

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXVII CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

**PRONÓSTICO DE SEQUÍAS HIDROLÓGICAS. CASO DE ESTUDIO: CUENCA
DEL RÍO HURTADO, EN ANGOSTURA DE PANGUE**

MISAE LUKINOVIC M.¹
MAURICIO ROMERO S.²
PABLO MENDOZA Z.³
FELIPE GATEÑO M.⁴

RESUMEN

Desde la creciente vulnerabilidad hídrica de la cuenca del río Hurtado, en la Región de Coquimbo, intensificada por una megasequía persistente desde el año 2010, este estudio propone un marco metodológico integral para el pronóstico de sequías. La metodología considera índices de sequía, como el Standardized Streamflow Index para 1 mes (SSI-1) y banderas de sequía (DF), con predictores móviles agregados a 12 meses, incluyendo precipitación, evapotranspiración potencial, balance hídrico, índice de aridez y temperatura máxima. Para pronosticar los indicadores de sequía se ajustaron y compararon, por un lado, modelos para el SSI-1, tanto lineales (ARMA, ARIMA, SARIMA) como de aprendizaje automático (Random Forest) y, por otro lado, un modelo GLM logístico binomial para la Drought Flag (DF). Todos los modelos se evaluaron bajo esquemas de validación robustos: *roll-origin* con una ventana de entrenamiento inicial del 60 % y horizonte de predicción de de uno a seis meses. Los resultados destacan el desempeño óptimo de los modelos ARIMA, mientras que Random Forest permite pronósticos con mayor antelación, aunque con limitaciones para capturar la severidad de las sequías extremas. El modelo GLM logístico binomial, por su parte, sobresale en la detección de eventos críticos, con métricas óptimas. Estos hallazgos subrayan la importancia de integrar enfoques estadísticos diversos para mejorar el pronóstico de sequías.

¹ Ingeniero Civil, Departamento de Ingeniería Civil, Universidad de Chile - email: mlukinovic@ing.uchile.cl

² Ingeniero Civil, Departamento de Ingeniería Civil, Universidad de Chile – email: mauricioromero@ug.uchile.cl

³ Profesor de cátedra, Departamento de Ingeniería Civil, Universidad de Chile – email: pamendoz@uchile.cl

⁴ Ingeniero Civil, Departamento de Ingeniería Civil, Universidad de Chile – email: felipe.gateno@ug.uchile.cl

1. INTRODUCCIÓN

Las sequías hidrológicas, caracterizadas por un desarrollo imperceptible y una persistente duración, ocasionan pérdidas humanas y económicas significativas en sectores tan diversos como el abastecimiento de agua potable, transporte fluvial, y generación hidroeléctrica (Turner et al., 2021). Frente a este escenario, varios países han implementado sistemas de alerta temprana y optimizado sus pronósticos meteorológicos de sequía con plazos de aviso cada vez más cortos; sin embargo, muchos de los impactos más críticos responden directamente a la escasez de caudales fluviales, lo que subraya la necesidad de contar con herramientas específicas para anticipar y mitigar déficits hídricos (Sutanto et al., 2024).

En la zona del Norte Chico de Chile, la megasequía de la última década ha reducido la precipitación en hasta un 40 % y ha dejado niveles de caudal históricamente bajos (Garreaud et al., 2017). Esta diversidad de regímenes, que va desde cuencas áridas de baja altitud hasta valles nival-pluviales por sobre los 4.000 m.s.n.m., dificulta la caracterización uniforme de la distribución, duración e intensidad de las sequías, así como su propagación desde el déficit pluviométrico hasta sus manifestaciones hidrológicas (Vega-Briones et al., 2023).

Para abordar esta complejidad, se han popularizado diversos índices de sequía, sin embargo, su desempeño varía según las particularidades de cada cuenca y el horizonte temporal de análisis (O. M. Baez-Villanueva et al., 2024; Bevacqua et al., 2021). En consecuencia, no existe un indicador único que funcione de manera óptima en todos los contextos, y los estudios disponibles suelen carecer de un consenso metodológico claro y de descripciones detalladas sobre la configuración de los modelos predictivos (Ó. Baez-Villanueva et al., 2024). Esta ausencia de estándares dificulta la aplicación práctica en la gestión de embalses y sistemas de riego, donde la replicabilidad y la escalabilidad son fundamentales (Alvarez-Garretón et al., 2023).

El presente estudio aborda esta brecha proponiendo un marco integral para evaluar y seleccionar índices de sequía, junto con el desarrollo de modelos de pronóstico hidrológico robustos y replicables. Como caso de aplicación, se analiza la cuenca del río Hurtado en la angostura de Pangue (parte esencial del sistema de riego La Paloma), cuyo recurso hídrico es vital para la producción agrícola de la región de Coquimbo.

