

SOCIEDAD CHILENA DE INGENIERÍA HIDRÁULICA
XXVII CONGRESO CHILENO DE INGENIERÍA HIDRÁULICA

**ENTRENAMIENTO DE UN MODELO DE PROBABILIDAD DE OCURRENCIA
ALUVIONAL EN LA CUENCA DEL RÍO HUASCO**

MARCIA PAREDES ARAVENA¹
SANTIAGO MONTSERRAT MICHELINI²
DIEGO PINTO GARAY³
GERMÁN AGUILAR MARTORELL⁴
ALEX GARCÉS CATALÁN⁵

RESUMEN

El estudio presenta la construcción, selección, y desempeño de un modelo probabilístico para la ocurrencia aluvional (modelo PDA) en quebradas del Río Huasco. Se entrenaron 4.095 modelos de regresión logística binaria (aluvión, no aluvión) en base a cuatro eventos de tormenta y registros aluvionales ocurridos en 139 quebradas ubicadas en la cuenca alta del Río Huasco, así como diferentes combinaciones de los 12 predictores candidatos, los cuales engloban características meteorológicas y geomorfológicas del área pluvial de las quebradas. El modelo PDA seleccionado está compuesto por ocho predictores, siendo los más importantes la intensidad horaria y precipitación en 24 horas máxima durante el evento de tormenta. El modelo PDA mostró un buen desempeño en el pronóstico aluvional (precisión del 88,4% y sesgo de 0,851), encontrándose errores del pronóstico principalmente en el evento de mayo del 2017. Una de las razones que explican este comportamiento es la falta de datos meteorológicos en alta montaña para tormentas extremas en la cordillera, impactando la estimación de los predictores meteorológicos. Además, se aplica el modelo en dos quebradas de prueba ubicadas en el río Elqui y el río Lluta para evaluar el desempeño del modelo PDA fuera de su zona de entrenamiento, así como una aplicación donde se aplican los efectos del cambio climático a los predictores meteorológicos.

¹Investigadora Asociada, Advanced Mining Technology Center (AMTC) - email: marcia.paredes@amtc.uchile.cl

²Investigador Asociado, Advanced Mining Technology Center (AMTC) - email: santiago.montserrat@amtc.cl

³Investigador Asociado, Advanced Mining Technology Center (AMTC) - email: diego.pinto@amtc.uchile.cl

⁴Investigador Asociado, Advanced Mining Technology Center (AMTC) - email: german.aguilar@amtc.uchile.cl

⁵Investigador Asociado, Advanced Mining Technology Center (AMTC) - email: agarces@uchile.cl

1. INTRODUCCIÓN

En Chile, los eventos aluvionales son una amenaza natural común de gran impacto que puede generar pérdidas de vidas humanas, destrucción de infraestructura, e impactos en actividades económicas (Calvo & Savi, 2009). En particular, el norte del país es una de las zonas con el mayor número de registros de remociones en masa según los catastros de peligros geológicos desarrollados por SERNAGEOMIN (2025), con Atacama y Copiapó registrando el 34 % y 16,6 % de las observaciones totales del catastro.

Según el catastro del SERNAGEOMIN, el principal desencadenante de los aluviones en el Norte de Chile son las lluvias, capaces de activar flujos de detritos en cuencas con alta disponibilidad de sedimentos sueltos, pendientes pronunciadas y escasa vegetación, lo que favorece la movilización rápida de material (Aguilar et al., 2020). Sin embargo, las tormentas que han generado aluviones en el norte del país son en gran medida de carácter convectivo, localizadas, y de gran intensidad; estas características resultan en eventos climáticos difíciles de pronosticar (Yáñez-Morrón et al., 2018; Aceituno et al., 2021), por lo que se requieren de herramientas que permitan pronosticar la ocurrencia aluvional según los montos de precipitación esperados o teóricos para el diseño de obras.

Frente a este contexto, se vuelve fundamental contar con herramientas que permitan anticiparse a los eventos aluvionales, especialmente en las zonas montañosas del Norte de Chile. Para ello, se propone la construcción de un modelo probabilístico para la ocurrencia aluvional (PDA) entrenado con datos históricos de aluviones en quebradas del río Huasco por su gran cantidad de datos dentro de la región, usando predictores meteorológicos y geomorfológicos para determinar la ocurrencia de un evento aluvional con el objetivo de contar con un modelo aplicable a quebradas nortinas similares. Debido a la construcción del modelo, este puede ser utilizado con valores teóricos, históricos, y futuros, considerando en particular las variaciones en la precipitación en escenarios climáticos futuros.

2. ZONA DE ESTUDIO

El modelo PDA fue entrenado con datos históricos de ocurrencia aluvional en 139 quebradas ubicadas en la parte alta del río Huasco, región de Atacama (Figura 1.A). Las quebradas se localizan en las laderas de los ríos Carmen y Tránsito, aguas arriba del embalse Santa Juana, y presentan áreas menores o iguales a 20 km².

Las Figuras 1.B a la 1.E indican la ocurrencia o no ocurrencia de aluviones en cada quebrada durante cuatro eventos de tormentas de características estratiformes según los registros de SERNAGEOMIN (2025) y las campañas en terreno realizadas por Aguilar et al. (2020). Las tormentas de finales de marzo de 2015 (Figura 1.C, línea de nieves a 3.044 m s.n.m.) y mediados de mayo de 2017 (Figura 1.E, línea de nieves a 3.971 m s.n.m.) presentaron precipitaciones intensas y un gran número de quebradas aluvionadas (Tabla 1); en contraste, las tormentas de mediado de mayo de 2013 y finales de julio de 2015 no presentaron registros de aluviones en la zona de estudio (Figuras 1.B y 1.D, líneas de nieve de 2.655 y 3.752 m s.n.m.).

