

## Aplicación de redes neuronales convuncionales (CNN) determinación de factores climatológicos del sector floricultor: Una revisión sistemática

*Application of conventional neural networks (CNN), determination of  
climatological factors in the flower sector: A systematic review*

DOI: [10.61210/kany.v2i3.123](https://doi.org/10.61210/kany.v2i3.123)

<sup>a</sup>Kenny Montalvo Morales<sup>1</sup>

[kmontalvo@unaat.edu.pe](mailto:kmontalvo@unaat.edu.pe)

<https://orcid.org/0000-0003-4403-4360>

<sup>b</sup>Jamir Ever Vilchez De la Cruz<sup>1</sup>

[72098358@unaat.edu.pe](mailto:72098358@unaat.edu.pe)

<https://orcid.org/0000-0002-6727-4861>

<sup>c</sup>Lesli Yata Franco<sup>1</sup>

[abcde@unaat.edu.pe](mailto:abcde@unaat.edu.pe)

<https://orcid.org/0000-0001-6797-6655>

<sup>d</sup>Laumer Tocto Yajahuanca<sup>1</sup>

[abcde@unaat.edu.pe](mailto:abcde@unaat.edu.pe)

<https://orcid.org/0009-0005-9720-9146>

<sup>1</sup>Universidad Nacional Autónoma Altoandina de Tarma, Junín, Perú.

Recibido: Setiembre, 2024

Aceptado: Noviembre, 2024

Publicado: Diciembre, 2024

### RESUMEN

El uso de redes neuronales convuncionales (RNC) se ha convertido en una herramienta clave para el control y la predicción de factores climatológicos que afectan significativamente a la floricultura. Este sector, altamente dependiente de condiciones ambientales específicas, enfrenta retos importantes para garantizar una producción eficiente y sostenible. La presente revisión sistemática siguió los procedimientos establecidos por el enfoque PRISMA, empleando la metodología PIO (Población, Intervención y Resultados) para analizar investigaciones relevantes y proporcionar un panorama integral de las aplicaciones de las RNC en este ámbito. El objetivo principal fue identificar cómo las RNC se están utilizando para modelar y optimizar variables climáticas como la temperatura, la humedad, la radiación solar y el viento, factores cruciales en el desarrollo de cultivos florícolas. Los hallazgos destacan que las RNC son capaces de interpretar relaciones complejas entre estas variables y la productividad, permitiendo la toma de decisiones más precisas y la implementación de estrategias automatizadas. Su uso en invernaderos y sistemas controlados demuestra mejoras significativas en la eficiencia de los procesos pre y postproductivos, así como en la calidad final de las flores. Entre los principales resultados se evidencia un creciente interés por integrar estas tecnologías en la floricultura de precisión, aunque se identifican importantes limitaciones, como la necesidad de datos de alta calidad, el acceso desigual a tecnologías avanzadas y la escasa adopción en regiones de bajos recursos. La revisión también resalta oportunidades futuras, como el desarrollo de modelos híbridos que combinen RNC con redes neuronales profundas, así como la validación de estas tecnologías en escenarios de estrés ambiental y cambios climáticos extremos. Finalmente, la revisión examina el estado actual de las aplicaciones de las RNC en la floricultura, destacando sus beneficios y limitaciones, y propone líneas de investigación orientadas a la mejora de su implementación y la sostenibilidad del sector.

**Palabras clave:** *redes neuronales convolucionales, control clima, flores, inteligencia artificial, factores climatológicos.*

### ABSTRACT

The use of conventional neural networks (CNN) has become a key tool for the control and prediction of climatic factors that significantly affect floriculture. This sector, highly dependent on specific environmental conditions, faces important challenges to ensure efficient and sustainable production. The present systematic review followed the procedures established by the PRISMA approach, using the PIO (Population, Intervention, and Outcomes) methodology to analyze relevant research and provide a comprehensive overview of CNN applications in this field. The main objective was to identify how CNNs are being used to model and optimize climatic variables such as temperature, humidity, solar radiation and wind, crucial factors in the development of floriculture crops. The findings highlight that CNNs are capable of interpreting complex relationships between these variables and productivity, allowing for more accurate decision making and the implementation of automated strategies. Their use in greenhouses and controlled systems demonstrates significant improvements in the efficiency of pre- and post-production processes, as well as in the final quality of flowers. The main results show a growing interest in integrating these technologies into precision floriculture, although important limitations are identified, such as the need for high-quality data, unequal access to advanced technologies and low adoption in low-resource regions. The review also highlights future opportunities, such as the development of hybrid models that combine NCN with deep neural networks, as well as the validation of these technologies in scenarios of environmental stress and extreme climate change. Finally, the review examines the current state of NCN applications in floriculture, highlighting their benefits and limitations, and proposes lines of research aimed at improving their implementation and the sustainability of the sector.

