

DOI: 10.24850/j-tyca-2026-03-01

Artículos

## **Estimación de la socavación local en pilas de puentes mediante programación genética para mejorar la precisión predictiva**

### **Estimation of local scour at bridge piers using genetic programming to enhance predictive accuracy**

Edwin David Valladares-Sandoval<sup>1</sup>, ORCID: <https://orcid.org/0009-0008-8906-6909>

Luis Felipe Herrera-Riega<sup>2</sup>, ORCID: <https://orcid.org/0009-0001-6231-5222>

Maiquel López-Silva<sup>3</sup>, ORCID: <https://orcid.org/0000-0002-0946-6160>

<sup>1</sup>Universidad Ricardo Palma, Lima, Perú, 202012253@urp.edu.pe

<sup>2</sup>Universidad Ricardo Palma, Lima, Perú, 202012250@urp.edu.pe

<sup>3</sup>Universidad Católica Sedes Sapientiae, Lima, Perú, mlopezs@ucss.edu.pe

Autor para correspondencia: Luis Felipe Herrera Riega, 202012250@urp.edu.pe



## Resumen

La socavación local es un fenómeno hidráulico, que resulta de la interacción entre una estructura y el cauce de un río, lo cual altera su flujo natural, provocando erosión del material de lecho donde se sitúan los pilares, por lo que determinar la profundidad adecuada a la cual se deben cimentar los pilares es crucial para la durabilidad de las estructuras; sin embargo, actualmente no existe una ecuación universal para su cálculo. Esta investigación utilizó la programación de expresión genética (GEP), que permite obtener ecuaciones para estimar la socavación local en pilas de puentes. Para ello, se recopilaron 919 datos de laboratorio y 746 de campo. Con estos datos se desarrollaron modelos predictivos de socavación local en tres escenarios: laboratorio, campo y combinados, así como su selección a través de las métricas evaluación de modelos y validación mediante datos de investigaciones externas. El escenario del laboratorio con GEP reveló una mejor robustez, eficiencia y estabilidad de los resultados con coeficiente de determinación ( $R^2$ ) de 0.899, error cuadrático medio (RMSE) de 0.054 y el error absoluto medio (MAE) de 0.027. No obstante, en la validación, el modelo del escenario de campo generó un resultado eficaz con error típico entre 6.0 y 14.0 % en cuanto a las ecuaciones analíticas. Así, se concluye que la inteligencia artificial basada en programación genética mejoró la predicción de la socavación local en puentes en relación con los modelos analíticos.

**Palabras clave:** inteligencia artificial, puente, erosión, ingeniería hidráulica, modelo matemático, lenguaje de programación, algoritmo.

## Abstract

Local scour is a hydraulic phenomenon resulting from the interaction between the riverbed and a structure that is altering the natural flow and eroding the bed material where piers are located. Therefore, determining the correct depth at which the piers are to be set is crucial for the structures' longevity. However, there is no general formula for its calculation today. This study utilized Gene Expression Programming (GEP), which allows for the derivation of equations to predict local scour around bridge piers. For this purpose, 919 laboratory data and 746 field data were gathered. Based on this data set, predictive models for local scour were established in three case scenarios: laboratory, field, and combined. Model selection was done via evaluation measures as well as validation using external research data. The laboratory scenario with GEP demonstrated better robustness, efficiency, and result stability, giving a coefficient of determination ( $R^2$ ) of 0.899, root mean square error (RMSE) of 0.054, and mean absolute error (MAE) of 0.027. At the validation stage, however, field scenario model provided successful results, with the average error ranging from 6.0 to 14.0 % compared to analytical equations. It is therefore concluded that genetic programming based artificial intelligence improved the prediction of local scour near bridge piers compared to analytical models.

**Keywords:** Artificial intelligence, bridges, erosion, hydraulic engineering, mathematical models, computer languages, algorithms.

Recibido: 28/05/2025

Aceptado: 06/07/2025

Publicado *ahead of print*: 16/07/2025



Versión final: 01/05/2026

## Introducción

La importancia de los puentes reside en su capacidad para superar obstáculos geográficos, como terrenos irregulares, cuerpos de agua o diferencias de altitud (Belmonte, 1990). Asimismo, aseguran la continuidad de las rutas que conectan comunidades (Rodríguez, 2020), permitiendo la circulación de personas y vehículos.

Sin embargo, en la actualidad todavía existen casos en los que las fallas han llevado a pérdidas económicas y de vidas humanas. Los errores de diseño y construcción, los eventos naturales hidráulicos, las colisiones y las sobrecargas representan las causas de las fallas más comunes en puentes, abarcando el 70 % de los casos (Zhang, Liu, Liu, Lan, & Yang, 2022). Además, considerando la información estadística revisada por Rocha (2013) las causas más comunes fueron choques de cuerpos extraños, acción del viento, sismos y comportamiento fluvial, siendo este último el de mayor incidencia. Khosravi, Khozani y Mao (2021), por su parte, afirman que la falla más habitual en los puentes sobre ríos está asociada con la fuerte erosión local en torno a sus pilares.

Una parte del comportamiento fluvial incluye la socavación, que según Kumar, Baranwal y Das (2024) es un proceso natural causado por la corriente de agua que remueve las partículas de sedimento del lecho del arroyo y las transporta fuera de fosa de socavación. Asimismo, el Ministerio de Transportes y Comunicaciones (MTC) (MTC, 2018) la define como un fenómeno hidrodinámico que combina dos tipos de socavación: la debida al estrechamiento del cauce y la local. Sobre esta última, Qi, Li y Chen (2016) señalan que es el resultado de la interacción entre

estructuras de flujo coherente, inestables y tridimensionales, y los lechos de ríos susceptibles a la erosión en las proximidades de los pilares del puente.

