



Patrones de comportamiento de precipitación utilizando Técnicas de Aprendizaje Automático

Precipitation behavior patterns using Machine Learning Techniques

Padrões de comportamento da precipitação usando técnicas de aprendizagem automática

Wilson Geovanny Miranda-Sayay^I

wilson.miranda@esepoch.edu.ec

<https://orcid.org/0009-0009-5806-3171>

Alex Eduardo Pozo-Valdiviezo^{II}

eduardo.pozo@esepoch.edu.ec

<https://orcid.org/0000-0003-0480-5669>

Natalia Alexandra Pérez-Londo^{III}

nperez@esepoch.edu.ec

<https://orcid.org/0000-0001-9068-8790>

Cristina Estefanía Ramos-Araujo^{IV}

cristina.ramos@esepoch.edu.ec

<https://orcid.org/0000-0002-8644-5814>

Correspondencia: wilson.miranda@esepoch.edu.ec

Ciencias de la Educación

Artículo de Investigación

* **Recibido:** 31 de mayo de 2024 * **Aceptado:** 20 de junio de 2024 * **Publicado:** 05 de julio de 2024

- I. Ingeniero en Estadística Informática, Investigador Externo en la Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.
- II. Máster en Ciencias, Tecnologías, Salud Mención Matemáticas y Aplicaciones-Matemáticas para las Ciencias de la Vida, Profesor Ocasional Tiempo Completo en la Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.
- III. Máster Universitario en Estadística Aplicada, Profesor Ocasional en la Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.
- IV. Máster of Science in Applied Mathematics, Profesor Ocasional Tiempo Completo en la Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.

Resumen

Esta investigación tiene como objetivo identificar patrones de comportamiento de las precipitaciones durante el período 2020-2050 a través de herramientas estadísticas, técnicas de aprendizaje automático utilizando datos de precipitación. Para ello, se utilizaron modelos atmosféricos del Centro Nacional de Investigaciones Meteorológicas (CNRM), de precipitación diaria para el periodo 2020-2050. En la primera etapa se utiliza estadísticas descriptivas: gráficas, medidas de tendencia central y dispersión, en la segunda etapa se utiliza técnicas multivariadas de reducción de dimensionalidad y se aplicaron diferentes técnicas de Machine Learning para identificar patrones de comportamiento como: K-Means, Agrupación espacial de aplicaciones con ruido basada en densidad (DBSCAN), donde la técnica (DBSCAN) determinó 4 agrupaciones de precipitación, la métrica de precisión Silhouette y la información de precipitación registrada para el año 2021 se ha utilizado para comparar la precisión de la técnica. Como resultado de este análisis, la mejor técnica para patrones de comportamiento de precipitaciones se considera el algoritmo con métricas euclidianas, con una efectividad del 70.92%. Los patrones de comportamientos observados se asemejan a las precipitaciones habituales en cada región ecuatoriana.

Palabras clave: Patrones de precipitación; Aprendizaje automático; Algoritmo DBSCAN.

Abstract

This research aims to identify precipitation behavior patterns during the period 2020-2050 through statistical tools, machine learning techniques using precipitation data. For this purpose, atmospheric models from the National Center for Meteorological Research (CNRM) were used, of daily precipitation for the period 2020-2050. In the first stage, descriptive statistics are used: graphs, measures of central tendency and dispersion, in the second stage, multivariate dimensionality reduction techniques are used and different Machine Learning techniques were applied to identify behavior patterns such as: K-Means, Density-Based Spatial Clustering of Applications with Noise (DBSCAN), where the technique (DBSCAN) determined 4 precipitation clusters, the Silhouette accuracy metric and the precipitation information recorded for the year 2021 has been used to compare the accuracy of the technique. As a result of this analysis, the best technique for precipitation behavior patterns is considered to be the algorithm with Euclidean

metrics, with an effectiveness of 70.92%. The observed patterns of behavior resemble the usual rainfall in each Ecuadorian region.

Keywords: Precipitation patterns; Machine learning; DBSCAN algorithm.

Resumo

Esta pesquisa tem como objetivo identificar padrões de comportamento da precipitação durante o período 2020-2050 através de ferramentas estatísticas, técnicas de aprendizagem automática utilizando dados de precipitação. Para tal foram utilizados modelos atmosféricos do Centro Nacional de Pesquisas Meteorológicas (CNRM), com precipitação diária para o período 2020-2050. Na primeira etapa são utilizadas estatísticas descritivas: gráficos, medidas de tendência central e dispersão, na segunda etapa são utilizadas técnicas multivariadas de redução de dimensionalidade e aplicadas diferentes técnicas de Machine Learning para identificar padrões comportamentais como: K-Means, Agrupamento de Aplicações Espaciais com ruído baseado na densidade (DBSCAN), onde a técnica (DBSCAN) determinou 4 clusters de precipitação, a métrica de precisão Silhouette e a informação de precipitação registrada para o ano de 2021 foram utilizadas para comparar a precisão da técnica. Como resultado desta análise, considera-se que a melhor técnica para os padrões de comportamento da precipitação é o algoritmo com métricas euclidianas, com uma eficácia de 70,92%. Os padrões de comportamento observados assemelham-se aos das chuvas habituais em cada região equatorial.

