

# MODELADO DE REGÍMENES CLIMÁTICOS ESPACIO TEMPORALES EN LA SIERRA CENTRAL ECUATORIANA MEDIANTE CLÚSTERING DINÁMICO UTILIZANDO DATOS DE TEMPERATURA Y PRECIPITACIÓN DE LA NASA

**Spatiotemporal Modeling of Climate Regimes in the Central Ecuadorian Highlands Through Dynamic Clustering Using NASA Temperature and Precipitation Data**

 <sup>1</sup> Geovanny Miranda\*

 <sup>2</sup> Cristina Ramos

<sup>1</sup> Escuela Superior Politécnica de Chimborazo, Informática y Electrónica, Riobamba, Ecuador.

<sup>2</sup> Escuela Superior Politécnica de Chimborazo, Ciencias, Riobamba, Ecuador.

\* wilson.miranda@epoch.edu.ec

## RESUMEN

El cambio climático se ha evidenciado en la Sierra Central de Ecuador, donde la compleja topografía andina es afectada por variaciones climáticas. Este estudio utilizó datos diarios espaciales de temperatura máxima (CHIRTS) y precipitación (CHIRPS) para identificar y modelar los regímenes climáticos de la región mediante clustering dinámico. La técnica empleada demostró una alta eficacia de separación de grupos, de acuerdo a los índices de clasificación de temperatura y precipitación de 0,98% y 0,99%. Se identificaron cuatro tipos de clima (WT) en cuanto a temperatura y precipitación. El WT2 presentó condiciones térmicas moderadas, pero no extremos características de las regiones como la Costa y la Amazonía. También el WT4 presentó temperaturas bajas frecuentes y escasa presencia de eventos térmicos extremos, un régimen climático propio de la Sierra Central especialmente en zonas de alta montaña. Se observó que la precipitación fue poco frecuente pero constante en zonas andinas (WT1), mientras que los (WT2 y WT3) presentó precipitaciones escasas pero frecuentes en las regiones más áridas como la región Costa y Sierra Sur. Los hallazgos contribuyen a una comprensión espacial y temporal del clima de la región, lo cual es esencial para la planificación ambiental y la gestión del cambio climático.

**Palabras claves:** *Clúster dinámico, precipitación, temperatura, clima, ecosistema, andes tropicales.*

## ABSTRACT

Climate change has been evident in the Central Sierra of Ecuador, where the complex Andean topography is affected by climatic variations. This study used daily spatial data of maximum temperature (CHIRTS) and precipitation (CHIRPS) to identify and model the region's climate regimes using dynamic clustering. The technique demonstrated high cluster separation efficiency, based on temperature and precipitation classification indices of 0.98% and 0.99%. Four climate types (WT) were identified in terms of temperature and precipitation. WT2 presented moderate thermal conditions, but not the extremes characteristic of regions such as the Coast and the Amazon. WT4 also presented frequent low temperatures and scarce occurrence of extreme thermal events, a climate regime characteristic of the Central Sierra, especially in high mountain areas. Precipitation was observed to be infrequent but constant in Andean areas (WT1), while WT2 and WT3 presented scarce but frequent precipitation in more arid regions such as the Coast and Southern Sierra. The findings contribute to a spatial and temporal understanding of the region's climate, which is essential for environmental planning and climate change management.

**Keywords:** *Dynamic cluster, precipitation, temperature, climate, ecosystem, tropical andes.*

## I. INTRODUCCIÓN

El cambio climático global, ocasionado por el aumento de gases de efecto invernadero como dióxido de carbono, metano y óxidos nitrosos, está alterando el equilibrio climático del planeta (1). Se proyecta un aumento de la temperatura global entre 1,5 y 4,5 °C en los próximos años, acompañado de cambios en los patrones de precipitación y temperatura generando grandes cambios en los ecosistemas (2). Estos cambios traen impactos catastróficos, como la expansión de enfermedades, inundaciones y sequías prolongadas, tormentas intensas, pérdida de la biodiversidad y la agricultura (3,4).

Ecuador se caracteriza por una compleja geografía debido a la presencia de la Cordillera de los Andes, que atraviesa el país de norte a sur y la divide en tres regiones Costa, Sierra y Amazonía, generando una distribución irregular de las precipitaciones y variaciones de temperatura (5). En términos de topografía, la diversidad de suelos, que van desde volcánicos hasta arenosos, aumenta la susceptibilidad de la agricultura y los ecosistemas a la erosión y la pérdida de calidad debido a fenómenos climáticos extremos (6). La variada orografía del país, en las zonas montañosas, contribuye a una gran diversidad ecológica, pero también dificulta la adaptación de las comunidades y ecosistemas a los efectos del cambio climático (7).

La influencia del fenómeno de El Niño Southern Oscillation (ENSO) como factor determinante en la variabilidad climática en el Ecuador. Este fenómeno se manifiesta en dos fases constantes: la fase cálida (El Niño), caracterizada por el calentamiento de las aguas del Pacífico ecuatorial, generando un aumento de las precipitaciones en algunas regiones, provocando efectos extremos como inundaciones. En contraste, la fase fría (La Niña), representa el comportamiento opuesto asociado con el enfriamiento de las aguas del Pacífico, ocasionando una notable disminución de las precipitaciones, dando lugar a sequías pronunciadas (8–10). Estos factores influyen directamente sobre el cambio climático, afectando tanto a su biodiversidad como a la vida de sus habitantes y dificultando la implementación de estrategias de adaptación y mitigación efectivas (11).

Los regímenes climáticos son patrones recurrentes que describen la variabilidad climática, de

manera espacial y temporal, a escalas mayores que las observaciones meteorológicas (12,13). Estos regímenes han sido estudiados mediante los métodos de clasificación. El primer método de clasificación climática fue desarrollado por Koppen, quien consideró los cambios temporales en la distribución geográfica de los tipos de clima a escala global y regional (14). Actualmente, los métodos de clustering (agrupamiento) se han convertido en herramientas valiosas para el estudio de estos regímenes climáticos, identificando los tipos de clima o Weather Types (WT), que agrupan los datos climáticos según patrones de circulación recurrentes. Cada grupo representa un estado disponible del sistema atmosférico, definido como una configuración que ocurre con cierta frecuencia en un período de tiempo determinado (15). Estas configuraciones se reconocen como regiones de alta densidad de visitas, o regiones que el sistema atmosférico tiende a visitar repetidamente. Estos grupos de datos representan tipos de circulación diaria, son definidos estadísticamente a partir de las configuraciones recurrentes de la circulación atmosférica (16,17).

Para caracterizar las principales condiciones atmosféricas de la región, el presente estudio examina los tipos de clima recurrentes (Tipos de Clima, WT) en la Sierra Central del Ecuador. Para ello, se aplica un agrupamiento dinámico a datos satelitales de la NASA sobre temperatura y precipitación. Se utilizan métricas como el índice de codo, el coeficiente de silueta y el índice de clasificabilidad para evaluar la estabilidad y representatividad de los grupos. Además, se realiza un análisis estadístico exhaustivo para profundizar en la variabilidad espaciotemporal de las regiones climáticas identificadas.

Además, los métodos de clustering han sido utilizados para analizar imágenes satelitales y series temporales climáticas, permitiendo caracterizar los patrones recurrentes espaciales de la circulación atmosférica, comparación de modelos, detección y diagnósticos de sesgos sistemáticos y tipos de clima (16,17).

