

(GAN) were analyzed in order to improve the spatial and temporal resolution of climate data. Both tools and techniques have proven to be effective in projects such as VALUE, which is in charge of evaluating downscaling methods in Europe, and DL4DS, a Python library in charge of applying deep learning algorithms to empirical downscaling of climate data. The main objective of this paper was to analyze the effectiveness of both tools and techniques focused on accuracy, scalability and computational efficiency, providing a complete overview of their use for the improvement of local weather forecasting.

Keywords: *climate model, weather forecasting, downscaling, General Circulation Models, Convolutional Neural Networks, Adversarial Generative Networks.*

Introducción

La predicción meteorológica representa una parte esencial para el funcionamiento del mundo moderno, debido a que, al tener exactitud en el clima, permitirá planificar actividades diarias sobre salir a pasear, realizar compras, deportes; para la agricultura tomar decisiones y planificar sobre qué momentos son los más adecuados para sembrar, cosechar y regar, en el transporte por los diferentes medios, ya sea terrestres, acuáticos, aéreos influye de manera decisiva para mantener una buena seguridad de todas las personas, evitando daños y pérdidas humanas y materiales. [1] También, el pronóstico específico del clima brinda información sobre cómo es el comportamiento de sistemas meteorológicos complejos, así como de la dinámica del cambio climático, aportando a una visión más compleja para el medioambiente.

La predicción meteorológica se conoce como el método científico de predecir el estado de la atmósfera basado en un determinado tiempo y lugar. Para ello se usa un enfoque cuantitativo que con el tiempo se ha ido perfeccionando, permitiendo obtener resultados de áreas limitadas; mediante la resolución de un complejo sistema de ecuaciones matemáticas no lineales basadas en modelos matemáticos específicos, La PNM usa algoritmos informáticos, con el fin de elaborar una previsión basada en las condiciones meteorológicas actuales. [2]

Esta predicción ha dependido desde sus inicios del sistema de la Predicción Numérica del Tiempo (NWP) el cual permite conocer los procesos que se dan en la atmósfera como el movimiento de las masas de aire, la energía en juego o los procesos termodinámicos implicados. Para su ejecución se consideran tres etapas bien marcadas, la primera es la asimilación de los datos, donde diariamente se registran en todo el mundo millones de datos meteorológicos de todo tipo; como segundo paso es que el modelo construye a partir de los datos, un estado inicial, significa que se asigna valores a cada 6 punto de la malla antes apuntada, para que a partir de ello el ordenador resuelva las ecuaciones y vaya calculando la evolución futura de variables como la presión, la temperatura o el viento, como resultado se obtiene el cálculo de una gigantesca matriz de números. El último paso es la transformación de esa matriz numérica, en los diferentes campos meteorológicos que tienen

a su disposición los meteorólogos [3]. A través del tiempo se han desarrollado diversos modelos, uno de los más importantes es el modelo de Investigación y Pronóstico del Tiempo (WRF), siendo uno de los modelos atmosféricos más usados en el mundo, esto debido a su gran resolución, precisión, naturaleza de código abierto, apoyo de la comunidad y sus diversas disciplinas. [2]

[4] La predicción del tiempo ha pasado a la era del Big Data gracias al progreso de los sistemas de observación climática como la observación satelital del clima, así como al rápido incremento en la cantidad de datos meteorológicos. Así pues, los modelos convencionales de inteligencia computacional no son idóneos para prever con exactitud el clima. De esa manera, se utilizan técnicas basadas en el aprendizaje profundo para manejar conjuntos de datos enormes que tienen la capacidad de aprender y realizar proyecciones de forma más eficaz basadas en datos anteriores.

En este artículo se describe y analiza las principales técnicas de aprendizaje profundo aplicadas a la predicción meteorológica, siendo el objetivo evaluar su efectividad para la mejora de la resolución espacial y temporal de las predicciones meteorológicas. Se explican algunos que otros tipos de predicciones meteorológicas. Se exponen los objetivos trazados, se revisan y analizan los trabajos más importantes junto con aportes de otros autores sobre el tema, el estudio se justifica con el fin de contar con pronósticos exactos a nivel local, buscando ofrecer una perspectiva completa de la capacidad de nuevas herramientas en la mejora de la predicción meteorológica, para lograr una mejor toma de decisiones y adaptarse a las condiciones del clima.

