

**Modelación de excedencias de periodos secos y húmedos en la cuenca del río Porce mediante
procesos de Poisson no homogéneos**

Estudiante:

Isaac Eli Ferrucho Maloof
ieferruchm@eafit.edu.co

Director:

Biviana Marcela Suarez Sierra
bmsuarezs@eafit.edu.co

Co-Directora:

Alejandra María Carmona Duque
amcarmonad@eafit.edu.co

UNIVERSIDAD EAFIT
ESCUELA DE CIENCIAS
MAESTRÍA EN CIENCIAS DE LOS DATOS Y ANALÍTICA
MEDELLÍN
2024

CONTENIDO

1. Planteamiento del problema.....	4
2. Justificación	5
3. Objetivos	6
3.1 Objetivo General	6
3.2 Objetivos específicos.....	6
4. Marco teórico	7
4.1 Caracterización hidroclimática de Colombia.....	7
4.2 Zona de estudio: cuenca hidrográfica del río Porce	8
4.3 Método imputación de datos espaciales.....	9
4.4 Índice de precipitación estandarizado (SPI)	10
4.5 Proceso de Poisson no homogéneo	12
4.6 Funciones de intensidad	13
5. Marco Metodológico.....	14
5.1 Comprensión del problema	15
5.2 Comprensión de los datos	15
5.3 Preparación de los datos.....	16
5.4 Evaluación del método de imputación	16
5.5 Modelado	16
5.6 Evaluación.....	17
6. Aplicación de la metodología	17
6.1 Entendimiento del problema	18
6.2 Comprensión de los datos	18
6.3 Preparación de los datos.....	20
6.3.1 Imputación de datos faltantes	20
6.3.2 Evaluación del método LOOCV	20
6.3.3 Transformación de los datos a escala del SPI	20
6.4 Evaluación de los modelos NHPP para estaciones meteorológicas.....	29
6.4.1 Modelo con Poisson no homogéneo en eventos moderados	30
6.4.2 Modelo con Poisson no homogéneo en eventos severos.....	32
6.5 Consideraciones importantes	35
7. Conclusiones y trabajos futuros	36
8. Referencias.....	37
9. Anexo I: Resultados de las métricas del modelo	40

LISTA DE FIGURAS

Figura 1. Ubicación de las estaciones meteorológicas en la cuenca del río Porce	9
Figura 2. Metodología del proyecto. Adaptación del ciclo de vida de los datos TDSP basada en CRISP-DM (Wirth & Hipp, 2000).....	15
Figura 3. Diagrama de flujo basado en la metodología CRISPDM (elaboración propia).	18
Figura 4. de las estaciones meteorológicas seleccionadas en la cuenca del río Porce.....	19
Figura 5. Ajuste de las distribuciones de probabilidad para las series mensuales de precipitación.	23
Figura 6. Serie temporal del SPI con la división de umbrales	25
Figura 7. Boxplot del SPI con la división de umbrales.....	26
Figura 8. Conteo de eventos acumulativo de eventos de excedencia por umbrales del SPI.....	27
Figura 9. Ajuste de los modelos para eventos de sequía moderada ($SPI < -1$) en la estación 27010870.....	32
Figura 10. Ajuste de los modelos para eventos de humedad moderada ($SPI > 1$) en la estación 27010870.....	32
Figura 11. Ajuste de los modelos para eventos de sequía extrema ($SPI < -1.5$) en la estación 27010870.....	35
Figura 12. Ajuste de los modelos para eventos de humedad extrema ($SPI > 1.5$) en la estación 27010870.....	35

LISTA DE TABLAS

Tabla 1 Clasificación de Condiciones Hidrológicas basadas en el Índice de Precipitación Estandarizado (SPI), adaptada de McKee et al. (1993).	11
Tabla 2. Resultados de pruebas de ajuste de distribución para estaciones meteorológicas.	21
Tabla 3. Análisis de Frecuencia de Eventos de Excedencia por Estación.	28
Tabla 4. Modelos de NHPP para el periodo de sequía moderada ($SPI < -1$) para la estación 27010870.....	30
Tabla 5. Modelos de NHPP para el periodo de humedad moderada ($SPI > 1$) para la estación 27010870.....	31
Tabla 6. Modelos de NHPP para el periodo de sequía extrema ($SPI < -1.5$) para la estación 27010870.....	33
Tabla 7. Modelos de NHPP para el periodo de humedad extrema ($SPI > 1.5$) para la estación 27010870.....	34

Modelación de excedencias de periodos secos y húmedos en la cuenca del río Porce mediante procesos de Poisson no homogéneos

Resumen

El presente estudio analiza los periodos de déficits y excesos de precipitación en la cuenca del río Porce, Colombia, durante el periodo de 1970 a 2023. Utilizando el Índice de Precipitación Estandarizado (SPI) y datos de series de precipitación mensual provenientes de estaciones meteorológicas seleccionadas por su completitud de datos en la cuenca del río Porce, se desarrolló y aplicó un modelo basado en Procesos de Poisson No Homogéneos (NHPP) para identificar y caracterizar estos periodos. Se evaluaron diferentes configuraciones de NHPP, como las funciones de intensidad lineal, potencial y exponencial. Los resultados indican que los modelos de ley de potencia y lineales, en la mayoría de los casos, ofrecen un ajuste superior para la estimación de periodos de sequía y humedad, mientras que los modelos exponenciales presentaron limitaciones notables en la capacidad para representar de manera precisa los eventos extremos de sequía y humedad. Este hallazgo subraya la importancia de elegir modelos adecuados que respondan a las particularidades climáticas y geográficas de la región, contribuyendo significativamente a la mejora en la gestión y planificación de los recursos hídricos.

Palabras clave: Índice de Precipitación Estandarizado, sequía, humedad, Proceso de Poisson no Homogéneo, función de intensidad lineal, función de intensidad potencial, función de intensidad exponencial.

1. Planteamiento del problema

La gestión hídrica es fundamental para el desarrollo sostenible y enfrenta desafíos cruciales debido a la variabilidad climática, manifestada en eventos como sequías e inundaciones. Estos eventos, caracterizados por variaciones significativas en las precipitaciones, pueden desencadenar desastres naturales con impactos adversos en las comunidades y ecosistemas. La sequía es un fenómeno recurrente que requiere un manejo proactivo para mitigar sus riesgos asociados (Wilhite & Pulwarty, 2017). Además, es crucial implementar estrategias de manejo que no solo atiendan la escasez de agua durante las sequías, sino que también preparen a las comunidades para manejar eficazmente las precipitaciones intensas y evitar inundaciones.

El Índice de Precipitación Estandarizado (SPI) es una herramienta ampliamente utilizada a nivel mundial para monitorear condiciones extremas de precipitación y facilitar comparaciones interregionales (McKee et al., 1993; Guttman, 1999). Su enfoque multiescalar y carácter espacialmente invariante permiten evaluar variaciones en la precipitación y realizar análisis comparativos entre distintas regiones. En América Latina, el SPI ha demostrado ser efectivo para identificar y gestionar amenazas naturales como las sequías, con implementaciones exitosas en países como Brasil y Colombia.

Para mejorar la estimación de eventos extremos detectados por el SPI, ambos países han utilizado modelos de Procesos de Poisson No Homogéneos (NHPP) y redes neuronales artificiales. Estas metodologías permiten predecir y mitigar los efectos de las sequías y otras condiciones extremas de precipitación. En el caso de Brasil, se han implementado estrategias de riego y gestión estratégica del agua para minimizar el impacto de la sequía en la agricultura, mientras que en Colombia se han desarrollado planes de contingencia para proteger a la población y el medio ambiente. (Achcar et al., 2016; Canchala et al., 2020).

Este estudio se enfoca en la estimación del SPI en la cuenca del río Porce, proponiendo la implementación de NHPP. Este modelo estocástico, aplicado en ámbitos tan variados como la calidad del aire, la sismología y las sequías, ofrece una metodología para analizar patrones de eventos que superan umbrales preestablecidos (Achcar et al., 2016). Se examinarán distintas variantes del NHPP, incluyendo funciones de intensidad lineal, potencial y exponencial para caracterizar efectivamente los periodos de sequía y humedad (Diggle, 2013; Achcar et al., 2016). De esta manera, se responderá la pregunta central: “¿Cómo pueden los modelos de Procesos de Poisson No Homogéneos con diferentes funciones de intensidad mejorar la estimación de los índices del SPI y contribuir a una caracterización efectiva de los periodos de sequía y humedad en la cuenca del río Porce?”

2. Justificación

Las variaciones extremas de la precipitación presentan desafíos críticos que afectan la disponibilidad agua, impactando considerablemente en varios sectores socioeconómicos. La sequía, por ejemplo, puede causar escasez de agua, afectando la agricultura, el suministro de agua potable y la generación de energía hidroeléctrica; además, puede provocar la degradación del suelo y la pérdida de biodiversidad (Wilhite & Pulwarty, 2017). Por otro lado, el exceso de precipitación puede ocasionar

inundaciones y deslizamientos, poniendo en riesgo infraestructuras y vidas humanas (Kundzewicz et al., 2013). Estas situaciones extremas evidencian la necesidad de mejorar la comprensión y estimación de los patrones de precipitación para mitigar sus efectos adversos.

El SPI es una herramienta fundamental para medir y clasificar eventos de precipitación extrema. Se propone como un indicador versátil para la alerta, monitoreo y análisis de sequías (McKee et al., 1993; Canchala et al., 2020; Karavitis et al., 2011). Este índice puede aplicarse en escalas temporales que van desde mensual hasta diaria, lo que proporciona flexibilidad y precisión en el análisis (Guttman, 1999; McKee et al., 1993; Wang et al., 2022). Sin embargo, su sensibilidad a la elección de la escala temporal y la distribución de probabilidad puede afectar la comparación y precisión de los resultados (Stagge et al., 2015).

En este contexto, el presente estudio utiliza datos de 21 estaciones meteorológicas operadas por el Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM), abarcando registros desde 1970 hasta 2023 con resolución diaria. A través del cálculo del SPI con estos datos, se pretende identificar y clasificar los eventos extremos de precipitación en la cuenca del río Porce. La implementación de modelos NHPP permitirá comprender la frecuencia e intensidad de estos fenómenos detectados por el SPI, contribuyendo así a una caracterización más precisa de los periodos de sequía y humedad. Esto, a su vez, favorecerá un manejo más eficiente del agua, reduciendo significativamente los impactos negativos de los eventos climáticos extremos en la sociedad y el medio ambiente.

3. Objetivos

3.1 Objetivo General

Desarrollar un modelo basado en el Índice Estandarizado de Precipitación (SPI) y Procesos de Poisson No Homogéneos (NHPP) con tres tipos de función de intensidad para identificar y analizar eficazmente los periodos de sequía y humedad.

3.2 Objetivos específicos

- Establecer el índice del SPI mediante diversas transformaciones de distribución y estandarización para definir con precisión los periodos severos de sequías y humedad.

- Determinar la frecuencia con la que se superan los umbrales críticos de precipitación, lo que implica calcular la tasa de ocurrencia de eventos severos por unidad de tiempo y su relación con la variabilidad climática observada en los registros históricos disponibles de 1970 a 2023.
- Evaluar la convergencia de los parámetros estimados y seleccionar el mejor modelo entre lineal, potencial y exponencial, basándose en su ajuste y relevancia en el contexto de la hidrología.

4. Marco teórico

4.1 Caracterización hidroclimática de Colombia

El clima de Colombia es altamente diverso y complejo, influenciado por factores como la topografía variada, la diversidad de ecosistemas y procesos atmosféricos a gran escala. Un factor determinante en el clima del país, especialmente en la escala interanual, es el fenómeno de El Niño-Oscilación del Sur (ENSO), que involucra fluctuaciones en la temperatura superficial del océano Pacífico y la presión atmosférica, impactando significativamente el régimen de lluvias en Colombia. El ENSO se manifiesta en dos fases principales: El Niño, caracterizado por un calentamiento de las aguas del océano Pacífico y una disminución en las precipitaciones, y La Niña, distinguida por un enfriamiento de las aguas y un incremento en las lluvias (Poveda & Álvarez, 2012; Enciso et al., 2016; Loaiza et al., 2020; Poveda, 2004).

Comprender el clima de Colombia es esencial para gestionar eficazmente el agua en zonas urbanas y rurales, lo que requiere adaptación continua frente al cambio climático y el crecimiento de la población. Las cuencas hidrográficas del país desempeñan un papel vital en la provisión de agua potable, la generación de energía hidroeléctrica y diversos servicios ecosistémicos (Angarita et al., 2018). Sin embargo, estas cuencas enfrentan retos ambientales significativos, incluyendo la variabilidad climática, la contaminación, la deforestación y la erosión, siendo particularmente susceptibles a eventos extremos como sequías e inundaciones. Por ello, es crucial contar con herramientas precisas para monitorear y estimar el comportamiento de las variables hidroclimáticas y su impacto en los recursos hídricos (Alhamsry et al., 2019).

