




EVALUACIÓN DE LA SEQUÍA EN EL DEPARTAMENTO DE NARIÑO MEDIANTE EL ÍNDICE ESTANDARIZADO DE PRECIPITACIÓN Y EVAPOTRANSPIRACIÓN (SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL



INVESTIGACIÓN PARA OPTAR POR EL TÍTULO DE INGENIERO SANITARIO Y AMBIENTAL



JUAN CAMILO TRIANA MADRID
GRUPO DE INVESTIGACIÓN DE RECURSOS HÍDRICOS Y SUELOS

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE ESTANDARIZADO DE
PRECIPITACIÓN EVAPOTRANSPIRACIÓN (SPEI) UTILIZANDO INTELIGENCIA
ARTIFICIAL EN EL DEPARTAMENTO DE NARIÑO.**

**TRABAJO DE GRADO PARA OPTAR AL TÍTULO DE INGENIERO SANITARIO Y
AMBIENTAL**

**PRESENTADO POR:
JUAN CAMILO TRIANA MADRID**

**DIRECTORES DE TRABAJO DE GRADO:
Ph.D.: YESID CARVAJAL ESCOBAR
ING. CAMILO OCAMPO MARULANDA**

**UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA DE RECURSOS NATURALES Y DEL AMBIENTE
PROGRAMA INGENIERÍA SANITARIA Y AMBIENTAL
GRUPO DE INVESTIGACIÓN DE RECURSOS HÍDRICOS Y SUELOS
SANTIAGO DE CALI
SEDE CALI
JULIO 2021**

Tabla de contenido

1. INTRODUCCIÓN	1
2. PLANTEAMIENTO DEL PROBLEMA	3
3. JUSTIFICACIÓN	6
4. OBJETIVOS	8
4.1 Objetivo general	8
4.2 Objetivos específicos	8
5. MARCO REFERENCIAL	9
5.1 Clima y sequía	9
5.2 Índices para monitorear la sequía	10
5.3 Inteligencia artificial en el estudio del clima	11
6. METODOLOGIA	14
6.1 Diagrama de metodología	14
6.2 Localización zona de estudio	15
6.3 Red meteorológica	16
6.4 Imputación datos faltantes	17
6.4.1 Datos faltantes de precipitación	17
6.4.2 Datos faltantes de horas de brillo solar	19
6.4.3 Datos faltantes de humedad relativa, velocidad del viento, temperatura máxima y mínima	21
6.5 Análisis exploratorio y confirmatorio de los datos	21
6.6 Estimación de la evapotranspiración potencial	22
6.7 Evaluación de métricas de desempeño de validación	23
6.8 Aplicación de Inteligencia artificial para la evapotranspiración potencial	24
6.9 Estimación del SPEI	26
6.10 Estimación del área bajo la curva y definición periodos más secos	27

6.11 Espacialización del SPEI	28
7. RESULTADOS Y DISCUSIÓN	29
7.1 Imputación de datos faltantes	29
7.2 Análisis exploratorio y confirmatorio de datos	29
7.2.1 Análisis descriptivo	30
7.2.2 Análisis gráfico	30
7.2.3 Pruebas de normalidad	34
7.3 Estimación evapotranspiración potencial	35
7.4 Evaluación métricas de desempeño de validación	40
7.5 Aplicación de Inteligencia artificial para la evapotranspiración potencial	41
7.5.1 Modelo de regresión lineal múltiple Hargreaves	41
7.5.2 Modelo de Redes Neuronales artificiales - Hargreaves	45
7.5.3 Comparación modelos Hargreaves	46
7.5.4 Modelo de regresión lineal múltiple FAO-PM56	47
7.5.5 Comparación modelos FAO-PM56	51
7.6 Evaluación temporal de la sequía	53
7.6.1 Estimación del SPEI y análisis de componentes principales no lineales	53
7.6.2 Coeficiente de determinación e identificación periodos más secos	54
7.6.3 Eventos evaluados	56
7.7 Evaluación espacial de la sequía a partir de los índices de sequía	57
7.7.1 Complemento del SPEI a partir del SPI	57
7.7.2 Interpolación sequía con el SPI	59
8. CONCLUSIONES	67
9 RECOMENDACIONES Y FUTURAS LINEAS DE INVESTIGACIÓN	68
9. REFERENCIAS	69

Índice de Figuras

Figura 1 estructura típica de una red neuronal artificial, fuente: (Sancho Caparrini, 2019)	12
Figura 2 Resumen de la metodología, fuente: elaboración propia	14
Figura 3 Delimitación y ubicación de la zona de estudio, fuente: propia	15
Figura 4 distribución espacial de estaciones del departamento de Nariño, fuente: elaboración propia	19
Figura 5 reconstrucción precipitación Sindagua	29
Figura 6 Análisis gráfico precipitación media mensual Aeropuerto Antonio Nariño: a) gráfico de barras b) diagrama de cajas y bigotes y c) histograma de frecuencia	31
Figura 7 Análisis gráfico temperatura media mensual Aeropuerto Antonio Nariño: a) gráfico de barras b) diagrama de cajas y bigotes y c) histograma de frecuencia	32
Figura 8 Análisis gráfico humedad relativa Aeropuerto Antonio Nariño: a) gráfico de barras b) diagrama de cajas y bigotes y c) histograma de frecuencia	33
Figura 9 Análisis gráfico promedio de horas de brillo solar mensual Aeropuerto Antonio Nariño: a) gráfico de barras b) diagrama de cajas y bigotes y c) histograma de frecuencia	33
Figura 10 Resultados ETo acumulada anual de la estación Aeropuerto Antonio Nariño	36
Figura 11 Resultados ETo acumulada anual de la estación Obonuco	36
Figura 12 Resultados ETo acumulada anual de la estación El Encano	37
Figura 13 Resultados ETo mensual de Aeropuerto Antonio Nariño	38
Figura 14 Resultados ETo mensual de Obonuco	38
Figura 15 Resultados ETo mensual de El Encano	39
Figura 16 Relación entre las variables regresoras y Hargreaves de acuerdo con la cota: (a) HBS y (b) Tmax	42
Figura 17 Resultados de supuestos del modelo6 de regresión lineal: (a) linealidad y (b) normalidad	44
Figura 18 Comparación de valores observados vs predichos por redes neuronales: (a) Barbacoas, (b) Monopamba, (C) Sindagua y (d) Botana	47
Figura 19 Relación entre las variables regresoras y FAO-PM56 de acuerdo con la cota: (a) Tmax, b) HBS y c) humrel	49
Figura 20 Resultados de supuesto de linealidad y normalidad del modelo4 de regresión lineal múltiple: a) linealidad y b) normalidad	50

Figura 21 Comparación de valores observados vs predichos por el modelo: (a) Obonuco, (b) El Encano y (c) Aeropuerto Antonio Nariño	52
Figura 22 Correlación entre SPEI trimestral y la primera componente	55
Figura 23 Correlación entre SPEI semestral y la primera componente	55
Figura 24 Correlación entre SPEI anual y la primera componente	55
Figura 25 Correlación entre el SPI y SPEI trimestral.....	57
Figura 26 Correlación entre el SPI y SPEI semestral.....	58
Figura 27 Correlación entre el SPI y SPEI anual.....	58
Figura 28 SPEI trimestral Oct-91 a May-92.....	60
Figura 29 SPEI trimestral Abr-92 a Nov-92	61
Figura 30 SPEI semestral Sep-91 a Jul-92	62
Figura 31 SPEI semestral Mar-92 a Ene-93.....	63
Figura 32 SPEI anual Jun-00 a Oct-01	64
Figura 33 SPEI anual Dic-00 a Abr-02	65

Índice de Tablas

Tabla 1 Resumen de ventajas y desventajas de los índices de sequías más investigados, elaboración propia.	10
Tabla 2 Resumen datos e información estaciones Nariño	16
Tabla 3 Porcentaje de datos faltantes de las variables climáticas analizadas	17
Tabla 4 Estaciones elegidas para la aplicación del método de razón normal.....	18
Tabla 5 Métodos de evapotranspiración potencial, fuente: elaboración propia	22
Tabla 6 métricas de desempeño de validación usadas en la investigación	23
Tabla 7 Clasificación índice SPEI, fuente:(Vicente-Serrano, Beguería y López-Moreno, 2010)	27
Tabla 8 Estadísticos descriptivos precipitación	30
Tabla 9 Resultados pruebas de normalidad Jarque & Bera	35
Tabla 10 Métricas de desempeño de validación para la estación Aeropuerto Antonio Nariño, fuente: elaboración propia	40
Tabla 11 Métricas de desempeño de validación para la estación Obonuco, fuente: elaboración propia	40

Tabla 12 Métricas de desempeño de validación para la estación El Encano, fuente: elaboración propia	40
Tabla 13 Resumen resultados prueba de normalidad y coeficiente de Spearman entre variables regresoras y variables de respuesta del modelo de Hargreaves.....	41
Tabla 14 Resumen estadístico modelos de regresión lineal múltiple HAR	43
Tabla 15 Ecuación local de ETo Hargreaves para cada estación.	44
Tabla 16 Resumen estadístico y parámetros para la arquitectura de la red neuronal artificial	45
Tabla 17 Métricas de desempeño de validación por métodos de inteligencia artificial, Hargreaves	46
Tabla 18 Resumen resultados prueba de normalidad y coeficiente de Spearman entre variables regresoras y variables de respuesta del modelo de FAO-PM56	48
Tabla 19 Resumen estadístico modelos de regresión lineal múltiple PM-56	49
Tabla 20 Ecuación local de ETo PM-56 para cada estación.	51
Tabla 21 métricas de desempeño de validación de métodos de regresión lineal múltiple PM-56	51
Tabla 22 Ventajas y desventajas de los modelos de inteligencia artificial	53
Tabla 23 Prueba autovalor escalas temporales	54
Tabla 24 Correlación entre el SPEI promedio y las dos componentes principales	54
Tabla 25 Eventos de sequía seleccionados	56

EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO



Nota de aceptación:

Firma del evaluador

Firma del evaluador

Santiago de Cali, 2021

DEDICATORIA

Este trabajo va dedicado a las personas más cercanas en mi vida mi papá, mi mamá y mi abuela: Jairo Doiner Triana García, Luz Stella Madrid Delgado y Nelly Delgado Porras, quienes desde el amor y la responsabilidad se han encargado de formarme como una persona íntegra dispuesta a aportarle a la sociedad, además de brindarme todas las herramientas para poder estudiar en la Universidad del Valle, inicialmente apoyándome para mis estudios como tecnólogo agroambiental y ahora como ingeniero sanitario y ambiental. También este logro está dedicado a Dios, por darme salud y las capacidades para la culminación de este trabajo. Finalmente también dedico este trabajo a las personas que trabajan y estudian, los animo a que nunca desistan de sus sueños, esfuércense y hagan realidad lo que se mentalizan, porque el que quiere puede, las limitaciones la mayoría de las veces son mentales.

AGRADECIMIENTOS

Agradecimientos a mi director Yesid Carvajal Escobar por su guía, apoyo y dirección en el desarrollo de esta investigación, en mi vida personal y profesional, pues su amplio conocimiento fue fundamental para poder alcanzar los objetivos propuestos y por permitirme ingresar al grupo IREHISA. Agradecimientos a mi director Camilo Ocampo Marulanda por introducirme en el tema de la hidrología, por contagiarme de su entusiasmo para entrar en el mundo de la investigación y sobre todo por depositar su confianza en mí para ayudarme entrar al grupo IREHISA.

Agradecimiento especial al equipo de trabajo de los grupos de investigación IREHISA y PSI: Wilmar Alexander Torres, Teresita Canchala Nastar, Camilo Ocampo Marulanda, Yesid Carvajal Escobar, Carlos David Ojeda, Wilfredo Alfonso Morales y Cristhian Eduardo Fernández Álvarez, por todas las asesorías y el continuo acompañamiento para la realización de la presente investigación.

Agradecimientos a mi hermano Joshua David Triana Madrid, ya que es un ejemplo para seguir como profesional y ser humano, por toda su ayuda, orientación, consejos y asesorías constantes en los temas de inteligencia artificial, al profesor Carlos Delgado por su apoyo y guía en los temas de redes neuronales artificiales, sin su ayuda este camino hubiera sido muy difícil.

Agradecimientos a la Universidad del Valle por permitirme trabajar durante casi 4 años para poder pagar mis estudios, con la vinculación como monitor en la Sección de Sostenibilidad y Mantenimiento, donde además conocí dos personas muy especiales: Erika Hellen Achinte Batero y Esau Sanchez Basto, dos grandes amigos que me ayudaron y me brindaron toda su ayuda tanto profesional como personalmente, para poder culminar mis estudios, el cariño es inmenso, son como mis padres adoptivos.

Agradecimientos al amor de mi vida Karent Lineth Aguilera David quien creyó en mí, me ayudo a ser un gran profesional, y con quien he vivido los momentos más felices de mi vida. A mi hermano de vida Luis Miguel Peña Zambrano por todo su apoyo constante, momentos de alegría, viajes y su amistad que vale oro.

Agradecimientos a la ingeniera Paula Restrepo, al ingeniero Eduardo De Los Ríos y a Sandra Villegas por permitirme desempeñarme profesionalmente como ingeniero sanitario y ambiental en el ingenio Mayagüez y por su apoyo constante.

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**



A mis compañeros de pregrado, especialmente a: Jackeline Diaz, Ana García, Banny Mendez, Liseth Narvaez, Deisy Gomez, Angelica Caviedes, Tatiana Montaña, Isabel Quintero, Andrea Rodriguez, Dair Rivera y Yurani Ruiz, agradezco a la vida, al universo y a Dios por permitirme compartir alegrías y tristezas durante mi estadía en la Universidad, por su compañía en las asignaturas en las que pudimos trabajamos juntos y por todos los momentos vividos, que estarán por siempre en mi corazón.

Agradecimientos a la familia Cabal, por su apoyo económico en mis estudios como tecnólogo e ingeniero sanitario y ambiental, especialmente a Felipe, Beatriz y Esperanza, espero poder retribuirle a la sociedad, así como ustedes lo hicieron conmigo.

Agradezco al IDEAM por el suministro de la información, la cual fue indispensable para la presente investigación, y finalmente, a todos los profesores que me enseñaron durante mis estudios como tecnólogo e ingeniero sanitario ambiental, especialmente a: Jenny Vannesa Marín, Mauricio Osorio Londoño, Carlos Arturo Madera, Juan Pablo Silva, Luis Fernando Marmolejo y Julia Rosa Caicedo.

RESUMEN

La sequía es un evento climático extremo de la naturaleza, que ha aumentado gradualmente en su duración, frecuencia e intensidad debido al cambio climático. Debido a esto, los estudios de la sequía han incrementado en los últimos años con el fin de caracterizar, comprender, mitigar y reducir los impactos negativos. En este estudio se estimaron diferentes métodos de evapotranspiración potencial: FAO-PM56 (FAO PENMAN MONTEITH), Hargreaves, Turc, Thornthwaite y Cenicafé, los cuales fueron evaluados mediante métricas de desempeño de validación: coeficiente correlación de Pearson, BIAS, NSE (ecuación Nash-Sutcliffe), RMSE (error cuadrático medio) y estadístico t, para determinar el método más ajustado al sugerido por la FAO (FAO-PM56) el cual fue Hargreaves. Posteriormente, para la estimación del método de Hargreaves y de FAO-PM56, se compararon dos modelos, regresión lineal múltiple y redes neuronales artificiales, donde también se aplicaron métricas de desempeño de validación (R^2 , BIAS, NSE, RMSE y coeficiente de correlación de Pearson). Finalmente se realizó la estimación del índice de sequía SPEI y SPI, y se correlacionaron ambos índices interpolando los resultados utilizando kriging para determinar las zonas más secas del departamento de Nariño.

Palabras clave: evapotranspiración potencial, FAO Penman Monteith, Hargreaves, índice de sequía, inteligencia artificial, métricas de desempeño de validación, redes neuronales artificiales, sequía y SPEI.

ABSTRACT

Drought is an extreme climatic event of nature, which has gradually increased in duration, frequency, and intensity due to climate change. Because of this, drought studies have increased in recent years in order to characterize, understand, mitigate and reduce the negative impacts. In this study, different methods of potential evapotranspiration were estimated: FAO-PM56 (FAO PENMAN MONTEITH), Hargreaves, Turc, Thornthwaite and Cenicafé, which were evaluated using validation performance metrics: Pearson correlation coefficient, BIAS, NSE (Nash-Sutcliffe equation), RMSE (root mean square error) and t-statistic, to determine the most adjusted method to the one suggested by FAO (FAO-PM56), which was Hargreaves. Subsequently, for the estimation of the Hargreaves and FAO-PM56 methods, two models were compared, multiple linear regression and artificial neural networks, where validation performance metrics were also applied (R^2 , BIAS, NSE, RMSE and Pearson's correlation coefficient). Finally, the SPEI and SPI drought

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**



index were estimated, and both indexes were correlated and the results were interpolated using kriging to determine the driest areas in the department of Nariño.

KEY WORDS: artificial intelligence, artificial neural networks, drought, drought index, FAO Penman Monteith, Hargreaves, potential evapotranspiration, validation performance metrics and SPEI.

1. INTRODUCCIÓN

La sequía es un evento climático extremo de la naturaleza, que ha aumentado gradualmente en su duración, frecuencia e intensidad debido al cambio climático. Las sequías se han convertido en una amenaza potencial por los impactos que genera en el ciclo hidrológico, que al final repercute en la humanidad y los ecosistemas (Mukherjee *et al.*, 2018). Ante tal situación, estudiar y caracterizar las sequías se constituye como uno de los principales retos a futuro, ya que la experiencia indica que es mejor prepararse para estar adaptados a los desastres naturales que enfrentarlos cuando ya han ocurrido (Carvajal-Escobar, 2011).

Los estudios de la sequía han incrementado en los últimos años con el objetivo de caracterizar, comprender, mitigar y reducir los impactos negativos que este fenómeno produce en las principales actividades socioeconómicas, por ejemplo en la agricultura genera pérdidas en los cultivos, pobreza y migración campesina en particular de personas dependientes de la agricultura de secano, a las ciudades (Ruiz & Molano, 2011; Sedano-cruz *et al.*, 2012). En relación con el medio ambiente, la sequía aumenta la temperatura promedio del aire, reduce la precipitación y oferta de macro y micronutrientes del suelo (Barella Ortiz & Quintana Seguí, 2019; Olivares *et al.*, 2016; Yang *et al.*, 2019). En cuanto a las actividades industriales, específicamente en el sector hidroeléctrico, existe el antecedente del apagón del año 1992 en Colombia donde se produjeron millonarias pérdidas económicas (Nobles Orozco, 2016).

Por eso, se recomienda utilizar índices que permitan monitorear las sequías, para conocer las zonas más vulnerables, con el fin de implementar metodologías que faciliten la adaptación y/o mitigación a las sequías (Achour *et al.*, 2019; Apurv *et al.*, 2019; Estrela & Vargas, 2012; Sun *et al.*, 2019; Vincent, 2007). En esta investigación se utilizó el índice SPEI desarrollado por Vicente-Serrano, Beguería y López-Moreno (2010) el cual ha sido mundialmente utilizado en la última década para estudiar eventos de sequías (Allen *et al.*, 2011; Deo & Mehmet, 2015; Kelley *et al.*, 2015; Nguyen *et al.*, 2017; Poornima & Pushpalatha, 2019; Soh *et al.*, 2018; Yen *et al.*, 2019).