## II. MATERIALES Y MÉTODOS

Los datos de la NASA (<https://www.chc.ucsb.edu/data>), incluyen los productos CHIRPS (Climate Hazards Group InfraRed Precipitation with Station

Data) y CHIRTS (Climate Hazards Group InfraRed Temperature with Station Data), los cuales fueron proporcionados por el proyecto de investigación “Predecir patrones de comportamiento climático mediante técnicas de aprendizaje automático para la provincia de Chimborazo” del Grupo de Investigación de Energías Alternativas y Ambiente (GEAA) de la Escuela Superior Politécnica de Chimborazo. Estos conjuntos de datos son de información satelital, permitiendo estimaciones aproximadas de precipitación del año 1980 a 2025 y temperatura máxima del año 1980 a 2016. La resolución temporal es diaria y la resolución espacial cubre un rango de longitud de -79° a -77° y latitud de -3° a -1°. Estos datos son apropiados para los análisis climáticos tanto globales como regionales.

## II.I Análisis estadístico

Se emplearon métodos estadísticos descriptivos e inferenciales para el análisis y tratamiento de la información climática. Además, se evaluó el número óptimo de conglomerados mediante el método de codo y de silueta, estos métodos determinan la validez de un método de agrupación mediante un índice interno que no requieren información externa y evalúan la cohesión y la separación de conglomerados mediante la distancia euclíadiana y algoritmo de K-means (18).

El método de codo calcula la suma de cuadrados dentro de los clústeres para cada K número de clúster, mide cuán cerca están los puntos del centro del clúster, donde el punto de suma de cuadrado de clúster deja de disminuir de manera considerable ese punto se identifica visualmente como un codo, es decir a partir de  $k = n$  la tendencia disminuye y nos permite identificar el número óptimo de clúster de acuerdo a la **Ecuación 1** (18).

$$WSS = \sum_i \sum_{x \in C_i} (x - m_i)^2 \quad (1)$$

Donde  $m_i$  es el centroide de clúster  $C_i$

El método de silueta se determina dividiendo la medida de separación entre la medida de cohesión y restando ese valor por 1 si la medida de separación es mayor que la medida de cohesión, o por 1 restado al valor de la medida de cohesión dividido por la medida de separación si la cohesión es mayor según la **Ecuación 2 y 3**. Cuanto mayor sea el coeficiente de silueta, mejor

será el grupo, se emplea clustering para varios valores de K clúster, calculando el coeficiente de silueta para cada punto, el número óptimo de clúster se identifica visualmente cuando el promedio del coeficiente alcanza su punto máximo antes de comenzar a descender (18).

$$s = 1 - \left( \frac{\text{medidadecohesión}}{\text{medidadeseparación}} \right) \quad (2)$$

Si cohesión < separación

$$s = \left( \frac{\text{medidadecohesión}}{\text{medidadeseparación}} \right) - 1 \quad (3)$$

Si cohesión > separación

## II.II Clústering Dinámico

El algoritmo de clustering dinámico es una técnica de aprendizaje no supervisada para la segmentación de datos en grupos homogéneos que aglomera datos en k clúster según la **Ecuación 4**, minimizando la varianza interna de cada grupo. Se basa en la reasignación progresiva de puntos hasta alcanzar una partición estable, donde la función objetivo a minimizar es la suma de varianzas dentro de los clústeres.

$$W(P) = \sum_{j=1}^k \sum_{x \in C_j} d^2(x, Y_j) \quad (4)$$

Donde  $Y_j$  es el centro de clúster  $C_j$  y  $d(x, Y_j)$  es la distancia euclíadiana entre un punto  $x$  y su centroide asignado y se define de acuerdo a la **Ecuación 5**:

$$d(x, Y_{j,i}) = \sqrt{\sum_{i=1}^n (d(x, Y_{j,i}))^2} \quad (5)$$

Donde  $n$  es la cantidad de dimensiones de los datos (temperatura y precipitación),  $x_i$  es la coordenada  $i$  del punto  $x$ , y  $Y_{j,i}$  es la coordenada correspondiente del centroide (12,16).

El algoritmo dinámico inicia a escoger aleatoriamente las semillas, después a la asignación de puntos a los centroides y el ajuste iterativo de la partición hasta que la suma de variaciones en los clústeres  $W(P)$  se acerca a su nivel más bajo. Es decir, cuando el algoritmo converge en función de  $W(P^{(n)})$  con  $k$  centroides  $Y_j^{(n-1)}$  que mide la suma de las variaciones entre

los clústeres, no cambia entre iteraciones. En otras palabras, cuando una parte  $W(P^{(n-1)})$  se pasa a  $W(P^{(n)})$  los puntos ya no se resignan a diferentes centroides y como resultado, la partición permanece igual. Esto indica que se ha alcanzado un mínimo local de  $W$ , y el algoritmo se detiene (converge) automáticamente.

Para medir la igualdad entre las particiones, se emplea el coeficiente de correlación (ACC) o también conocida de correlación de patrones, que establece cuán reproducible es una partición al cotejar diferentes particiones del mismo conjunto de datos, para identificar patrones de comportamiento o tipo de clima por sus siglas en inglés (WT) (12,16).

Dados dos clústeres  $P$  y  $Q$  en  $k$  del mismo conjunto de datos, la matriz se calcula de acuerdo a la **Ecuación 6**:

$$A_{ij} \text{ Donde } i = 1, \dots, k; j = 1, \dots, k \quad (6)$$

Donde los valores coeficiente de correlación (ACC) entre el clúster  $i$  de la partición  $P$  y el clúster  $j$  de la partición  $Q$  para cada fila  $i$  de la matriz  $A$ , se determina el valor máximo y se define:  $A'(i)$  se encuentra para el grupo de  $Q$  que mejor se ajusta al  $i$ -ésimo clúster  $P$ .

Por otro lado, el valor mínimo de  $A'$ , denotado por  $c(P, Q)$ , corresponde al clúster de que  $P$  que tiene menor correlación en  $Q$  y es una medida de la similitud entre las dos particiones. Cuando las dos particiones son idénticas  $c(P, Q)=1$  lo que significa que cada grupo en  $P$  contiene una correlación perfecta en  $Q$ , e indica máxima estabilidad en la clasificación; por el contrario, si el valor es bajo, al menos un grupo en  $P$  no parece estar en ninguno de  $Q$ , lo que muestra poca coincidencia o inestabilidad entre los grupos por (12,19).

El rendimiento de la clasificación se mide según la **Ecuación 7** mediante el coeficiente de correlación de patrones  $P_{ij}$  entre pares de centroides de clúster  $\bar{p}_i$  y  $\bar{q}_j$  en las particiones  $P$  y  $Q$ , respectivamente, lo que permite calcular la matriz  $P[P(K), Q(K)]$  con elementos dados por (12,19):

$$p(\bar{p}_i, \bar{q}_j) = \frac{\sum_m \bar{p}_i \bar{q}_j}{\sqrt{\sum_m \bar{p}_i^2 \sum_m \bar{q}_j^2}} \quad \forall i, j = 1 \dots K, \quad (7)$$

Donde las sumas consideran todos los  $M$  puntos de la cuadrícula en el dominio, y las desviaciones de los puntos de la cuadrícula se calculan de acuerdo a la Ecuación 8 y 9 (12,19):

$$\bar{p}_c = \bar{p}_c - \frac{1}{K} \sum_r^k \bar{p}_{rm} \quad (8)$$

$$\bar{q}_c = \bar{q}_c - \frac{1}{K} \sum_r^k \bar{q}_{rm} \quad (9)$$

Donde el valor de  $m = 1 \dots M$ . El valor máximo de la  $i$ -ésima fila del  $K \times K$ . La matriz  $p$  en la ecuación representa el grupo en  $Q$  que mejor se ajusta al  $i$ -ésimo grupo en  $P$ . Si las dos particiones son idénticas, por supuesto  $p = 1$ , cuando el índice de clasificabilidad (CI) es más se acerca a 1 el modelo es adecuado y la partición se considera clasificable y robusta (12,19). Se utilizó este algoritmo para analizar las variaciones del régimen climático utilizando datos de precipitación y temperatura máxima, lo que facilita una categorización precisa de los patrones climáticos en la zona de estudio.