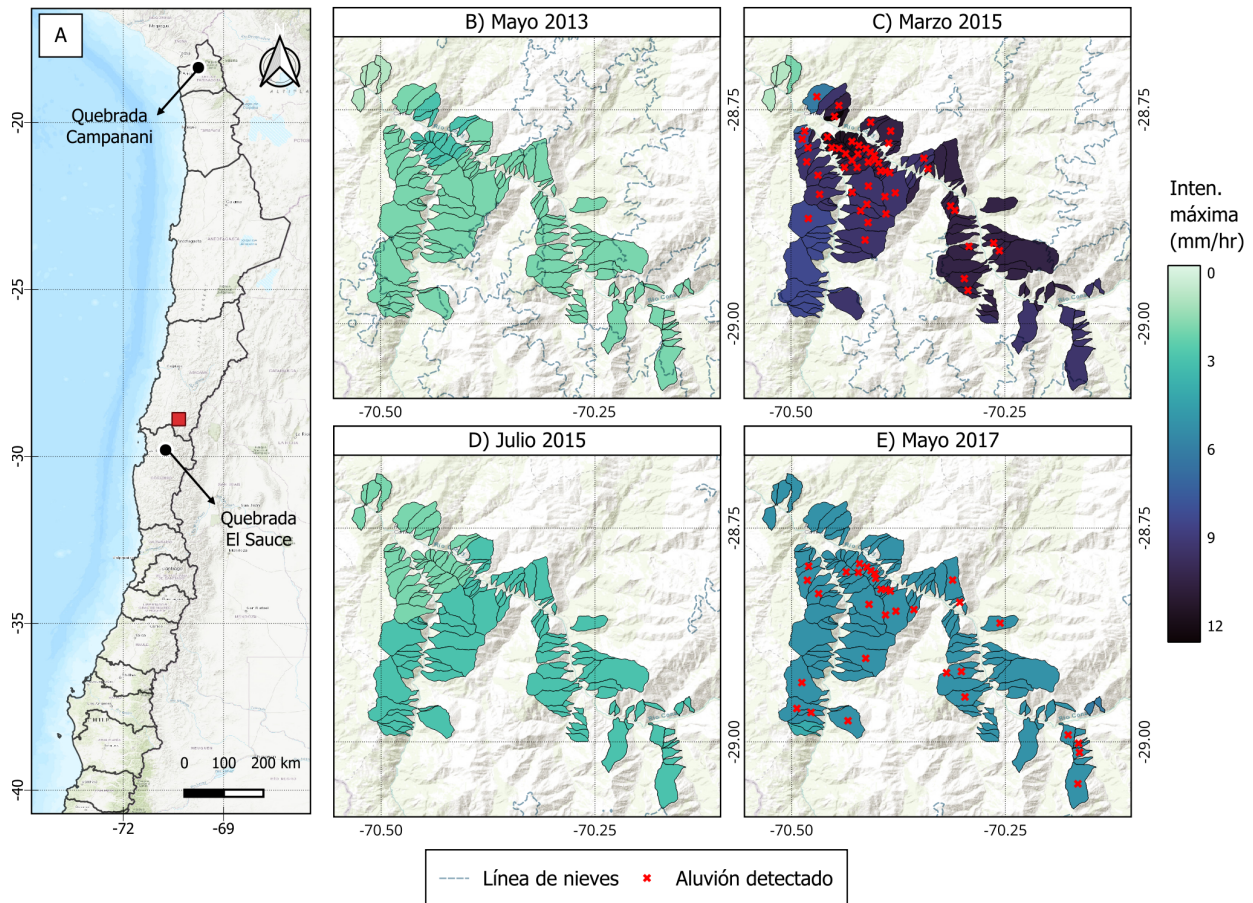


Figura 1: Ubicación de las quebradas usadas para el entrenamiento, validación y prueba del modelo PDA. Los paneles B - E indican la intensidad horaria máxima experimentada por cada quebrada en los eventos de tormenta.

Adicionalmente a las quebradas del río Huasco, la Figura 1.A indica la ubicación de dos quebradas del norte de Chile utilizadas en la prueba del modelo PDA. La quebrada El Sauce, ubicada en la cuenca del río Elqui, experimentó aluviones para las tormentas de marzo de 2015 y mayo de 2017; la quebrada Campanani, ubicada en la cuenca del río Lluta, experimentó aluviones en la tormenta de enero de 2019.

Tabla 1: Número de quebradas aluvionadas por evento de tormenta.

Número de quebradas	Mayo 2013	Marzo 2015	Julio 2015	Mayo 2017
Aluvionadas	0	46	0	29
No aluvionadas	139	93	139	110

3. METODOLOGÍA

3.1. Datos de entrenamiento, validación, y prueba

Se contó con un total de 556 datos correspondientes a la generación o no generación aluvional en 139 quebradas durante cuatro eventos de tormenta (sección 2). Estos datos se separaron aleatoriamente en dos conjuntos: datos de entrenamiento del modelo PDA (70 %), y datos de validación del modelo (30 % restante). Además, se prepararon los datos de prueba correspondientes a dos quebradas de prueba alejadas de la cuenca del Huasco para probar el desempeño del modelo PDA en otras cuencas: la quebrada El Sauce (Río Elqui) y la quebrada Campanani (Río Lluta).

