

Red Neuronal Convolutacional Multitarea para la Estimación Espacio-temporal de Precipitaciones en Regiones Andinas

Multitask Convolutional Neural Network for Spatiotemporal Precipitation Estimation in Andean Regions

Henry Rubiano¹   Miguel Barrios¹  Cristian Guevara¹ 

¹Laboratorio de Hidrología Computacional e Hidráulica, Universidad del Tolima, Ibagué, Colombia.

Resumen

Introducción: los andes colombianos presentan limitaciones para la estimación espacial de la precipitación, debido a la escasa instrumentación pluviométrica y la alta variabilidad influida por fenómenos como El Niño. Por ello se hace necesario desarrollar enfoques para fusionar datos de teledetección con observaciones terrestres y mejorar la modelación espaciotemporal de la lluvia.

Objetivos: Implementar un modelo de red neuronal convolutacional multitarea con arquitectura U-Net para estimar simultáneamente la probabilidad de lluvia (clasificación) y la tasa de precipitación (regresión), con resolución de 2 km y 10 minutos en una región andina.

Metodología: El estudio se realizó en la zona andina colombiana, usando datos pluviométricos, radar meteorológico, y satélite GOES-16. Se implementó una red neuronal convolutacional con arquitectura U-Net para estimar precipitaciones, con datos distribuidos en proporciones de 70%, 15%, y 15% para entrenamiento, validación y prueba, la evaluación del modelo se llevó a cabo con métricas de clasificación y regresión.

Resultados: El modelo presenta una eficiencia satisfactoria para la detección de eventos de lluvia, con un área bajo la curva ROC cercana a 0.8, demostrando una alta capacidad para clasificar el patrón espacial de su ocurrencia. En contraste, la red convolutacional tiene un inferior desempeño en la tarea de cuantificación de los milímetros de lluvia, con valores de correlación de Pearson del orden de 0.6 en entrenamiento y validación.

Conclusiones: El uso de redes neuronales convolucionales logra clasificaciones satisfactorias de los eventos de lluvia, sin embargo tiende a subestimar la tasa de precipitación en condiciones de información escasa.

Palabras clave: redes neuronal convolucionales; precipitación; modelación matemática; satélite; radar.

Abstract

Introduction: The Colombian Andes present limitations for spatial estimation of precipitation due to scarce rainfall instrumentation and high variability influenced by phenomena such as El Niño. Therefore, it is necessary to develop approaches to merge remote sensing data with terrestrial observations and improve the spatiotemporal modeling of precipitation.

Objectives: To implement a multitask convolutional neural network model with U-Net architecture to estimate rainfall probability (classification) and precipitation rate (regression), with a resolution of 2 km and 10 minutes in an Andean region of Colombia.

Methodology: The study was conducted in the Colombian Andean zone, using pluviometric data, meteorological radar, and GOES-16 satellite. A convolutional neural network with U-Net architecture was implemented to estimate precipitations, with data distributed in proportions of 70%, 15%, and 15% for training, validation, and testing. The model evaluation was carried out with classification and regression metrics.

Results: The model shows satisfactory efficiency for detecting rainfall events, with an area under the ROC curve close to 0.8, demonstrating a high capacity to classify the spatial pattern of its occurrence. In contrast, the convolutional network has lower performance in the task of quantifying rainfall millimeters, with Pearson correlation values on the order of 0.6 in training and validation.

Conclusions: The use of convolutional neural networks achieves satisfactory classifications of rainfall events; however, it tends to underestimate the precipitation rate under conditions of scarce information.

Keywords: convolutional neural networks; precipitation; mathematical modeling; satellite; radar.

¿Cómo citar?

Rubiano H, Barrios M, Guevara C. Red Neuronal Convolutacional Multitarea para la Estimación Espaciotemporal de Precipitaciones en Regiones Andinas. Ingeniería y Competitividad, 2026, 28(1)e-20515228

<https://doi.org/10.25100/iyv.v28i1.15228>

Recibido: 12/09/25

Revisado: 20/10/25

Aceptado: 21/01/26

Online: 18/02/26

Correspondencia

hgrubianos@ut.edu.co



¿Por qué se realizó?

El estudio se realizó para superar las limitaciones de la escasa instrumentación pluviométrica en los Andes colombianos, donde la baja densidad de estaciones y la alta variabilidad orográfica/debida al ENSO dificultan la estimación precisa de la precipitación espacial. El objetivo fue aprovechar los datos de teledetección (satélite GOES-16 y radar) fusionados con observaciones puntuales mediante aprendizaje profundo, generando reconstrucciones subhorarias (2 km/10 min) útiles para la modelización hidrológica, la predicción de eventos extremos y la gestión de los recursos hídricos en zonas vulnerables con infraestructura meteorológica limitada.


¿Cuáles fueron los resultados más relevantes?

El modelo logró un rendimiento satisfactorio en la tarea de clasificación (detección de lluvia/ausencia de lluvia), alcanzando un AUC $\approx$ 0,80, un POD de 0,80-0,85 y un FAR $\approx$ 0,21 en los conjuntos de validación y prueba. En contraste, la estimación cuantitativa de la precipitación fue notablemente más débil, con un RMSE $\approx$ 1,02–1,07 mm/10 min, un MAE $\approx$ 0,44–0,51 mm y un R² muy bajo (0,05–0,36), lo que muestra una subestimación sistemática de eventos intensos y una alta dispersión, lo que revela las dificultades de una arquitectura CNN pura para capturar dependencias temporales y magnitudes extremas.

¿Qué aportan?