**Keywords:** *convolutional neural networks, weather control, flowers, artificial intelligence, climatological factors*

## INTRODUCCIÓN

En el panorama de la Cuarta Revolución Industrial, conocida como Industria 4.0, el sector agroindustrial ha comenzado a experimentar una transformación significativa, impulsada por la adopción de tecnologías digitales avanzadas como las redes neuronales convolucionales (CNN), inteligencia artificial (IA) y sistemas automatizados (Schwab, 2017). Estas tecnologías están diseñadas para abordar desafíos relacionados con la variabilidad climática, el monitoreo de cultivos y la optimización de procesos, factores esenciales para la sostenibilidad y productividad del sector (Kunkel et al., 2023)

La floricultura, un componente clave del agro, enfrenta retos críticos debido a su dependencia de condiciones ambientales específicas, como la temperatura, la humedad y la radiación solar. En este contexto, las CNN han emergido como una solución prometedora para modelar, predecir y controlar factores climatológicos que afectan directamente la calidad y el rendimiento de las flores (Chandel et al., 2022). Estas redes, basadas en arquitecturas de aprendizaje profundo, destacan por su capacidad para procesar datos complejos de múltiples fuentes, incluyendo sensores, imágenes satelitales y sistemas IoT (Apacionado & Ahamed, 2024).

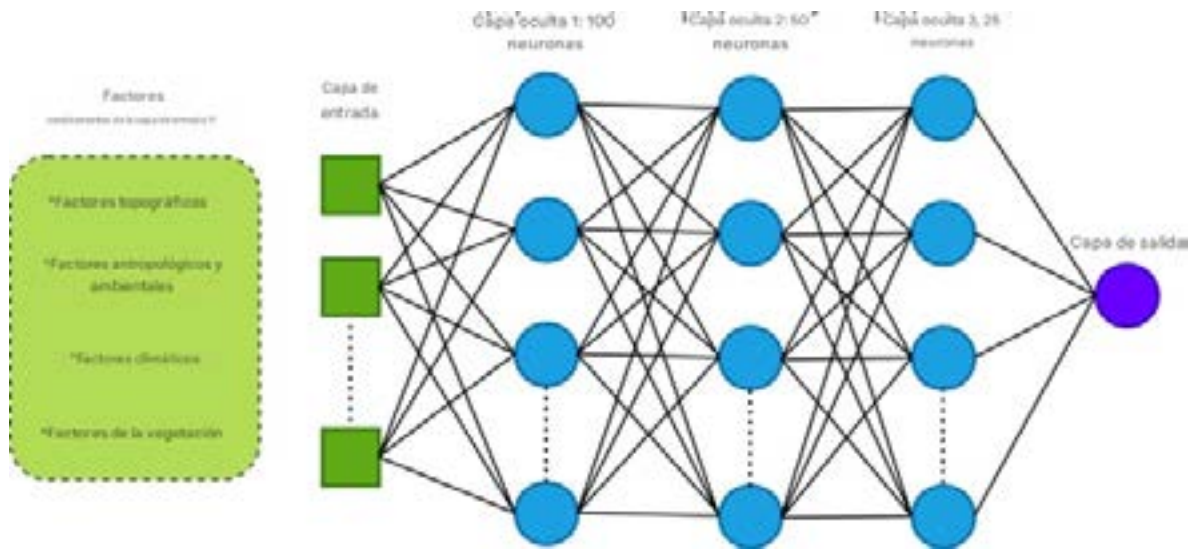
Además, la integración de las CNN en sistemas de invernaderos inteligentes ha demostrado mejoras significativas en la eficiencia de los procesos de producción, reducción de costos y sostenibilidad ambiental. Estas tecnologías permiten implementar estrategias automatizadas para el control del clima y el manejo de recursos hídricos, lo cual es crucial en regiones con limitaciones tecnológicas y acceso desigual a innovaciones agrícolas (Geetha et al., 2024); (Chen et al., 2024)

Sin embargo, la implementación de estas tecnologías no está exenta de desafíos. Factores como la falta de datasets de alta calidad, la necesidad de personal capacitado y las barreras económicas limitan su adopción en países en vías de desarrollo. Por ello, investigaciones recientes proponen el desarrollo de modelos híbridos que combinen CNN con redes neuronales profundas y técnicas de big data para mejorar la precisión y escalabilidad de estas herramientas (Asbaş & Tuzlukaya, 2024)

En este contexto, el presente trabajo tiene como objetivo realizar una Revisión Sistemática de la Literatura (RSL) sobre el uso de CNN en la determinación de factores climatológicos en la floricultura. Se busca proporcionar un análisis integral que identifique las aplicaciones actuales, sus beneficios y limitaciones, así como explorar oportunidades futuras para la implementación de estas tecnologías en el marco de la floricultura de precisión. Este enfoque no solo promueve la sostenibilidad del sector, sino que también contribuye a mitigar los efectos adversos del cambio climático y la variabilidad ambiental (muralikrishna, 2024).

**Figura 1**

Secuencia de adquisición de data en una CNN. Adaptado de (Gürsoy et al., 2023a)



**METODOLOGÍA**

**Tipo de investigación**

El estudio de revisión sistemática se llevó a cabo en Noviembre del año 2024 bajo las normativa de la declaración PRISMA para una correcta revisión sistemática (Page et al., 2021).

