



Uso de modelos predictivos basados en inteligencia artificial para anticipar la producción agrícola en función de variables climáticas

Using predictive models based on artificial intelligence to anticipate agricultural production based on climatic variables

Utilizando modelos predictivos basados em inteligênciã artificial para antecipar a produção agrícola com base em variáveis climáticas

Luis Jacinto Mendoza Cuzme ^I
luis.mendoza@uleam.edu.ec
<https://orcid.org/0000-0001-7621-5743>

Mike Paolo Machuca Avalos ^{II}
mike.machuca@uleam.edu.ec
<https://orcid.org/0000-0003-1093-3886>

Oscar Armando González López ^{III}
oscar.gonzalez@uleam.edu.ec
<https://orcid.org/0009-0004-9696-0600>

Correspondencia: luis.mendoza@uleam.edu.ec

Ciencias Técnicas y Aplicadas
Artículo de Investigación

* **Recibido:** 26 de febrero de 2025 * **Aceptado:** 24 de marzo de 2025 * **Publicado:** 13 de abril de 2025

- I. Universidad Laica Eloy Alfaro de Manabí, Ecuador.
- II. Universidad Laica Eloy Alfaro de Manabí, Ecuador.
- III. Universidad Laica Eloy Alfaro de Manabí, Ecuador.

Resumen

Los modelos predictivos basados en inteligencia artificial representan una evolución poderosa de los métodos cuantitativos, permitiendo analizar relaciones más complejas entre variables climáticas y la producción agrícola. La IA puede mejorar la precisión, el horizonte temporal y el nivel de detalle de los pronósticos, lo que se traduce en una toma de decisiones más informada y eficiente para los agricultores y la industria agrícola en general. La precisión, la resolución espacial y temporal, y el horizonte de pronóstico de los modelos NWP impactan directamente en la calidad y utilidad de las predicciones de producción agrícola generadas por la IA. La integración efectiva de la información meteorológica pronosticada con técnicas de aprendizaje automático y otras fuentes de datos representa una vía prometedora para mejorar la resiliencia y la eficiencia del sector agrícola frente a la variabilidad y el cambio climático. La IA proporciona las herramientas para analizar complejas relaciones entre el clima y los cultivos, mientras que los modelos NWP ofrecen la información meteorológica prospectiva necesaria para realizar predicciones informadas y potencialmente mejorar la resiliencia y la eficiencia del sector agrícola. El uso de modelos predictivos basados en inteligencia artificial, alimentados con información precisa y oportuna de modelos numéricos de predicción meteorológica, representa un avance significativo en la capacidad de anticipar la producción agrícola. Esta combinación ofrece el potencial de mejorar la toma de decisiones en el sector agrícola, optimizar la gestión de recursos, aumentar la eficiencia y contribuir a la seguridad alimentaria en un contexto de creciente variabilidad climática.

Palabras Clave: modelos predictivos; inteligencia artificial; agricultura.

Abstract

Artificial intelligence-based predictive models represent a powerful evolution of quantitative methods, enabling the analysis of more complex relationships between climate variables and agricultural production. AI can improve the accuracy, time horizon, and level of detail of forecasts, resulting in more informed and efficient decision-making for farmers and the broader agricultural industry. The accuracy, spatial and temporal resolution, and forecast horizon of NWP models directly impact the quality and usefulness of AI-generated agricultural production predictions. Effectively integrating forecasted weather information with machine learning techniques and other data sources represents a promising avenue for improving the resilience and efficiency of the agricultural sector in the face of climate variability and change. AI provides the tools to analyze

complex relationships between climate and crops, while NWP models offer the forward-looking weather information needed to make informed predictions and potentially improve the resilience and efficiency of the agricultural sector. The use of artificial intelligence-based predictive models, coupled with accurate and timely information from numerical weather prediction models, represents a significant advance in the ability to anticipate agricultural production. This combination offers the potential to improve decision-making in the agricultural sector, optimize resource management, increase efficiency, and contribute to food security in a context of increasing climate variability.

Keywords: predictive models; artificial intelligence; agriculture.