2. ZONA DE ESTUDIO

El área de estudio abarca la cuenca del río Hurtado, delimitada en su salida por la estación la Angostura de Pangue, con una superficie total de 1.837 km² (véase Figura 1). Administrativamente, la cuenca se encuentra principalmente en la comuna de Río Hurtado, con una pequeña porción en la comuna de Ovalle, ambas en la provincia de Limarí, Región de Coquimbo. La estación Angostura de Pangue, se emplaza en un estrechamiento natural del cauce con afloramientos rocosos que permite monitorear la serie de caudales aguas abajo (Cartes Martínez & Ureta Parraguez, 2009). Esta estación monitorea el régimen de caudales en la cuenca intermedia y cumple un rol esencial en el balance hídrico del valle, debido a que la estación situada en el ingreso al embalse presenta inconsistencias en sus registros y ha cesado su operación. (Ministerio de agricultura, 2025).

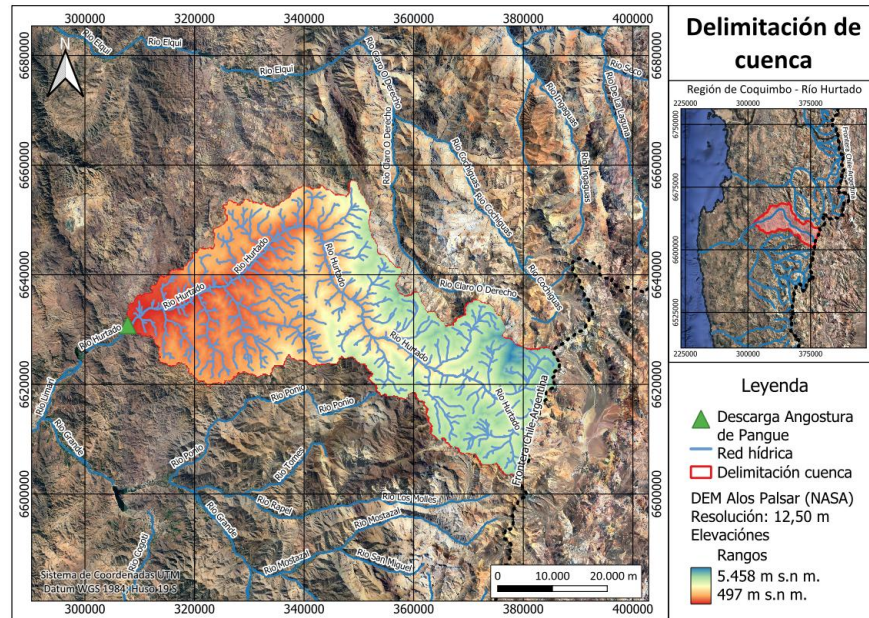


Figura 1. Ubicación geográfica, delimitación de la cuenca y red hídrica del río Hurtado, con cierre en la estación hidrométrica Angostura de Pangué

Desde 2010, Chile ha enfrentado una denominada megasequía, la más extensa y severa de su historia, caracterizada por precipitaciones hasta un 40 % por debajo de lo normal, especialmente en la región de Coquimbo (Arias Rodriguez, 2021). En los últimos años, la Dirección General de Aguas (DGA) ha manifestado que Coquimbo es una de las regiones con mayor riesgo hídrico. Lo anterior, tomando en cuenta que sus cuencas han presentado un déficit cercano a los 40 m³/s y que, a su vez, se podría acentuar hacia el año 2050 con un déficit del orden de 95 m³/s (Stehr, 2019).

En la Angostura de Pangué, un sector crítico de la cuenca del río Hurtado, la mega sequía ha provocado una drástica disminución del caudal, con tramos casi secos y precipitaciones extremadamente bajas (6,1 mm/año en 2021). Esta reducción hídrica ha afectado gravemente sistemas de Agua Potable Rural y actividades agrícolas, especialmente durante el período 2021–2024, donde se registraron caudales mínimos históricos asociados a déficit de nieve y lluvias. El impacto ha sido calificado por las autoridades locales como “un terremoto” hídrico, evidenciando el carácter excepcional y crítico del fenómeno (Ministerio de agricultura, 2025).