**Diseño de investigación**

Las principales fuentes y bases de datos consideradas en la revisión sistemática fueron: Science Direct, Scopus , Google académico, Redalyc, PudMed y Scielo,. En la determinar las palabras claves se empleó la estrategia PIO (Población, Intervención, Outputs), el cual permitió identificar los términos de búsqueda clave.

**Población:** La población de estudio fueron flores ornamentales cultivadas en (invernaderos y campos abiertos) con enfoque de la determinación de factores climáticos.

**Intervención:** Se investigaron el uso de redes neuronales convuncionales (CNN), aprendizaje automatizado y técnicas de análisis de datos climáticos, modelos algoritmos de predicción por factores climáticos.

**Outputs:** Determinación e impacto de la aplicación de CNN en la predicción precisa de factores como temperatura, humedad y radicación solar, y su relación con la productividad y calidad del sector floricultor.

**Tabla 1.**

Aplicación de la estrategia PIO, para determinar las ecuaciones de búsqueda.

PIO Category	Keywords
Population	“ornamental flowers”, “floriculture”, “ornamental plants”, “flower crops”
Intervention	“convolutional neural networks”, “CNN”, “deep learning”, “artificial intelligence”, “ climate modeling”
Outputs	“climatic factor prediction”, “temperature monitoring”, “humidity prediction”, “radiation prediction”, “crop quality improvement”

Antes de proceder con la selección de artículos se determinaron los criterios de inclusión y exclusión.

### Figura 2

Metodología de investigación y selección de artículos



### Criterios de inclusión

- Tratarse de investigaciones publicadas en idioma inglés, español y portugués.
- Que trate de la determinación de CNN en la producción de flores
- Artículos científicos de no menos de 5 años de publicación.

### Criterios de exclusión

- Artículos que no tienen relación con el tema de estudio.
- Artículos que se refieren a temas psicológicos y políticos.
- Los que no hablan sobre las redes neuronales convuncionales.
- Resúmenes de congreso, revisiones sistemáticas, artículos meta analíticos, artículos de opinión, trabajos duplicados.

### Población de estudio

La combinación de términos empleados en la búsqueda se evidencia en la tabla siguiente, se nos permitió seleccionar un total de 513 artículos científicos encontrados en la base de datos (Science Direct, Scopus , Google académico, Redalyc, PudMed y Scielo), las cuales contribuyeron a la fundamentación y sustento teórico.

