



UNIVERSIDAD TECNICA
FEDERICO SANTA MARIA

Departamento de Obras Civiles

“RELACIÓN DE LA PRECIPITACIÓN, TEMPERATURA Y CAUDALES DE CRECIDA, Y SU USO PARA LA ESTIMACIÓN DE CRECIDAS DE DISEÑO: APLICACIÓN EN CUENCA DEL RÍO MAULE EN ARMERILLO”

Memoria de Título presentada por

JUAN PABLO RODRÍGUEZ BAHAMONDES

Como requisito parcial para optar al título de la carrera de

Ingeniería Civil

de la Universidad Técnica Federico Santa María

Profesor Guía

Álvaro Humberto Ossandón Álvarez

Profesor Correferente

Lina Mabel Castro Heredia

Abril de 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: Relación de la Precipitación, Temperatura y Caudales de crecida y su uso para la estimación de crecidas de diseño: Aplicación en Cuenca del Río Maule en Armerillo

Nombre del candidato(a): Juan Pablo Rodríguez Bahamondes

Carrera / Grado: Ingeniería Civil

Campus: San Joaquín

Departamento: Obras Civiles

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Álvaro Ossandón, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 13-10-2025

Firma:

Estudiante o Candidato(a):

Fecha: 13-10-2025

Firma:

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

“Relación de la Precipitación, Temperatura y Caudales de crecida y su uso para la estimación de crecidas de diseño: Aplicación en Cuenca del Río Maule en Armerillo”

Juan Pablo Rodríguez¹, Álvaro Ossandón¹

¹ Departamento de Obras Civiles, Universidad Técnica Federico Santa María, Santiago/Valparaíso, Chile.

Resumen

Las inundaciones son catástrofes cada vez más frecuentes y devastadoras que están siendo identificadas por el cambio climático. Este fenómeno está asociado a modificaciones en los patrones climáticos globales actuales, debido a un aumento de gases de efecto invernadero en la atmósfera, lo que impacta gravemente los ecosistemas, la biodiversidad y la vida humana. Este estudio se centra en los análisis de los eventos de crecida y su relación con los datos meteorológicos (temperatura y precipitación) para la cuenca del Río Maule en Armerillo, que se ubica en la región del Maule, en la zona Centro-Sur del país. Para identificar los peaks relevantes en estos eventos de crecida, se emplea la Curva de Duración General (CDG), utilizada para definir un umbral específico en las series de excedencia. Posteriormente, se analizan las correlaciones entre las variables hidro-meteorológicas obtenidas para los eventos máximos de crecida. Se verifica la independencia de los peaks de crecida mediante el método de separación temporal, definiendo un intervalo mínimo de 3 días entre crecidas sucesivas, debido a la geografía de la cuenca estudiada. Se realiza un análisis estacional enfocado en los meses de invierno, debido a que generalmente se presentan eventos de carácter pluvial, en los cuales para los meses de Junio y Julio presentan las correlaciones más altas. Para el análisis, se verifica una combinación de variables, donde se destacan las variables con mejor correlación con el caudal instantáneo, estas son la temperatura índice del día del evento y la precipitación acumulada hasta los tres días previos al evento. En base los resultados obtenidos, se construye un modelo de regresión lineal multivariado utilizando las combinaciones de variables predictoras de mejor correlación. Este modelo presenta un ajuste alentador, obteniendo una predicción precisa para los caudales de baja magnitud. Sin embargo, presenta limitaciones en la captura de los eventos de crecida más extremos. Para abordar esta deficiencia, se incursiona en los modelos GAMLSS, logrando una mejora significativa, especialmente en el enfoque Gamma, que presenta los mejores resultados. No obstante, esta mejora sigue siendo insuficiente para representar con precisión los eventos más extremos. La incapacidad del modelo para reproducir correctamente algunos eventos de crecida puede deberse al fenómeno de Rain-on-Snow (ROS), que ocurre cuando la lluvia cae sobre nieve acumulada, afectando el volumen de agua en la cuenca (Bean & Watts, 2024). Se sugiere mejorar el modelo para incluir el fenómeno ROS, lo que permitiría una estimación más precisa de las crecidas y contribuiría a una mejor gestión del riesgo de crecidas mediante medidas de mitigación.

Palabras clave: Inundaciones, cambio climático, GAMLSS, Peak Over Threshold (POT), Rain-on-Snow (ROS), análisis estacional, caudal, temperatura, precipitación, cuenca río Maule, modelación hidrológica.

Abstract

Floods are increasingly frequent and devastating disasters, strongly linked to climate change. This phenomenon is associated with alterations in current global climate patterns due to the increase in greenhouse gases in the atmosphere, significantly impacting ecosystems, biodiversity, and human life. This study focuses on analyzing flood events and their relationship with meteorological data (temperature and precipitation) for the Maule River basin in Armerillo, located in the Maule region in the south-central part of the country. To identify the most relevant peaks in these flood events, the General Duration Curve (GDC) is used to define a specific threshold within the exceedance series. Subsequently, correlations between the hydro-meteorological variables obtained for the maximum flood events are analyzed. The independence of flood peaks is verified using the temporal separation method, establishing a minimum interval of three days between successive floods, considering the geography of the studied basin. A seasonal analysis is conducted, focusing on the winter months, as pluvial events are generally more frequent during this period, with June and July showing the highest correlations. For the analysis, different variable combinations are examined, highlighting those with the strongest correlation with instantaneous flow. The most significant variables are the index temperature on the event day and the cumulative precipitation up to three days before the event. Based on the obtained results, a multivariate linear regression model is developed using the best-correlated predictive variable combinations. This model demonstrates promising performance, providing an accurate prediction for low-magnitude flows. However, it has limitations in capturing the most extreme flood events. To address this deficiency, Generalized Additive Models for Location, Scale, and Shape (GAMLSS) are explored, leading to a significant improvement, particularly with the Gamma approach, which yields the best results. Nevertheless, this enhancement remains insufficient for accurately representing the most extreme events. The model's inability to correctly reproduce certain flood events may be attributed to the Rain-on-Snow (ROS) phenomenon, which occurs when rainfall falls on accumulated snow, affecting the water volume in the basin (Bean & Watts, 2024). It is suggested that the model be improved to incorporate the ROS phenomenon, which would enable a more precise estimation of floods and contribute to better flood risk management through mitigation measures.

Keywords: Floods, climate change, GAMLSS, General Duration Curve (GDC), Rain-on-Snow (ROS), seasonal analysis, flow, temperature, precipitation, Maule River basin, hydrological modeling.

1. Introducción

El cambio climático es uno de los desafíos más urgentes y complejos que enfrenta la humanidad en la actualidad, lo que ha afectado con cambios significativos en eventos climáticos a nivel global, estos cambios tienen impactos profundos en los ecosistemas, la biodiversidad, la economía y la vida de las personas en todo el mundo (Jovel, 1989). Este fenómeno es impulsado en gran medida por actividades humanas, como la quema de combustibles fósiles, la deforestación, la agricultura intensiva y la industrialización. Por lo tanto, es de suma importancia transformar estas actividades para que sean un aporte y que como sociedad reduzca y alivie el efecto que está produciendo en el ecosistema, y es que, de un tiempo a esta fecha, la cantidad de desastres naturales a lo largo del mundo ha aumentado considerablemente, y gran parte de esto es consecuencia del cambio climático (Kossin et al., 2020).

En nuestro país esta situación no ha sido diferente, en los últimos años la zona central de Chile ha experimentado una serie de desastres relacionados con inundaciones provocadas por el desbordamiento de cuerpos de agua. Uno de los territorios más afectados por estos eventos ha sido la región del Maule, que ha sufrido considerables pérdidas, tanto materiales como humanas (Soto, 2022). Estos fenómenos extremos han tenido consecuencias devastadoras para las comunidades locales y han provocado la preocupación en la sociedad e interés en el ámbito de la hidrología. La necesidad de comprender y abordar estos fenómenos se ha vuelto vital, destacando la importancia de investigaciones y medidas preventivas para mitigar los impactos de futuras inundaciones en la zona.

Uno de los factores clave que influyen en la ocurrencia de crecidas es la variabilidad de línea de nieve, que se define como la altitud que divide la precipitación líquida de la sólida (nieve), particularmente en episodios de tormenta. Variados estudios han explorado la relación entre la línea de nieve, y las crecidas para varias estaciones y cuencas de Chile (Covián & Stowhas, 2012; Peña & Vidal, 1993; y Zúñiga & Jara, 2017). Estos estudios han abordado la modelación probabilística de la línea de nieve, en los que se propone que la isoterma 0 está fuertemente ligada a las variables de temperatura mínima y precipitación, destacando la importancia de la variable de temperatura, la que determina el comportamiento de la línea de nieve durante eventos climáticos extremos. Esto puede traer como consecuencia el aumento sustancial en los caudales de los ríos y, por ende, las inundaciones de gran magnitud que se presentaron este último tiempo.