4.2 Zona de estudio: cuenca hidrográfica del río Porce

La cuenca hidrográfica del río Porce, ubicada en el departamento de Antioquia, Colombia, es una región de gran relevancia ambiental y socioeconómica, destacada no solo por su diversidad de ecosistemas, que abarcan desde montañas hasta valles profundos, sino también por su papel fundamental en la regulación hidrológica regional y el suministro de agua para actividades agrícolas y comunidades locales (Poveda, 2004; Hurtado & Mesa, 2015). La hidrología de la cuenca está influenciada por fenómenos climáticos como el ENSO y el doble paso anual de la Zona de Convergencia Intertropical (ZCIT), los cuales generan variaciones significativas en los patrones de precipitación y afectan la disponibilidad de recursos hídricos (Poveda, 2004; Poveda et al., 2011).

Para este estudio, se recopilaron datos de precipitación diaria de 21 estaciones meteorológicas operadas por el IDEAM, abarcando el período de 1970 a 2023. Estas estaciones, distribuidas a lo largo de la cuenca y cubriendo diversas altitudes y zonas climáticas dentro del departamento de Antioquia, se presentan en la figura 1. Durante la recopilación de datos, se identificaron desafíos relacionados con la presencia de datos faltantes, debido a interrupciones en las mediciones y limitaciones en las redes de monitoreo. Estos vacíos en la información pueden afectar el análisis y la comprensión de los patrones de precipitación, por lo que es necesario implementar técnicas de imputación para completar los registros incompletos.

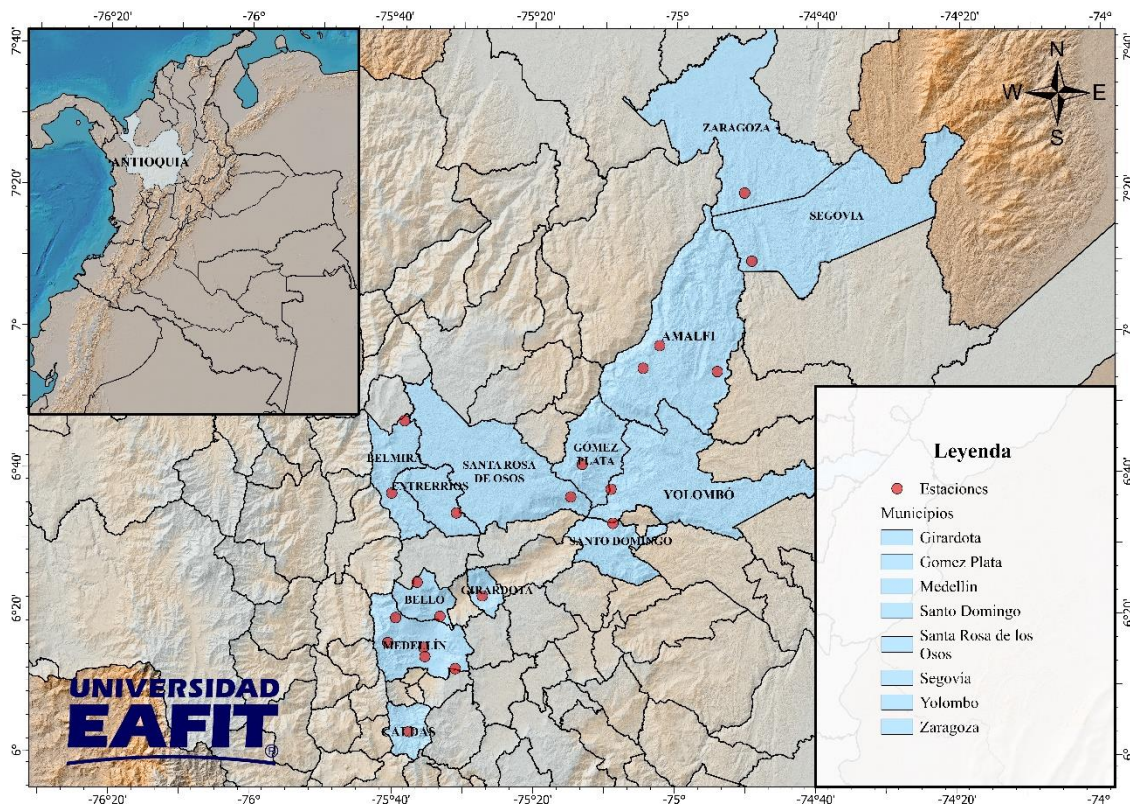


Figura 1. Ubicación de las estaciones meteorológicas en la cuenca del río Porce

4.3 Método imputación de datos espaciales

La presencia de datos faltantes en series de precipitación diaria es un problema común en estudios hidroclimáticos, debido a la variabilidad meteorológica y las limitaciones en las redes de monitoreo (Russi & Larrahondo, 2019). Estas lagunas de información pueden afectar significativamente el análisis de los patrones de precipitación, haciendo necesario implementar técnicas de imputación para completar los datos faltantes (Egigu, 2020).

La interpolación por Distancia Inversa Ponderada (IDW) es una técnica espacial ampliamente utilizada para estimar valores en ubicaciones no muestreadas a partir de observaciones conocidas, basada en el principio de que la influencia de una estación disminuye con la distancia, implicando que las estaciones más cercanas tienen mediciones más similares (Roshan & Lulu, 2011; Bivand et al., 2013).

En este estudio, el IDW se aplica para imputar datos faltantes en series temporales de precipitación diaria, abordando la ausencia de registros en ciertos días. Esta interpolación garantiza una representación continua y fiable de la precipitación, esencial para el análisis hidroclimático (Egigu,

2020). Este método ha sido destacado en estudios previos por su efectividad en la imputación de datos faltantes en series temporales meteorológicas (Roshan & Lulu, 2011; Egigu, 2020).

La fórmula utilizada en el IDW es la siguiente (Russi & Larrahondo, 2019):

$$\hat{Z}(S_0) = \frac{\sum_{i=1}^n w(S_i)z(S_i)}{\sum_{i=1}^n w(S_i)} \quad (1)$$

Donde:

- $\hat{Z}(S_0)$ representa los datos de precipitación desconocidos (en mm).
- $z(S_i)$ representa los datos de precipitación de las estaciones pluviométricas conocidas (en mm)
- $w(S_i) = ||S_i - S_0 ||^{-p}$ es el peso asignado a cada estación pluviométrica.
- $||S_i - S_0 ||$ es la distancia euclidiana entre la estación conocida S_i y el punto desconocido S_0
- n es el número de estaciones pluviométricas.
- p es el exponente de ponderación de la distancia inversa, que comúnmente se asume igual a dos.

4.4 Índice de precipitación estandarizado (SPI)

El SPI es un indicador clave para la medición y clasificación de eventos meteorológicos severos, ofreciendo una metodología estandarizada para evaluar los periodos de precipitación en diversas escalas temporales, desde 1 hasta 12 meses (McKee et al., 1993; Guttman, 1999; Tsakiris & Vangelis, 2004).

Para calcular el SPI, se selecciona primero una distribución de probabilidad que se ajuste adecuadamente a las series temporales de precipitación de cada estación meteorológica. Entre las distribuciones consideradas están la Gamma, Gumbel y Weibull, cuya adecuación se evalúa mediante pruebas estadísticas como la prueba de Kolmogorov-Smirnov (Justel et al., 1997; Ellahi et al., 2020; Pieper et al., 2020). Esta prueba es una herramienta ampliamente utilizada para comparar la distribución empírica de los datos con una distribución teórica. Mide la distancia máxima entre ambas distribuciones acumuladas, y si el valor p resultante es mayor que 0.05, se considera que no

hay evidencia suficiente para rechazar la hipótesis nula de que los datos siguen la distribución teórica seleccionada (Massey, 1951; Justel et al., 1997).

Tradicionalmente, se utiliza la distribución Gamma para ajustar los datos de precipitación debido a su capacidad para modelar eficazmente las series temporales (Guttman, 1999; Tsakiris & Vangelis, 2004). Una vez seleccionada y ajustada la distribución adecuada, los datos se transforman a una distribución normal estándar (media 0 y desviación estándar 1), permitiendo que los índices obtenidos sean comparables entre diferentes regiones y periodos de tiempo. Dependiendo de las características específicas de los datos de precipitación, otras distribuciones como la Weibull o la exponencial generalizada pueden ser más apropiadas (Stagge et al., 2015).

Los valores del SPI pueden ser positivos o negativos, reflejando condiciones húmedas o secas, respectivamente. Para interpretar estos valores, se utiliza una tabla de clasificación que define distintas categorías de los periodos de precipitación (ver Tabla 1) (McKee et al., 1993; Guttman, 1999; Zhiña et al., 2017). Comprender estos umbrales es fundamental para que diversos sectores puedan anticiparse de manera efectiva a las condiciones de sequía, gestionar adecuadamente las reservas hídricas y reducir el riesgo de escasez durante periodos críticos.

Tabla 1 Clasificación de Condiciones Hidrológicas basadas en el Índice de Precipitación Estandarizado (SPI), adaptada de McKee et al. (1993).

Valores SPI	Categoría
≥ 2.0	Extremadamente húmedo
(1.5,1.99)	Muy húmedo
(1.00, 1.49)	Moderadamente húmedo
(-0.99, 0.99)	Normal
(-1.49, -1.00)	Moderadamente seco
(-1.99,-1.5)	Muy seco
≤ -2.0	Extremadamente seco

A pesar de sus ventajas, el SPI tiene limitaciones. La sensibilidad del índice a la elección de la escala temporal, el periodo de referencia y la distribución de probabilidad puede influir significativamente en los resultados (McKee et al., 1993; Guttman, 1999; Stagge et al., 2015). Por tanto, es crucial

seleccionar adecuadamente estos parámetros para asegurar que los resultados del SPI sean comparables y precisos entre diferentes regiones y periodos.

4.5 Proceso de Poisson no homogéneo

El Proceso de Poisson No Homogéneo (NHPP) es un modelo estocástico utilizado para modelar la ocurrencia de eventos aleatorios en el tiempo o espacio, caracterizado por una tasa de ocurrencia no constante. Este modelo es especialmente útil para analizar la frecuencia de eventos y la variabilidad en procesos dinámicos como la calidad del aire, la sismología y las sequías (Guler et al., 2022; Diggle, 2013; Liu & Xie, 2022).

El NHPP se caracteriza por el proceso de conteo $N(t)$, que registra el número de eventos en el intervalo $(0, t]$ para $t \geq 0$. Este proceso se caracteriza por las siguientes propiedades, descritas por Ross (2014):

- $N(0) = 0$.
- $N(t)$ tiene incrementos independientes, lo que implica que los eventos en intervalos no solapados son independientes.
- La distribución condicional del número de eventos en un intervalo depende de la longitud del intervalo y de la función de intensidad $\lambda(t)$, que representa la tasa instantánea de ocurrencia de eventos en el tiempo t .

La función de intensidad $\lambda(t)$ puede ser constante o variable en el tiempo. Si $\lambda(t)$ es variable, el NHPP se describe mediante una función de valor medio $m(t)$, que representa el número esperado de eventos hasta el tiempo t . Esta función, conocida como la media acumulada del NHPP, estima el número acumulado de eventos y es no decreciente, reflejando la acumulación de eventos a lo largo del tiempo. La función de valor medio se define como la integral de la función de intensidad hasta el tiempo t , y es fundamental para entender y estimar la ocurrencia de eventos extremos, como los relacionados con la precipitación (Ng & Zammit-Mangion, 2023; Ross, 2014). La función de valor medio se define como:

$$m(t) = \int_0^t \lambda(s) ds \quad (2)$$

Para un intervalo $(t, t + x]$, el número de eventos sigue una distribución de Poisson con $\lambda = m(t + x) - m(t)$. Esto nos permite calcular la probabilidad de que exactamente k eventos ocurran en el intervalo de tiempo. Por ejemplo, con esto se puede establecer la probabilidad de tener k excedencias del umbral 1.5 en un tiempo determinado, proporcionando una herramienta valiosa para el análisis de riesgos y planificación hidrológicos.

$$P [N(t + x) - N(t) = k] = \frac{(m(t + x) - m(t))^k}{k!} e^{-(m(t+x)-m(t))} \quad (3)$$

Para el modelo que se utiliza en el presente trabajo, $g(t, x)$ se establece como la probabilidad de no contar excedencias en el intervalo $(t, t + x]$. Como lo explica Cox & Lewis (1966), $g(t, x)$ es la probabilidad de que, comenzando en el tiempo t , el tiempo hasta el próximo evento sea mayor que x . Por lo tanto:

$$g(t, x) = P [N(t + x) - N(t) = 0] = \frac{(m(t + x) - m(t))^0}{0!} e^{-(m(t+x)-m(t))}$$

$$g(t, x) = e^{-(m(t+x)-m(t))}$$

$$g(t, x) = e^{-\int_t^{t+x} \lambda(s) ds} \quad (4)$$

Si se desea conocer la probabilidad de que, comenzando en t , el tiempo hasta el próximo evento sea menor que x , se puede calcular $1 - g(t, x)$. Diferenciando esta última función con respecto a x , se obtiene la función de densidad de probabilidad (PDF) para el intervalo hasta el próximo evento:

$$f(t + x) = \frac{\partial(1 - g(t, x))}{\partial x} = \lambda(t + x) * e^{-\int_t^{t+x} \lambda(s) ds} \quad (5)$$