Como lo mencionan Choi y Choi (2022), se han propuesto diversos enfoques para estimar la profundidad de socavación. Sin embargo, hasta el momento no existe un método universal aceptado. De igual forma, Fuladipanah, Hazi y Kisi (2023) explican que el principal desafío que se presenta con la socavación en cualquiera de sus variantes es su cálculo, pues los modelos matemáticos analíticos que se usan en la actualidad son imprecisos, lo que conlleva a subdimensionar o sobredimensionar las cimentaciones, lo cual trae consigo el posible colapso del puente en evaluación. La situación óptima es construir puentes estratégicamente ubicados, amplios y con una cimentación adecuada, de manera que la estructura no afecte el comportamiento del flujo durante las crecidas; que los parámetros hidráulicos se comporten de manera natural antes y después de la ejecución del puente (Guevara, 2021).

Como alternativa de una explicación y estimación más exacta de la socavación en pilas de puentes se han desarrollado modelos numéricos y otros basados en inteligencia artificial. Al respecto, en cuanto al aspecto experimental, Amini-Baghbadorani, Ataie-Ashtiani, Beheshti, Hadzaman, y Jamali (2018) indican que mediante el uso el algoritmo M5 lograron proponer seis ecuaciones para la predicción de la socavación en pilares complejos, obteniendo coeficientes de determinación ( $R^2$ ) entre 0.690 y 0.820. En el aspecto experimental, en condiciones de campo y para un grupo de cimientos de muelles complejos, Chou y Nguyen (2022) aplican el sistema de apilamiento optimizado por metaheurísticas (MOSS) y lograron conseguir errores porcentuales absolutos medios de 7.127, 29.1195 y 13.131 % en la predicción de la profundidad de socavación.

Dichos valores son al menos 36, 19 y 41 % más bajos que los obtenidos utilizando otros enfoques. Concluyen que el análisis predictivo automatizado reveló eficiencia y estabilidad de MOSS.

Dentro del campo de la inteligencia artificial se ha desarrollado la programación de expresión genética (GEP), lo que brinda eficientes resultados para predecir la socavación local (Abd-El-Hady-Rady, 2020), lo cual explica que los métodos de inteligencia artificial, como las redes neuronales artificiales (ANN), los sistemas de inferencia neurodifusa adaptativa (ANFIS), la programación genética (GP) y la programación genética lineal (LGP) se usen cada vez más para predecir la socavación en torno a estructuras hidráulicas y pilares de puentes; dentro de ellas destaca la programación de expresión genética, por tener menor error relativo con respecto al resto de ecuaciones analíticas; además, presentan mayor precisión con coeficiente de determinación ( $R^2$ ) superior a 0.90, en comparación con el modelo ANFIS. Asimismo, Hassan y Jalal (2021) propusieron un modelo para el cálculo de la socavación local para pilas de puente mediante GEP empleando 243 registros de datos, logrando un  $R^2$  de 0.901 para su modelo de campo. Por otro lado, Rathod y Manekar (2022) utilizaron la misma técnica de GEP aplicado para la predicción de la socavación local en pilas de puentes y lograron un modelo global para condiciones de campo y de laboratorio con  $R^2$  de 0.903.

Sin embargo, persiste la incertidumbre en los modelos, producto de escasas bases de datos, gran número de variables que influyen en la socavación local, condiciones propias del GEP en cuanto a número cromosomas, genes y funciones. En segundo lugar, las investigaciones se desarrollan en condiciones solo de laboratorio o de campo, por tanto, dichas funciones obtenidas en algunos de los casos no son validadas. Así, en la presente investigación se pretende estimar la socavación local en

pilas de puentes mediante la programación genética. Para ello, se espera recopilar información cuantitativa a gran escala con el fin de contribuir con una base de datos robusta que respalde el desarrollo del estudio. Además de construir modelos GEP bajo escenarios diferenciados de bases de datos de laboratorio, campo y combinado, para evaluar su desempeño, precisión y capacidad de generalización. Por último, validar el ajuste de los modelos GEP frente a datos observacionales para verificar su utilidad práctica en contextos reales.

## Materiales y métodos

### Recopilación de datos

La predicción de un modelo de socavación de pilares de puentes requirió de la recopilación de una extensa base de datos para condiciones de laboratorio y condiciones de campo. Se enfatizó el empleo de parámetros que Ebtehaj, Bonakdari, Zaji y Sharafi (2019), y Ghumman *et al.* (2024) enfatizan como los más importantes: el tirante de agua y el ancho de la pila. Además, se propuso un parámetro adimensional para resaltar la energía disipada con respecto a la forma del pilar, al cual se denomina el factor de forma ( $Sh$ ). En concordancia con Chou y Nguyen (2022), se tomaron valores desde 0.8 para pilares cuadrados, 1.0 para pilares circulares y hasta 1.3 para pilares cuadrados en concordancia. Para los registros que no presentaban la información de la geometría de la pila, se asumió la cara expuesta al flujo como circular y por tanto un valor de  $Sh$  de 1.0.

En relación con la base de datos de laboratorio, se usaron 919 registros que generaron una matriz de 7 352 datos. El registro de 552

datos se obtuvo de Wilson y Eaton (1995), y los 367 restantes de Amini-Baghdadorani *et al.* (2018). Las variables analizadas fueron el ancho del canal ( $Bn$ ), la velocidad del flujo ( $V$ ), la velocidad crítica ( $Vc$ ), el tirante de agua ( $Y$ ), el diámetro medio de la partícula ( $D50$ ), el factor de forma del pilar ( $Sh$ ), la gradación del material de la cama ( $\sigma g$ ) y la socavación local calculada ( $Ys$ ). En la Tabla 1 se muestra el resumen de los registros de datos de laboratorio.