Adicionalmente, el estudio de Seguel & Stowhas (1985) profundiza en las cuencas pluvio-nivales, realizando una estimación de crecidas de diseño. En este estudio se destaca a la temperatura del aire como un buen índice para determinar la temperatura real de la zona de estudio. Por lo tanto, la incorporación de esta variable en el análisis es de gran importancia para estimar la situación pluviométrica en dicha elevación. Esto permite determinar la situación de la zona, considerando el aumento de temperatura y la acumulación de nieve en el área pluvial aportante, definida como el área bajo la línea de nieve que aporta directamente al caudal de las crecidas, aumentando así la probabilidad de ocurrencia de inundaciones.

En el contexto del cambio climático, las alteraciones en los patrones de temperatura y precipitación están cambiando significativamente los regímenes hidrológicos de las cuencas a nivel mundial. La evidencia sugiere que el calentamiento global está afectando de manera desigual a las temperaturas diurnas y nocturnas: el aumento de la temperatura mínima tiende a ser más pronunciado que el de la temperatura máxima, lo que reduce el rango de oscilación diurno y genera variaciones importantes en el balance energético, especialmente en latitudes medias y altas (Villarroel Jiménez, 2013). Este fenómeno impacta los ciclos hidrológicos y es un factor crítico en el desarrollo de

eventos de caudal extremo, pues la elevación de las temperaturas mínimas contribuye a la reducción de la cobertura de nieve y, por ende, al aumento del caudal durante el periodo invernal en las cuencas de montaña. La reducción de la nieve acumulada afecta directamente el flujo de los ríos, ya que disminuye la reserva hídrica disponible en las estaciones cálidas del año.

En Chile, los cambios observados en la temperatura son consistentes con las tendencias globales: la región central, en particular, ha experimentado un aumento en la frecuencia e intensidad de los eventos cálidos, junto a una reducción de los fríos. Esto, combinado con una disminución de las precipitaciones, ha incrementado el déficit hídrico, lo cual se ha traducido en una de las mega sequías más prolongadas de las últimas décadas, abarcando la década de 2010 y extendiéndose en la de 2020 (Vincent et al., 2005). Este fenómeno prolongado no solo ha afectado la disponibilidad de recursos hídricos, sino que también ha incrementado el riesgo de desastres naturales como las inundaciones repentinas y los eventos de caudal extremo, los cuales se ven potenciados cuando las lluvias intensas coinciden con suelos saturados por nieve derretida o cuando ocurren sobre áreas previamente secas.

Estos cambios en el régimen hidrológico de las cuencas chilenas exigen una revisión exhaustiva de los modelos de predicción de caudales y de gestión de recursos hídricos, ya que las condiciones de precipitación y temperatura bajo un clima cambiante dificultan la previsión de eventos extremos. En consecuencia, el monitoreo y análisis continuo de estas variables en la región central resulta esencial para el desarrollo de políticas de adaptación y para la implementación de medidas efectivas que eviten el riesgo a estos eventos extremos.

La presente investigación se enfoca en estudiar la conexión entre caudales de crecida y las de precipitación y temperatura para dichos eventos. El estudio se realizará con la información de caudal de la estación Río Maule en Armerillo, Región del Maule, para estimar crecidas de gran magnitud, asociadas a dicho punto de control. La relevancia de este enfoque radica en comprender mejor los patrones climáticos y su impacto directo en el régimen hídrico de la región, en la cual la temperatura desempeña un papel crucial, ya que, su variación puede influir la fase de precipitación, determinando la altura de la línea de nieve y, en consecuencia, el área pluvial asociada a una crecida. Para la selección de eventos de crecida significativos, se consideran caudales de la cuenca con baja probabilidad de excedencia, para así centrar la investigación en analizar detalladamente estos eventos, comprender las condiciones climáticas que los desencadenan y así mejorar la capacidad predictiva y prevenir a la población ante posibles inundaciones.

2. Objetivos

2.1. Objetivo general

Analizar la conexión entre los datos de precipitación y temperatura con los eventos de crecidas, con el fin de mejorar la comprensión de eventos hidro climáticos asociados a inundaciones, utilizando como ejemplo la estación Río en Armerillo, Región del Maule.

2.2. Objetivos específicos

- Identificar los eventos de crecidas en los caudales de la estación de punto de aforo de la cuenca, para la posterior correlación entre los datos de caudal de crecida con los de temperatura y precipitación.

- Analizar la variabilidad temporal y espacial de las variables de precipitación y temperatura en la cuenca del Maule, identificando relación entre las estaciones para eventos de alta intensidad que puedan estar relacionados con crecidas significativas.
- Modelar la respuesta del caudal de una cuenca en la región del Maule ante eventos de crecida, identificando eventos con alto periodo de retorno y evaluando su relación con la variabilidad de la línea de nieve.

3. Zona de estudio y métodos

Para tener una mejor estimación de las crecidas de diseño, se propone implementar un modelo considerando el caudal como variable dependiente, y los datos meteorológicos (precipitación y temperatura) como variables predictoras. Para esto se realiza la siguiente metodología aplicada a la zona de estudio, la cuenca de Río Maule en Armerillo de la región del Maule:

3.1. Zona de estudio y datos

La zona de estudio corresponde la cuenca Armerillo, ubicada en la región del Maule, en la zona centro sur de Chile, específicamente definida por la estación de Río Maule en Armerillo. La estación de Armerillo, que forma parte del sistema de monitoreo hidrométrico, se localiza en un punto estratégico de esta cuenca. En la Figura 1 se presenta la ubicación de la zona de estudio en un mapa.

El clima de la región del Maule es generalmente mediterráneo, con estaciones bien definidas, donde los inviernos son lluviosos y los veranos secos. Las precipitaciones anuales varían significativamente con mayores concentraciones entre mayo y agosto, que coinciden con el periodo de crecidas en la cuenca. Las temperaturas también muestran estacionalidad marcada, con bajas en invierno y altas en verano, lo que afecta directamente los patrones de escurrimiento y el comportamiento del caudal en la estación de Armerillo.

La cuenca de estudio cuenta con características físicas que influyen en su respuesta hidrológica, como es el caso de su área, que tiene una magnitud de 5.469 km², lo que la clasifica como una cuenca de gran tamaño. La pendiente promedio es aproximadamente del 1%, y su relieve se clasifica como “plano”. Además, la curva hipsométrica presentada en la Figura 2 muestra una curva de tipo “B”, indicando que es una cuenca en equilibrio y en fase de madurez. Estas características hacen que el análisis de sus caudales sea relevante, especialmente en el contexto de eventos extremos y variabilidad climática. En la Tabla 1 se presentan las características de la zona de estudio.




Figura 1. Ubicación de la cuenca Río Maule en Armerillo y su distribución en el mapa




Figura 2. Curva hipsométrica de la Cuenca Río Maule en Armerillo

Tabla 1. Características de la Cuenca Armerillo

Zona	Estación Fluviométrica	Código de cuenca	Latitud (°)	Longitud (°)	Área de la cuenca (km ²)	Elevación (m)
Región del Maule	Río Maule en Armerillo	7321002	-35,71	-71,11	5469	453

En cuanto a los datos de la estación Armerillo, se obtiene el caudal horario instantáneo a partir del registro público de la Dirección General de Aguas (DGA), el cual se procesa para generar una serie diaria, seleccionando el valor máximo instantáneo de caudal para cada día. Por otra parte, los datos meteorológicos de la estación se obtienen del explorador CR2, aunque presentan un vacío de varios años, debido a la falta de datos en el registro de precipitación y temperatura. Para abordar esta ausencia de información, se realiza un análisis de regresión lineal a los datos meteorológicos, específicamente a la precipitación y temperatura (máxima y mínima).

Este procedimiento comparó los datos observados en la estación de estudio, obtenidos a partir de la base de datos CR2 Explorador (datos observados), con los datos pronosticados proporcionados por la base de datos CAMELS (datos grillados) (Alvarez-Garretón, et al., 2018), que corresponden a datos obtenidos para cuencas chilenas, desde simulaciones de modelos climáticos globales. Esto permitió corregir posibles sesgos en los valores registrados, mejorando la precisión de los datos y reflejando de forma más ajustada las condiciones climáticas reales de precipitación y temperatura en el área de estudio. De este modo y teniendo todos los registros a disposición, se determina el periodo de estudio, que, debido a la limitación temporal del caudal, corresponde al periodo entre los años 2002 y 2022 (20 años). En la Tabla 2 se presenta el periodo de cada variable y del análisis considerado para el estudio, mientras que la Tabla 3 presenta el resumen de la información fluviométrica de la estación Río Maule en Armerillo.