Palavras-chave: Padrões de precipitação; aprendizagem de máquina; Algoritmo DBSCAN.

Introducción

En las últimas décadas, la influencia del cambio climático se ha vuelto cada vez mayor, planteando desafíos importantes, particularmente para los países emergentes. Estas naciones a menudo carecen de los recursos y la infraestructura para hacer frente de manera efectiva a los efectos adversos de los patrones climáticos cambiantes. El cambio climático exacerba las vulnerabilidades existentes, provocando una intensificación de fenómenos meteorológicos como tormentas, sequías e inundaciones, que afectan desproporcionadamente a las comunidades marginadas. En consecuencia, comprender la dinámica de la variabilidad climática y sus impactos es importante para desarrollar estrategias de adaptación efectivas, especialmente en regiones donde el desarrollo

socioeconómico está estrechamente vinculado con las condiciones ambientales (Sebenius, 1991; Useros, 2013).

Se han logrado avances significativos en la predicción de las precipitaciones, que desempeñan un papel vital en la vida humana. Todavía resulta difícil predecir con precisión la cantidad de lluvia que caerá durante las estaciones secas y húmedas. Los centros meteorológicos integran inteligencia artificial para mejorar las previsiones numéricas (Slater et al., 2023). La Oficina Nacional de Administración Oceánica y Atmosférica (NOAA), la principal agencia gubernamental de EE. UU., tiene como objetivo ampliar el uso de la IA en cada misión de la NOAA para mejorar la eficiencia, la eficacia y la coordinación en el desarrollo, los productos y los servicios científicos (Lima et al., 2023; Waqas et al., 2023; Materia et al., 2023; Khandelwal et al., 2020).

El impacto observado en Ecuador se refleja en la percepción biofísica del territorio, incluyendo la degradación de los glaciares andinos, aumento de temperatura y nivel del mar, inundaciones, sequías, impactos negativos en las actividades productivas y la biodiversidad, etc. Además, El Niño Oscilación del Sur (ENSO) influyen en Ecuador en dos escenarios: ENSO (fase cálida) y ENSO (fase fría), donde la precipitación aumenta y disminuye, respectivamente. Las consecuencias observadas se manifiestan en cambios de temperatura y precipitaciones intensas (Vega et al., 2020; Campozano et al., 2020; Perez et al., 2010; World Bank Group, 2021).

Según el Panel Intergubernamental sobre Cambio Climático (IPCC), América Latina es una de las regiones más vulnerable, enfrentando pérdidas económicas, humanas, de infraestructura, agrícolas y ambientales. El informe del IPCC afirma que la concentración de dióxido de carbono en la atmósfera ha aumentado hasta las 379 partes por millón (un umbral no alcanzado en los últimos 650.000 años de la historia de la Tierra), junto con un aumento de las concentraciones de metano y óxido nitroso entre 1995 y 2005 (Zhang, 2024). El océano está 17 cm más alto que a principios del siglo XX y la temperatura es 0,7 °C más cálida que en 1850. En consecuencia, las precipitaciones han aumentado en determinadas regiones, con sequías más intensas y prolongadas en extensas zonas tropicales y subtropicales, y la frecuencia de fuertes lluvias en varios países (Magrin et al., 2007; IPCC), 2023).

Las técnicas de aprendizaje automático han apoyado varios campos, incluida la climatología, debido a su capacidad para analizar grandes conjuntos de datos de manera eficiente (Slater et al., 2023; Lima et al., 2023). Estas técnicas ofrecen estadísticas avanzadas para comprender y predecir los patrones de precipitación, que son cruciales para informar las estrategias de adaptación

climática. La complejidad y variabilidad de los sistemas climáticos, agravadas por factores como la topografía y los microclimas, plantean obstáculos importantes para una predicción precisa (Slater et al., 2023). A pesar de estos desafíos, los métodos de aprendizaje automático tienen potencial para mejorar nuestra comprensión de la dinámica de las precipitaciones y mejorar la precisión de los pronósticos. Ecuador se caracteriza por su diversa topografía y variabilidad climática (Campozano et al., 2020). Los ecosistemas diversos, que van desde llanuras costeras hasta regiones andinas de gran altitud, que contribuye a la complejidad de su sistema climático. En consecuencia, la necesidad de explorar técnicas avanzadas de aprendizaje automático debido a que los métodos estadísticos tradicionales pueden no capturar las características de la diversidad climática de Ecuador.