Evaluando la aplicación del índice SPEI en otros países y considerando que en Colombia se observan obstáculos que impiden el avance en los estudios hidrológicos, como: ausencia de información adecuada de variables climatológicas relevantes en espacio-tiempo, falta de metodologías apropiadas para predecir

variables y datos de mala calidad, se deben aunar esfuerzos que permitan la implementación de este índice (Poveda *et al.*, 2006). Un ejemplo donde se evidencian estas problemáticas es en la estimación de la evapotranspiración potencial, debido a que existen varios métodos, entre los que destacan: Thornthwaite, Hargreaves, Turc, FAO-PM56 (FAO Penman-Monteith 56), etcétera (Allen *et al.*, 1998; Hargreaves & Samani, 1985; Jaramillo, 2006; Thornthwaite & Wilm, 1948; Turc, 1961). Estos métodos requieren información de diferentes variables como: precipitación, temperatura, humedad o radiación, las cuales en algunos casos son difíciles de obtener y más en zonas donde históricamente el conflicto armado ha ocasionado estragos.

Para Nariño es fundamental tomar medidas preventivas contra la sequía y las bajas precipitaciones, debido a que es uno de los departamentos con mayor participación en producción de agrícola para el país, ofreciendo gran variedad de productos, como: cacao, café, coco, plátano, papa, frijol, alverja, entre otros (Minagricultura, 2017; Moncayo, 2015). Por eso, se deben implementar estrategias de adaptación contra el cambio climático y las sequías, ya que estos fenómenos pueden impactar negativamente la productividad agrícola del departamento, lo cual se constituye como una amenaza para cumplir con los objetivos 1 y 7 del milenio: erradicar la pobreza extrema y el hambre y garantizar la sostenibilidad del medio ambiente (Arteaga & Burbano, 2018; ONU, 2015).

Evaluar la sequía con el índice SPEI es muy importante, ya que al espacializar los resultados, será posible identificar las zonas más secas del departamento de Nariño. Esta información será de mucha ayuda para las entidades gubernamentales, debido a que se podrán priorizar y establecer actividades preventivas y correctivas para evitar al máximo los impactos asociados a sequías en estas zonas.

2. PLANTEAMIENTO DEL PROBLEMA

La precipitación es un factor importante en la sequía, ya que es una variable meteorológica esencial del ciclo hidrológico (Urdiales & Céleri, 2018). Por tal motivo, se considera un excelente indicador en campos de investigación, como: gestión integral de recurso hídrico, evaluación de sistemas agrícolas y estudios de cambio climático, ya que, su monitoreo, análisis y estudio, sirve como punto de partida para tomar medidas de adaptación a eventos extremos de sequía y al cambio climático (Shi et al., 2016).

La mayoría de los estudios de sequías se centran en la precipitación porque es una de las variables climáticas más importantes del ciclo hidrológico. Sin embargo, se deberían considerar otras variables, como: temperatura, humedad relativa y radiación solar. Tales variables permiten identificar características y tendencias climáticas más precisas para así implementar acciones de adaptación y mitigación más eficientes contra las sequías. Por ejemplo, Basher (2006) menciona que a nivel mundial se produjeron aproximadamente 6.000 desastres entre 1995 y 2004 que causaron 900.000 muertos y 2.500.000.000 de personas damnificadas. Por esta razón, es importante aplicar índices climatológicos que permitan monitorear el clima y evitar futuros desastres asociados a eventos extremos (Feng & Houser, 2016).

A nivel nacional el IDEAM (Instituto de Hidrología, Meteorología y Estudios Ambientales) recomienda utilizar el índice SPI (índice estandarizado de precipitación) para evaluar la sequía. Por eso, algunos autores han realizado investigaciones en departamentos, como: Córdoba, Cundinamarca, Magdalena y Valle del Cauca, con el fin de identificar los principales impactos asociados de la sequía y su relación con el fenómeno ENOS (El Niño-Oscilación Sur) (Cerón, 2014; Cerón *et al.*, 2019; González *et al.*, 2016; Nobles Orozco, 2016; Ojeda-Flechas *et al.*, 2019; Velandia, 2016; Viviescas, 2019). Actualmente, no se reporta ningún estudio previo de índices de sequía en el departamento de Nariño, sin embargo, en el siguiente enlace: <http://www.ideam.gov.co/web/tiempo-y-clima/mapas-de-indices-de-sequia-para-periodos-de-1-3-6-y-12-meses> el IDEAM presenta la cartografía asociada al índice SPI a escala mensual, trimestral y semestral a nivel nacional.

El ENOS es un fenómeno climático con un periodo de retorno entre 3-7 años, que influye en la variabilidad interanual de las condiciones océano-atmosféricas del planeta. Se caracteriza por presentar anomalías en la presión atmosférica y temperatura superficial del Océano Pacífico tropical. En Colombia la fase cálida (El

Niño) corresponde a periodos de altas temperaturas y disminución de lluvias, caudales de los ríos y humedad del suelo en la región Andina, Caribe y Pacífico, mientras que la fase fría (La Niña) corresponde a las condiciones contrarias anteriormente mencionadas (Altamiranda-Saavedra *et al.*, 2018; McGregor & Ebi, 2018; Navarro-Monterroza *et al.*, 2019; Seyoum, 2018)

Según lo reportado en el plan de desarrollo departamental de Nariño los impactos generados por el fenómeno El Niño en el 2015, fueron catastróficos, ya que 41 de los 64 municipios, se vieron afectados por: sequías, granizadas y heladas que representaron aproximadamente US\$ 130.000.000 en pérdidas económicas. Por lo tanto, resulta importante entender que la falta de información de estos fenómenos climatológicos genera impactos negativos, en lugares que son especialmente sensibles a las modificaciones del clima, como los municipios ubicados en la zona andina que representan el 40% de Nariño (Gobernación de Nariño, 2016).

La información climática sirve como punto de partida para mejorar la toma de decisiones en cuanto a la productividad agrícola y la incertidumbre generada por el cambio climático (FAO, 2013). De ahí que, aunque se requiera de tiempo para implementar planes de adaptación y mitigación en la agricultura, si se tiene información oportuna de: tipo del suelo, requerimientos hídricos, tipo y variedad de cultivo, entre otros, se puedan recortar tiempos para obtener mejores rendimientos que garanticen la seguridad alimentaria (Han *et al.*, 2018).

Como se observa, estudiar la conexión entre el clima y el cultivo es extremadamente importante en la agricultura, ya que, permite crear nuevas oportunidades de investigación, sobre todo en campos multidisciplinarios que se especializan en la predicción de datos como la inteligencia artificial (Bangaru & Parvathi, 2020). Por consiguiente, la mayoría de las investigaciones recientes se han orientado a evaluar la factibilidad de la inteligencia artificial en la predicción de datos (Canchala *et al.*, 2019; Deo y Mehmet, 2015; Liu *et al.*, 2010; Nguyen *et al.*, 2017; Obregon *et al.*, 2003; Poornima y Pushpalatha, 2019; Soh *et al.*, 2018; Zabbah *et al.*, 2018)

En ese orden de ideas, con el fin de prevenir, reducir y mitigar los impactos de las problemáticas anteriormente mencionadas, se ha formulado la siguiente pregunta: **¿Cómo es la distribución espacio-temporal de la sequía en el departamento de Nariño utilizando el SPEI apoyado en la inteligencia artificial?** Responder esta pregunta permitirá evaluar la eficiencia de la inteligencia artificial para la evaluación de la sequía y además permitirá identificar las zonas más secas del

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**



departamento de Nariño. En ese sentido, ante los posibles escenarios de escasez de agua que se avecinan, la agricultura podría verse gravemente afectada y considerando que esta es la principal actividad socioeconómica del departamento, se deben priorizar inmediatamente para implementar acciones preventivas a corto y largo plazo, con el fin de prevenir el colapso de la economía nariñense y problemas de seguridad alimentaria en el país.

3. JUSTIFICACIÓN

El calentamiento global y el cambio climático afectan el ciclo hidrológico y la agricultura en el mundo, especialmente a los países en desarrollo, donde los agricultores aprovechan las condiciones climáticas y el agua lluvia para hacer crecer los cultivos. Por eso, cuando hay eventos climáticos extremos (sequías, olas de calor e inundaciones), los agricultores tienen menor capacidad de adaptarse al cambio climático debido a que se encuentran en zonas cálidas, donde las temperaturas ya se encuentran cerca a los umbrales en los que un aumento puede ocasionar una disminución en la oferta de productos agrícolas (Cline, 2008).

Esta situación es alarmante debido a que se afecta directamente la economía, la producción de alimentos y los ecosistemas, mediante: el aumento de costos de producción, excesivas olas de calor que limitan agua para el consumo y variabilidad climática, respectivamente (Liu *et al.*, 2018; Perez *et al.*, 2019; Poornima & Pushpalatha, 2019; Seyoum, 2018). Asimismo, Lehmann, Mempel y Coumou (2018) mencionan que los cambios en los patrones mensuales de precipitación tendrán mayores impactos en el ambiente y la sociedad, por ejemplo con inundaciones más fuertes y con sequías más prolongadas e intensas (Field *et al.*, 2014).

Considerando que la ingeniería debe tener un componente de conciencia y compromiso social, ya que, como mencionan Serrano *et al.* (2018), mediante la incorporación de criterios de dimensiones ambientales, económicos y sociales en los procesos de planificación y gestión del recurso hídrico, se pueden implementar estrategias de adaptación y mitigación ante el cambio climático para anticiparse adecuadamente y que haya menos consecuencias negativas en el sector productivo. La amenaza es real pues se ha evidenciado en los últimos años catástrofes e impactos ambientales significativos (Basher, 2006), por ello nace la importancia de investigar e implementar estudios que contribuyan a el cumplimiento del objetivo 13 (acción por el clima) de los Objetivos del Desarrollo Sostenible propuestos por la ONU, de tal manera que la presente investigación se hace con el fin de aportar conocimiento a través de la identificación de zonas más vulnerables a la sequía, para apoyar procesos de una gestión eficiente del recurso hídrico (ONU, 2011).

Por todo lo anteriormente mencionado, se hace necesario investigar la forma en la que la sequía y sus impactos asociados afectan al medio ambiente, la economía y la sociedad, ya que estos sirven como una herramienta de monitoreo e indicador

operacional para el manejo del recurso hídrico para las diferentes actividades socioeconómicas (Monish y Rehana, 2019; Poornima y Pushpalatha, 2019).

Evaluar la sequía en el departamento de Nariño es importante, ya que el departamento tiene una posición geoestratégica privilegiada por su cercanía con el Ecuador climático y el Océano Pacífico, además el 8% de su territorio pertenece al Pie de Monte de la Amazonía (una de las grandes reservas de biodiversidad del mundo), el 52% corresponde a la Llanura del Pacífico o Chocó Biogeográfico, que presenta condiciones excepcionales en diversidad de comunidades y especies y el 40% restante, pertenece a la zona andina en donde se destacan los páramos y volcanes. Los aspectos mencionados anteriormente lo posicionan como una de las regiones más diversas de Colombia y el mundo; cabe aclarar que con respecto al país éste posee el 10% de la flora, 11% de especie de anfibios, 17% de reptiles, 56,2% de aves y 37% de mamíferos, es por esto que se le conoce como “el corazón de Colombia” (Gobernación de Nariño, 2016).

La presente investigación se realizó en el marco del proyecto **“Análisis de eventos extremos de precipitación asociados a variabilidad y cambio climático para la implementación de estrategias de adaptación en sistemas productivos agrícolas de Nariño”** de la convocatoria 818 de MinCiencias. Esta investigación fue un complemento de la actividad 4 del objetivo 1, la cual consistió en realizar una evaluación espaciotemporal de los eventos extremos de precipitación utilizando el SPI, ya que inicialmente se había considerado solo la precipitación para evaluar las zonas de mayor vulnerabilidad.

4. OBJETIVOS

4.1 *Objetivo general*

- Evaluar la sequía mediante el índice estandarizado de precipitación y evapotranspiración (SPEI) utilizando inteligencia artificial en el departamento de Nariño.

4.2 *Objetivos específicos*

- Evaluar la aplicabilidad de metodología empírica existente para la estimación evapotranspiración potencial en el departamento de Nariño.
- Evaluar la estimación del SPEI mediante inteligencia artificial para el departamento de Nariño.
- Establecer zonas secas en el departamento de Nariño mediante la espacialización del SPEI.

5. MARCO REFERENCIAL

5.1 Clima y sequía

Acorde con el IPCC (2012), la agricultura es una de las actividades más influenciada por la variabilidad climática y eventos extremos, en particular la sequía. Sin embargo, Kubiak (2019) menciona que aunque no existe una definición universal de la sequía aceptada debido a su complejidad, algunos autores coinciden en que la sequía se define como una característica climática natural, de carácter peligroso, con un bajo promedio de precipitación que puede ocurrir en cualquier parte del mundo (Diani et al., 2019; Hu et al., 2019; Mpelasoka et al., 2008).

Algunas de las causas de las sequías durante los últimos años que afectaron el crecimiento y rendimiento de los cultivos fueron: el incremento de la evapotranspiración, velocidad del viento y la disminución de la precipitación, humedad relativa y temperatura (Liu *et al.*, 2010; Soh *et al.*, 2018). Además, la escasez de agua se ve afectada por la aridez, la cual es una característica climática con bajo contenido de humedad, expresado en términos de tasas de precipitación y evapotranspiración (Arora, 2002).

La complejidad de entender las sequías radica en que no existe una variable física que se pueda medir para cuantificarla (Vicente-Serrano, Beguería y López-Moreno, 2010) debido a esto se han desarrollado indicadores que permiten monitorear y cuantificar, el inicio, desarrollo y final de esta. Así pues, la American Meteorological Society (2014), definió cuatro tipos de sequías:

- **Sequía meteorológica:** Definida como la falta de precipitación sobre una región en un determinado periodo de tiempo. Considerando esta como el déficit de precipitación con respecto a los valores promedios, la mayoría de los estudios asocian las sequías con valores de precipitación mensual.
- **Sequía agrícola:** Hace referencia a un periodo con baja humedad del suelo en el que debido a la escasez de agua no se alcanzan a satisfacer las necesidades de un cultivo, lo que conlleva a su pérdida.
- **Sequía hidrológica:** Se refiere a un periodo de tiempo con una deficiencia de la disponibilidad de agua superficial y/o subterránea, de un sistema de abastecimiento.
- **Sequía socioeconómica:** se refiere a la escasez del agua que trae consecuencias sociales (falta de acceso, cobertura, continuidad y calidad del agua) y económicas desfavorables (pérdidas de cultivos, infraestructuras, aumento del precio promedio de los cultivos).

5.2 Índices para monitorear la sequía

Así como no hay una única definición de sequía aceptada mundialmente, para los índices de sequía tampoco, ya que no hay un índice que pueda ser aplicado y tenga en cuenta tipos de: sequía, régimen climático y sectores. Por eso, es bastante común que cuando un índice identifica sequía en un lugar concreto, otro índice indique condiciones normales (Bhuiyan, 2004; WMO & GWP, 2016; Yihdego et al., 2019). De ahí que, algunos autores sugieren algunos criterios básicos que debe cumplir cualquier índice de sequía (Eslamian et al., 2017; Hayes, 2006):

- La escala de tiempo debe ser apropiada para evaluar el problema en cuestión (sequía).
- El índice debe ser una medida cuantitativa de las condiciones de sequía a gran escala y de larga duración.
- El índice debe ser aplicable al problema estudiado.

En ese sentido, un índice estandarizado que incluya los criterios básicos de la variabilidad del ciclo hidrológico permitirá estudiar las condiciones de sequía, en áreas de importancia agrícola y ecológica como Nariño. En la Tabla 1 se presentan algunos de los índices más estudiados por la comunidad científica.

Tabla 1 Resumen de ventajas y desventajas de los índices de sequías más investigados, elaboración propia.

Nombre y Referencia.	Tipo de sequía que evalúa y parámetros de entrada	Ventajas	Desventajas
Índice de precipitación estandarizado. (SPI) (Mckee, Doesken y Kleist, 1993)	Meteorológica y datos de precipitación	• Es muy simple ya que utiliza solo datos de precipitación. • Puede ser usada en múltiples escalas de tiempo, lo que lo hace conveniente para monitorear las sequías (Mishra y Singh, 2010).	• Al utilizar solo datos de precipitación, no es posible describir todos los factores que influyen las sequías (Zargar et al., 2011). • No permite identificar regiones con grandes tendencias a sequías, se requiere tener conocimiento del clima local (Zargar et al., 2011).
Índice de sequías. severas de Palmer. (PSDI) (Palmer, 1965)	Meteorológica y datos de precipitación, características del suelo y evapotranspiración de referencia.	• Es más comprensivo que los índices que utilizan solo precipitación, ya que incluye humedad del suelo y la evapotranspiración (Monzonís et al., 2015). • Permite comparar entre las regiones y escalas de tiempo (Mishra y Singh, 2010).	• No tiene presente la duración de las sequías. (Moorhead et al., 2015). • Asumen que toda la precipitación es lluvia (excluye nieve, escorrentía) lo que hace que los valores altos en época de invierno sean constantemente cuestionados (Zargar et al., 2011).
Índice de humedad de cultivos. (CMI) (Palmer, 1968)	Agrícola y los mismos que el de Palmer.	• Fue diseñado para evaluar a corto plazo las condiciones de humedad de un cultivo, en grandes extensiones de cultivos (Mishra y Singh, 2010). • Es muy efectiva para medir sequías. agrícolas en temporadas cálidas (Heim, 2002).	• No es una buena herramienta para evaluar sequías., debido a que el índice a corto plazo puede variar, por sus datos de entrada lo que ofrecería información errónea a largo plazo (Eslamian et al., 2017). • Está diseñado para mostrar condiciones de humedad efectiva en el crecimiento de cultivos a corto plazo, por lo tanto, no es un buen instrumento para mostrar sequías a largo plazo (Eslamian et al., 2017).