Con tal de explorar las posibles aplicaciones del modelo PDA a otras condiciones climáticas, se cuentan con los datos meteorológicos para diferentes periodos de retorno en la quebrada El Sauce a partir de modelos climáticos del CMIP6 para el escenario SSP5-8.5 (Calvin et al., 2023) con tal de estimar los cambios en la probabilidad de ocurrencia aluvional según los predictores históricos. Estos datos fueron obtenidos por Montserrat et al. (2025) para el norte de Chile en tres periodos futuros: futuro cercano (2025-2049), mediano plazo (2050-2074), y futuro lejano (2075-2100).

3.2. Predictores del modelo

Para la construcción del modelo probabilístico, se probaron 12 predictores candidatos asociados a la meteorología, geomorfología e hidrología de las quebradas: **(i)** la intensidad horaria máxima del evento de tormenta (mm/hr), **(ii)** la precipitación máxima en 24 horas durante el evento (mm), **(iii)** el área (km²), **(iv)** la elevación mínima (m s.n.m.), **(v)** la elevación media (m s.n.m.), **(vi)** la elevación máxima (m s.n.m.), **(vii)** el porcentaje de suelo sin vegetación o suelo desnudo (%), **(viii)** la pendiente promedio (°), **(ix)** la distancia recorrida desde el punto más alejado de la quebrada al punto de drenaje (km), **(x)** la densidad de drenaje (km⁻¹, ecuación 1), **(xi)** el índice de Melton (adimensional, ecuación 2), y **(xii)** el índice de Gravelius (adimensional, ecuación 3).

$$\text{Densidad de drenaje} = \frac{\sum_{i=1}^N L_i}{A} \quad (1)$$

$$\text{Índice de Melton} = \frac{H_{\text{máx}} - H_{\text{mín}}}{\sqrt{A}} \quad (2)$$

$$\text{Índice de Gravelius} = \frac{0,282 \cdot P}{\sqrt{A \cdot 10^6}} \quad (3)$$

Donde L_i es el largo del i -ésimo cauce de la red fluvial de la quebrada, A es el área (km²), $H_{\text{máx}}$ y $H_{\text{mín}}$ son las elevaciones máximas y mínimas (m s.n.m.), y P es el perímetro (m). Estos predictores fueron seleccionados de un total de 44 predictores por su alta correlación de Spearman con la variable dependiente y la facilidad de ser calculados por otros usuarios, independiente de la resolución espacial de los mapas digitales de elevación usados (Montserrat et al., 2025).

Es importante indicar que, debido a que ninguno de los predictores candidatos hace referencia a la temperatura o elevación de la línea de nieves, el cálculo de los predictores geomorfológicos sólo

consideran las características del área pluvial de cada quebrada según lo indicado en la sección 2 (Figura 1). La Tabla 2 resume el rango de valores y estadísticos del conjunto de datos de entrenamiento del modelo para cada predictor.

Tabla 2: Estadísticos del conjunto de datos de entrenamiento del modelo PDA.

Predictor	Mínimo	Promedio	Máximo	Desviación estándar
Intensidad horaria máxima (mm/hr)	2,35	5,43	12,01	2,91
Precipitación en 24 horas (mm)	3,38	30,37	71,14	15,23
Área (km ²)	0,24	2,89	17,52	3,49
Elevación mínima (m s.n.m.)	785	1061,48	1622	202,32
Elevación media (m s.n.m.)	997,5	1750,49	2641	342,51
Elevación máxima (m s.n.m.)	1372	2328,92	3794	432,38
Cobertura de suelo desnudo (%)	0,212	0,858	0,999	0,161
Pendiente promedio (°)	13,89	28,80	36,60	3,11
Distancia máxima al punto de drenaje (km)	1,04	3,99	15,93	2,43
Densidad de drenaje (km ⁻¹)	0,51	2,43	4,65	0,73
Índice de Melton (-)	0,30	0,97	1,95	0,31
Índice de Gravelius (-)	1,37	1,83	2,55	0,22

3.3. Modelo probabilístico para la ocurrencia aluvional

El modelo probabilístico para la ocurrencia aluvional (PDA) tiene por objetivo pronosticar la probabilidad de ocurrencia de un aluvión basado en un conjunto de variables independientes o predictores ($X = X_1 + X_2 + \dots + X_p$). Debido a que la variable dependiente del modelo es categórica y binaria (aluvión o no aluvión), se construyó el modelo PDA en base a una regresión logística binaria definida por la ecuación 4, y un vector de predictores transformado según las estadísticas del conjunto de datos de entrenamiento del modelo (ecuación 5).

$$Prob(Y = 1|X) = \left[1 + \exp \left(-(X_0 + \sum_{i=1}^p X_i \beta_i) \right) \right]^{-1} \quad (4)$$

$$X_i = \frac{x_i - \mu_i}{\sigma_i} \quad (5)$$

Donde Y es la probabilidad de ocurrencia aluvional (valor continuo entre 0 y 1), y $X = (X_1, X_2, \dots, X_p)$ es un vector de p predictores normalizado por el promedio μ y desviación estándar σ del i -ésimo predictor según el conjunto de datos de entrenamiento del modelo (Tabla 2). Esta normalización fue realizada debido a las diferencias en magnitud entre los 12 predictores candidatos.