4.6 Funciones de intensidad

Para comprender el comportamiento de los eventos de sequía y humedad en la cuenca del río Porce, es fundamental analizar las funciones de intensidad $\lambda(t)$. En este estudio, se comparan tres casos de NHPP: la función de intensidad lineal, el proceso de ley potencial y la función exponencial, expresadas como:

$$\lambda_L(t) = \alpha_i + \beta_i t \quad (6)$$

$$\lambda_P(t) = \alpha_i + t^{\beta_i - 1} \quad (7)$$

$$\lambda_E(t) = e^{\alpha_i + \beta_i t} \quad (8)$$

Las funciones de valor medio acumulado $m(t)$ se calculan como:

$$m_L(t) = \alpha_i t + \frac{\beta_i t^2}{2}, \quad \alpha_i, \beta_i \in (0, \infty) \quad (9)$$

$$m_P(t) = \alpha_i t + \frac{t^{\beta_i}}{\beta_i}, \quad \alpha_i, \beta_i \in (0, \infty) \quad (10)$$

$$m_E(t) = \frac{e^{\alpha_i + \beta_i t}}{\beta_i}, \quad \alpha_i, \beta_i \in (0, \infty) \quad (11)$$

Donde:

- $\lambda(t)$ es la función de intensidad, que indica la tasa de ocurrencia de eventos en un instante de tiempo t . Cada una de las tres funciones (lineal, potencial y exponencial) refleja un modelo distinto de cómo se espera que los eventos ocurran a lo largo del tiempo.
- $m(t)$ es la función de valor medio acumulado, que refleja el número esperado de eventos hasta el tiempo t . Para cada tipo de las tres funciones (lineal, potencial y exponencial), $m(t)$ tiene una forma diferente, capturando la acumulación de eventos esperados según el modelo aplicado.
- α_i es el parámetro de escala inicial para las funciones lineal, potencia y exponencial, respectivamente. Estos valores representan la intensidad inicial del proceso en $t=0$.
- β_i es el coeficiente que determinan cómo varía la intensidad con el tiempo en cada caso. En el modelo lineal, β_i controla el aumento lineal de la intensidad, mientras que en los modelos de potencia y exponencial, β_i gobiernan los cambios no lineales de la intensidad.

Estos parámetros varían según la estación meteorológica y el tipo de función aplicada. El modelo lineal asume una intensidad que cambia de manera constante, mientras que los modelos de potencia y exponencial permiten capturar comportamientos más complejos en la ocurrencia de eventos extremos en la cuenca del río Porce.

5. Marco Metodológico

A continuación, se detalla la metodología utilizada para analizar los datos del SPI y comprender el comportamiento de los eventos de sequía y humedad en la cuenca del río Porce. El estudio se basa

en la metodología CRISP-DM, un estándar ampliamente reconocido para la exploración de datos y el desarrollo de proyectos de aprendizaje automático (Wirth & Hipp, 2000) (ver figura 2). Esta metodología se estructura en las siguientes fases:




Figura 2. Metodología del proyecto. Adaptación del ciclo de vida de los datos TDSP basada en CRISP-DM (Wirth & Hipp, 2000).

5.1 Comprensión del problema

En esta fase inicial, se busca entender el contexto de la precipitación en la cuenca del río Porce y su impacto en la gestión de recursos hídricos. Se identifican las variables e indicadores clave para una gestión efectiva del agua y se establece un enfoque para el análisis de sequías y humedad. Este análisis es crucial para desarrollar estrategias que permitan una respuesta adaptativa a los patrones cambiantes de precipitación, asegurando la sostenibilidad de los recursos hídricos.

5.2 Comprensión de los datos

Se identifica y documenta el flujo de trabajo, así como los sistemas de registros y la procedencia de los datos. Para el desarrollo del proyecto, se recopilaron datos históricos de precipitación del IDEAM, disponibles en formatos CSV o Excel.

5.3 Preparación de los datos

Este paso abarca todas las acciones necesarias para configurar el conjunto de datos para el modelo, enfocándose en los datos pluviométricos de las estaciones meteorológicas:

- **Extracción:** Se recopilan datos de precipitación de estaciones meteorológicas ubicadas en diversos sectores de la cuenca del río Porce, Colombia. El objetivo es obtener una serie temporal de precipitación suficientemente larga y representativa para modelar eventos extremos e identificar periodos de sequía y humedad.
- **Imputación de los datos faltantes:** Se emplea la interpolación IDW como técnica para imputar datos faltantes en series temporales de precipitación diaria, debido a la ausencia de registros en ciertos días.
- **Transformación de los datos:** Se suman los valores diarios de precipitación para cada mes, creando un total mensual. Los datos se ajustan a una distribución de probabilidad adecuada (Weibull, Gamma o Gumbel) y se transforman a una distribución normal estándar (media 0 y desviación estándar 1), permitiendo comparar los niveles de precipitación de manera uniforme en diferentes escalas temporales.

5.4 Evaluación del método de imputación

Para asegurar la calidad y precisión de los datos imputados mediante IDW, se implementó la validación cruzada Leave-One-Out (LOOCV). Este enfoque evalúa la capacidad predictiva del modelo cuando ciertos datos están ausentes, excluyendo una observación y entrenando el modelo con las restantes para predecir el valor excluido (Antal et al., 2021).

Se utilizó el Error Cuadrático Medio (RMSE) para medir la efectividad del método IDW, comparando las diferencias entre los valores observados y los predichos (Antal et al., 2021; Sánchez, 2020). Esto proporciona una medida de la precisión del proceso de imputación implementado.

5.5 Modelado

Se describe el modelado utilizado para comprender el comportamiento de los eventos de sequía y humedad, basado en Procesos de Poisson No Homogéneo (NHPP). Se aplican tres funciones de intensidad: lineal, potencia y exponencial, que permiten capturar diversos patrones en la ocurrencia de eventos extremos en la cuenca del río Porce.

5.6 Evaluación

La evaluación del modelo NHPP es crucial para asegurar su efectividad en la estimación de eventos de sequía y humedad. Para comparar los diferentes modelos de función de intensidad se utilizan métricas estadísticas como:

- **AIC (Criterio de Información de Akaike):** Mide la calidad relativa de un modelo considerando la bondad de ajuste y la complejidad. Un valor más bajo de AIC indica un mejor ajuste del modelo. Estos valores se comparan entre los diferentes modelos y se selecciona el que tiene el AIC más bajo.
- **BIC (Criterio de Información Bayesiano):** Similar al AIC, pero con una penalización más fuerte a la complejidad del modelo. Un valor más bajo de BIC también indica un mejor ajuste. Al igual que el AIC, se utiliza para comparar entre modelos, seleccionando el que tenga el BIC más bajo.
- **RMSE (Raíz del Error Cuadrático Medio) y MAE (Error Absoluto Medio):** Miden la magnitud promedio de los errores del modelo, indicando su precisión. Valores más bajos indican mejor precisión en la estimación de la tasa de ocurrencia de eventos y su duración comparados con los valores observados.

6. Aplicación de la metodología

La metodología adoptada en este estudio, basada en el modelo CRISP-DM y adaptada a los principios del ciclo de vida de los datos de la metodología TDSP, se orienta específicamente hacia desafíos críticos en la gestión de recursos hídricos en la cuenca del río Porce. Este enfoque analítico permite no solo entender y caracterizar los periodos de sequía y humedad en la cuenca del río Porce, sino también desarrollar estrategias de gestión de riesgos para enfrentar eventos climáticos significativos. Las etapas del proceso incluyen el entendimiento del problema, la caracterización y análisis exploratorio de los datos, seguido por la preparación del modelo y su evaluación, asegurando así que cada fase contribuya eficazmente a una toma de decisiones informada y basada en evidencia (Wirth & Hipp, 2000) (ver figura 3).

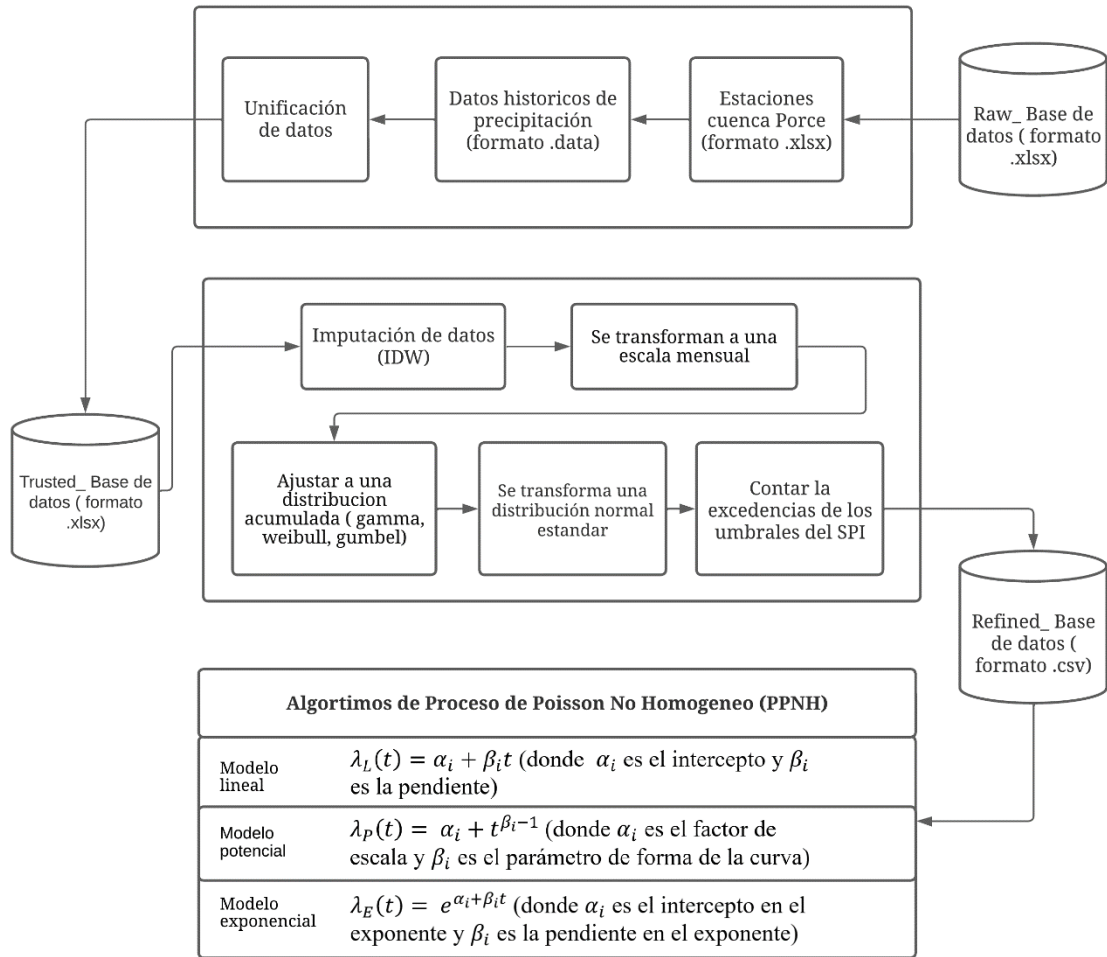


Figura 3. Diagrama de flujo basado en la metodología CRISPDM (elaboración propia).

6.1 Entendimiento del problema

Este proyecto adopta un enfoque cuantitativo para el análisis detallado de los registros de excedencias de los umbrales de precipitación. A través del SPI, se identifican valores que superan los umbrales de 1, 1.5, -1, y -1.5, indicando periodos de humedad o sequía. Estos hallazgos son vitales para informar decisiones estratégicas en sectores como la planificación hídrica y la agricultura.

6.2 Comprensión de los datos

Los datos empleados en esta investigación provienen del IDEAM y son accesibles a través del Sistema de Información Ambiental de Colombia (SIAC). Estos datos incluyen registros históricos desde 1970 hasta 2023 y abarcan variables climáticas como precipitación, humedad y temperatura

6.3 Preparación de los datos

6.3.1 Imputación de datos faltantes

Para los registros de precipitación diaria de un período de 36 años, se seleccionaron 13 estaciones meteorológicas con datos completos en más del 90%. Para rellenar las lagunas en los registros diarios a lo largo de los años, se aplicó una técnica de imputación utilizando el método de IDW. Este método ha sido destacado en estudios previos por su efectividad en la imputación de datos faltantes en series temporales meteorológicas (Roshan & Lulu, 2011; Egigu, 2020).

6.3.2 Evaluación del método LOOCV

El método de imputación de valores faltantes mediante Interpolación por IDW fue evaluado utilizando la validación cruzada Leave-One-Out (LOOCV), un enfoque que permite examinar la capacidad predictiva del modelo al excluir secuencialmente una observación y predecir su valor con las restantes. La precisión del modelo se midió utilizando el RMSE, que en este estudio fue de 11.86 mm/día, comparado con una media de precipitación observada de 7.30 mm/día. El valor del RMSE se comparó con investigaciones en otras regiones con condiciones hidroclimáticas comparables, las cuales reportan valores de RMSE que oscilan entre 5 y 15 mm/día. Estos estudios destacan que un RMSE en este rango indica una buena capacidad predictiva para la reconstrucción de datos faltantes (Sánchez, 2020; Vargas et al., 2011).