Tabla 2. Periodos de los registros de las variables meteorológicas

Zona	Estación Fluviométrica	Código de cuenca	Periodo de caudales	Periodo de Temperatura	Periodo de Precipitaciones	Periodo de Análisis
Región del Maule	Río Maule en Armerillo	7321002	2002-2022	1979-2022	1979-2022	2002-2022

Tabla 3. Información del caudal de la estación Río Maule en Armerillo

Zona	Estación Fluviométrica	Caudal medio histórico (m ³ /s)	Caudal máximo (m ³ /s)	Caudal mínimo (m ³ /s)
Región del Maule	Río Maule en Armerillo	26,8	1.882,1	0,015

Además, para mejorar la comprensión de la zona de estudio, se han elaborado gráficos que presentan la curva de variación estacional de caudales y la serie de precipitación anual de la estación para el periodo de estudio, las cuales se presentan en la Figura 3 y Figura 4. Como se observa en la Curva de variación estacional, los registros de caudal muestran una tendencia al aumento para los meses de invierno, lo que confirma que la zona de estudio tiene estaciones del año bien definidas, destacando también los peaks que se presentan en el periodo de octubre a enero, lo que resalta la naturaleza pluvio-nival de la cuenca. En el gráfico de distribución histórica, se observa un alza significativa en el año 2002, un año particularmente lluvioso. Sin embargo, la tendencia de la precipitación mensual promedio ha disminuido en los años posteriores, lo que respalda la existencia del fenómeno del cambio climático (Brown, 2015) y la mega sequía (Garreaud et al, 2017) que afecta la zona de estudio.




Figura 3. Curva de variación estacional de caudales medios




Figura 4. Serie de Precipitación Anual de la estación Río Maule en Armerillo para el periodo de estudio 2002-2022.

3.2. Métodos

3.2.1. Temperatura índice

La temperatura índice es una medida que se utiliza comúnmente en climatología que representa la temperatura ambiente de un periodo de tiempo, y se utiliza para tener un indicador representativo de las condiciones térmicas promedio o extremas de un período. Esta se calcula utilizando la fórmula proporcionada por Seguel & Stowhas (1985):

$$T^{\circ}_{\text{índice}} = \frac{1}{k} \cdot (T^{\circ}_{\text{máxima}} + (k - 1) \cdot T^{\circ}_{\text{mínima}}) \quad (1)$$

Donde:

k = Coeficiente con valor 7.

3.2.2. Tiempo de concentración

Para la cuenca de estudio, el tiempo de concentración se calcula utilizando las fórmulas establecidas en las normas españolas, las cuales son comúnmente empleadas para estimar este parámetro en cuencas naturales. En particular, se aplica la fórmula de Témez (1978), ampliamente reconocida en estudios hidráulicos.

$$T_c = 0,0078 \cdot L^{0,77} \cdot S^{-0,385} \cdot A^{0,2} \quad (2)$$

Donde:

L = Longitud del cauce principal.

S = Pendiente media de la cuenca.

A = Área de la cuenca.

3.2.3. Curva de Duración General

La Curva de Duración General (CDG) es una herramienta gráfica ampliamente utilizada en hidrología para representar la variabilidad y disponibilidad de los caudales en un sistema fluvial. Esta curva muestra la relación entre los caudales y la probabilidad de que estos sean igualados o superados a lo largo de un periodo de tiempo determinado (Vogel & Fennessey, 1994). Su construcción se basa en el análisis estadístico del registro histórico de caudal, organizados según su magnitud y frecuencia de ocurrencia.

Los caudales diarios se ordenan de forma descendente, desde el mayor valor observado hasta el menor. Este ordenamiento asegura una interpretación clara de la probabilidad de excedencia asociada a cada valor (Mosley & McKerchar, 1993). Se emplea la fórmula de Weibull para determinar la probabilidad asociada a cada valor:

$$P_i = \frac{i}{N + 1} \quad (3)$$

Donde:

P_i = Probabilidad de Excedencia.

i = Posición del caudal en el orden descendente.

N = Número total de datos disponibles.

La CDG se grafica tomando el eje X como probabilidad acumulada expresada en porcentaje y el eje Y como los valores de caudal. Este análisis representa la proporción de tiempo que el sistema mantiene o excede un determinado caudal. Se utiliza para ordenar eventos y estimar sus probabilidades, es posible determinar la recurrencia de eventos de inundación o flujo máximo en ríos. Para el registro de datos de caudal, se ha determinado analizar hasta el 5% de las crecidas con mayor magnitud, es decir, todos los eventos registro que superen ese umbral serán seleccionados para este estudio.

3.2.4. Análisis de visualización gráfica

El análisis de visualización gráfica implica usar gráficos para comprender mejor los datos, identificar patrones y obtener información relevante sobre las relaciones entre variables. Este análisis es de gran importancia en estudios exploratorios de datos. Para el análisis de los datos se elaboraron gráficos a escala diaria con extensión de un mes para asegurar la independencia de los eventos de caudal y para evaluar los patrones que presentaban las series de tiempo.

Se grafican los 51 eventos de caudal máximo, centrándose en el peak más alto de cada evento y descartando los peaks menores influenciados por el caudal principal. Se utiliza un gráfico donde el eje Y presenta los valores de caudal instantáneo y el eje X muestra el periodo de tiempo representado en días alrededor del evento, incluyendo 15 días antes y después del mismo.

Además, se grafican los datos de temperatura y precipitación para el mismo periodo de tiempo en que ocurrían estos 51 eventos. A modo de resumen, se realiza un gráfico que incluye todas las variables relevantes: Precipitación, Temperatura Índice y Caudal instantáneo, con el fin de realizar una mejor comparación entre los datos. Este análisis cualitativo proporciona una comprensión más profunda de la relación entre las variables de estudio y permite una evaluación integral de los eventos de caudal máximo en relación con las condiciones meteorológicas locales, facilitando la identificación de tendencias y la comprensión de los factores que influyen en la ocurrencia de estos eventos.

3.2.5. Correlación de Spearman

El coeficiente de correlación de Spearman (Spearman, 1904) es una medida no paramétrica que evalúa la fuerza y la dirección de la asociación monotónica entre dos variables. El coeficiente de Spearman se basa en los rangos de los datos en lugar de sus valores absolutos, esto lo hace especialmente útil cuando las variables no cumplen con los supuestos de normalidad o cuando la relación entre ellas no es lineal. El coeficiente de Spearman varía entre -1 y 1, donde un valor de 1 indica una relación perfectamente positiva, -1 una relación perfectamente negativa, y 0 ninguna relación.

La fórmula para calcular el coeficiente de correlación de Spearman (ρ) es:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (4)$$

Donde:

d_i = Diferencia entre los rangos de cada par de valores.

n = Número de pares de valores.

Se emplea el coeficiente de correlación de Spearman para analizar la relación entre las variables características del registro, ya sea, comparándolas en los mismos días del evento o desfasadas hasta 3 días antes del mismo. Este análisis cuantitativo proporcionó una comprensión más profunda de la relación entre la temperatura índice, la precipitación y caudal, validando las observaciones cualitativas realizadas en los gráficos.

3.2.6. Modelo de Regresión Lineal Multivariado (MRLM)

Se implementa un MRLM (Jobson, 1991) para la predicción de caudales máximos en eventos de crecida, considerando las variables meteorológicas como posibles predictores para demostrar su capacidad predictiva. Utilizamos el MRLM debido a su fácil implementación e interpretabilidad, además de que ha sido ampliamente utilizado en aplicaciones de pronóstico en diferentes escalas temporales (e.g., Mendoza et al., 2017; Papacharalampous & Tyrallis, 2018; Jozaghi et al., 2021).

Considere que $Q_j(t)$ para $t=1, \dots, N$ representa el caudal estacional promedio (variable dependiente) de la estación j en un lugar específico para el año t . Para pronosticar esta variable, asumimos que puede expresarse como una función lineal de p -predictores con un tiempo de anticipación de k -meses, como sigue:

$$Q_j(t) = \beta_0 + \sum_{i=1}^p \beta_i X_{i,k}(t) + \varepsilon \quad (5)$$

Donde:

$X_{i,k}(t)$ = Representa el predictor i con un tiempo de anticipación k para el año t .

β_0 = Intercepto.

β_i = Coeficiente de regresión asociado al predictor $X_{i,k}(t)$.

ε = Representa el error del modelo, que se asume normalmente distribuido con media y desviación estándar σ_ε .

La elección del modelo de regresión lineal se justifica por su capacidad de capturar relaciones directas entre las variables predictoras y la respuesta. Además, este modelo ofrece una estructura sencilla que permite evaluar la importancia de cada predictor en el comportamiento del caudal, facilitando el análisis y la interpretación de los resultados. Los coeficientes obtenidos para cada variable predictora representan la magnitud y dirección del impacto de la temperatura índice y precipitación en los niveles de caudal, lo que es clave para entender y anticipar cambios en respuesta a eventos climáticos específicos en el futuro.

3.2.7. Modelos GAMLSS

Los Modelos Aditivos Generalizados para Ubicación, Escala y Forma (GAMLSS, por sus siglas en inglés) (Amat Rodrigo J, 2020) permiten explorar diversas distribuciones para identificar la que mejor se ajusta a los datos de caudal, considerando también ajustes en el tiempo (modelo no estacionario).