El estudio demuestra que una U-Net multitarea puede detectar adecuadamente la ocurrencia espacial de la lluvia incluso con muy pocos pluviómetros, lo que proporciona un producto binario útil para la predicción inmediata y la alerta temprana en los Andes. Al mismo tiempo, expone claramente las limitaciones actuales de las CNN para la estimación cuantitativa precisa de la precipitación subhoraria en entornos con escasez de datos, lo que refuerza la necesidad de arquitecturas híbridas y una mayor densidad de pluviómetros para mejorar el rendimiento de la regresión. Ofrece un punto de referencia de diagnóstico realista y valioso para futuros desarrollos en regiones montañosas tropicales similares.

Resumen Gráfico



Introducción

Comprender la variabilidad espaciotemporal de la precipitación es fundamental para desarrollar herramientas de modelización y estrategias de gestión de recursos hídricos que apoyen la toma de decisiones para su uso y explotación sostenibles. Sin embargo, la estimación de precipitaciones espaciotemporales en el contexto andino está limitada por la insuficiente disponibilidad de estaciones pluviométricas (1). Esta escasez de datos es especialmente crítica en los estudios hidroclimáticos, especialmente en países en desarrollo que enfrentan altos costes asociados al establecimiento y mantenimiento de infraestructuras meteorológicas (2,3). En este contexto, la necesidad de generar alternativas para abordar la limitada disponibilidad de información pluviométrica ha aumentado debido a los avances en la implementación de algoritmos de aprendizaje automático y a la creciente disponibilidad de productos de teledetección para meteorología monitorización (4).

En los últimos años, se han aplicado diversos algoritmos de aprendizaje automático para estimar la precipitación combinando productos basados en satélites con observaciones de pluviómetros. Chen et al. (5) propusieron un enfoque de aprendizaje automático para generar estimaciones diarias de precipitación de alta resolución (1 km) combinando datos satelitales y observaciones terrestres. De manera similar, Zhang et al. (6) presentaron un enfoque de doble aprendizaje automático para fusionar múltiples productos de precipitación basados en satélites con observaciones de pluviómetros, logrando una reducción significativa del sesgo. Estos enfoques han capturado con éxito patrones no lineales complejos para la estimación de precipitaciones; sin embargo, las herramientas de aprendizaje automático apenas se han aplicado a la modelización de precipitaciones de alta resolución temporal (10 minutos) en áreas con instrumentación escasa, como la región andina.

En el campo del Aprendizaje Automático, las técnicas de Aprendizaje Profundo han cobrado relevancia debido a su capacidad para reconocer patrones no lineales y características complejas en grandes conjuntos de datos. Las Redes Neuronales Convolucionales (CNN) son especialmente eficaces en tareas como la clasificación de imágenes, el reconocimiento de objetos y el procesamiento de secuencias espaciotemporales, incluyendo la predicción meteorológica (7). En el contexto de la precipitación, las CNN se han utilizado para procesar y analizar imágenes satelitales y de radar, así como otros datos espaciales, identificando patrones complejos correlacionados con eventos de lluvia, como ciertas formaciones de nubes, sistemas de baja presión o frentes de tormenta (8–11).

El objetivo de este estudio es evaluar la capacidad de las CNN para reconstruir series temporales históricas de precipitación subhoraria (intervalos de 10 minutos) y reproducir el patrón espacial de ocurrencia de lluvias a una resolución de 2 km, utilizando una red multitarea entrenada con información meteorológica terrestre observada y sensores remotos (satélite y radar), en un contexto de escasa información pluviométrica. A través de esta investigación, se aporta conocimiento sobre el comportamiento y la variabilidad de las precipitaciones para apoyar procesos de análisis climatológico, hidrológico y meteorológico en regiones con baja densidad de pluómetros.

Materiales y métodos

Esta sección describe el área de estudio, las variables utilizadas para desarrollar el modelo de red neuronal convolutacional, el procesamiento de datos y los procedimientos aplicados para su configuración, entrenamiento y evaluación.

Ubicación

La zona andina colombiana es una región altamente susceptible a la variabilidad climática y sufre impactos significativos debido a la intensidad y frecuencia de eventos extremos como sequías e inundaciones. La ocurrencia de estos eventos está estrechamente relacionada con las fases cálida y fría del fenómeno El Niño, que muestra teleconexión con patrones climáticos locales (12,13). El área de estudio corresponde a la zona cubierta por el radar meteorológico de Múnich (RMM), situado en el municipio de El Tambo (departamento del Cauca), operando en un radio efectivo de 240 km con mediciones cada 5 a 10 minutos. Es un radar PPI (Indicador de Posición Plana) en banda C equipado con un receptor/procesador de doble polarización, lo que permite una mayor precisión para distinguir fenómenos meteorológicos y no meteorológicos (Ya me lo imagino. 1).

Dentro del área de influencia del radar, 85 estaciones automáticas proporcionan monitorización continua de la precipitación durante 10 minutos, de las cuales 58 están activas y libres de errores o inconsistencias. Según la Organización Meteorológica Mundial (14), en zonas montañosas la densidad mínima recomendada de estación es de 250 km² por estación convencional y 2.500 km² por estación automática. En cuanto al área de cobertura del RMM, la densidad es del orden de 7.200 km² por estación automática, reflejando una instrumentación activa muy escasa para el monitoreo de precipitaciones en la región.