6.3.3 Transformación de los datos a escala del SPI

La transformación de los datos de precipitación diaria a mensual es un paso esencial en el análisis del SPI. Este proceso se realizó sumando todos los valores diarios de precipitación para cada mes, generando así un total mensual. Posteriormente, estos datos mensuales fueron ajustados a distribuciones de probabilidad acumulada, incluyendo Gamma, Weibull y Gumbel, para evaluar su adecuación mediante la prueba de Kolmogorov-Smirnov (McKee et al., 1993; Guttman, 1999; Justel et al., 1997; Stagge et al., 2015). Se consideró que los ajustes eran adecuados cuando los valores p obtenidos superaban el umbral de 0.05, lo cual indica que la distribución se ajusta bien a los datos.

De las 13 estaciones analizadas, 9 pasaron la prueba con la distribución Gumbel, mientras que 6 estaciones mostraron resultados satisfactorios tanto con Gumbel como con Weibull (ver tabla 2). Es importante destacar que algunos registros mensuales de precipitación contenían valores de cero, un

hecho no común pero posible, especialmente en zonas con alta variabilidad climática (Poveda et al., 2011). Estos valores de cero pueden resultar problemáticos para ciertas distribuciones, como Gamma y Weibull, que no manejan bien la ausencia de precipitación. Por esta razón, las estaciones que presentaron estos valores no se ajustaron adecuadamente a las distribuciones y fueron excluidas del análisis del SPI.

Tabla 2. Resultados de pruebas de ajuste de distribución para estaciones meteorológicas.

Id	Estaciones	Gamma	Gumbel	Weibull
1	26230220	*	0.05	*
2	27010800	*	0.05	*
3	27010810	*	0.51	*
4	27010820	*	0.65	*
5	27010830	0.01	0.32	0.18
6	27010840	0.00	0.09	0.10
7	27010850	*	0.03	*
8	27010870	0.13	0.49	0.13
9	27010900	0.00	0.27	0.07
10	27015090	0.03	0.55	0.51
11	27015190	0.00	0.27	0.06
12	27015260	*	0.23	*
13	27030090	*	0.00	*

Es fundamental aclarar que las estaciones seleccionadas para el análisis del SPI no solo pasaron la prueba de Kolmogorov-Smirnov, sino que también mostraron consistencia en sus resultados. En este contexto, la consistencia se refiere a la verificación de que los eventos extremos de precipitación identificados mediante los ajustes del SPI coinciden con eventos históricos conocidos, como El Niño de 1997-1998 y La Niña de 2010-2011. Estos eventos climáticos han sido ampliamente documentados por la NOAA, y al comparar los resultados obtenidos del SPI con estos registros, se observó una correlación significativa entre los ajustes del SPI y los eventos extremos de precipitación. Esto sugiere que la transformación de los datos refleja adecuadamente la variabilidad

climática observada en la región, aunque es importante considerar las limitaciones inherentes en los datos y el análisis. Las estaciones que no lograron pasar la prueba fueron aquellas que mostraron valores p inconsistentes, lo que podría indicar inconvenientes en el monitoreo, como datos faltantes o fallos en los instrumentos de medición.

La evaluación de esta consistencia y el ajuste adecuado de los datos se visualiza en la figura 5, que presenta las funciones de densidad ajustadas para las series mensuales de precipitación en seis estaciones meteorológicas seleccionadas. De las nueve estaciones que pasaron la prueba de Kolmogorov-Smirnov, se presentan seis que se caracterizan por su variabilidad climática y por haber pasado la prueba tanto con la distribución Gumbel como con la distribución Weibull. En cada gráfico, se comparan las distribuciones teóricas Gamma, Gumbel y Weibull con la distribución observada de precipitación. Aunque los ajustes de las tres distribuciones son en general similares, la distribución Gumbel mostró un mejor rendimiento en un mayor número de estaciones, como se refleja en la tabla 2. Esto se debe a la capacidad de la distribución Gumbel para manejar de manera más efectiva los eventos extremos de precipitación, especialmente en regiones con alta variabilidad climática. Por lo tanto, la transformación de los datos para el cálculo del SPI se realizó utilizando la distribución Gumbel, que demostró ser la más adecuada en este contexto.

Sin embargo, la distribución Weibull también podría demostrar un buen ajuste en algunas estaciones específicas, como en los casos de las estaciones 27010830 y 27010840, lo que sugiere que su aplicación puede ser adecuada en contextos particulares. Es importante destacar que la elección de la distribución óptima se realizó mediante pruebas de bondad de ajuste, como Kolmogorov-Smirnov, que permitieron comparar las distribuciones teóricas con los datos observados. Estas pruebas aseguran que las distribuciones seleccionadas, como Gumbel y Weibull, reflejan adecuadamente los patrones de precipitación en la región de estudio, aunque algunas estaciones mostraron un mejor ajuste con Gumbel. Además, esta validación también se complementó con la comparación de los resultados con eventos climáticos extremos históricos, como El Niño y La Niña, para asegurar que las distribuciones seleccionadas reflejan de manera precisa los patrones de precipitación en la región de estudio.

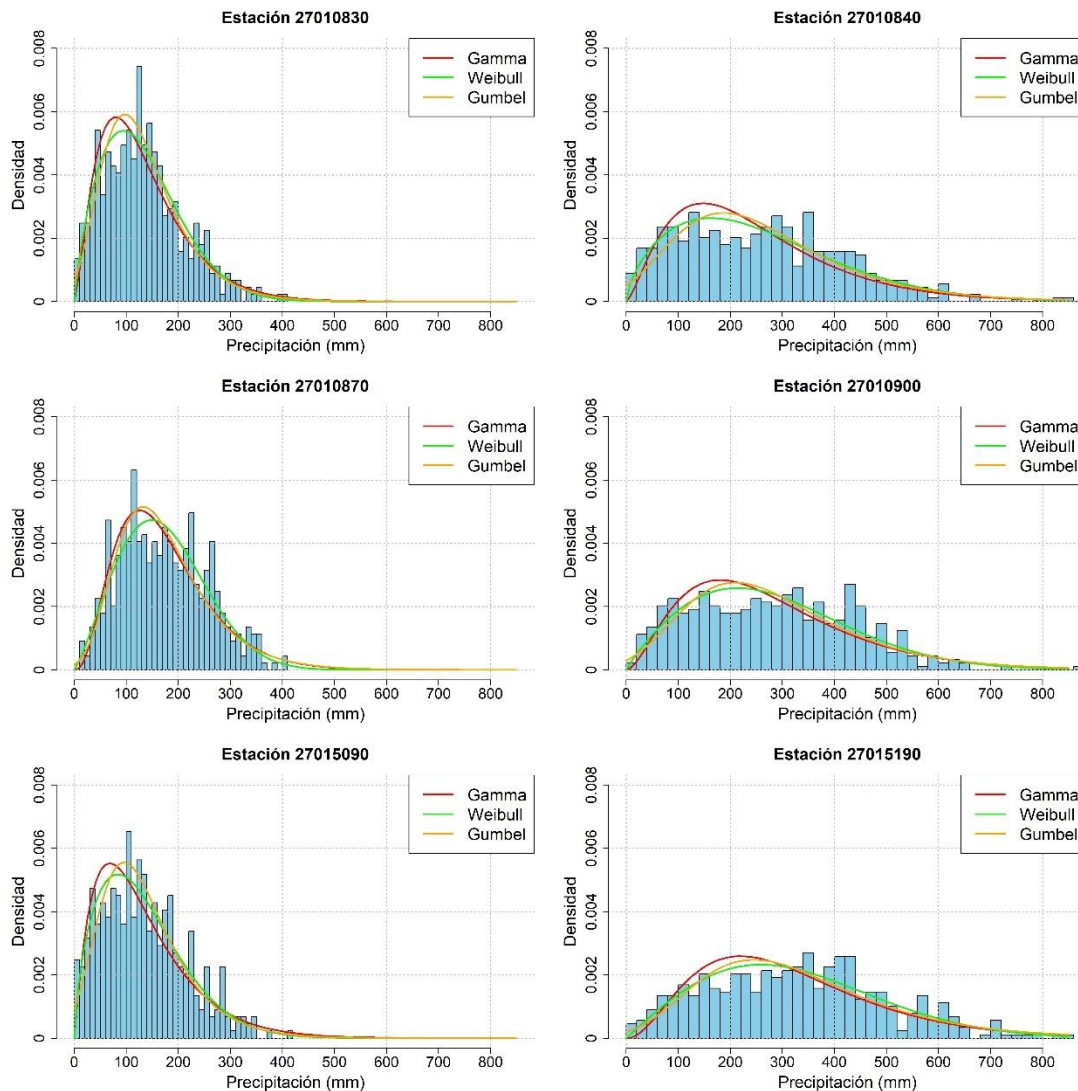


Figura 5. Ajuste de las distribuciones de probabilidad para las series mensuales de precipitación.

En la estación 27010830, ubicada en el municipio de Entrerriós, se observa un pico de densidad alrededor de los 130 mm/mes, lo que sugiere que la mayor concentración de valores de precipitación en esta estación ocurre alrededor de esta cifra. Aunque el rango de precipitación se extiende de 0 a 500 mm, la mayor frecuencia de valores se concentra en el rango moderado de precipitaciones cercanas a los 130 mm/mes. Esto refleja una tendencia de lluvias frecuentes de magnitud moderada, lo que es importante considerar para la gestión del agua y la planificación de medidas preventivas en eventos recurrentes de lluvia.

Por otro lado, la estación 27010840, ubicada en Santa Rosa de Osos, muestra una distribución con una cola más pesada hacia la derecha, extendiéndose de 0 a 850 mm. Esta región, caracterizada por

su alta pluviosidad y terrenos montañosos. La observación de esta cola pesada sugiere que, aunque sean menos frecuentes, los eventos de alta precipitación deben ser considerados en las estrategias de gestión de riesgos, como las inundaciones. Además, el análisis de la precipitación en esta estación es esencial para garantizar la sostenibilidad de estas actividades económicas, y debe ser evaluado en conjunto con la precipitación anual, que puede alcanzar entre 1500 y 2000 mm, para determinar su impacto real en la gestión de riesgos.

La capacidad de la curva de Gumbel para capturar tanto los eventos de precipitación más frecuentes como los más inusuales proporciona una representación precisa de la variabilidad de la precipitación mensual en estaciones como 27010840. Este ajuste es crucial para el cálculo del SPI, que implica transformar los datos de precipitación mensual ajustados de la distribución Gumbel a una distribución normal estándar con media 0 y desviación estándar 1. El proceso incluye primero calcular la probabilidad acumulada para cada valor de precipitación usando la distribución de Gumbel, y luego transformar esa probabilidad acumulada a valores de SPI utilizando la función de distribución acumulada inversa normal (Ellahi et al., 2020; Pieper et al., 2020). Los valores resultantes del SPI reflejan adecuadamente la variabilidad en las estaciones seleccionadas (McKee et al., 1993).

La Figura 6 ilustra la serie temporal del SPI a escala mensual, mostrando la variabilidad entre períodos húmedos y secos a lo largo de varios años. Se compararon los resultados del SPI con los datos históricos de la NOAA, destacando su capacidad para identificar eventos climáticos extremos en años críticos como el inicio de la década de los 90 y las Niñas Multi-anales del segundo decenio del 2000. A través de esta comparación, se observó que el porcentaje de acierto de las estaciones al capturar estos eventos fue del 44.44%.

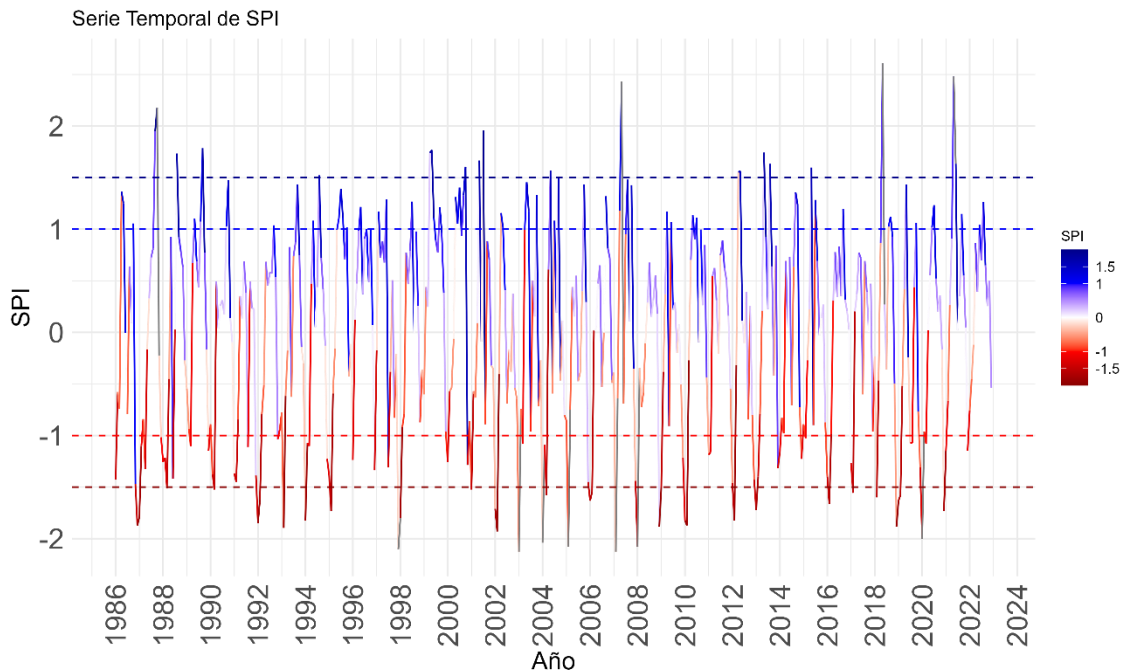


Figura 6. Serie temporal del SPI con la división de umbrales

No obstante, la variabilidad climática, las características específicas de cada estación y su ubicación geográfica influyeron en la precisión del SPI, subrayando la importancia de seleccionar cuidadosamente los parámetros y métodos de análisis para mejorar la identificación de estos eventos. Comprender estos patrones y adaptar el análisis a las condiciones locales puede ser clave para mejorar la exactitud en la identificación de eventos climáticos extremos, lo cual es crucial para optimizar la gestión de los recursos hídricos y la preparación ante períodos de sequía o humedad.