## II.III Fuentes

Se empleó Jupyter Notebook de Python 3.12.3 para el desarrollo y ejecución de los algoritmos implementados. El análisis y procesamiento de datos de estudio se realizó en sistema operativo Windows 11 con un procesador Core i7 y con una memoria RAM de 8 GB, de esta forma se garantizó el manejo de datos y los cálculos informáticos apropiados, se utilizaron bibliotecas de Python. Los Datos y el código fuente utilizados para la investigación están disponibles en GitHub (20).

## III. RESULTADOS

### III.I Análisis estadístico

Se realizó el análisis estadístico exploratorio con la finalidad de evaluar la calidad y consistencia del conjunto de datos de temperatura máxima y precipitación. Este proceso permitió identificar posibles valores atípicos, tendencias estacionales y patrones de variabilidad, garantizando que los datos estén en condiciones óptimas para su posterior modelado. La verificación de la integridad de los datos garantiza la solidez metodológica del estudio y respalda la fiabilidad de los hallazgos.

### III.I.I Temperatura máxima

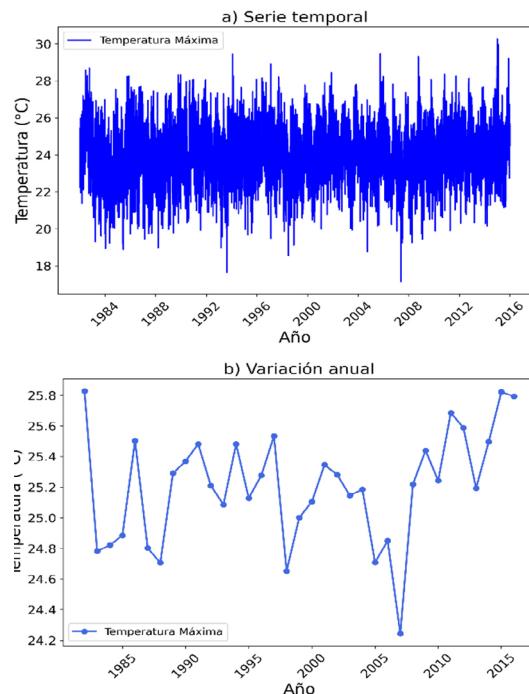


Figura 1: Serie temporal y variación anual de temperatura máxima.

Se analizó la variabilidad de la temperatura máxima como se muestra en la **Figura 1 (a)**, donde se identificaron picos elevados en los años 1982, 1983, 2006 y 2015 asociados al incremento en las temperaturas máximas. En 1982 se presentó el promedio anual más alto con 25.98°C en comparación a los demás años del período de estudio. Por otro lado, en 1993 y 2007 se registraron picos bajos que reflejan eventos de temperaturas extremas inferiores a 18°C. En cambio, la variación interanual, como se representa en la **Figura 1 (b)**, muestra una alta variabilidad interanual, sin evidenciar una tendencia del aumento y disminución de temperaturas máximas durante el período analizado (prueba de Mann-Kendall  $p > 0.05$ ). Mientras que en 2008, se muestra un aumento considerable de 0.98 °C, el cual presenta la mayor variación anual de temperatura máxima en comparación a los demás años del período analizado.

Las fluctuaciones térmicas correspondientes a los años más representativos del período analizado de temperatura máxima se muestran en la **Figura 2**. Se evidenció que la variabilidad térmica en la región Sierra Central presentó un comportamiento estable que no experimentó temperaturas extremas a lo largo del tiempo, sin

cambios notables entre períodos. Por otro lado, en las regiones Costa y Amazonía, se identificaron patrones térmicos de temperaturas elevadas. La influencia del gradiente regional de temperatura y la modulación natural causada por el relieve andino y la latitud ecuatorial fue evidente en la región Sierra.

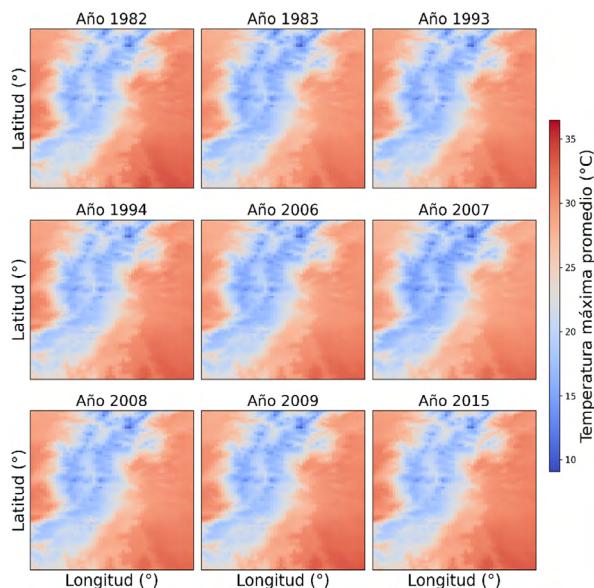


Figura 2: Mapa de calor de promedio anual de las fluctuaciones de temperatura.

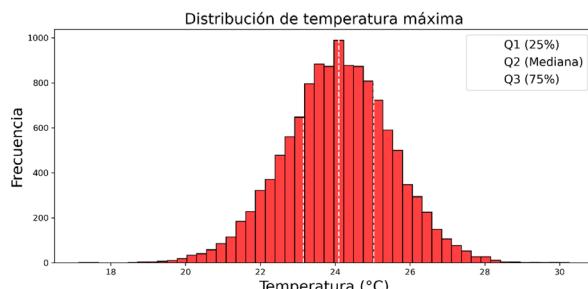


Figura 3: Distribución de los datos.

La distribución de la temperatura máxima de la Sierra Central se presenta en la **Figura 3**, que muestra una forma aproximadamente simétrica y cercana a una distribución normal. La media registrada es de 24.07°C durante los últimos 36 años, y la mediana Q2 es de 24.09°C, lo que respalda la simetría de la distribución, mientras que el tercer cuartil (Q3) de 25.03°C y el primer cuartil (Q1) de 23.15°C muestran una distribución centrada de los datos alrededor de la mediana. Esta concentración se evidencia con una variación de 1.74 °C que indica menor variabilidad de valores extremos con un mínimo de 17.5°C y un máximo de 30.26°C.

### III.I.II Temperatura máxima

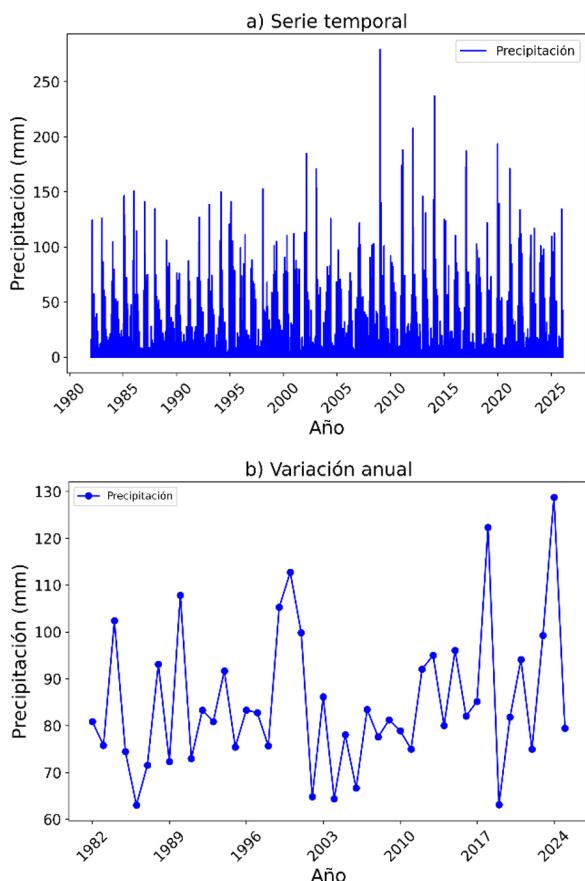


Figura 4: Serie temporal y variación anual de precipitación.