Además, la distribución espacial de las estaciones disponibles muestra una mayor concentración en la zona central alrededor del RMM y en el sureste del área de influencia, lo que indica una monitorización más intensiva en estas zonas. En cambio, hay menos estaciones presentes en el noroeste de los departamentos de Nariño, Cauca y Valle del Cauca, así como en el sur de Chocó y Tolima, lo que pone de manifiesto la necesidad de desarrollar e implementar métodos para fusionar la información meteorológica de la red de pluviometría y los productos de teledetección (Ya me lo imagino. 1).




Figura 1. Ubicación del área de estudio y las estaciones automáticas de pluviometría utilizadas.

Datos de entrada

Los datos de entrada del modelo provienen de cuatro fuentes de información: imágenes satelitales, imágenes de radar, pluviómetros automáticos y un Modelo Digital de Elevación (DEM) (Tabla 1). La información satelital es proporcionada por el satélite operacional ambiental geoestacionario GOES-16, que ofrece una amplia cobertura de casi todo el hemisferio occidental, incluyendo Norteamérica, Central y Sudamérica, así como partes del Atlántico y el Pacífico en modo disco completo. Su Advanced Baseline Imager (ABI) proporciona imágenes de alta resolución espacial (2 km) y temporales (10 minutos). El ABI cuenta con 16 canales espectrales que abarcan desde el ultravioleta hasta el infrarrojo, mejorando la detección y monitorización de la formación y evolución de las nubes, la temperatura superficial del mar y la humedad atmosférica. Las bandas seleccionadas como variables de entrada para el modelo son: Banda 7 (3,9 μm) diseñada para identificar niebla y nubes bajas por la noche, Banda 8 (6,19 μm) diseñada para pronosticar trayectorias de huracanes y movimientos de tormentas en latitudes medias, y Banda 13 (10,3 μm) diseñada para mejorar las correcciones de humedad atmosférica y la identificación y clasificación de nubes. Las características operativas de estas bandas infrarrojas (IR) son propiedades importantes de las nubes precipitables (10).

Tabla 1. Variables de entrada del modelo

Variable	Unidad	Descripción
GOES 16 Banda 7	K	Infrarrojo de onda corta
GOES 16 Banda 8	K	Vapor de agua en niveles superiores
GOES 16 Banda 13	K	Ventana infrarroja limpia
Reflectividad	dBZ	Valor de reflectividad del radar
Distancia al radar	m	Distancia al radar
Precipitaciones	mm/10 min	Valor de precipitación de la estación
Ubicación del pluviometro.	Binario	Ubicación espacial de pluviómetros
Topografía	m	Elevación sobre el nivel del mar
Hora del día	Adimensional	Valor relativo de la hora

Los datos de radar corresponden a la reflectividad equivalente (Z), expresada en decibeles (dBZ), que representa la intensidad de la precipitación dentro del radio efectivo. Esta información fue proporcionada por el Instituto de Hidrología, Meteorología y Estudios Ambientales de Colombia (IDEAM), la entidad responsable de operar y mantener el instrumento. Además, la distancia al radar se consideraba como una variable predictiva, definida como la distancia desde cada celda de análisis hasta la ubicación exacta del radar, con el objetivo de tener en cuenta posibles efectos de curvatura de la Tierra en los límites del alcance efectivo.

La información de pluviometría se obtuvo de la red de monitoreo hidrometeorológico del IDEAM, que proporciona registros a escalas mensuales, diarias y sub-horarias. Para este estudio se utilizaron registros de 58 estaciones automáticas con mediciones de precipitación en 10 minutos. Dado que los pluviómetros proporcionan datos puntuales, la precipitación para cada celda de análisis se asignó según la proximidad al pluviómetro más cercano al centro de la celda, asignando un valor nulo a las celdas sin medidores disponibles. Además, se consideró una variable binaria que indica la presencia de pluviómetros, asignando 0 a celdas sin estaciones y 1 en caso contrario.

La topografía desempeña un papel fundamental en la distribución y cantidad de precipitación, influyendo significativamente en los patrones climáticos locales. Esta información la proporciona el Satélite Avanzado de Observación Terrestre (ALOS) de la Agencia Japonesa de Exploración Aeroespacial (JAXA), utilizando un sensor de radar de apertura sintética en banda L (PALSAR) que opera entre 14 y 28 MHz. Se implementó un DEM, corregido radiométricamente por el terreno, con una resolución espacial de 90 m para representar la elevación del terreno en cada celda.

Finalmente, se incorporó una variable adimensional para representar la hora del día, con el objetivo de analizar variaciones sistemáticas en los datos de radiación infrarroja que puedan producirse debido a cambios de temperatura superficial a lo largo del día (8). Para modelar la hora del día como una variable continua, se aplicó una transformación coseno, oscilando entre 1 a medianoche y 0 al mediodía. Los minutos transcurridos desde la medianoche se transforman en radianes, asignando valores proporcionalmente a lo largo de un ciclo completo de 2π correspondiente a

un día entero. Esta metodología es adecuada para estudios que requieren un examen preciso de patrones variables diurnos.

El periodo del 1 de febrero al 30 de abril de 2021 fue seleccionado como ventana de análisis, cubriendo un total de 12.816 pasos temporales representados como variables de entrada para el modelo. Esta elección permitió utilizar los datos más relevantes y precisos para evaluar la dinámica de las lluvias espaciotemporales en el estudio de caso.

Las capas de entrada a la red se proporcionaban como imágenes multiespectrales en formato TIF, con una extensión de 160×160 píxeles que cubrían un área total de 102.400 km². Todas las entradas del modelo se reescalaron espacialmente y agruparon temporalmente según la resolución de información del satélite, es decir, 2 km y 10 minutos, respectivamente.

