidad, con errores relativos SMAPE inferiores al 12 % y desviaciones absolutas medias RMSE moderadas, lo que confirma su idoneidad para aplicaciones vinculadas a la gestión dinámica de la red eléctrica. Aunque en el caso de variables más volátiles, como la radiación solar, el sistema ha presentado mayores niveles de error relativo SMAPE= 58 %, estos valores se encuentran dentro de los márgenes esperados, dada la naturaleza estocástica y la alta variabilidad espacial y temporal de dicha magnitud. Este resultado pone de manifiesto que predecir directamente la ampacidad ofrece un mejor rendimiento que estimarla de forma indirecta a partir de la predicción individual de las variables meteorológicas que intervienen en su cálculo. Esto se debe a que, en el enfoque indirecto, los errores asociados a cada variable temperatura, viento, radiación, etc. se propagan y acumulan en el cálculo final, incrementando significativamente el error total. En cambio, al modelar directamente la ampacidad como variable objetivo, el sistema aprende su comportamiento global de forma integrada, reduciendo la incertidumbre asociada al proceso de predicción.

Por otro lado, el análisis comparativo con el servicio Open-Meteo ha evidenciado ciertas limitaciones inherentes a los modelos de predicción comerciales de propósito general, particularmente en la estimación de radiación y velocidad del viento, donde se han observado errores porcentuales significativamente más altos, por ejemplo, un SMAPE superior al 100 % en el caso de la radiación. Estos resultados reflejan la limitada capacidad de generalización de dichos sistemas en entornos específicos, como el de este estudio.

Asimismo, debe subrayarse que, aunque Open-Meteo ha mostrado un comportamiento razonablemente estable en variables como la temperatura, el sistema propio ha ofrecido mejores prestaciones en prácticamente todas las métricas evaluadas, especialmente en la estimación final de la ampacidad, una variable derivada que no es directamente

proporcionada por servicios externos y cuya precisión depende fuertemente de la calidad de las variables meteorológicas de entrada.

En términos operativos, también se ha demostrado que la eliminación de la autorregresión y la reconfiguración del proceso de generación de predicciones han sido decisiones clave para optimizar la eficiencia del sistema sin comprometer su precisión. Este equilibrio entre tiempo de cómputo y calidad de predicción ha resultado esencial para asegurar la viabilidad del sistema en escenarios reales de aplicación.

En conjunto, los resultados obtenidos permiten concluir que el sistema de predicción desarrollado constituye una herramienta eficaz, flexible y técnicamente válida para la estimación de ampacidad en redes eléctricas, superando las capacidades de predicción de servicios comerciales genéricos y adaptándose de manera más efectiva a las particularidades del entorno de estudio.

7 BIBLIOGRAFÍA

- [1] wwwreees, “Informe del Sistema Eléctrico: Informe resumen de energías renovables 2023,” 2023.
- [2] “Generación renovable de energía eléctrica | Informes del sistema.” Accessed: Feb. 19, 2025. [Online]. Available: <https://www.sistemaelectrico-ree.es/informe-del-sistema-electrico/generacion/generacion-de-energia-electrica/generacion-renovable-de-energia-electrica>
- [3] P. D. Da Pilar Sánchez Núñez Consejeros Josep Maria Salas Prat D Carlos Aguilar Paredes Secretaria Da María Ángeles Rodríguez Paraja, “INFORME DE ANÁLISIS ECONÓMICO FINANCIERO DE RED ELÉCTRICA DE ESPAÑA, S.A.U. (2018-2022) CONSEJO. SALA DE SUPERVISIÓN REGULATORIA.” [Online]. Available: www.cnmc.es
- [4] “Generación total de energía eléctrica | Informes del sistema.” Accessed: Feb. 19, 2025. [Online]. Available: <https://www.sistemaelectrico-ree.es/informe-del-sistema-electrico/generacion/generacion-de-energia-electrica/generacion-total-de-energia-electrica>
- [5] “Plan Nacional Integrado de Energía y Clima (PNIEC 2023-2030).” Accessed: May 17, 2025. [Online]. Available: <https://www.miteco.gob.es/es/energia/estrategia-normativa/pniec-23-30.html?>
- [6] “La producción renovable crece en España un 10,3% en 2024 y alcanza sus mayores registros | Red Eléctrica.” Accessed: May 17, 2025. [Online]. Available: <https://www.ree.es/es/sala-de-prensa/actualidad/nota-de-prensa/2025/03/la-produccion-renovable-crece-en-Espana-un-10-3-por-ciento-2024-alcanza-mayores-registros?>
- [7] “Energía A Debate.” Accessed: May 17, 2025. [Online]. Available: <https://energiaadebate.com/electricidad-renovables-inercia-y-estabilidad-de-los-sistemas-electricos/>
- [8] P. Ledesma, “Y CONTROL ANÁLISIS DINÁMICO DE SISTEMAS ELÉCTRICOS,” 2022.