La figura 7, basada en un análisis multianual de datos mensuales, muestra un boxplot que revela la variabilidad de los eventos de sequía y humedad a lo largo del año. Aunque la gráfica está a escala anual, se pueden identificar tendencias claras en ciertos meses. Se destaca que entre diciembre y febrero prevalecen las sequías, mientras que mayo muestra una inclinación hacia eventos de humedad moderada. Estas tendencias podrían estar influenciadas por la migración estacional de la ZCIT, un fenómeno que desplaza una franja de nubosidad y precipitación de norte a sur y viceversa a lo largo del año, afectando los patrones de sequía y humedad en la región (Poveda, 2004). Durante los meses de diciembre a febrero, la ZCIT se desplaza hacia el sur, disminuyendo las precipitaciones en la región en cuestión. En contraste, en mayo y octubre, la ZCIT se sitúa más al norte, lo que incrementa la probabilidad de eventos húmedos.




Figura 7. Boxplot del SPI con la división de umbrales.

Asimismo, se observa que noviembre y enero presentan una mayor variabilidad, reflejando transiciones en las condiciones climáticas. En algunas regiones, este comportamiento podría asociarse con un ciclo anual de precipitación bimodal, en el que se observan dos picos de precipitación durante el año. Estos picos pueden estar influenciados, en parte, por la migración de la ZCIT, junto con otros factores climáticos. Comprender estos patrones es importante para analizar los eventos de sequía y humedad en estos meses específicos, lo que resulta de gran utilidad para planificadores urbanos, agricultores y otros sectores que dependen de una adecuada gestión de recursos hídricos.

La figura 8 ilustra la tasa de ocurrencia de eventos de sequía y humedad en seis estaciones pluviométricas, reflejando el conteo acumulativo de excedencias del SPI. En la estación 27010830, se observa una prevalencia clara de episodios de humedad en comparación con eventos de sequía. La línea azul, representando la humedad moderada, tiene una pendiente más pronunciada que la línea roja de la sequía moderada, sugiriendo un régimen predominantemente húmedo en esta localización. Este comportamiento podría estar influenciado por factores climáticos a gran escala que afectan el conteo de excedencias de eventos. Por ello, es fundamental considerar tanto los factores climáticos locales como la ubicación geográfica al interpretar estos resultados.

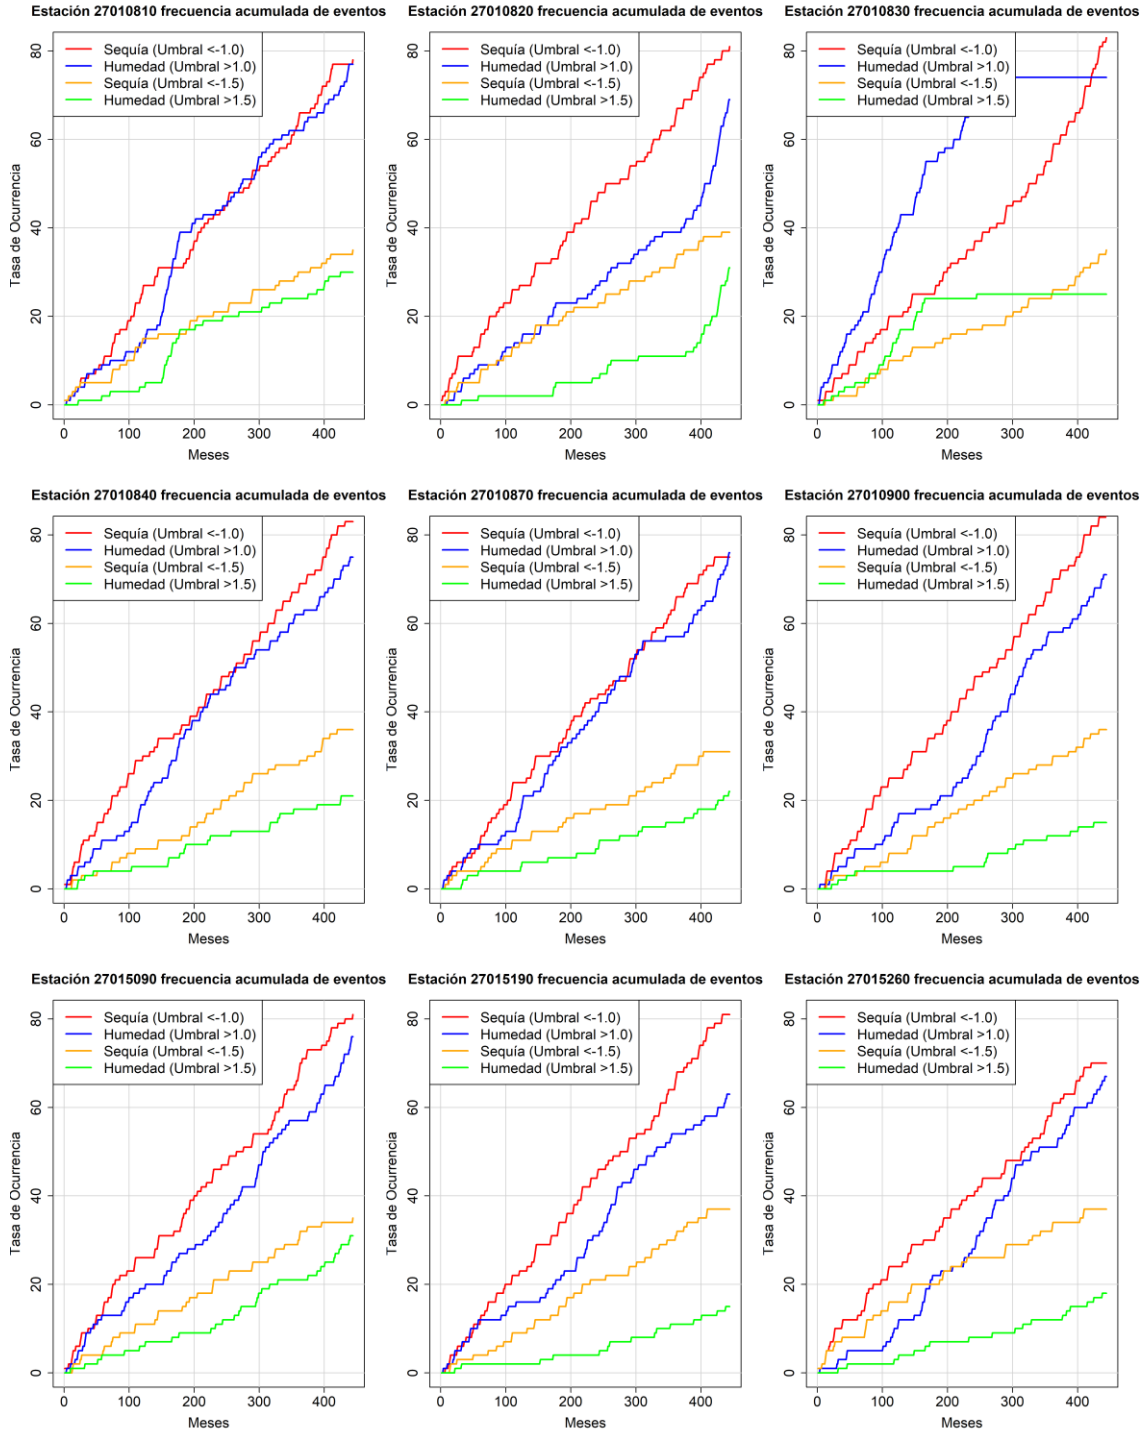


Figura 8. Conteo de eventos acumulativo de eventos de excedencia por umbrales del SPI.

En otras estaciones, como la 27010900, ubicada en el municipio de Gómez Plata, se muestra una distribución más equilibrada entre eventos de sequía y humedad, lo que refleja la diversidad de patrones climáticos de la región. En algunos casos, los conteos de excedencia se mantienen estables por más de 80 meses, lo que podría indicar una estabilidad climática específica o una persistencia en

las condiciones atmosféricas locales. Este análisis resalta la necesidad de adaptar modelos específicos para capturar estas variabilidades locales y mejorar las estimaciones de eventos extremos. Además, la considerable distancia entre estaciones, como los aproximadamente 35 km entre las estaciones 27010830 y 27010900, junto con las diferencias topográficas y climáticas, también contribuyen a las variaciones observadas en los patrones de humedad y sequía.

La tabla 3 ilustra el porcentaje de eventos que exceden los umbrales del SPI desde 1986 hasta 2022, a lo largo de 444 meses. Se establecen umbrales de 1 y -1 para condiciones moderadamente húmedas y secas, y de 1.5 y -1.5 para condiciones extremadamente húmedas y secas. En promedio, al menos el 32% de los eventos se clasifican como moderadamente húmedos o secos, mientras que cerca del 10% corresponden a eventos extremos. Estas cifras reflejan la regularidad e intensidad de los fenómenos climáticos observados.

Tabla 3. Análisis de Frecuencia de Eventos de Excedencia por Estación.

Estaciones	Porcentaje % de eventos Exc. de >1.0	Porcentaje % de eventos Exc. de <- 1.0	Porcentaje % de eventos Exc. de >1.5	Porcentaje % de eventos Exc. de <-1.5
27010810	17.34	17.57	6.76	7.88
27010820	15.54	18.24	6.98	8.78
27010830	16.67	18.69	5.63	7.88
27010840	16.89	18.69	4.73	8.11
27010870	17.12	16.89	4.95	6.98
27010900	15.99	19.14	3.38	8.11
27015090	17.12	18.24	6.98	7.88
27015190	14.19	18.24	3.38	8.33
27015260	15.09	15.77	4.05	8.33

En particular, la estación 27010840 muestra un 8.11% de eventos muy secos, uno de los valores más altos de eventos extremos registrados en la cuenca. Esto sugiere que, en ciertos periodos, la estación experimenta condiciones secas recurrentes que podrían estar relacionadas con la variabilidad de las precipitaciones a lo largo de los años. Estas diferencias, observadas entre estaciones ubicadas en

regiones con características climáticas contrastantes, enfatizan la importancia de considerar la ubicación geográfica y las condiciones climáticas locales al interpretar los datos y desarrollar estrategias efectivas de adaptación y mitigación. Por ejemplo, en la estación 27010840 podrían implementarse programas de riego y almacenamiento de agua para mitigar los efectos de la sequía, mientras que en la estación 27015090 las estrategias podrían enfocarse en la gestión de excesos de agua y la prevención de inundaciones.

Además de los porcentajes detallados en la tabla 3, es crucial examinar las tendencias que muestran las gráficas de excedencia, como se evidencia en la estación 27010870. Aunque esta estación presenta porcentajes comparables con otras respecto a eventos que superan los umbrales del SPI, la figura 7 revela diferencias notables en la frecuencia y la dinámica con la que se alcanzan estos umbrales. Esto es fundamental para el modelo de Poisson no homogéneo, permitiendo una modelación de la frecuencia y ritmo de los eventos climáticos en cada ubicación, lo que favorece la interpretación de los datos y la formulación de estrategias de adaptación y mitigación climática, alineadas adecuadamente con las características específicas de cada estación.

6.4 Evaluación de los modelos NHPP para estaciones meteorológicas

La presente sección analiza el rendimiento de los modelos NHPP aplicados a nueve estaciones meteorológicas, proporcionando una visión detallada de cómo la variabilidad climática influye en la hidrología regional. Para este análisis, se consideraron los parámetros α y β , junto con métricas estadísticas como el AIC, BIC, RMSE y MAE, con el objetivo de identificar el modelo más adecuado para cada estación. Estos indicadores resultan fundamentales para encontrar un equilibrio entre la precisión del modelo y su simplicidad, evitando problemas de sobreparametrización.