En los GAMLSS, los parámetros de ubicación, escala y forma se representan como (μ, σ, ν, τ) , cada uno de estos parámetros pueden ser modelados en función de variables predictoras, con la opción de usar funciones de suavizado no lineales para capturar relaciones más complejas. Así, la fórmula general de un modelo GAMLSS se representa como:

$$Y \sim D(\mu, \sigma, v, \tau) \quad (6)$$

donde Y representa los caudales y D es la distribución seleccionada. La estructura de los parámetros en términos de las variables predictoras (temperatura y precipitación, en este caso) es:

$$\begin{aligned} \eta_1 &= g_1(\mu) = X^T \beta + f_1(x_1) + f_2(x_2) + \dots + f_p(x_p) \\ \eta_2 &= g_2(\sigma) = X^T \beta + f_1(x_1) + f_2(x_2) + \dots + f_p(x_p) \\ \eta_3 &= g_3(v) = X^T \beta + f_1(x_1) + f_2(x_2) + \dots + f_p(x_p) \\ \eta_4 &= g_4(\tau) = X^T \beta + f_1(x_1) + f_2(x_2) + \dots + f_p(x_p) \end{aligned} \quad (7)$$

La matriz de diseño X contiene los términos lineales, los coeficientes β representan los efectos de cada variable predictora, y las funciones $f_i(x_i)$ son funciones de suavizado no lineales para cada predictor, lo que proporciona mayor flexibilidad al modelo.

El término $X^T \beta$ se puede escribir como:

$$X^T \beta = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (8)$$

Donde:

β_0 = Coeficiente del intercepto (valor sin considerar los predictores).

$\beta_1, \beta_2, \dots, \beta_n$ = Coeficientes de regresión asociados a las variables predictoras.

$x_1, x_2, \dots, x_n$ = Valores de las variables predictoras.

Para este análisis, se evaluaron cinco distribuciones potenciales (Gamma General, Gamma, Normal, Weibull y Log-normal), considerando que los parámetros de ubicación (μ) y escala (σ) pueden variar en el tiempo.

3.2.8. Métricas de ajuste

Se evalúa el desempeño de los modelos mediante métricas, asegurando que el modelo tenga un ajuste adecuado y una capacidad predictiva suficiente para los fines del estudio.

3.2.8.1. Criterio de Información de Akaike (AIC)

El AIC (Akaike, 1974) es una medida estadística que evalúa la calidad relativa de los modelos en un conjunto de candidatos, equilibra la bondad de ajuste a partir de su complejidad, buscando encontrar aquel que mejor describa los datos subyacentes, penalizando al mismo tiempo los modelos excesivamente complejos. El AIC se define como:

$$AIC = -2 \cdot \ln(L) + N_p \quad (9)$$

Donde:

L = Verosimilitud del modelo.

N_p = Numero de parámetros estimados en el modelo.

El AIC se calcula para un conjunto de modelos candidatos con diversas combinaciones de predictores y el que presente el AIC menor se selecciona como el modelo que mejor equilibra ajuste y complejidad para la predicción de caudal máximo.

3.2.8.2. Coeficiente de determinación (R^2)

El coeficiente de determinación (R^2) (Draper N. & Smith H., 1998) mide la proporción de la variabilidad total de la variable dependiente (caudal observado) que puede explicarse mediante el modelo ajustado. Su fórmula es:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Q_{obs,i} - Q_{pred,i})^2}{\sum_{i=1}^n (Q_{obs,i} - \overline{Q_{obs}})^2} \quad (10)$$

Donde:

$Q_{obs,i}$ = Valor observado del caudal en el instante i.

$Q_{pred,i}$ = Valor predicho por el modelo en el instante i.

$\overline{Q_{obs}}$ = Valor promedio de los valores observados de caudal.

Un R^2 cercano a 1 indica que el modelo ajustado explica la mayor parte de la variabilidad observada, mientras que un valor cercano a 0 sugiere que el modelo tiene poca capacidad predictiva. Es ampliamente utilizado para evaluar la calidad general del ajuste.

3.2.8.3. Sesgo promedio (BIAS)

El BIAS (Legates D. & McCabe G., 1999) mide la desviación promedio entre los valores predichos ($Q_{pred,i}$) y los valores observados ($Q_{obs,i}$). Su fórmula es:

$$BIAS = \frac{1}{n} \sum_{i=1}^n (Q_{pred,i} - Q_{obs,i}) \quad (11)$$

Donde:

$Q_{obs,i}$ = Valor observado del caudal en el instante i.

$Q_{pred,i}$ = Valor predicho por el modelo en el instante i.

El BIAS indica si el modelo tiende a sobrestimar o subestimar sistemáticamente los valores de caudal. Un BIAS positivo significa una sobreestimación promedio, mientras que un valor negativo indica subestimación. Idealmente, el BIAS debería ser cercano a 0.

3.2.8.4. Coeficiente de Eficiencia de Nash-Sutcliffe (NSE)

El NSE (Nash J. & Sutcliffe J., 1970) evalúa la precisión de las predicciones del modelo en comparación con el promedio de los valores observados. Su fórmula es:

$$NSE = 1 - \frac{\sum_{i=1}^n (Q_{obs,i} - Q_{pred,i})^2}{\sum_{i=1}^n (Q_{obs,i} - \overline{Q_{obs}})^2} \quad (12)$$

Donde:

$Q_{obs,i}$ = Valor observado del caudal en el instante i.

$Q_{pred,i}$ = Valor predicho por el modelo en el instante i.

$\overline{Q_{obs}}$ = Valor promedio de los valores observados de caudal.

El NSE varía entre $-\infty$ y 1. Un valor de 1 indica predicciones perfectas, mientras que valores cercanos a 0 o negativos indican que el modelo no es mejor que usar el promedio de los datos observados como predicción. Es ampliamente empleado en hidrología debido a su enfoque en minimizar los errores cuadráticos.

4. Resultados

4.1. Procesamiento de datos

Para la selección de eventos de caudal máximo se grafica la Curva de Duración General (CDG), con la cual se identificaron 51 eventos de crecida, el evento de mayor magnitud es de 2305,2 m³/s y el de menor magnitud es de 162,83 m³/s. El registro de eventos representa un 5,3% de excedencia del total de datos disponibles. En la Figura 5 se presenta la CDG obtenida calculando la probabilidad empírica de Weibull para el registro de caudales en el periodo de 2002-2022.




Figura 5. Análisis de Weibull para el registro de caudales en el periodo 2002-2022

En la Figura 6 se presentan los ajustes realizados para la corrección de datos de los tres registros de variables meteorológicas (precipitación, temperatura máxima y mínima).




Figura 6. Ajuste de Regresión Lineal para los Datos observados (CR2) con los Datos Grillados (CAMELS)

4.2. Análisis exploratorio de crecidas

En la Figura 7 se presenta el gráfico integrado de algunos eventos de crecida estudiados, considerando las variables de caudal, precipitación y temperatura índice, ilustrando la distribución y la independencia de los eventos seleccionados. De acuerdo con el gráfico se observa cómo la precipitación y la temperatura índice influyen al caudal instantáneo en los eventos de crecida, en el caso de la temperatura índice se observa un aumento de esta variable en los días anteriores y el día del peak de caudal del evento. En cuanto a la precipitación, se observa un aumento gradual en la precipitación en los días anteriores al evento. Este patrón se repite en la mayoría de los 51 eventos estudiados, sugiriendo una relación entre estas variables.

El Anexo A presenta los gráficos integrados de precipitación, temperatura y caudal para el registro de eventos de crecida. Estos gráficos presentan un comportamiento similar al observado, manteniendo el patrón de influencia de las variables meteorológicas sobre el caudal instantáneo.




Figura 7. Gráficos integrados de precipitación, temperatura índice y caudal, para los eventos de crecida

A partir del análisis de visualización gráfica, se lleva a cabo un estudio de correlación entre el registro de eventos de caudal y las variables de precipitación y temperatura, identificando aquellas con mayor influencia. En la Tabla 4 se presentan las variables con mayor correlación en el registro de datos.

Tabla 4. Variables de correlación de cada registro: Caudal, Temperatura índice y Precipitación.

Caudal	Temperatura índice	Precipitación
Caudal máximo del evento	Temperatura índice del día del evento	Precipitación del día del evento
	Promedio de Temperatura índice hasta 1 día antes del evento	Precipitación acumulada hasta el 1 día antes del evento
	Promedio de Temperatura índice hasta 2 día antes del evento	Precipitación acumulada hasta el 2 día antes del evento
	Promedio de Temperatura índice	Precipitación acumulada hasta el 3 día antes del evento

Caudal	Temperatura índice hasta 3 día antes del evento	Precipitación

4.3. Correlación de Spearman

En la Tabla 5 se presenta la correlación de Spearman para los casos recomendados según lo obtenido en el análisis de visualización gráfica de los eventos de crecida.