División de datos

Una estrategia fundamental para construir modelos de aprendizaje automático robustos y efectivos es segmentar el conjunto de datos en tres grupos: entrenamiento, validación y prueba. Este método es crucial para evitar el sobreajuste, asegurando que el modelo logre una representación adecuada de la precipitación con datos no vistos. Para lograrlo, se estableció un 70% de entrenamiento, 15% de validación y 15% de análisis de pruebas.

Teniendo en cuenta que la precipitación observada por pluviómetros es la variable objetivo para la modelización, se realizó una selección representativa de pluviómetros para subdividirlos en tres subconjuntos de datos, basada en su distribución espacial y temporal. La selección espacial de pluviómetros se realizó mediante muestreo aleatorio estratificado basado en la distribución de distancias entre ellos. En cuanto a la selección temporal, se cuantificó la precipitación acumulada diaria, se clasificaron las fechas de mayor a menor precipitación acumulada y se seleccionaron de forma ordenada e intercalada para cada subconjunto (entrenamiento, validación y prueba) para asegurar muestras homogéneas entre los tres subconjuntos.

Arquitectura de red

A lo largo de los años, las arquitecturas de redes neuronales convolucionales (CNN) han evolucionado, aumentando su precisión, eficiencia y capacidad para procesar imágenes y otros datos espaciales en tareas de reconocimiento, detección y segmentación de objetos (10). La estimación de la tasa de precipitación y la probabilidad de lluvia se clasifican como tareas de segmentación, asignando cada píxel de imagen a una categoría binaria (lluvia/sin lluvia) o realizando regresión. En este contexto, la arquitectura U-Net, propuesta inicialmente por Ronneberger et al. (15) para segmentación de imágenes biomédicas, ha destacado como uno de los más efectivos y ampliamente utilizados debido a su capacidad para trabajar con pocos datos, su estructura simétrica codificador-decodificador y conexiones de salto que ayudan a preservar detalles importantes de la imagen.

Por lo tanto, para el presente estudio, una arquitectura tipo U-Net empleada en Moraux et al. (8,9), que demostró la eficacia de las CNN para la estimación multimodal de la tasa de precipitación y la detección instantánea de eventos de lluvia. Esta arquitectura supera las técnicas existentes y reduce sus limitaciones individuales al proporcionar estimaciones más precisas con mejor resolución espacial (Ya me lo imagino. 2). La arquitectura consta de una etapa de codificación, una etapa de decodificación y una tercera etapa compuesta por dos subredes que realizan tareas de clasificación y regresión.




Figura 2. Arquitectura U-Net implementada

En la etapa de codificación (contracción), las imágenes se reducen a través de capas de doble convolución con 3×3 núcleos, seguidas de la normalización por lotes y la activación de ReLU. Además, la reducción de imagen se realiza mediante capas de 2×2 max-pooling, lo que permite capturar características de alto nivel y la abstracción de información. El número de filtros en cada capa de reducción de muestreo es 64, 128, 256 y 512, respectivamente. Así, la resolución pasa de 2 km por píxel (160×160 píxeles) al inicio de la codificación a 16 km por píxel (20×20 píxeles) al final. Esta última constituye el núcleo central de la red, con la menor resolución espacial pero la representación abstracta más completa de las características.

En la etapa de decodificación (expansión), la red aumenta progresivamente la resolución de imagen mediante capas de upsampling 2×2 usando interpolación de vecinos más cercanos, seguida de convolución 3×3 . Esto permite reconstruir la imagen original pero con las características aprendidas durante la codificación. De manera similar, las capas de doble convolución tienen 3×3 núcleos, normalización por lotes y activación de ReLU. El número de filtros en cada capa de upsampling es 512, 256, 128 y 1, respectivamente, devolviendo la imagen a la resolución original de 2 km por píxel (160×160 píxeles) antes de pasar a las dos subredes diferentes.

Como en Moraux et al. (8,9), algunas capas de convolución en codificación y decodificación son reemplazadas por módulos dobles de Inception propuestos por Szegedy et al. (16) en GoogLeNet (Ya me lo imagino. 3). Estos módulos capturan características más complejas aplicando filtros de varios tamaños. Tabla 2 muestra el número de filtros configurados para cada capa de convolución implementada en el módulo Inception. Para núcleos 5×5 y 7×7 , se aplican convoluciones

factorizadas siguiendo a Szegedy et al. (17) mejorar el rendimiento de la red y reducir los costes computacionales.




Figura 3. Estructura de los módulos de Inception y residuales

Tabla 2. Número de filtros en capas convolucionales de módulos de Inception

Filtros de salida	1x1	1x1 (3x3)	3x3	1x1 (5x5)	5x5	1x1 (7x7)	7x7
256	64	128	128	64	32	32	32
512	64	256	384	64	32	32	32

Además, se implementaron conexiones de salto, conectando directamente capas de codificador con capas de decodificador para preservar y recuperar información de alta resolución perdida durante capas sucesivas de max-pooling (Ya me lo imagino. 3). Estas conexiones se implementan mediante módulos residuales propuestos por He et al. (18) como medida para prevenir la degradación de la información en redes muy profundas, evitando la anulación del gradiente y mejorando la precisión. La unión de estas capas dentro de la red se realiza mediante concatenación de mapas de características, uniendo características aprendidas durante la codificación con resultados de upsampling de la decodificación.