Con base en estos antecedentes, la investigación se guía por las siguientes preguntas: ¿Existen cambios significativos en las precipitaciones en el Ecuador durante el periodo 2020 al 2050? ¿Qué factores definen el comportamiento climático en el Ecuador? ¿Cuál es la mejor técnica de aprendizaje automático que ha producido resultados para determinar patrones de comportamiento? ¿Y qué precisión tiene la técnica de aprendizaje automático para lograr el objetivo de la investigación? Este estudio tiene como objetivo comprender los patrones de comportamiento de la precipitación utilizando herramientas estadísticas y de aprendizaje automático en datos de los modelos de circulación atmosférica de 2020 a 2050 que podrían apoyar el desarrollo de políticas y la toma de decisiones gubernamentales.

Materiales y Métodos

La presente investigación considera datos diarios de precipitación de la (CNRM), que son utilizados para estudiar el comportamiento del patrón de precipitación durante los últimos 30 años (Lima et al., 2023; Loritzet al., 2021). Se ha utilizado el lenguaje de programación Python.


Modelo Estadístico: En la investigación se utilizó la estadística descriptiva, como gráficas y medidas de tendencia central y dispersión para explorar las características de la variable precipitación. Los datos provienen de una distribución de probabilidad normal estándar $N(0,1)$. Además, se aplicó técnicas multivariadas para reducir la dimensionalidad de los datos. Posteriormente, se aplicaron técnicas de aprendizaje automático, K-means, DBSCAN y Agglomerative Clustering, para identificar patrones de comportamiento en la precipitación.

Análisis de Datos: Se realizó el Análisis de Componentes Principales para reducir la complejidad de los datos, se obtuvo el 70% de la variabilidad explicada con cuarenta componentes, de la misma manera, se aplicaron las técnicas de aprendizaje automático como: K-Means, DBSCAN y Agglomerative Clustering utilizando métricas como Chebyshev y Euclidiana, al mismo tiempo se aplicó Stochastic Neighbor Embedding Technique in t (t-SNE) y Uniform Manifold Approximation and Projection para identificar patrones de comportamiento de precipitación. Se realizó una comparación entre técnicas para determinar cuál de ellos es más efectivo.

Resultados y Discusión

La variable precipitación diaria presenta tres dimensiones diferentes con sus respectivas coordenadas: Y para latitud, X para longitud y T para tiempo. Los datos de precipitación son estandarizados mediante una de distribución normal.


Figura 1: Histograma de frecuencias



Exploración de Anomalías: La Figura 2 y la Figura 3 muestran el comportamiento de la precipitación en el tiempo. Como se muestra, los días de lluvia (fuertes precipitaciones) alcanzan su punto máximo durante los años 2036-2040, así como las escasas precipitaciones. También se

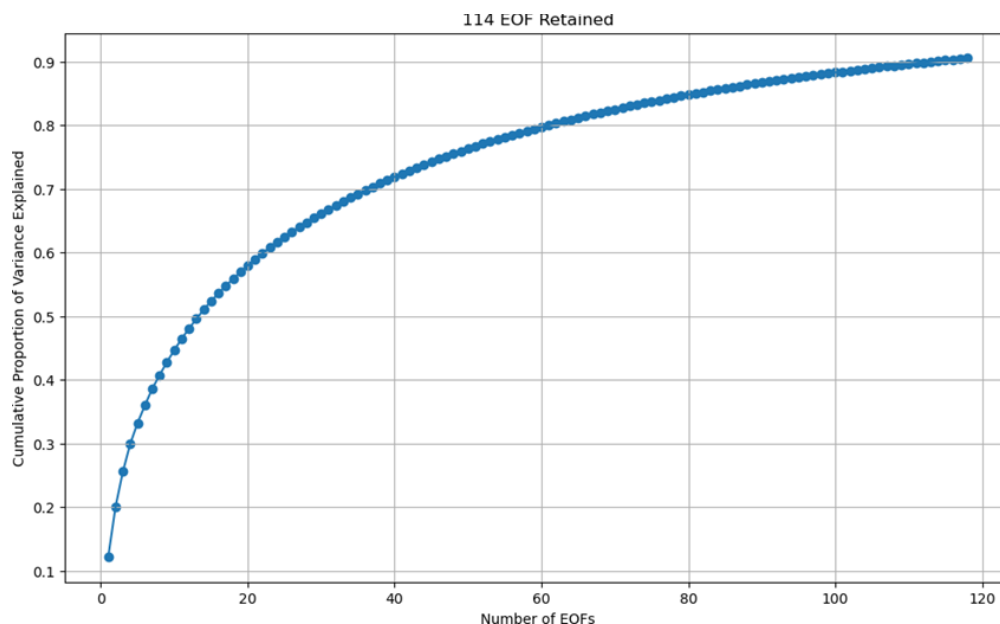
puede observar que el rango de variaciones positivas (extremadamente húmedo) es mayor que el de variaciones negativas (extremadamente seco).