3. DATOS Y MÉTODOS

A continuación, se presentan las fuentes de información y las metodologías empleadas para responder la pregunta científica que guía este estudio: ¿Qué nivel de precisión pueden alcanzar distintos modelos en el pronóstico de sequías hidrológicas, al utilizar diversos índices hidrológicos en la cuenca del río Hurtado? En la Figura 2 se muestra el flujo general de la investigación:

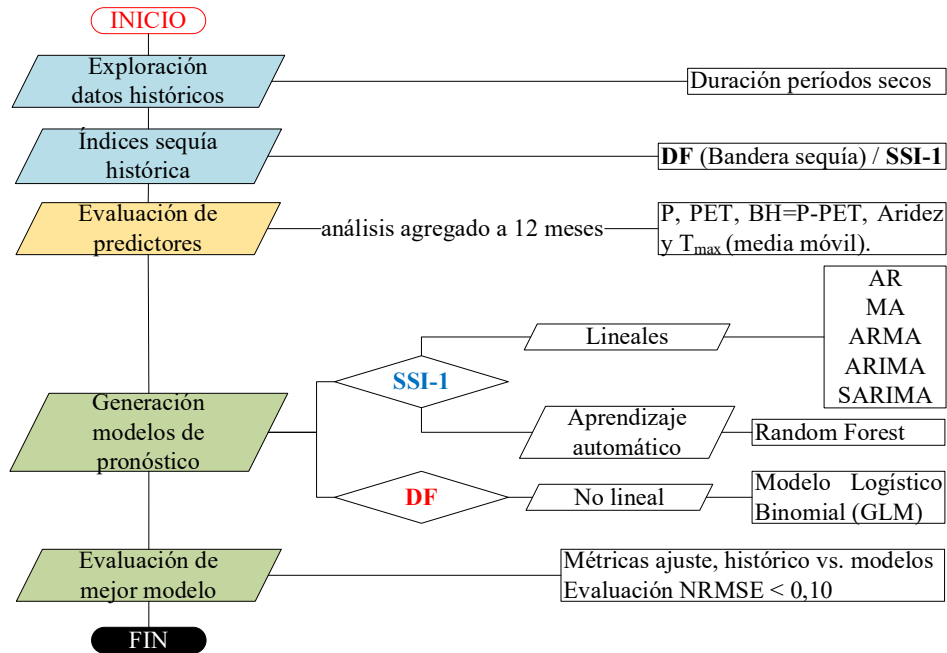


Figura 2. Flujo de investigación para la Generación y Evaluación de Modelos de Pronóstico de Sequías

3.1. Datos

Se utilizaron datos hidrometeorológicos disponibles en la plataforma CAMELS-CL, la cual integra registros del sistema CR2MET para diversas cuencas de Chile. En particular, se descargaron los datos correspondientes a la cuenca del río Hurtado en Angostura de Pangué (código 4503001), incluyendo series mensuales que fueron empleadas como predictores: precipitación (P), temperatura máxima (T_{max}), índice de aridez (Aridez), evapotranspiración potencial (PET) y caudal en el punto de control (Q). El periodo de estudio estuvo determinado por la disponibilidad de datos de caudal, abarcando desde el 1 de abril de 1979 hasta el 31 de marzo de 2020. Según los datos de CAMELS-CL, se puede inferir que el régimen hidrológico es predominantemente pluvial.

3.2. Métodos

En la presente subsección se detallan los métodos y modelos empleados en el desarrollo de esta investigación:

a. Hipótesis

La hipótesis de esta investigación sostiene que los modelos estadísticos de pronóstico de sequías mediante índices hidrológicos no logran un nivel de precisión aceptable para anticipar con un mes de antelación la ocurrencia de sequías hidrológicas en la cuenca estudio, ya que no alcanzan un desempeño inferior a $NRMSE < 0,10$ (modelo óptimo).

b. Exploración de datos históricos

Se consolidaron todas las variables en una única serie temporal, interpolando los vacíos en los registros de caudal. Se calcularon estadísticas descriptivas mensuales y globales, y se depuró la serie de caudales mediante la eliminación de valores atípicos superiores a $50 \text{ m}^3/\text{s}$,

correspondientes al percentil 99. Para cada mes se estimaron las anomalías restando la climatología (media histórica) al valor observado, lo que permitió identificar eventos extremos de sequía definidos como aquellos por debajo del percentil 10.

Las sequías se definieron como periodos de al menos dos meses consecutivos con anomalías negativas en caudal, es decir, definidos por valores inferiores al percentil 20. Para cada evento detectado se estimaron su frecuencia, duración y magnitud. Asimismo, se compararon distintos escenarios asociados a condiciones secas y se caracterizó la distribución de la duración de los periodos secos continuos.

c. Índices de sequía histórica

Standardized Streamflow Index (SSI)

El SSI es un índice de sequía ampliamente utilizado, especialmente para evaluar la severidad de la sequía hidrológica (Sutanto & Van Lanen, 2022). Para el cálculo del SSI se utiliza datos de caudal observados o simulados, este concepto se ejemplifica en la ecuación (1), el cual deriva de la metodología subyacente de cálculo del índice SPI (McKee, 1993).

$$SSI_i = \Phi^{-1}(G(Q_i)) \quad (1)$$

Donde:

- Q_i es el caudal observado en el mes i
- $G(\cdot)$ es la función de distribución acumulada de la serie de caudales, obtenida al ajustar los datos a una distribución Gamma
- $\Phi^{-1}(\cdot)$ es la inversa de la función de distribución acumulada de la normal estándar.