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**



Nombre y Referencia.	Tipo de sequía que evalúa y parámetros de entrada	Ventajas	Desventajas
Índice de reclamación de sequía. (RDI) (Weghorst, 1996)	Hidrológica y datos de temperatura y precipitación.	- Determina la severidad y la duración de una sequía (Eslamian et al., 2017). - Es aplicable para las regiones, teniendo en cuenta reservas de agua y componentes climáticos (Eslamian et al., 2017).	- Es complejo hacer comparaciones en los resultados, pues todas las cuencas tienen diferentes condiciones. - Limita su aplicación a las sequías agrícolas debido a que las prácticas agrícolas a lo largo del mundo varían (Moorhead et al., 2015).
Índice de diferencia de vegetación normalizado. (NDVI) (Rouse et al., 1973)	Agrícola e imágenes satelitales.	- Utiliza un radiómetro con alta resolución avanzada para conocer el estado de salud de la planta (Zargar et al., 2011). - Permite cuantificar el estado del agua en la planta a partir de la cobertura vegetal (Monzonis et al., 2015).	- Si hay contaminación, los píxeles se verán afectados, por ejemplo, con nubes, humo, aerosoles (Zargar et al., 2011). - Este índice es sensible a suelos oscuros y húmedos, además que la resolución en zonas urbanas no es la mejor (Zargar et al., 2011).
Índice de sequía de Estados Unidos. (U.S. Drought monitor) (NDMC, 2013)	Meteorológica y precipitación, índices de sequía, nivel agua subterránea y nivel del embalse.	- Sirve como una representación simple gráfica de los índices de sequía. - Es un mapa de sequía diseñado para informar al público y a la comunidad científica (Moorhead et al., 2015).	- Solo aplica en Estados Unidos, por lo que su validez a nivel mundial es nula. - Es limitada como una herramienta de sequía agrícola en tiempo real (Moorhead et al., 2015).
Índice de sequía acumulado. (ADI) (Sivakumar et al., 2011)	Precipitación y evapotranspiración de referencia.	El resultado del índice incluye el balance hídrico teniendo en cuenta la precipitación y la evapotranspiración.	- Hay limitada información disponible en la literatura que valide este método. - Se recomienda un índice que incluya flujo de corriente, niveles de embalse, niveles de agua subterránea, para tener una mejor aplicación a nivel mundial (Sivakumar et al., 2011).
Índice de precipitación y evapotranspiración estandarizado. (SPEI) (Vicente-Serrano, Beguería y López-Moreno, 2010)	Meteorológica y precipitación y evapotranspiración de referencia	- Explica el aumento en la duración y magnitud de las sequías resultantes de temperaturas más altas (Zargar et al., 2011). - Puede ser usado en múltiples escalas de tiempo. - Es una versión mejorada del SPI, el cual ha sido aceptado mundialmente por la comunidad científica.	- Existen muchas formas de ecuaciones para estimar evapotranspiración potencial, por lo que no ha sido posible decidir cuál es la mejor metodología. - El requerimiento de una serie de datos completa de precipitación y temperatura puede limitar su uso debido a que no se cuenta con un registro significativo.

5.3 Inteligencia artificial en el estudio del clima

La Inteligencia Artificial es una de las ramas provenientes de las ciencias de la computación que más interés ha despertado en los investigadores, debido a su potencial y enorme campo de aplicación. La búsqueda de mecanismos que ayuden a comprender los diferentes modelos es algo que ha motivado a muchos científicos a elegir esta área de investigación multidisciplinaria, ya que generalmente se realizan modelos que tratan de hacer tareas y resolver problemas como lo haría un humano, es decir, se trata de simular de manera artificial las formas del pensamiento y como trabaja el cerebro para una mejor toma de decisiones. Entre las principales técnicas de inteligencia artificial, destacan: redes neuronales artificiales, minería de datos, redes bayesianas, lógica difusa, entre otras (Ponce Gallego et al., 2014).

Las redes neuronales artificiales se definen como un sistema de procesamiento de información que intenta emular el comportamiento de las redes neuronales biológicas, las cuales se encuentran conectadas y funcionan como un modelo de caja negra (Caicedo Bravo & López Sotelo, 2017; Liu et al., 2010; Obregon et al., 2003).

Algunos autores (Deo & Mehmet, 2015; Jiménez Carrión et al., 2018; Liu et al., 2010; Şahin, 2012; Solomatine, 2002) mencionan ventajas de utilizar redes neuronales artificiales: permite analizar diversos problemas relacionados con el reconocimiento de patrones, pueden ser utilizadas donde otros modelos resultan inadecuados, permiten deducir las relaciones entre las entradas y las salidas a partir de datos históricos; permite modelar, calibrar, simular y predecir los datos a partir de una fase de entrenamiento. Estas ventajas resultan ideales para los estudios hidrológicos, ya que algunas de las variables climatológicas más importantes son aleatorias y no tienen explicación natural.

En la Figura 1 se evidencia un ejemplo de una estructura típica de una red neuronal artificial, y como es su símil con las neuronas biológicas, para poder entender, cuáles son las diversas interacciones que ocurren con esta herramienta.




Figura 1 estructura típica de una red neuronal artificial, fuente: (Sancho Caparrini, 2019)

Datos de entrada: X_1 hasta X_n , Pesos sinápticos: W_1 hasta W_n , Σ : sumatoria y umbral, f : función de activación y Salida: variable de interés a calcular.

Las redes neuronales artificiales son un modelo computacional basado en neuronas biológicas. Los datos de entrada provienen de fuentes externas y van almacenando información en cada neurona, donde se le asigna un peso y posteriormente se intercomunicará con otras neuronas por medio de sinapsis. Después se aplican

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**



generalmente transformaciones no lineales y se van almacenando en otra neurona hasta realizar un proceso sumatorio. Luego, por medio de una función de activación en la capa oculta, usando un optimizador, se va modificando la topología de la red, en función de la tasa de aprendizaje, con el fin de reducir la incertidumbre y facilitar la adaptación al problema para definir la mejor arquitectura de la red (Caicedo Bravo & López Sotelo, 2017; Russell & Norvig, 1995).

6. METODOLOGIA

6.1 Diagrama de metodología

En la Figura 2 se muestra un resumen de la metodología empleada para el cumplimiento de los objetivos planteados de esta investigación.




Figura 2 Resumen de la metodología, fuente: elaboración propia.

Donde:

A: Análisis de resultados

*: búsqueda de referencias

DR: Discusión de resultados

ET₀: evapotranspiración potencial

AED: análisis exploratorio de datos

MDV: métricas de desempeño de validación

6.2 Localización zona de estudio

La zona de estudio es el departamento de Nariño, ubicado al extremo del suroccidente colombiano, entre la región Pacífico, Amazónica y Andina, cuenta con 64 municipios, una superficie de 33.268 km² que representa el 2,97% del territorio nacional y una población de aproximadamente 1.700.000 personas (DANE, 2020). El departamento se encuentra delimitado entre las coordenadas 79° - 77°W y 0° - 3°N con una altitud máxima de 4767 msnm, promedio de 2467 msnm y mínima de 0 msnm. Se utilizaron datos climatológicos de 10 estaciones y su distribución espacial se presenta en la Figura 3.




Figura 3 Delimitación y ubicación de la zona de estudio, fuente: propia

6.3 Red meteorológica

Se realizó una revisión de la red de estaciones del IDEAM a escala mensual en el departamento de Nariño y los criterios preliminares para la selección fueron:

1. Periodo de registro mayor a 30 años.
2. Vigencia de operación activa.
3. Tener una ubicación y altitud diferente.
4. Porcentaje de datos faltantes inferior a 15%.

No se tuvieron en cuenta los criterios 3 y 4, ya que se hubieran disminuido considerablemente el número final de estaciones, por ende, solo se consideraron los criterios 1 y 2. En la Tabla 2 se presentan las estaciones seleccionadas para esta investigación, donde además se observa un resumen del periodo de registro, altura, coordenadas y variables a utilizar.

Tabla 2 Resumen datos e información estaciones Nariño

Nombre	Abreviatura	Coordenadas		Altura (msnm)	Periodo de registro	Variables:
		Latitud	Longitud			
Barbacoas	BAR	1,67	-78,14	32	1972-2012	P, HBS, HR, TMAX, TMED Y TMIN
Bombona	BOM	1,18	-77,47	1493	1969-2017	P, HBS, HR, TMAX, TMED Y TMIN
Botana	BOT	1,16	-77,28	2820	1984-2017	P, HBS, HR, TMAX, TMED Y TMIN
Obonuco	OBO	1,20	-77,30	2710	1961-2017	P, HBS, HR, TMAX, TMED, TMIN Y VV
San Bernardo	SBO	1,54	-77,03	2190	1972-2017	P, HBS, HR, TMAX, TMED Y TMIN
Taminango	TAM	1,55	-77,27	1875	1972-2017	P, HBS, HR, TMAX, TMED Y TMIN
Monopamba	MON	0,80	-77,30	1776	1983-2017	P, HBS, HR, TMAX, TMED Y TMIN
Aeropuerto Antonio Nariño	ANN	1,39	-77,29	1796	1958-2017	P, HBS, HR, TMAX, TMED, TMIN Y VV
Sindagua	SIN	1,11	-77,39	2800	1987-2017	P, HBS, HR, TMAX, TMED Y TMIN
El Encano	EEN	1,16	-77,16	2830	1984-2017	P, HBS, HR, TMAX, TMED, TMIN Y VV

Precipitación = P, Horas de brillo solar = HBS, Humedad relativa = HR, Temperatura máxima = TMAX, Temperatura media= TMED, Temperatura mínima = TMIN, Velocidad del viento = VV

El periodo común de registro seleccionado fue 1983-2019, el criterio para definirlo fue la disponibilidad de información en la mayoría de las estaciones. Para completar la información asociada a los datos faltantes y completar las series temporales, se utilizaron métodos de imputación de datos faltantes, los cuales se explican detalladamente en el apartado 6.4.

En la Tabla 3, se muestran los porcentajes de datos faltantes de las variables analizadas, donde se evidencia que en la mayoría hay un alto porcentaje (>10%).

Además, se observa que solo 3 estaciones tienen datos de VV y presentan más de 30% de datos faltantes.

Tabla 3 Porcentaje de datos faltantes de las variables climáticas analizadas

Nombre	%P	%HBS	%HR	%TMAX	%TMED	%TMIN	%VV
Barbacoas	11,94	25,00	22,98	31,30	20,27	21,84	100,00
Bombona	7,20	12,16	11,94	23,20	7,20	10,36	100,00
Botana	7,20	16,66	14,86	18,08	8,10	17,11	100,00
Obonuco	13,28	24,77	17,56	14,41	15,09	15,54	36,48
San Bernardo	6,75	24,54	9,45	14,18	7,20	10,58	100,00
Taminango	8,10	100,00	10,13	8,55	6,30	10,81	100,00
Monopamba	10,13	18,24	15,31	34,09	12,62	16,89	100,00
Aeropuerto Antonio Nariño	6,30	6,76	6,98	10,58	5,85	8,10	44,14
Sindagua	19,36	25,22	21,39	20,94	19,59	25,00	100,00
El Encano	10,58	14,63	14,63	17,11	12,83	11,48	59,68

6.4 Imputación datos faltantes

El impacto de los datos faltantes en las series temporales puede repercutir en posibles sesgos y en el tamaño de la muestra disponible para el análisis, por lo tanto, la imputación de datos faltantes se realizó para conseguir una serie temporal con mayor validez estadística.

Las series temporales de las variables climatológicas pueden verse afectadas por diferentes eventos que repercuten en los registros, como: la interrupción en las lecturas, fallos en los instrumentos de medida, errores de digitación, entre otros. Por eso, ante la ausencia y/o escasez de datos Allen *et al.*, (1998) sugieren procedimientos para la imputación de datos faltantes a nivel mundial, sin embargo, al evaluar su aplicabilidad en el contexto local de esta investigación, se evidenció que lo sugerido no representa la realidad de los datos observados, por lo tanto, se buscaron otras metodologías para estimar valores similares a los datos observados.

6.4.1 Datos faltantes de precipitación

Para la precipitación se realizó el proceso de imputación de datos faltantes desarrollado por Paulus y Kohler (1952), con el método de razón normal, el cual emplea los registros de estaciones próximas a la estación que se desea calcular y viene dado por la Ecuación 1.

$$P_x = \frac{1}{n} * \left[\left(\frac{N_x}{N_1} \right) * P_1 + \left(\frac{N_x}{N_2} \right) * P_2 + \dots + \left(\frac{N_x}{N_n} \right) * P_n \right]$$

Ecuación 1

Donde:

n: número de estaciones pluviométricas con datos de registros continuos

P_x: precipitación de la estación con datos faltantes durante el periodo de tiempo a completar.

P_n: precipitación de las estaciones auxiliares del periodo de tiempo a completar.

N_x: Precipitación media multianual de la estación con datos faltantes.

N_n: Precipitación media multianual de las estaciones multianuales.

En la Tabla 4 se presentan las estaciones cercanas elegidas para la estimación del método y en la Figura 4 se observa la distribución espacial de la red pluviométrica del departamento de Nariño.

Tabla 4 Estaciones elegidas para la aplicación del método de razón normal

Estación de estudio	Abreviatura estación de estudio	Estaciones cercanas	Abreviatura estaciones cercanas
Barbacoas	BAR	Magui, Guayacana y Jose Tapaje	MAG, GYA Y JOS
Bombona	BOM	Imues, Nariño y Tangua	IMU, NAR Y TAN
Botana	BOT	Tangua, Remolino y Riobobo	TAN, RMO Y RBB
Obonuco	OBO	Tangua, Remolino y Riobobo	TAN, RMO Y RBB
San Bernardo	SBO	Hidromayo, La Cruz y Aponte	HID, CRU Y APO
Taminango	TAM	Berruecos, Peñol y Union	BER, PEÑ Y UNI
Monopamba	MON	Gualmatan, Aeropuerto San Luis y Puerres	GMT, ASL Y PUE
Aeropuerto Antonio Nariño	AAN	Remolino, Peñol y Sandona	RMO, PEÑ Y SAN
El Encano	EEN	Remolino, Aponte y Riobobo	REM, APO Y RBB
Sindagua	SIN	Tangua, Imues y Paraiso	TAN, IMU Y PAR




Figura 4 distribución espacial de estaciones del departamento de Nariño, fuente: elaboración propia

6.4.2 Datos faltantes de horas de brillo solar

Para la imputación de datos faltantes de horas de brillo solar se siguió la metodología desarrollada por Angstrom (1924), el cual planteó utilizar la Ecuación 2 para la estimación del promedio diario de radiación solar:

$$\frac{H}{H_0} = a + b \cdot \frac{S}{S_0}$$

Ecuación 2

Donde:

H : es el promedio diario de la radiación solar ($W \cdot m^2 / día$).

H_o : es el promedio diario de la radiación extraterrestre diaria ($W \cdot m^2 / día$).

S : promedio diario de brillo solar (horas).

S_o : máxima duración de brillo solar posible (horas).

a y b : coeficientes empíricos.

Para el cálculo de H_o se utilizó la Ecuación 3:

$$H_o: \frac{24}{\pi} * I_{sc} * F * [\cos \Theta * \cos \delta * \sin \omega_s + \frac{\pi}{180} * \omega_s * \sin \Theta * \sin \delta]$$

Ecuación 3

Donde:

I_{sc} : es la constante solar ($1367 W \cdot m^2$).

F : es el factor de corrección de excentricidad.

Θ : es la latitud del sitio.

δ : es la declinación solar.

ω_s : ángulo medio de la inclinación solar.

El factor de corrección de excentricidad (F), la declinación solar (δ) y el ángulo medio de la inclinación solar (ω_s), se estimaron a través de la Ecuaciones 4 a 6:

$$F : 1 + 0,033 * [\cos(\frac{360 * n}{365})]$$

Ecuación 4

$$\delta: 23,45 \sin[\frac{360(284+n)}{365}]$$

Ecuación 5

$$\omega_s: \cos^{-1}(-\tan \Theta * \tan \delta)$$

Ecuación 6

Donde:

n : es el número del día empezando el primero de enero.

Para un mes dado, la máxima duración de brillo solar posible (S_o) se calculó con la Ecuación 7:

$$S_o: \frac{2}{15} * \omega_s$$

Ecuación 7

Adicionalmente Rietveld (1978) examinó varios valores publicados de los coeficientes a y b , donde observó que a está relacionado linealmente y b hiperbólicamente al valor promedio de S/S_o , según la Ecuación 8 y Ecuación 9:

$$a = 0,10 + 0,24 * \frac{S}{S_o}$$

Ecuación 8

$$b = 0,38 + 0,08 * \frac{S}{S_o}$$

Ecuación 9

Al sustituir dichos coeficientes en la Ecuación 2, la ecuación de Angstrom se convierte en la propuesta en la Ecuación 10:

$$\frac{H}{H_o} = 0,18 + 0,62 * \frac{S}{S_o}$$

Ecuación 10

El resultado obtenido de H está en las siguientes unidades: $W \cdot m^2/día$, por lo tanto, de acuerdo con lo propuesto por SunFields (2007), se recomienda utilizar el factor de conversión que indica que una hora de brillo solar es igual a $1000 W/m^2$, y así se puede obtener las horas de brillo solar en función de la potencia por área.

6.4.3 Datos faltantes de humedad relativa, velocidad del viento, temperatura máxima y mínima

Para estas variables, como el coeficiente de variación a escala mensual es bajo y fluctúa alrededor de los valores medios ($< 10\%$), es factible reemplazar el promedio mensual multianual, ya que se considera que la variabilidad no representa un error significativo en las series de tiempo (Castro & Carvajal-Escobar, 2010).

6.5 Análisis exploratorio y confirmatorio de los datos

Para el análisis exploratorio de datos se utilizó el programa R, el cual es un lenguaje de programación interpretado, es decir, que permite ejecutar comandos libremente sin que se deba compilar el programa, este destaca por su enfoque hacia el análisis estadístico. Inicialmente se estimaron estadísticos básicos, como: promedio, valor máximo, valor mínimo, desviación estándar y coeficiente de variación, los cuales permitieron tener un primer acercamiento a los datos, y conocer su comportamiento general. Posteriormente, se realizó un análisis gráfico en el cual se hicieron: diagramas de dispersión, de caja e histogramas de frecuencia, con el fin de

examinar los datos, identificar datos atípicos, observar cambios y/o tendencias en las series temporales. Finalmente se realizó la prueba de normalidad de Jarque & Bera (1980), para verificar si los datos provenían de una población normalmente distribuida, ya que a diferencia de otras pruebas, esta involucra tanto la asimetría, como la curtosis en la serie de datos.

6.6 Estimación de la evapotranspiración potencial

La estimación de la evapotranspiración potencial se realizó con los métodos: FAO-PM56, Hargreaves, Thornthwaite y Turc debido a que son los más aceptados y utilizados internacionalmente, no obstante, también se calculó el de Jaramillo (2006), el cual fue desarrollado en condiciones del trópico colombiano. En la Tabla 5 se presentan los diferentes métodos evaluados, las variables de entrada requeridas y complejidad.