Resumo

Os modelos preditivos baseados em inteligência artificial representam uma poderosa evolução dos métodos quantitativos, permitindo a análise de relações mais complexas entre as variáveis climáticas e a produção agrícola. A IA pode melhorar a precisão, o horizonte temporal e o nível de detalhe das previsões, resultando numa tomada de decisões mais informada e eficiente para os agricultores e para o setor agrícola em geral. A precisão, a resolução espacial e temporal e o horizonte de previsão dos modelos de NWP impactam diretamente a qualidade e a utilidade das previsões de produção agrícola geradas pela IA. A integração eficaz da informação meteorológica prevista com técnicas de aprendizagem automática e outras fontes de dados representa um caminho promissor para melhorar a resiliência e a eficiência do sector agrícola face à variabilidade e às alterações climáticas. A IA fornece ferramentas para analisar relações complexas entre o clima e as plantações, enquanto os modelos NWP oferecem informações meteorológicas futuras necessárias para fazer previsões informadas e potencialmente melhorar a resiliência e a eficiência do sector agrícola. A utilização de modelos preditivos baseados em inteligência artificial, alimentados por informação precisa e oportuna de modelos numéricos de previsão climática, representa um avanço significativo na capacidade de antecipar a produção agrícola. Esta combinação oferece o potencial para melhorar a tomada de decisões no sector agrícola, otimizar a gestão dos recursos, aumentar a eficiência e contribuir para a segurança alimentar num contexto de crescente variabilidade climática.

Palavras-chave: modelos preditivos; inteligência artificial; agricultura.

Introducción

La creciente preocupación por la seguridad alimentaria global, exacerbada por el cambio climático y el aumento de la población, exige soluciones innovadoras para optimizar la producción agrícola. La agricultura, intrínsecamente ligada a las condiciones ambientales, se ve directamente afectada por la variabilidad climática, lo que genera incertidumbre en la planificación y la productividad. En este contexto, la capacidad de anticipar con precisión la producción agrícola se ha convertido en un objetivo crucial para la toma de decisiones informada a lo largo de toda la cadena de valor, desde la siembra hasta la distribución.

Tradicionalmente, la predicción de la producción agrícola se ha basado en métodos estadísticos y modelos empíricos que, si bien útiles, a menudo presentan limitaciones para capturar la complejidad no lineal y las interacciones multifactoriales inherentes a los sistemas agroclimáticos. Sin embargo, el advenimiento y la rápida evolución de la inteligencia artificial (IA) ofrecen un paradigma prometedor para abordar estos desafíos. Los modelos predictivos basados en IA, con su capacidad para aprender patrones complejos a partir de grandes volúmenes de datos, han demostrado un potencial significativo en diversas áreas, incluyendo la predicción de la demanda, el pronóstico financiero y el análisis ambiental.

En el ámbito agrícola, la IA se presenta como una herramienta poderosa para integrar y analizar diversas fuentes de información, incluyendo datos históricos de producción, características del suelo, información fenológica y, de manera fundamental, variables climáticas. La disponibilidad de predicciones meteorológicas cada vez más precisas, generadas por Modelos Numéricos de Predicción Meteorológica (NWP), proporciona un insumo valioso para los modelos de IA, permitiendo anticipar el impacto de las condiciones climáticas futuras en el rendimiento de los cultivos.

Este artículo explora el uso de modelos predictivos basados en inteligencia artificial para anticipar la producción agrícola en función de variables climáticas. Se analizarán los fundamentos de los métodos estadísticos tradicionales y los enfoques de soft computing, con un enfoque particular en las redes neuronales, así como el papel crucial de los modelos NWP como fuente de datos predictivos del clima. El objetivo es ofrecer una visión general del estado actual de la investigación, destacar los beneficios y desafíos de la aplicación de la IA en este dominio, y discutir las perspectivas futuras para el desarrollo de sistemas de predicción agrícola más precisos y robustos, contribuyendo así a una agricultura más resiliente y sostenible.