Figura 2: Serie de tiempo de Precipitación (años)



Reducción de dimensionalidad: se aplicó el Análisis de Componentes Principales (PCA) para reducir la dimensionalidad; Sesenta componentes principales representan el 80% de la variabilidad explicada de los datos, como se presenta en la Figura 3.

Figura 3: Análisis de Componentes Principales



Stochastic Neighbor Embedding Technique in t (t-SNE): Esta técnica no supervisada se utiliza principalmente para la exploración, visualización y reducción de datos de alta dimensión.

La Figura 4 muestra similitud entre las observaciones de precipitación, pero no hay agrupación de patrones definidos.

UMAP: Uniform Manifold Approximation and Projection: La Figura 5 muestra la técnica UMAP que ha identificado 6 patrones de comportamiento de la precipitación, no definidos.

Figura 4: Técnica t-SNE





Figura 5: Gráfica de dispersión del agrupamiento mediante UMAP




Selección del número óptimo de conglomerados: La Figura 6 presenta el método del codo que indica que el número óptimo de conglomerados es cuatro.

Figura 6: Gráfico del método del codo. El eje x representa el número de grupos y el eje y representa la suma de distancias.



UMAP Algorithm (Euclidean Metric) with DBSCAN Clustering: En la Figura 7 se observa la dispersión de los patrones de precipitación, con cuatro grupos definidos. Las características de la precipitación están agrupadas.

Figura 7: UMAP diagrama de dispersión con la técnica DBSCAN



Se utilizó la métrica de Chebyshev y el resultado se muestra en la Tabla 1 y en la Tabla 2, el valor de precisión de 0,85 indica que el algoritmo DBSCAN es un buen estimador para identificar patrones de comportamiento de precipitación clasificados en cuatro grupos. Dado que se trata de un enfoque de aprendizaje no supervisado, la matriz de confusión se utiliza simplemente para observar la predicción del algoritmo.

Tabla 1: Agrupación de precipitación

Rango	Observaciones
Moderadamente seco	3481
Normal – aproximadamente normal	3204
Muy húmedo o moderadamente húmedo	2594
Extremadamente húmedo	1675

Tabla 2: Matriz de Confusión

Observaciones reales		Observaciones estimadas			
		Moderadamente seco	Normal – aproximadamente normal	Muy húmedo o moderadamente húmedo	Extremadamente húmedo
Observaciones reales	Moderadamente seco	4016	8	304	12
	Normal – aproximadamente normal	19	3653	225	42
	Muy húmedo o moderadamente húmedo	41	26	1826	7
	Extremadamente húmedo	14	340	35	1070
	Precisión	0.8534			

Representación de Resultados mediante Algoritmo DBSCAN: Los resultados se interpretan como: i) moderadamente seco está formado por el grupo de formulario -1, ya que Ecuador