La serie temporal de precipitación diaria se muestra en la **Figura 4 (a)**. La gráfica refleja la evolución diaria de la precipitación acumulada al largo de 45 años, se observan picos pronunciados que superan los 60 mm, lo que evidencia la ocurrencia de eventos de precipitación intensa en determinados períodos, en algunos años presentan valores superiores al promedio histórico. En particular, en el año 2009, se registró el promedio anual más alto, con 256.83 mm, lo que indica la presencia de precipitaciones extremas. Asimismo, no se identifica una tendencia en los valores de precipitación. La **Figura 4 (b)**, que indica el comportamiento de la precipitación anual, permitiendo observar patrones a largo plazo. Los valores fluctúan entre mínimo a 70 mm y mayor a 120 mm, corroborando una alta fluctuación interanual. Se identifican períodos de pocas precipitaciones, asociadas a sequías, así otros períodos, con precipitaciones elevadas, vinculadas a eventos de lluvias extensas.

Además, en el año 2024 en particular, con

una desviación de 128.73 mm, muestra la mayor variabilidad registrada respecto al resto del período. Las variaciones regionales de precipitación se muestran en la **Figura 5**. La región amazónica presenta altos valores de precipitación en todos los años de estudio, con una notable diferencia en el año 2000 y en el año 1992. En la región costa se visualiza precipitaciones moderadas, mientras que la región de la Sierra Central experimenta bajas precipitaciones.

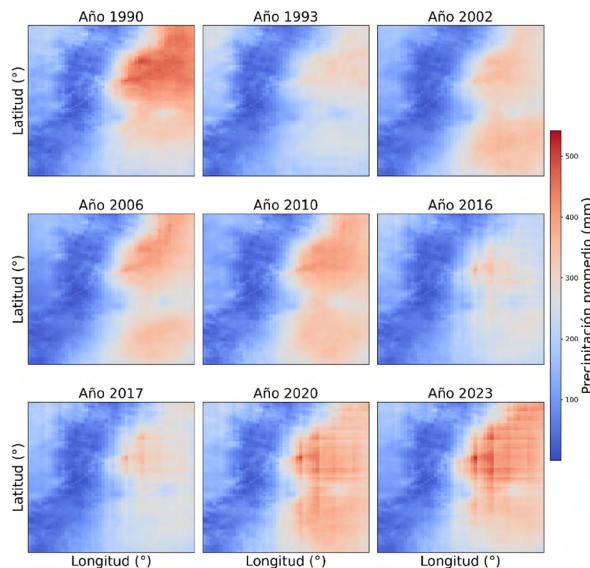


Figura 5: Mapa de calor de promedio anual de las fluctuaciones de precipitación.

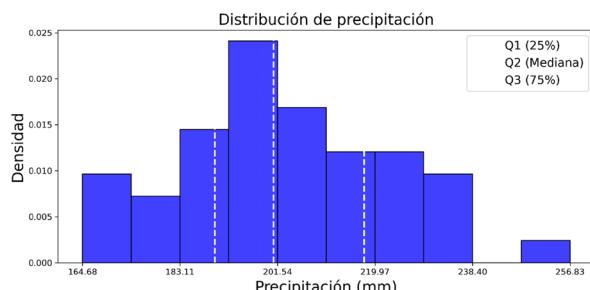


Figura 6: Distribución de datos de precipitación.

Durante el período 1982-2025, el análisis de la distribución de Sierra Central de la precipitación se evidenció un comportamiento asimétrico, diferente a una distribución normal como se muestra en la **Figura 6**. La media anual fue de 202.94 mm y una varianza de 41.33 mm que indica que la precipitación es variable, los valores están lejos del promedio y existe fluctuaciones. Los valores del primer cuartil con 189.71 mm y el mínimo de 164.68 mm están asociados con eventos de precipitaciones intensas o condiciones secas. Por lo tanto, el tercer cuartil de 217.93 mm

y el máximo de 256.83 mm indicaron precipitación de mayor intensidad de períodos extremos.

### III.II Clustering dinámico

Mediante el clustering dinámico basado en el algoritmo k-means, se identificaron los tipos de clima (WT) en la Sierra Central del Ecuador. Se realizaron 21 simulaciones, manteniendo un número fijo de clústeres ( $n = 4$ ) y variando las semillas aleatorias en cada ejecución para asegurar la coherencia y robustez de los resultados. A partir de estas simulaciones se entrenó el modelo utilizando una única iteración para obtener los agrupamientos adecuados. Asimismo, se evaluó la coherencia interna de los clústeres mediante el índice de clasificabilidad, seleccionando las configuraciones más representativas. Por último, los datos fueron etiquetados según el tipo de clima (WT) y se calculó la frecuencia de recurrencia en cada agrupamiento.

#### III.II.I Análisis de Componentes Principales (PCA) de temperatura máxima y precipitación.

Se realizó un análisis PCA para simplificar el número de variables (dimensión), manteniendo la mayor cantidad posible de su variabilidad. El índice de variabilidad del 80% se considera adecuado, mientras que los valores cercanos al 90% sugieren que la reducción dimensionalidad preserva casi toda la información pertinente mientras minimiza la pérdida de varianza y se considera adecuado y coherente para el estudio.

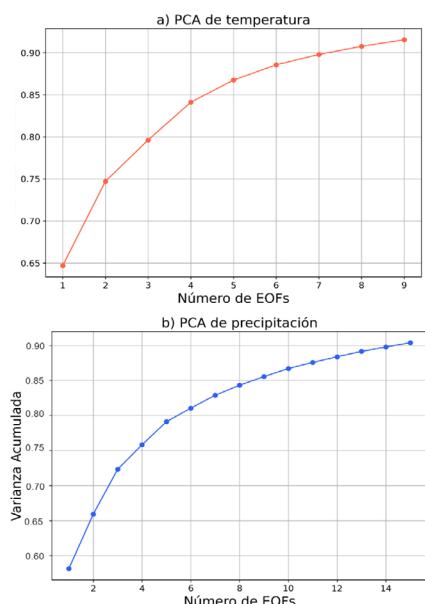


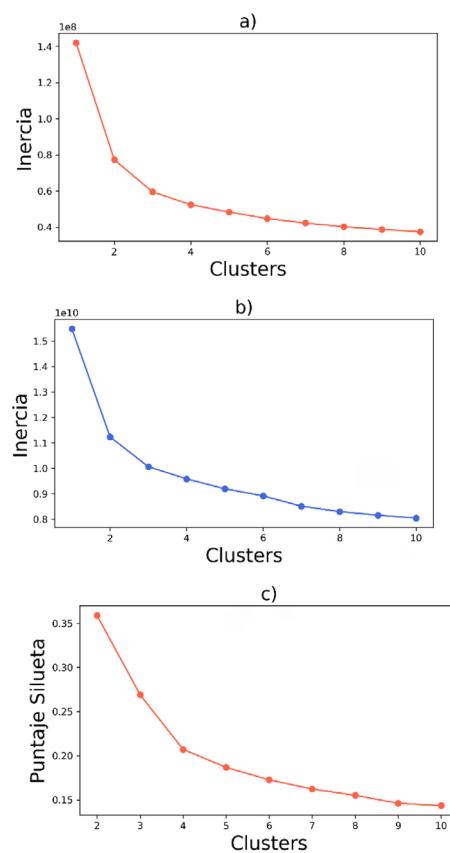
Figura 7: Componentes principales de temperatura máxima y precipitación