Tipos de Predicciones Meteorológicas

1. **Método Climatológico:** Este procedimiento ofrece un procedimiento para crear una predicción climática. Después de analizar los datos climáticos acumulados durante muchos años y realizar proyecciones, los meteorólogos emplean este procedimiento. [5]
2. **Método de Persistencia y Tendencia:** La persistencia y la inclinación demandan menos conocimientos para anticipar el tiempo, ya que se basan en tendencias anteriores. En todo el mundo, el tiempo es inalterable, al igual que la predicción climática para el día de hoy. Esto solo implica mantenerse actualizado sobre las temperaturas presentes y entender las condiciones climáticas de la región. [5]
3. **Mirando al Cielo:** Si bien es algo que puede sonar muy simple, este tipo de predicción ha ayudado a muchas personas durante largos años. Cuando observas el cielo, puedes establecer el tiempo observando el sol o la luna, o si observas nubes de gran altura. Si las nieblas han nublado, existe la posibilidad de que se genere un clima desagradable en un corto periodo. Para determinar cuándo la tempestad se aproxima, verifica si las nubes se desplazan o no. [5]

4. **Nowcasting:** Las proyecciones climáticas para las seis horas venideras se conocen frecuentemente como nowcasting. En este momento, se puede anticipar elementos pequeños, como tormentas individuales, con la exactitud necesaria, al igual que otras cosas que son demasiado pequeñas para que un ordenador pueda tratarlas.
5. **Use of Forecasting Models:** Los predictores humanos tenían la tarea de generar todo el tiempo que reflejaba los datos existentes. Actualmente, la información humana a menudo se restringe a la elección de modelos basándose en diversos límites, como la discriminación y el desempeño de los mismos. Emplea la concordancia de los modelos climáticos, junto con la inclusión de integrantes de una extensa variedad de especies, puede contribuir a reducir los errores ambientales. En cualquier situación, sin importar la sencillez del error en cualquier sistema individual, pueden surgir fallos significativos en cualquier corrección direccional particular en cualquier funcionamiento del modelo proporcionado. Las personas pueden emplear información acerca de resultados locales, que podrían ser muy reducidos en tamaño para ser resueltos por un modelo para su solución.

Materiales y métodos

En el presente trabajo, se realizó una revisión exhaustiva de la literatura existente sobre el uso de técnicas de aprendizaje profundo aplicadas a la predicción meteorológica. La metodología empleada incluyó las siguientes etapas:

1. **Selección de fuentes:** Se consultaron bases de datos académicas como IEEE Xplore, ScienceDirect, SpringerLink y Google Scholar para identificar artículos, revisiones y proyectos relevantes. Los criterios de búsqueda incluyeron palabras clave como "deep learning", "weather forecasting", "CNN", "GAN", y "downscaling".
2. **Criterios de inclusión y exclusión:** Se seleccionaron trabajos publicados entre 2015 y 2024 que abordaron el uso de redes neuronales en la mejora de predicciones climáticas, priorizando aquellos que reportan resultados cuantitativos sobre la eficacia de los métodos aplicados.
3. **Análisis comparativo:** Los artículos seleccionados fueron analizados y categorizados según las técnicas empleadas, la calidad de los resultados obtenidos, y las limitaciones identificadas por los autores.
4. **Estudio de casos:** Se revisaron proyectos como VALUE (Validating and Understanding Local-scale Environments) y el uso de la librería DL4DS (Deep Learning for Downscaling) para evaluar su aplicabilidad en diferentes contextos.

5. **Herramientas utilizadas:** Se emplearon herramientas computacionales como Python y librerías especializadas (TensorFlow, PyTorch y DL4DS) para analizar la estructura de los modelos y comprender su funcionamiento.