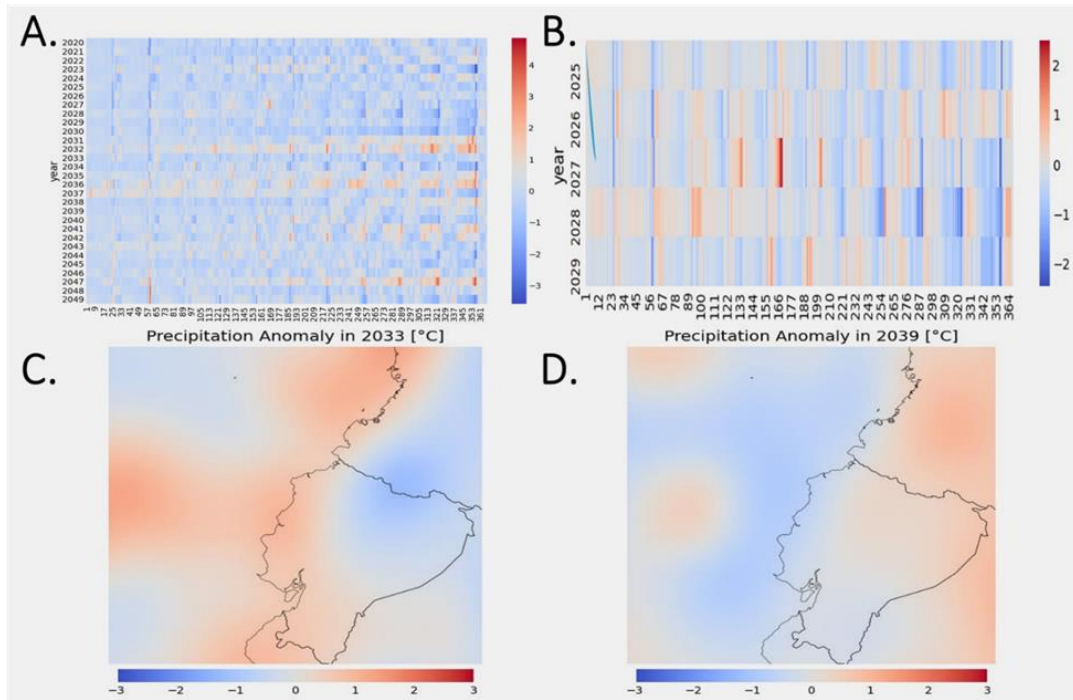
generalmente no experimenta días extremadamente secos. ii) La precipitación normal o aproximadamente normal está formada por el grupo 0. iii) La precipitación muy húmeda está formada por el grupo 1 y iv) La precipitación extremadamente húmeda está formada por el grupo 2, como se muestra en la Tabla 3.

Table 3: Agrupaciones

Rango	Número de observaciones	Porcentaje de ocurrencia
Moderadamente seco	3481	32 %
Normal – aproximadamente normal	3204	29 %
Muy húmedo o moderadamente húmedo	2594	24 %
Extremadamente húmedo	1675	15 %

Patrones de Comportamiento: En la Figura 8A se puede observar que en el año 2044 podría haber pocos días extremadamente secos, mientras que en el año 2032 podría haber días extremadamente húmedos. Además, podría haber un aumento de días extremadamente secos en el año 2030 en comparación con el resto de los años. Siguiendo esto, en la Figura 8B, en el año 2027 podría haber menos días moderadamente húmedos, mientras que en el año 2028 podrían disminuir los días moderadamente secos. Además, en el año 2029 podrían disminuir los días extremadamente secos y las lluvias frecuentes en comparación con el resto del año. La Figura 8C muestra que en el año 2030 podría haber pocos días moderadamente secos, mientras que en el año 2034 podría haber días moderadamente húmedos, mientras que en el año 2032. De manera similar, en la Figura 8D, en la región costera podría haber mucha humedad en 2033. año, mientras que en las regiones montañosas y orientales podrían presentarse días moderadamente secos. Además, en la región costera y parte de la región montañosa, podría haber días moderadamente secos en el año 2039, mientras que en las regiones altas y orientales podría haber días muy húmedos con menos frecuencia.

Figura 8: Mapa de calor patrones de comportamiento



Aplicación de Varios Algoritmos de Agrupación: Las Figuras 9 y 10 muestran la dispersión de los datos, donde emergen cuatro grupos o patrones de precipitación diferentes. Las agrupaciones no son bien definidas. La métrica de Chebyshev se utiliza para evaluar esta dispersión y, si bien muestra cierta variación entre grupos.

Figura 9: UMAP K-Means clustering algorithm.

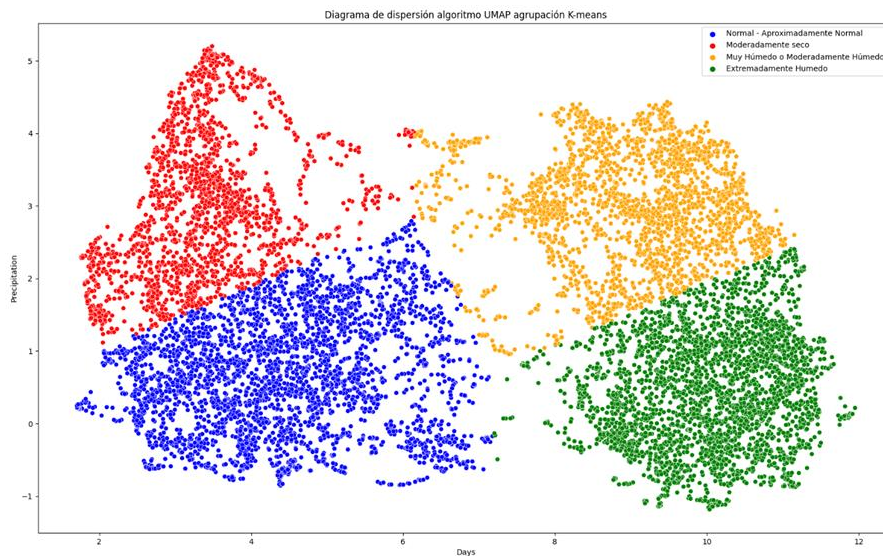



Figura 10: UMAP Agglomerative Clustering algorithm.