Es fundamental destacar que los parámetros α y β poseen interpretaciones específicas que varían según el tipo de modelo y la estación en cuestión, lo que limita la posibilidad de generalizar los resultados. Se revisaron todas las estaciones meteorológicas para evaluar cuál de los modelos Poisson era más adecuado para cada tipo de evento, utilizando las métricas AIC, BIC, RMSE y MAE. Aunque el análisis detallado se centra en la estación 27010870, ubicada en el municipio de Entreríos, debido a que presentó los mejores resultados en las métricas mencionadas, se han tomado en cuenta los resultados de todas las estaciones. Los resultados completos, que incluyen las métricas comparativas de todas las estaciones, se encuentran en el Anexo I.

6.4.1 Modelo con Poisson no homogéneo en eventos moderados

Durante períodos de sequía moderada (ver tabla 4), el modelo potencial en la estación 2700870 se destacó con un AIC de 1420.70, BIC de 1432.99, RMSE de 1.19 y MAE de 0.94, demostrando una alta precisión y un error mínimo en comparación con otros modelos (Ellahi et al., 2021). En este modelo, los parámetros α y β fueron de 0.24 y 1.95, respectivamente, indicando una tasa inicial baja de eventos y una variación significativa a lo largo del tiempo. Este patrón podría reflejar un incremento en la frecuencia de sequías moderadas, posiblemente debido a cambios climáticos. Desde un enfoque hidrológico, un valor bajo de α implica una escasez inicial de eventos de sequía, mientras que el valor elevado de β indica que la frecuencia de las sequías podría aumentar considerablemente con el tiempo. Esta información es vital para la planificación de estrategias de gestión del agua, permitiendo anticipar un aumento en la frecuencia de eventos de sequía y adoptar medidas preventivas adecuadas.

Tabla 4. Modelos de NHPP para el periodo de sequía moderada ($SPI < -1$) para la estación 27010870

Estación	Modelo	Alfa	Beta	AIC	BIC	RMSE	MAE
27010870	Potencial	0.24	1.95	1420.70	1432.99	1.19	0.94
27010870	Lineal	1.39	0.17	1486.56	1498.85	1.28	1.00
27010870	Exponencial	2.67	0.01	2790.25	2802.54	5.56	4.50

Por otro lado, el modelo exponencial mostró un rendimiento menos satisfactorio con un AIC de 2790.25, BIC de 2802.54, RMSE de 5.56 y un MAE de 4.50. Los valores de α y β , de 2.67 y 0.01 respectivamente, sugieren una alta frecuencia inicial de eventos que no varía significativamente con el tiempo, lo que contribuye a una variabilidad y precisión reducida en las predicciones. Esta caracterización indica que el modelo exponencial puede no ser el más adecuado para estimar las sequías en esta estación, debido a su incapacidad para modelar adecuadamente los cambios significativos en la tasa de ocurrencia de estos eventos.

Asimismo, en relación con eventos de sequía moderada, la estación 27010840, ubicada en la región de Santa Rosa de Osos, también mostró resultados consistentes con el modelo potencial, presentando un AIC de 1784.72 y un RMSE de 1.79 (ver anexo I). Estos resultados refuerzan la idea de que el modelo potencial, en algunas ocasiones y en diferentes contextos geográficos dentro de la región de estudio, capta mejor los patrones de precipitación. Por el contrario, en la estación 27010900, situada en el municipio de Gómez Plata, el modelo lineal demostró un mejor rendimiento para eventos de

sequía moderada, con un AIC de 1529.56 y un RMSE de 1.35, lo que subraya la necesidad de seleccionar modelos basados en las características específicas de cada estación.

En relación con los eventos de humedad moderada, el modelo lineal para la estación 27010870, a pesar de ser más simple, ofreció resultados prometedores con un AIC de 1486.56, RMSE de 1.28 y MAE de 1 (ver tabla 5). Los parámetros α y β fueron de 1.39 y 0.17, respectivamente, sugiriendo una tasa inicial positiva y un cambio lineal en la tasa de ocurrencia de eventos a lo largo del tiempo. Este modelo podría ser una opción viable para la estimación de eventos de sequía moderada debido a su simplicidad y precisión razonable (Ellahi et al., 2020). Este modelo es particularmente útil para estaciones donde la frecuencia de eventos de sequía sigue un patrón más predecible y constante.

Además, la estación 27010870 mostró que el modelo potencial es adecuado en ciertas ocasiones, con un AIC de 1973.78, BIC de 1986.06, RMSE de 2.22 y un MAE de 1.81, aunque en este caso, los mejores resultados fueron obtenidos con el modelo lineal (ver tabla 5). Estos resultados son comparables con los observados en la estación 27015260, ubicada en el municipio de Caldas (Antioquia), donde el modelo lineal destacó con un AIC de 2217.02 y un RMSE de 2.92 (ver anexo I). En contraste, el modelo exponencial, aunque mostró buenos resultados con un AIC de 2426.71 y un RMSE de 3.70 en la estación 27010900, no logró capturar de manera efectiva la complejidad de los eventos en algunas estaciones. Esto resalta la importancia de seleccionar el modelo adecuado para cada estación, considerando la ubicación geográfica y la climatología local.

Tabla 5. Modelos de NHPP para el periodo de humedad moderada ($SPI > 1$) para la estación 27010870

Estación	Modelo	Alfa	Beta	AIC	BIC	RMSE	MAE
27010870	Lineal	-0.73	0.17	1965.98	1978.27	2.20	1.82
27010870	Potencial	0.15	2.01	1973.78	1986.06	2.22	1.81
27010870	Exponencial	2.53	0.01	2867.02	2879.31	6.07	5.47

Las figuras 9 y 10 muestran la comparación entre los valores estimados por los modelos NHPP y los datos observados para la estación 2701870, complementados con los intervalos de confianza basados en los cuantiles de Poisson. Estos intervalos son cruciales para representar la variabilidad temporal y la incertidumbre en las estimaciones de los eventos climáticos. La utilización de los cuantiles de Poisson permite una captura más efectiva de la distribución de eventos extremos, proporcionando así una evaluación clara de la incertidumbre asociada con las estimaciones de los modelos. En la figura 9, el modelo potencial muestra el mejor ajuste para los datos de sequía moderada, mientras

que en la figura 10, tanto el modelo potencial como el lineal demuestran un buen desempeño para los datos de humedad moderada (Ellahi et al., 2020).

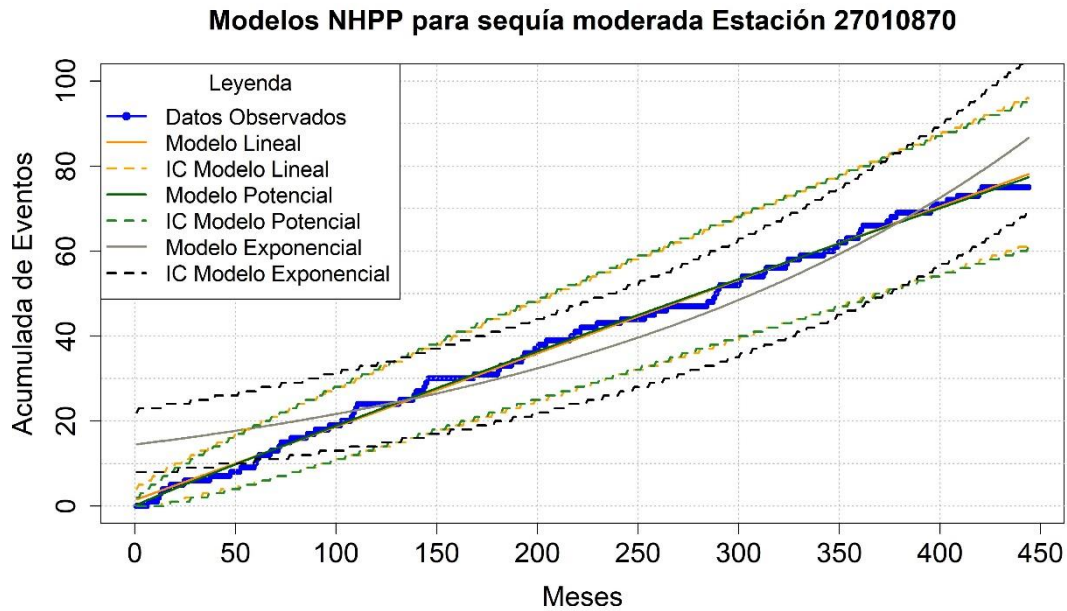


Figura 9. Ajuste de los modelos para eventos de sequía moderada (SPI < -1) en la estación 27010870.

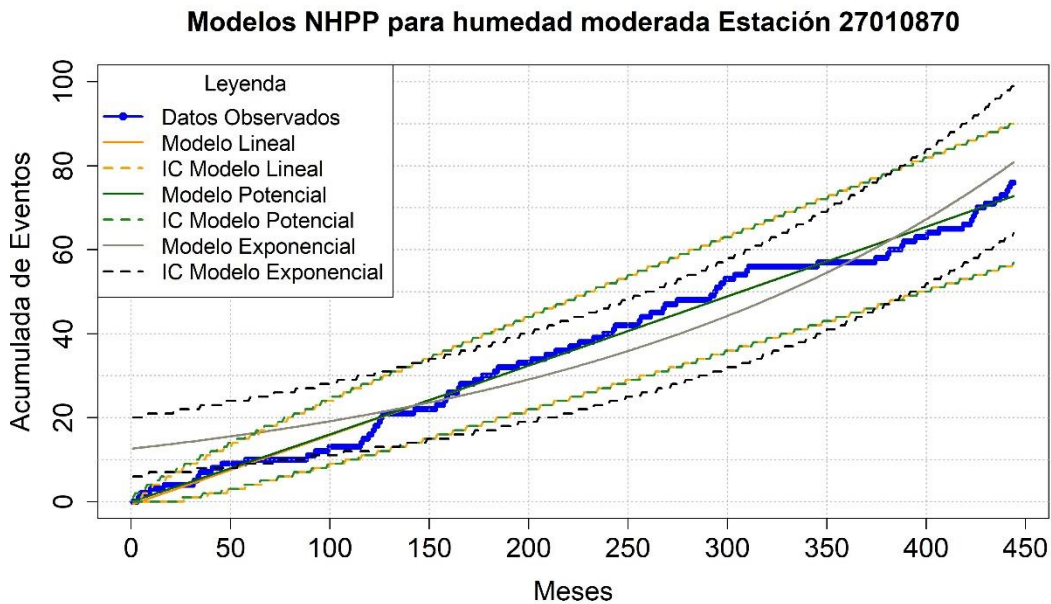


Figura 10. Ajuste de los modelos para eventos de humedad moderada (SPI > 1) en la estación 27010870.

6.4.2 Modelo con Poisson no homogéneo en eventos severos

En la tabla 6 se presentan los resultados detallados de los modelos para sequía extrema en la estación

27010870. El modelo lineal mostró un AIC de 1155.77, BIC de 1168.06, RMSE de 0.88 y MAE de 0.73, indicando una alta precisión en la estimación de eventos extremos comparado con otros modelos. Los parámetros α de 1.56 y β de 0.07 sugieren un régimen estable de sequías extremas, lo que refleja un ajuste constante a lo largo del tiempo, permitiendo capturar eficazmente la frecuencia y severidad de estos eventos.

Tabla 6. Modelos de NHPP para el periodo de sequía extrema ($SPI < -1.5$) para la estación 27010870.

Estación	Modelo	Alfa	Beta	AIC	BIC	RMSE	MAE
27010870	Lineal	1.56	0.07	1155.77	1168.06	0.88	0.73
27010870	Potencial	0.15	1.88	1161.89	1174.18	0.89	0.73
27010870	Exponencial	1.86	0.01	1935.46	1947.75	2.13	1.62

El modelo potencial, aunque con un rendimiento más moderado con un AIC de 1161.89, BIC de 1174.18, RMSE de 0.89 y MAE de 0.73. Los parámetros α de 0.15 y β de 1.88 indican una tasa inicial baja de eventos que aumenta significativamente, adecuado para representar un incremento lineal en la frecuencia y severidad de las sequías extremas. En cambio, el modelo exponencial tuvo un rendimiento inferior con un AIC de 1935.46, BIC de 1947.75, RMSE de 2.13 y MAE de 1.62, indicando un modelo menos adaptable. Los valores de α de 1.86 y β de 0.01 sugieren una alta frecuencia inicial sin variaciones significativas, lo que limita su capacidad para adaptarse a cambios en la intensidad de los eventos.

En otras estaciones, como la 27010840, el modelo potencial también demostró ser el más adecuado para eventos de sequía extrema, presentando un AIC de 1326.50 y un RMSE de 1.07 (ver anexo I). Esto sugiere que el modelo potencial es capaz de capturar de manera más precisa la variación en la frecuencia y severidad de estos eventos extremos. Por el contrario, en la estación 27010900, el modelo lineal mostró mejores resultados para eventos de sequía extrema, con un AIC de 1151 y un RMSE de 0.87, indicando que este modelo es más eficiente para representar eventos con una tendencia más uniforme a lo largo del tiempo. Esto subraya la importancia de seleccionar el modelo más adecuado en función de las características geográficas y climáticas de cada estación.