De acuerdo con el análisis de componentes principales aplicado a la temperatura máxima reveló que los siete componentes explican el 90 % de la variabilidad total como se muestra en la **Figura 7 (a)**. En cambio, para la variable precipitación, nueve componentes principales explican el 85% de la variabilidad como se evidencia en la **Figura 7 (b)** lo que presenta una alta capacidad de representación del modelo. Este proceso de reducción de dimensionalidad permite identificar patrones latentes en los datos, optimizando la clasificación posterior mediante clustering al reducir el ruido y mejorar la interpretabilidad de los grupos climáticos.

#### III.III Determinación del número óptimo de clustering

El número óptimo de grupos para la temperatura máxima y precipitación se determinó mediante las métricas del método del codo y coeficiente de silueta. Estas herramientas permitieron encontrar una segmentación coherente y grupos bien definidos, mejorando la estructura de los agrupamientos y la interpretación de los patrones climáticos encontrados en la Sierra Central del Ecuador.

Número Óptimo de Clusters: Temperatura y Precipitación



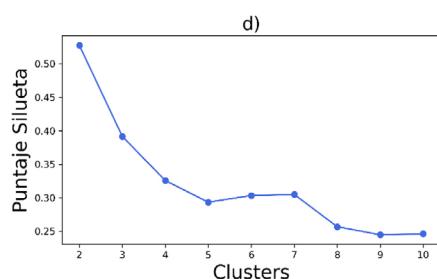


Figura 8: Gráfico de codo y silueta de temperatura máxima y precipitación.

El gráfico de codo de temperatura máxima y precipitación como se muestra en la **Figura 8 (a,b)**, la inercia disminuye gradualmente a partir del componente 4; por lo tanto, el número óptimo de clustering a clasificar es 4. Por otro lado, se utilizó el coeficiente de silueta, que se muestra en la **Figura 8 (c,d)**, para validar el número de agrupamiento obtenido mediante el método codo. Ambas métricas respaldan que cuatro grupos permiten la mejor separación y coherencia de los datos, lo que garantiza una segmentación espacial y temporal adecuada para el análisis de patrones de comportamiento mediante el método de clustering dinámico.

### III.IV Patrones de recurrencia Temporal

El diagrama de Klee y la variabilidad interanual permitió identificar y analizar patrones de comportamiento de los tipos de clima (WT) de temperatura máxima y precipitación a lo largo del período. El diagrama de Klee muestra la distribución temporal diaria y la recurrencia de cada WT. Además, la variabilidad interanual permitió analizar la variabilidad interanual de cada WT, permitiendo identificar períodos con mayor frecuencia de ocurrencia de tipos climáticos. Estas representaciones proporcionaron una visión integrada del espacio-temporal en la región Sierra Central.

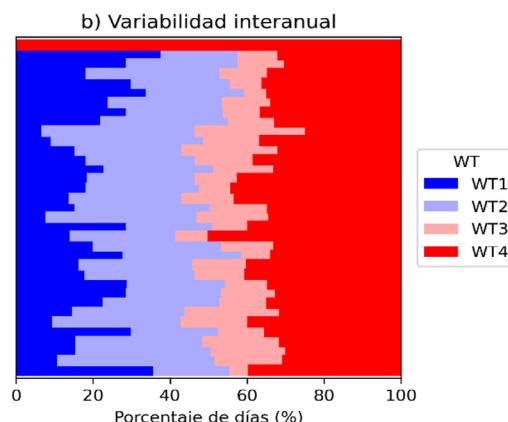
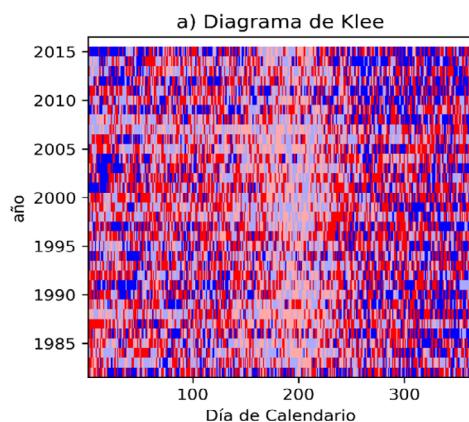


Figura 9: Tipos de clima de temperatura máxima.

Se identificarán 4 tipos de clima para la variable temperatura, como se muestra en la **Figura 9 (a)**, donde el WT1 representa el 20.58 % de frecuencia de ocurrencia de los días de temperaturas extremas, con una media de 26.91°C, y una desviación estándar de 5.37°C, lo que representa mayor dispersión de temperatura, como los días secos. El WT2, que representa días con temperaturas moderadamente cálidas, con el 29.82% de ocurrencia con una media de 24.47°C y una desviación estándar de 4.96°C, mostrando una variabilidad de temperatura intermedia, característica de la época húmeda. Por otro lado, el WT3 con un porcentaje menor de 13.72% con días de ocurrencia poco frecuente, asociados a temperaturas frías con una media de 23.07°C y una dispersión de 8.88°C. Estas condiciones pueden estar asociadas a días lluviosos, propios de eventos climáticos como La Niña, que tienden a aumentar las precipitaciones y el calor en los Andes, disminuyendo la radiación solar y en consecuencia a las temperaturas máximas.

El WT4 con un alto porcentaje de 35.93%, abarca la mayoría de los días, con una media de 25.61°C tiende a ser más frecuentes y más persistentes. El comportamiento de este grupo puede estar relacionado con las estaciones climáticas de la zona: los días secos y los días lluviosos, que en algunas fases puede resultar en un aumento de la temperatura y cambios en los patrones de circulación atmosférica, favoreciendo una disminución de la temperatura máxima en las regiones andinas.

La frecuencia diaria de cada régimen se muestra en la **Figura 9 (b)** que proporciona condiciones climáticas frecuentes. El tipo de clima WT4 y el WT2 presentan las mayores frecuencias de ocurrencia, lo que indica que son las más

persistentes a lo largo del período analizado. Estos WT se asocian a temperaturas moderadas, en comparación con los demás regímenes, lo que sugiere su relevancia en la configuración climática predominante de la Sierra Central.