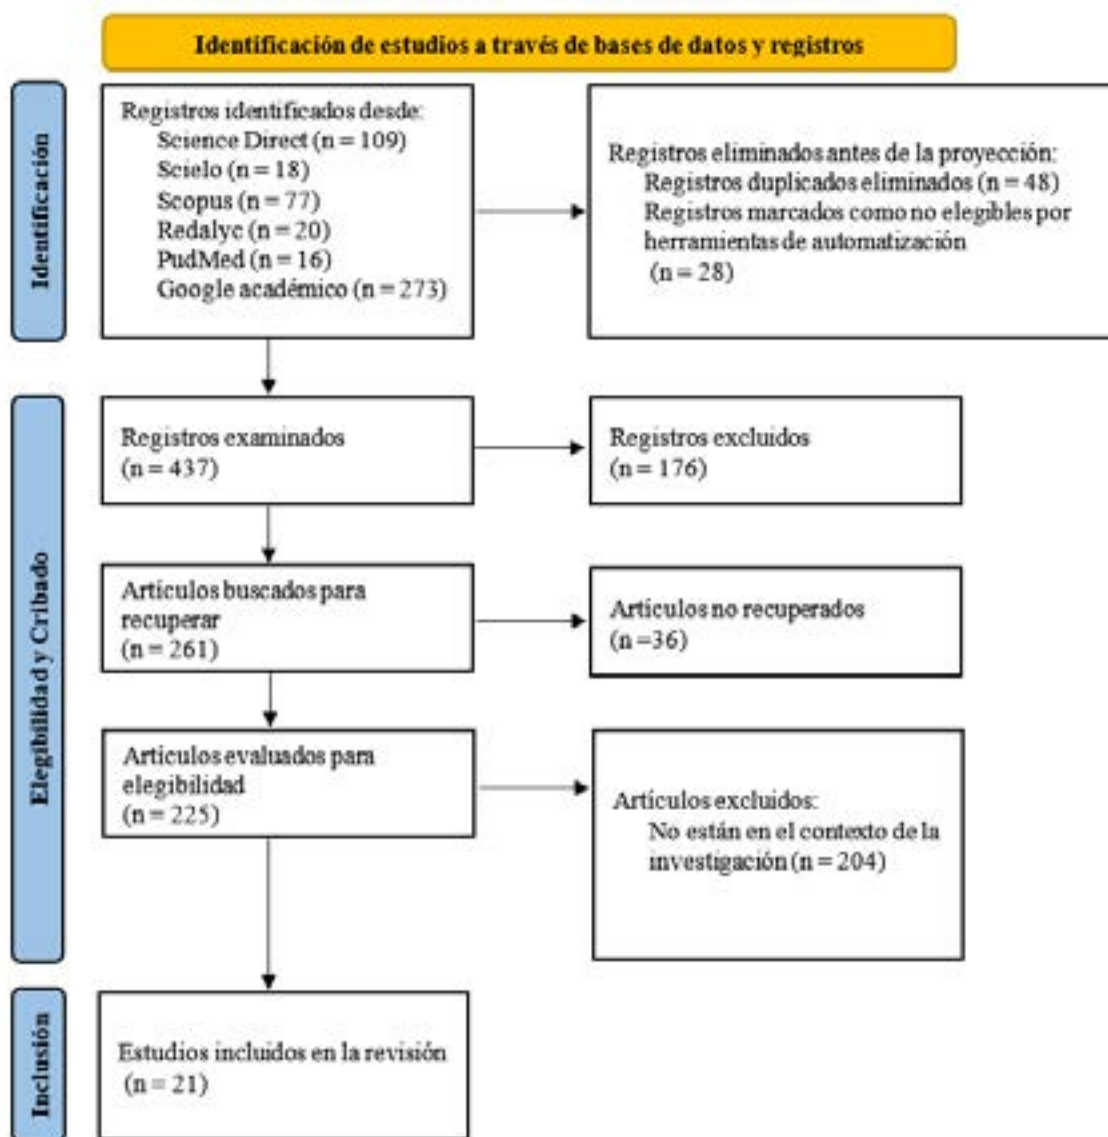
Base de Datos	Keywords	Ecuación de búsqueda avanzada	Nº de artículos
Scopus	Convolutional neural networks climate control	(TITLE-ABS-KEY (convolutional neural networks) AND TITLE-ABS-KEY (climatic AND factors)) AND PUBYEAR > 2018 AND PUBYEAR < 2025	77
Science Direct	Convolutional neural network Climatic factors	convolutional neural networksTitle, abstract, keywords:climatic factors	109
Scielo	Convolutional neural networksartificial intelligence	((convolutional neural networks) AND (artificial intelligence))	18
Google academico	Convolutional neural networks weather control flowers artificial intelligence climatological factors ornamental flowers CNN CNN	Con todas las palabras:convolutio- nal neural networks weather control flowers artificial intelligence clima- tological factors ornamental flowers . Con la frase exacta :CNN, Con la menos una de las palabras cli- matic factor temperature monitoring fecha entre 2019-2024	273
Redalyc	Convolutional Neural Networks	“Convolutional Neural Networks”site:redalyc.org	20
PubMed	Convolutional neural networks weather control flowers artificial intelligence climatological factors ornamental flowers CNN CNN climatic OR factor OR temperature OR monitoring	Buscar: control del clima flores inte- ligencia artificial factores climatoló- gicos CNN CNN climático OR factor OR temperatura OR monitoreo redes neuronales convolucionales Filtros: en los últimos 5 años, Artículo Clási- co Ordenar por: Revista	16

### Técnica de recolección de datos

En la figura 3 se detalla el proceso de selección de los artículos, mediante un diagrama de flujo:

**Figura 3**

Proceso de selección de artículos empleando la metodología PRISMA.



## RESULTADOS Y DISCUSIÓN

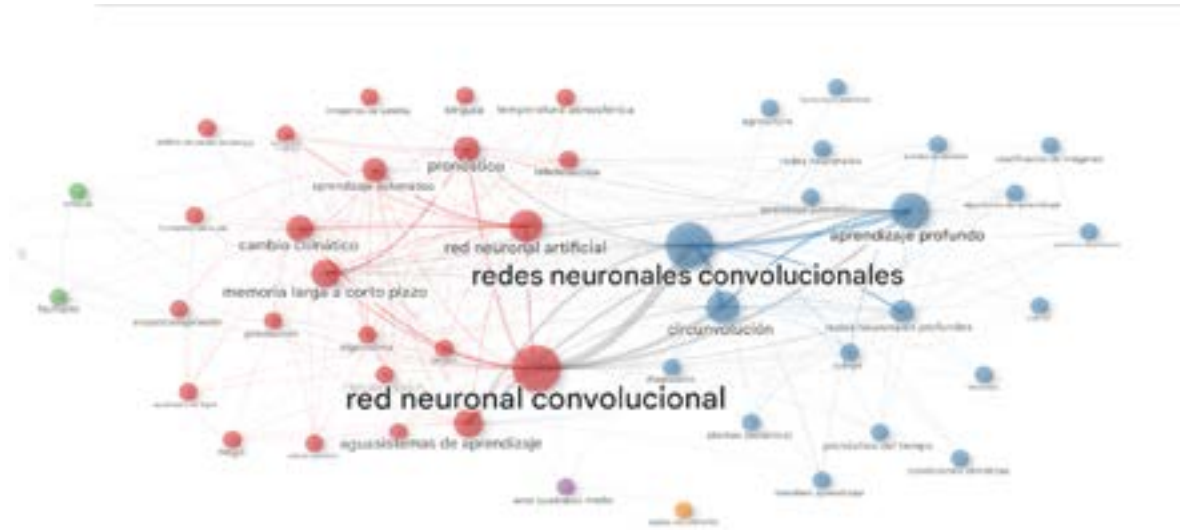
### Análisis cualitativo y extracción de datos