Para eventos de humedad extrema en la tabla 7, se observa una distinción clara en la capacidad de los modelos para capturar la dinámica de estos eventos. El modelo potencial muestra un ajuste más adecuado que con respecto a los demás modelos presentando un AIC de 1068.04, BIC de 1080.32, RMSE de 0.80 y MAE de 0.64. Los parámetros α de 0.02 y β de 2.11 muestra cómo la intensidad de

eventos puede aumentar progresivamente. El modelo lineal y el exponencial, aunque con rendimientos diversos, ilustran distintas capacidades para capturar la variabilidad en la intensidad y frecuencia de eventos.

Tabla 7. Modelos de NHPP para el periodo de humedad extrema ($SPI > 1.5$) para la estación 27010870.

Estación	Modelo	Alfa	Beta	AIC	BIC	RMSE	MAE
27010870	Potencial	0.02	2.11	1068.04	1080.32	0.80	0.64
27010870	Lineal	-0.41	0.04	1135.13	1147.42	0.86	0.67
27010870	Exponencial	1.07	0.01	1409.69	1421.98	1.18	0.85

Sin embargo, en la estación 27015260, el modelo lineal se destacó en la estimación de eventos de humedad extrema, con un AIC de 1203.62 y un RMSE de 0.93 (ver anexo I). Este modelo fue capaz de capturar con mayor precisión las variaciones en la frecuencia de eventos extremos. En contraste, el modelo exponencial, aunque mostró buenos resultados en algunas estaciones como la 27010830, no logró capturar la complejidad de los eventos de humedad extrema en otras ubicaciones. Esto sugiere el modelo exponencial podría no ser adecuada para representar la dinámica de eventos en estaciones con mayor variabilidad climática, destacando la necesidad de seleccionar modelos basados en las características específicas de cada estación.

Las figuras 11 y 12 ilustran el ajuste de los modelos NHPP lineal, potencial y exponencial para los eventos de sequía y humedad extrema en la estación 27010870, mostrando la comparación entre los valores estimados por cada modelo y los datos observados. En la figura 11, el modelo potencial muestra la mejor adaptación para capturar sequías extremas, siguiendo la tendencia general de los datos con mayor precisión y menor incertidumbre. Por otro lado, en la figura 12, los modelos lineal y potencial ofrecen resultados comparables y adecuados para representar eventos de humedad extrema, ajustándose bien a los datos observados.




Figura 11. Ajuste de los modelos para eventos de sequía extrema ($SPI < -1.5$) en la estación 27010870.




Figura 12. Ajuste de los modelos para eventos de humedad extrema ($SPI > 1.5$) en la estación 27010870.

6.5 Consideraciones importantes

Durante el análisis de los modelos NHPP bajo distintas condiciones de sequía y humedad en las diferentes estaciones evaluadas, se han destacado aspectos cruciales para su comprensión y aplicación en la hidrología. Los modelos potenciales y lineales han demostrado ser efectivos para ajustar datos y estimar eventos climáticos extremos en diversas estaciones (Ellahi et al., 2020). Sin

embargo, la función de intensidad exponencial ha revelado limitaciones, especialmente en la estimación de eventos extremos, como se refleja en las métricas de varias estaciones analizadas en el anexo I. Esto sugiere que el modelo exponencial podría no capturar adecuadamente la variabilidad extrema en todas las ubicaciones.

La elección del modelo más adecuado depende de la naturaleza específica de los eventos y las características geográficas de cada estación. En las estaciones donde se observaron eventos de sequía extrema, el modelo potencial ha mostrado ser el más efectivo, mientras que, para eventos de humedad extrema, tanto el modelo lineal como el potencial son viables, proporcionando una base sólida para la planificación y mitigación de riesgos climáticos. La incorporación de puntos de cambio en las funciones de intensidad también podría mejorar la capacidad del modelo para capturar cambios abruptos en la frecuencia de los eventos, aumentando así la precisión en condiciones variables de sequía y humedad (Ellahi et al., 2020).

Entender las interpretaciones de α , β y $\lambda(t)$ en cada contexto, según lo observado en las diferentes estaciones, no solo mejora la precisión de las estimaciones, sino que también optimiza el manejo de riesgos asociados con fenómenos hidrológicos extremos. Este enfoque adaptado a las condiciones climáticas específicas de cada estación permite mejorar la respuesta a tales eventos, ya sea en la implementación de programas de riego y almacenamiento de agua en zonas con alta frecuencia de sequías, o en el control de excesos de agua y la prevención de inundaciones en áreas propensas a eventos de humedad extrema. La interpretación de estos resultados, aplicados a las diversas estaciones evaluadas, es directamente relevante para la administración de recursos hídricos en la cuenca del río Porce, permitiendo un enfoque más preciso y localizado para la mitigación de riesgos climáticos.

7. Conclusiones y trabajos futuros

El presente estudio ha desarrollado un modelo basado en el SPI y NHPP en la cuenca del río Porce, utilizando diversas funciones de intensidad como la lineal, potencial y exponencial. Estos modelos han permitido evaluar la frecuencia de ocurrencia y la dinámica temporal de los eventos de sequía y humedad. Los modelos potencial y lineal demostraron ser particularmente efectivos para identificar eventos climáticos extremos, permitiendo determinar periodos críticos y proponer medidas preventivas adecuadas. Estos hallazgos son fundamentales para optimizar el manejo del agua ante

eventos extremos, proporcionando una base sólida para la elaboración de estrategias y mitigación de riesgos climáticos.

Los parámetros α y β de los modelos NHPP han jugado un papel crucial en este estudio, ayudando a entender la dinámica de los eventos climáticos a través de diferentes modelos y configuraciones. Estos parámetros son esenciales para interpretar la frecuencia inicial de los eventos y cómo esta tasa evoluciona con el tiempo. Dependiendo del modelo utilizado, α y β ofrecen perspectivas variadas: en algunos casos proporcionan una estimación constante de la tasa de ocurrencia de eventos, mientras que en otros revelan variaciones significativas en la frecuencia de los eventos. Este estudio ha demostrado que, aunque la tasa de eventos puede comenzar de manera diferente en cada modelo, todos tienden a ofrecer consideraciones importantes sobre cómo pueden desarrollarse estos eventos en el tiempo bajo condiciones climáticas cambiantes.

Para futuros trabajos, se recomienda explorar la integración de puntos de cambio en las funciones de intensidad y considerar factores meteorológicos locales para mejorar la precisión de los modelos NHPP. Además, La exploración de otros modelos de Poisson, como la intensidad de Weibull, podría proporcionar una comprensión más profunda de la variabilidad climática y su impacto en la hidrología regional. Estas investigaciones futuras contribuirán a una mejor comprensión y manejo de los periodos de sequía y humedad, fundamentales para la planificación y gestión de los recursos hídricos en la cuenca del río Porce.

8. Referencias

- Achcar, J. A., Coelho-Barros, E. A., & de Souza, R. M. (2016). Use of non-homogeneous Poisson process (NHPP) in presence of change-points to analyze drought periods: a case study in Brazil. *Environmental and Ecological Statistics*, 23, 405-419. <https://doi.org/10.1007/s10651-016-0345-z>
- Alhamsry, A., Fenta, A. A., Yasuda, H., Shimizu, K., & Kawai, T. (2019). Prediction of summer rainfall over the source region of the Blue Nile by using teleconnections based on sea surface temperatures. *Theoretical and applied climatology*, 137, 3077-3087. <https://doi.org/10.1007/s00704-019-02796-x>
- Angarita, H., Wickel, A. J., Sieber, J., Chavarro, J., Maldonado-Ocampo, J. A., Herrera-R., G. A., Delgado, J., and Purkey, D. (2018). Basin-scale impacts of hydropower development on the Mompós Depression wetlands, Colombia. *Hydrology and Earth System Sciences*, 22(5), 2839-2865. <https://doi.org/10.5194/hess-22-2839-2018>
- Antal, A., Guerreiro, P.M.P., & Cheval, S. (2021). Comparison of spatial interpolation methods for estimating the precipitation distribution in Portugal. *Theoretical and Applied Climatology*, 145, 1193–1206. <https://doi.org/10.1007/s00704-021-03675-0>

- Bivand, R.S., Pebesma, E., Gómez-Rubio, V. (2013). Hello world: introducing spatial data. *Applied spatial data analysis with R*, 1-16. https://doi.org/10.1007/978-1-4614-7618-4_1
- Canchala, T., Alfonso-Morales, W., Carvajal-Escobar, Y., Cerón, W. L., & Caicedo-Bravo, E. (2020). Monthly rainfall anomalies forecasting for southwestern Colombia using artificial neural networks approaches. *Water*, 12(9), 2628. <https://doi.org/10.3390/w12092628>
- Cox, D. R., & Lewis, P. A. (1966). The Statistical Analysis of Series of Events. Methuen's Monographs on Applied Probability and Statistics. Springer Netherlands. [link]
- Diggle, P. J. (2013). Statistical analysis of spatial and spatio-temporal point patterns. CRC press. Academic press. (libro) [link]
- Egigu, M. (2020). Techniques of filling missing values of daily and monthly rain fall data: a review. *SF J. Environmental Earth Sciences*, 3(1).
- Ellahi, A., Hussain, I., Hashmi, M. Z., Almazah, M. M. A., & Al-Duais, F. S. (2021). Agricultural drought periods analysis by using nonhomogeneous Poisson models and regionalization of appropriate model parameters. *Tellus A: Dynamic Meteorology and Oceanography*, 73(1), 1-16. <https://doi.org/10.1080/16000870.2021.1948241>
- Ellahi, A., Almanjahie, I. M., Hussain, T., Hashmi, M. Z., Faisal, S., & Hussain, I. (2020). Analysis of agricultural and hydrological drought periods by using non-homogeneous Poisson models: linear intensity function. *Journal of Atmospheric and Solar-Terrestrial Physics*, 198, 105190. <https://doi.org/10.1016/j.jastp.2020.105190>
- Enciso, A. M., Carvajal-Escobar, Y., & Sandoval, M. C. (2016). Hydrological analysis of historical floods in the upper valley of Cauca river: Análisis hidrológico de las crecientes históricas del río Cauca en su valle alto. *Ingeniería y competitividad*, 18(1), 47-58. <https://doi.org/10.25100/iyc.v18i1.2176>
- Guler Dincer, N., Demir, S., & Yalçın, M. O.. (2022). Forecasting COVID19 Reliability of the Countries by Using Non-Homogeneous Poisson Process Models. *New Generation Computing*. <https://doi.org/10.1007/s00354-022-00183-1>
- Guttman, N. B. (1999). Accepting the standardized precipitation index: a calculation algorithm 1. *JAWRA Journal of the American Water Resources Association*, 35(2), 311-322. <https://doi.org/10.1111/j.1752-1688.1999.tb03592.x>
- Hurtado Montoya, A. F., & Mesa Sánchez, Ó. J. (2015). Cambio climático y variabilidad espacio-temporal de la precipitación en Colombia. *Revista EIA*, (24), 131-150.
- Justel, A., Peña, D., & Zamar, R. (1997). A multivariate Kolmogorov-Smirnov test of goodness of fit. *Statistics & probability letters*, 35(3), 251-259. [https://doi.org/10.1016/S0167-7152\(97\)00020-5](https://doi.org/10.1016/S0167-7152(97)00020-5)
- Karavitis, C. A., Alexandris, S., Tsesmelis, D. E., & Athanasopoulos, G. (2011). Application of the standardized precipitation index (SPI) in Greece. *Water*, 3(3), 787-805. <https://doi.org/10.3390/w3030787>
- Kundzewicz, Z. W., Kanae, S., Seneviratne, S. I., Handmer, J., Nicholls, N., Peduzzi, P., Mechler, R., Bouwer, L. M., Arnell, N., Mach, K., Muir-Wood, R., Brakenridge, G. R., Kron, W., Benito, G., Honda, Y., Takahashi, K., & Sherstyukov, B. (2013). Flood risk and climate change: global and regional perspectives. *Hydrological Sciences Journal*, 59(1), 1-28. <https://doi.org/10.1080/02626667.2013.857411>
- Liu, X., & Xie, N. (2022). Grey-based approach for estimating software reliability under nonhomogeneous Poisson process. *Journal of Systems Engineering and Electronics*, 33(2), 360-369. <https://doi.org/10.23919/JSEE.2022.000038>