Tabla 5 Métodos de evapotranspiración potencial, fuente: elaboración propia

Nombre y autor	Variables de entrada	Complejidad	Fórmula
FAO-PM56 (Allen <i>et al.</i> , 1998)	Temperatura mínima, máxima, radiación, altura, velocidad del viento y horas de brillo solar.	Alta	$ET_0 = \frac{(0,408 \cdot \Delta \cdot (R_n - G) + \gamma \cdot \left(\frac{900}{Z + 273}\right) \cdot U_2 \cdot (e_s - e_a))}{\Delta + \gamma(1 + 0,34 \cdot U_2)}$ Para más información, remitirse a (Allen, 2006).
Thornthwaite Thornthwaite & Wilm (1948).	Temperatura media.	Baja	$I = 12 \cdot \left(\frac{T_{medAnual}}{5}\right)^{1,514}$ $a = (675 \cdot 10^{-9}) \cdot I^3 - (771 \cdot 10^{-7}) \cdot I^2 + (-179 \cdot 10^{-4}) \cdot I + 0,492$ $ET_0 = 16 \cdot K \cdot \left(\frac{10 \cdot t_{med}}{I}\right)^a$ Para más información, remitirse a Thornthwaite & Wilm (1948).
Turc (Turc, 1961).	Temperatura máxima y temperatura mínima, humedad relativa y radiación solar.	Media	$ET_0 = 0,0133 \cdot \frac{t_{med}}{t_{med} + 15} \cdot (R_s + 50) \text{ si Hum rel} > 50\%$ $ET_0 = 0,0133 \cdot \frac{t_{med}}{t_{med} + 15} \cdot (R_s + 50) \cdot \left(1 + \frac{50 - HR}{70}\right) \text{ si Hum rel} < 50\%$ Para más información, remitirse a (Turc, 1961).
Hargreaves (Hargreaves & Samani, 1985).	Radiación solar, temperatura máxima, media y mínima.	Baja	$ET_0 = 0,023 \cdot (t_{med} + 17,78) \cdot R_o \cdot (t_{max} - t_{min})^{0,5}$ Para más información, remitirse a Hargreaves & Samani, (1985).
Cenicafé (Jaramillo, 2006)	Altura.	Baja	$ET_0 = 4,37 \cdot e^{(-0,002 \cdot H)}$ Donde H es altura en metros (Jaramillo, 2006).

Para la estimación de la evapotranspiración potencial se utilizó el paquete “SPEI” desarrollado por Vicente-Serrano, Beguería y López-Moreno (2010) en el software R, donde se encuentran específicamente los métodos de Hargreaves, Thornthwaite

y FAO-PM56. Los métodos de Cenicafé y Turc, se calcularon por medio de hojas electrónicas en formato .xlsx.

El método considerado como “**patrón de referencia**” por la FAO para estimar la ET_0 es FAO-PM56 ya que es el que más variables climatológicas involucra, sin embargo, no siempre se puede aplicar este método, ya que como se explicó anteriormente su complejidad es alta. Por ejemplo, en la presente investigación solo 3 estaciones de las 10 seleccionadas tenían información de la velocidad del viento. Por lo tanto, se realizó una comparación entre los otros métodos con el de FAO-PM56 mediante métricas de desempeño de validación, para encontrar el más correlacionado y poder estimar la ET_0 para las 10 estaciones.

6.7 Evaluación de métricas de desempeño de validación

Para evaluar los métodos de ET_0 , se realizaron las pruebas estadísticas presentadas en la Tabla 6, de acuerdo con lo sugerido por estudios anteriores (Almorox, 2008; Toté et al., 2015):

Tabla 6 métricas de desempeño de validación usadas en la investigación

Nombre	Fórmula	Resultado ideal
Coeficiente de correlación de Pearson (R)	$R = \frac{\sum (G - \bar{G}) * (S - \bar{S})}{\sqrt{(\sum (G - \bar{G})^2) * \sum (S - \bar{S})^2}}$ Para más información, remitirse a Toté et al., (2015)	1
BIAS	$BIAS = \frac{\sum S}{\sum G}$ Para más información, remitirse a (Toté et al., 2015)	1
NSE (Nash-Sutcliffe equation)	$NSE = 1 - \frac{[\sum (ET_{0PM-56} - ET_{0Har})^2]}{[\sum (ET_{0PM-56} - ET_{0promedioHar})^2]}$ Para más información, remitirse a Toté et al., (2015)	1
RMSE - (Root mean-square error)	$RMSE = \frac{\sum (di)^2}{N \text{ obs}^{0.5}}$ Para más información, remitirse a Almorox, (2008)	0
Estadístico t	$t = \frac{[(N \text{ obs} - 1) - MBE^2]}{[(RMSE^2 - MBE^2)]^{0.5}}$ Para más información, remitirse a Almorox, (2008)	0

El coeficiente de correlación de Pearson y BIAS se usan para evaluar que tan bien se hacen las estimaciones con respecto al valor observado. El valor de RMSE (error cuadrático medio) aporta información acerca de la bondad de la estimación, comparando dato a dato la desviación real entre los valores estimados y los calculados. Finalmente, para una mejor validación del modelo, se sugiere estimar el estadístico t y NSE (ecuación Nash-Sutcliffe).

6.8 Aplicación de Inteligencia artificial para la evapotranspiración potencial

De acuerdo con lo propuesto por Tayfur (2017), los procesos hidrológicos pueden considerarse como no lineales en la naturaleza. Algunas variables como el caudal, evapotranspiración y precipitación en diferentes lugares tienen un parámetro de dependencia con el tiempo. Por eso, cuando los algoritmos y parámetros de la inteligencia artificial de los modelos se formulan adecuadamente, se producen resultados económicos, rápidos y precisos. Es importante que la persona que construya el modelo tenga la capacidad de identificar la relación de las variables con el ciclo hidrológico, con el fin de seleccionar o cambiar los parámetros, funciones, números de iteración y algoritmos basados en su experiencia, para obtener el mejor resultado (Murat y Serhat, 2018).

En esta investigación se compararon dos métodos, uno de inteligencia artificial llamado redes neuronales artificiales y otro estadístico llamado regresión lineal múltiple, con el fin de evaluar si alguno facilita la estimación de la ET_0 .

El análisis de regresión es una técnica estadística para investigar y modelar la relación entre variables. Las aplicaciones de la regresión son numerosas y ocurren en casi todos los campos, incluida la ingeniería, las ciencias físicas y químicas, la economía, la administración, las ciencias biológicas y sociales, entre otras, donde una ventaja de la regresión lineal múltiple es que evalúa el efecto de cada predictor en presencia del resto de variables (Montgomery *et al.*, 2012). La composición general de un modelo de regresión lineal se presenta en la Ecuación 11:

$$y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + e$$

Ecuación 11

Donde:

y = Variable de respuesta

β_0 = Intercepto

$\beta_1, \dots, \beta_k$ = coeficientes de regresión asociados a las variables regresoras $X_1, \dots, X_k$, respectivamente.

e = error aleatorio que debe cumplir con los supuestos de linealidad, normalidad, homocedasticidad e independencia.

En este caso, se construyeron dos modelos que involucra más de una variable regresora, es decir, un modelo de regresión lineal múltiple, uno para estimar la ET_0 .

por el método de Hargreaves y otro para el FAO-PM56. Para ambos casos se consideraron las siguientes variables regresoras:

PEN = evapotranspiración potencial por el método de FAO-PM56 (mm/mes).

HAR = evapotranspiración potencial por el método de Hargreaves (mm/mes).

Rad = radiación solar ($\text{Mj} \cdot \text{m}^2/\text{d}$)

Tmax= temperatura máxima ($^{\circ}\text{C}$)

Tmin= temperatura mínima ($^{\circ}\text{C}$)

humrel= humedad relativa (%).

HBS= Horas de brillo solar (horas/día).

cota= altura sobre el nivel del mar (m).

Inicialmente se organizó toda la información de las 10 estaciones en una hoja de cálculo formato .xlsx, donde se incluyeron todos los registros de las 6 variables regresoras y la variable de respuesta. Luego se realizó la prueba de normalidad de Jarque & Bera, con el fin de verificar si los datos provenían de una población normalmente distribuida, para aplicar un coeficiente de correlación (Spearman o Pearson), que permitiera encontrar las variables más correlacionadas con la variable de respuesta.

Posterior a ello, se formularon diferentes modelos de regresión lineal múltiple mediante el lenguaje de programación R en la versión 4.0.4. Para evitar la colinealidad entre las variables regresoras, se aplicó el criterio de información de Akaike (AIC, por sus siglas en inglés) con el fin de identificar las variables más relevantes para la explicación de la ET_o (Venables, 2002). Después se realizó la estimación del factor de inflación de varianza (VIF, por sus siglas en inglés) el cual indica que si sus valores son superiores a 5 hay indicios de que los coeficientes asociados de regresión están mal estimados debido a la multicolinealidad entre las variables regresoras (Montgomery *et al.*, 2002). Luego se estimó el coeficiente de determinación (R^2) y se seleccionó el modelo que tuviera mejores resultados estadísticos, para posteriormente evaluar los supuestos del error, con el fin de garantizar que la predicción sea uniforme en cualquier instante de tiempo.

En relación con el método de inteligencia artificial, todas las redes neuronales artificiales tienen una capa de entrada y de salida; sin embargo, el número de capas ocultas puede variar dependiendo de la complejidad de cada problema. Zhang *et al* (1997) reportan que no existe un proceso estandarizado para garantizar una solución óptima, de ahí que algunos investigadores sugieran adoptar la metodología ensayo y error (Zulifqar *et al.*, 2017). De modo que factores tales como: número de

entrada, capas ocultas y neuronas, son seleccionados de acuerdo con el criterio del desarrollador.

Para la elaboración del modelo de redes neuronales artificiales, se usó el lenguaje de programación Python, en la plataforma Anaconda mediante el entorno spyder 4.1.4. También se utilizó la librería sklearn y las funciones MLPRegressor y preprocessing, para definir la mejor arquitectura de la red neuronal artificial. Se adoptó la metodología de ensayo y error y se realizaron diferentes iteraciones variando los optimizadores, neuronas en la capa oculta y funciones de activación.

Para la comparación de los modelos, se aplicaron las mismas métricas de desempeño de la ET_0 , sin embargo, se eliminó la métrica NSE y se agregó el coeficiente de determinación (R^2), pues como mencionan Cardona *et al.* (2013) esta prueba se utiliza para evaluar la varianza explicada de los modelos de inteligencia artificial.

6.9 Estimación del SPEI

Para la estimación del SPEI, se utilizó la metodología propuesta por el autor Vicente-Serrano, Beguería y López-Moreno (2010). El balance hídrico empleado en esta investigación considero los datos de precipitación mensual y la ET_0 del método de Hargreaves con redes neuronales artificiales. La estimación del índice se realizó en el programa R, con el paquete “SPEI”, los cálculos se presentan con las Ecuaciones 12 y 13:

$$SPEI = W - \frac{C_0 + C_1 W + C_2 W^2}{1 + d_1 W + d_2 W^2 + d_3 W^3}$$

Ecuación 12

Donde:

$$W = \sqrt{-2 \ln \ln(P)} \text{ si } P \leq 0.5$$

Ecuación 13

P es la probabilidad de exceder un valor D determinado, $P = 1 - F(x)$. Si $p > 0,5$, entonces P se reemplaza por $1 - P$ y se invierte el signo del SPEI resultante. Las constantes son $C_0 = 2,515517$, $C_1 = 0,802853$, $C_2 = 0,010328$, $d_1 = 1,432788$, $d_2 = 0,189269$ y $d_3 = 0,001308$.

Básicamente, las funciones del paquete “SPEI” estandarizan una variable siguiendo una función de distribución log-Logística (Gamma, o Pearson III); es decir, la transforman en una variante Gaussiana estándar con media cero y desviación estándar de uno.

Para clasificar la intensidad del índice SPEI se recomienda utilizar la información presentada en la Tabla 7, ya que así se puede evaluar y cuantificar los resultados obtenidos, asimismo se sugiere utilizar la gama de colores propuesta, para visualizar la variabilidad del índice.

Tabla 7 Clasificación índice SPEI, fuente: (Vicente-Serrano, Beguería y López-Moreno, 2010)

Valores SPEI	Clasificación	Color
Mayor o igual a 2	Extremadamente húmedo	
Entre 1,5 y 1,99	Muy húmedo	
Entre 1,00 y 1,49	Moderadamente húmedo	
Entre -0,99 y 0,99	Aproximadamente normal	
Entre -1,00 y -1,49	Moderadamente seco	
Entre -1,50 y -1,99	Severamente seco	
Menor o igual a -2	Extremadamente seco	

Para esta investigación se estimó el índice SPEI de las 10 estaciones presentadas en la Figura 3, en las siguientes escalas temporales: trimestral, semestral y anual. Estas escalas permitirán ver la variación intranual de la sequía y las posibles zonas secas del departamento de Nariño.

6.10 Estimación del área bajo la curva y definición de periodos más secos

Primeramente, se organizó la información en una hoja de cálculo formato .xlsx, del SPEI de las 10 estaciones y del promedio por cada escala temporal. Luego se aplicó el ACPNL (Análisis De Componentes Principales No Lineal), el cual es un método basado en perceptrón multicapa de tipo autoencoder, que permite reducir la dimensionalidad y simplificar la complejidad de espacios conservando su información (Scholz *et al.*, 2008). Este proceso se realizó en MATLAB, se usaron 5 capas ocultas con 8, 4, 2, 4 y 8 neuronas respectivamente, una tasa de aprendizaje de 0,001 y un porcentaje promedio de la varianza explicada del 74,13%.

Posteriormente, se calcularon los autovalores de cada componente, donde se observó que las dos primeras componentes son las que mejor explican el SPEI.

Luego se calculó el coeficiente de determinación entre la serie del SPEI en cada escala temporal con su primera y segunda componente, con el fin de evaluar cuál tiene mayor relación con el comportamiento promedio del índice. Después, se graficó el resultado de la primera componente del SPEI con el valor promedio del SPEI de todas las estaciones de cada escala temporal, lo cual permitió observar que la primera componente explica el comportamiento del SPEI y los posibles periodos secos del SPEI.

Finalmente se construyó un código en python con el paquete “**scipy.integrate**” para integrar el área bajo la curva y a pesar de que se consideraron varios métodos, se seleccionó el método de Simpson, debido a que es el que mejor trabaja con funciones no lineales (Tallarida y Murray, 1987).

6.11 Espacialización del SPEI

Luego de identificar los periodos más secos, se espacializaron los resultados con un programa de sistemas de información geográfico, utilizando el método kriging con el semivariograma esférico, pues Basconcillo *et al.*, (2017) y Cerón *et al.*, (2021), sugieren que con esta técnica se obtienen buenas correlaciones con la temperatura y precipitación, lo cual hará posible obtener una interpolación más acercada a la realidad para el índice de sequía SPEI.

7. RESULTADOS Y DISCUSIÓN

7.1 Imputación de datos faltantes

La imputación de datos faltantes se aplicó a la precipitación, horas de brillo solar, humedad relativa, temperatura máxima y mínima y velocidad del viento. Se presenta el resultado de precipitación en la estación Sindagua, ya que presentó el mayor porcentaje de datos faltantes (15,5%). Los resultados de la serie reconstruida se observan en la Figura 5 el resto de las variables y estaciones se presentan en el Anexo 1.




Figura 5 reconstrucción precipitación Sindagua

En términos generales, se observó que los valores estimados con los diferentes métodos de imputación de datos faltantes siguieron la tendencia de los valores observados, lo cual demuestra que los métodos evaluados en esta investigación aportaron información para un mayor soporte estadístico a las series temporales.

7.2 Análisis exploratorio y confirmatorio de datos

Se muestra el análisis descriptivo para la precipitación ya que es la variable más importante del ciclo hidrológico en regiones tropicales, los resultados de las otras variables se presentan en el Anexo 2. En relación con el análisis exploratorio y confirmatorio solo se presentó para una estación de Nariño; sin embargo, en el Anexo 3 se evidencian los análisis gráficos de las otras estaciones.

7.2.1 Análisis descriptivo

En la Tabla 8 se observan los estadísticos descriptivos de la precipitación de las estaciones seleccionadas, con el fin de observar la variabilidad intraestacional en la zona de estudio.

Tabla 8 Estadísticos descriptivos precipitación

Estación	$\bar{X}$ (mm)	Vmax (mm)	Vmin (mm)	DE (mm)	CV (%)	Coefficiente de asimetría	Región
Barbacoas	564	1391	185	217	41	0,33	Pacífico
Bombona	86	268	0	45	61	0,58	Andina
Botana	78	227	15	33	43	0,91	Andina
Obonuco	68	567	0	39	61	3,46	Andina
San Bernardo	168	539	0	79	54	0,61	Andina
Taminango	142	515	0	72	58	0,71	Andina
Monopamba	264	682	57	92	35	0,89	Amazónica
Aeropuerto Antonio Nariño	99	327	0	54	63	0,71	Andina
El Encano	116	353	21	46	41	0,74	Andina
Sindagua	81	267	2	39	53	0,67	Andina

$\bar{X}$: Promedio mensual multianual, Vmax: valor máximo, Vmin: valor mínimo, DE: desviación estándar, CV: coeficiente de variación

La precipitación promedio mensual multianual presenta valores altos en la estación Barbacoas (564 mm/mes) y Monopamba (264 mm/mes), mientras que las demás estaciones ubicadas en la región Andina presentan precipitaciones entre 68 mm/mes y 142 mm/mes. Asimismo, se evidenciaron valores de precipitación máximos superiores a 1000 mm/mes en la estación Barbacoas y valores de precipitación mínimos cercanos a 0 mm/mes en la mayoría de las estaciones de la región Andina. Finalmente, se evidencia que la media no es representativa en los datos, ya que tanto la DE como el CV presentan valores superiores a 30 mm y 30% respectivamente, un resultado coherente, teniendo en cuenta que la precipitación es un fenómeno aleatorio y variable.


7.2.2 Análisis gráfico

En relación con la variabilidad interanual, se seleccionó la estación Aeropuerto Antonio Nariño, ya que se considera la más consistente del departamento de Nariño, por tener la serie temporal más continua y con menor cantidad de datos faltantes. En la Figura 6 se presentan los resultados gráficos de la precipitación media mensual de Aeropuerto Antonio Nariño.


EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO



a)



b)



c)




Figura 6 Análisis gráfico precipitación media mensual Aeropuerto Antonio Nariño: a) gráfico de barras b) diagrama de cajas y bigotes y c) histograma de frecuencia

En la Figura 7 se muestran los resultados gráficos del promedio de la temperatura media mensual de la estación Aeropuerto Antonio Nariño.

EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO





Figura 7 Análisis gráfico temperatura media mensual Aeropuerto Antonio Nariño: a) gráfico de barras b) diagrama de cajas y bigotes y c) histograma de frecuencia

En la Figura 8 se observan los resultados gráficos del promedio de humedad relativa (%) mensual de la estación Aeropuerto Antonio Nariño.






Figura 8 Análisis gráfico humedad relativa mensual Aeropuerto Antonio Nariño: a) gráfico de barras b) diagrama de cajas y bigotes y c) histograma de frecuencia

En la Figura 9 se muestran los resultados gráficos del promedio mensual del promedio de horas de brillo solar mensual de la estación Aeropuerto Antonio Nariño.




Figura 9 Análisis gráfico promedio de horas de brillo solar mensual Aeropuerto Antonio Nariño: a) gráfico de barras b) diagrama de cajas y bigotes y c) histograma de frecuencia

En las Figuras 6-9a se presentan los gráficos de barras de las variables de estudio, donde se evidenció un régimen bimodal de lluvias característico de la región Andina, con periodos lluviosos en marzo-abril-mayo y septiembre-octubre-noviembre y periodos secos en junio-julio-agosto y diciembre-enero-febrero, a excepción de la estación Barbacoas y Monopamba, las cuales tuvieron régimen monomodal. Con relación a la humedad relativa, se observó que durante los meses de agosto-septiembre-octubre se registraron los valores más bajos. Respecto a la temperatura media y horas de brillo solar no se observó algún comportamiento característico.