Se evaluaron gráficamente los índices en escalas de 1–24 meses, identificando al SSI-1 como el más sensible para activar oportunamente planes de mitigación en embalses y sistemas de almacenamiento agrícola.

Drought Flags (DF)

Corresponde a un indicador binario, de 0 o 1, que refleja la ocurrencia o no ocurrencia de sequía en un periodo determinado. Se genera a partir de la aplicación de un umbral sobre una serie de caudales, asignando valores de 1 (sequía) o 0 (ausencia de sequía). Este enfoque ha sido ampliamente utilizado en modelos probabilísticos, orientados a caracterizar la persistencia estacional de la sequía (Van Huijgevoort, 2012).

En la práctica, el indicador DF identifica la ocurrencia de sequía cuando el caudal mensual se mantiene igual o por debajo de su percentil 20 durante al menos dos meses consecutivos. Formalmente, esta variable binaria se expresa en la ecuación (2).

$$DF = \begin{cases} 1, & \text{si } Q_{i-1} \leq Q_{P20} \wedge Q_i \leq Q_{P20} \\ 0, & \text{en otro caso} \end{cases} \quad (2)$$

Donde Q_{P20} corresponde al percentil 20 de la serie histórica de caudales.

La señal binaria permite modelar la probabilidad de ocurrencia de sequía mediante una regresión logística. En este estudio, se aplicó el enfoque basado en el indicador DF para identificar la condición de sequía dentro de la cuenca analizada.

d. Evaluación de predictores

En primer lugar, se realizó una caracterización estadística integral del predictando SSI-1. Posteriormente, para evaluar el comportamiento de los predictores en relación con el SSI-1, se analizó la correlación entre las variables climatológicas. Se seleccionaron como predictores potenciales las sumas móviles de 12 meses de precipitación $P_{acum}(12)$, evapotranspiración potencial $PET(12)$ y balance hídrico $BH(12)=P(12) - PET(12)$, así como la Aridez(12) estimada a partir de estas variables. Para la temperatura máxima $T_{max}(12)$ y media $T_{med}(12)$, se empleó una media móvil de 12 meses. Estos predictores fueron sincronizados temporalmente con los valores del SSI-1 y se estimó el coeficiente de determinación (R^2) y la correlación de Spearman (ρ) en cada comparación.

Para evaluar posibles desviaciones de la linealidad, se aplicó la prueba de no-aditividad de Tukey (Tukey, 1949). Este análisis, se complementó con un examen de curvatura de los residuos del modelo lineal, evaluando gráficamente la dispersión de los residuos frente a cada predictor para detectar patrones sistemáticos no capturados por la forma lineal. Es importante mencionar que frente a ciertos predictores de carácter no lineal, se consideró el uso de splines cuadráticos al generar los modelos de pronóstico.

Se desestimó realizar el mismo análisis de predictores con el DF, ya que, al ser un indicador binario, de 0 o 1, no se adapta a ninguno de los predictores utilizados.

e. Generación modelos de pronóstico

Modelos de pronóstico SSI-1 - Estructuras lineales de tiempo

La familia de modelos autorregresivos de medias móviles (ARMA) y sus extensiones integradas (ARIMA, SARIMA) constituyen un marco robusto para el pronóstico de series temporales que combinan dependencias temporales y fluctuaciones estocásticas (Arumugam & Natarajan, 2023). Para encontrar el mejor modelo se efectuó un método de búsqueda por medio de la librería *auto.arima*, luego se usó validación cruzada para evaluar el modelo en búsqueda de un óptimo.

El mejor resultado, se obtiene mediante el modelo ARIMA(p,d,q), el cual tiene la forma que se muestra en la ecuación (3).

$$(1 - B)^d X_t = c + \sum_{i=1}^p \phi_i * (1 - B)^d * X_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j * \varepsilon_{t-j} \quad (3)$$

Donde:

- p es el orden autoregresivo.
- q el orden de media móvil
- d el orden de diferenciación
- ε_t es ruido blanco.
- B es el operador de rezago

Modelos de pronóstico SSI-1 – Aprendizaje automático Random Forest

Para modelar SSI se emplea un modelo Random Forest (RF), que hace un ensamblaje de B árboles de regresión entrenados sobre muestras bootstrap del conjunto de datos. Cada árbol crece de forma no podada, seleccionando en cada nodo un subconjunto aleatorio de m predictores incluyendo variables móviles a 12 meses (balance hídrico, precipitación, PET, aridez, temperatura máxima), de modo que el corte óptimo minimice el error cuadrático medio local (A Alshahrani et al., 2024). Para un vector de predictores x, la predicción agregada del SSI se calcula siguiendo la ecuación (4).

$$SSI(x) = \frac{1}{B} * \sum_{b=1}^B T_b(x) \quad (4)$$

Donde: $T_b(x)$ es la predicción del árbol b.