**Tabla 1.** Rango de datos empleados en el modelo de laboratorio.

Parámetros	Unidades	Wilson y Eaton (1995)		Amini-Baghdadorani <i>et al.</i> (2018)	
		min	máx	min	máx
Ancho normal del pilar ( $Bn$ )	m	0.02	0.92	0.01	0.06
Velocidad del flujo ( $V$ )	m/s	0.15	2.16	0.22	1.23
Velocidad crítica ( $Vc$ )	m/s	0.22	1.27	0.29	0.44
Tirante de agua ( $Y$ )	m	0.02	1.90	0.06	0.60
Diámetro medio de la partícula ( $D50$ )	mm	0.22	7.80	0.60	2.40
Gradación del material de la base ( $\sigma g$ )	--	1.10	5.50	1.20	1.80
Factor de Forma ( $Sh$ )	--	--	--	0.80	1.30
Socavación local ( $Ys$ )	m	0.004	1.410	0.000	0.330

En cuanto a la base de datos de campo, se utilizaron 745 registros con 8 195 datos. Los 508 registros se obtuvieron de Wilson y Eaton (1995), y los 237 restantes de Chou y Nguyen (2022). Las variables analizadas fueron el ancho del canal ( $Bn$ ), la velocidad del flujo ( $V$ ), el tirante de agua ( $Y$ ), el factor de forma ( $Sh$ ), el ángulo de ataque ( $Sk$ ), la



gradación del material de la cama ( $\sigma_g$ ) y la socavación local ( $Y_s$ ), además de diámetros representativos de las partículas, como el diámetro de la partícula de lecho en una mezcla, cuyo 16 % es menor ( $D_{16}$ ); el diámetro de la partícula de lecho en una mezcla, cuyo 50 % es menor ( $D_{50}$ ); el diámetro de la partícula de lecho en una mezcla, cuyo 84 % es menor ( $D_{84}$ ); el diámetro de la partícula de lecho en una mezcla, cuyo 96% es menor ( $D_{96}$ ), y el "accuracy" ( $P$ ). En total se trabajó con 1 471 registros, entre los cuales se encuentran 15 547 datos cuantitativos. En la Tabla 2 se muestra la base datos de campo.

**Tabla 2.** Rango de datos empleados en el modelo de campo.

Parámetros	Unidades	Wilson y Eaton (1995)		Chou y Nguyen (2022)	
		min	máx	min	máx
Ancho normal del pilar ( $B_n$ )	m	0.30	1.86	0.30	5.50
Tirante de agua ( $Y$ )	m	0.12	22.53	0.20	22.50
Factor de Forma ( $Sh$ )	--	0.70	1.3	0.70	1.30
Ángulo de ataque ( $Sk$ )	°	--	--	0	85
Gradación del material de la base ( $\sigma_g$ )	--	1.2	20.34	1.20	21.80
Diámetro de partícula ( $D_{16}$ )	mm	0.01	68	--	--
Diámetro medio de la partícula ( $D_{50}$ )	mm	0.01	108	0.12	95
Diámetro de partícula ( $D_{84}$ )	mm	0.083	233	--	--
Diámetro de partícula ( $D_{95}$ )	mm	0.33	350	--	--
Accuracy ( $P$ )	m	0	0.91	--	--
Socavación local ( $Y_s$ )	m	0	7.65	0.1	7.7

## Programación genética

Para el análisis de la base de datos se planteó que la socavación local de la pila de puente estuvo en función de tres escenarios. El primer escenario, en condiciones experimentales, se realizó con la matriz de datos de laboratorio, como se puede apreciar en la Ecuación (1); el segundo, en condiciones reales, con la matriz de datos de campo, como se puede apreciar en la Ecuación (2); por último, la combinación de ambas matrices, como se muestra en la Ecuación (3):

$$Y_s = f(B_n, V, V_c, Y, D_{50}, \sigma_g, S_h, Y_s) \quad (1)$$

$$Y_s = f(B_n, V, Y, D_{16}, D_{50}, D_{84}, D_{95}, \sigma_g, S_h, S_k, P, Y_s) \quad (2)$$

$$Y_s = f(B_n, V, V_c, Y, D_{16}, D_{50}, D_{84}, D_{95}, \sigma_g, S_h, S_k, Y_s) \quad (3)$$

Cada modelo se desarrolló como proceso de entrenamiento de la base de datos en función del escenario para entrenar el algoritmo de la programación genética. En general, se aplicaron operadores aritméticos (+, -, \*, /); logarítmicos ( $\ln(x)$ ,  $\log(x)$ ); exponenciales ( $\exp(x)$ ,  $x^{-1}$ ,  $x^2$ ,  $x^3$ ,  $x^{1/2}$ ,  $x^{1/3}$ ), y funciones trigonométricas ( $\text{atan}(x)$ ). Los valores predominantes del número de cromosomas fueron alrededor de 30, mientras que las funciones de enlace empleadas fueron las de adición y multiplicación. En la Tabla 3 se muestran las combinaciones que se emplearon de cromosomas, genes y tamaño de celda.

**Tabla 3.** Configuraciones generales del GEP.

Parámetros	Modelos de laboratorio	Modelos de campo	Modelos de combinación
Número de cromosomas	30-32	30-32	28-30
Tamaño de celda	8-10	8-10	8-10
Número de genes	3-5	3-5	3-5

Cabe señalar que dentro del conjunto de la base de datos se reservó el 20 % para la validación del modelo y el 80 % se usó para la calibración del modelo. Por lo tanto, la estimación de la socavación local en pilas de puentes en función con el proceso de la actitud de la programación de expresión genética se realizó empleando las ecuaciones (4) y (5):

$$F_i = 1\,000 \times \frac{1}{1+E_i} \quad (4)$$

$$E_i = P_{ij} - O_j \quad (5)$$

Donde:

$F$  = función de aptitud

$P_{ij}$  = valor predicho por el cromosoma  $i$  individual para el caso de aptitud  $j$

$O_j$  = valor observado para el caso de aptitud  $j$

Cuando  $P_{ij} = O_{ij}$  significa que  $E_{ij} = 0$  es una solución perfecta sin error.

## Selección de resultados

La validación de los resultados obtenidos se realizó tomando en cuenta los criterios de error cuadrático medio (RMSE), Ecuación (6); el error absoluto medio (MAE), Ecuación (7), y el coeficiente de determinación ( $R^2$ ), Ecuación (8):

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{i=1}^n [p_i - y_i]^2} \quad (6)$$

$$MAE = \left(\frac{1}{n}\right) \times \sum_{i=1}^n [p_i - y_i] \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n [p_i - y_i]^2}{\sum_{i=1}^n [y_i - \bar{y}]^2} \quad (8)$$

## Validación de resultados

Las ecuaciones obtenidas se validaron con una matriz de datos diferente a la que se empleó para realizar la regresión lineal en el *software GenexProTools*. En el caso de la ecuación obtenida en el escenario de datos de laboratorio, se empleó una matriz de 152 registros con 912 datos recopilados en Chou y Nguyen (2022).