En relación con las Figuras 6-9b, se presentaron los diagramas de cajas y bigotes, los cuales mostraron variabilidad significativa con respecto a la media para la precipitación y horas de brillo solar, contrario a la humedad relativa y temperatura media. Además, se observó que los rangos intercuartiles no estaban homogéneamente distribuidos, pues la mayoría de los datos se encontraban concentrados en los valores más bajos en la precipitación y hacia los más altos en la humedad relativa. También se evidenciaron datos atípicos en todas las variables, sin embargo, no se eliminaron, debido a que algunas estaciones cercanas reportaron valores similares en el caso de la región Andina y otras no tenían punto de comparación como en el caso de la región Pacífico y Amazónica.

Finalmente, en las Figuras 6-9c, se presentaron los histogramas de frecuencia, donde se observó una ligera asimetría positiva en el caso de la precipitación, lo que aunado a lo obtenido en los diagramas de caja y bigotes, muestra la tendencia de precipitaciones bajas. Para la humedad relativa se observó una significativa asimetría negativa, lo cual demostró la concentración hacia los valores más altos. Para la temperatura media y horas de brillo solar se observó una concentración hacia los valores promedio.

7.2.3 Pruebas de normalidad

La prueba de Jarque & Bera indica que cuando el *valor p* es superior a 0,05 se adopta la hipótesis nula, la cual menciona que la serie de datos siguen una distribución normal, de lo contrario se rechaza y se adopta la hipótesis alterna, la cual sugiere que los datos no siguen una distribución normal. En la Tabla 9 se presentan los resultados de la prueba de normalidad Jarque & Bera de todas las variables de estudio.

Tabla 9 Resultados pruebas de normalidad Jarque & Bera

Sigla	Precipitación	Temperatura media	Humedad relativa	Horas de brillo solar	Velocidad del viento
	Valor <i>p</i>	Valor <i>p</i>	Valor <i>p</i>	Valor <i>p</i>	Valor <i>p</i>
BAR	0,00	0,00	0,00	0,12	N.A
BOM	0,00	0,00	0,00	0,48	N.A
BOT	0,00	0,00	0,36	0,00	N.A
OBO	0,00	0,00	0,00	0,00	0,00
SBO	0,00	0,26	0,00	0,64	N.A
TAM	0,00	0,00	0,00	0,00	N.A
MON	0,00	0,00	0,90	0,01	N.A
AAN	0,00	0,00	0,00	0,02	0,00
EEN	0,00	0,00	0,00	0,00	0,00
SIN	0,00	0,01	0,00	0,00	N.A

N.A : no aplica

No se pudo estimar la normalidad de la velocidad del viento para la mayoría de las estaciones, debido a que no se tenían datos. En relación con las otras variables se observó que la mayoría de *los valores p* fueron inferiores a 0,05, sugiriendo que las variables en estudio no presentan una distribución normal. El conocer que los datos no siguen una distribución normal, permitió determinar el uso de pruebas no paramétricas en futuros cálculos para la serie.

7.3 Estimación evapotranspiración potencial

En las Figuras 10 a 12, se observan los resultados de la ET_0 anual de las tres estaciones con las cuales se pudo estimar el método de FAO-PM56, en el eje de las ordenadas se observan los 37 años de registro y en el eje de las abscisas se observan los valores de evapotranspiración potencial en el año. En el Anexo 4. se presentan los resultados a escala mensual y anual de todas las estaciones.

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**




Figura 10 Resultados ETo acumulada anual de la estación Aeropuerto Antonio Nariño




Figura 11 Resultados ETo acumulada anual de la estación Obonuco




Figura 12 Resultados ETo acumulada anual de la estación El Encano

De las Figuras anteriores, se observó que la evapotranspiración potencial anual presenta los valores más altos en la estación Aeropuerto Antonio Nariño (> 1500 mm/año) y valores más bajos en Obonuco y El Encano (< 700 mm/año). Asimismo, se evidenció que los métodos de Hargreaves y Turc sobreestimaron la evapotranspiración potencial en relación con el “**patrón de referencia**”, el método de Thornthwaite lo subestimo y el método de Cenicafé tuvo un comportamiento lineal.

En las Figuras 13 a 15, se presentan los resultados de la ETo mensual de las tres estaciones con las cuales se pudo estimar el método de FAO-PM56.

EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO




Figura 13 Resultados ETo mensual de Aeropuerto Antonio Nariño




Figura 14 Resultados ETo mensual de Obonuco




Figura 15 Resultados ETo mensual de El Encano

La evapotranspiración potencial mensual presenta un comportamiento similar al observado en la evapotranspiración potencial anual, donde los valores más altos en la estación Aeropuerto Antonio Nariño (> 140 mm/mes) y los más bajos en Obonuco y El Encano (< 50 mm/mes). Además, se observó que el método de Hargreaves y Turc sobreestimaron la evapotranspiración potencial en relación con el “**patrón de referencia**”, el método de Thornthwaite lo subestimo y el método de Cenicafé tuvo un comportamiento casi lineal.

Teniendo en cuenta los resultados obtenidos a escala mensual y anual, hay tres que destacan:

1. El método de Hargreaves sobrestima en magnitud y el de Turc subestima al método FAO-PM56; sin embargo, en cuanto a forma, ambos son muy parecidos.
2. El método de Thornthwaite en las tres estaciones se encuentra considerablemente subestimado en magnitud al de FAO-PM56, aunque su forma también es similar.
3. El método definido como Cenicafé, propuesto por Jaramillo (2006), considera la evapotranspiración potencial como una constante, y este es un proceso que no solo depende de la altura, por lo tanto este método se descartará para la comparación.

7.4 Evaluación métricas de desempeño de validación

Las métricas de desempeño de validación se aplicaron con el fin de conocer mediante un análisis estadístico, cual método tuvo mejor correlación con respecto a FAO-PM56 para mejorar la precisión del índice SPEI. En las Tablas 10 a 12 se presentan los resultados.

Tabla 10 Métricas de desempeño de validación para la estación Aeropuerto Antonio Nariño, fuente: elaboración propia

Validación FAO-PM56 - Aeropuerto Antonio Nariño				
Métrica de desempeño	FAO-PM56 vs. Hargreaves	FAO-PM56 vs. Turc	FAO-PM56 vs. Thornthwaite	Resultado ideal
Pearson	0,83	0,72	0,79	1,00
BIAS	1,13	0,88	0,55	1,00
NSE	0,31	-0,09	0,04	1,00
RMSE	19,53	22,68	59,76	0,00
Estadístico t	42,59	19,00	117,71	0,00

Tabla 11 Métricas de desempeño de validación para la estación Obonuco, fuente: elaboración propia

Validación FAO-PM56 - Obonuco				
Métrica de desempeño	FAO-PM56 vs. Hargreaves	FAO-PM56 vs. Turc	FAO-PM56 vs. Thornthwaite	Resultado ideal
Pearson	0,79	0,72	0,24	1,00
BIAS	1,11	0,81	0,52	1,00
NSE	0,21	0,06	0,00	1,00
RMSE	13,00	21,05	50,25	0,00
Estadístico t	39,86	54,72	117,38	0,00

Tabla 12 Métricas de desempeño de validación para la estación El Encano, fuente: elaboración propia

Validación FAO-PM56 - El Encano				
Métrica de desempeño	FAO-PM56 vs. Hargreaves	FAO-PM56 vs. Turc	FAO-PM56 vs. Thornthwaite	Resultado ideal
Pearson	0,80	0,74	0,26	1,00
BIAS	1,27	0,97	0,58	1,00
NSE	0,04	-1,06	0,00	1,00
RMSE	24,77	11,38	38,84	0,00
Estadístico t	87,19	3,86	105,37	0,00

Se observó que para las estaciones Aeropuerto Antonio Nariño y Obonuco el método de Hargreaves fue el que tuvo métricas más ajustadas respecto al “**patrón de referencia**”; sin embargo, para la estación El Encano el método de mejor ajuste fue Turc. Además, se evidenció que a pesar de que el método de Thornthwaite tuvo una forma similar al “**patrón de referencia**”, estadísticamente sus resultados difieren significativamente de los otros métodos. Por lo tanto, se determinó que el **método de Hargreaves** fue el que tuvo la mejor correlación con el “**patrón de referencia**”. En ese orden de ideas, se calculó la ET_0 con el método de Hargreaves para las diez estaciones de estudio, lo cual se respalda conforme a lo recomendado por Allen *et al* (2006) y Almorox (2008), ya que al ser un método de complejidad baja permite una fácil aplicación.

7.5 Aplicación de Inteligencia artificial para la evapotranspiración potencial

7.5.1 Modelo de regresión lineal múltiple Hargreaves

Inicialmente se aplicó la prueba Jarque & Bera a las variables regresoras y a la de respuesta, con el fin de ver si los datos seguían una distribución normal, los resultados se presentan en la Tabla 13.

Tabla 13 Resumen resultados prueba de normalidad y coeficiente de Spearman entre variables regresoras y variables de respuesta del modelo de Hargreaves

Variables	Valor p	Coeficiente de Correlación de Spearman
Variable de respuesta	0,00	1,00
HAR (mm/mes)		
Variable regresora		
RAD ($\text{mJ} \cdot \text{m}^2/\text{día}$)	0,00	0,50
humrel (%)	0,00	0,10
Tmax ($^{\circ}\text{C}$)	0,00	0,92
HBS (horas/día)	0,00	0,20
Tmin ($^{\circ}\text{C}$)	0,00	0,66
COTA (metros)	0,00	-0,72

Los resultados mostraron que ninguna variable regresora tuvo un *valor p* superior a 0,05, por lo tanto, se sugiere que todas las variables en estudio no presentan un ajuste a la distribución normal. Posteriormente, se calculó el coeficiente de correlación de Spearman, para conocer la correlación entre las variables regresoras y la de respuesta. De los resultados se observó que las variables con mayor correlación fueron: Tmax, Tmin y cota.

Posteriormente, se construyeron varios modelos de regresión lineal múltiple con sus respectivas pruebas estadísticas, los cuales se compararon, sin embargo, en el momento de validar los supuestos del error, se observó que la mayoría no se cumplieron.

Por eso, para corregir los problemas de los supuestos del error se hicieron tres modificaciones respecto a los modelos iniciales:

- i. Reemplazar los valores atípicos con el promedio mensual, debido a que estos no representan el comportamiento típico de la mayoría de los datos, lo cual probablemente influenció a que el modelo no cumpliera con los supuestos del error.
- ii. Se aplicó una transformación de logaritmo natural a la variable de respuesta.
- iii. Se adicionó la variable cota indirectamente como una variable categórica, pues como se observa en Figura 16a y b para cada cota existe una pendiente diferente.




Figura 16 Relación entre las variables regresoras y Hargreaves de acuerdo con la cota: (a) HBS y (b) Tmax

Teniendo en cuenta las modificaciones, se construyeron cinco modelos de regresión lineal múltiple con sus respectivas pruebas estadísticas, los cuales se compararon en la Tabla 14.

Tabla 14 Resumen estadístico modelos de regresión lineal múltiple HAR

Modelo	Variables regresoras	R ²		VIF					
		ajustado	AIC	RAD	Tmin	Tmax	COTA	HBS	humrel
1	RAD, Tmin, Tmax, HBS, humrel y cota (Categórica)	0,94	-29320	1,31	5,23	7,48	2,92	2,44	1,88
2	RAD, Tmax, HBS, humrel y cota (Categórica)	0,93	-28311	1,30	-	3,42	2,16	2,40	1,82
3	Tmax, HBS, humrel y cota (Categórica)	0,91	-27403	-	-	3,29	1,15	2,39	1,78
4	Tmax, HBS y cota (Categórica)	0,91	-27362	-	-	3,06	8,66	2,38	-
5	Tmax y cota (Categórica)	0,91	-27272	-	-	2,65	2,64	-	-

Los resultados muestran que los modelos saturados (1-3) tuvieron un valor de R² mayor que los modelos 4 y 5, sin embargo, paralelamente se observó que el AIC aumentaba conforme se iban eliminando variables, lo que significa que todas las variables son relevantes para la variable de respuesta. En relación con el VIF se observó que inicialmente algunos valores reportados eran mayores a 5 lo cual sugería alta colinealidad; sin embargo, a medida que se iban eliminando variables, se evidenció que los valores oscilaban entre 1-5 lo cual significa baja colinealidad. Teniendo en cuenta todos los resultados, se consideró que el modelo 5 fue el mejor, ya que además de tener un R² superior a 0,90 y el VIF más bajo, fue el más parsimonioso pues solo utilizó una variable regresora (Tmax) y otra categórica (cota), por lo tanto, será evaluado con los supuestos de error para garantizar estadísticamente su validez.

En la Figura 17a se observó que la línea roja mostró ajuste con los residuales, lo que significa que si se cumplió con la linealidad del error. Con relación a la normalidad, en la Figura 17b se observó que en el gráfico Q-Q los errores se mantuvieron dentro de los intervalos de confianza, lo que podría sugerir normalidad; sin embargo, para corroborarlo se realizó la prueba de Jarque & Bera y su *valor p* fue de 0,99, por lo tanto, también se cumplió con el supuesto de normalidad.




Figura 17 Resultados de supuestos del modelo6 de regresión lineal: (a) linealidad y (b) normalidad

Posteriormente se realizó la prueba de homocedasticidad de Goldfeld-Quandt (1965), la cual comprueba la homocedasticidad en el modelo de. El umbral para aceptar la hipótesis nula de homocedasticidad (varianza del error constante) es que el *valor p* debe ser mayor a 0,05. Inicialmente se estimó si la varianza del error es creciente y se obtuvo un *valor p* de 0,95, y de 0,05 para para la varianza del error decreciente; por lo tanto, también se cumplió con la homocedasticidad. Para validar el supuesto de independencia del error, se aplicó la prueba Durbin-Watson, la cual de acuerdo con Fox (2016) estima la autocorrelación en los, el resultado fue de 14% considerándose un valor despreciable, lo cual indica que también se cumplió con este supuesto.

En conclusión, se cumplieron con todos los supuestos del error del modelo de regresión lineal múltiple; por lo tanto, se procedió a formular las diez ecuaciones locales para estimar la ET_o por el método de Hargreaves para cada estación, los resultados se presentan en la Tabla 15.

Tabla 15 Ecuación local de ET_o Hargreaves para cada estación

Estación	Ecuación
Barbacoas	$\ln(ET_o) = 3,72 + (0,04 \cdot T_{max})$
Bombona	$\ln(ET_o) = 3,56 + (0,05 \cdot T_{max})$
Botana	$\ln(ET_o) = 3,52 + (0,06 \cdot T_{max})$

Estación	Ecuación
Obonuco	$\ln(ETo) = 3,41 + (0,06 * T_{max})$
San Bernardo	$\ln(ETo) = 3,64 + (0,05 * T_{max})$
Taminango	$\ln(ETo) = 3,53 + (0,05 * T_{max})$
Monopamba	$\ln(ETo) = 3,27 + (0,06 * T_{max})$
Aeropuerto Antonio Nariño	$\ln(ETo) = 3,57 + (0,05 * T_{max})$
El Encano	$\ln(ETo) = 3,62 + (0,06 * T_{max})$
Sindagua	$\ln(ETo) = 3,50 + (0,06 * T_{max})$

7.5.2 Modelo de Redes Neuronales artificiales - Hargreaves

Inicialmente se realizaron pruebas preliminares, donde se observó que al utilizar 3 neuronas en la capa oculta, una tasa de aprendizaje de 0,01 e iterar más de 20 veces la red, no hubo mayor variación en relación en el valor estimado. Por lo tanto, en la Tabla 16 se mostraron los resultados del R^2 , las diferentes combinaciones entre funciones de activación y optimizadores de la red neuronal artificial.

Tabla 16 Resumen estadístico y parámetros para la arquitectura de la red neuronal artificial

Función activación utilizada	Optimizador utilizado	Capas ocultas	Neuronas en la capa oculta	Tasa de aprendizaje	Número de iteraciones	Valor máximo R^2	Valor mínimo R^2	Valor medio R^2	R^2 promedio de la función de activación
identity	lbfgs	1	3	0,01	30	0,94	0,94	0,94	0,94
identity	adam	1	3	0,01	30	0,94	0,94	0,94	
identity	sgd	1	3	0,01	30	0,94	0,94	0,94	
tanh	lbfgs	1	3	0,01	30	0,95	0,94	0,94	
tanh	adam	1	3	0,01	30	0,94	0,93	0,94	0,93
tanh	sgd	1	3	0,01	30	0,93	0,92	0,92	
logistic	lbfgs	1	3	0,01	30	0,95	0,94	0,94	
logistic	adam	1	3	0,01	30	0,93	0,93	0,93	0,93
logistic	sgd	1	3	0,01	30	0,92	0,92	0,92	
relu	lbfgs	1	3	0,01	30	0,94	0,94	0,94	
relu	adam	1	3	0,01	30	0,94	0,94	0,94	0,94
relu	sgd	1	3	0,01	30	0,94	0,92	0,93	

Se observó que el valor promedio más bajo de R^2 (0,92) se obtuvo al emplear cualquier función de activación con el optimizador *sgd* (gradiente estocástico descendente) salvo *identity* (identidad). Los promedios más altos se obtuvieron con las funciones *tanh* (tangente hiperbólica) y *logistic* (logística) usando el optimizador *lbfgs* (método de Broyden-Fletcher-Goldfarb-Shanno con limitación de memoria). A pesar de que no existe una función de activación sugerida por la literatura (Jianli & Shengnan, 2019; Szandala, 2020), se utilizó la función de *tanh*, con una capa oculta, 3 neuronas, una tasa de aprendizaje de 0,01 y el optimizador *lbfgs*, debido a que dicha arquitectura reportó el mejor R^2 , tanto para Hargreaves como para FAO-PM56. En ambos casos se utilizaron todas las variables de estudio, debido a la capacidad que tiene la red neuronal artificial de adaptarse y utilizar solo las variables que necesita para estimar la variable de respuesta. Finalmente se utilizó el 20% de los datos para entrenar la red y con el 80% se validó la estimación de la evapotranspiración.

7.5.3 Comparación modelos Hargreaves

Para la comparación del modelo de regresión lineal múltiple y de red neuronal artificial, se aplicaron métricas de desempeño, los resultados se presentan en la Tabla 17.

Tabla 17 Métricas de desempeño de validación por métodos de inteligencia artificial, Hargreaves

Comparación modelos para estimar la evapotranspiración potencial por el método Hargreaves			
Métrica de desempeño	Datos observados vs RNA	Datos observados vs RLM	Resultado ideal
R	0,90	0,83	1,00
BIAS	1,00	1,00	1,00
R²	0,94	0,95	1,00
RMSE	4,77	6,04	0,00
Estadístico t	1,04	1,80	0,00

RNA: red neuronal artificial, RLM: regresión lineal múltiple

Las métricas de desempeño del modelo de redes neuronales presentaron resultados más ajustados en Pearson, R^2 y estadístico *t*, por lo tanto, estadísticamente el modelo de redes neuronales fue el mejor para estimar la ET_0 , sin embargo, también se realizó la comparación entre los valores predichos por los modelos y los observados.