Los parámetros clave son el número de árboles B, número de variables por división m y profundidad máxima, se optimizaron mediante validación cruzada bloqueada en tiempo (k = 5) y validación roll-origin (h = 1 mes, con 60 % inicial de la serie). El desempeño se evaluó con NRMSE y R^2 sobre las predicciones acumuladas.

Modelos de pronóstico DF – Logístico binomial GLM

Para la predicción de la drought flag mensual se empleó un modelo logístico binomial (GLM), lo que introduce una relación no lineal entre las covariables y la probabilidad de sequía (Lee et al., 2024). Sea y_t la bandera (1 = sequía, 0 = no sequía) y X_t el vector de predictores, se emplean las ecuaciones (5) y (6).

$$\log\left(\frac{P_t}{1 - P_t}\right) = \beta_0 + \sum_{i=1}^k \beta_i * X_{i,t} \quad (5)$$

$$P_t = Pr(y_t = 1) = \frac{1}{1 + e^{-(\beta_0 + \sum_i \beta_i X_{i,t})}} \quad (6)$$

Se mapea de forma no lineal el predictor lineal η al rango (0,1). Los coeficientes $\{\beta_i\}$ se estimaron por máxima verosimilitud, y su significancia se evaluó con pruebas de razón de verosimilitudes y Wald (χ^2). Para evitar filtraciones temporales y capturar la dinámica real, la validación se realizó con cross-validation bloqueada en el tiempo (k = 5) y roll-origin (h=1 mes), midiendo desempeño con F₁-score, RMSE y R^2 sobre datos fuera de muestra. Finalmente, la capacidad de clasificación del modelo se mejoró aplicando un umbral de probabilidad escalonado (Step-Function) fijado en 0,33. El F₁-score es una métrica particular del GLM realizada para modelos de sequía binarios, mide el equilibrio entre precisión (precision) y la tasas de verdaderos positivos (recall) en clasificación binaria. Se define como la media armónica de ambos, como se expresa en la ecuación (7).

$$F_1 = \frac{2 * TP}{2 * TP + FP + FN} \quad (7)$$

Donde T_p , FP y FN son verdaderos positivos y falsos negativos, respectivamente. Un $F_1=1$ indica perfecta precisión y recobrado; $F_1=0$ señala que bien precision o recall es cero. Los modelos descritos fueron calibrados y validados para emitir pronósticos con un horizonte de un mes respecto de la última observación disponible.

f. Evaluación de mejor modelo


Para evaluar el rendimiento predictivo se calculó como métrica principal el error cuadrático medio normalizado (NRMSE), el coeficiente de ajuste (R^2) y para el modelo GLM el F_1 -score comparando las modelaciones contra los índices históricos.

4. RESULTADOS

Se presentan los resultados del diagnóstico integral de la serie SSI-1:

- La descomposición estacional (STL) mostró oscilaciones multianuales y un descenso suave desde comienzos de los 2000; la estacionalidad es débil y estable en torno al cero con un patrón constante. En términos inferenciales, la prueba de Dickey–Fuller aumentada (ADF) sugiere estacionariedad ($p = 0,01$), mientras que la prueba de Pettitt detecta un quiebre estructural en 2009 ($p = 5,49 \times 10^{-11}$).
- La tendencia es negativa según Mann–Kendall ($\tau = -0,178$; $p = 3,7 \times 10^{-9}$) y la pendiente de Theil–Sen es $-0,0014$ SSI/mes, sin embargo, la ruptura estructural de 2009 puede sesgar esta inferencia; en este estudio se mantuvo un enfoque clásico y no se modeló explícitamente dicha ruptura.
- La ACF decae sin picos en los primeros 12 rezagos y la PACF corta en el rezago 1; existe persistencia en la serie y para efectos prácticos, en el análisis se incluye la diferenciación en un orden.
- Los residuos cumplen la hipótesis de ruido blanco según Box–Ljung a 12 y 24 meses ($p = 0,948$; $0,56$) y no evidencian heterocedasticidad de acuerdo con Breusch–Pagan ($p = 0,322$).
- Finalmente, los residuos no se ajustan a normalidad según Shapiro–Wilk ($p = 5,46 \times 10^{-23}$), lo que respalda el uso de métodos no paramétricos y de inferencia para la exploración inicial.