Esta metodología permitió recopilar información actualizada y relevante, identificando las principales ventajas y limitaciones de las técnicas estudiadas.

Técnicas y herramientas

1. **Downscaling:** El downscaling es un proceso utilizado para traducir proyecciones climáticas globales generadas por Modelos de Circulación General (MCG) a predicciones más detalladas y específicas a nivel regional o local. Existen dos tipos principales de downscaling: el dinámico, que utiliza modelos de alta resolución basados en leyes físicas, y el estadístico, que establece relaciones empíricas entre variables de gran escala y características locales. Este enfoque es crucial porque los MCG no capturan adecuadamente los fenómenos locales debido a su resolución limitada, lo que puede resultar en pronósticos menos precisos para regiones específicas [6]. Esto es crucial porque los MCG no capturan adecuadamente los fenómenos locales debido a su resolución limitada, lo que puede resultar en pronósticos menos precisos para regiones específicas [6]. Este enfoque es crucial para superar las limitaciones inherentes de los modelos globales que no capturan adecuadamente los fenómenos locales. Existen dos tipos principales de downscaling:
 - a) **Downscaling dinámico:** Utiliza modelos de alta resolución que incorporan leyes físicas para generar proyecciones detalladas. Se contemplan dos técnicas dinámicas de disminución de escala, que conllevan la utilización de la temperatura superficial o la lluvia simulada en el punto de cuadrícula más próximo en un modelo de circulación general (GCM) de aproximadamente 300 km de resolución, y un modelo climático regional (RCM) de 50 km anidado dentro del GCM.. [7]
 - b) **Downscaling estadístico:** Establece relaciones empíricas entre variables climáticas de gran escala y características locales, y es aquí donde técnicas como redes neuronales y aprendizaje profundo tienen un impacto significativo. El enfoque estadístico (STAT) se fundamenta en las relaciones lineales de regresión detectadas entre la temperatura superficial o la lluvia y un espectro de variables predictivas del clima. [7]
2. **Redes Neuronales Convolucionales (CNN):** Las Redes Neuronales Convolucionales (CNN, por sus siglas en inglés) son un tipo de red neuronal diseñada para procesar datos con estructuras de tipo rejilla, como imágenes o mapas climáticos [4]. Por ejemplo, un estudio reciente demostró que las CNN pueden mejorar significativamente la predicción de precipitaciones al capturar patrones espaciales complejos en datos climáticos históricos, permitiendo identificar fenómenos locales con mayor precisión [6]. Su principal

característica es la capacidad de extraer patrones espaciales mediante operaciones de convolución, lo que las hace ideales para mejorar la resolución espacial y temporal en la predicción meteorológica. Las CNN han demostrado su eficacia en la identificación de patrones complejos en grandes volúmenes de datos climáticos, facilitando predicciones más precisas y detalladas. En la predicción meteorológica, las CNN ayudan a reducir la pérdida de información durante el procesamiento, permitiendo un análisis más detallado de fenómenos atmosféricos específicos. [2]

3. **Redes Generativas Adversariales (GAN):** Las Redes Generativas Adversariales (GAN) son un enfoque innovador que consta de dos redes neuronales: una generadora y una discriminadora, que trabajan en conjunto para crear datos sintéticos altamente realistas [8]. En el contexto de la meteorología, las GAN se utilizan para generar datos climáticos que complementen conjuntos de datos insuficientes o para simular eventos extremos. Este enfoque ha sido especialmente útil para mejorar la representación de fenómenos locales y la resolución de los modelos climáticos, proporcionando una base de datos más robusta para la predicción de eventos meteorológicos complejos. Una investigación [9] centrada en la aplicación de una Red Generativa Adversaria, se enfocó en el uso de esta red para la predicción del clima meteorológico en EUROPA, entrenando simultáneamente el modelo con datos históricos durante 4 años (2015-2018) para su adecuada predicción. La investigación señala que los pronósticos demostraron un acuerdo cualitativo y cuantitativo adecuado con los datos reales proporcionados, además de que se evidencia que el modelo en relación a datos globales tiende a fallar más, pero cuando se presentan datos más específicos se logran mejores resultados.
4. **Librería DL4DS:** DL4DS (Deep Learning for Downscaling) es una librería de Python diseñada específicamente para aplicar algoritmos de aprendizaje profundo en el downscaling de datos climáticos [7]. Por ejemplo, en un estudio realizado en Europa, se utilizó DL4DS para mejorar la resolución de las predicciones de precipitaciones diarias, lo que resultó en una reducción significativa de errores al comparar con datos observados locales. Esta herramienta permite a los investigadores implementar modelos avanzados de manera eficiente, integrando funciones preconfiguradas para la mejora de la resolución espacial y temporal. DL4DS ha sido utilizada en diversos estudios para evaluar su impacto en la predicción climática a nivel local. Su uso facilita la aplicación de técnicas complejas sin la necesidad de construir modelos desde cero, lo que optimiza los recursos y acelera el análisis.