En la Figura 18, se observan los resultados entre los valores predichos por el modelo de regresión lineal múltiple y de redes neuronales artificiales respecto a los observados, donde se evidenció que el modelo tendió a subestimar algunos valores respecto a los observados, sobre todo en los valores más extremos. El resto de los resultados se presentan en el Anexo 5.




Figura 18 Comparación de valores observados vs predichos por redes neuronales: (a) Barbacoas, (b) Monopamba, (c) Sindagua y (d) Botana

7.5.4 Modelo de regresión lineal múltiple FAO-PM56

Se aplicó la prueba Jarque & Bera a las variables regresoras y a la de respuesta (PEN), con el fin de determinar si los datos seguían una distribución normal, los resultados se presentan en la Tabla 18.

Tabla 18 Resumen resultados prueba de normalidad y coeficiente de Spearman entre variables regresoras y variables de respuesta del modelo de FAO-PM56

Variables	Valor p	Coeficiente de Correlación de Spearman
Variable de respuesta		
PEN (mm/mes)	0,00	1,00
Variable regresora		
RAD ($Mj \cdot m^2/día$)	0,00	0,44
humrel (%)	0,00	-0,69
Tmax ($^{\circ}C$)	0,00	0,88
HBS (horas/día)	0,00	0,88
Tmin ($^{\circ}C$)	0,00	0,68
COTA (metros)	0,00	-0,85

Los resultados mostraron que ninguna variable regresora tuvo un *valor p* superior a 0,05, por lo tanto, se rechazó la hipótesis nula y se adoptó la hipótesis alterna. Luego, se calculó el coeficiente de Spearman, para conocer la correlación entre las variables regresoras y la de respuesta. Los resultados mostraron que las variables con mayor correlación fueron: Tmax, HBS y COTA.

Posteriormente, se construyeron varios modelos de regresión lineal múltiple con sus respectivas pruebas estadísticas, los cuales se compararon, sin embargo, en el momento de validar los supuestos del error, se observó que la mayoría no se cumplieron. Por eso, para corregir los problemas con los supuestos del error, se realizaron modificaciones como en el modelo de Hargreaves; sin embargo, para este caso, se le aplicó una transformación de raíz cuadrada a la variable de respuesta. En la Figura 19 se observa que las pendientes también son diferentes, por eso la necesidad de adicionar la variable cota indirectamente como variable categórica.




Figura 19 Relación entre las variables regresoras y FAO-PM56 de acuerdo con la cota: (a) Tmax, b) HBS y c) humrel

Considerando las modificaciones anteriores, se construyeron varios modelos de regresión lineal múltiple con sus respectivas pruebas estadísticas, los cuales se compararon en la Tabla 19.


Tabla 19 Resumen estadístico modelos de regresión lineal múltiple PM-56

Modelo	Variables regresoras	R ² ajustado	AIC	VIF					
				RAD	Tmin	Tmax	cota	HBS	humrel
1	RAD, Tmin, Tmax, HBS, humrel y cota (Categórica)	0,95	-4143	2,12	1,09	1,16	2,38	1,05	5,05
2	RAD, Tmax, HBS, humrel y cota (Categórica)	0,94	-3986	1,18	-	7,00	2,29	1,05	5,01
3	Tmax, HBS, humrel y cota (Categórica)	0,93	-3762	-	-	3,19	2,01	1,05	4,81
4	Tmax, HBS y cota (Categórica)	0,93	-3607	-	-	2,74	1,76	1,04	-
5	Tmax y cota (Categórica)	0,87	-2808	-	-	1,74	1,56	-	-

Los resultados mostraron que los modelos saturados (1-3) tuvieron mayor R^2 que los modelos 4 y 5, no obstante, se observó que el AIC aumentaba a medida que se eliminaban variables, lo que significa que todas las variables son relevantes para la variable de respuesta. En relación con el VIF se observó que la mayoría de los datos eran inferiores a 5 lo cual sugería baja colinealidad. Teniendo en cuenta todos los resultados, se consideró que el modelo 3 fue el mejor, ya que además de tener un R^2 superior a 0,90 y el VIF con valores bajos, se involucraron las variables regresoras con más correlación a la variable de respuesta. Por lo tanto, dicho modelo será evaluado con los supuestos de error para garantizar estadísticamente su validez.

En la Figura 20a se observó que la línea roja mostró ajuste con los residuales, lo que significa que se cumplió con la linealidad del error. Con relación a la normalidad, en la Figura 20b se evidencio que los errores del gráfico Q-Q se mantuvieron dentro de los intervalos de confianza, lo que podría sugerir normalidad, sin embargo, para corroborarlo se realizó la prueba de Jarque & Bera y su *valor p* fue de 0,99, por lo tanto, también se cumplió con el supuesto de normalidad.

a) Prueba de linealidad



b) Gráfico Q-Q




Figura 20 Resultados de supuesto de linealidad y normalidad del modelo4 de regresión lineal múltiple: a) linealidad y b) normalidad

En relación con la homocedasticidad se aplicó la prueba de Goldfeld-Quandt. Para el error de la varianza creciente se obtuvo *valor p* de 0,95, y de 0,05 para el error decreciente, por lo tanto, se demuestra que cumplió con este supuesto. Para la independencia del error, se aplicó la prueba Durbin-Watson y su resultado fue de 15% un valor despreciable, lo que significa que se cumplió con este supuesto.

Acorde con los resultados, se observó que todos los supuestos del error del modelo de regresión lineal múltiple se cumplieron, por lo tanto, se procedió a formular las tres ecuaciones locales para estimar la ET_o por el método de FAO-PM56 para cada estación, los resultados se presentan en la Tabla 20.

Tabla 20 Ecuación local de ET_o PM-56 para cada estación.

Estación	Ecuación
Aeropuerto Antonio Nariño	$\sqrt{(ET_o)} = 5,24 + (0,23 \cdot T_{max}) + (0,23 \cdot HBS) - (0,02 \cdot Humrel)$
Obonuco	$\sqrt{(ET_o)} = 6,60 + (0,25 \cdot T_{max}) + (0,27 \cdot HBS) + (-0,03 \cdot Humrel)$
El Encano	$\sqrt{(ET_o)} = 7,11 + (0,12 \cdot T_{max}) + (0,28 \cdot HBS) + (-0,01 \cdot Humrel)$

7.5.5 Comparación modelos FAO-PM56

Para la comparación de los modelos de regresión lineal múltiple y de redes neuronales artificiales, se aplicaron métricas de desempeño, cuyos resultados se presentan en la Tabla 21.

Tabla 21 métricas de desempeño de validación de métodos de regresión lineal múltiple FAO PM-56

Comparación modelos para estimar la evapotranspiración potencial por el método FAO-PM56			
Métrica de desempeño	Datos observados vs RNA	Datos observados vs RLM	Resultado ideal
R	0,90	0,86	1,00
BIAS	1,00	1,00	1,00
R ²	0,90	0,86	1,00
RMSE	4,36	5,00	0,00
Estadístico t	0,34	0,24	0,00

Las métricas de desempeño del modelo de redes neuronales presentaron resultados más ajustados en Pearson, R^2 y estadístico t, por lo tanto, estadísticamente el modelo de redes neuronales fue el mejor para estimar la ET_o ; sin embargo, también se realizó la comparación entre los valores predichos por los modelos y los observados.

En la Figura 21, se observan los resultados entre los valores predichos por el modelo de regresión lineal múltiple y de redes neuronales artificiales respecto a los observados, donde se evidenció que el modelo RLM tendió a subestimar algunos

valores respecto a los observados, especialmente en los valores más extremos, mientras que los de redes neuronales artificiales se encuentran más ajustados respecto a la RLM.




Figura 21 Comparación de valores observados vs predichos por el modelo: (a) Obonuco, (b) El Encano y (c) Aeropuerto Antonio Nariño

Finalmente, en la Tabla 22 se presenta un cuadro comparativo con las respectivas ventajas y desventajas de cada método, con el fin de identificar cuál es la mejor para la estimación de la ETo en el departamento de Nariño.

Tabla 22 Ventajas y desventajas de los modelos de inteligencia artificial

Método	Ventajas	Desventajas
Regresión lineal múltiple (RLM)	● Para el caso de FAO-PM56, se observó que es muy útil, ya que permite estimar la ET_0 , a partir de tres variables (T_{max} , HBS y humrel).	● Es un método local que se ajusta a las condiciones de las estaciones utilizadas, si se desea estimar para un nuevo punto en el espacio, con condiciones diferentes, su ejecución no es viable.
	● Es un método estadístico supervisado, que permite la interpretación del modelo y el entendimiento físico del fenómeno.	● En algunos casos se debe sacrificar la precisión del valor de la evapotranspiración potencial si no se cuenta con todas las variables.
	● Contempla el aporte de la altura en la explicación del fenómeno de variable, la cual es importante.	● En el momento de estimar valores extremos, el modelo no tiene la capacidad de predecir un resultado ajustado.
Redes neuronales (RN)	● Presenta una precisión ajustada respecto a los valores observados, sobre todo en los valores extremos.	● Al ser un método de caja negra, no permite ni identificar los procedimientos que se realizan, ni entender las relaciones de las variables.
	● No requiere tener un conocimiento previo del fenómeno, ya que basta tener disponibilidad de las variables, para obtener buenos resultados.	● No permite adicionar la COTA como una variable categórica a diferencia del RLM.
	● Al no ser un modelo local, esta metodología se podría replicar para otro nuevo punto en el espacio.	● Requiere tener un conocimiento previo avanzado de un lenguaje de programación y de su respectivo paquete.

Por todo lo anteriormente explicado, se consideró que el modelo de **redes neuronales artificiales** es el mejor método para estimar la ET_0 tanto para Hargreaves como para FAO-PM56 en el departamento de Nariño.

7.6 Evaluación temporal de la sequía

7.6.1 Estimación del SPEI y análisis de componentes principales no lineales

La estimación del SPEI se realizó para tres escalas temporales (trimestral, semestral y anual) con el programa Rstudio, utilizando el balance hídrico entre la precipitación y la ET_0 estimada por redes neuronales artificiales. Posteriormente, se calcularon los autovalores del SPEI y el % de varianza explicada con el análisis de componentes principales no lineales para cada escala temporal en MATLAB, sus resultados se presentan en la Tabla 23.

Tabla 23 Prueba autovalor escalas temporales

Componente	Trimestral		Semestral		Anual	
	Autovalor	Varianza explicada (%)	Autovalor	Varianza explicada (%)	Autovalor	Varianza explicada (%)
1	5,47	57,71	5,63	62,04	5,99	63,25
2	1,28	12,87	1,35	13,25	1,25	13,28
3	0,94	9,60	0,83	7,69	0,83	8,86
4	0,58	5,98	0,50	5,23	0,46	4,88
5	0,37	3,79	0,36	3,13	0,32	3,41
6	0,30	3,14	0,24	2,53	0,17	1,81
7	0,23	2,37	0,21	2,01	0,13	1,46
8	0,23	2,25	0,18	1,72	0,12	1,33
9	0,18	1,23	0,14	1,30	0,09	0,95
10	0,17	1,03	0,12	1,10	0,08	0,73

Los resultados mostraron que para las tres escalas temporales, la componente 1 y 2 son las que mejor representan la variabilidad del SPEI, ya que su autovalor fue mayor a 1, tal como sugieren Jolliffe (1986) y Preisendorfer & Mobley (1988).

7.6.2 Coeficiente de determinación e identificación periodos más secos

Se calculó el coeficiente de determinación (R^2) entre el SPEI promedio de las diez estaciones y las dos componentes principales, con el fin de observar cuál componente estaba más correlacionada, los resultados se presentan en la Tabla 24.

Tabla 24 Correlación entre el SPEI promedio y las dos componentes principales

Escala temporal SPEI	R^2	
	Componente 1	Componente 2
Trimestral	0,99	-0,11
Semestral	0,99	-0,08
Anual	0,99	0,00

Los resultados mostraron que la primera componente tuvo un coeficiente de determinación promedio de 0,99, lo cual indica que tiene una correlación muy fuerte con el SPEI. Con el fin de corroborar dicho resultado, se realizó un gráfico del SPEI promedio de las 10 estaciones con la primera componente, lo cual se reportó en las Figuras 22 a 24.

EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO




Figura 22 Correlación entre SPEI trimestral y la primera componente




Figura 23 Correlación entre SPEI semestral y la primera componente




Figura 24 Correlación entre SPEI anual y la primera componente

7.6.3 Eventos evaluados

Se identificaron gráficamente los periodos más secos y severos por escala temporal, luego se listaron y se caracterizaron como eventos, los cuales se observan en la Tabla 25.

Tabla 25 Eventos de sequía seleccionados

Evento	Trimestral				Semestral				Anual			
	Duración		Severidad	Intensidad	Duración		Severidad	Intensidad	Duración		Severidad	Intensidad
	Fecha inicio	Fecha fin	Resultado integral	Valor	Fecha inicio	Fecha fin	Resultado integral	Valor	Fecha inicio	Fecha fin	Resultado integral	Valor
1	Nov-00	Jul-03	-18,93	-1,40	Nov-00	Sep-03	-23,68	-1,21	Abr-01	Nov-05	-36,12	-1,43
2	Feb-15	May-16	-12,00	-1,30	Abr-15	Nov-16	-14,31	-1,46	May-15	Nov-16	-8,86	-0,92
3	Nov-90	Ene-93	-15,95	-1,48	May-89	Mar-93	-23,06	-1,77	Nov-89	Abr-93	-15,95	-1,75

Respecto a la duración se observó que en la escala trimestral estuvieron los eventos más cortos de sequía y en la escala anual los eventos más largos. Con relación a la severidad se evidenció que el evento 1 fue el que en general tuvo los valores más severos y en el evento 2 se observó que fue el que tuvo la severidad más baja. Finalmente, en el evento 3, se reportaron los valores más intensos de sequía.

Los eventos 1, 2 y 3 representan periodos los cuales han sido gravemente afectados por la fase cálida del fenómeno ENSO. Por ejemplo, el evento 1 coincidió con fuertes sequías en el país donde se evidenciaron impactos significativos, por ejemplo en el departamento de Nariño, se vieron afectadas 3890 hectáreas de producción de alimentos (maíz, frijol, arroz, plátano, yuca, maní) y se secaron varias microcuencas que abastecían a 14 cabeceras municipales, veredas y corregimientos (El Tiempo, 2001). El evento 2 fue considerado por la NOAA (Administración Nacional Oceánica y atmosférica) como muy fuerte y durante el 2015-2016, se afectó la producción agrícola, el sector energético, disminución en las precipitaciones, entre otros (Weng et al., 2020). En relación con el evento 3, la NOAA lo catalogo como fuerte y entre los años 1991-1992, se produjeron diversos impactos en el país, como: millonarias pérdidas económicas en el sector hidroeléctrico, racionamiento de agua y energía (ley Gaviria), reducción de la precipitación y reducción en el nivel de los ríos y embalses (Cerón et al., 2019; Nobles-Orozco, 2016).

7.7 Evaluación espacial de la sequía a partir de los índices de sequía

7.7.1 Complemento del SPEI a partir del SPI

Para la espacialización del SPEI, se aplicó el método de interpolación kriging con el fin de obtener una mayor cobertura espaciotemporal en el departamento de Nariño; sin embargo, como se observó en el Anexo 6, los resultados no fueron coherentes, ya que las interpolaciones solo se realizaron en áreas cercanas a las estaciones, desconociendo lo que ocurre en la región Pacífico o Amazónica, por la inequitativa distribución de estaciones (Urrea *et al.*, 2019).

Debido a esto, se calculó el índice SPI para las estaciones presentadas en la Figura 4, con el fin de complementar la identificación y evaluación de la sequía y tener cobertura espacial del fenómeno. Posteriormente, se estimó el coeficiente R^2 entre el SPI y el SPEI de cada escala temporal y se realizaron gráficos de dispersión, con el fin de observar la correlación entre ambos índices, sus resultados se observan en las Figuras 25 a 27.




Figura 25 Correlación entre el SPI y SPEI trimestral

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**




Figura 26 Correlación entre el SPI y SPEI semestral




Figura 27 Correlación entre el SPI y SPEI anual

Los resultados mostraron un R^2 promedio de 0,97 y un valor del intercepto despreciable, por lo tanto, considerando la buena correlación y la similitud entre la escala, se estimó el SPEI a partir del valor conocido del SPI de las 47 estaciones, con el fin de tener una mayor cobertura espacial para evaluar la sequía a lo largo del departamento.

Este resultado es muy importante, debido a que para estimar el SPEI se requieren datos de variables que son difíciles de medir, a diferencia del SPI que solo requiere información de datos de precipitación. La alta correlación entre estos índices puede atribuirse al concepto de “**lluvia reciclada**”, el cual es un fenómeno que ocurre en el trópico donde a partir de la evapotranspiración captada del suelo ocurren lluvias, y su aporte es de aproximadamente el 30-40% en Colombia (Cuartas & Poveda, 2002). En ese orden de ideas, resulta lógico tener una correlación tan alta, pues implícitamente dentro del cálculo del SPI se incluye el porcentaje de la evapotranspiración del ciclo hidrológico, por lo tanto, utilizar este índice se convierte en una buena alternativa técnica y operativa para evaluar la sequía.

7.7.2 Interpolación sequía con el SPI

Los procesos de interpolación de los periodos de mayor duración por escala temporal se presentan en las Figuras 28 a 33, el resto de los periodos se reportan en el Anexo 7. Para la discusión de resultados se tendrán en cuenta las cuencas de Nariño las cuales se reportan en el Anexo 8.

EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO




Figura 28 SPEI trimestral Oct-91 a May-92

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**




Figura 29 SPEI trimestral Abr-92 a Nov-92

Durante el periodo Oct-91 a Nov-92 se observó que inicialmente la severidad de la sequía fue normal; sin embargo, conforme iban avanzando los meses la sequía moderada y severa fueron abarcando las cuencas del Río Mira, Telembi, Mayo, Juanambú, Guáitara y Patía, además se evidenció sequía extrema en las cuencas Guáitara, Juanambú y Patía alto. Como resultado general se observó que la región Pacífico no se vio tan afectada por las sequías, a diferencia de la región Andina la cual fue la más afectada en los tres periodos analizados a escala trimestral. Durante el trimestre Ene-92 a Mar-92 el departamento de Nariño fue gravemente afectado por sequía, ya que el 53% presento sequía moderada, el 17% sequía severa y 6% sequía extrema.

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**




Figura 30 SPEI semestral Sep-91 a Jul-92

EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO




Figura 31 SPEI semestral Mar-92 a Ene-93

Durante el periodo Sep-91 a Ene-93 se evidenció que la severidad del índice fue moderada sobre todo en la cuenca del río Guátara, Chingual y San miguel, además se observó que conforme iba transcurriendo los meses, la sequía severa iba afectando las cuencas mencionadas y también se observó sequía extrema en las cuencas Guátara, Juanambú y Telembí. Como resultado general se observó que la región Pacífico no se vio afectada por sequías, a diferencia de la Andina fue la más afectada en los tres periodos reportados de la escala semestral. Durante el semestre Ene-92 a Jun-92 el departamento de Nariño se vio considerablemente afectado por sequía, ya que el 16% presento sequía moderada, el 38% sequía severa y 12% sequía extrema.