Para constatar la validación se empleó el error típico que generó la ecuación de Laursen modificada por Neill y el modelo GEP de campo para el cálculo de la socavación. Se seleccionó el porcentaje de validación para aquellos valores cuyo error típico fue menor del 10 %. Por otro lado, la validación se hizo con base en los datos del escenario de campo del

puente Imbaba, ubicado en El Cairo, Egipto (Abd-El-Hady-Rady, 2020). Además, los modelos se validaron con datos de campo recopilados por Chou y Nguyen (2022).

## Resultados

Los resultados obtenidos mediante los algoritmos de programación genética proporcionaron diversos modelos producto de las múltiples combinaciones de escenarios, operadores aritméticos, logarítmicos, exponenciales, cromosomas, genes y tamaño de celda. Sin embargo, se exponen tres diagramas de árbol para el cálculo más preciso de la socavación local en pilas de puente para cada escenario. En la Figura 1, Figura 2 y Figura 3 se muestran los diagramas de los árboles del escenario de laboratorio, de campo y combinado, respectivamente, de los cuales el que representa mayor magnitud de complejidad es el modelo combinado con operadores aritméticos ( $-$ ,  $*$ ,  $/$ ) y exponenciales ( $x$ ,  $x^2$ ,  $x^3$ ,  $x^{1/3}$ ).

Sub-ET 3


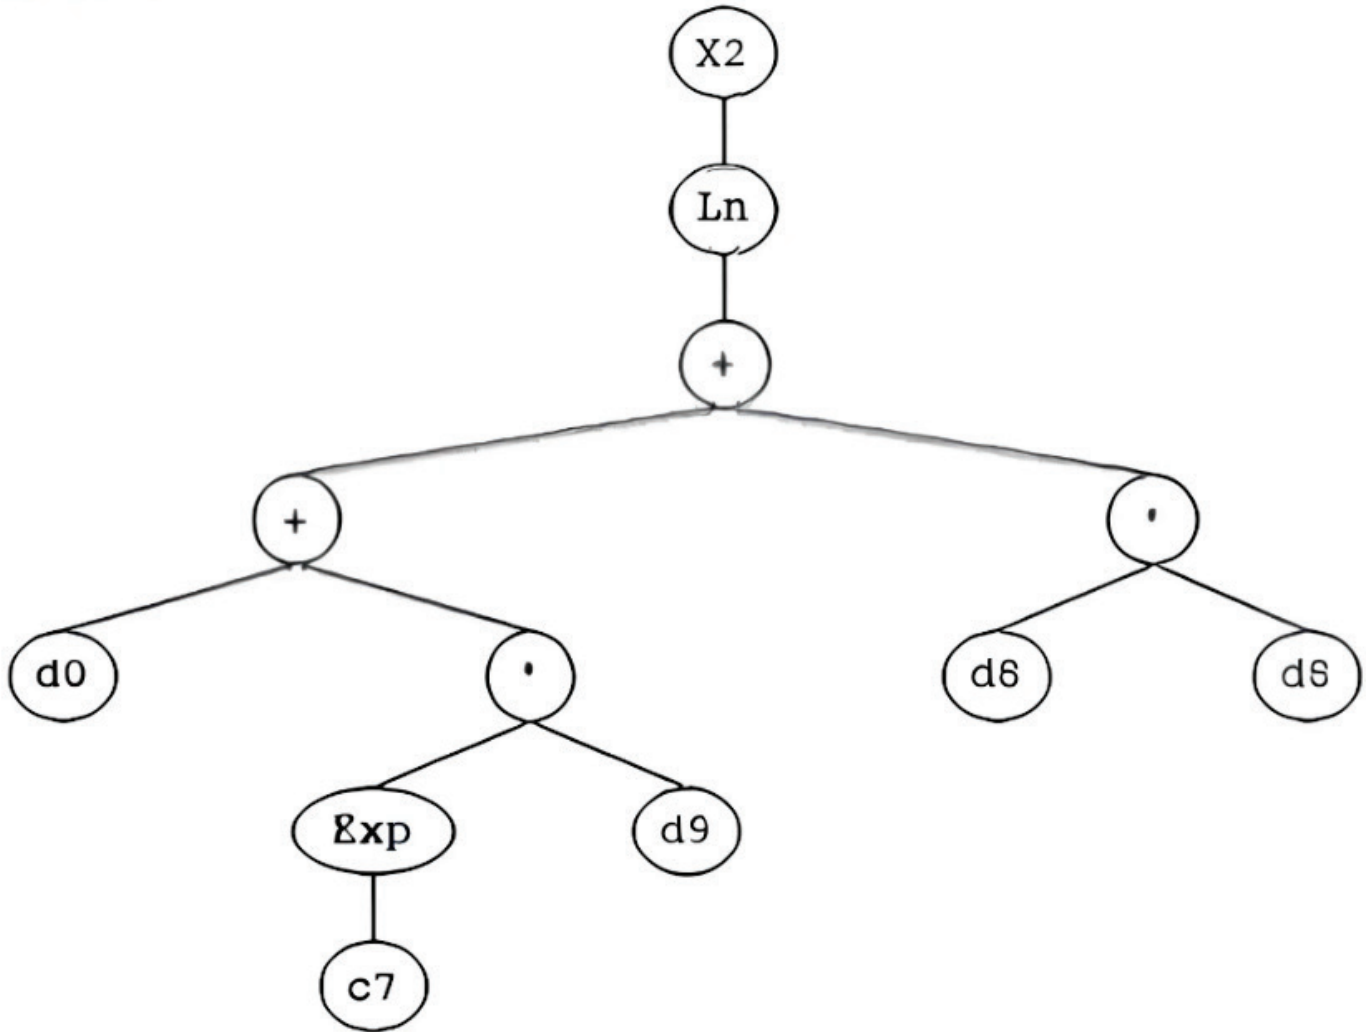



Figura 1. Diagrama de árbol del escenario de laboratorio.