Se comprende que la demanda se refiere a la cantidad total de un producto que un grupo específico de compradores planea adquirir durante un periodo determinado, considerando las condiciones del entorno y las estrategias comerciales implementadas (Poorzaker & Ebrahimpour, 2019) La predicción de la demanda futura se basa en el análisis de patrones identificables en la demanda histórica, lo que facilita su estimación a través de pronósticos (Hu, Szerlip, Karaletsos, & Singh, 2019). Estos autores definen el pronóstico como un proceso para estimar eventos futuros mediante la proyección de datos pasados, combinados sistemáticamente para predecir tendencias futuras y así identificar patrones recurrentes.

Según (Kim, Lee, & Sohn, 2019), los pronósticos se clasifican por su horizonte temporal: Corto plazo: Generalmente hasta 3 meses, útil para la planificación de compras, personal y asignaciones de producción. Mediano plazo: De 3 meses a 3 años, empleado en la planificación de ventas, producción, presupuesto y operaciones. Largo plazo: Usualmente 3 años o más, utilizado para la planificación de nuevos productos, ubicación de instalaciones, expansiones e investigación y desarrollo.

Autores como (Vijai & Bagavathi Sivakumar, 2018) señalan cuatro características fundamentales de los pronósticos, identificadas a través de la experimentación. Estas incluyen la importancia de reconocer y valorar el error de pronóstico para mejorar la toma de decisiones, la menor precisión de los pronósticos a largo plazo debido a una mayor desviación estándar, la mayor exactitud de los pronósticos agregados en comparación con los desagregados, y la sensibilidad de la efectividad del pronóstico a la calidad de la información utilizada.

Los modelos numéricos de predicción meteorológica son un componente esencial de la infraestructura de datos para el desarrollo de sistemas de predicción agrícola basados en inteligencia artificial. . La sinergia entre los modelos predictivos basados en inteligencia artificial y los modelos numéricos de predicción meteorológica representa un avance significativo en la capacidad de anticipar la producción agrícola

DESARROLLO

Para la elaboración de pronósticos precisos, resulta fundamental la disponibilidad de datos históricos que sirvan como insumo para los modelos predictivos. Estos conjuntos de datos, denominados series de tiempo, se definen como una secuencia de observaciones registradas cronológicamente, donde el tiempo constituye una variable independiente crucial para el análisis

de la evolución de múltiples variables dependientes ((Rezaie, 2022) La naturaleza secuencial de las series de tiempo permite identificar patrones y tendencias que sustentan la proyección de eventos futuros.

Este mismo autor Rezaie (2022) categoriza los métodos de pronóstico en diversas tipologías, ofreciendo a las organizaciones un abanico de opciones para seleccionar la estrategia más adecuada a las características de su demanda y mercado objetivo, o incluso combinar diferentes enfoques. Estas categorías principales se distinguen por su metodología y aplicabilidad:

El primero de ellos es el Método Cualitativo caracterizado por la ausencia de una estructura analítica formal, estos métodos se emplean principalmente en situaciones de incertidumbre, como la introducción de nuevos productos al mercado. Su naturaleza subjetiva se basa en el juicio experto y la opinión personal, lo que permite obtener resultados con relativa rapidez. El segundo referido a los Métodos Cuantitativos: Estos enfoques emplean herramientas matemáticas y estadísticas para la determinación de la demanda futura.

Dentro de esta categoría, se identifican dos subgrupos principales: Pronósticos de Series de Tiempo, los cuales explotan los patrones históricos de la demanda para proyectar valores futuros, asumiendo que las tendencias pasadas pueden ofrecer información valiosa sobre el comportamiento futuro. Y los de pronósticos causales que se fundamentan en la identificación de relaciones de correlación entre la demanda y otras variables relevantes, buscando explicar y predecir la demanda en función de los cambios en dichas variables causales.

La comprensión de esta clasificación y las particularidades de cada método resulta necesario para la selección e implementación de estrategias de pronóstico efectivas en el ámbito empresarial y científico.