-
- [9] I. Encabo, J. Peiró, and G. García David Alvira, "NUEVAS HERRAMIENTAS DE OPERACIÓN EN EL SISTEMA ELÉCTRICO ESPAÑOL PARA POSIBILITAR LA TRANSICIÓN ECOLÓGICA," 2024.
- [10] "ENTSO-E confirma una desconexión de 2.200 MW en el sur de España como detonante del apagón." Accessed: May 17, 2025. [Online]. Available: <https://www.eleconomista.es/energia/noticias/13357195/05/25/entsoe-confirma-una-desconexion-de-2200-mw-en-el-sur-de-espana-como-detonante-del-apagon.html>
- [11] "Responsabilidad de Red Eléctrica de España (REE) ante el apagón peninsular del 28 de abril de 2025." Accessed: May 17, 2025. [Online]. Available: <https://es.linkedin.com/pulse/responsabilidad-de-red-el%C3%A9ctrica-espa%C3%B1a-ree-ante-el-el%C3%BAa-samaniego-sgvkf?>
- [12] "Qué es el grid forming y la inercia sintética: así se estabiliza la red eléctrica del futuro." Accessed: May 17, 2025. [Online]. Available: <https://www.eleconomista.es/energia/noticias/13340857/04/25/que-es-el-grid-forming-y-la-inercia-sintetica-asi-se-estabiliza-la-red-electrica-del-futuro.html>
- [13] "Compensadores Sincrónicos | Compensadores Sincrónicos | Generación, Transmisión y Distribución | WEG - Productos." Accessed: May 17, 2025. [Online]. Available: https://www.weg.net/catalog/weg/MX/es/Generaci%C3%B3n%2CTransmisi%C3%B3n-y-Distribuci%C3%B3n/Compensadores-Sincr%C3%B3nicos/Compensadores-Sincr%C3%B3nicos/p/MKT_WEM_SYN_CONSENSERS
- [14] "Almacenamiento." Accessed: May 17, 2025. [Online]. Available: <https://www.ree.es/es/transicion-ecologica/almacenamiento>
- [15] "El nuevo Mercado de Capacidad en España: ¿qué propone el diseño sometido a consulta pública? - Energía Estratégica España - Noticias sobre energías renovables del mercado ibérico." Accessed: May 17, 2025. [Online]. Available: <https://energiaestrategica.es/propuesta-mercado-capacidad/>
- [16] "Flexibilidad en redes eléctricas. Una nueva forma de mejorar la gestión energética. - CEMOSA." Accessed: May 17, 2025. [Online]. Available: <https://www.cemosa.es/2021/07/21/flexibilidad-en-redes-electricas-una-nueva-forma-de-mejorar-la-gestion-energetica/>
-

-
- [17] “Curvas de demanda y producción en tiempo real.” Accessed: May 17, 2025. [Online]. Available: <https://www.ree.es/es/operacion/sistema-electrico/demanda-y-produccion-en-tiempo-real>
- [18] “P.O. 12.1 Solicitudes de acceso para la conexión de nuevas instalaciones a la red de transporte”.
- [19] “BOE-A-2011-10202 Resolución de 3 de junio de 2011, de la Secretaría de Estado de Energía, por la que se aprueba el procedimiento de operación 3.7 ‘Programación de la generación de origen renovable no gestionable’ de los sistemas eléctricos insulares y extrapeninsulares.” Accessed: May 17, 2025. [Online]. Available: https://www.boe.es/diario_boe/txt.php?id=BOE-A-2011-10202
- [20] wwwreees, “Informe del Sistema Eléctrico: Informe resumen de energías renovables 2023,” 2023.
- [21] “BOE-A-2011-10202 Resolución de 3 de junio de 2011, de la Secretaría de Estado de Energía, por la que se aprueba el procedimiento de operación 3.7 ‘Programación de la generación de origen renovable no gestionable’ de los sistemas eléctricos insulares y extrapeninsulares.” Accessed: May 18, 2025. [Online]. Available: https://www.boe.es/diario_boe/txt.php?id=BOE-A-2011-10202
- [22] “Generación renovable de energía eléctrica | Informes del sistema.” Accessed: May 18, 2025. [Online]. Available: <https://www.sistemaelectrico-ree.es/informe-del-sistema-electrico/generacion/generacion-de-energia-electrica/generacion-renovable-de-energia-electrica>
- [23] “I. Disposiciones generales MINISTERIO DE INDUSTRIA Y ENERGÍA.”
- [24] “P.O. 3.7 Aplicación de limitaciones a las entregas de producción de energía en situaciones no resolubles con la aplicación de los servicios de ajuste del sistema”.
- [25] “715 GWh de vertidos en España en 2022 debido a que el sistema de transporte no crece al ritmo de la implantación de renovables – pv magazine España.” Accessed: May 18, 2025. [Online]. Available: <https://www.pv-magazine.es/2023/04/14/715-gwh-de-vertidos-en-espana-en-2022-debido-a-que-el-sistema-de-transporte-no-crece-al-ritmo-de-la-implantacion-de-renovables/>
-