La ecuación de búsqueda permitió encontrar un total de 513 documentos. Una vez identificadas todas las publicaciones, se realizó una preselección considerando el tema. Todos los resultados de búsqueda se exportaron en formato bibliotex y se subieron al programa Rstudio, el cual permitió visualizar las temáticas de estudio. El análisis por palabras clave permitió establecer las áreas temáticas de las investigaciones (Figura 3). Con ello fue posible identificar los floricultura y redes neuronales. Se consideró las publicaciones realizadas año tras año desde el 2019 hasta el 2024. La línea roja representa la producción científica total sin duplicados, mientras que la línea azul indica el número de citas recibidas cada año.



**Figura 3**

Visualización de red neuronal por palabras claves obtenida de Rstudio



**CNN en el control de factores ambientales**

Las redes neuronales convolucionales (CNN) han demostrado ser herramientas efectivas para el control de factores ambientales en la agricultura, particularmente en el manejo de variables climáticas en invernaderos y cultivos. En un estudio reciente de Maheswar et al. (2024), se destacó que las CNN son capaces de integrar datos de temperatura, humedad y luz para predecir las necesidades de ajuste en los sistemas de control de invernaderos, mejorando la eficiencia del uso de recursos y optimizando el crecimiento de las plantas. Estas redes, al aprender patrones complejos a partir de grandes volúmenes de datos, permiten una predicción precisa de condiciones climáticas adversas, lo que facilita la automatización del control de factores como la ventilación y el riego.

La capacidad de las CNN para procesar imágenes también ha sido explotada para monitorear las condiciones del cultivo en tiempo real. Según Sakka y Ivanovici (2024), las CNN pueden analizar imágenes de plantas para identificar signos de estrés o enfermedades, lo que permite ajustar inmediatamente las condiciones climáticas dentro de un invernadero para evitar daños en las plantas.

**CNN y aplicaciones en la floricultura**

En el sector florícola, las Redes Neuronales Convolucionales (CNN) han demostrado ser herramientas eficaces para mejorar el monitoreo y control de factores que afectan la producción, como plagas y las condiciones del suelo. En un estudio de Sango et al. (2021), se emplearon CNN para analizar imágenes obtenidas de las rosas de la variedad Freedom, con el objetivo de identificar plagas y prevenir pérdidas económicas. Los resultados mostraron que las CNN pueden identificar de manera precisa los tipos de plagas que afectan las rosas,

como plagas en las hojas, tallos y botones foliares, facilitando la implementación de medidas correctivas como la fumigación de manera eficiente y oportuna. Esta metodología, basada en el análisis de imágenes, resultó efectiva para el control de la calidad y la estabilidad de la producción de las rosas, mejorando el rendimiento y reduciendo las pérdidas económicas.

Por otro lado, el estudio de Scobar et al. (2021) mostró cómo las redes neuronales pueden ser utilizadas para analizar el estado del suelo en invernaderos, lo que es crucial para el éxito del cultivo de flores. Utilizando sensores y sistemas informáticos, el análisis de datos a través de CNN permitió evaluar si los suelos en los invernaderos de Cotopaxi eran aptos para el cultivo de rosas. Los resultados indicaron que las redes neuronales proporcionaron mediciones más estables y precisas respecto al estado del suelo, facilitando la toma de decisiones adecuadas para el mantenimiento y control de los suelos, lo que mejora las condiciones de cultivo y, en consecuencia, la calidad de las flores producidas.

### **CNN y sus miras a futuro**

A medida que la tecnología avanza, las aplicaciones de las CNN en la agricultura y la floricultura continúan evolucionando. Las Redes Neuronales Convolucionales (CNN) tienen un gran potencial para mejorar la gestión de invernaderos inteligentes. Un estudio de Zhang et al. (2020) demostró que el uso de IoT y CNN para la predicción climática en invernaderos mejora la precisión de las condiciones ambientales y permite ajustes para un crecimiento óptimo de las plantas. Esta tecnología también ayuda a controlar la variabilidad climática, ofreciendo una solución costo-efectiva y accesible para los productores.

Por otro lado, Maravedies (2022) resalta que la inteligencia artificial (IA) en invernaderos está optimizando el uso de recursos, controlando plagas y enfermedades, y mejorando la eficiencia en riego y fertilización. A pesar de los desafíos en costos y la brecha tecnológica, las aplicaciones de IA y CNN en la agricultura tienen un futuro prometedor, ofreciendo soluciones sostenibles y eficientes para la producción agrícola frente al cambio climático.