Desde estas ideas se comprende que los métodos de pronóstico tradicionales emplean como base los métodos cualitativos y cuantitativos (series de tiempo y causales) proporcionan los fundamentos conceptuales para la predicción. Debido a esto, entender la naturaleza de la demanda (en este caso, la producción agrícola), los diferentes horizontes de tiempo para la planificación y las características esenciales de un pronóstico (error, precisión según el horizonte, agregación) es crucial antes de aplicar técnicas más avanzadas como la IA.

Por tanto, los datos históricos de producción agrícola y variables climáticas constituyen las series de tiempo que alimentan tanto los modelos estadísticos tradicionales como los modelos de IA. La

calidad y la extensión de estas series de tiempo son determinantes para la precisión de cualquier pronóstico.

Del mismo modo, la IA se considera como una evidencia de evolución de los métodos cuantitativos teniendo en cuenta que los modelos predictivos basados en IA, como el aprendizaje automático (Machine Learning) y el aprendizaje profundo (Deep Learning), representan una extensión novedosa de los métodos cuantitativos. Estos pueden analizar grandes cantidades de datos complejos (incluyendo series de tiempo multivariadas con variables climáticas, datos de suelo, imágenes satelitales, etc.) e identificar al mismo tiempo patrones no lineales y relaciones causales que serían difíciles o imposibles de detectar con los métodos estadísticos tradicionales (regresión lineal, ARIMA, etc.).

Por otra parte, mientras que los métodos de series de tiempo tradicionales se centran en analizar la evolución temporal de una o varias variables, los modelos de IA pueden añadir una mayor cantidad de variables independientes (climáticas, edáficas, fenológicas, etc.) y sus interacciones lo cual permite predecir la variable dependiente tal es el caso de la producción agrícola.

Ahora bien, existen tipos de pronósticos aplicables en la IA agrícola definidos en atención a los horizontes de tiempo tales como a corto, mediano y largo plazo y que siguen siendo relevantes para los modelos de IA en la agricultura.

En tal sentido, los pronósticos aplicables en la IA agrícola a corto plazo, pueden permitir la predicción de cosechas inmediatas, gestión de riego y fertilizantes en tiempo real, alertas tempranas de enfermedades o plagas basadas en condiciones climáticas.

A Mediano plazo, los pronósticos aplicables en la IA agrícola pudiesen permitir la planificación de siembra, decisiones sobre qué cultivos plantar en función de las tendencias climáticas estacionales, gestión de recursos para la próxima temporada. Y, a largo plazo, la evaluación del impacto del cambio climático en la productividad agrícola, planificación de inversiones en infraestructura y desarrollo de nuevas variedades de cultivos.

Se comprende entonces que los modelos de IA pueden ir más allá al identificar relaciones causales complejas y no evidentes entre variables climáticas específicas (temperatura en diferentes etapas fenológicas, patrones de lluvia, humedad, radiación solar, etc.) y el rendimiento de los cultivos.

Por otra parte en la mejora de las características del pronóstico con IA, ésta puede ayudar a cuantificar y reducir el error de pronóstico mediante la validación cruzada, la optimización de hiperparámetros y la selección de los modelos más adecuados para cada contexto agrícola.

Si bien la regla general de que los pronósticos a largo plazo son menos precisos se mantiene, la IA puede mejorar la precisión de los pronósticos a largo plazo al incorporar modelos climáticos y escenarios futuros más complejos. Además de lo anterior, la IA facilita la realización de pronósticos desagregados, como por ejemplo por parcela, por tipo de cultivo específico, los cuales pueden ser analizados con mayor precisión que los métodos tradicionales, al considerar la variabilidad espacial y las condiciones locales.