Figura 1. Arquitectura general de DL4DS. Se representa como se puede convertir un conjunto de datos de baja resolución en uno de alta resolución.

5. **TensorFlow:** TensorFlow es una plataforma de código abierto desarrollada por Google que permite construir y entrenar modelos de aprendizaje profundo de manera eficiente. En la predicción meteorológica, TensorFlow se utiliza para implementar redes neuronales avanzadas que analizan grandes volúmenes de datos climáticos, facilitando el desarrollo de modelos escalables y de alta precisión.
6. **PyTorch:** PyTorch, desarrollado por Facebook, es otra librería de aprendizaje profundo ampliamente utilizada debido a su flexibilidad y capacidad para realizar cálculos dinámicos. En el campo meteorológico, PyTorch se emplea para construir y optimizar redes neuronales complejas, incluyendo las mencionadas CNN y GAN, proporcionando herramientas para ajustar modelos de manera más intuitiva.
7. **Validación y Estudio de Entornos a Escala Local (Proyecto VALUE):** El proyecto VALUE (Validating and Understanding Local-scale Environments) se centra en la validación y comparación de métodos de downscaling estadístico en Europa [3]. Sus resultados han influido significativamente en la adaptación de estas metodologías para su aplicación en otras regiones, proporcionando un marco para estandarizar y mejorar las técnicas de predicción climática a nivel global. Este proyecto ha proporcionado un marco integral para evaluar cómo diferentes enfoques de reducción de escala, incluidos los basados en aprendizaje profundo, pueden mejorar la precisión de las predicciones climáticas regionales. VALUE ha

sido clave en la estandarización de técnicas y en la promoción de prácticas replicables en la investigación climática, ofreciendo una referencia confiable para el desarrollo de modelos en otras regiones del mundo.

Resultados y discusión

1. **Eficacia de las Redes Neuronales Convolucionales (CNN):** Las CNN han demostrado ser altamente efectivas en la mejora de la resolución espacial y temporal de los datos meteorológicos. Estudios como el de Stengel et al. [6] reportaron aumentos significativos en la precisión de los pronósticos al aplicar CNN al downscaling de datos climáticos. El estudio reciente de Jhonatan et al [10] demuestra que las redes neuronales convolucionales las cuales estan basadas en datos son mucho mas rapidas y eficaces a diferencia de otros modelos para la prediccion del clima, sugiriendo que el aprendizaje automático podría convertirse en un recurso útil para la predicción de grandes conjuntos. Estas redes optimizan la extracción de patrones espaciales, lo que resulta en un análisis más detallado de fenómenos locales.
2. **Aplicación de Redes Generativas Adversariales (GAN):** Las GAN han sido útiles para generar datos sintéticos que complementen conjuntos de datos existentes, mejorando la representación de fenómenos locales. Por ejemplo, el trabajo de Weyn et al. [11] destaca el uso de GAN para simular eventos meteorológicos extremos, permitiendo una mejor planificación frente a condiciones adversas.
3. **Integración de herramientas especializadas:** Librerías como DL4DS han facilitado la implementación de algoritmos avanzados de aprendizaje profundo, permitiendo realizar pruebas rápidas y eficientes en diferentes contextos geográficos y climáticos. Su integración reduce la complejidad técnica y acelera el proceso de experimentación.
4. **Limitaciones identificadas:** A pesar de los avances, persisten retos relacionados con el costo computacional y la interpretabilidad de los modelos. Además, la falta de estandarización en los datos de entrenamiento puede influir negativamente en la precisión de los resultados.