3.4. Métricas de desempeño

Con tal de comparar el ajuste a los datos entre múltiples modelos candidatos con diferentes números de predictores, se eligieron cuatro métricas: el criterio de información de Akaike (AIC, ecuación 6), el coeficiente de determinación ajustado (R^2_{Adj} , ecuación 7), la precisión del pronóstico (*Accuracy*, ecuación 8), y el sesgo del pronóstico (*Bias*, ecuación 9).

$$AIC = 2 \cdot p - 2 \cdot \ln(\hat{L}) \quad (6)$$

$$R^2_{Adj} = 1 - \left(\frac{(1 - R^2) \cdot (n - 1)}{n - p - 1} \right) \quad (7)$$

$$Accuracy = \frac{a + d}{a + b + c + d} \quad (8)$$

$$Bias = \frac{a + b}{a + c} \quad (9)$$

Donde p es el número de predictores utilizados por el modelo, \hat{L} es el valor de la función de máxima verosimilitud, R^2 es el coeficiente de determinación, y n es el número de datos de entrenamiento. Los valores de a , b , c y d están asociados a la distribución de las predicciones del modelo entrenado y las observaciones del predictando (y). Si la generación de un aluvión es $y_{obs} = 1$ y la no generación es $y_{obs} = 0$, se debe transformar la probabilidad pronosticada por los modelos candidatos a categorías binarias. Para ello, se consideró una probabilidad límite de 0,5 para determinar si se pronostica un aluvión: si $y_{pro} < 0,5$, entonces $y_{pro} = 0$, si $y_{pro} \geq 0,5$, entonces $y_{pro} = 1$. La Tabla 3 muestra las componentes de una tabla de contingencia para variables binarias, donde se definen los términos de las ecuaciones 8 y 9. Las métricas de precisión y sesgo fueron obtenidas para los conjuntos de datos de entrenamiento y validación de cada modelo, mientras que las métricas *AIC* y R^2_{Adj} fueron obtenidas solo para los datos de entrenamiento.

Tabla 3: Ejemplo de tabla de contingencia para variables categóricas.

		Evento observado	
		Si (1)	No (0)
Evento pronosticado	Si (1)	a (Aciertos / Verdaderos positivos)	b (Falsas alarmas / Falsos positivos)
	No (0)	c (Faltas / Falsos negativos)	d (Verdaderos negativos)

Un buen ajuste a los datos de entrenamiento se indica por un valor bajo del AIC dentro de un conjunto de modelos y un valor alto de R^2_{Adj} . Tanto el AIC como el R^2_{Adj} pueden adoptar valores negativos como positivos debido a las correcciones por el número de predictores del modelo. La

precisión del pronóstico es un valor positivo entre 0 y 1, siendo 1 el valor asociado a un ajuste perfecto. En contraste, el sesgo del pronóstico es un número real, siendo 1 el valor asociado a una representación perfecta de la distribución de eventos aluvionales y no aluvionales según los datos observados.

3.5. Selección del modelo PDA

El modelo PDA seleccionado debe contar con un buen ajuste a los datos de entrenamiento, así como un desempeño alto en el pronóstico de la probabilidad aluvional para los datos de validación y las quebradas de prueba. Para ello, se definió un modelo compuesto por los 12 predictores candidatos (modelo base) como punto de comparación en las métricas de de los 4.094 modelos candidatos restantes.

Debido al número de datos y de predictores candidatos, la metodología de selección del modelo PDA implementó diferentes estrategias para minimizar el nivel de sobreajuste del modelo PDA seleccionado. Las métricas AIC y R_{Adj}^2 aplican penalizaciones a los modelos ajustados según el número de predictores (p , ecuaciones 6 y 7), siendo las métricas principales en determinar el verdadero desempeño de los modelos según los datos de entrenamiento. Adicionalmente, con tal de evitar que las métricas de desempeño se vean influenciadas por datos atípicos dentro del conjunto de entrenamiento, se aplicó el método de validación cruzada (*Leave-One-Out Cross Validation*) en el entrenamiento de cada modelo candidato. La aplicación de la validación cruzada consistió en eliminar una observación del conjunto de datos de entrenamiento a la vez, ajustar el modelo candidato, y calcular sus métricas de desempeño usando los $n - 1$ datos restantes. Esto se repite n veces para considerar eliminar cada observación del conjunto, por lo que se obtienen métricas representativas por modelo candidato correspondientes al promedio de las obtenidas por la validación cruzada.

4. RESULTADOS

4.1. Selección y desempeño del modelo PDA

El modelo base obtenido a partir de los 12 predictores candidatos presentó un valor de AIC igual a 223,57 y un R_{Adj}^2 de 0,450; el desempeño del modelo base en el pronóstico de probabilidades de ocurrencia aluvional en el conjunto de datos de entrenamiento mostró una precisión de 0,887 y un sesgo de 0,865, mientras que en el conjunto de validación estas métricas fueron iguales a 0,799 y 0,676 respectivamente. La Tabla 4 indica los coeficientes β ajustados por predictor según la ecuación 4, donde se observa que los predictores meteorológicos y el índice de Melton presentan un peso mayor respecto al resto, siendo además estadísticamente significativos ($p - valor \leq 0,05$).

De los 4.094 modelos candidatos restantes, se filtraron aquellos con valores de AIC menores o iguales a 223,57 y R_{Adj}^2 mayores o iguales a 0,4 para encontrar un mejor ajuste con un menor número de predictores. De estos modelos, se seleccionó finalmente un modelo compuesto por ocho predictores: intensidad horaria máxima, precipitación en 24 horas máxima, área, elevación mínima, porcentaje de suelo desnudo, pendiente promedio, índice de Melton, e índice de Gravelius.