Otros de los modelos, son los de Análisis de Regresión, la cual es una técnica estadística ampliamente utilizada para modelar y pronosticar la demanda, estableciendo relaciones entre la variable de interés y diversos factores influyentes, tales como las condiciones meteorológicas, el tipo de día o las características de los consumidores (Singh, Ibraheem, Khatoon S. Muazzam, & Chaturvedi, 2012). Una parte significativa de la investigación en regresión lineal se ha centrado en la identificación de las variables predictoras relevantes para la demanda tal como lo han encontrado investigadores como (Ruzic & Vuckovic, 2003.) (Engle, Mustafa, & Rice, 1992)

Lo anteriormente descrito señala que en contexto de la predicción de la producción agrícola mediante IA, el análisis de regresión proporciona un marco conceptual inicial para comprender cómo las variables climáticas como la temperatura, precipitación, radiación solar, etc. impactan el rendimiento de los cultivos. Los modelos de IA pueden considerarse como una extensión sofisticada de la regresión, capaces de modelar relaciones no lineales y complejas entre un conjunto aún mayor de variables predictoras y la producción agrícola, superando las limitaciones de los modelos lineales tradicionales.

Se ha encontrado además los Métodos Basados en Series de Tiempo, los cuales se fundamentan en la premisa de que los datos secuenciales en el tiempo contienen una estructura interna susceptible de ser modelada para realizar predicciones.

Alguno de ellos son Modelos Autoregresivos (AR), los cuales predicen el valor actual de una serie basándose en valores previos de la misma serie de demanda (Huang, Huang, Gadh, & Li, 2012);. Los Modelos de Medias Móviles (MA) que estiman el siguiente valor como una combinación del promedio histórico de la serie y una combinación de errores aleatorios precedentes. Los Modelos ARMA que integran componentes autoregresivos y de medias móviles para capturar diferentes aspectos de la dinámica temporal., (Erdem & Shi, 2011) los Modelos ARIMA que extienden los modelos ARMA para modelar series de tiempo no estacionarias mediante la inclusión de una etapa de diferenciación (integración) y los Modelos ARIMAX y SARIMAX (Mandal, Senjyu, Urasaki,

& Funabashi, 2006), los cuales permiten incorporar variables exógenas (como factores climáticos) y componentes estacionales, respectivamente, enriqueciendo la capacidad predictiva de los modelos ARIMA (Singh, Ibraheem, Khatoon S. Muazzam, & Chaturvedi, 2012).

Los modelos de IA pueden aprovechar estos principios al analizar patrones temporales complejos en múltiples series de tiempo simultáneamente, por ejemplo, las redes neuronales recurrentes (RNN) y las redes de memoria a corto plazo (LSTM) las cuales son arquitecturas de aprendizaje profundo diseñadas específicamente para procesar datos secuenciales y pueden identificar dependencias temporales intrincadas entre las variables climáticas y la producción de cultivos, superando las limitaciones de los modelos lineales de series de tiempo tradicionales en la captura de no linealidades y dependencias de largo alcance. La capacidad de los modelos ARIMAX y SARIMAX para incorporar variables exógenas anticipa la capacidad de los modelos de IA para integrar una amplia gama de factores climáticos y otros datos relevantes para una predicción más precisa de la producción agrícola.

Los modelos numéricos de predicción meteorológica (NWP) constituyen una herramienta fundamental para anticipar el estado futuro de la atmósfera, con horizontes temporales que generalmente oscilan entre 15 y 240 horas. Estos modelos se basan en la representación de la atmósfera a través de un conjunto de ecuaciones diferenciales que describen las leyes físicas que gobiernan su comportamiento. El concepto inicial de un modelo NWP fue introducido por el científico noruego Vilhelm Bjerknes (Lynch, 2008.)

Los modelos numéricos de predicción meteorológica desempeñan un papel crucial como fuente de datos fundamentales para el desarrollo de modelos predictivos basados en inteligencia artificial destinados a anticipar la producción agrícola en función de variables climáticas.

Se ha encontrado que existen variables climáticas predictoras que son analizadas a través de los modelos NWP proporcionando predicciones detalladas de las variables climáticas clave que influyen directamente en el crecimiento y rendimiento de los cultivos, como temperatura, precipitación, radiación solar, humedad y viento. Estos datos constituyen las variables de entrada esenciales para entrenar y operar los modelos de IA.

Además la información generada por los modelos NWP abarca tanto la dimensión espacial a través de su resolución geográfica como la dimensión temporal a través de sus horizontes de pronóstico y resolución temporal. Esta riqueza de datos espacio-temporales permite a los modelos de IA

capturar la variabilidad climática en diferentes ubicaciones y a lo largo del tiempo, lo que es crucial para realizar predicciones agrícolas precisas y localizadas.