-
- [26] M. Kanálik, A. Margitová, and Ľ. Beňa, "Temperature calculation of overhead power line conductors based on CIGRE Technical Brochure 601 in Slovakia," *Electrical Engineering*, vol. 101, no. 3, pp. 921–933, Sep. 2019, doi: 10.1007/s00202-019-00831-8.
- [27] P. Por, R. Alberdi, M. Directores, I. Albizu Flórez, and E. Fernández Herrero, "Tesis doctoral METODOLOGÍA PARA LA PREDICCIÓN DE AMPACIDAD EN LÍNEAS ELÉCTRICAS AÉREAS A PARTIR DE MEDIDAS DIRECTAS Y PREDICCIONES METEOROLÓGICAS."
- [28] M. Merenda, C. Porcaro, and D. Iero, "Edge machine learning for ai-enabled iot devices: A review," *Sensors (Switzerland)*, vol. 20, no. 9, May 2020, doi: 10.3390/s20092533.
- [29] S. Shao, Z. Zhou, G. Deng, P. Du, C. Jian, and Z. Yu, "Experiment of structural geometric morphology monitoring for bridges using holographic visual sensor," *Sensors (Switzerland)*, vol. 20, no. 4, Feb. 2020, doi: 10.3390/s20041187.
- [30] "El programa HIRLAM-A."
- [31] E. Rodriguez Camino and G.-M. Zapata, "EL MODELO HIRLAM DE PREDICCIÓN DEL INM," no. 1, 1995.
- [32] "GFS." Accessed: May 26, 2025. [Online]. Available: https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gfs.php
- [33] "WRF Y GFS".
- [34] "Weather Research & Forecasting Model (WRF) | Mesoscale & Microscale Meteorology." Accessed: May 26, 2025. [Online]. Available: <https://www.mmm.ucar.edu/models/wrf>
- [35] "Unified Model - Met Office." Accessed: May 26, 2025. [Online]. Available: <https://www.metoffice.gov.uk/research/approach/modelling-systems/unified-model>
- [36] "GEFS." Accessed: May 26, 2025. [Online]. Available: https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gefs.php
- [37] J. A. Mauricio, "Análisis de Series Temporales _____
SERIES TEMPORALES PÁGINA II OBSERVACIONES PRELIMINARES."
-

-
- [38] “¿Qué es un modelo MA 1? Todo lo que debe saber sobre los modelos MA (medias móviles).” Accessed: Feb. 17, 2025. [Online]. Available: <https://shallbd.com/es/que-es-un-modelo-ma-1-todo-lo-que-debe-saber-sobre-los-modelos-ma-medias-moviles/>
- [39] “COMPARATIVA DEL MODELO AUTORREGRESIVO Y MEDIA MÓVIL PARA EL PRONÓSTICO DE LA DEMANDA ELÉCTRICA DEL ECUADOR CONSIDERANDO EL CRITERIO AKAIKE”.
- [40] A. Micaela, M. Rubio, and J. C. Cañas, “ESTIMACIÓN DE MODELOS ARMA USANDO EL MODELO ESPACIO DE LOS ESTADOS”.
- [41] J. J. Díaz, “MODELOS REG-ARIMA PARA LA PREDICCIÓN DE DEMANDA ELÉCTRICA EN EL Martín Sainz-Trápaga de Garnica”.
- [42] A. Sherstinsky, “Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network”, Accessed: Feb. 17, 2025. [Online]. Available: <https://www.linkedin.com/in/alexsherstinsky>
- [43] D. De Trabajo and C. Arana, “UNIVERSIDAD DEL CEMA Buenos Aires Argentina Serie,” 2021. [Online]. Available: www.cema.edu.ar/publicaciones/doc_trabajo.html
- [44] “¿Qué es la long short-term memory (LSTM)? - IONOS.” Accessed: May 28, 2025. [Online]. Available: <https://www.ionos.com/es-us/digitalguide/paginas-web/desarrollo-web/long-short-term-memory/>
- [45] “Guía completa sobre Random Forest - Ander Fernández.” Accessed: Feb. 18, 2025. [Online]. Available: <https://anderfernandez.com/blog/guia-completa-random-forest/>
- [46] M. R. Segal, “UCSF Recent Work Title Machine Learning Benchmarks and Random Forest Regression Publication Date Machine Learning Benchmarks and Random Forest Regression,” Apr. 14, 2004.
- [47] “Descomposición de series temporales: Tendencias, estacionalidad y ruido | DataCamp.” Accessed: May 28, 2025. [Online]. Available: https://www.datacamp.com/es/tutorial/time-series-decomposition?utm_source
- [48] “Forecasting: Principles and Practice (3rd ed).” Accessed: May 28, 2025. [Online]. Available: <https://otexts.com/fpp3/index.html>
-

-
- [49] “Descomposición Multiplicativa - FasterCapital.” Accessed: May 28, 2025. [Online]. Available: https://fastercapital.com/es/palabra-clave/descomposici%C3%B3n-multiplicativa.html?utm_source