Tabla 4: Coeficientes del modelo base de regresión logística binaria ($p = 12$).

Predictor	Valor	p-valor
Intercepto	-3,63452	$1,4 \cdot 10^{-11}$
Intensidad horaria máxima	1,49674	$1,6 \cdot 10^{-8}$
Precipitación en 24 horas	2,09694	$6,9 \cdot 10^{-8}$
Área	0,52661	$1,5 \cdot 10^{-1}$
Elevación mínima	-1,36868	$2,7 \cdot 10^{-4}$
Elevación media	-0,07110	$9,0 \cdot 10^{-1}$
Elevación máxima	0,25892	$6,4 \cdot 10^{-1}$
% Suelo desnudo	0,49888	$1,3 \cdot 10^{-1}$
Pendiente promedio	0,79805	$2,9 \cdot 10^{-2}$
Distancia máxima	-0,11830	$7,3 \cdot 10^{-1}$
Densidad de drenaje	0,09508	$6,4 \cdot 10^{-1}$
Índice de Melton	-1,23577	$2,8 \cdot 10^{-2}$
Índice de Gravelius	0,38211	$2,4 \cdot 10^{-1}$

El modelo seleccionado presentó un valor de AIC de 216,11 y un R^2_{Adj} de 0,455, lo cual indica un mejor ajuste a los datos de entrenamiento comparado con el modelo base. La precisión de los pronósticos aluvionales del modelo seleccionado para los datos de entrenamiento y validación fue de 0,884 y 0,805 respectivamente; de forma similar, el sesgo de los pronósticos fue de 0,851 en el entrenamiento y 0,649 en la validación. La Tabla 5 indica los coeficientes β de cada predictor a usar en el modelo PDA y los p-valores según el ajuste a los datos de entrenamiento. Se observa que, con excepción de la cobertura de suelo desnudo y el índice de Gravelius, todos los coeficientes β del modelo seleccionado son estadísticamente significativos.

Tabla 5: Coeficientes del mejor modelo de regresión logística del conjunto ($p = 8$).

Predictor	Valor	p-valor
Intercepto	-3,64308	$1,3 \cdot 10^{-11}$
Intensidad horaria máxima	1,50801	$1,4 \cdot 10^{-8}$
Precipitación en 24 horas	2,11132	$5,7 \cdot 10^{-8}$
Área	0,59925	$4,0 \cdot 10^{-2}$
Elevación mínima	-1,26959	$1,1 \cdot 10^{-5}$
% Suelo desnudo	0,50950	$1,2 \cdot 10^{-1}$
Pendiente promedio	0,76354	$2,5 \cdot 10^{-2}$
Índice de Melton	-1,11532	$2,8 \cdot 10^{-2}$
Índice de Gravelius	0,40881	$1,8 \cdot 10^{-1}$

La Figura 2 muestra visualmente el desempeño del modelo seleccionado al pronosticar la probabilidad de generación aluvional para todas las quebradas del río Huasco en los cuatro eventos de tormenta según el conjunto de datos usados (entrenamiento, validación). Se observa que el modelo seleccionado estimó bajas probabilidades de generación aluvional ($P \leq 0,2$) en los eventos de ma-

yo de 2013 y julio de 2015 en ambos conjuntos, los cuales no presentaron registros de aluviones. El evento de marzo de 2015 muestra altas probabilidad de generación aluvional ($P > 0,4$) para aquellas quebradas que sí presentaron aluviones, con la mayoría de los datos entregando probabilidades mayores a 0,5; finalmente, el evento de mayo de 2017 presenta probabilidades de ocurrencia aluvional más bajas que el evento de marzo, con probabilidades medias ($0,2 < P \leq 0,4$) y altas para las quebradas aluvionadas en el conjunto de entrenamiento, y en las tres categorías para el conjunto de validación. Por otro lado, las quebradas no aluvionadas en marzo de 2015 y mayo de 2017 presentan probabilidades medias y bajas, con un menor número de quebradas en ambos eventos identificadas como falsos positivos en generación aluvional.