Sub-ET 4



**Figura 2.** Diagrama de árbol del escenario de campo.

## Sub-ET 4



**Figura 3.** Diagrama de árbol del escenario combinado.

La interpretación física-matemática de los diagramas de árboles generados para cada escenario permitió definir las ecuaciones de mejor ajuste en cada escenario. La Ecuación (9) responde al escenario del laboratorio; la Ecuación (10), al escenario de campo; y la Ecuación (11), al escenario combinado:

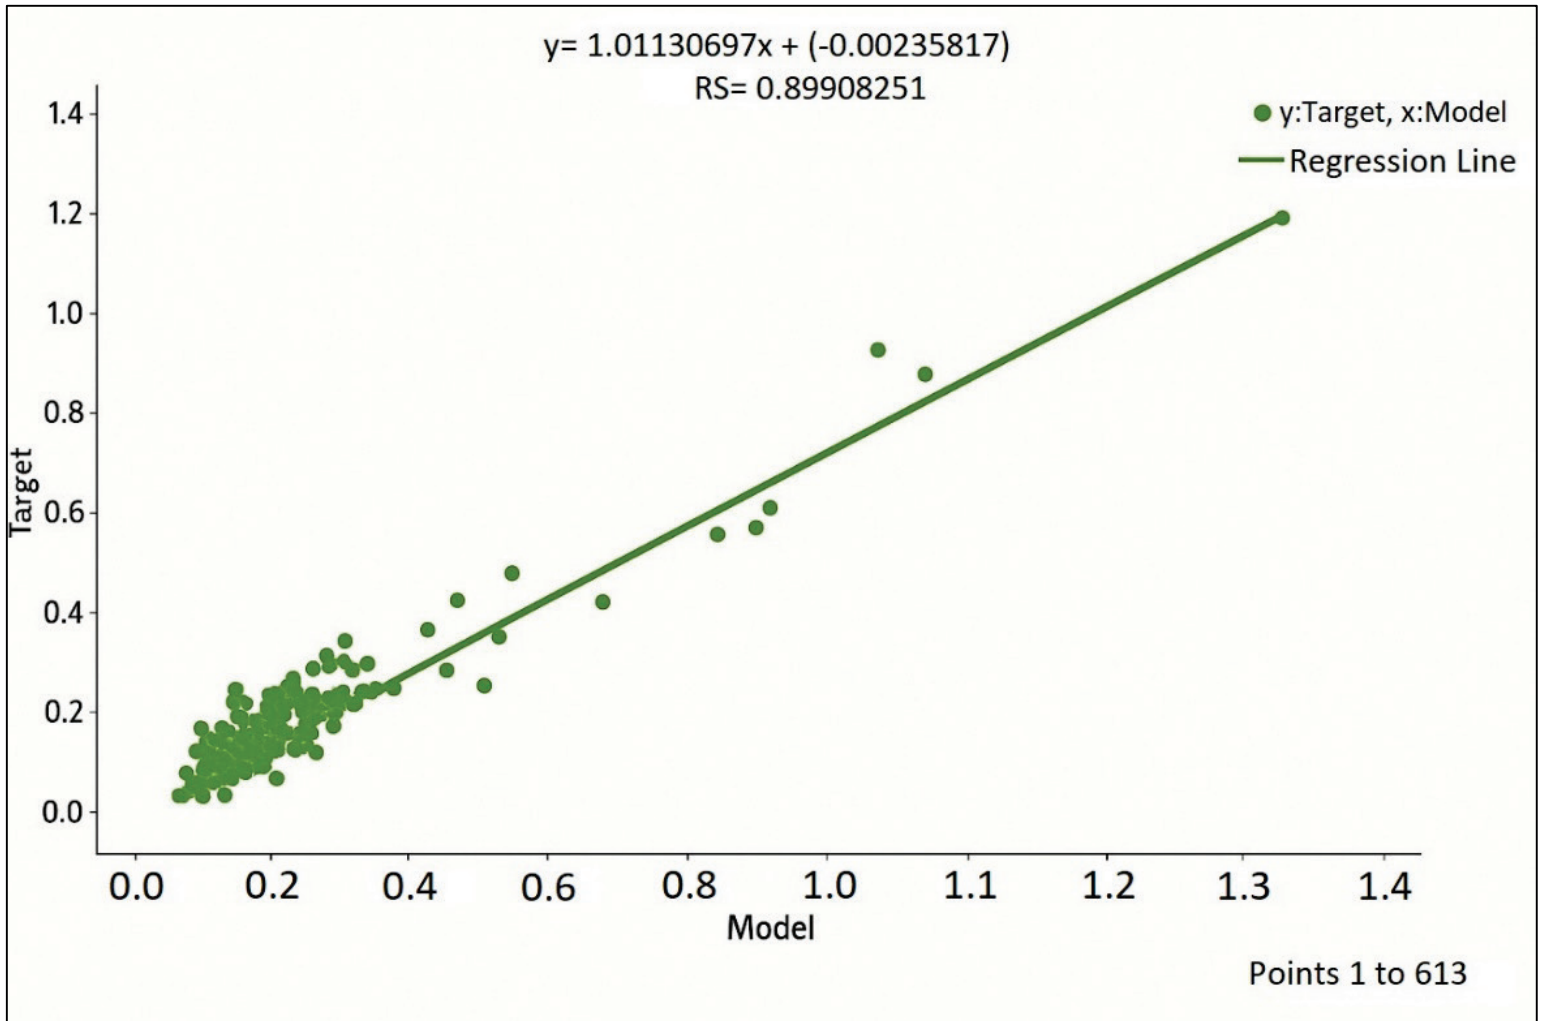
$$Y_s = 10.761 \times \ln[1.718 + D_{50}^2] \times B \times V_c \times S_h \quad (9)$$