En la Figura 8 se observa un gráfico tipo Pairwise Scatter Plot, a modo de resumen, presentando las correlaciones encontradas para los 51 eventos de crecida, con histograma incluido.

Los resultados presentan una correlación considerable entre el caudal del evento y la precipitación acumulada durante 3 días previos. Este comportamiento está influenciado por las características geomorfológicas e hidrológicas de la cuenca, detallada en la Tabla 6, en la que se observa una pendiente suave y un tiempo de concentración acorde al registro de acumulación de precipitaciones, que ocurre en un periodo similar al identificado en el análisis de correlación de Spearman.

Sin embargo, la correlación entre los datos de caudal, precipitación y temperatura resultó insuficiente, esto puede deberse a que el régimen hidrológico de la cuenca de Armerillo es mixto. Este régimen combina componentes nival y pluvial, influenciado por su ubicación geográfica y sus variaciones de altitud. Como resultado, los caudales de la zona tienden a ser mayores durante el invierno. Ante esta situación, se opta por establecer nuevos criterios para la elección de eventos de crecida, restringiendo el análisis exclusivamente a la temporada de invierno, periodo en el cual los datos mostraron una tendencia más consistente, como se evidenció en el análisis gráfico. Con este enfoque, se llevaron a cabo cuatro análisis de correlación distintos, los cuales se presentan en la Tabla 7.

Tabla 5. Correlación de Spearman para los casos elegidos según el análisis de visualización de gráficos

Caso de estudio de correlación	Correlación de Spearman
TDE – CPDE	0,062
TMD-1 – CPDE	-0,006
TMD-2 – CPDE	-0,045
TMD-3 – CPDE	-0,085
PDE - CPDE	0,082
PAD-1 – CPDE	0,241
PAD-2 – CPDE	0,387
PAD-3 – CPDE	0,413

*La nomenclatura para esta tabla es:

PDE: Precipitación día evento.

TDE: Temperatura día evento.

CPDE: Caudal Peak día del evento.

PAD-X: Precipitación acumulada día X antes del evento.

TMD-X: Temperatura media día X antes del evento.

Tabla 6. Características Geomorfológicas e hidrológicas de la Cuenca Río Maule en Armerillo

Estación Fluviométrica	Pendiente de la cuenca (%)	Longitud del cauce principal (km)	Diferencia de cota (m)	Tiempo de concentración (h)
Río Maule en Armerillo	1,03	97,13	3.499	63,90




Figura 8. Pairwise Scatter Plot del caso evaluado

Tabla 7. Análisis estacional

Análisis estacional de correlación
Mayo, Junio, Julio, Agosto
Mayo, Junio, Julio
Junio, Julio, Agosto
Junio, Julio

4.4. Análisis estacional

En las Tabla 8-10 se presentan los resultados de correlación para cada periodo de análisis estacional, considerando las variables de estudio (caudal, temperatura índice y precipitación). Como se puede observar en las tablas, el análisis de los meses Junio-Julio es el que presentan mayor correlación, para este periodo se identificaron 21 eventos de caudal máximo, donde el mayor evento tiene una magnitud de 2305,2 m³/s, mientras que el menor registró 161,86 m³/s, con una probabilidad de excedencia correspondiente al 5,0%.

Además, en la Figura 9 se presenta el gráfico tipo Pairwise Scatter Plot para el periodo con mejor correlación de datos. De acuerdo con el gráfico, se observa que el caudal peak presenta la correlación más alta con dos variables, que corresponden a la temperatura índice del día del evento y la precipitación acumulada hasta tres días antes al evento, por lo tanto, estos datos serán utilizados como variable predictora del caudal en la creación del modelo multivariado.

El Anexo B presenta los gráficos Pairwise Scatter Plot para los distintos periodos de tiempo considerados en el análisis estacional. En ellos se observa un comportamiento similar entre los periodos, destacando que la menor correlación se registra entre el periodo de Mayo-Agosto.

Tabla 8. Correlación de Spearman para el análisis del periodo Mayo-Agosto

Caso de estudio de correlación	Correlación de Spearman
TDE – CPDE	0,39
TMD-1 – CPDE	0,31
TMD-2 – CPDE	0,37
TMD-3 – CPDE	0,26

Caso de estudio de correlación	Correlación de Spearman
PDE - CPDE	0,36
PAD-1 – CPDE	0,36
PAD-2 – CPDE	0,40
PAD-3 – CPDE	0,46

*La nomenclatura para esta tabla es:

PDE: Precipitación día evento.

TDE: Temperatura día evento.

CPDE: Caudal Peak día del evento.

PAD-X: Precipitación acumulada día X antes del evento.

TMD-X: Temperatura media día X antes del evento.

Tabla 9. Correlación de Spearman para el análisis del periodo Junio-Agosto

Caso de estudio de correlación	Correlación de Spearman
TDE – CPDE	0,42
TMD-1 – CPDE	0,39
TMD-2 – CPDE	0,40
TMD-3 – CPDE	0,24
PDE - CPDE	0,39
PAD-1 – CPDE	0,39
PAD-2 – CPDE	0,39
PAD-3 – CPDE	0,47

*La nomenclatura para esta tabla es:

PDE: Precipitación día evento.

TDE: Temperatura día evento.

CPDE: Caudal Peak día del evento.

PAD-X: Precipitación acumulada día X antes del evento.

TMD-X: Temperatura media día X antes del evento.

Tabla 10. Correlación de Spearman para el análisis del periodo Mayo-Julio

Caso de estudio de correlación	Correlación de Spearman
TDE – CPDE	0,50
TMD-1 – CPDE	0,37
TMD-2 – CPDE	0,40
TMD-3 – CPDE	0,36
PDE - CPDE	0,38
PAD-1 – CPDE	0,39
PAD-2 – CPDE	0,46
PAD-3 – CPDE	0,53

*La nomenclatura para esta tabla es:

PDE: Precipitación día evento.

TDE: Temperatura día evento.

CPDE: Caudal Peak día del evento.

PAD-X: Precipitación acumulada día X antes del evento.

TMD-X: Temperatura media día X antes del evento.

Tabla 11. Correlación de Spearman para el análisis del periodo Junio-Julio

Caso de estudio de correlación	Correlación de Spearman
TDE – CPDE	0,52
TMD-1 – CPDE	0,44
TMD-2 – CPDE	0,43
TMD-3 – CPDE	0,36
PDE - CPDE	0,22
PAD-1 – CPDE	0,48

Caso de estudio de correlación	Correlación de Spearman
PAD-2 – CPDE	0,50
PAD-3 – CPDE	0,53

*La nomenclatura para esta tabla es:

PDE: Precipitación día evento.

TDE: Temperatura día evento.

CPDE: Caudal Peak día del evento.

PAD-X: Precipitación acumulada día X antes del evento.

TMD-X: Temperatura media día X antes del evento.




Figura 9. Pairwise Scatter Plot para el análisis del periodo Junio-Julio

4.5. Modelo Lineal Multivariado

En base a los resultados de la sección anterior, se consideran las combinaciones de las variables con mayor correlación de Spearman para ajustar un modelo lineal multivariado, con la finalidad de predecir el caudal máximo diario del periodo Junio-Julio, que corresponde al periodo de análisis estacional con mejores indicadores, para esto se utiliza el caudal como variable dependiente y los datos climáticos como variables predictoras. En la Tabla 12 se presentan los indicadores de ajuste para las combinaciones verificadas, en la cual se observa la combinación con mejores indicadores, que corresponde al modelo N°4, la cual considera las variables de Precipitación Acumulada del Día 3 antes del evento y la Temperatura índice del Día del Evento (PAD-3 – TDE).

En la Tabla 13 se indican los coeficientes para el modelo de mejor predicción, incluyendo el intercepto, así como los coeficientes de regresión correspondientes a la temperatura y la precipitación.

En la Figura 10 se presenta el gráfico de la combinación con mejores indicadores, que corresponde al modelo N°4, comparando los datos observados con los datos predichos de caudal. Se observa que el ajuste no es satisfactorio, ya que el modelo presenta caudales negativos para algunos instantes. A pesar de esto, los valores predichos por el modelo son generalmente coincidentes con los datos observados para caudales de baja magnitud. Sin embargo, para los eventos de mayor magnitud, se observa que el modelo no los predice correctamente, como es el caso de los eventos del 20 junio

2003, del 29 junio de 2005 y del 07 de junio de 2006, que corresponden a los caudales de mayor magnitud dentro del registro, 2.174, 2.279 y 1.779 respectivamente, lo que influencia negativamente al modelo y al ajuste para los demás eventos. Debido a esto, se utilizan los modelos GAMLSS con el fin de mejorar la predicción de eventos de mayor magnitud.

Además, posterior al año 2010 se observa que el régimen de crecidas cambia drásticamente, presentando peaks de caudales mucho más bajos, lo que puede estar vinculado con la ocurrencia de la mega-sequía en la zona central del país (Garreaud et al, 2017).