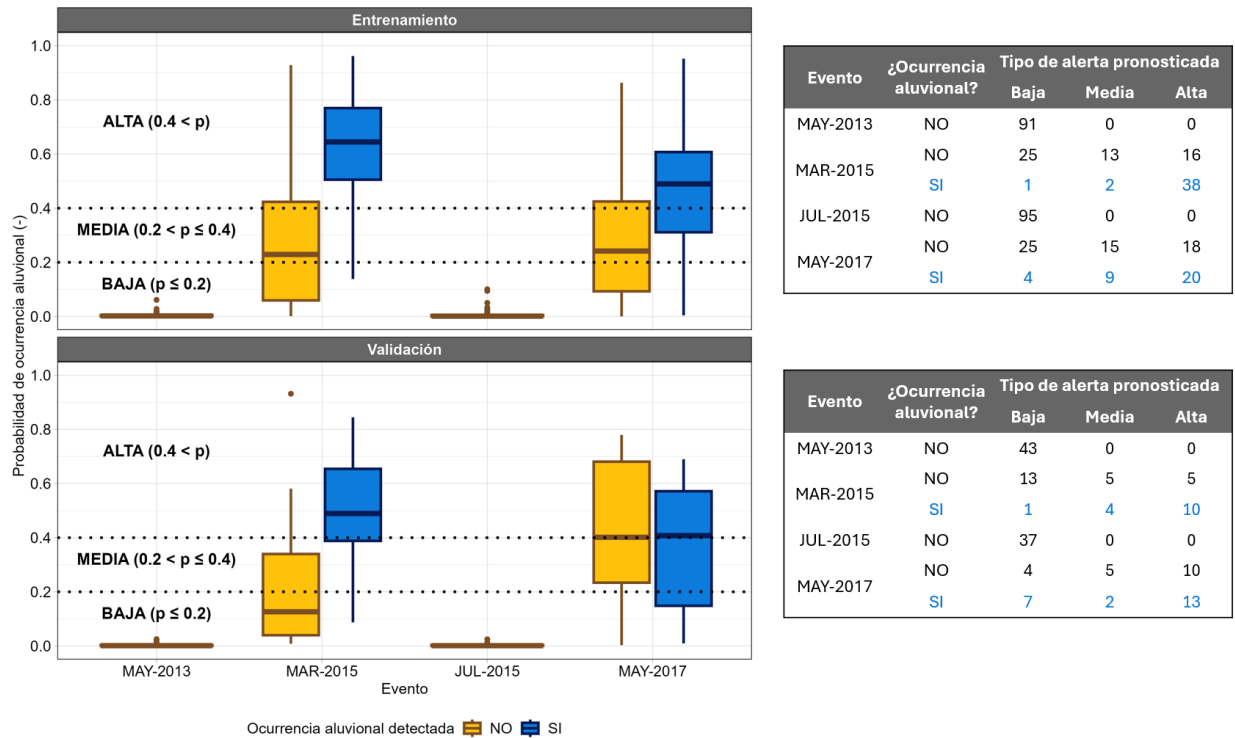


Figura 2: Desempeño del modelo final para los cuatro eventos estudiados en la cuenca del Huasco según el conjunto de datos, y la distribución de eventos pronosticados según la ocurrencia aluvional observada.

4.2. Aplicación en quebradas de prueba

Tal como se indicó en la sección 3.3, los predictores de las quebradas El Sauce y Campanani debieron ser normalizados según los estadísticos de la Tabla 2 previo a la aplicación del modelo PDA (ecuación 5). La Tabla 6 indica los predictores normalizados de las quebradas de prueba utilizados en la ecuación 4 junto a los coeficientes β del modelo PDA seleccionado, listados en la Tabla 5. Esto resultó en una probabilidad de generación aluvional de 3,95 % (baja, falso negativo) y 99,94 % (alta, acierto) para los eventos de marzo de 2015 y mayo de 2017 en la quebrada El Sauce, y una probabilidad de 99,45 % (alta, acierto) en el evento de 2019 en la quebrada Campanani.

Otra forma de uso del modelo PDA es en la estimación de las probabilidades de generación aluvional bajo cambios en las condiciones climáticas. La Figura 3 muestra los cambios en las probabilidades en periodos futuros según el periodo de retorno de la tormenta estudiada en la quebrada El Sauce para el escenario futuro SSP5-8.5 según los modelos climáticos estudiados. La aplicación del modelo PDA bajo estas nuevas condiciones requirió modificar los predictores meteorológicos (intensidad, precipitación en 24 horas) por aquellos estimados por un conjunto de modelos climáticos. De la Figura 3 se observa como las probabilidades aluvionales pronosticadas por el modelo son menores en el futuro lejano con respecto al periodo histórico para eventos con $Tr < 10$ años debido a la disminución de las lluvias proyectadas en la zona.

Tabla 6: Datos normalizados de las quebradas El Sauce y Campanani para determinar la probabilidad de ocurrencia aluvional.

Predictor	Quebrada El Sauce (2015)	Quebrada El Sauce (2017)	Quebrada Campanani (2019)
Intensidad horaria máx.	0,471	1,158	5,866
Precipitación en 24 hr	-0,129	4,427	1,637
Área	1,189	1,189	2,269
Elevación mínima	0,660	0,660	2,948
% Suelo desnudo	-0,681	-0,681	-3,938
Pendiente promedio	-3,084	-3,084	-0,550
Índice de Melton	-2,032	-2,032	-1,387
Índice de Gravelius	1,409	1,392	-0,500

5. DISCUSIÓN

La construcción del modelo PDA está basado en un modelo de regresión logística cuyo predictando es binario, por lo que los modelos candidatos fueron entrenados en base a relaciones matemáticas entre un máximo de 12 predictores y la ocurrencia/no ocurrencia aluvional. La metodología de este estudio implementó técnicas para evitar el sobreajuste del modelo a los datos de entrenamiento como: diferentes predictores asociados a características del evento y geomorfología de la quebrada con bajas correlaciones entre sí, la aplicación de métricas que castigan el desempeño por el número de predictores usados (AIC, R_{Adj}^2), el número de observaciones en los datos de entrenamiento del modelo (R_{Adj}^2), y la validación cruzada en la estimación de las métricas para disminuir el efecto de datos atípicos en el desempeño. Puesto que este estudio no incluyó predictores asociados a la temperatura del evento debido a la amplia variación horaria durante un evento de tormenta, los predictores geomorfológicos están ligados al área pluvial de la quebrada en donde se pueden generar volúmenes de escorrentía.