Título	Aplicación de la red neuronal	Beneficio	Conclusión	Citación
Spatial-Temporal Neural Network for Rice Field Classification from SAR Images	Clasificación de campos de arroz utilizando imágenes SAR mediante redes convolucionales y de memoria a largo plazo (ConvLSTM) para analizar características espaciales y temporales.	Alta precisión en la identificación de campos de cultivo incluso bajo condiciones climáticas adversas.	ConvLSTM-RFC permite una clasificación precisa y robusta de campos de arroz, ayudando en la gestión agrícola y la planificación estratégica ante desastres naturales.	(Chang et al., 2022)
Impact of climatic factors on the prediction of hydroelectric power generation: CNN-SVR	Predicción de generación hidroeléctrica basada en datos climáticos con una combinación híbrida de CNN y soporte vectorial de regresión (SVR).	Mejora la precisión de predicciones a partir de factores climáticos y mejora la eficiencia energética.	La combinación CNN-SVR proporciona predicciones precisas, asegurando una mejor planificación y manejo de recursos hidroeléctricos bajo condiciones climáticas variables.	(Özbay Karakus, 2023)
Modeling Chickpea Productivity with Artificial Image Objects and Convolutional Neural Network	Uso de redes neuronales convolucionales (CNN) para modelar la productividad de garbanzos basándose en datos artificiales de imágenes.	Permite estimaciones precisas de la productividad de cultivos, facilitando decisiones agrícolas optimizadas.	CNN ayuda a modelar la productividad de cultivos con alta precisión, apoyando una planificación eficiente en la agricultura.	(Bankin et al., 2024)
Predicting Gross Primary Productivity under Future Climate Change for the Tibetan Plateau	Predicción de la productividad primaria bruta (GPP) utilizando CNN para analizar los efectos de futuros cambios climáticos en el Tibet.	Ayuda a prever impactos del cambio climático en la productividad primaria, facilitando la conservación ambiental.	Las CNN ofrecen una herramienta eficaz para modelar los efectos del cambio climático en los ecosistemas, proporcionando información clave para la gestión ambiental.	(Li et al., 2024)
Analyzing the Impact of Environmental Factors on Solar Power Output Using Explainable AI	Uso de redes neuronales explicables (CNN y técnicas deep learning) para analizar cómo los factores ambientales afectan la generación solar.	Proporciona una mejor comprensión de los factores que impactan la generación solar, optimizando su rendimiento.	Los modelos explicables basados en CNN mejoran la eficiencia operativa y el diseño de sistemas solares al identificar influencias clave de factores ambientales.	(Salman et al., 2024)

Monthly climate prediction using deep CNN and LSTM	Predicción mensual del clima usando una combinación de CNN y memoria a largo plazo (LSTM).	Mejora las predicciones climáticas a mediano plazo, apoyando en la planificación estratégica.	La integración CNN-LSTM es eficaz para abordar la complejidad de predicciones climáticas, ofreciendo herramientas valiosas para la gestión de riesgos climáticos.  (Guo et al., 2024)
Solar irradiance forecasting models using machine learning and digital twin	Predicción de irradiancia solar mediante redes neuronales y gemelos digitales para optimizar el uso de energía solar.	Aumenta la eficiencia en sistemas fotovoltaicos mediante predicciones precisas de irradiancia.	Los modelos basados en aprendizaje automático y gemelos digitales permiten gestionar de manera eficiente sistemas de energía solar, incrementando su viabilidad económica y energética.  (Sehrawat et al., 2023)
Estimation of surface soil moisture with SEM-ANN	Estimación de humedad superficial del suelo combinando modelos de ecuaciones estructurales (SEM) y redes neuronales artificiales (ANN).	Permite evaluaciones precisas de humedad del suelo para aplicaciones agrícolas y ambientales.	La combinación SEM-ANN mejora la precisión de las estimaciones de humedad del suelo, apoyando en la gestión hídrica y agrícola.  (Wang et al., 2023)
Creation of wildfire susceptibility maps using CNN and MLP	Creación de mapas de susceptibilidad a incendios en regiones mediterráneas utilizando CNN y perceptrones multicapa (MLP).	Mejora la predicción de zonas vulnerables a incendios forestales, apoyando la gestión de riesgos.	Las CNN y MLP son herramientas eficaces para identificar áreas susceptibles a incendios forestales, promoviendo estrategias de mitigación y prevención.  (Gürsoy et al., 2023b)
Solar photovoltaic power prediction using ANN and regression	Predicción de la potencia fotovoltaica utilizando redes neuronales artificiales (ANN) y técnicas de regresión.	Optimiza la generación de energía solar mediante estimaciones precisas de potencia bajo condiciones ambientales diversas.	Los modelos ANN integrados con regresión mejoran la precisión de producción fotovoltaica, maximizando el uso de energía renovable.  (Keddouda et al., 2023)