En el Anexo C se observan los gráficos ajuste lineal de modelo multivariado para las otras combinaciones, de las cuales se observan ajustes similares, aunque con una menor exactitud en la predicción de los eventos de caudal.

Tabla 12. Indicadores de ajuste para la combinación de predictores

Nº de Modelo	Combinación de predictores	AIC	R	BIAS	NSE
1	PDE – TDE	322,89	0,56	-0,02	0,56
2	PAD-1 – TDE	328,11	0,43	-0,02	0,43
3	PAD-2 – TDE	328,08	0,43	-0,02	0,43
4	PAD-3 – TDE	318,24	0,65	-0,02	0,65
5	PDE – TMD-1	333,04	0,28	-0,02	0,28
6	PAD-1 – TMD-1	335,92	0,18	-0,02	0,18
7	PAD-2 – TMD-1	336,27	0,16	-0,02	0,16
8	PAD-3 – TMD-1	328,93	0,41	-0,02	0,41
9	PDE – TMD-2	333,32	0,27	-0,02	0,27
10	PAD-1 – TMD-2	336,46	0,16	-0,02	0,16
11	PAD-2 – TMD-2	336,65	0,15	-0,02	0,15
12	PAD-3 – TMD-2	328,73	0,42	-0,02	0,42
13	PDE – TMD-3	332,24	0,31	-0,02	0,31
14	PAD-1 – TMD-3	335,64	0,19	-0,02	0,19
15	PAD-2 – TMD-3	335,64	0,19	-0,02	0,19
16	PAD-3 – TMD-3	328,43	0,42	-0,02	0,42

*La nomenclatura para esta tabla es:

PDE: Precipitación día evento.

TDE: Temperatura día evento.

PAD-X: Precipitación acumulada día X antes del evento.

TMD-X: Temperatura media día X antes del evento.

Tabla 13. Coeficientes del modelo de mejor predicción – Modelo N°4

Nº de Modelo	Intercepto	Coeficiente Precipitación	Coeficiente Temperatura
4	-2.459	4,64	282,14




Figura 10. Ajuste lineal Multivariado de la combinación con el modelo de mejor ajuste

4.6. Ajuste de modelos GAMLSS

De acuerdo con lo descrito en la sección 3.2.7, se ajustan distintas distribuciones de los modelos GAMLSS utilizando como predictores las variables de mejor ajuste para el modelo lineal multivariado, correspondiente a la Precipitación acumulada 3 días antes del evento y Temperatura día del evento (PAD-3 y TDE respectivamente).

Según lo indicado en la Tabla 14, el valor más bajo de AIC corresponde al modelo Gamma General ($\text{AIC} = 278.82$), indicando que este modelo logra un ajuste relativamente bueno sin sobre ajustar los datos. En cuanto al coeficiente de correlación (R), se presenta el valor más alto en el modelo Gamma ($R = 0.8217$), sugiriendo una fuerte relación lineal y un ajuste adecuado a los datos observados. En el caso del sesgo (BIAS), el valor más próximo a cero lo obtuvo el modelo Weibull ($\text{BIAS} = 0.644$), indicando que este modelo tiene un sesgo mínimo y una capacidad de ajuste balanceada. En cuanto a la eficiencia de Nash-Sutcliffe (NSE), presentó su valor más alto en el modelo Gamma ($\text{NSE} = 0.661$), indicando que es el más efectivo en relación con la media de los datos observados, lo cual lo convierte en la mejor opción para describir los caudales de la cuenca en estudio.

De acuerdo con los resultados anteriores, el modelo Gamma fue el que mejor desempeño tuvo en cuanto a equilibrio entre las métricas de ajuste y predicción (AIC, R y NSE), sugiriendo que es la opción más adecuada para representar el comportamiento del caudal bajo las condiciones estudiadas. No obstante, otros modelos, como el Weibull, también demostraron ajustes aceptables, especialmente en términos de bajo sesgo, lo que podría ser considerado si el sesgo mínimo es una prioridad en el análisis. En la Figura 11 se presenta el gráfico de ajuste lineal del modelo para las distribuciones de Gamma.

Tabla 14. Indicadores de ajuste para los modelos GAMLSS evaluados

Modelo	AIC	R	BIAS	NSE
Gamma General	278,82	0,813	-28,07	0,55
Normal	285,54	0,815	-10,53	0,64
Gamma	280,85	0,822	-7,93	0,66
Weibull	281,91	0,811	0,64	0,66
Log-normal	278,83	0,801	-98.89	-0,60




Figura 11. Ajuste lineal del modelo para el enfoque de Gamma

Por otra parte, en los enfoques utilizados para los GAMLSS, se puede observar que los modelos también presentan problemas al predecir correctamente los eventos de caudal de mayor magnitud (2.174, 2.279 y 1.779), lo que influencia el ajuste para los demás eventos.

El uso de GAMLSS en este estudio permitió ajustar cuantiles que cambian con el tiempo, lo cual proporciona una herramienta más robusta para entender y predecir caudales extremos en un escenario de cambio climático, mejorando la precisión del modelo lineal inicial que subestimaba eventos de alta magnitud (Debele et al., 2017; Covián & Stowhas, 2012).

En el Anexo D se presentan los gráficos de ajuste del modelo utilizando los diferentes enfoques de los modelos GAMLSS, en los cuales se observa un comportamiento similar, exceptuando para el modelo de Log-Normal, que presenta un mal ajuste y predicción de los eventos de caudal.

5. Análisis y discusión

5.1. Análisis exploratorio de crecidas

En el análisis visual de los eventos de caudal máximo se observan patrones marcados, como el incremento de temperatura y la acumulación de precipitaciones los días previos a cada evento, ambos factores clave en la generación de eventos extremos (Rasmussen et al., 2018).

Si bien estos factores meteorológicos están relacionados con eventos de gran magnitud, el registro muestra que los eventos de crecidas no siempre están asociados a precipitaciones extremas, lo que puede sugerir la contribución del deshielo y de la acumulación de precipitaciones en la generación de la crecida, lo que coincide con las observaciones de Peña & Vidal (1993) sobre la influencia de la línea de nieve en cuencas andinas, en el cual el deshielo juega un papel importante en la generación de peaks de caudal.

Este análisis permite identificar que los eventos siguen patrones estacionales, similares a los observados en otros estudios. Esto sugiere que la acumulación de precipitación y el aumento de temperatura en días previos son factores clave para la estimación de los caudales en la cuenca del Maule. Entender estos patrones abre la posibilidad de implementar alertas tempranas basadas en el riesgo que presentan estas condiciones, lo que facilitaría una mejor gestión sobre las crecidas de diseño.

5.2. Correlación de Spearman

El análisis de correlación de Spearman es un método efectivo para evaluar la relación entre el caudal y las variables meteorológicas. Dado que estudios previos han señalado la importancia de la acumulación de precipitación en días anteriores a eventos extremos (Zúñiga & Jara, 2017), se extendió el análisis a la precipitación acumulada hasta tres días antes de cada evento, lo cual es coherente, debido a la geomorfología de la cuenca y al respaldo del cálculo del tiempo de concentración, correspondiente a 63 horas. El análisis de la precipitación acumulada reveló una correlación significativa de 0,413. Esto confirma que los eventos de caudal máximo están fuertemente influenciados por precipitaciones acumuladas en días previos, respaldando estudios como el de McCabe & Clark (2007), quienes también encontraron una dependencia entre la precipitación acumulada y el caudal en cuencas montañosas del oeste de EE. UU.

El uso de Spearman permite evaluar la correlación entre variables sin asumir linealidad, abordando así la complejidad de las interacciones en sistemas pluvio-nivales. Esta correlación acumulativa refuerza la idea de que las variables climáticas deben analizarse en periodos acumulativos para capturar su impacto real en los caudales extremos. Estos hallazgos resaltan la necesidad de incluir la precipitación acumulada en modelos predictivos, alineándose con enfoques previos en la modelación de cuencas mixtas (Marks & Dozier, 1998).

5.3. Análisis estacional

A partir análisis estacional se determina que los eventos de caudal extremo son más frecuentes durante los meses de otoño e invierno, debido a las características de la cuenca de estudio que presenta las estaciones del año muy marcadas. Este hallazgo se complementa con el trabajo de Soto Muenia (2022), quien destacó la influencia de la estacionalidad en el comportamiento del caudal en cuencas andinas, indicando que el aumento de temperatura en invierno intensifica el deshielo y, junto con la precipitación, provoca crecidas significativas.

Este análisis estacional aporta una visión importante en cuanto a las catástrofes producidas por las crecidas, ya que permite enfocar el análisis en el periodo de mayor frecuencia de los eventos extremos (Junio y Julio), apoyando estrategias para la mitigación de riesgos pluviales en cuencas mixtas (Debele et al., 2017).