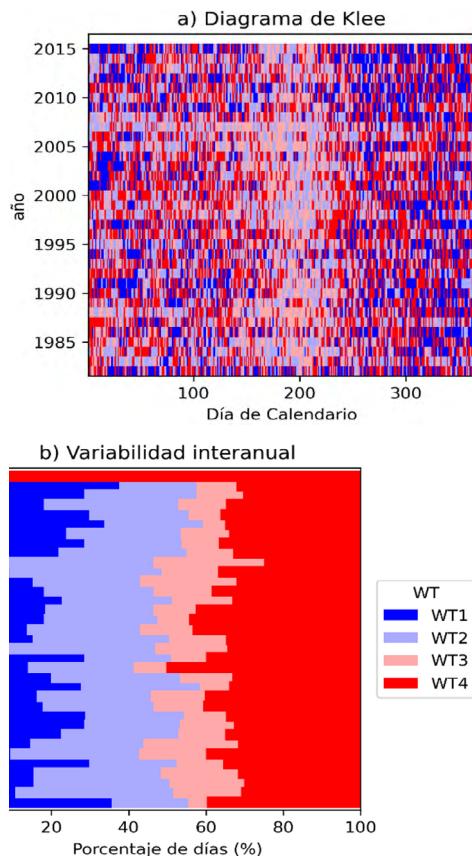


Figura 10: Tipo de clima de precipitación

En la **Figura 10 (a)**, se muestra cómo se distribuye los patrones de comportamiento de precipitación a lo largo del período asociado a los patrones de precipitaciones bajas y frecuentes. El WT1, con 64.26% de los días, el más dominante asociado a precipitación baja, con una media de 2.02 mm/día y una desviación estándar de 0.99 mm representa días de lluvias ligeras pero frecuentes, relacionada a la estación climática de días secos. El WT2 con 9.16% representa eventos extremos o precipitaciones intensas con una precipitación media de 42.34 mm/día y una desviación estándar de 28.57 mm/día, relacionada a eventos extremos como el ENSO, el WT3 con 24,62% representan precipitación media de 22.36 mm/día, asociados a lluvias moderadas influenciadas por la estación climática de días lluviosos. Por último, el WT4, el menos frecuente con 1.96%, y 10.10 mm/día relacionado con lluvias moderadas características de la zona andina.

La frecuencia diaria de cada régimen se muestra en la **Figura 10 (b)** asociada a condiciones climáticas de precipitación baja pero frecuente, donde el WT1 representan mayor frecuencia de ocurrencia en comparación con los demás WT, reflejando una ausencia de lluvias en Sierra Central en el período desde 1980 hasta 2025.

### III.V Representación espacial-temporal de los tipos de clima WT en la región central de Ecuador

El análisis espacial temporal mediante el clustering dinámico reveló patrones climáticos irregulares en la Sierra Central del Ecuador durante el período analizado. Esta variedad está influenciada por factores como la topografía, la altitud y la latitud, que actúan como barreras naturales y modula la distribución del clima. Por lo tanto, el análisis espacial de la temperatura máxima y la precipitación reveló patrones propios que muestran cómo estos factores geográficos afectan la dinámica climática regional.

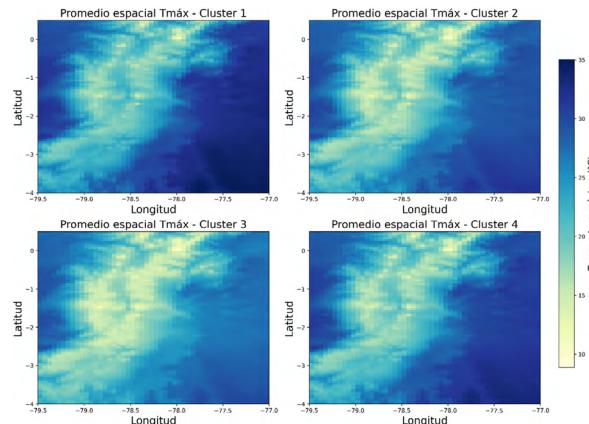


Figura 11: Distribución de los WT de temperatura en la sierra ecuatoriana.

Los tipos de clima (WT) identificados a través del clustering dinámico de la temperatura máxima diaria en la región como se muestra en la **Figura 11**, reveló una segmentación adecuada, sustentada por el índice de clasificabilidad de 0.87, lo que demostró una clasificación bien estructurada y coherente. Durante el período analizado se muestran variaciones estacionales en cada clúster. Como se evidencia en el Clúster 1 (WT1) el dominio del color azul celeste refleja las temperaturas más altas superiores a 30°C, principalmente en la región Costa y las zonas interandinas de baja altitud (longitud -79.5 y -78.0; latitud (-3.5 y 1.0), así como condiciones

poco frecuentes de días muy calurosos o fríos. Por otro lado, el Clúster 2 (WT2) presentó tonalidades amarillo-verdosas, lo que se asocia a temperaturas moderadas y constantes (20-28°C) distribuidas por los valles andinos, así como la Amazonía y la región Costa, que forman parte de períodos de transición. Además, el Clúster 3 (WT3) muestra una mezcla de color azul y verde, con temperaturas que oscilan entre los 15 y los 22°C características de días fríos, pero poco frecuentes, que ocurren en regiones áridas de la Costa y la Amazonía, posiblemente debido a lluvias prolongadas. Mientras que el Clúster 4 refleja las temperaturas más frías por debajo de los 15°C representados por tonos blanco azulados, particularmente en regiones de alta montaña de la Sierra centro-sur influenciada por la altitud y las frecuentes masas de aire frío situadas en zonas geográficas latitud (-4.0 y -2.0).

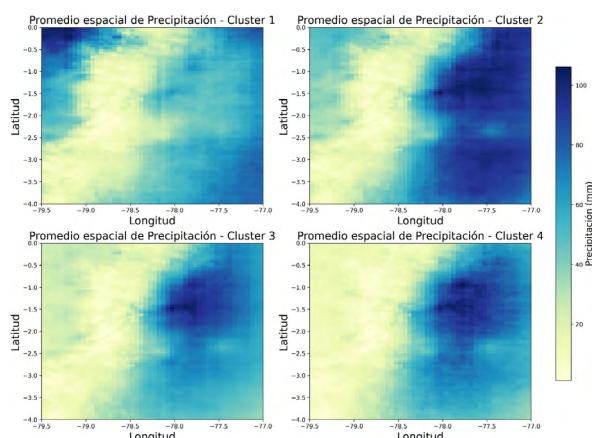


Figura 12: Distribución de los WT precipitación en la sierra ecuatoriana.

Mediante el clustering dinámico se demostró una segmentación de grupos bien definidos de patrones de comportamiento de precipitación como se muestra en la **Figura 12**, sustentada por el índice de clasificabilidad de 0.99. Uno de los casos más representativos es el Clúster 1 (WT1) representado por el color amarillo claro, que se caracteriza por precipitaciones ligeras pero frecuentes con valores promedio por debajo de 23 mm/día, propios de las regiones interandinas ubicadas en longitud (-78.5 y -77.5) y latitud (-3.5 y -1.0) y de una parte de la región amazónica, donde la influencia de la humedad orográfica es más prevalente. Por otro lado, los Clústeres 2 y 3 (WT2 y WT3) presentó una tonalidad azul verdosa, lo que indica precipitaciones moderadas y poco frecuentes, asociadas a condiciones más áridas o irregulares que se encuentran

particularmente en la Costa y la Sierra Sur, donde las precipitaciones son menos concentradas y asociadas a días intermitentes. Por otro lado, el Clúster 4, caracterizado por un intenso color azul asociado a precipitaciones extremas superiores a 100 mm/día, se encuentra principalmente en la región amazónica, la costa norte y las zonas de transición climática de la Sierra Oriental que determinan eventos de lluvia intensa vinculados a fenómenos atmosféricos.

#### IV. DISCUSIÓN

Ecuador se describe por patrones de precipitación definidos por su relieve y orografía como las regiones: Sierra, Costa, Amazonía y región insular (21) que se alinean a los cuatro (WT) de precipitación encontrados mediante clustering dinámico. La influencia de las corrientes oceánicas y la existencia de regiones naturales como la Costa, la Sierra, y la Amazonía que dan lugar a una variedad de microclimas a lo largo del territorio nacional como se evidencia en estudios de Cornwall (22). De la misma forma, se ha observado fluctuaciones de temperatura y precipitación espacio-temporales, generando patrones atmosféricos cambiantes en zonas geográficas cercanas, identificando fenómenos naturales como El ENSO como los picos más pronunciados como resultado de esta dinámica climática (21,23,24).