Comparación de los modelos: Los valores del índice de Silhouette se calcularon para diferentes algoritmos de agrupamiento, y el algoritmo DBSCAN con UMAP y la métrica de Chebyshev demostró la mayor efectividad con una precisión del 70,97% como se presenta en la Tabla 4. Esto indica que DBSCAN es la mejor técnica para agrupar patrones de comportamiento de precipitación. Además, se proporcionan los datos de precipitación mensual registrados a partir de 2021 para compararlos con los patrones previstos.

Tabla 4: Comparación del index Silhouette

UMAP características	Algoritmo	Grupos	Silhouette
UMAP métrica = "euclidean"	DBSCAN	4	0.7092
UMAP métrica = "euclidean"	Agglomerative clustering	4	0.4106
UMAP métrica = "euclidean"	k-means	4	0.4676
UMAP métrica = "Chebyshev"	k-means	4	0.5128

UMAP	métrica	=	Agglomerative	4	0.4383
	“Chebyshev”		clustering		
UMAP	métrica	=	DBSCAN	4	0.3690
	“Chebyshev”				

La información de precipitación obtenida de INOCAR para Ecuador en 2021 se asemeja con los patrones de comportamiento previstos identificados por la técnica de aprendizaje automático DBSCAN (Li et al., 2021). Esto sugiere que DBSCAN es un método confiable para representar patrones de precipitación, indicando variaciones significativas que conducen a días moderadamente secos y días extremadamente húmedos (Jianwei et al., 2023; Jin et al., 2021; Chen et al., 2023). Además, se observan patrones estacionales de precipitación, como precipitaciones intensas en febrero-marzo y días secos en octubre-noviembre, con días extremadamente secos en junio-agosto y menor probabilidad de ocurrencia de ENSO en diciembre y enero (Intergovernmental Panel on Climate Change, 2023). Nuestros hallazgos tienen implicaciones importantes en la comprensión de los patrones de precipitación aplicando técnicas de aprendizaje automático como los algoritmos DBSCAN y UMAP.

Se representa los patrones de precipitación en cuatro grupos: moderadamente seco, normal a moderadamente húmedo, muy húmedo a moderadamente húmedo y extremadamente húmedo. Estas características son frecuentes en las observaciones diarias a través del tiempo. La representación de diagramas de dispersión ilustra las observaciones de precipitación diaria que mostraron cambios entre los períodos secos y húmedos, enfatizando la variabilidad inherente a la dinámica de la precipitación. La identificación de posibles eventos extremos en 2030 y 2044 años, caracterizadas por variaciones de los patrones de precipitación típicos. Estas características sirven como indicadores críticos de posibles eventos climáticos, destacando la importancia del estudio continuo de comportamiento de variables meteorológicas para una gestión eficaz de riesgos y estrategias de adaptación.

Además, la comparación del modelo con datos reales proporcionados por INOCAR con índice Silhouette, en donde el algoritmo DBSCAN es considerado adecuado para capturar las características de la precipitación. Las técnicas de aprendizaje automático son convenientes para extraer información significativa de conjuntos de datos climáticos, como lo han empleado otros

autores con resultados similares (Pamuji & Rongtao, 2020; Chefrour, 2022; Cammalleri & Toreti, 2023).

Nuestros hallazgos tienen implicaciones significativas para la planificación de la adaptación, particularmente en regiones vulnerables a eventos climáticos extremos. Al representar la dinámica temporal y espacial de los patrones de precipitación, las partes interesadas pueden anticipar y responder mejor a las condiciones climáticas cambiantes, reduciendo la vulnerabilidad.

Sin embargo, el conjunto de datos reales para comparar con las proyecciones del modelo (CNRM) es una limitación de este estudio. Los esfuerzos de investigación futuros deberían centrarse en probar otras técnicas de agrupación e incorporar variables adicionales.