Al final de la etapa del decodificador, la red se ramifica en dos subredes responsables de tareas de clasificación y regresión, respectivamente. Cada subred consta de una capa de convolución 3×3 con normalización por lotes y activación de ReLU, seguida de una capa final de convolución 1×1 con un filtro de salida. Como resultado, se obtiene un mapa de características de la misma dimensión que la imagen de entrada. La cabeza de clasificación utiliza una función de activación sigmoide, limitando las salidas a valores entre 0 y 1. La cabeza de regresión utiliza una función de recorte que limita las salidas a valores entre 0 y 100 para limitar la tasa máxima simulada de precipitación.

Estrategia de entrenamiento

Para los tres subconjuntos de datos (entrenamiento, validación y prueba), en cada paso de tiempo de 10 minutos, se seleccionaba aleatoriamente un pluviómetro como objetivo, correspondiente a la precipitación medida en un punto/píxel específico de la cuadrícula euclidiana del área de estudio. Las mediciones de todos los demás pluviómetros, excluyendo el medidor objetivo en el mismo paso de tiempo, se consideraron como muestras y se utilizaron como variables de entrada para el modelo. Este enfoque permite evaluar la capacidad de la red para estimar tanto la tasa de precipitación como la probabilidad de lluvia en el punto objetivo/píxel, en lugar de considerar múltiples objetivos debido al número limitado de pluviómetros disponibles. Un aspecto fundamental en la selección del pluviómetro objetivo fue asegurar una distribución equitativa de valores de precipitación cero y positivos entre los tres conjuntos de datos, buscando equilibrar la cantidad de datos entre eventos de precipitación y no precipitación para un entrenamiento y evaluación balanceados.

Dado que la red implementada es un modelo multitarea que estima simultáneamente la probabilidad de lluvia y la tasa de precipitación, las pérdidas se calculan de forma independiente con una pérdida por tarea. La probabilidad de precipitación es una tarea de clasificación configurada con la Entropía Cruzada Binaria (Lbce) como función de pérdida, adecuada para problemas con instancias que pertenecen a una de dos clases posibles (lluvia/sin lluvia). La tasa de precipitación se define como una tarea de regresión configurada con el Error Cuadrático Medio (Lmse), como función de pérdida, ideal cuando la predicción responde a valores continuos, cuantificando directamente la magnitud del error entre las predicciones y los valores observados de precipitación. En escenarios donde la tasa objetivo de precipitación es cero (precipitación = 0), la pérdida de Lmse se establece en 0, por lo que el modelo solo aprende de muestras con tasas de precipitación positivas (precipitación > 0).

Para el aprendizaje multitarea, es esencial unificar las pérdidas para equilibrar el entrenamiento y lograr un rendimiento óptimo en todas las tareas. La elección del método depende de la naturaleza de la tarea, los datos y los objetivos específicos. Para este estudio, la pérdida combinada de la red se determinó implementando la metodología de Conflictos de Gradiente Proyectados (PCGrad) propuesta en Yu et al. (19), una estrategia poderosa en el aprendizaje multitarea que conduce a ganancias sustanciales en eficiencia y rendimiento de red.

En cuanto a la optimización de la red, se empleó el Descenso Estocástico de Gradiente (SGD) con momento, ajustado usando el método de tasa de aprendizaje de superconvergencia de un ciclo propuesto por Smith y Topin (20). Este método demostró que las redes neuronales pueden entrenarse más rápido que con métodos estándar, especialmente útil en escenarios con recursos computacionales limitados. La configuración óptima de hiperparámetros estableció un tamaño de lote de 32, una tasa de aprendizaje de 0,01 y una tasa máxima de aprendizaje de 3×10^{-4} , esta última obtenida implementando el método de tasa de aprendizaje superconvergencia de 1 ciclo. La red se entrenaba en una GPU RTX A6000 usando la biblioteca PyTorch.

Métodos de evaluación

Para evaluar la eficiencia del modelo en la estimación de la probabilidad de lluvia o ausencia de lluvia y la tasa de precipitación, se consideraron siete métricas de rendimiento (Tabla 3). Para la tarea de clasificación, se calcularon los siguientes índices: 1) Probabilidad de Detección (POD), que mide la capacidad del modelo para identificar instancias positivas; 2) Ratio de Falsas Alarmas (FAR), que evalúa con qué frecuencia el modelo clasifica incorrectamente las instancias negativas como positivas; 3) Precisión (ACC), que proporciona una visión global del rendimiento del modelo mediante el cálculo de la proporción de predicciones correctas; 4) F1-score (F1), combinando precisión y recuperación; y 5) Curva de Característica de Operación del Receptor (ROC), calculada como el área bajo la curva (AUC), que indica la capacidad discriminativa del modelo.

Tabla 3. Métricas utilizadas para evaluar el rendimiento del modelo

	Ecuación	Distribución	Óptima
Puntuaciones de clasificación			
Probabilidad de detección (POD)	$POD = \frac{tp}{tp + fn}$	[0, 1]	1
Ratio de falsas alarmas (FAR)	$FAR = \frac{fp}{fp + tp}$	[0, 1]	0
Precisión (ACC)	$ACC = \frac{tp + tn}{tp + fp + tn + fn}$	[0, 1]	1
Puntuación en F1 (F1)	$F1 = 2 * \frac{P * R}{P + R}, \quad P = \frac{tp}{tp + tn}, \quad R = \frac{tp}{tp + fn}$	[0, 1]	1
Característica de Funcionamiento del Receptor (ROC)	$AUC = Area\ under\ the\ ROC\ curve$	[0, 1]	1
TP: Verdaderos positivos; FN: falsos negativos; FP: falsos positivos; TN: Verdaderos aspectos negativos			
Puntuaciones de regresión			
Error absoluto medio (MAE)	$MAE = \frac{1}{N} \sum_{i=1}^N \hat{y}_i - y_i $	[0, ∞]	0
Error cuadrático medio raíz (RMSE)	$RMSE = \frac{1}{N} \sum_{i=1}^N \sqrt{(\hat{y}_i - y_i)^2}$	[0, ∞]	0
$y_i, \hat{y}_i$: valor observado, : valor estimado			