Por otra parte, las precipitaciones en zonas andinas condicionan el régimen pluviométrico, favoreciendo contrastes entre las regiones expuestas al flujo de aire húmedo de la Amazonía, que puede registrar lluvias frecuentes e intensas, y los valles interandinos más secos (24–26). Este incremento en los niveles de precipitación se ha relacionado con la ocurrencia del ENSO como en los años 1982-1983 y 1997-1998, el cual intensificó la humedad atmosférica, especialmente en lo que respecta a la variabilidad interanual.

El clustering dinámico es ampliamente aplicado como en (12,19,21,27) para identificar la agrupación de los patrones de variables climáticas que proporciona una visión más clara y coherente del comportamiento climático en comparación con otros métodos, adaptándose a variaciones estacionales o fenómenos extremos que se presentan en el clima (16,17), se ha identificado cuatro tipos de clima (Weather Types, WT) para la región Sierra Central en base a

la variabilidad espacio-temporal de temperatura máxima y precipitación. A través del índice de clasificabilidad se validó la calidad del grupo, que confirmó una segmentación coherente y bien definida con valores de 0.99 para la precipitación y 0.98 para la temperatura máxima. Por lo tanto, estos hallazgos fueron consistentes con Diday y Simon (16), así como de Recalde (28), quienes emplearon metodologías similares en diferentes regiones y logran clasificaciones climáticas adecuadas, demostrando un método confiable para representar la complejidad climática en la región Sierra Central que proporciona una segmentación efectiva para la clasificación de patrones de comportamiento.

Los tipos de clima (WT) identificados en la región de Sierra Central de temperatura máxima confluyen con investigaciones como Buytaert (29), que resaltan la alta variabilidad interanual de la precipitación en la Sierra. La zona Andina se ve afectada por el ENSO en incremento de temperaturas de acuerdo con los estudios de Tobar y Wyseure (27). Los resultados obtenidos han mostrado WT1 con ocurrencia de 26.91%, destacando su persistencia y frecuencia con temperaturas más altas podrían ser asociadas al ENSO, particularmente en las regiones de alta montaña de la Sierra Central (30). Por el contrario, el WT2 y WT3, con una frecuencia de ocurrencia de 29.82% y 13.72%, están asociados a condiciones térmicas más moderadas asociadas a las estaciones climáticas típicas de la zona ecuatorial.

Mientras que, para precipitación, el WT1 con 64.26% de ocurrencia y 8054.53 mm que indica la presencia de precipitaciones ligeras pero frecuentes, características de los valles interandinos. Por otro lado, los WT3 con 24.62% de ocurrencia y 89027.68 mm están asociados a precipitaciones de mayor intensidad y de poca frecuencia, el WT2 con 9.16% de ocurrencia y 168650.06 mm está relacionado con intensas precipitaciones poco frecuentes observadas en la estación climática lluviosa de febrero a mayo, octubre y noviembre influenciadas por la corriente de aire húmedo del Atlántico y la cuenca del Amazonas (31). Estos resultados demuestran la diversidad climática de patrones de recurrencia temporal de la región y las estaciones climáticas de la zona: días lluviosos y días secos en un periodo de junio a septiembre que es más fuerte que el segundo periodo alrededor de diciembre.

Los resultados de este estudio han permitido determinar patrones de comportamiento climático de temperatura máxima y precipitación en la región Sierra Central. Esta clasificación esta representada por la variabilidad espacial y temporal de los datos de las variables climáticas estudiadas, proporcionando información para la gestión de los recursos hidrológicos y la adaptación al cambio climático en zonas vulnerables. La identificación de tipos de clima con patrones recurrentes asociados a incrementos de temperatura y precipitación es significativa para la planificación agrícola y el monitoreo de riesgos naturales. Estos hallazgos resaltan la importancia de incorporar datos satelitales de la NASA y las herramientas de aprendizaje automático para la identificación de patrones de comportamiento en las regiones climáticas Andinas.

## V. CONCLUSIONES

En el período analizado, la temperatura máxima mostró alta variabilidad interanual, con picos cálidos asociados al ENSO (1982, 1983, 2006, 2015) y descensos puntuales en 1993 y 2007, sin evidenciar una tendencia significativa (prueba de Mann-Kendall  $p > 0.05$ ). Espacialmente, la Sierra Central mantuvo un régimen térmico estable, mientras que en la Costa y Amazonía predominaron anomalías cálidas, moduladas por el relieve andino y la latitud ecuatorial.

Con índices de clasificabilidad superiores a 0.98 que validan la robustez metodológica del clustering dinámico permitió determinar cuatro tipos de clima (WT) en la región Sierra Central, reflejando la complejidad espacio-temporal de la temperatura máxima y la precipitación. Estos hallazgos son consistentes con estudios previos y demuestran que el método constituye una herramienta confiable para representar patrones climáticos en regiones andinas.

Los WT identificados evidencian la influencia determinante de las características morfológicas y topográficas, de la misma manera, fenómenos de gran escala como el ENSO en la variabilidad climática del Ecuador. Mientras los valles interandinos presentan precipitaciones frecuentes pero ligeras, las zonas expuestas al flujo de aire húmedo amazónico registran lluvias más intensas y poco frecuentes, lo que confirma la diversidad de microclimas y la sensibilidad de la región Sierra Central

## VI. AGRADECIMIENTOS

Los autores expresan su profundo agradecimiento al proyecto de investigación "Predecir los patrones de comportamiento climático utilizando técnicas de aprendizaje automático en la provincia de Chimborazo" (IDIPI-306), del Grupo de Energías Alternativas y Ambiente (GEAA) de la Escuela Superior Politécnica de Chimborazo (ESPOCH) por su

apoyo en el desarrollo de esta investigación. Asimismo, se reconoce el respaldo cuya contribución fue fundamental para la realización de este estudio. En particular, se agradece a la Biof. Isabel Balvoa por su valiosa participación y aporte en el análisis de los resultados de esta investigación.