<p>Multistep ahead prediction of temperature and humidity in solar greenhouse</p>	<p>Predicción de temperatura y humedad en invernaderos solares mediante modelos FAM-LSTM.</p>	<p>Mejora el control ambiental en invernaderos solares, optimizando la producción agrícola.</p>	<p>FAM-LSTM proporciona herramientas efectivas para la gestión ambiental precisa en sistemas agrícolas protegidos como los invernaderos.</p> <p>(Yang et al., 2023)</p>
<p>Global NDVI forecasting using DNN</p>	<p>Predicción global del índice de vegetación NDVI basada en temperatura, humedad del suelo y precipitación usando redes neuronales profundas (DNN).</p>	<p>Permite monitorear la salud de la vegetación global y prever impactos climáticos.</p>	<p>Los DNN ofrecen capacidades avanzadas para modelar índices de vegetación, facilitando la conservación y manejo de ecosistemas globales.</p> <p>(Fathollahi et al., 2024)</p>
<p>Assessment of climatic influences on net primary productivity</p>	<p>Evaluación de influencias climáticas sobre la productividad primaria neta (NPP) en gradientes de elevación usando redes neuronales profundas.</p>	<p>Apoya la evaluación de cómo los factores climáticos afectan ecosistemas en distintas elevaciones.</p>	<p>Las redes neuronales son esenciales para analizar complejas relaciones entre clima y productividad ecológica, informando esfuerzos de conservación y uso sostenible.</p> <p>(Mehmood et al., 2024)</p>

## CONCLUSIÓN

La revisión sistemática muestra que las redes neuronales convolucionales (CNN) están revolucionando el sector florícola al ofrecer soluciones avanzadas para predecir y controlar factores climatológicos esenciales. Estas tecnologías destacan por su capacidad para analizar grandes cantidades de datos, lo que permite automatizar y optimizar procesos en invernaderos y entornos controlados. Los resultados demuestran mejoras significativas en la eficiencia, la calidad de los cultivos y la sostenibilidad ambiental, especialmente cuando se aplican en sistemas de floricultura de precisión. No obstante, se identifican desafíos importantes, como la calidad y disponibilidad de los datos, las barreras económicas y la desigualdad tecnológica en regiones con menor acceso a estas herramientas. En este contexto, los modelos híbridos, que integran CNN con tecnologías como redes neuronales profundas y análisis de big data, surgen como una estrategia prometedora para superar estas limitaciones. Dado el impacto del cambio climático y la creciente demanda de producción sostenible, las aplicaciones de las CNN en la floricultura se posicionan como herramientas clave para abordar la variabilidad ambiental y fortalecer la resiliencia del sector. Es fundamental que futuras investigaciones se centren en desarrollar tecnologías más accesibles y en probar estas metodologías en escenarios de estrés climático, para garantizar su implementación efectiva y equitativa.

Este trabajo contribuye a consolidar el conocimiento sobre el uso de las CNN en la floricultura, proporcionando una base para su incorporación en estrategias innovadoras que impulsen la sostenibilidad y competitividad de este sector en el mercado global.

## REFERENCIAS

- Apacionado, B. V., & Ahamed, T. (2024). Digital Transformation of Horticultural Crop Production Systems Toward Sustainable Agricultural Productivity. *IoT and AI in Agriculture*, 199–227. [https://doi.org/10.1007/978-981-97-1263-2\\_13](https://doi.org/10.1007/978-981-97-1263-2_13)
- Asbaş, C., & Tuzlukaya, Ş. E. (2024). The New Agricultural Revolution: Agriculture 4.0 and Artificial Intelligence Applications in Agriculture, Forestry, and Fishery. <https://Services.Igi-Global.Com/Resolvedoi/Resolve.aspx?Doi=10.4018/979-8-3693-3498-0.Ch012>, 265–291. <https://doi.org/10.4018/979-8-3693-3498-0.CH012>
- Bankin, M., Tyrykin, Y., Duk, M., Samsonova, M., & Kozlov, K. (2024). Modeling Chickpea Productivity with Artificial Image Objects and Convolutional Neural Network. *Plants*, 13(17), 2444. <https://doi.org/10.3390/PLANTS13172444/S1>
- Chandel, N. S., Rajwade, Y. A., Dubey, K., Chandel, A. K., Subeesh, A., & Tiwari, M. K. (2022). Water Stress Identification of Winter Wheat Crop with State-of-the-Art AI