Conclusiones

A partir del análisis realizado, se concluye que:

1. **Impacto positivo del aprendizaje profundo:** Las técnicas de aprendizaje profundo, particularmente las CNN y las GAN, han transformado el campo de la predicción meteorológica, permitiendo superar las limitaciones de los métodos numéricos tradicionales.
2. **Avances en la resolución local:** La aplicación de métodos de downscaling asistidos por aprendizaje

profundo ha mejorado significativamente la precisión de los pronósticos a nivel local, lo cual es crucial para la toma de decisiones en sectores como la agricultura y la gestión de desastres.

3. **Retos pendientes:** Persiste la necesidad de abordar limitaciones como el alto costo computacional y la interpretabilidad de los modelos, así como de desarrollar estándares para el manejo de datos climáticos.

a) **Futuras líneas de investigación:** Se sugiere explorar la integración de modelos de aprendizaje profundo con enfoques híbridos que combinen técnicas tradicionales y modernas para mejorar aún más la capacidad predictiva.

Contribución de Autoría

Jose Luis Gutierrez Diaz: [Conceptualización](#), [Investigación](#), [Redacción - borrador original](#). Kevin Parimango Gómez: [Metodología](#), [Software](#). Marcelino Torres Villanueva: [Supervisión](#), [Escritura, revisión y edición](#).

Referencias

- [1] CEUPE, “Meteorología: qué es y su importancia,” <https://www.ceupe.com/blog/meteorologia-que-es-y-su-importancia.html>, n.d., accedido: 09-dic-2024.
- [2] H. S. Walia and M. Mahajan, “Automatic feature learning using neuro-fuzzy systems: a survey,” *Pattern Analysis and Applications*, vol. 23, no. 2, pp. 451–471, 2020. [Online]. Available: <https://link.springer.com/article/10.1007/s10044-020-00898-1>
- [3] J. M. Viñas Rubio, “Origen y desarrollos actuales de la predicción meteorológica,” *EM*, vol. 45, no. 2, pp. 1–20, n.d., accedido: 09-dic-2024.
- [4] K. U. Jaseena and B. C. Kovoov, “Deterministic weather forecasting models based on intelligent predictors: A survey,” *J. King Saud Univ. - Comput. Inf. Sci.*, 2020.
- [5] Anonymous, “A survey of weather forecasting based on machine learning and deep learning techniques,” *Int. J. Emerg. Trends Eng. Res.*, vol. 9, no. 7, pp. 988–993, 2021.
- [6] P. Bauer, A. Thorpe, and G. Brunet, “The quiet revolution of numerical weather prediction,” *Nature*, vol. 525, no. 7567, pp. 47–55, 2015.
- [7] J. Murphy, “Predictions of climate change over europe using statistical and dynamical downscaling techniques,” *Int. J. Climatol.*, vol. 20, no. 5, pp. 489–501, 2000.

- [8] K. Stengel, A. Glaws, D. Hettinger, and R. N. King, “Adversarial super-resolution of climatological wind and solar data,” *Proceedings of the National Academy of Sciences*, vol. 117, no. 29, pp. 16 805–16 815, 2020.
- [9] A. Bihlo, “A generative adversarial network approach to (ensemble) weather prediction,” *Neural Netw.*, vol. 139, pp. 1–16, 2021.
- [10] J. A. Weyn, D. R. Durran, and R. Caruana, “Improving data-driven global weather prediction using deep convolutional neural networks on a cubed sphere,” *J. Advances Model. Earth Syst.*, vol. 12, no. 9, 2020.
- [11] P. Lynch, “The origins of computer weather prediction and climate modeling,” *Journal of Computational Physics*, vol. 227, no. 7, pp. 3431–3444, 2008.