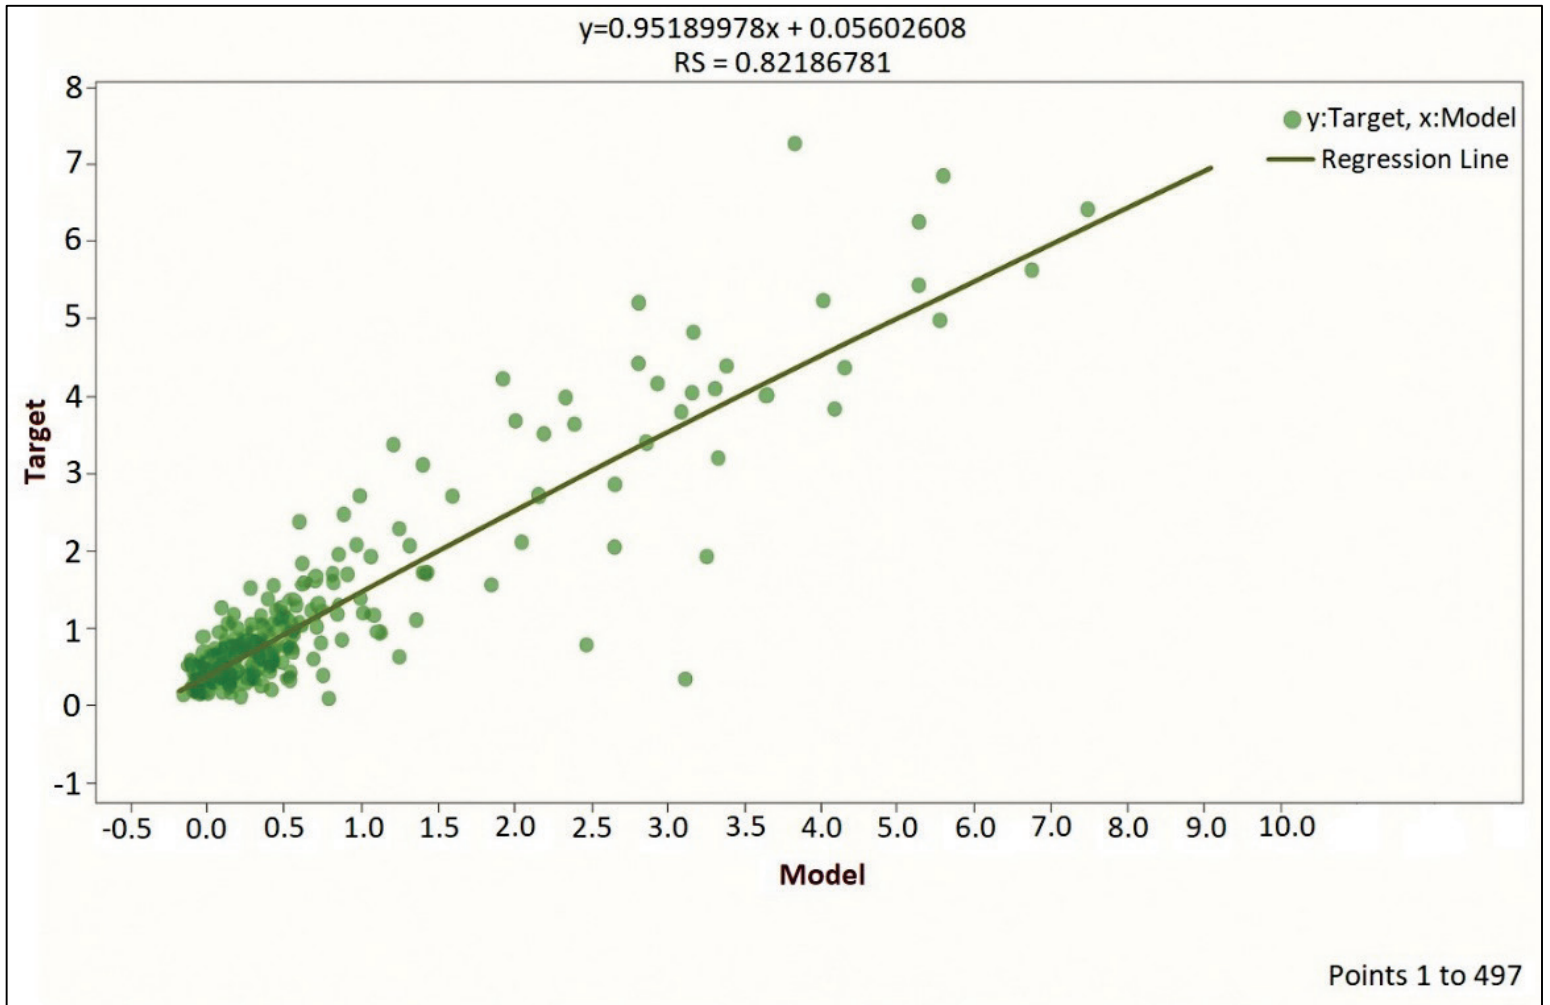
$$Y_s = [l_n(B + 0.008935S_k + S_h^2)]^2 \quad (10)$$

$$Y_s = \left( \frac{1}{-\sqrt[3]{3.576 \times B - [0.444 - V]^2 - D_{50}}} \right)^3 \quad (11)$$


En general se observa escasa dispersión de predicción de los datos del escenario de laboratorio en relación con el escenario de campo y el combinado, tal como se muestran en la Figura 4, Figura 5 y Figura 6.



**Figura 4.** Regresión lineal del escenario de laboratorio.



**Figura 5.** Regresión lineal del escenario de campo.



**Figura 6.** Regresión lineal del escenario combinado.

## Discusión

Los modelos de predicción de la socavación de pila de puente identifican como variables de mayor significancia para el rendimiento del modelo el ancho normal del pilar ( $Bn$ ), elemento que se encuentra en concordancia con Landers y Mueller (1996). Posteriormente, le siguen el diámetro medio de la partícula ( $D50$ ), factor de forma ( $Sh$ ), velocidad del flujo ( $V$ ),

velocidad crítica ( $V_c$ ) y el de menor significancia: el ángulo de ataque ( $Sk$ ).