Tabla 4 detalla los valores de contingencia entre observaciones y estimaciones necesarias para calcular métricas relacionadas con la clasificación. Para la tarea de regresión, se calculó el Error Absoluto Medio (MAE), interpretando la magnitud media de los errores del modelo sin considerar la dirección; y el Error Cuadrático Medio de la Raíz (RMSE), que indica en promedio la distancia de las predicciones del modelo respecto a los valores reales.

Otro aspecto relevante fue la categorización de días lluviosos y no lluviosos a partir de los valores de probabilidad generados por la red entrenada. Para ello, fue necesario establecer el umbral de probabilidad que define la separación de clases, optimizado como hiperparámetro maximizando el área bajo la curva ROC (AUC) en los conjuntos de datos agregados de entrenamiento y validación.



Tabla 4. Tabla de contingencia de clasificación

		Observado	
		$r = 0$	$r > 0$
Estimado	$r = 0$	tn	fn
	$r > 0$	fp	tp

$tntn$: negativos verdaderos, fn : falsos negativos, $fnfn$
 $fpfp$: falsos positivos, tp : verdaderos positivos, $tp tp$

Resultados y discusión

Durante la fase de entrenamiento, la red neuronal convolucional (CNN) implementada mostró una convergencia exitosa tras 17 épocas, identificada como el punto de equilibrio óptimo entre subajuste y sobreajuste, es decir, el mejor punto de ajuste de la red (Ya me lo imagino. 4). En los tres subconjuntos de datos, las pérdidas disminuyeron de forma constante a medida que el modelo avanzaba a través de épocas, lo que evidenció un aprendizaje efectivo. Los conjuntos de entrenamiento y validación mostraron un comportamiento similar, caracterizado por la reducción y estabilización de la pérdida. Aunque el conjunto de pruebas mostró cierta variabilidad, también evidenció una disminución en las pérdidas, lo que sugiere el potencial del modelo para generalizarse a datos no vistos.

Por otro lado, en la tarea de clasificación, el modelo muestra una mejora significativa en la identificación de eventos de lluvia y ausencia de lluvia. Los valores de Área Bajo la Curva (AUC) son 0,80 para entrenamiento, 0,79 para validación y 0,80 para prueba, considerados aceptables e indicando buena capacidad discriminativa. Analizando métricas asociadas a la capacidad de clasificación de la red, se observa un índice de Probabilidad de Detección (POD) alto de 0,80 en el conjunto de validación, lo que evidencia la eficacia del modelo para detectar eventos de lluvia. La Falsa Razón de Alarmas (FAR) presenta valores medios de 0,21 en los tres conjuntos de datos, lo que indica una tendencia moderada a clasificar correctamente los eventos sin lluvia. Las métricas de precisión (ACC) y F1 muestran que el modelo mantiene una precisión consistente (alrededor de 0,62 en validación), destacando su sólido rendimiento en la tarea de clasificación.

En cuanto a la tarea de regresión de la red, al comparar la tasa de precipitación observada frente a la simulada, el modelo muestra incapacidad para capturar adecuadamente los valores extremos de precipitación, lo que tiende a subestimar los eventos intensos. Además, se observa dispersión de datos, lo que sugiere que el modelo no realiza óptimamente su función de regresión. Analizando las métricas calculadas para evaluar la eficiencia del modelo, se obtuvieron valores RMSE de 1,04, 1,02 y 1,07 mm en entrenamiento, validación y prueba, respectivamente. El Error Absoluto Medio (EAM) es de 0,44, 0,48 y 0,51 para los tres subconjuntos, respectivamente, pero la evidencia del coeficiente de determinación (R^2) indica que la tarea de regresión alcanza solo 0,29, 0,36 y 0,05% de varianza explicada. Estos resultados indican que el modelo captura adecuadamente la probabilidad de ocurrencia de precipitaciones, pero no logra un rendimiento aceptable para predecir cantidades de lluvia en milímetros.




Figura 4. Pérdidas de los conjuntos de entrenamiento, validación y prueba durante el entrenamiento del modelo

Al evaluar el comportamiento de la red a lo largo de las épocas de entrenamiento, la Tabla 5 muestra la mejora continua en la mayoría de las métricas hasta la época 17, lo que indica que el modelo aprende y ajusta eficientemente los datos de probabilidad de ocurrencia de precipitaciones. Estas mejoras corresponden a un aumento notable en la detección de lluvias (POD) y a la reducción de falsas alarmas (FAR), especialmente en el entrenamiento y la validación. También se logró un rendimiento satisfactorio en métricas como la precisión (ACC) y el área bajo la curva (ROC), incluso en la fase de prueba. Para la tarea de regresión, se observa una reducción marginal en los índices MAE y RMSE, demostrando que la estructura de la red neuronal convolutacional requeriría acoplamiento con modelos de series temporales para aprender de forma más eficiente la estructura de dependencias temporales de los datos.