El entrenamiento de los modelos candidatos utiliza alrededor de 389 datos normalizados por el promedio y desviación estándar del conjunto para evitar que las diferencias de magnitud entre los predictores influenciaran la selección del modelo PDA final. Esta normalización de predictores debe ser realizada en cada quebrada en donde se aplique el modelo PDA; es importante notar que,

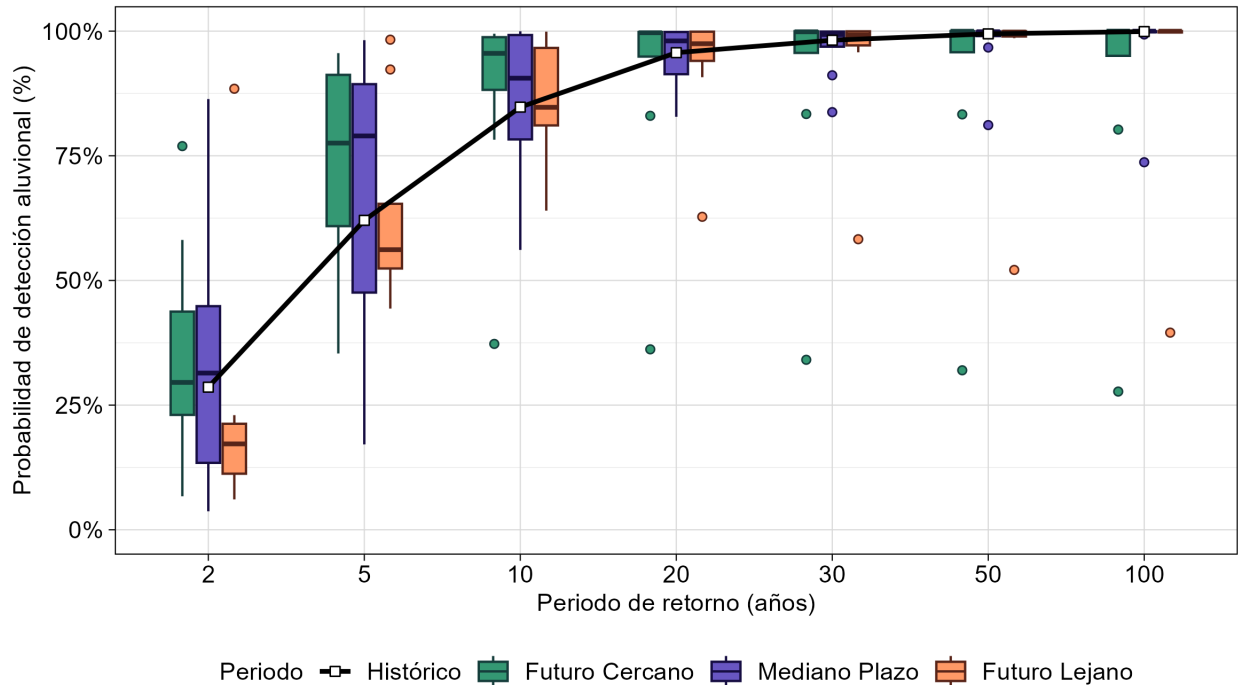


Figura 3: Proyecciones futuras de la probabilidad de ocurrencia aluvional en la quebrada El Sauce según el modelo PDA, al aplicarlo a diferentes precipitaciones futuras según su periodo de retorno.

como todo modelo ajustado, valores fuera del rango de entrenamiento pueden presentar comportamientos no estudiados. Esta limitación puede ser reducida al incluir un mayor número de quebradas a los datos de entrenamiento; sin embargo, el modelo PDA presentado utiliza las quebradas del río Huasco por ser una zona ampliamente estudiada en generación aluvional, lo cual permitió definir que eventos de tormenta no generaron aluviones. Si bien se cuenta con un amplio registro de aluviones en el norte del país (SERNAGEOMIN, 2025), un modelo de pronóstico también requiere de eventos en donde no se haya generado aluviones para determinar que predictores tienen más influencia en estos desastres.

El pronóstico aluvional del modelo PDA seleccionado mostró un buen desempeño en la estimación de probabilidades de ocurrencia aluvional en las quebradas del Huasco, especialmente en aquellos eventos donde no se observaron aluviones, donde se pronosticaron probabilidades menores a 0,1. El modelo PDA muestra un amplio rango de probabilidades en los eventos de marzo de 2015 y mayo de 2017, en donde se registraron 46 y 29 quebradas aluvionadas, respectivamente. Como se ilustra en la Figura 2, las quebradas aluvionadas tienen mayores probabilidades de ocurrencia aluvional según el modelo PDA que aquellas quebradas que no experimentaron aluviones; sin embargo, los diagramas de caja de estas quebradas no aluvionadas presentan un rango intercuantil amplio, con algunas alcanzando probabilidades medias o altas de ocurrencia ($P > 0,2$). Una explicación a este comportamiento del modelo PDA puede ser explicado por la estimación de la precipitación en las quebradas; las zonas cordilleranas presentan un número menor de estaciones meteorológicas, por lo que una incorrecta estimación de estos predictores afecta en gran medida los pronósticos. La quebrada de prueba El Sauce presentó un falso negativo para el evento de marzo de 2015, en

donde las estaciones meteorológicas más cercanas se encuentran en el valle Central, por lo que una explicación de este resultado es en la estimación de los predictores meteorológicos del evento por una baja cantidad de datos cercanos.

Otro punto importante es que el modelo PDA fue entrenado en la cuenca del Río Huasco, la cual cuenta con una disponibilidad ilimitada de sedimentos (Montserrat et al., 2025); esta característica corresponde a cuencas con un volumen de sedimentos disponible considerablemente superior al volumen de sedimentos que una tormenta es capaz de transportar. En este sentido, el modelo PDA utiliza predictores físicos estáticos, como la pendiente media y el porcentaje de suelo desnudo. Por esta razón su aplicabilidad en otras quebradas debe ser verificada mediante campañas de terreno que cuantifiquen el sedimento disponible y verifiquen la hipótesis de disponibilidad ilimitada de sedimentos.