5.4. Modelo Lineal Multivariado

Entre los resultados obtenidos por el modelo lineal, para el periodo de mayor correlación Junio-Julio, se observa un ajuste adecuado, destacando la combinación de variables predictoras correspondiente a la temperatura índice del día del evento (TDE) y la precipitación acumulada día 3 antes del evento (PAD-3), las cuales presentan el mejor ajuste en comparación a las otras variables consideradas. Estas variables son coherentes con la geomorfología y las características pluviométricas de la cuenca, respaldando su relevancia en el análisis.

Sin embargo, el modelo presenta limitaciones para capturar los valores extremos de caudal, se observa una tendencia a subestimar los caudales extremos, algunos incluso resultando negativos, tendencia observada en otros estudios donde los modelos lineales subestiman los eventos de alta magnitud (Covián & Stowhas, 2012). Si bien este ajuste es útil para capturar tendencias generales, no resulta completamente adecuado para representar caudales extremos. Esto resalta la importancia de incluir variables adicionales en el modelo que permitan una mejor representación de los eventos de crecida de mayor magnitud.

5.5. Modelos GAMLSS

Para mejorar la predicción de eventos extremos en el modelo, se utilizan los GAMLSS. Entre las distribuciones evaluadas, Gamma es la mejor, considerando todos los indicadores de ajuste. Con un AIC de 278.82 y una correlación de 0,822, es la opción más precisa para este análisis, destacándose como una herramienta confiable para la predicción de caudales extremos.

Este análisis muestra la relevancia de utilizar modelos flexibles para ajustar eventos extremos y demuestra que la distribución Gamma es eficaz en este contexto, coincidiendo con estudios previos que destacan su aplicación en hidrología (Bean & Watts, 2024). La selección de un modelo adecuado permite una representación más precisa de la variabilidad hidrológica en cuencas pluvio-nivales, proporcionando la capacidad para el desarrollo de estrategias de gestión hídrica.

Independiente de lo anterior, el ajuste actual aún presenta limitaciones, por lo que se considera necesario implementar mejoras en los datos para optimizar su precisión. Además, se propone investigar y establecer correlaciones más sólidas entre las variables meteorológicas, lo que permitirá afinar las estimaciones y mejorar su desempeño. Este proceso debe incluir una revisión de factores no considerados en este estudio y que pueden estar influyendo en los resultados, con el objetivo de identificar limitaciones que afectan la capacidad predictiva del modelo. Para abordar los eventos que no fueron correctamente representados, se propone diversas modificaciones en el enfoque de predicción, específicamente se identifica que los tres mayores eventos de caudal no están siendo bien capturados, debido a la exclusión de factores clave, como las reservas de nieve y las temperaturas inusualmente elevadas en los días anteriores a esos eventos. Estos eventos extremos parecen indicar que la línea de nieve, un elemento crucial en la dinámica del deshielo, podría haberse ubicado a mayor altitud durante los eventos de tormenta, lo que explicaría el comportamiento observado.

Este suceso se explica a través del fenómeno de Rain-on-Snow (ROS) que es conocido por su capacidad para desencadenar inundaciones rápidas en cuencas de zonas montañosas, debido a la lluvia

que cae sobre nieve acumulada, lo que provoca un derretimiento acelerado de la nieve y un incremento enorme del caudal (Marks & Dozier, 1998; Cohen et al., 2015). Esta anomalía es particularmente relevante en cuencas de alta montaña como la del Río Maule, donde la combinación de lluvias y nieve puede generar eventos de crecida extremos (Rasmussen et al., 2018).

Los eventos de lluvia sobre nieve (ROS) suelen ocurrir a grandes altitudes, generalmente por encima de los 500 m s.n.m. Aunque la estación de Río Maule en Armerillo está a 453 m s.n.m., la cuenca abarca zonas con mayor altitud. La estación (Río Maule en Desague, Río Melado) ubicada aguas arriba (a una elevación de 2.148 m s.n.m.), en el punto de aforo de la Laguna del Maule, presenta un caudal normal, lo que indica que no hay aportes de la Laguna en los eventos de crecida, pero registra unas temperaturas índice superiores a lo normal, durante y los días anteriores a los eventos correspondientes a los tres casos de mal ajuste del modelo. Esto sugiere que es probable que dichos eventos estén influenciados por el fenómeno ROS, incrementando significativamente el caudal instantáneo y afectando así la precisión del modelo.

Por lo tanto, el fenómeno de ROS parece ser un factor crítico que no se ha incluido en el análisis y puede ser una causa de que el modelo actual presente problemas para estimar eventos de caudal de gran magnitud. Incorporar variables relacionadas con la dinámica de la nieve, como la altura de la línea de nieve y su impacto sobre el caudal durante eventos ROS, podría mejorar significativamente la precisión del modelo (Hotovy et al., 2024). Además, en un contexto de cambio climático, los eventos ROS están mostrando una tendencia al aumento en frecuencia e intensidad, lo que hace aún más urgente considerar estas variables en la predicción de caudales para cuencas de montaña (McCabe & Clark, 2007; Bean & Watts, 2024).

6. Conclusiones

En este estudio se ha demostrado la importancia de analizar las correlaciones entre los datos meteorológicos y los eventos de crecida en la estación de Río Maule en Armerillo, ubicada en la Región del Maule, Chile. Mejorando la comprensión de eventos hidro climáticos asociados a catástrofes que aquejan la zona, como son las inundaciones. Los resultados indican que la mejor época para realizar estos estudios es durante los meses de invierno, específicamente Junio y Julio, cuando se observan fuertes correlaciones entre las variables meteorológicas y eventos de caudal máximo. En este periodo, se correlacionan diversas combinaciones de variables meteorológicas con los eventos de crecida, de las cuales algunas presentan un buen resultado en los análisis de datos.

A pesar de que el modelo lineal multivariado creado presenta un buen ajuste para caudales menores, se identifican irregularidades significativas, como la predicción de caudales negativos para algunos eventos y un mal ajuste para los eventos de crecida de gran magnitud.

Para abordar las predicciones de caudales negativos que se presentan en algunos eventos de crecida, se utilizan los GAMLSS. Los que presentan ciertas limitaciones, debido a que no lograron capturar con precisión los caudales observados en los eventos de mayor magnitud, específicamente se detectó que el modelo subestimó el ajuste para los tres eventos con mayor magnitud. Sin embargo, estos modelos permiten mejorar la precisión de la predicción al considerar una mayor variedad de variables y su interacción, proporcionando un ajuste más adecuado para los eventos.

La subestimación de estos tres eventos podría estar relacionada con el fenómeno de “Rain on Snow” (ROS), proceso en donde la línea de nieve (Isotherma 0) se ubica en una elevación mayor a lo normal, que en combinación con la humedad del sitio, hacen que las reservas de nieve acumulada se derritan,

dando paso a un aumento de caudal considerable y por ende a los eventos de crecida con una mayor magnitud.

La integración de variables adicionales, como la altura de la línea de nieve y su interacción con las precipitaciones, es crucial para mejorar la precisión de los modelos predictivos. Esto permitirá una mejor comprensión y predicción de los eventos extremos, facilitando la implementación de estrategias de mitigación más efectivas.

En conclusión, los patrones hidrológicos en las cuencas montañosas del sur de Chile , y esto se debe en gran parte a fenómenos como el ROS, que están teniendo un impacto significativo. Es esencial continuar investigando y adaptando los modelos predictivos a esta nueva realidad para mejorar la capacidad de respuesta ante los eventos de crecida extremos y advertir a las comunidades afectadas.