- Loaiza Cerón, W., Carvajal-Escobar, Y., Andreoli de Souza, R. V., Toshie Kayano, M., & González López, N. (2020). 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>
- Massey, F. J. (1951). The Kolmogorov-Smirnov Test for Goodness of Fit. *Journal of the American Statistical Association*, 46(253), 68-78. <https://doi.org/10.1080/01621459.1951.10500769>
- McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference on Applied Climatology* 17(22) 179-183.
- Ng, T. L. J., & Zammit-Mangion, A. (2023). Non-homogeneous Poisson process intensity modeling and estimation using measure transport. *Bernoulli*, 29(1), 815-838. <https://doi.org/10.3150/22-BEJ1480>
- Pieper, P., Düsterhus, A., & Baehr, J. (2020). A universal Standardized Precipitation Index candidate distribution function for observations and simulations. *Hydrology and Earth System Sciences*, 24(9), 4541-4565. <https://doi.org/10.5194/hess-24-4541-2020>
- Poveda, G. (2004). La hidroclimatología de Colombia: una síntesis desde la escala inter-decadal hasta la escala diaria. *Revista de la Academia Colombiana de Ciencias Exactas, Físicas y Naturales*, 28(107), 201-222.
- Poveda, G., Alvarez, D. M., & Rueda, O. A. (2011). Hydro-climatic variability over the Andes of Colombia associated with ENSO: a review of climatic processes and their impact on one of the Earth's most important biodiversity hotspots. *Climate Dynamics*, 36, 2233-2249. <https://doi.org/10.1007/s00382-010-0931-y>
- Poveda, G., & Álvarez, D. M. (2012). The collapse of the stationarity hypothesis due to climate change and climate variability: Implications for hydrologic engineering design. *Revista de Ingeniería*, (36), 65-76.
- Roshan, J. & Lulu, K (2011). Regression-Based Inverse Distance Weighting With Applications to Computer Experiments. *Technometrics*, 53(3), 254–265 <https://doi.org/10.1198/TECH.2011.09154>
- Ross, S. M. (2014). Introduction to probability models. Academic press. (libro) [link]
- Sánchez Quiroga, L. (2020). Estimación e imputación de datos faltantes mediante métodos de interpolación espacial para precipitación mensual acumulada en el departamento de Antioquia durante el periodo 2014-2018. Ph. D. Thesis, Universidad Santo Tomás, Colombia. (tesis).
- Stagge, J. H., Tallaksen, L. M., Gudmundsson, L., Van Loon, A. F., & Stahl, K. (2015). Candidate distributions for climatological drought indices (SPI and SPEI). *International Journal of Climatology*, 35(13), 4027-4040. <https://doi.org/10.1002/joc.4267>
- Tsakiris, G., & Vangelis, H. (2004). Towards a drought watch system based on spatial SPI. *Water resources management*, 18, 1-12. <https://doi.org/10.1023/B:WARM.0000015410.47014.a4>
- Vargas, A., Santos, A. N. A., Cárdenas, E., & Obregón, N. (2011). Análisis de la distribución e interpolación espacial de las lluvias en Bogotá, Colombia. *Dyna*, 78(167), 151-159.
- Wang, Q., Zhang, R., Qi, J., Zeng, J., Wu, J., Shui, W., Wu, X. & Li, J. (2022). An improved daily standardized precipitation index dataset for mainland China from 1961 to 2018. *Scientific Data*, 9(1), 124. (2022). <https://doi.org/10.1038/s41597-022-01201-z>
- Wilhite, D., & Pulwarty, R. S. (2017). *Drought and water crises: integrating science, management, and policy*. CRC Press. <https://doi.org/10.1201/b22009>

Wirth, R., & Hipp, J. (2000, April). CRISP-DM: Towards a standard process model for data mining. In *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining* (Vol. 1, pp. 29-39).

Zhiña, D., Pacheco, J., & Avilés, A. (2017). Modelos estocásticos para el pronóstico de sequías en la microcuenca del río Chulco en Ecuador. *Revista de la Facultad de Ciencias Químicas*, 16, 44-61.

9. Anexo I: Resultados de las métricas del modelo

Modelos de NHPP para el periodo de sequía moderada (SPI < -1).

Estación	Modelo	Alfa	Beta	AIC	BIC	RMSE	MAE
27010870	Potencial	0.24	1.95	1420.7	1432.99	1.19	0.94
27015190	Lineal	0.45	0.18	1473.04	1485.33	1.26	1.01
27015190	Potencial	0.19	1.99	1484.64	1496.93	1.28	1.02
27010870	Lineal	1.39	0.17	1486.56	1498.85	1.28	1
27010900	Lineal	1.52	0.18	1529.56	1541.85	1.35	1.08
27010900	Potencial	0.24	1.96	1550.59	1562.88	1.38	1.1
27010820	Lineal	4.61	0.17	1554.54	1566.83	1.38	1.15
27015260	Lineal	4.5	0.15	1636.65	1648.94	1.52	1.23
27010810	Potencial	0.24	1.95	1661.52	1673.81	1.56	1.26
27010820	Potencial	0.4	1.87	1669.44	1681.73	1.58	1.32
27010810	Lineal	1.23	0.18	1696.15	1708.44	1.62	1.33
27015260	Potencial	0.39	1.85	1719.55	1731.84	1.67	1.37
27015090	Lineal	3.54	0.18	1751.24	1763.53	1.73	1.38
27010840	Lineal	5.17	0.18	1784.72	1797.01	1.79	1.39
27015090	Potencial	0.33	1.9	1813.37	1825.66	1.85	1.49
27010840	Potencial	0.45	1.85	1828.11	1840.4	1.88	1.62
27010830	Potencial	0.08	2.12	2168.25	2180.54	2.76	2.21
27010830	Lineal	-1.22	0.16	2268.97	2281.25	3.09	2.39
27010830	Exponencial	2.38	0.01	2340.86	2353.15	3.35	2.46
27015260	Exponencial	2.69	0.01	2557.82	2570.11	4.28	3.21
27010820	Exponencial	2.8	0.01	2664.63	2676.91	4.83	3.67
27010840	Exponencial	2.84	0.01	2698.48	2710.76	5.02	3.87
27015090	Exponencial	2.77	0.01	2708.62	2720.91	5.08	3.81
27015190	Exponencial	2.65	0.01	2730.96	2743.25	5.21	4.1
27010900	Exponencial	2.73	0.01	2760.77	2773.06	5.38	4.2
27010870	Exponencial	2.67	0.01	2790.25	2802.54	5.56	4.5
27010810	Exponencial	2.67	0.01	2801.54	2813.82	5.64	4.53

Modelos de NHPP para el periodo de humedad moderada (SPI > 1).

Estación	Modelo	Alfa	Beta	AIC	BIC	RMSE	MAE
27015090	Potencial	0.1	2.07	1948.15	1960.44	2.16	1.8
27010870	Lineal	-0.73	0.17	1965.98	1978.27	2.2	1.82
27010870	Potencial	0.15	2.01	1973.78	1986.06	2.22	1.81
27010840	Potencial	0.21	1.96	1982.33	1994.62	2.24	1.85
27010840	Lineal	0.29	0.17	2008.62	2020.9	2.31	1.91
27015090	Lineal	-0.39	0.16	2021.43	2033.71	2.34	1.97
27015190	Potencial	0.08	2.09	2121.97	2134.26	2.62	2.3
27015190	Lineal	-1.14	0.15	2175.55	2187.84	2.79	2.37
27015260	Lineal	-7.02	0.16	2217.02	2229.31	2.92	2.41
27010820	Potencial	0.07	2.1	2248.27	2260.56	3.02	2
27010820	Lineal	-0.78	0.12	2283.31	2295.6	3.14	1.97
27010820	Exponencial	2.09	0.01	2335.75	2348.04	3.34	2.75
27010810	Lineal	-1.46	0.18	2420.44	2432.73	3.67	3.07
27010900	Lineal	-5.23	0.16	2426.71	2439	3.7	3.12
27010810	Potencial	0.16	2.01	2436.75	2449.04	3.74	3.06
27015090	Exponencial	2.43	0.01	2451.35	2463.64	3.8	2.93
27010900	Exponencial	2.13	0.01	2576.44	2588.72	4.37	3.63
27015190	Exponencial	2.33	0.01	2649.68	2661.96	4.75	3.99
27015260	Exponencial	2.03	0.01	2737.17	2749.46	5.24	4.53
27010870	Exponencial	2.53	0.01	2867.02	2879.31	6.07	5.47
27010830	Potencial	2.3	1.59	2873.32	2885.61	6.11	5.4
27010840	Exponencial	2.64	0.01	2953.22	2965.5	6.69	5.96
27010810	Exponencial	2.61	0.01	3093.55	3105.84	7.83	7.3
27010830	Lineal	15.45	0.17	3183.21	3195.49	8.66	7.74
27010830	Exponencial	3.33	0.01	3472.58	3484.87	12	10.38
27015260	Potencial	-0.62	-17.39	4443.39	4455.67	35.81	29.03
27010900	Potencial	0.01	-7.13	4493.85	4506.14	37.9	31.3

Modelos de NHPP para el periodo de sequía extrema ($SPI < -1.5$).

Estación	Modelo	Alfa	Beta	AIC	BIC	RMSE	MAE
27015090	Potencial	0.12	1.94	1100.59	1112.87	0.83	0.68
27010820	Potencial	0.23	1.84	1113.38	1125.66	0.84	0.67
27015190	Potencial	0.05	2.11	1125.37	1137.66	0.85	0.7
27015090	Lineal	0.77	0.08	1138.34	1150.62	0.87	0.7
27010900	Lineal	-1.17	0.08	1138.83	1151.12	0.87	0.68
27010900	Potencial	0.05	2.08	1147.03	1159.32	0.87	0.72

27010870	Lineal	1.56	0.07	1155.77	1168.06	0.88	0.73
27010870	Potencial	0.15	1.88	1161.89	1174.18	0.89	0.73
27015190	Lineal	-1.31	0.09	1202.96	1215.24	0.93	0.78
27015260	Potencial	0.64	1.67	1203.62	1215.91	0.93	0.74
27010810	Potencial	0.26	1.8	1226.78	1239.06	0.96	0.75
27010820	Lineal	2.36	0.09	1312.92	1325.2	1.05	0.81
27010840	Potencial	0.04	2.12	1326.5	1338.78	1.07	0.89
27010830	Potencial	0.07	2	1394.63	1406.92	1.16	0.96
27010830	Lineal	-0.03	0.07	1394.66	1406.95	1.16	0.96
27010810	Lineal	2.78	0.07	1410.13	1422.42	1.18	0.92
27010840	Lineal	-1.26	0.08	1425.1	1437.39	1.2	0.99
27015260	Lineal	5.55	0.08	1694.84	1707.13	1.62	1.3
27010870	Exponencial	1.86	0.01	1935.46	1947.75	2.13	1.62
27010830	Exponencial	1.69	0.01	2007.48	2019.77	2.3	1.84
27010840	Exponencial	1.72	0.01	2126.88	2139.16	2.64	2.17
27010810	Exponencial	2.08	0.01	2166.53	2178.82	2.76	2.31
27015190	Exponencial	1.78	0.01	2167.67	2179.96	2.76	2.31
27015090	Exponencial	1.94	0.01	2168.59	2180.87	2.76	2.21
27010900	Exponencial	1.75	0.01	2205.02	2217.3	2.88	2.58
27010820	Exponencial	2.14	0.01	2225.45	2237.74	2.95	2.36
27015260	Exponencial	2.35	0.01	2280.08	2292.37	3.13	2.49

Modelos de NHPP para el periodo de humedad extrema (SPI > 1.5).

Estación	Modelo	Alfa	Beta	AIC	BIC	RMSE	MAE
27015190	Exponencial	0.27	0.01	929.76	942.05	0.68	0.56
27015260	Lineal	-1.03	0.04	1048.70	1060.99	0.78	0.64
27010870	Potencial	0.02	2.11	1068.04	1080.32	0.80	0.64
27010870	Lineal	-0.41	0.04	1135.13	1147.42	0.86	0.67
27010840	Potencial	0.04	2.03	1164.07	1176.35	0.89	0.72
27010840	Lineal	-0.04	0.05	1172.20	1184.49	0.90	0.73
27010900	Exponencial	0.69	0.01	1231.52	1243.81	0.96	0.81
27015260	Exponencial	0.74	0.01	1346.00	1358.29	1.09	0.91
27015190	Lineal	-1.23	0.03	1376.27	1388.56	1.13	0.97
27010900	Potencial	0.01	2.22	1404.01	1416.30	1.17	0.91
27010870	Exponencial	1.07	0.01	1409.69	1421.98	1.18	0.85
27010900	Lineal	-0.18	0.03	1473.50	1485.78	1.26	1.04
27015090	Exponencial	1.18	0.01	1612.36	1624.65	1.48	1.13

27010840	Exponencial	1.28	0.01	1668.25	1680.54	1.57	1.34
27015090	Lineal	-1.88	0.06	1691.53	1703.82	1.61	1.33
27010820	Exponencial	0.01	0.01	1777.47	1789.76	1.78	1.30
27010810	Lineal	-1.70	0.08	2026.86	2039.15	2.36	1.92
27010810	Potencial	0.05	2.06	2070.52	2082.81	2.47	2.04
27010820	Lineal	-2.99	0.05	2161.26	2173.55	2.74	1.93
27010830	Potencial	0.98	1.56	2401.39	2413.68	3.59	3.16
27010810	Exponencial	1.63	0.01	2501.85	2514.14	4.02	3.69
27010830	Lineal	5.85	0.06	2601.91	2614.20	4.50	4.02
27010830	Exponencial	2.33	0.01	2778.95	2791.24	5.49	4.80
27015190	Potencial	-0.45	-14.76	3014.22	3026.50	7.16	5.80
27015260	Potencial	0.01	-229.57	3215.31	3227.60	8.98	7.48
27010820	Potencial	0.01	-15.40	3296.38	3308.67	9.84	7.34
27015090	Potencial	0.01	-7.57	3668.20	3680.49	14.96	12.39