Se consideró que  $R^2 \geq 0.9$  indica alta precisión;  $0.75 \leq R^2 \leq 0.9$ , buena precisión;  $0.6 \leq R^2 \leq 0.75$ , moderada precisión; y  $R^2 \leq 0.6$ , baja precisión (López-Silva *et al.*, 2024)

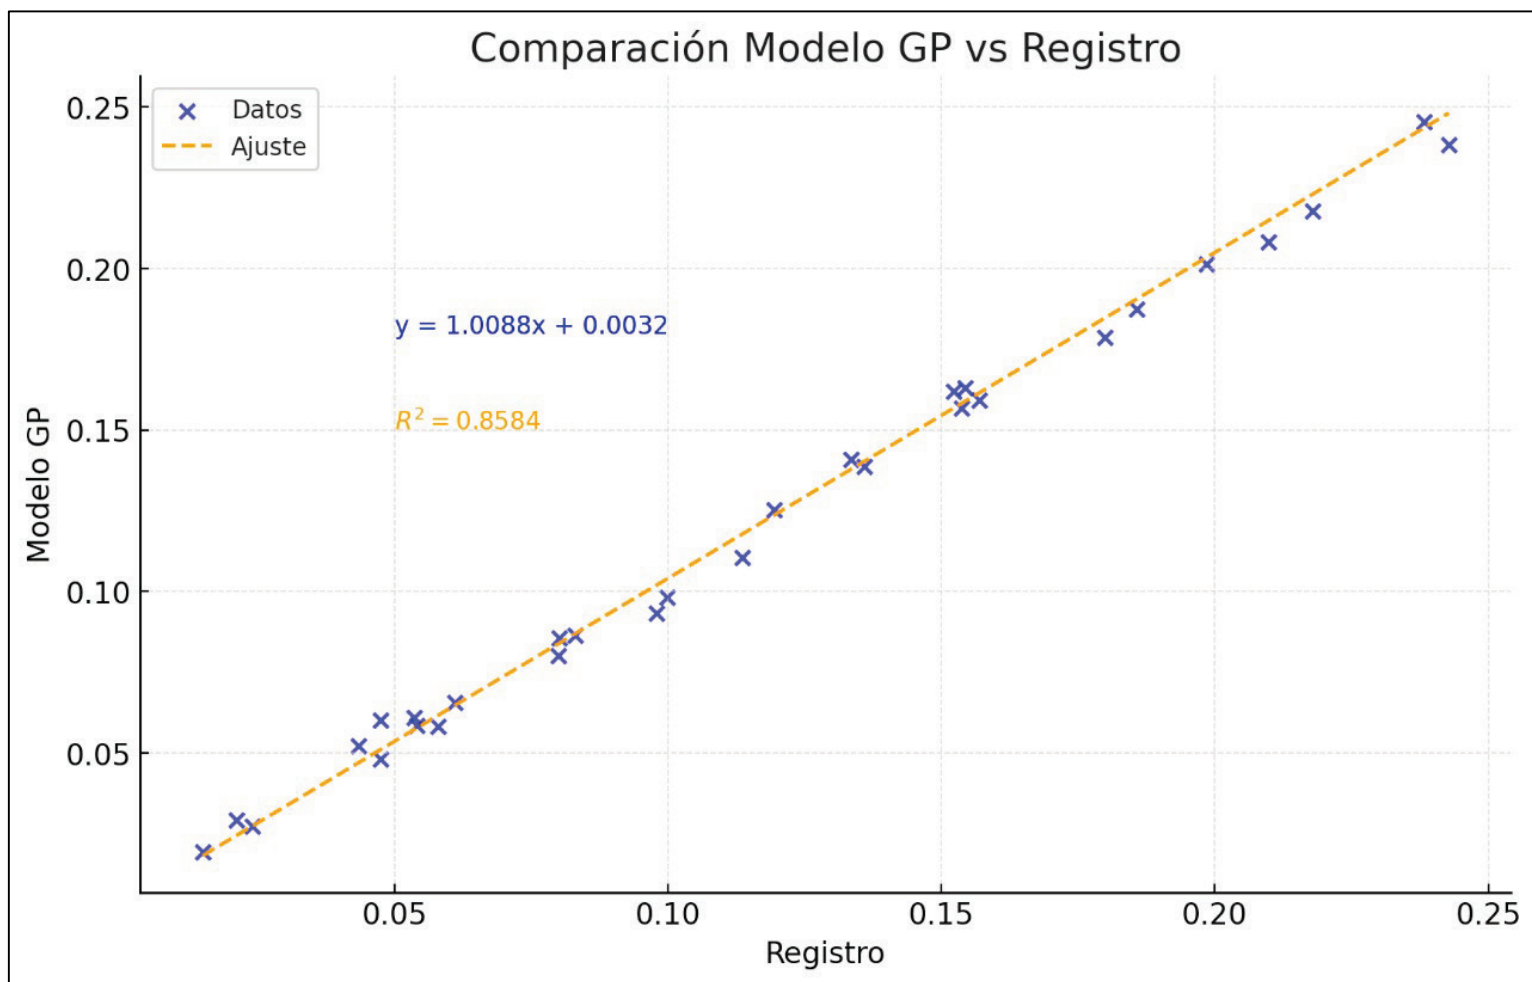
Al respecto, en el escenario de laboratorio se observa una buena precisión del modelo predictivo, producto del agrupamiento de datos con función lineal  $y = 1.011x \pm 0.002$ ,  $R^2$  de 0.899, un RMSE de 0.036 y un MAE de 0.026.

En el escenario de campo se observa mayor dispersión de datos, lo cual genera menor precisión sobre la función matemática predictiva para el escenario del laboratorio. No obstante, se encuentra en un rango de buena precisión para  $R^2$  de 0.822, RMSE de 0.546 y un MAE de 0.387.

Del mismo modo, sucede con cierta similitud el escenario combinado (Figura 6). Las posibles causas se deben a múltiples factores tanto relacionados con el modelo como con las condiciones del entorno. En relación con el modelo, se debe a su simplificación, a las características geomorfológicas locales, propiedades del lecho del río y fenómenos transitorios. No obstante, el modelo del escenario combinado mostró favorables métricas de errores con un  $R^2$  de 0.835, RMSE de 0.413 y un MAE de 0.226.