Conclusiones

- Se realizó una exploración de datos, describiendo las estadísticas descriptivas, representaciones gráficas que ayudaron a comprender el comportamiento de la precipitación.
- Se identificaron cuatro grupos mediante la técnica DBSCAN. Que podrían corresponder a la frecuencia de los días con precipitación: Moderadamente Seco, Normal - Aproximadamente Normal, Muy Húmedo o Moderadamente Húmedo y Extremadamente Húmedo.
- Se concluye que la mejor técnica para identificar patrones de comportamiento de precipitación es DBSCAN, la cual tuvo un índice Silhouette de 70,92% en comparación con otras técnicas utilizadas.
- Los resultados de las técnicas de agrupación se han comparado considerando el informe climatológico de INNOCAR correspondiente al año 2021, mostrando patrones de comportamiento similares.
- Este estudio proporcionó información para comprender la variabilidad de las precipitaciones, que podría utilizarse para evaluar los riesgos climáticos.

Contribuciones de los autores: Todos los autores han leído y aceptado la versión publicada del manuscrito.

Financiamiento: Esta investigación no recibió financiamiento externo.

Conflictos de intereses: Los autores declaran no tener ningún conflicto de intereses.

Referencias

1. Cammalleri, C., & Toreti, A. (2023). Un algoritmo generalizado basado en densidad para el seguimiento espaciotemporal de eventos de sequía. *Journal of Hydrometeorology*, 24 (3), 537-548. <https://journals.ametsoc.org/view/journals/hydr/24/3/JHM-D-22-0115.1.xml>
2. Campozano, L., Ballari, D., Montenegro, M., & Avilés, A. (2020). Future meteorological droughts in Ecuador: decreasing trends and associated spatio-temporal features derived from CMIP5 models. *Frontiers in Earth Science*, 8, 17. <https://www.frontiersin.org/journals/earth-science/articles/10.3389/feart.2020.00017/full>
3. Chefrou, A. (2022). Weather forecasting using DBSCAN clustering algorithm. In *Annales Mathematicae et Informaticae* (Vol. 55, pp. 12-27). Eszterházy Károly Egyetem Líceum Kiadó. <https://real.mtak.hu/155440/>
4. Chen, H., Wang, S., Zhu, J., & Wang, D. (2023). Projected changes in the pattern of spatially compounding drought and pluvial events over Eastern China under a warming climate. *Earth's Future*, 11(5), e2022EF003397. <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2022EF003397>
5. Grupo Intergubernamental de Expertos sobre el Cambio Climático (IPCC). (2023). América Central y del Sur. En *Cambio climático 2022 – Impactos, adaptación y vulnerabilidad: Contribución del Grupo de Trabajo II al Sexto Informe de Evaluación del Grupo Intergubernamental de Expertos sobre el Cambio Climático* (pp. 1689–1816). capítulo, Cambridge: Cambridge University Press. <https://www.cambridge.org/core/books/climate-change-2022-impacts-adaptation-and-vulnerability/central-and-south-america/A9FC9F29685A35A7BF8C6D832E7B2A2A>
6. Intergovernmental Panel on Climate Change. (2023). Weather and Climate Extreme Events in a Changing Climate. *Climate Change 2021 – The Physical Science Basis*. 1513–1766. <https://www.ipcc.ch/report/ar6/wg1/>
7. Jianwei, L., Zheng, A., Wei, G., Bandyopadhyay, N., Zhang, Y., & Qianfeng, R. (2023). Urban flood risk assessment based on DBSCAN and K-means clustering algorithm. *Geomatics, Natural Hazards and Risk*, 14(1), 2250527. <https://www.tandfonline.com/doi/full/10.1080/19475705.2023.2250527>
8. Jin H, Chen X, Wu P, Song C, & Xia W. (2021). Evaluation of spatial-temporal distribution of precipitation in mainland China by statistic and clustering methods. *Atmospheric*