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**




Figura 32 SPEI anual Jun-00 a Oct-01

**EVALUACIÓN DE LA SEQUÍA MEDIANTE EL ÍNDICE
ESTANDARIZADO DE PRECIPITACIÓN EVAPOTRANSPIRACIÓN
(SPEI) UTILIZANDO INTELIGENCIA ARTIFICIAL EN EL
DEPARTAMENTO DE NARIÑO**




Figura 33 SPEI anual Dic-00 a Abr-02

Para el periodo Jun-00 a Abr-02 se observó que inicialmente la severidad del índice fue moderada y severa en las cuencas Mayo y Juanambú, además conforme iban avanzando los meses la sequía moderada y severa se fue extendiendo en las cuencas del río Mira, San Juan, Patía Alto y Chingual. En general, la región Pacífico no se vio tan afectada por las sequías, a diferencia de la región Andina como se observó en los tres periodos analizados a escala anual. Finalmente, para el periodo Sep-00 a Oct-01 el departamento de Nariño se vio gravemente afectado por sequía, ya que el 43% presento sequía moderada, el 28% sequía severa y 3% sequía extrema.

En conclusión, con la cartografía obtenida de las tres escalas temporales, fue posible identificar los periodos más secos y las cuencas más afectadas por la sequía. Considerando la destacada participación agrícola del departamento, este

resultado es de interés para los municipios aledaños a las cuencas más afectadas, ya que servirá como insumo para que los entes gubernamentales adopten políticas para una adecuada gestión integral del recurso hídrico y medidas de adaptación ante la variabilidad climática enfocadas a sequías, para garantizar la seguridad y soberanía alimentaria del país.

El café es uno de los principales cultivos del departamento y acorde con la OIC (Organización Internacional del Café) se esperan grandes retos debido al cambio climático y variabilidad del cambio climático, pues la variabilidad de factores ambientales (precipitación, humedad y temperatura) afectará notablemente la fenología, etapas de crecimiento y grano y se propiciará el desarrollo de plagas y enfermedades (Camargo, 2010; Panhuysen & Pierrot, 2014; Porter & Semenov, 2005).

Al considerar los posibles impactos que los eventos extremos pueden producir en la productividad y calidad del café, se hace necesario conocer cuáles zonas serán las más afectadas por sequía, por eso, con la cartografía obtenida en las Figuras 30-35, se espera que se identifiquen las zonas más susceptibles a sequías y se adopten medidas preventivas y correctivas para brindarle las condiciones óptimas y garantizar la producción del cultivo.

8. CONCLUSIONES

- De las metodologías empíricas existentes para estimar la ET_0 , se observó que el método de Hargreaves fue el que tuvo mejor desempeño y correlación con el de FAO-PM56 para el departamento de Nariño, un resultado importante, ya que si se instalan más estaciones que midan temperatura máxima y mínima, se podría tener más datos de evapotranspiración potencial, ya que con las condiciones actuales la información es muy limitada.
- Las redes neuronales artificiales permitieron estimar la ET_0 con mayor precisión que los modelos de regresión lineal múltiple, lo cual demuestra que la inteligencia artificial es una buena herramienta para la explicación de fenómenos climatológicos.
- La región Pacífico es la región menos afectada por las sequías, un resultado coherente, considerando que es una de las regiones más lluviosas del mundo. Por otro lado, la región Andina si se vio gravemente afectada, específicamente en los municipios aledaños a las cuencas Rio mayo, Juanambú y Guátara, por eso, considerando que la principal actividad socioeconómica desarrollada es la agricultura, se recomienda implementar planes de gestión integral del recurso hídrico medidas de adaptación ante la variabilidad climática orientadas a las sequías, para no ver comprometida la soberanía y seguridad alimentaria.
- El SPEI no es un buen índice para evaluar la sequía en el departamento de Nariño como región tropical, ya que la red de estaciones disponibles para medir variables necesarias para la ET_0 es muy escasa, lo cual dificulta mucho su estimación. Debido a la poca información disponible, el proceso de interpolación no permitió estimar la sequía correctamente para el resto del departamento, sin embargo, al utilizar el SPI se amplió la espacialidad de la sequía y se pudo realizar correctamente la interpolación.
- El SPEI incluye en el balance hídrico la ET_0 a diferencia del SPI, sin embargo, se observó que al implementar este índice no hubo un cambio significativo respecto al SPI, lo cual podría sugerir que implícitamente dentro del proceso de estimación del SPI se utiliza el concepto de “lluvia reciclada” de la ET_0 . A diferencia de otros lugares del mundo, en el trópico la temperatura es una variable muy estable, quizás por eso, en otros países, donde la variabilidad de la temperatura es mucho mayor, la implementación del índice permite tener una mejor explicación de la sequía, por eso se recomienda utilizar el índice SPI para evaluar la sequía en un contexto tropical como Nariño.

9 RECOMENDACIONES Y FUTURAS LINEAS DE INVESTIGACIÓN

- Instalar más estaciones que midan variables climatológicas, debido a que la información existente es muy limitada a nivel espaciotemporal, considerado la vocación agrícola del departamento.
- Evaluar la sequía con el índice SPEI en otros departamentos del país, ya que, a pesar de que para Nariño, no hubo diferencias significativas respecto al SPI, no significa que en el resto sea igual.
- Instalar más lisímetros, debido a que los métodos actualmente utilizados para el balance hídrico utilizan la ET_0 , lo cual podría estar generando un error, ya que no es la evapotranspiración real.
- Implementar imágenes satelitales para medir variables climatológicas que permitan evaluar diferentes índices de sequía, con el fin de mejorar la resolución espaciotemporal.
- Evaluar el SPEI en zonas de estudio por fuera del trópico, donde la variación de la temperatura es mayor, con el fin de observar si existen diferencias significativas entre el índice SPI y SPEI.
- Comparar los diferentes métodos de interpolación recomendados por la literatura, para mejorar la predicción del índice SPEI.

9. REFERENCIAS

- Achour, K., Meddi, M., Zeroual, A., Bouabdelli, S., Maccioni, P., & Moramarco, T. (2019). Spatio-temporal analysis and forecasting of drought in the plains of northwestern Algeria using the standardized precipitation index. *Journal of Earth System Science*, 22. <https://doi.org/10.1007/s12040-019-1306-3>
- Allen, R., Pereira, L., Howell, T., & Jensen, M. (2011). Evapotranspiration information reporting: I. Factors governing measurement accuracy. *Agricultural Water Management*, 98(6), 899–920. <https://doi.org/10.1016/j.agwat.2010.12.015>
- Allen, R., Pereira, L., Raes, D., & Smith, M. (1998). Crop evapotranspiration, guidelines for computing crop water requirements (No. 56; Irrigation and Drainage). https://www.researchgate.net/publication/235704197_Crop_evapotranspiration-Guidelines_for_computing_crop_water_requirements-FAO_Irrigation_and_drainage_paper_56
- Almorox, J. (2008). Comparación de algunos métodos de estimación de la evapotranspiración en Uruguay. *Research Gate*, 33(4), 11. https://www.researchgate.net/publication/280830934_COMPARACION_DE_ALGUNOS_METODOS_DE_ESTIMACION_DE_LA_EVAPOTRANSPIRACION_EN_URUGUAY
- Altamiranda-Saavedra, M., Gutierrez, J., Araque, A., Valencia-Mazo, D., Gutiérrez, R., & Martínez-Vega, R. (2018). Effect of El Niño Southern Oscillation cycle on the potential distribution of cutaneous leishmaniasis vector species in Colombia. *PLoS Negl Trop Dis*, 14(5). <https://doi.org/10.1371/journal.pntd.0008324>
- American Meteorological Society. (2014). Statement on meteorological drought. *Meteorological Science*, 85, 771–773.
- Angstrom, A. (1924). Solar and terrestrial radiation. *Quarterly Journal of the Royal Meteorological Society*, 20, 121–125.
- Apurv, T., Xu, Y. P., Wang, Z., & Cai, X. (2019). Multidecadal Changes in Meteorological Drought Severity and Their Drivers in Mainland China. *Journal of Geophysical Research: Atmospheres*, 39. <https://doi.org/10.1029/2019JD031317>
- Arora, V. K. (2002). The use of the aridity index to assess climate change effect on annual runoff. *Journal of Hydrology*, 265(1–4), 164–177. [https://doi.org/10.1016/S0022-1694\(02\)00101-4](https://doi.org/10.1016/S0022-1694(02)00101-4)
- Arteaga, L., & Burbano, J. (2018). Efectos del cambio climático: Una mirada al Campo. 35(2), 79–91.

- Bangaru Kamatchi, S., & Parvathi, R. (2020). Crop- Climate management: a review. *Journal of Critical Reviews*, 7(6), 10. <http://www.jcreview.com/fulltext/197-1588255513.pdf>
- Barella Ortiz, A., & Quintana Seguí, P. (2019). Evaluation of drought representation and propagation in regional climate model simulations across Spain. *Hydrology and Earth System Sciences*, 21. <https://doi.org/10.5194/hess-23-5111-2019>
- Basconcillo, J., Duran, G. A., Fransisco, A., Abastillas, R., Hilario, F., Juanillo, E., Solis, A. L., Lucero, A. J., & Maratas, S.-L. (2017). Evaluation of Spatial Interpolation Techniques for Operational Climate Monitoring in the Philippines. *SOLA*, 13, 114–119. <https://doi.org/10.2151/sola.2017-021>
- Basher, R. (2006). Global early warning systems for natural hazards: systematic and people-centred. *Philosophical Transactions of the Royal Society*, 364(June), 16. <https://doi.org/10.1098/rsta.2006.1819>
- Bhuiyan, C. (2004). Various Drought Indices For Monitoring Drought Condition In Aravalli Terrain Of India. Working Group VII/5, 6. <https://www.isprs.org/proceedings/XXXV/congress/comm7/papers/243.pdf>
- Caicedo Bravo, E. F., & López Sotelo, J. A. (2017). Una aproximación práctica a las redes neuronales artificiales [recurso electrónico]. <http://bibliotecadigital.univalle.edu.co/handle/10893/10330>
- Camargo, M. (2010). The impact of climatic variability and climate change on arabic coffee crop in Brazi. *Bragantia*, 69(1), 239–247.
- Canchala, T., Carvajal-Escobar, Y., Alfonso-Morales, W., Cerón, W., & Caicedo, E. (2019). Estimation of missing data of monthly rainfall in southwestern Colombia using artificial neural networks. *Data in Brief*, 9. <https://doi.org/10.1016/j.dib.2019.104517>
- Cardona, D., González, J., Rivera, Mi., & Cárdenas, E. (2013). Aplicación de la regresión lineal en un problema de pobreza. *Revista Interacción*, 12, 11. [http://www.zeuseduca.org/zeuseduca.org/fernando.infestas/Magíster en Economía y Finanzas/Econometría \(MEF-113-115\)/Ramon Perazzi, Josefa/Semana 4/Ejemplo Aplicación Regresión.pdf](http://www.zeuseduca.org/zeuseduca.org/fernando.infestas/Magíster%20en%20Economía%20y%20Finanzas/Econometría%20(MEF-113-115)/Ramon%20Perazzi,%20Josefa/Semana%204/Ejemplo%20Aplicación%20Regresión.pdf)
- Carvajal-Escobar, Y. (2011). Inundaciones en Colombia. ¿Estamos preparados para enfrentar la variabilidad y el cambio climático? *Revista Memorias*, 9(16), 105–119.
- Castro, L., & Carvajal, Y. (2010). Análisis de tendencia y homogeneidad de series climatológicas. *Sistema de Información Científica Redalyc*, 9, 13. <https://www.redalyc.org/pdf/2311/231116434002.pdf>
- Cerón, W. (2014). Evaluación de sequías meteorológicas y procesos de adaptación

y procesos de adaptación de las comunidades agrícolas de la cuenca del río Dagua - Valle del Cauca. Caso de estudio: microcuenca la Centella. 128.

- Cerón, W., Andreoli, R., Kayano, M., Canchala, T., Carvajal-Escobar, Y., & Souza, R. (2021). Comparison of spatial interpolation methods for annual and seasonal rainfall in two hotspots of biodiversity in South America. *Annals of the Brazilian Academy of Sciences*, 93(1), 22.
- Cerón, W., Carvajal-Escobar, Y., De Souza, R. V. A., Kayano, M. T., & López, N. G. (2019). Spatio-temporal analysis of the droughts in Cali, Colombia and their primary relationships with the El Niño-Southern Oscillation (ENSO) between 1971 and 2011. *Atmosfera*, 33(1), 51–69. <https://doi.org/10.20937/ATM.52639>
- Cline, W. (2008). Global warming in agriculture. *Finance and Development*, 5. <https://www.imf.org/external/pubs/ft/fandd/2008/03/pdf/cline.pdf>
- Cuartas, A., & Poveda, G. (2002). Balance Atmosférico de humedad y estimación de la precipitación reciclada en Colombia según el reanálisis NCEP/NCAR. *Meteorología Colombiana*, 5, 12. <https://repositorio.unal.edu.co/bitstream/handle/unal/7936/DD3528.pdf?sequence=1&isAllowed=y>
- DANE. (2020). Perspectivas territoriales de desarrollo socioeconómico Valor agregado de las estadísticas económicas regionales. <https://www.dane.gov.co/files/investigaciones/planes-desarrollo-territorial/280120-Info-Regional-Pasto.pdf>
- Deo, R. C., & Mehmet, Ş. (2015). Application of the Artificial Neural Network model for prediction of monthly Standardized Precipitation and Evapotranspiration Index using hydrometeorological parameters and climate indices in eastern Australia. *ELSEVIER*, 162, 65–81.
- Diani, K., Kacimi, I., Zemzami, M., Tabyaoui, H., & Haghighi, A. T. (2019). Evaluation of meteorological drought using the Standardized Precipitation Index (SPI) in the High Ziz River basin, Morocco. *Limnological Review*, 19(3), 125–135. <https://doi.org/10.2478/limre-2019-0011>
- El País. (2016). *La peor sequía en casi dos décadas sacude a Colombia*. https://elpais.com/internacional/2016/01/11/colombia/1452545517_823579.html
- El Tiempo. (2001). Emergencia por sequía en Nariño. <https://www.eltiempo.com/archivo/documento/MAM-654755>
- Eslamian, S., Ostad-ali-askari, K., Singh, V. P., & Dalezios, N. R. (2017). A Review of Drought Indices. *International Journal of Constructive Research in Civil Engineering*, 3(4), 48–66. <https://doi.org/10.20431/2454-8693.0304005>

- Estrela, T., & Vargas, E. (2012). Drought Management Plans in the European Union. The Case of Spain. *Water Resources Management*, 26(6), 1537–1553. <https://doi.org/10.1007/s11269-011-9971-2>
- FAO. (2013). Climate-smart agriculture sourcebook. <http://www.fao.org/3/a-i3325e.pdf>
- Feng, X., & Houser, P. (2016). Developing and Demonstrating Climate Indicators for Monitoring the Changing Water Cycle. *Advances in Meteorology*. <https://doi.org/10.1155/2016/5481731>
- Field, C. B., Barros, V. R., Dokken, D. J., Mach, K. J., Mastrandrea, M. D., & Bilier, T. E. (2014). Climate change 2014: Impacts, adaptation, and vulnerability. Part A: Global and sectoral aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge, UK and New York: Cambridge University Press. https://www.ipcc.ch/pdf/assessment-%0Areport/ar5/wg2/WGIIAR5-FrontMatterA_FINAL.pdf
- Fox, J. (2016). Applied Regression Analysis and Generalized Linear Models. In Sage (3rd ed.). Sage.
- Gobernación de Nariño. (2016). Plan participativo de Desarrollo Departamental - Nariño Corazón del Mundo. (p. 255). <http://xn--nario-rt-a.gov.co/inicio/index.php/gobernacion/plan-de-desarrollo/354-plan-de-desarrollo-departamental-narino-corazon-del-mundo-2016-2019>
- Goldfeld, S., & Quandt, R. (1965). Some Tests for Homoskedasticity. *Journal of the American Statistical Association*, 60, 539–547.
- González, N., Carvajal-Escobar, Y., & Cerón, W. (2016). Análisis de sequías meteorológicas para la cuenca del Río Dagua, Valle del Cauca, Colombia. 15. <https://doi.org/10.14483/udistrital.jour.tecnura.2016.2.a07>
- Han, E., Baethgen, W., Ines, A. V, Mer, F., Souza, J. S., Berterretche, M., Atunez, G., & Barreira, C. (2018). Original papers SIMAGRI : An agro-climate decision support tool. *Computers and Electronics in Agriculture*, 161(April 2018), 241–251. <https://doi.org/10.1016/j.compag.2018.06.034>
- Hargreaves, H. G., & Samani, Z. A. (1985). Reference crop evapotranspiration from temperature. *Applied Eng. in Agric*, 1, 3.
- Hayes, M. (2006). Drought indices. *Van Nostrand's Scientific Encyclopedia*, 13. <https://doi.org/10.1002/0471743984.vse8593>
- Heim, R. (2002). Century Drought Indices Used in the United States. *Climate Monitoring Branch*, 1149–1165.