En línea con nuestros hallazgos, otros autores han identificado limitaciones en las redes neuronales convolucionales (CNN) para reproducir correlaciones temporales en series temporales, lo que afecta la precisión en tareas de regresión. Han y otros. (21) observó que, en el contexto de la estimación de la temperatura oceánica subsuperficial en el Pacífico, las CNN no capturan adecuadamente la

correlación temporal de series, subestimando variaciones extremas y mostrando dispersión, como la detectada en la cuantificación de la tasa de precipitación en este estudio. De manera similar, Badrinath et al. (22) reportaron mejoras en la predicción diaria de precipitaciones acumuladas utilizando CNNs; sin embargo, destacan que las dependencias temporales largas no se modelan de forma eficiente, lo que sugiere que la integración de redes neuronales recurrentes podría mitigar estos problemas. En este contexto, estudios como el de Shi et al. (23) han mostrado resultados prometedores en la predicción simultánea de ambas tareas (probabilidad de precipitación y cantidad de lluvia) aplicando un enfoque de doble aprendizaje automático combinado con redes neuronales recurrentes y estructuras convolucionales, logrando coeficientes de correlación satisfactorios en la validación. Estos resultados ponen de manifiesto la necesidad de una arquitectura híbrida en el modelo de red convolucional desarrollado en esta investigación para reducir la subestimación de eventos intensos.

Tabla 5. Evolución de las eficiencias de los modelos

	Formación		Validación		Test	
	Ep1	Ep17	Ep1		Ep1	
POD	0.79	0.85	0.66	0.80	0.69	0.83
LEJOS	0.39	0.21	0.31	0.22	0.35	0.21
ACC	0.64	0.81	0.68	0.79	0.66	0.80
F1	0.69	0.65	0.56	0.62	0.60	0.64
ROC	0.64	0.81	0.68	0.79	0.66	0.80
MAE	0.54	0.44	0.58	0.48	0.58	0.51
RMSE	1.23	1.01	1.35	1.02	1.22	1.07

Conclusiones

La red neuronal convolucional (CNN) implementada en este estudio ha demostrado un rendimiento significativo en la detección de la probabilidad de ocurrencia de lluvia en una región con baja instrumentación. El modelo mostró un desempeño satisfactorio en la detección de patrones de lluvia y ausencia de lluvia, reflejado en las eficiencias y métricas obtenidas como el Área Bajo la Curva (AUC) y el índice de Probabilidad de Detección (POD).

A pesar de los resultados positivos en la clasificación de eventos precipitativos, se identificó la necesidad de mejorar la estimación cuantitativa de la tasa de precipitación. Los valores de RMSE y MAE sugieren que el modelo aún no captura completamente las relaciones entre las tasas de precipitación observadas y simuladas. Esto pone de manifiesto la importancia de fortalecer la red de monitorización para lograr una mayor representatividad espacial, lo que contribuiría a una mejor representación de la magnitud de las precipitaciones.

Agradecimientos

Los autores agradecen a la Universidad del Tolima su apoyo financiero para la ejecución de la investigación a través del proyecto 80623 de 2023 (acuerdo 601-2023).

Financiación

Proyecto Universidad del Tolima 80623 de 2023 (acuerdo 601-2023).

Declaración de contribución de autoría de CreditT

Conceptualización - Ideas: Henry Rubiano, Miguel Barrios. **Curación de datos:** Henry Rubiano. **Análisis formal:** Cristian Guevara, Henry Rubiano, Miguel Barrios. **Investigación:** Henry Rubiano. **Metodología:** Cristian Guevara, Henry Rubiano, Miguel Barrios. **Dirección de Proyecto:** Miguel Barrios. **Recursos:** Miguel Barrios. **Software:** Miguel Barrios. **Supervisión:** Miguel Barrios. **Validación:** Cristian Guevara, Miguel Barrios. **Redacción - borrador original - Elaboración:** Henry Rubiano, Cristian Guevara, Miguel Barrios. **Redacción - revisión y edición -Elaboración:** Cristian Guevara, Miguel Barrios.

Referencias

1. Valencia S, Marín DE, Gómez D, Hoyos N, Salazar JF, Villegas JC. Spatio-temporal assessment of Gridded precipitation products across topographic and climatic gradients in Colombia. Atmos Res [Internet]. 2023;285:106643.
<https://doi.org/10.1016/j.atmosres.2023.106643>
2. Hou AY, Kakar RK, Neeck S, Azarbarzin AA, Kummerow CD, Kojima M, et al. The Global Precipitation Measurement Mission. Bull Am Meteorol Soc [Internet]. 2014;95(5):701-22.
<https://doi.org/10.1175/BAMS-D-13-00164.1>
3. Baez-Villanueva OM, Zambrano-Bigiarini M, Ribbe L, Nauditt A, Giraldo-Osorio JD, Thinh NX. Temporal and spatial evaluation of satellite rainfall estimates over different regions in Latin-America. Atmos Res [Internet]. 2018;213:34-50.
<https://doi.org/10.1016/j.atmosres.2018.05.011>
4. Baez-Villanueva OM, Zambrano-Bigiarini M, Beck HE, McNamara I, Ribbe L, Nauditt A, et al. RF-MEP: A novel Random Forest method for merging gridded precipitation products and ground-based measurements. Remote Sens Environ [Internet]. 2020;239:111606.
<https://doi.org/10.1016/j.rse.2019.111606>
5. Chen S, Xiong L, Ma Q, Kim JS, Chen J, Xu CY. Improving daily spatial precipitation estimates by merging gauge observation with multiple satellite-based precipitation products based on the geographically weighted ridge regression method. J Hydrol (Amst) [Internet]. 2020;589:125156.
<https://doi.org/10.1016/j.jhydrol.2020.125156>
6. Zhang L, Li X, Zheng D, Zhang K, Ma Q, Zhao Y, et al. Merging multiple satellite-based precipitation products and gauge observations using a novel double machine learning approach. J Hydrol (Amst) [Internet]. 2021;594:125969.
<https://doi.org/10.1016/j.jhydrol.2021.125969>
7. Han Y, Wu J, Zhai B, Pan Y, Huang G, Wu L, et al. Coupling a Bat Algorithm with XGBoost to Estimate Reference Evapotranspiration in the Arid and Semiarid Regions of China. Advances in Meteorology [Internet]. 2019;2019(1):9575782.
<https://doi.org/10.1155/2019/9575782>
8. Moraux A, Dewitte S, Cornelis B, Munteanu A. Deep Learning for Precipitation Estimation from Satellite and Rain Gauges Measurements. Remote Sens (Basel) [Internet]. 2019;11(21).
<https://doi.org/10.3390/rs11212463>