Los diferentes tipos de modelos NWP (globales y regionales) ofrecen información climática a diversas escalas espaciales y con distintos horizontes temporales. Esta diversidad permite alimentar modelos de IA diseñados para predicciones agrícolas a corto, mediano y largo plazo, adaptándose a las diferentes necesidades de planificación y toma de decisiones en el sector agrícola.

Por último, la mejora de la Precisión de la IA se alcanza al integrar predicciones meteorológicas de alta calidad provenientes de modelos NWP y los modelos de IA, los cuales pueden refinar sus propias predicciones de producción agrícola, incorporando información explícita sobre las condiciones climáticas futuras en lugar de depender únicamente de patrones históricos. Esto es especialmente relevante en escenarios de variabilidad climática y eventos meteorológicos extremos.

En tal sentido, como forma de sintetizar algunos aspectos clave, se tiene que la IA representa una evolución valiosa para la predicción agrícola, superando las limitaciones de los métodos estadísticos tradicionales. Mientras que métodos como la regresión y los modelos de series de tiempo proporcionan la base conceptual y los datos históricos iniciales, la IA, especialmente a través de redes neuronales, ofrece la capacidad de modelar relaciones no lineales complejas entre múltiples variables (climáticas, edáficas, de manejo, etc.) y la producción agrícola con mayor precisión y adaptabilidad.

Los modelos NWP son una fuente de datos esencial y de alta calidad para los modelos de IA en la agricultura. Proporcionan predicciones detalladas y espacio-temporales de variables climáticas cruciales (temperatura, precipitación, radiación solar, etc.) que actúan como insumos fundamentales para el entrenamiento y la operación de los modelos de IA. La precisión y la resolución de los modelos NWP impactan directamente en la fiabilidad de las predicciones agrícolas generadas por la IA.

La combinación de la capacidad de modelado avanzado de la IA con la información predictiva de los modelos NWP permite abordar la complejidad de la producción agrícola de manera más efectiva. La IA puede aprender patrones complejos y no lineales a partir de los datos históricos y las predicciones meteorológicas, adaptándose a las dinámicas cambiantes del clima y los sistemas agrícolas..

En tal sentido, la integración de datos de modelos NWP con otras fuentes de información agrícola (historial de rendimientos, datos de suelo, sensores remotos, etc.) en los modelos de IA puede conducir a predicciones aún más precisas y holísticas. La combinación de diferentes tipos de datos permite a la IA capturar una visión más completa de los factores que influyen en la producción agrícola.

CONCLUSIONES

Las principales conclusiones sobre el uso de modelos predictivos basados en inteligencia artificial (IA) para anticipar la producción agrícola en función de variables climáticas son las siguientes:

La IA emerge como una herramienta eficaz e innovadora para la predicción agrícola, superando las limitaciones de los métodos estadísticos tradicionales. Mientras que enfoques como la regresión y los modelos de series de tiempo facilitan una base fundamental, la IA, especialmente a través de técnicas de aprendizaje automático y aprendizaje profundo como las redes neuronales, ofrece la capacidad de modelar relaciones complejas, no lineales y multivariadas entre las variables climáticas y la producción de cultivos de manera más efectiva.

Los Modelos Numéricos de Predicción Meteorológica (NWP) son una fuente de datos crucial y esencial para alimentar los modelos de IA en la agricultura al proporcionar predicciones detalladas y espacio-temporales de las variables climáticas clave como la temperatura, precipitación, radiación solar, viento, etc. que influyen directamente en el crecimiento y rendimiento de los cultivos. La calidad, resolución y horizonte temporal de los modelos NWP impactan significativamente la precisión de las predicciones agrícolas generadas por la IA.

La sinergia entre la capacidad de modelado avanzado de la IA y la información predictiva proporcionada por los modelos NWP permite una comprensión y anticipación más precisa de la producción agrícola. La IA puede aprender patrones intrincados a partir de datos históricos y pronósticos meteorológicos, adaptándose a la dinámica cambiante del clima y los sistemas agrícolas.