6. CONCLUSIONES

La implementación de un modelo matemático basado en registros aluvionales en quebradas del norte de Chile puede resultar en una herramienta importante para el estudio de los desencadenante de aluviones en esta zona, así como un pronóstico simple según las características de los eventos de tormenta y la geomorfología. Para obtener una primera aproximación con este modelo PDA, se utilizaron metodologías asociadas al ajuste estadístico de modelos matemáticos binarios en quebradas con disponibilidad ilimitada de sedimentos, por lo que los pronósticos de probabilidades de ocurrencia aluvional provenientes del modelo PDA son independientes de eventos pasados para los datos de entrenamiento y validación.

El modelo PDA presentado mostró un buen desempeño en las quebradas del río Huasco, pero se puede continuar en su mejora incluyendo más predictores y datos de entrenamiento al modelo, siendo esto último un factor limitante en estudios del Norte de Chile. Además, el modelo PDA es fuertemente influenciado por los montos de intensidad horaria y precipitación en 24 horas, por lo que se requiere contar con una buena calidad de estos datos en las quebradas del conjunto de entrenamiento para poder representar correctamente la generación o no generación aluvional.

AGRADECIMIENTOS

Los autores agradecen el apoyo financiero del Proyecto AFB230001 ANID y el apoyo financiero del proyecto FONDEF ID22I10122 ANID.

REFERENCIAS

- Aceituno, P., Boisier, J. P., Garreaud, R., Rondanelli, R., & Rutllant, J. A. (2021). Climate and weather in Chile. In *Water resources of Chile* (pp. 7–29). Springer.
- Aguilar, G., Cabré, A., Fredes, V., & Villela, B. (2020). Erosion after an extreme storm event in an arid fluvial system of the southern Atacama Desert: An assessment of the magnitude, return time, and conditioning factors of erosion and debris flow generation. *Natural Hazards and Earth System Sciences*, 20(5), 1247–1265.

Calvin, K., Dasgupta, D., Krinner, G., Mukherji, A., Thorne, P. W., Trisos, C., Romero, J., Aldunce, P., Barrett, K., Blanco, G., Cheung, W. W., Connors, S., Denton, F., Diongue-Niang, A., Dodman, D., Garschagen, M., Geden, O., Hayward, B., Jones, C., Jotzo, F., Krug, T., Lasco, R., Lee, Y.-Y., Masson-Delmotte, V., Meinshausen, M., Mintenbeck, K., Mokssit, A., Otto, F. E., Pathak, M., Pirani, A., Poloczanska, E., Pörtner, H.-O., Revi, A., Roberts, D. C., Roy, J., Ruane, A. C., Skea, J., Shukla, P. R., Slade, R., Slangen, A., Sokona, Y., Sörensson, A. A., Tignor, M., Van Vuuren, D., Wei, Y.-M., Winkler, H., Zhai, P., Zommers, Z., Hourcade, J.-C., Johnson, F. X., Pachauri, S., Simpson, N. P., Singh, C., Thomas, A., Totin, E., Arias, P., Bustamante, M., Elgizouli, I., Flato, G., Howden, M., Méndez-Vallejo, C., Pereira, J. J., Pichs-Madruga, R., Rose, S. K., Saheb, Y., Sánchez Rodríguez, R., Ürge-Vorsatz, D., Xiao, C., Yassaa, N., Alegría, A., Armour, K., Bednar-Friedl, B., Blok, K., Cissé, G., Dentener, F., Eriksen, S., Fischer, E., Garner, G., Guivarch, C., Haasnoot, M., Hansen, G., Hauser, M., Hawkins, E., Hermans, T., Kopp, R., Leprince-Ringuet, N., Lewis, J., Ley, D., Ludden, C., Niamir, L., Nicholls, Z., Some, S., Szopa, S., Trewin, B., Van Der Wijst, K.-I., Winter, G., Witting, M., Birt, A., Ha, M., Romero, J., Kim, J., Haites, E. F., Jung, Y., Stavins, R., Birt, A., Ha, M., Orendain, D. J. A., Ignon, L., Park, S., Park, Y., Reisinger, A., Cammaramo, D., Fischlin, A., Fuglestedt, J. S., Hansen, G., Ludden, C., Masson-Delmotte, V., Matthews, J. R., Mintenbeck, K., Pirani, A., Poloczanska, E., Leprince-Ringuet, N., & Péan, C. (2023). *IPCC, 2023: Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (Eds.)]. IPCC, Geneva, Switzerland. Technical report, Intergovernmental Panel on Climate Change (IPCC).*

Calvo, B. & Savi, F. (2009). A real-world application of monte carlo procedure for debris flow risk assessment. *Computers & Geosciences*, 35(5), 967–977.

Montserrat, S., Aguilar, G., Garces, A., Lagos-Zúñiga, M., Paredes, M., Pinto, D., Jerez, C., Villela, B., Matus, F., Contreras, T., & Iturra, D. (2025). *Guía Metodológica Para El Diagnóstico y Cálculo de La Amenaza Aluvional Presente y Futura*. 1° edition.

SERNAGEOMIN (2025). Catálogo Nacional de Información Geológica y Minera. <https://portalgeomoin.sernageomin.cl/>.

Yáñez-Morrón, G., Gironás, J., Caneo, M., Delgado, R., & Garreaud, R. (2018). Using the Weather Research and Forecasting (WRF) model for precipitation forecasting in an Andean region with complex topography. *Atmosphere*, 9(8), 304.