En la Figura 3 se muestran los resultados de la evaluación de predictores:



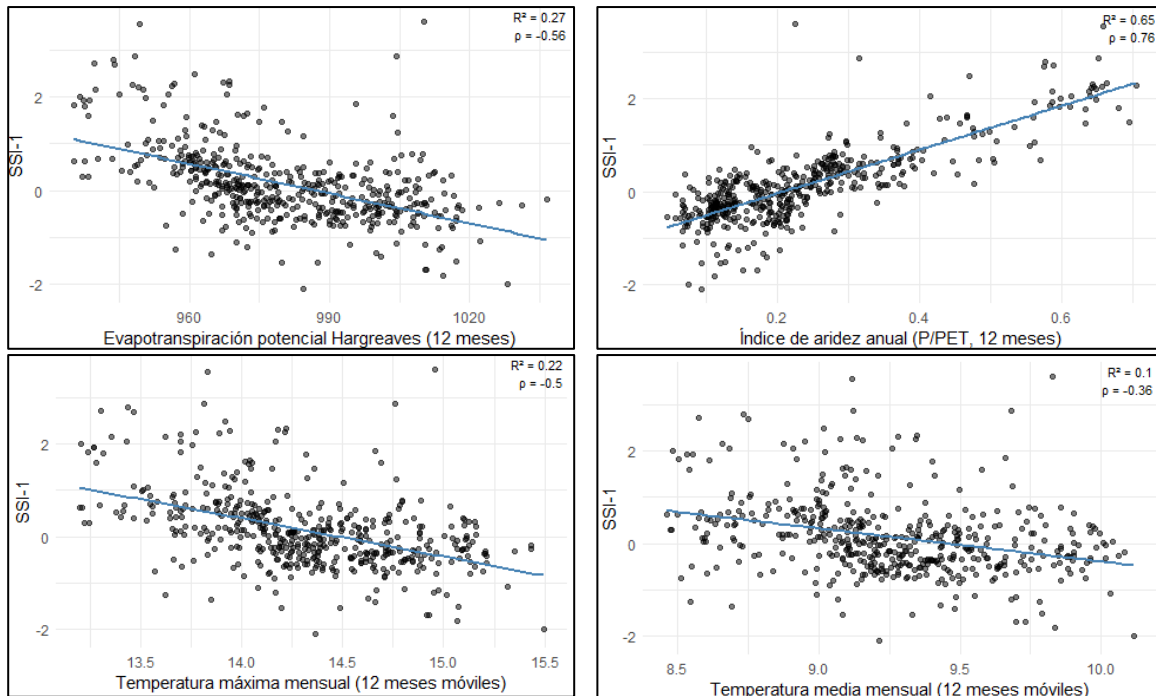


Figura 3. Relación entre índice SSI-1 y predictores considerados

En el Test de Tukey, se identificó que existe evidencia estadísticamente significativa de no linealidad global ($p < 0,001$) de los predictores. A nivel de predictores individuales, según el análisis de curvatura de residuos, se identificaron relaciones no lineales significativas ($p < 0,05$) entre el SSI-1 y cuatro variables; $BH(12)$, $P_{acum}(12)$, $Aridez(12)$. En cuanto a los resultados, se seleccionó el modelo lineal ARIMA(0,1,2), que incorpora una diferenciación de orden 1 para abordar el quiebre estructural presente, sin incluir componentes autoregresivos, pero sí una parte de media móvil de orden 2, representativa de patrones detectados en la serie, lo que le confiere un ajuste óptimo ($NRMSE < 0,1$) a lo largo de todo el rango de valores del SSI-1. En contraste, el modelo basado en Random Forest, aun cuando alcanza métricas igualmente óptimas, subestima los eventos de sequía media/severa ($SSI-1 < -1$). En la Figura 4 y Figura 5 se muestran los resultados de los modelos de pronóstico ARIMA (0,1,2) y Random Forest respectivamente:




Figura 4. Modelo de pronóstico ARIMA (0,1,2) a un mes de adelanto ($H=1$)




Figura 5. Modelo de pronóstico Random Forest a un mes de adelanto (H=1)

En el caso del modelo GLM binomial de pronóstico para las Drought Flags (DF), se obtuvieron métricas óptimas ($F_1=0,76$), lo que evidencia la capacidad robusta para detectar la ocurrencia de sequías. A continuación, se presenta los resultados del modelo:

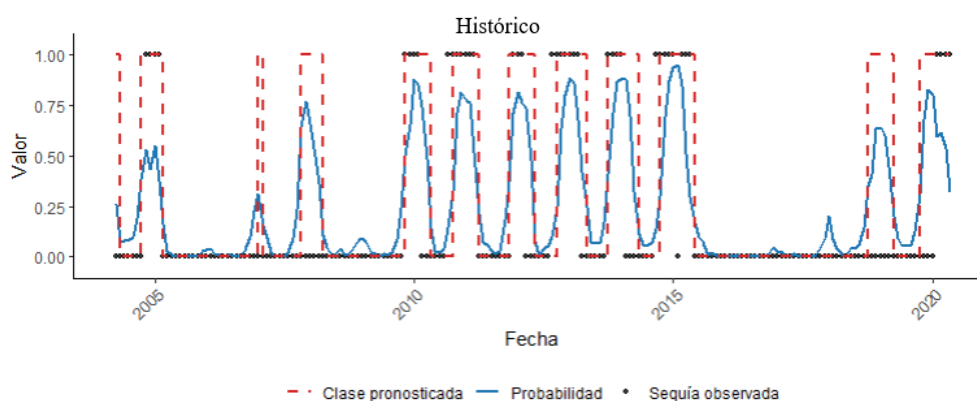


Figura 6. Modelo de pronóstico GLM binomial a un mes de adelanto (H=1)

Finalmente, en la Tabla 1, se muestran las métricas de evaluación de los modelos:

Tabla 1: Métricas de validación de los modelos de pronóstico

Tiempo de adelanto	Tipo de Modelo	Métricas en validación		
		Roll-Origin		
		R ²	NRMSE	F ₁
H=1 mes	ARIMA (0,1,2)	0,58	0,082	-
	Random Forest	0,44	0,089	-
	GLM Binomial	-	-	0,76
H=3 meses	ARIMA (0,1,2)	0,12	0,134	-
	Random Forest	0,47	0,091	-
	GLM Binomial	-	-	0,72
H=6 meses	ARIMA (0,1,2)	0,01	0,145	-
	Random Forest	0,45	0,103	-
	GLM Binomial	-	-	0,66

Por los resultados obtenidos, se rechaza hipótesis nula de la investigación, al haber obtenido modelos de pronósticos con métricas $NRMSE < 0,10$ o $F_1 > 0,70$ hasta incluso con un tiempo de adelanto de 3 meses. En consecuencia, existen modelos que permitan tener pronósticos óptimos de las sequías en la zona de estudio.

5. CONCLUSIONES

Este estudio se evaluaron modelos de pronóstico de sequías para la cuenca del río Hurtado en Angostura de Pangué. A continuación, se presentan las principales conclusiones:

- Los predictores más efectivos para los índices de sequía son aquellos que capturan la disponibilidad y la demanda climática reciente de agua. En particular las sumas móviles de 12 meses de precipitación $P_{acum}(12)$, evapotranspiración potencial PET(12), balance hídrico meteorológico BH(12) e Índice de Aridez(12) destacan como los mejores al tener un coeficiente R^2 óptimo situado entre 0,77 y 0,76.
- El modelo de pronóstico ARIMA (0,1,2) se posiciona como el enfoque más confiable para pronósticos con un mes de adelanto, gracias a su buen ajuste (NRMSE < 8 %); no obstante, su rendimiento disminuye notablemente con plazos mayores.
- El modelo Random Forest destaca por ofrecer rendimientos óptimos hasta 3 meses y aceptables hasta 6 meses de adelanto, aunque presenta limitaciones para predecir eventos extremos de sequía (SSI-1 < -1).
- El modelo de pronóstico GLM binomial, cuenta con un rendimiento óptimo en relación con la métrica F₁-score (0,76) y se mantiene hasta en 3 meses de adelanto, decayendo gradualmente a plazos mayores.
- Desde los resultados se desprende que es conveniente combinar los enfoques para pronosticar adecuadamente la ocurrencia y la severidad de las sequías en la zona de estudio.

AGRADECIMIENTOS

Se agradece al cuerpo docente del Departamento de Ingeniería Civil de la Universidad de Chile por el apoyo al elaborar esta investigación.