Los modelos NWP ofrecen pronósticos en estas diversas escalas, lo que permite a la IA generar predicciones agrícolas que se ajustan a diferentes necesidades de planificación y toma de decisiones, desde la gestión operativa de la temporada actual hasta la planificación estratégica a largo plazo.

El diseño, la implementación y la optimización de modelos de IA para la predicción agrícola requieren una consideración cuidadosa de la arquitectura del modelo (por ejemplo, redes

neuronales), la selección de las variables de entrada más relevantes, la gestión del sobreajuste y la validación rigurosa. No existe una solución única, y la investigación se centra en adaptar y mejorar continuamente los modelos para contextos agrícolas específicos.

La integración de datos provenientes de modelos NWP con otras fuentes de información relevantes para la agricultura (datos históricos de rendimiento de cultivos, características del suelo, datos de sensores remotos, prácticas de manejo agrícola, etc.) en los modelos de IA tiene el potencial de generar predicciones aún más precisas y holísticas. La combinación de diversas fuentes de datos permite a la IA capturar una imagen más completa y detallada de los factores que influyen en la producción agrícola.

Referencias

- Engle, R., Mustafa, C., & Rice, J. (1992). "Modelling peak electricity demand. J. Forecast, vol. 11, pp. 241-251, .
- Erdem, E., & Shi, J. (2011). ARMA based approaches for forecasting the tuple of wind speed and direction. Appl. Energy, vol. 88, pp. 1405-1414, .
- Hu, X., Szerlip, P., Karaletsos, T., & Singh, R. (2019). Applying SVGD to Bayesian Neural Networks for Cyclical Time-Series Prediction and Inference, . arxiv., (1), 1–5. <http://arxiv.org/abs/1901.05906>.
- Huang, R., Huang, T., Gadh, R., & Li, N. (2012). "Solar generation prediction using the ARMA model in a laboratory-level micro-grid,". IEEE Third International Conference on, . 528-533.
- Kim, T., Lee, S., & Sohn, S. (2019). Graph convolutional network approach applied to predict hourly bike-sharing demands considering spatial, temporal, and global effects. Plos One, 14(9), 1–17. <https://doi.org/10.1371/journal.pone.0220782>.
- Lynch, P. (2008.). The origins of computer weather prediction and climate modeling,". Journal of Computational Physics, vol. 227, pp. 3431-3444, .
- Mandal, P., Senjyu, T., Urasaki, N., & Funabashi, T. (2006). A neural network based severalhour-ahead electric load forecasting using similar days approach. Electrical Power & Energy Systems, <https://www.sciencedirect.com/science/article/abs/pii/S0142061506000275>.
- Poorzaker, S., & Ebrahimpour, H. (2019). The Improvement of Forecasting ATMs Cash Demand of Iran Banking Network Using Convolutional Neural Network. Arabian Journal for Science and Engineering, , 44(4), 3733–3743. <https://doi.org/10.1007/s13369-018-3647-7>.
- Rezaie, M. (2022). Model parameters estimation of the proton exchange membrane fuel cell by a Modified Golden Jackal Optimization, Sustain53. Energy Technol. Assessments, 102657. <https://www.sciencedirect.com/science/article/abs/pii/S2213138822007068>.
- Ruzic, S., & Vuckovic, A. .. (2003.). Weather sensitive method for short term load forecasting in electric power utility of Serbia," . Power Systems, IEEE Transactions on, vol. 18, pp. 1581-1586.
- Singh, A., Ibraheem, I., Khatoon S. Muazzam, M., & Chaturvedi, D. (2012). "Load forecasting techniques and methodologies: A review," in . International Conference Power, Control and Embedded Systems (ICPCES), 2012 2nd , 110. .

Vijai, P., & Bagavathi Sivakumar, P. (2018). Performance comparison of techniques for water demand forecasting. . *Procedia Computer Science*,, 143, 258–266.
<https://doi.org/10.1016/j.procs.2018.10.394>.

© 2025 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).