7. Referencias

- Akaike, H. (1974). A New Look at the Statistical Model Identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723. DOI: 10.1109/TAC.1974.1100705
- Jobson, J. D. (1991). Multiple Linear Regression. 219–398. DOI: 10.1007/978-1-4612-0955-3_4.
- Amat Rodrigo, J. (2020). GAMLSS: modelos aditivos generalizados para posición, escala y forma.
- Ancapichún, P., & Garcés, L. (2015). La influencia del Anticiclón Subtropical del Pacífico Sudeste en las precipitaciones de la zona central de Chile. *Revista Geográfica de Chile*, 72(2), 161-177.
- Bean, B. L., & Watts, E. (2024). Quantifying the impact of rain-on-snow induced flooding in the Western United States. *Water*, 16, 2826. <https://doi.org/10.3390/w16192826>
- Brown Manrique, O., Gallardo Ballat, Y., Correa Santana, A., & Barrios García, S. (2015). El cambio climático y sus evidencias en las precipitaciones. *Ingeniería Hidráulica y Ambiental*, 36(1). Recuperado de http://www.scielo.sld.cu/scielo.php?script=sci_arttext&pid=S1680-03382015000100007
- Centro de Ciencia del Clima y la Resiliencia (CR)2. (2015). *Cambio climático en Chile: Impactos y adaptación*. Ministerio del Medio Ambiente, Gobierno de Chile.
- Cohen, J., Ye, H., & Jones, J. (2015). Trends and variability in rain-on-snow events. *Geophysical Research Letters*. <https://doi.org/10.1002/2015GL065320>
- Draper, N. R., & Smith, H. (1998). *Applied Regression Analysis* (3rd ed.). Wiley.
- Escobar, G., & Aceituno, P. (1998). Interannual variability of winter precipitation in central Chile: The influence of ocean-atmosphere anomalies. *Journal of Climate*.
- Garreaud, R., Alvarez-Garreton, C., Barichivich, J., Pablo Boisier, J., Christie, D., Galleguillos, M., ... & Zambrano-Bigiarini, M. (2017). The 2010–2015 megadrought in central Chile: Impacts on regional hydroclimate and vegetation. *Hydrology and Earth System Sciences*, 21(12), 6307-6327.
- Hernandez, M., et al. (2022). Influence of ENSO on hydrological variables in central Chile. *Hydrology and Earth System Sciences*.
- Hotovy, O., Nedelcev, O., Seibert, J., & Jenicek, M. (2024). Rain-on-snow events in mountainous catchments under climate change. *EGUSPHERE*. <https://doi.org/10.5194/egusphere-2024-2274>
- Ibáñez Asensio, S., Moreno Ramón, H., & Gisbert Blanquer, J. M. (2011). Métodos para la determinación del tiempo de concentración (tc) de una cuenca hidrográfica.
- Jobson, J. D. (1991). Multiple Linear Regression. 219–398. DOI: 10.1007/978-1-4612-0955-3_4.
- Jovel, J. R. (1989). *Los Desastres naturales y su incidencia económico-social*, tesis.
- Jozaghi, A., Shen, H., Ghazvinian, M., Seo, D. J., Zhang, Y., Welles, E., & Reed, S. (2021). Multi-model streamflow prediction using conditional bias-penalized multiple linear regression. *Stochastic Environmental Research and Risk Assessment*, 35(11), 2355–2373. DOI: 10.1007/s00477-021-02048-3.
- Legates, D. R., & McCabe, G. J. (1999). Evaluating the use of "goodness-of-fit" measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, 35(1), 233–241.
- Marks, D., & Dozier, J. (1998). The sensitivity of snowmelt processes to climate conditions and forest cover during rain-on-snow events. *Hydrological Processes*. [https://doi.org/10.1002/\(SICI\)1099-1085\(199808/09\)12:10/11](https://doi.org/10.1002/(SICI)1099-1085(199808/09)12:10/11)


- McCabe, G. J., & Clark, M. P. (2007). Trends in rain-on-snow events in the western United States. *American Meteorological Society*.
- Mendoza, P. A., Wood, A. W., Clark, E., Rothwell, E., Clark, M. P., Nijssen, B., ... Arnold, J. R. (2017). An intercomparison of approaches for improving operational seasonal streamflow forecasts. *Hydrology and Earth System Sciences*, 21(7), 3915–3935. DOI: 10.5194/hess-21-3915-2017.
- Montalva Meza, J. (2022). Estudio de Tele conexión entre Caudal Estacional y Variables Climatológicas e Hidrometeorológicas en la cuenca alta del Río Maipo para su aplicación en Modelo de Pronóstico Estacional. Universidad Técnica Federico Santa María.
- Mosley, M. P., & McKerchar, A. I. (1993). Streamflow. In D. R. Maidment (Ed.), *Handbook of Hydrology* (pp. 8.1-8.39). McGraw-Hill.
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models of principles. *Journal of Hydrology*, 10(3), 282–290.
- Papacharalampous, G. A., & Tyralis, H. (2018). Evaluation of random forests and Prophet for daily streamflow forecasting. *Advances in Geosciences*, 45, 201–208. DOI: 10.5194/adgeo-45-201-2018.
- Peña, R., & Vidal, P. (1993). Estimación estadística de la línea de nieve durante los eventos de precipitación entre las latitudes 28 y 38 grados sur. *Sociedad Chilena de Ingeniería Hidráulica XI Congreso Chileno*, SOCHID.
- Rasmussen, R., Liu, C., & Ikeda, K. (2018). Rain-on-snow flood risk in western North America: A high-resolution climate model analysis. *Nature Climate Change*. <https://doi.org/10.1038/s41558-018-0236-4>
- Risbey, J. E., & Kandlikar, M. (2007). Trends in the mean and extremes of global precipitation: Observations and modeling. *Geophysical Research Letters*.
- Rootzén, H., & Katz, R. W. (2013). Design Life Level: Quantifying risk in a changing climate. *Water Resources Research*. <https://doi.org/10.1002/wrcr.20425>
- Seguel, R., & Stowhas, P. (1985). Estimación de crecidas de diseño en cuencas mixtas Pluvio-Nivales. *Sociedad Chilena de Ingeniería Hidráulica VII Congreso Nacional*, SOCHID.
- Soto Mueña, A. (2022). Inundaciones históricas y medidas de mitigación estructural en cuencas andinas de Chile Centro-Sur: Río Maule y Río Cautín, Tesis.
- Spearman, C. (1904). The proof and measurement of association between two things. *The American Journal of Psychology*, 15(1), 72–101.
- Témez, J. R. (1978). Modelo matemático de transformación de lluvia en escorrentía. Dirección General de Carreteras, Centro de Estudios Hidrográficos, CEDEX.
- Villarreal Jiménez, J. (2013). Tendencias climáticas en Chile: Análisis de la temperatura mínima y su relación con los eventos extremos. Universidad de Chile.
- Vogel, R. M., & Fennessey, N. M. (1994). Flow duration curves II: A review of applications in water resources planning. *Water Resources Bulletin*, 30(6), 1029-1039.
- Zúñiga, M., & Jara, D. (2017). Estimación de la línea de nieves utilizando técnicas de percepción remota, entre -28° y 36° de latitud ¿Qué ha pasado desde Peña y Vidal? *Sociedad Chilena de Ingeniería Hidráulica XIII Congreso Chileno de Ingeniería Hidráulica*, SOCHID.

8. Anexo


A. Análisis exploratorio de crecidas para periodos de meses con menor correlación




Anexo 1. Algunos eventos de crecida con datos de caudal, temperatura índice y precipitación - Análisis de todo el registro



Anexo 2. Algunos eventos de crecida con datos de caudal, temperatura índice y precipitación - Análisis de meses Mayo-Agosto




Anexo 3. Algunos eventos de crecida con datos de caudal, temperatura índice y precipitación - Análisis de meses Junio-Agosto




Anexo 4. Algunos eventos de crecida con datos de caudal, temperatura índice y precipitación - Análisis de meses Mayo-Julio


B. Análisis estacional – Gráficos tipo Pairwise Scatter Plot para periodos de meses con menos correlación



Anexo 5. Pairwise Scatter Plot para el análisis del periodo Mayo-Agosto




Anexo 6. Pairwise Scatter Plot para el análisis del periodo Junio-Agosto




Anexo 7. Pairwise Scatter Plot para el análisis del periodo Mayo-Julio


C. Modelo Lineal Multivariado – Modelos con combinaciones de predictores con menor AIC




Anexo 8. Ajuste modelo para Precipitación y Temperatura día del evento




Anexo 9. Ajuste modelo para Precipitación acumulada 1 día antes y Temperatura día del evento




Anexo 10. Ajuste modelo para Precipitación acumulada 2 días antes y Temperatura día del evento




Anexo 11. Ajuste modelo para Precipitación día del evento y Temperatura media 1 día antes del evento




Anexo 12. Ajuste modelo para Precipitación acumulada y Temperatura media 1 día antes del evento




Anexo 13. Ajuste modelo para Precipitación acumulada 3 días y Temperatura media 1 día antes del evento




Anexo 14. Ajuste modelo para Precipitación acumulada 3 días y Temperatura media 1 día antes del evento




Anexo 15. Ajuste modelo para Precipitación día del evento y Temperatura media 2 días antes del evento




Anexo 16. Ajuste modelo para Precipitación acumulada 1 día y Temperatura media 2 días antes del evento




Anexo 17. Ajuste modelo para Precipitación acumulada y Temperatura media 2 días antes del evento




Anexo 18. Ajuste modelo para Precipitación acumulada 3 días y Temperatura media 2 días antes del evento




Anexo 19. Ajuste modelo para Precipitación día del evento y Temperatura media 3 días antes del evento



Anexo 20. Ajuste modelo para Precipitación acumulada 1 día y Temperatura media 3 días antes del evento




Anexo 21. Ajuste modelo para Precipitación acumulada 2 día y Temperatura media 3 días antes del evento




Anexo 22. Ajuste modelo para Precipitación acumulada y Temperatura media 3 días antes del evento


D. Modelos GAMLSS – Modelos con enfoques distintos y menor AIC




Anexo 23. Ajuste lineal del modelo para el enfoque de Gamma General



Anexo 24. Ajuste lineal del modelo para el enfoque Normal



Anexo 25. Ajuste lineal del modelo para el enfoque de Weibull



Anexo 26. Ajuste lineal del modelo para el enfoque Log-Normal