## VII. REFERENCIA

1. Filonchyk M, Peterson MP, Zhang L, Hurynovich V, He Y. Emisiones de gases de efecto invernadero y cambio climático global: examen de la influencia del CO<sub>2</sub>, CH<sub>4</sub> y N<sub>2</sub>O. *Sci Total Environ.* 2024;935:173359.
2. Vuille M, Bradley RS, Werner M, Keimig F. Cambio climático del siglo XX en los Andes tropicales: observaciones y resultados de modelos. En: Diaz HF, editor. *Climate Variability and Change in High Elevation Regions: Past, Present & Future* [Internet]. Dordrecht: Springer Netherlands; 2003 [cited 2025 Mar 16]. p. 75–99. Available from: [https://doi.org/10.1007/978-94-015-1252-7\\_5](https://doi.org/10.1007/978-94-015-1252-7_5)
3. Bolan S, Padhye LP, Jasemizad T, Govarthanan M, Karmegam N, Wijesekara H, et al. Impacts of climate change on the fate of contaminants through extreme weather events. *Sci Total Environ.* 2024;909:168388.
4. VijayaVenkataRaman S, Iniyan S, Goic R. A review of climate change, mitigation and adaptation. *Renew Sustain Energy Rev.* 2012;16(1):878–97.
5. Capa-Mora D, Medina J, Benítez Á, Jiménez Álvarez L. Perspectives on climate change and adaptation and mitigation measures amongst farmers of Zamora–Ecuador. *Clim Serv.* 2025;38:100565.
6. Toulkeridis T, Tamayo E, Simón-Baile D, Merizalde-Mora MJ, Reyes-Yunga DF, Viera-Torres M, et al. El cambio climático según académicos ecuatorianos: percepciones versus hechos. *La Granja.* 2020;31(1):21–46.
7. Cadilhac L, Torres R, Calles J, Vanacker V, Calderón E. Desafíos para la investigación sobre el cambio climático en Ecuador. *Neotrop Biodivers.* 2017;3(1):168–81.
8. Francou B, Vuille M, Favier V, Cáceres B. New evidence for an ENSO impact on low-latitude glaciers: Antizana 15, Andes of Ecuador, 0°28'S. *J Geophys Res Atmospheres* [Internet]. 2004 [cited 2025 Mar 11];109(D18). Available from: <https://onlinelibrary.wiley.com/doi/abs/10.1029/2003JD004484>
9. Sanabria J, Neukom R, Llacza A, Salzmann N, Calanca P. Representation of extreme El Niño events and associated atmospheric moisture flux divergence in the central-eastern tropical Pacific in a CMIP6 model ensemble. *Weather Clim Extrem.* 2025;47:100746.
10. Alexander MA, Vimont DJ, Chang P, Scott JD. The impact of extratropical atmospheric variability on ENSO: testing the seasonal footprinting mechanism using coupled model experiments. *J Clim* [Internet]. 2010 [cited 2025 Jul 23]. Available from: <https://journals.ametsoc.org/view/journals/clim/23/11/2010jcli3205.1.xml>
11. Millán H, Kalauzi A, Llerena G, Sucoshañay J, Piedra D. Climatic trends in the Amazonian area of Ecuador: classical and multifractal analyses. *Atmos Res.* 2008;88(3):355–66.
12. Michelangeli PA, Vautard R, Legras B. Weather regimes: recurrence and quasi stationarity. *J Atmos Sci* [Internet]. 1995 [cited 2025 Jun 25]. Available from: [https://journals.ametsoc.org/view/journals/atsc/52/8/1520-0469\\_1995\\_052\\_1237\\_wrraqs\\_2\\_0\\_co\\_2.xml](https://journals.ametsoc.org/view/journals/atsc/52/8/1520-0469_1995_052_1237_wrraqs_2_0_co_2.xml)

13. Laraque A, Ronchail J, Cochonneau G, Pombosa R, Guyot JL. Heterogeneous distribution of rainfall and discharge regimes in the Ecuadorian Amazon Basin. *J Hydrometeorol* [Internet]. 2007 [cited 2025 Jun 19]. Available from: [https://journals.ametsoc.org/view/journals/hydr/8/6/2007jhm784\\_1.xml](https://journals.ametsoc.org/view/journals/hydr/8/6/2007jhm784_1.xml)
14. Kottke M, Grieser J, Beck C, Rudolf B, Rubel F. World map of the Köppen-Geiger climate classification updated. *Meteorol Z*. 2006;15(3):259–63.
15. Netzel P, Stepinski T. On using a clustering approach for global climate classification. *J Clim* [Internet]. 2016 [cited 2025 Jul 2]. Available from: <https://journals.ametsoc.org/view/journals/clim/29/9/jcli-d-15-0640.1.xml>
16. Diday E, Simon JC. Clustering analysis. En: Fu KS, editor. *Digital Pattern Recognition* [Internet]. Berlin, Heidelberg: Springer; 1976 [cited 2025 Mar 3]. p. 47–94. Available from: [https://doi.org/10.1007/978-3-642-96303-2\\_3](https://doi.org/10.1007/978-3-642-96303-2_3)
17. Yokoi S, Takayabu YN, Nishii K, Nakamura H, Endo H, Ichikawa H, et al. Application of cluster analysis to climate model performance metrics. *J Appl Meteorol Climatol* [Internet]. 2011 [cited 2025 Jun 26]. Available from: <https://journals.ametsoc.org/view/journals/apme/50/8/2011jamc2643.1.xml>
18. Saputra DM, Saputra D, Oswari LD. Effect of distance metrics in determining K-value in K-means clustering using elbow and silhouette method. En: Atlantis Press [Internet]. 2020 [cited 2025 Jun 28]. p. 341–6. Available from: <https://www.atlantis-press.com/ proceedings/siconian-19/125939938>
19. Muñoz ÁG, Yang X, Vecchi GA, Robertson AW, Cooke WF. A weather-type-based cross-time-scale diagnostic framework for coupled circulation models. *J Clim* [Internet]. 2017 [cited 2025 Jun 28]. Available from: <https://journals.ametsoc.org/view/journals/clim/30/22/jcli-d-17-0115.1.xml>
20. Miranda G. Cluster-Dinamico-Sierra-Ecuador/Cluster\_Dinamico\_Precipitación.ipynb [Internet]. GitHub; 2025 [cited 2025 Jun 18]. Available from: [https://github.com/Geovanny-Miranda1/Cluster-dinamico-Sierra-Ecuador/blob/main/Cluster\\_Dinamico\\_Precipitaci%C3%93N.ipynb](https://github.com/Geovanny-Miranda1/Cluster-dinamico-Sierra-Ecuador/blob/main/Cluster_Dinamico_Precipitaci%C3%93N.ipynb)
21. Nalluri S, Ramasubbareddy S, Kannayaram G. Weather prediction using clustering strategies in machine learning. *J Comput Theor Nanosci*. 2019;16(5–6):1977–81.
22. Cornwall A. Unpacking ‘Participation’: models, meanings and practices. *Community Dev J*. 2008;43(3):269–83.
23. Ruiz-Hernández JC, Condom T, Ribstein P, Le Moine N, Espinoza JC, Junquas C, et al. Spatial variability of diurnal to seasonal cycles of precipitation from a high-altitude equatorial Andean valley to the Amazon Basin. *J Hydrol Reg Stud*. 2021;38:100924.
24. Rollenbeck R, Bendix J. Rainfall distribution in the Andes of southern Ecuador derived from blending weather radar data and meteorological field observations. *Atmos Res*. 2011;99(2):277–89.
25. Pérez N, Mullo H, Marcatoma A. Análisis del cambio climático en un ecosistema alto andino, Riobamba–Ecuador. *Perfiles*. 2019;1(23):1–8.
26. Pérez Londo NA, Lema Londo DS, Toapanta Yugcha EA. Patrones de comportamiento de temperatura en el Ecuador en modelos de circulación atmosférica mediante clustering. *Rev Científico-Prof*. 2023;8(8):2169–85.
27. Tobar V, Wyseure G. Seasonal rainfall patterns classification, relationship to ENSO and rainfall trends in Ecuador. *Int J Climatol*. 2018;38(4):1808–19.
28. Recalde-Coronel GC, Barnston AG, Muñoz ÁG. Predictability of December–April rainfall in coastal and Andean Ecuador. *J Appl Meteorol Climatol* [Internet]. 2014. Available from: <https://journals.ametsoc.org/view/journals/apme/53/6/jamc-d-13-0133.1.xml>
29. Buytaert W, Celleri R, Willems P, Bièvre BD, Wyseure G. Spatial and temporal rainfall variability in

- mountainous areas: a case study from the south Ecuadorian Andes. *J Hydrol.* 2006;329(3):413–21.
30. Thielen DR, Ramoni-Perazzi P, Zamora-Ledezma E, Puche ML, Marquez M, Quintero JI, et al. Effect of extreme El Niño events on the precipitation of Ecuador. *Nat Hazards Earth Syst Sci.* 2023;23(4):1507–27.
  31. Araujo CR, Hidalgo HG. Aplicación del cálculo fraccional a una serie de temperaturas de la zona andina. *Perfiles.* 2020;1(24):54–61.