9. Moraux A, Dewitte S, Cornelis B, Munteanu A. A Deep Learning Multimodal Method for Precipitation Estimation. Remote Sens (Basel) [Internet]. 2021;13(16).
<https://doi.org/10.3390/rs13163278>
10. Wang C, Tang G, Xiong W, Ma Z, Zhu S. Infrared precipitation estimation using convolutional neural network for FengYun satellites. J Hydrol (Amst) [Internet]. 2021;603:127113.
<https://doi.org/10.1016/j.jhydrol.2021.127113>
11. Wang C, Xu J, Tang G, Yang Y, Hong Y. Infrared Precipitation Estimation Using Convolutional Neural Network. IEEE Transactions on Geoscience and Remote Sensing. diciembre de 2020;58(12):8612-25.
<https://doi.org/10.1109/TGRS.2020.2989183>
12. Poveda G, Álvarez D, Rueda Ó. Hydro-climatic variability over the Andes of Colombia associated with ENSO: a review of climatic processes and their impact on one of the Earth's most important biodiversity hotspots. Clim Dyn [Internet]. 2011;36:2233-49.
<https://doi.org/10.1007/s00382-010-0931-y>
13. Salas HD, Builes-Jaramillo A, Boers N, Poveda G, Mesa ÓJ, Kurths J. Precipitation over northern South America and the far-eastern Pacific during ENSO: Phase synchronization at inter-annual time scales. International Journal of Climatology [Internet]. 2024;44(6):2106-23.
<https://doi.org/10.1002/joc.8443>
14. World Meteorological Organization. Guide to Hydrological Practice. Volume I: Hydrology from Measurement to Hydrological Information. WMO-No. 168 [Internet]. Vol. Volume 1. Geneva: World Meteorological Organization; 2025 [citado el 7 de septiembre de 2025]. Disponible en: <https://library.wmo.int/idurl/4/35804>
15. Ronneberger Olaf, Fischer P, Brox Thomas. U-Net: Convolutional Networks for Biomedical Image Segmentation. En: Navab Nassir and Hornegger J and WWM and FAF, editor. Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015. Cham: Springer International Publishing; 2015. p. 234-41.
https://doi.org/10.1007/978-3-319-24574-4_28
16. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al. Going deeper with convolutions. En: 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2015. p. 1-9.
<https://doi.org/10.1109/CVPR.2015.7298594>
17. Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the Inception Architecture for Computer Vision. En: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016. p. 2818-26.
<https://doi.org/10.1109/CVPR.2016.308>
18. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition. En: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2016.
<https://doi.org/10.1109/CVPR.2016.90>
19. Yu T, Kumar S, Gupta A, Levine S, Hausman K, Finn C. Gradient Surgery for Multi-Task Learning. En: Larochelle H, Ranzato M, Hadsell R, Balcan MF, Lin H, editores. Advances in Neural Information Processing Systems [Internet]. Curran Associates, Inc.; 2020. p. 5824-36. Disponible en: https://proceedings.neurips.cc/paper_files/paper/2020/file/3fe78a8acf5fda99de95303940a2420c-Paper.pdf

20. Smith LN, Topin N. Super-convergence: very fast training of neural networks using large learning rates. En: Pham T, editor. Artificial Intelligence and Machine Learning for Multi-Domain Operations Applications [Internet]. SPIE; 2019. p. 1100612.

<https://doi.org/10.1117/12.2520589>

21. Han M, Feng Y, Zhao X, Sun C, Hong F, Liu C. A Convolutional Neural Network Using Surface Data to Predict Subsurface Temperatures in the Pacific Ocean. IEEE Access. septiembre de 2019;7:172816-29.

<https://doi.org/10.1109/ACCESS.2019.2955957>

22. Badrinath A, Monache LD, Hayatbini N, Chapman W, Cannon F, Ralph M. Improving Precipitation Forecasts with Convolutional Neural Networks. Weather Forecast [Internet]. 2023;38(2):291-306.

Disponible en: <https://journals.ametsoc.org/view/journals/wefo/38/2/WAF-D-22-0002.1.xml>

23. Shi X, Chen Z, Wang H, Yeung DY, Wong W kin, Woo W chun. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. En: Cortes C, Lawrence N, Lee D, Sugiyama M, Garnett R, editores. Advances in Neural Information Processing Systems [Internet]. Curran Associates, Inc.; 2015. Disponible en: https://proceedings.neurips.cc/paper_files/paper/2015/file/07563a3fe3bbe7e3ba84431ad9d055af-Paper.pdf