- Techniques and High-Resolution Thermal-RGB Imagery. *Plants* 2022, Vol. 11, Page 3344, 11(23), 3344. <https://doi.org/10.3390/PLANTS11233344>
- Chang, Y.-L., Tan, T.-H., Chen, T.-H., Chuah, J. H., Chang, L., Wu, M.-C., Tatini, N. B., Ma, S.-C., & Alkhaleefah, M. (2022). Spatial-Temporal Neural Network for Rice Field Classification from SAR Images. *Remote Sensing*, 14(8). <https://doi.org/10.3390/rs14081929>
- Chen, C. Y. T., Lin, Y. B., Chen, W. L., Wu, K. C., Lin, Y. W., Sun, E. W., & Liu, C. Y. (2024). CWT IoT Device for Detecting Rare Events of Orchid Disease. *IEEE Internet of Things Journal*, 11(12), 22830–22842. <https://doi.org/10.1109/JIOT.2024.3383832>
- Fathollahi, L., Wu, F., Melaki, R., Jamshidi, P., & Sarwar, S. (2024). Global Normalized Difference Vegetation Index forecasting from air temperature, soil moisture and precipitation using a deep neural network. *Applied Computing and Geosciences*, 23, 100174. <https://doi.org/10.1016/J.ACAGS.2024.100174>
- Geetha, T. S., Chellaswamy, C., Raja, E., & Venkatachalam, K. (2024). Deep learning for river water quality monitoring: a CNN-BiLSTM approach along the Kaveri River. *Sustainable Water Resources Management*, 10(3), 1–15. <https://doi.org/10.1007/S40899-024-01102-6/METRICS>
- Guo, Q., He, Z., & Wang, Z. (2024). Monthly climate prediction using deep convolutional neural network and long short-term memory. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-68906-6>
- Gürsoy, M. İ., Orhan, O., & Tekin, S. (2023a). Creation of wildfire susceptibility maps in the Mediterranean Region (Turkey) using convolutional neural networks and multilayer perceptron techniques. *Forest Ecology and Management*, 538, 121006. <https://doi.org/10.1016/J.FORECO.2023.121006>
- Gürsoy, M. İ., Orhan, O., & Tekin, S. (2023b). Creation of wildfire susceptibility maps in the Mediterranean Region (Turkey) using convolutional neural networks and multilayer perceptron techniques. *Forest Ecology and Management*, 538, 121006. <https://doi.org/10.1016/J.FORECO.2023.121006>
- Keddouda, A., Ihaddadene, R., Boukhari, A., Atia, A., Arıcı, M., Lebbihiat, N., & Ihaddadene, N. (2023). Solar photovoltaic power prediction using artificial neural network and multiple regression considering ambient and operating conditions. *Energy Conversion and Management*, 288, 117186. <https://doi.org/10.1016/J.ENCONMAN.2023.117186>
- Kunkel, S., Neuhäusler, P., Matthess, M., & Dachrodt, M. F. (2023). Industry 4.0 and energy in manufacturing sectors in China. *Renewable and Sustainable Energy Reviews*, 188, 113712. <https://doi.org/10.1016/J.RSER.2023.113712>

- Li, M., Zhu, Z., Ren, W., & Wang, Y. (2024). Predicting Gross Primary Productivity under Future Climate Change for the Tibetan Plateau Based on Convolutional Neural Networks. *Remote Sensing*, 16(19). <https://doi.org/10.3390/rs16193723>
- Mehmood, K., Anees, S. A., Rehman, A., Rehman, N. U., Muhammad, S., Shahzad, F., Liu, Q., Alharbi, S. A., Alfarraj, S., Ansari, M. J., & Khan, W. R. (2024). Assessment of climatic influences on net primary productivity along elevation gradients in temperate ecoregions. *Trees, Forests and People*, 18, 100657. <https://doi.org/10.1016/J.TFP.2024.100657>
- muralikrishna, bala. (2024). Classification and Prediction of Plant Diseases Based on AI. <https://papers.ssrn.com/abstract=4756814>
- Özbay Karakuş, M. (2023). Impact of climatic factors on the prediction of hydroelectric power generation: a deep CNN-SVR approach. *Geocarto International*, 38(1). <https://doi.org/10.1080/10106049.2023.2253203>
- Salman, D., Elmi, Y. K., Isak, A. M., & Siyad, A. A. (2024). Analyzing the Impact of Environmental Factors on Solar Power Output Using Explainable Deep Learning Techniques. *SSRG International Journal of Electronics and Communication Engineering*, 11(10), 119–134. <https://doi.org/10.14445/23488549/IJECE-V11I10P110>
- Schwab, Klaus. (2017). The fourth industrial revolution. 184. <https://www.penguin.co.uk/books/304971/the-fourth-industrial-revolution-by-schwab-klaus/9780241300756>
- Sehrawat, N., Vashisht, S., & Singh, A. (2023). Solar irradiance forecasting models using machine learning techniques and digital twin: A case study with comparison. *International Journal of Intelligent Networks*, 4, 90–102. <https://doi.org/10.1016/J.IJIN.2023.04.001>
- Wang, S., Li, R., Wu, Y., & Wang, W. (2023). Estimation of surface soil moisture by combining a structural equation model and an artificial neural network (SEM-ANN). *Science of The Total Environment*, 876, 162558. <https://doi.org/10.1016/J.SCITOTENV.2023.162558>
- Yang, Y., Gao, P., Sun, Z., Wang, H., Lu, M., Liu, Y., & Hu, J. (2023). Multistep ahead prediction of temperature and humidity in solar greenhouse based on FAM-LSTM model. *Computers and Electronics in Agriculture*, 213, 108261. <https://doi.org/10.1016/J.COMPAG.2023.108261>