REFERENCIAS

- A Alshahrani, M., Laiq, M., Noor-ul-Amin, M., Yasmeen, U., & Nabi, M. (2024). A support vector machine based drought index for regional drought analysis. *Scientific Reports*, 14(1), 1–12. <https://doi.org/10.1038/s41598-024-60616-3>
- Alvarez-Garreton, C., Boisier, J. ., Blanco, G., Billi, M., Nicolas-Artero, C., Maillet, A., Aldunce, P., Urrutia-Jalabert, R., Zambrano-Bigiarini, M., Guevara, G., Galleguillos, M., Muñoz, A., Marinao, R., & Garreaud, R. (2023). Seguridad Hídrica en Chile: Caracterización y Perspectivas de Futuro. Centro de Ciencia del Clima y la Resiliencia CR2. (Anid/Fondap/1522a0001), 3–6. www.cr2.cl/seguridadhidrica
- Arias Rodriguez, O. (2021). La Mega Sequía en Chile (2010-2020): Una revisión general de la catástrofe. *Revista de Indagación Científica Nothofagus*, 6, 2021.
- Arumugam, V., & Natarajan, V. (2023). Time Series Modeling and Forecasting Using Autoregressive Integrated Moving Average and Seasonal Autoregressive Integrated Moving Average Models. *Instrumentation Measure Metrologie*, 22(4), 161–168. <https://doi.org/10.18280/i2m.220404>
- Baez-Villanueva, O. M., Zambrano-Bigiarini, M., Miralles, D. G., Beck, H. E., Siegmund, J. F., Alvarez-Garreton, C., Verbist, K., Garreaud, R., Boisier, J. P., & Galleguillos, M. (2024). On the timescale of drought indices for monitoring streamflow drought considering catchment hydrological regimes. *Hydrology and Earth System Sciences*, 28(6), 1415–1439. <https://doi.org/10.5194/hess-28-1415-2024>
- Baez-Villanueva, Ó., Zambrano-Bigiarini, M., Miralles, D., Beck, H., Siegmund, J., Alvarez-

- Garretón, C., Garreaud, R., Boisier, J. P., & Galleguillos, M. (2024). *Índices de sequía para monitorear el déficit hídrico en los caudales de las cuencas de Chile*. 1–3.
- Bevacqua, A. G., Chaffe, P. L. B., Chagas, V. B. P., & AghaKouchak, A. (2021). Spatial and temporal patterns of propagation from meteorological to hydrological droughts in Brazil. *Journal of Hydrology*, 603(PA), 126902. <https://doi.org/10.1016/j.jhydrol.2021.126902>
- Cartes Martínez, M. I., & Ureta Parraguez, N. A. (2009). *Estudio preliminar para el diseño de un sistema de gestión integrado del agua de la Cuenca del río Hurtado, Región de Coquimbo* [Universidad de Chile]. <https://repositorio.uchile.cl/handle/2250/112445>
- Garreaud, R. D., Alvarez-Garretón, C., Barichivich, J., Pablo Boisier, J., Christie, D., Galleguillos, M., LeQuesne, C., McPhee, J., & 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. <https://doi.org/10.5194/hess-21-6307-2017>
- Lee, T., Kong, Y., Lee, J. H., & Won, C. H. (2024). Drought forecasting with regionalization of climate variables and generalized linear model. *Meteorological Applications*, 31(6), 1–12. <https://doi.org/10.1002/met.70016>
- McKee, T. B., Doesken, N. J., & Kleist, J. (1993). The relationship of drought frequency and duration to time scales. En *Proceedings of the 8th Conference on Applied Climatology* (pp. 179-184). American Meteorological Society.
- Ministerio de agricultura. (2025). Recursos naturales comuna del río Hurtado. *CIREN*, 1, 13.
- Stehr, A. (2019). Recursos hídricos en Chile: Impactos y adaptación al cambio climático. *Recursos Hídricos*, 14, 65. <https://www.minciencia.gob.cl/comitecientifico/documentos/ mesa-agua/19.Agua-Recursos-Hidricos-Stehr.pdf>
- Sutanto, S. J., Syaehuddin, W. A., & de Graaf, I. (2024). Hydrological drought forecasts using precipitation data depend on catchment properties and human activities. *Communications Earth and Environment*, 5(1). <https://doi.org/10.1038/s43247-024-01295-w>
- Sutanto, S. J., & Van Lanen, H. A. J. (2022). Catchment memory explains hydrological drought forecast performance. *Scientific Reports*, 12(1), 1–11. <https://doi.org/10.1038/s41598-022-06553-5>
- Tukey, J. W. (1949). One degree of freedom for non-additivity. *Biometrics*, 5(3), 232-242. <https://doi.org/10.2307/3001938>
- Turner, S., Barker, L. J., Hannaford, J., Muchan, K., Parry, S., & Sefton, C. (2021). The 2018/2019 drought in the UK: a hydrological appraisal. *Weather*, 76(8), 248–253. <https://doi.org/10.1002/wea.4003>
- Van Huijgevoort, M. H. J., Hazenberg, P., van Lanen, H. A. J., & Uijlenhoet, R. (2012). A generic method for hydrological drought identification across different climate regions. *Hydrology and Earth System Sciences*, 16, 2437-2451. <https://doi.org/10.5194/hess-16-2437-2012>
- Vega-Briones, J., de Jong, S., Galleguillos, M., & Wanders, N. (2023). Identifying driving processes of drought recovery in the southern Andes natural catchments. *Journal of Hydrology: Regional Studies*, 47(March), 101369. <https://doi.org/10.1016/j.ejrh.2023.101369>