- Hu, X., Ren, H., Tansey, K., Zheng, Y., Ghent, D., Liu, X., & Yan, L. (2019). Agricultural drought monitoring using European Space Agency Sentinel 3A land surface temperature and normalized difference vegetation index imageries. *Agricultural and Forest Meteorology*, 21. <https://doi.org/10.1016/j.agrformet.2019.107707>
- IPPC. (2012). Managing the risks of extreme events and disasters to advance climate change adaptation (1st ed.). https://www.ipcc.ch/site/assets/uploads/2018/03/SREX_Full_Report-1.pdf
- Jaramillo, A. (2006). Evapotranspiración de referencia en la región andina de Colombia. *Cenicafé*, 57(4), 288–298. [https://www.cenicafe.org/es/publications/arc057\(04\)288-298.pdf](https://www.cenicafe.org/es/publications/arc057(04)288-298.pdf)
- Jarque, C., & Bera, A. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics Letters*, 6, 255–259. http://l.academicdirect.org/Horticulture/GAs/Refs/Jarque&Bera_1980.pdf
- Jianli, F., & Shengnan, L. (2019). Performance analysis of various activation functions in artificial neural networks. *Journal of Physics: Conference Series*. https://www.researchgate.net/publication/334420833_Performance_Analysis_of_Various_Activation_Functions_in_Artificial_Neural_Networks
- Jiménez Carrión, M., Gutiérrez Segura, F., & Celi Pinzón, J. (2018). Modelado y Predicción del Fenómeno El Niño en Piura , Perú mediante Redes Neuronales Artificiales usando Matlab Modeling and prediction of El Niño in Piura using Artificial Neuronal Networks. 29(4), 303–316.
- Jolliffe, I. (1986). *Principal component Analysis*. Springer, 271, 129–155.
- Kelley, C. P., Mohtadi, S., Cane, M. A., Seager, R., & Kushnir, Y. (2015). Climate change in the Fertile Crescent and implications of the recent Syrian drought. *Proceedings of the National Academy of Sciences of the United States of America*, 112(11), 3241–3246. <https://doi.org/10.1073/pnas.1421533112>
- Kubiak, K. (2019). The course of hydrological drought in the river Drawa catchment (Northern Poland) as characterized by the standardized runoff index. *AIP Conference Proceedings*, 2186(December), 5. <https://doi.org/10.1063/1.5138035>
- Lehmann, J., Mempel, F., & Coumou, D. (2018). Increased Occurrence of Record-Wet and Record-Dry Months Reflect Changes in Mean Rainfall. *Geophysical Research Letters*, 45(24), 13,468-13,476. <https://doi.org/10.1029/2018GL079439>
- Liu, Ze, Peng, C. H., Xiang, W. H., Tian, D. L., Deng, X. W., & Zhao, M. F. (2010). Application of artificial neural networks in global climate change and ecological

- research: An overview. Chinese Science Bulletin, 55(34), 3853–3863.
<https://doi.org/10.1007/s11434-010-4183-3>
- Liu, Zhaofei, Wang, R., & Yao, Z. (2018). Climate change and its impact on water availability of large international rivers over the mainland Southeast Asia. Hydrological Processes, 32(26), 3966–3977. <https://doi.org/10.1002/hyp.13304>
- McGregor, G., & Ebi, K. (2018). El Niño Southern Oscillation (ENSO) and Health: An Overview for Climate and Health Researchers. Atmosphere, 9(282). <https://doi.org/10.3390/atmos9070282>
- Mckee, T., Doesken, N., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. Journal of Surgical Oncology, 105(8), 818–824. <https://doi.org/10.1002/jso.23002>
- Minagricultura. (2017). Principales Cultivos por Área Sembrada en 2017. Agronet. https://www.agronet.gov.co/Documents/NARIÑO_2017.pdf
- Mishra, A. K., & Singh, V. P. (2010). A review of drought concepts. Journal of Hydrology, 391(1–2), 202–216. <https://doi.org/10.1016/j.jhydrol.2010.07.012>
- Moncayo, C. (2015). Valle del Cauca, Antioquia y Nariño, departamentos líderes en producción. Instituto Nacional de Contadores Públicos. <https://incp.org.co/valle-del-cauca-antioquia-y-narino-departamentos-lideres-en-produccion/#:~:text=Valle del Cauca%2C Antioquia y Nariño%2C departamentos líderes en producción,-5 noviembre%2C 2015&text=Los departamentos de Valle del,%2C2 millones de tone>
- Monish, N. T., & Rehana, S. (2019). Suitability of distributions for standard precipitation and evapotranspiration index over meteorologically homogeneous zones of India. Journal of Earth System Science, 1. <https://doi.org/10.1007/s12040-019-1271-x>
- Montgomery, D., Peck, E., & Vining, G. (2002). *Introducción al análisis de regresión lineal* (Tercera ed). John Wiley & Sons, Inc
- Monzonís, P., Solera, A., Ferrer, J., Estrela, T., & Paredes-Arquiola, J. (2015). A review of water scarcity and drought indexes in water resources planning and management. Journal of Hydrology, 527, 482–493. <https://doi.org/10.1016/j.jhydrol.2015.05.003>
- Moorhead, J. E., Gowda, P. H., Singh, V. P., Porter, D. O., Marek, T. H., Howell, T. A., & Stewart, B. A. (2015). Identifying and Evaluating a Suitable Index for Agricultural Drought Monitoring in the Texas High Plains. Journal of the American Water Resources Association, 51(3), 807–820. <https://doi.org/10.1111/jawr.12275>
- Mpelasoka, F., Hennesey, K., Jones, R., & Bates, B. (2008). Comparison of suitable

- drought indices for climate change impacts assessment over Australia towards resource management. *International Journal of Climatology*, 2029(March 2008), 2011–2029. <https://doi.org/10.1002/joc>
- Mukherjee, S., Mishra, A., & Trenberth, K. (2018). Climate Change and Drought: a Perspective on Drought Indices. *Current Climate Change Reports*, 4, 19. <https://doi.org/10.1007/s40641-018-0098-x>
- Murat, A., & Serhat, Ö. (2018). Artificial Intelligence (AI) Studies in Water Resources. *Natural and Engineering Sciences*, 3(2), 9.
- Navarro-Monterroza, E., Arias, P. A., & Vieira, S. C. (2019). El Niño-Oscilación del Sur, fase Modoki, y sus efectos en la variabilidad espacio-temporal de la precipitación en Colombia. *Ciencias de La Tierra*, 43(166), 120–132.
- NDMC. (2013). U.S. Drought Monitor. <http://drought.unl.edu/MonitoringTools/USDroughtMonitor.aspx>
- Nguyen, V. H., Li, Q. F., & Nguyen, L. B. (2017). Drought forecasting using ANFIS-a case study in drought prone area of Vietnam. *Paddy and Water Environment*, 12. <https://doi.org/10.1007/s10333-017-0579-x>
- Nobles Orozco, E. (2016). Evaluación de la amenaza por sequía en el departamento de Córdoba [Universidad de Córdoba]. [https://repositorio.unicordoba.edu.co/bitstream/handle/ucordoba/340/TRABAJO DE GRADO 2016 - EGLENDYS NOBLES OROZCO.pdf?sequence=1&isAllowed=y](https://repositorio.unicordoba.edu.co/bitstream/handle/ucordoba/340/TRABAJO_DE_GRADO_2016_-_EGLENDYS_NOBLES_OROZCO.pdf?sequence=1&isAllowed=y)
- Obregon, N., Fragala, F., & Prada, L. (2003). Redes neuronales artificiales en hidroinformática. *Seminario Internacional: La Hidroinformática En La Gestión Integrada de Los Recursos Hidricos*, 1–5.
- Ojeda-Flechas, C., Burbano-Rodríguez, J., Carvajal-Escobar, Y., & Hernández Torres, L. (2019). Characterization of comprehensive drought events associated with the ENSO warm phase through satellite images in the Valle del Cauca, Colombia. *DYNA*, 87(214), 204–214. <https://doi.org/10.15446/dyna.v87n214.83221>
- Olivares, B., Cortez, A., Lobo, D., Mayela, R., Rey, J., & Rodríguez, M. F. (2016). Estudio de la Sequía Meteorológica en Localidades de los Llanos de Venezuela Mediante el Índice de Precipitación Estandarizado Study of Meteorological Drought in the Venezuelan Plains using the Standardized Precipitation Index. 7, 266–283.
- ONU. (2011). The Millenium Development Goals report. [https://www.un.org/millenniumgoals/2015_MDG_Report/pdf/MDG_2015_rev\(July 1\).pdf](https://www.un.org/millenniumgoals/2015_MDG_Report/pdf/MDG_2015_rev(July_1).pdf)

- ONU. (2015). Documento A/CONF.216/16Informe de la Conferencia de las Naciones Unidas sobre el Desarrollo Sostenible. <http://mdgs.un.org/unsd/mdg/Resources/Static/Products/Progress2015/Spansih2015.pdf>
- Palmer, W. C. (1965). Meteorological Drought. U.S. Weather Bureau, Res. Pap. No. 45, 58. <https://www.ncdc.noaa.gov/temp-and-precip/drought/docs/palmer.pdf>
- Palmer, W. C. (1968). Keeping Track of Crop Moisture Conditions, Nationwide: The New Crop Moisture Index. Weatherwise, 21(4), 156–161. <https://doi.org/10.1080/00431672.1968.9932814>
- Panhuysen, S., & Pierrot, J. (2014). Barometro del café. Hivos IUCN Nederland. OxfamNovib.Solidaridad.WWF. <http://infocafes.com/portal/biblioteca/barometro-de-cafe-2014/>
- Paulus, J., & Kohler, M. (1952). Interpolation of missing precipitation records. Monthly Weather Review, 80(8), 5.
- Perez, L., Rios, D., Giraldo, D., Twyman, J., Blundo-Canto, G., Prager, S., & Ramirez-Villegas, J. (2019). Determinants of vulnerability of bean growing households to climate variability in Colombia. Climate and Development, 0(0), 1–13. <https://doi.org/10.1080/17565529.2019.1685931>
- Ponce Gallego, J. C., Torres Soto, A., Quezada Aguilera, F. S., Silva Sprock, A., Martínez Flor, E. U., Casali, A., Scheihing, E., Túpac Valdivia, Y. J., Torres Soto, M. D., Ornelas Zapata, F. J., Hernández A, J. A., Zavala D., C., Vakhnia, N., & Pedreño, O. (2014). Inteligencia artificial (1st ed.). <https://doi.org/10.13140/2.1.3720.0960>
- Poornima, S., & Pushpalatha, M. (2019). Drought prediction based on SPI and SPEI with varying timescales using LSTM recurrent neural network. Soft Computing, 23(18), 8399–8412. <https://doi.org/10.1007/s00500-019-04120-1>
- Porter, J., & Semenov, M. (2005). Crop responses to climatic variation. Philosophical Transactions of the Royal Society B-Biological Sciences, 360, 2021–2035. <https://repository.rothamsted.ac.uk/item/89825/crop-responses-to-climatic-variation>
- Poveda, G., Vélez, J. I., Mesa, O. J., Cuartas, A., Barco, J., Mantilla, R. I., Mejía, J. F., Hoyos, C. D., Ramírez, J. M., Ceballos, L. I., Zuluaga, M. D., Arias, P. A., Botero, B. A., Montoya, M. I., Giraldo, J. D., & Quevedo, D. I. (2006). Linking Long-Term Water Balances and Statistical Scaling to Estimate River Flows along the Drainage Network of Colombia. Journal of Hydrologic Engineering, 12(1), 4–13.
- Preisendorfer, R., & Mobley, C. (1988). Principal component analysis in meteorology

- and oceanography. Elsevier, 17, 425.
- Rietveld, M. (1978). A new method for estimating the regression coefficients in the formula relating solar radiation to sunshine. *Agricultural Meteorology*, 19, 9.
- Rouse, J., Haas, R., Schell, J., & Deering, D. (1973). Monitoring the vernal advancement and retrogradation (Green wave effect) of natural vegetation. Texas University, 120.
<https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19730017588.pdf>
- Ruiz, J., & Molano, Ni. (2011). Dinámica de la precipitación, la temperatura y la razón de aridez (1973-2011) en un escenario de cambio global en la isla de la vieja Providencia, Colombia: ¿qué está cambiando? *Revista Colombiana de Geografía*, 26, 25–35. <https://doi.org/10.15446/rcdg.v26n1.56019>.
- Russell, S., & Norvig, P. (1995). *Artificial intelligence: A modern approach*. Prentice Hall.
- Şahin, M. (2012). Modelling of air temperature using remote sensing and artificial neural network in Turkey. *Advances in Space Research*, 50(7), 973–985. <https://doi.org/10.1016/j.asr.2012.06.021>
- Sancho Caparrini, F. (2019). Redes Neuronales: una visión superficial. <http://www.cs.us.es/~fsancho/?e=72>
- Scholz, M., Fraunholz, M., & Selbig, J. (2008). Nonlinear Principal Component Analysis: Neural Network Models and Applications. Springer, 58. https://doi.org/https://doi.org/10.1007/978-3-540-73750-6_2
- Sedano-cruz, K., Carvajal-escobar, Y., & Ávila, Á. (2012). Variabilidad climática, cambio climático y gestión integrada del riesgo de inundaciones en Colombia. Cc.
- Serrano, B. M., González-Caselas, N., Soler-flores, F., & Orive, A. C. (2018). Análisis de las dimensiones social y ambiental portuarias a través de inteligencia artificial. 18, 264–284.
- Seyoum, W. M. (2018). Characterizing water storage trends and regional climate influence using GRACE observation and satellite altimetry data in the Upper Blue Nile River Basin. *Journal of Hydrology*, 566(March), 274–284. <https://doi.org/10.1016/j.jhydrol.2018.09.025>
- Shi, H., Li, T., Wei, J., Fu, W., & Wang, G. (2016). Journal of Hydrology : Regional Studies Spatial and temporal characteristics of precipitation over the Three-River Headwaters region during 1961 – 2014. *Biochemical Pharmacology*, 6, 52–65. <https://doi.org/10.1016/j.ejrh.2016.03.001>
- Sivakumar, M., Raymond, M., Wilhite, D., & Wood, D. (2011). Agricultural Drought

- Indices. Proceedings of the WMO/UNISDR Expert Group Meeting on Agricultural Drought Indices, June 2-4, 2010, Murcia, Spain. World Meteorological Organization, Geneva, Switzerland. AGM-11, WMO/TD No. 1572; World Meteorological Organization, 15.
[https://www.droughtmanagement.info/literature/WMO_agricultural_drought_in
dices_proceedings_2010.pdf](https://www.droughtmanagement.info/literature/WMO_agricultural_drought_indices_proceedings_2010.pdf)
- Soh, Y. W., Koo, C. H., Huang, Y. F., & Fung, K. F. (2018). Application of artificial intelligence models for the prediction of standardized precipitation evapotranspiration index (SPEI) at Langat River Basin, Malaysia. *Computers and Electronics in Agriculture*, 144(September 2017), 164–173.
<https://doi.org/10.1016/j.compag.2017.12.002>
- Solomatine, D. P. (2002). Applications of Data-Driven Modelling and Machine Learning in Control of Water Resources. *Computational Intelligence in Control*, 20. <https://doi.org/10.4018/9781591400370.ch012>
- Sun, F., Mejia, A., Zeng, P., & Che, Y. (2019). Projecting meteorological, hydrological and agricultural droughts for the Yangtze River basin. *Science of the Total Environment*, 696, 134076.
<https://doi.org/10.1016/j.scitotenv.2019.134076>
- SunFields. (2007). Radiación, Geometría, Recorrido óptico, Irradiancia y HSP.
[https://www.sfe-solar.com/noticias/articulos/energia-fotovoltaica-radiacion-
geometria-recorrido-optico-irradiancia-y-hsp](https://www.sfe-solar.com/noticias/articulos/energia-fotovoltaica-radiacion-geometria-recorrido-optico-irradiancia-y-hsp)
- Szandala, T. (2020). Review and comparison of commonly used activation functions for deep neural networks. Springer, 903.
- Tallarida, R., & Murray, R. (1987). Area under a Curve: Trapezoidal and Simpson's Rules. In *Manual of Pharmacologic Calculations with computer programs* (pp. 77–81). Springer. [https://doi.org/https://doi.org/10.1007/978-1-4612-4974-0_26](https://doi.org/10.1007/978-1-4612-4974-0_26)
- Tayfur, G. (2017). Modern Optimization Methods in Water Resources Planning, Engineering and Management. *Water Resource Management*, 29.
- Thornthwaite, C., & Wilm, H. (1948). Report of the Committee on transpiration and evaporation. *Transactions American Geophysical Union*, 25, 10.
- Toté, C., Domingos, P., Boogard, H., Wijngaart, R., Tarnavsky, E., & Funk, C. (2015). Evaluation of Satellite Rainfall Estimates for Drought and Flood Monitoring in Mozambique. *Remote Sensing*, 7, 1758–1776.
[https://www.researchgate.net/publication/272352703_Evaluation_of_Satellite
Rainfall_Estimates_for_Drought_and_Flood_Monitoring_in_Mozambique/link/
54e265cf0cf2966637969a2e/download](https://www.researchgate.net/publication/272352703_Evaluation_of_Satellite_Rainfall_Estimates_for_Drought_and_Flood_Monitoring_in_Mozambique/link/54e265cf0cf2966637969a2e/download)
- Turc, L. (1961). Evaluation of irrigation water requirements, potential

- evapotranspiration: A simple climatic formula evolved up to date. *Ann. Agron.*, 12, 36.
- Urdiales, D., & Céleri, R. (2018). Pronóstico de la ocurrencia de precipitación diaria en un gradiente altitudinal en el Sur del Ecuador , mediante un generador climático. 29–41.
- Urrea, V., Ochoa, A., & Mesa, O. (2019). Seasonality of Rainfall in Colombia. *Water Resources Research*, 55, 4149–4162.
<https://agupubs.onlinelibrary.wiley.com/doi/epdf/10.1029/2018WR023316>
- Velandia, J. (2016). Modelo Hidrológico De Predicción De Amenazas Por Sequía Bajo Escenarios De Cambio Climático. Universidad de Los Andes, 85.
- Venables, W., & Ripley, B. (2002). Modern Applied Statistics with S. In Springer.
<https://link.springer.com/book/10.1007/978-0-387-21706-2>
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index. *Journal of Climate*, 23(7), 1696–1718.
<https://doi.org/10.1175/2009JCLI2909.1>
- Vincent, K. (2007). Uncertainty in adaptive capacity and the importance of scale. *Global Environmental Change*, 17, 12–24.
<https://doi.org/10.1016/j.gloenvcha.2006.11.009>
- Viviescas, C. V. (2019). Análisis de sequías meteorológicas e hidrológicas en la Macrocuenca Magdalena – Cauca (McMC) para el período 1980-2010.
- Weghorst, K. (1996). The reclamation drought index: guidelines and practical applications. ASCE.
- Weng, W., Becker, S., Lüdeke, M., & Lakes, T. (2020). Landscape matters: Insights from the impact of mega droughts on Colombia's energy transition. *Environmental Innovation and Societal Transitions*, 36, 1–16.
<https://www.sciencedirect.com/science/article/pii/S2210422420300666>
- WMO, & GWP. (2016). Handbook of Drought Indicators and Indices (M. Svoboda and B.A. Fuchs) Integrated Drought Management Programme (IDMP), Integrated Drought Management Tools and Guidelines Series 2. Geneva.
https://library.wmo.int/doc_num.php?explnum_id=3057
- Yang, Y., Yew, T., & Tan, X. (2019). Spatiotemporal changes of drought characteristics and their dynamic drivers in Canada. *Atmospheric Research*, 232, 17. <https://doi.org/10.1016/j.atmosres.2019.104695>
- Yen, M. H., Liu, D. W., Hsin, Y. C., Lin, C. E., & Chen, C. C. (2019). Application of the deep learning for the prediction of rainfall in Southern Taiwan. *Scientific*

- Reports, 9(1), 1–9. <https://doi.org/10.1038/s41598-019-49242-6>
- Yihdego, Y., Vaheddoost, B., & Al-Weshah, R. A. (2019). Drought indices and indicators revisited. *Arabian Journal of Geosciences*, 12(69), 12. <https://doi.org/10.1007/s12517-019-4237-z>
- Zabbah, I., Roshani, A., & Khafage, A. (2018). Prediction of monthly rainfall using artificial neural network mixture approach, Case Study : Torbat-e Heydariy yeh. *Journal of Earth and Space Physics*, 44(4), 12. <https://doi.org/10.22059/jesph>
- Zargar, A., Sadiq, R., Naser, B., & Khan, F. I. (2011). A review of drought indices. *Environmental Reviews*, 19(1), 333–349. <https://doi.org/10.1139/a11-013>
- Zhang, G., Patuwo, E., & Hu, M. (1997). Forecasting With Artificial Neural Networks: The State of the Art. *International Journal of Forecasting*, 14, 35–62. https://www.researchgate.net/publication/222489987_Forecasting_With_Artificial_Neural_Networks_The_State_of_the_Art
- Zulifqar, A., Hussain, I., Muhammad, F., Haffisa, M., Hussain, T., Muhammad, Y., Alaa, M., & Showkat, H. (2017). Forecasting Drought Using Multilayer Perceptron Artificial Neural Network Model. *Advances in Meteorology*, 10.