- Research, 262, 105772.
<https://www.sciencedirect.com/science/article/abs/pii/S0169809521003288>
9. Khandelwal, A., Xu, S., Li, X., Jia, X., Stienbach, M., Duffy, C., Nieber, J., & Kumar, V. (2020). Physics Guided Machine Learning Methods for Hydrology. Preimpresión de arXiv arXiv:2012.02854. <http://arxiv.org/abs/2012.02854>
 10. Li, X., Yang, Y., Mi, J., Bi, X., Zhao, Y., Huang, Z., Liu, C., Zong, L., & Wanju, L. (2021). Aprovechamiento del aprendizaje automático para la estimación cuantitativa de precipitaciones a partir de observaciones geoestacionarias de Fengyun-4 y mediciones meteorológicas terrestres. *Atmospheric Measurement Techniques*, 14 (11), 7007-7023. <https://amt.copernicus.org/articles/14/7007/2021/amt-14-7007-2021.html>
 11. Lima, E., Nogueira, A., Paes, A., Wanzeler, C., Gonçalves, J., Martins, P., De Lima, R., Cley, R., Dos Santos, V., Costa, E., & Gonçalves, R. (2023). Predicción de precipitaciones: desde aspectos geofísicos hasta aplicaciones de aprendizaje automático. *Frontiers in Climate*, 5, 1250201. <https://www.frontiersin.org/journals/climate/articles/10.3389/fclim.2023.1250201/full>
 12. Loritz, R., Hrachowitz, M., Neuper, M., & Zehe, E. (2021). The role and value of distributed precipitation data in hydrological models. *Hydrology and Earth System Sciences*, 25(1), 147-167. <https://hess.copernicus.org/articles/25/147/2021/>
 13. Magrin, G., Gay, C., Cruz, D., Giménez, J., Moreno, A., Nagy, G., Nobre, C., & Villamizar, A., (2007). Latin America. *Climate Change 2007: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*, M.L. Parry, O.F. Canziani, J.P. Palutikof, P.J. van der Linden and C.E. Hanson, Eds., Cambridge University Press, Cambridge, UK, 581-615. <https://www.ipcc.ch/site/assets/uploads/2018/02/ar4-wg2-chapter13-1.pdf>
 14. Materia S, Palma, L., Van Straaten, C., O, S., Mamalakis, A., Cavicchia, L., Coumou, D., De Luca, P., Kretschmer, M., & Donat, M. (2023). Artificial Intelligence for Prediction of Climate Extremes: State of the art, challenges and future perspectives. arXiv preprint arXiv:2310.01944. <https://arxiv.org/abs/2310.01944>
 15. Pamuji, G., & Rongtao, H. (2020, July). A Comparison study of DBScan and K-Means Clustering in Jakarta rainfall based on the Tropical Rainfall Measuring Mission (TRMM) 1998-2007. In *IOP conference series: materials science and engineering* (Vol. 879, No. 1,

- p. 012057). IOP Publishing. <https://iopscience.iop.org/article/10.1088/1757-899X/879/1/012057/meta>
16. Pérez, C., Nicklin, C., Dangles, O., Vanek, S., Sherwood, S., Halloy, S., Garrett, K., & Forbes, G. (2010). Cambio climático en los Altos Andes: Implicancias y estrategias de adaptación para los pequeños agricultores. *Revista Internacional de Sostenibilidad Ambiental, Cultural, Económica y Social*, 6, 71-88. <https://research.wur.nl/en/publications/climate-change-in-the-high-andesimplications-and-adaptation-strat>
 17. Sebenius, J. (1991). Designing negotiations toward a new regime: The case of global warming. *International Security*, 15(4), 110-148. <https://www.jstor.org/stable/2539013>
 18. Slater, L, Arnal, L., Boucher, M., Chang, A., Moulds, S., Murphy, C., & Zappa, M. (2023). Pronóstico híbrido: combinación de predicciones climáticas con modelos de IA. *Hidrología y ciencias del sistema terrestre*, 27 (9), 1865-1889. <https://hess.copernicus.org/articles/27/1865/2023/hess-27-1865-2023.html>
 19. Useros J. (2013). El Cambio Climático: Sus Causas Y Efectos Medioambientales *Climate Change: Causes and Environmental Effects*. An la Real Acad Med y Cirugía Valladolid, 50, 71-98. <https://uvadoc.uva.es/handle/10324/23839>
 20. Vega, S., Malla, C., & Bejarano, H. (2020). Evidencias del cambio climático en Ecuador. *Revista Científica Agroecosistemas*, 8(1), 72-76. <https://aes.ucf.edu.cu/index.php/aes/article/view/388/367>
 21. Waqas, M., Wannasingha, E., Wangwongchai A., Dechpichai, C., & Ahmad, S. (2023). Potencial de las técnicas basadas en inteligencia artificial para la previsión de precipitaciones en Tailandia: una revisión exhaustiva. *Water*, 15 (16), 2979. <https://www.mdpi.com/2073-4441/15/16/2979>
 22. World Bank Group (WBG). (2021). *Climate Risk Country Profile: Ecuador*. https://climateknowledgeportal.worldbank.org/sites/default/files/country-profiles/15988-WB_Ecuador%20Country%20Profile-WEB.pdf
 23. Zhang, Y. (2024). El calentamiento del sistema climático es inequívoco”: Aspectos más destacados del Cuarto Informe de Evaluación del Grupo Intergubernamental de Expertos sobre el Cambio Climático. Naciones Unidas. <https://www.un.org/es/chronicle/article/el->

calentamiento-del-sistema-climatico-es-inequivocoaspectos-mas-destacados-del-cuarto-informe-de

© 2024 por los autores. Este artículo es de acceso abierto y distribuido según los términos y condiciones de la licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 Internacional (CC BY-NC-SA 4.0) (<https://creativecommons.org/licenses/by-nc-sa/4.0/>).