La validación de la ecuación del escenario del laboratorio mostró que el 24.5 % de los resultados obtenidos (37 de 151) presentaban un error típico menor al 10 % y que estos, al compararlos, presentaban un coeficiente de determinación de 0.858. En general, la tendencia es que mediante la ecuación del escenario del laboratorio se presentaban

resultados de socavación local similares al registrado. En la Figura 7 se muestra la gráfica de validación del escenario de laboratorio.



**Figura 7.** Validación del modelo de laboratorio, Ecuación (9).

A pesar de que algunos autores (Choi & Choi, 2022; Kim *et al.* (2025) señalan que las ecuaciones predictivas basadas en datos de laboratorio presentan disimilitudes de resultados por la geometría entre pilares y otras variables, como el diámetro medio de las partículas, en

este estudio como hallazgo significativo se ha logrado mejorar la brecha de disimilitud.

La validación de modelo del escenario de campo, Ecuación (10), muestra porcentajes de error típico mínimo y máximo de 6.73 y 14.62 %, respectivamente. Sin embargo, en relación con la ecuación de Laursen, modificada por Neil, se reflejó un error típico superior que osciló entre el 27.28 y 63.17 %, superando al escenario de campo de 27.67 a 23.14 % de error. Como se observa, existe elevado error típico por parte de la ecuación Laursen modificada por Neil, lo cual manifiesta limitaciones importantes en la capacidad predictiva del modelo. Todo ellos tienen varias implicaciones prácticas, como diseños de las dimensiones de cimentación poco fiable e inseguras, porque no están ajustadas a la realidad hidráulica del cauce. Por tanto, se demuestra que las ecuaciones analíticas tienden a sobrestimación o subestimación de los resultados de la socavación de pila de puente frente a los modelos derivados de la GEP.

Por otro lado, la validación de la ecuación —obtenida mediante programación genética— para el escenario de datos combinados sugirió valores que tienden a cero o negativos, lo que conceptualmente implica la inexistencia de socavación. Sin embargo, es sabido que la interacción de un puente con un río altera su flujo natural, por lo que la presencia de socavación es inevitable. Los modelos GEP suelen considerarse superiores a las ecuaciones analíticas tradicionales en problemas complejos como la predicción de la socavación en pilas de puentes por varias razones clave, como las siguientes: capturan relaciones no lineales complejas, flexibilidad, adaptabilidad, mejor precisión predictiva y capacidad de integración de múltiples variables. Moussa (2013), en un análisis comparativo del modelo GEP, ANN y MLR, demostró que el enfoque GEP proporciona resultados satisfactorios para la predicción de la profundidad

de socavación de aguas de las estructuras hidráulicas. Del mismo modo, Hassan y Jalal (2021), y Rathod y Manekar (2022) ratifican que el modelo GEP mantiene una robustez superior a otros modelos de inteligencia artificial para estimar la socavación en pila de puente.

Sin embargo, es necesario señalar algunas limitaciones que posee el modelo, como la amplia base de datos para el entrenamiento, posible sobreajuste para escaso proceso de validación, interpretación de expertos para proporcionar sentido físico del fenómeno. Finalmente, se han expuesto algunos procesos metodológicos y prácticos que permiten disminuir las diferencias entre los datos de laboratorio y de campo, y se proponen ecuaciones matemáticas para abordarla, considerando los niveles de precisión y conservadurismo en las actitudes de socavación evaluadas.

## Conclusiones

A partir del análisis profundo de la programación de expresión genética en *GeneXproTools*, se lograron obtener tres ecuaciones analíticas para calcular la socavación local de pilas de puentes basadas en escenarios de datos de laboratorio, de campo y combinación entre ellos. Con base en el escenario de laboratorio, se concluye que la Ecuación (9), propuesta para la predicción de la socavación local en pilas de puentes, resulta ser aquella que mostró mejor concordancia con los resultados de socavación local de la matriz de datos evaluada, con un coeficiente de determinación ( $R^2$ ) de 0.899. A esto se le añade que también presentó una concordancia significativa con el 24.5 % de los datos empleados para la validación, alcanzando un coeficiente de determinación de 0.858. Ello demostró que



esta ecuación es aplicable en entornos de laboratorio, al poseer una aproximación significativa.

De la Ecuación (10) propuesta para la predicción de la socavación local en pilas de puentes para el escenario de campo, se puede concluir que mostró mejor concordancia con los resultados socavación local de la matriz de datos evaluada con un coeficiente de determinación ( $R^2$ ) de 0.822. A esto se le añade que para la validación se obtuvo un porcentaje de error mínimo de 6.73 % y máximo de 14.62 %, y que a su vez estos porcentajes fueron menores en comparación con el modelo analítico de Laursen modificada por Neil, lo cual demuestra que la Ecuación (10) es aplicable en entornos de campo al poseer una aproximación más cercana a la realidad.

Por otro lado, la Ecuación (11) empleada para la predicción de la socavación local en pilas de puente en escenario combinados (laboratorio y campo) mostró una significativa concordancia con los resultados de la matriz de la combinación con un coeficiente de determinación de 0.835. Sin embargo, la validación de la ecuación aplicada al escenario de laboratorio mostró no tener concordancia alguna. Así, se concluye que esta ecuación no es aplicable en ambos escenarios. Para finalizar, es importante destacar que con las ecuaciones encontradas mediante programación genética se podría proyectar con mejor precisión la profundidad a la cual deberían estar situadas las pilas de los puentes, haciendo que sean más seguras, eficientes, económicas y, sobre todo, estables, frente a las transformaciones climáticas actuales.

## Agradecimientos

Agradecemos en primer lugar a Dios, por brindarnos la sabiduría, fortaleza y perseverancia necesarias para culminar este proyecto. A nuestras familias, por su amor incondicional, comprensión y constante apoyo a lo largo de este proceso. A la Escuela Profesional de Ingeniería Civil de la Universidad Ricardo Palma y a su equipo por el acompañamiento y el entorno necesario para desarrollar esta investigación plenamente. De manera especial, queremos reconocer a la Dra. Enriqueta Pereyra Salardi, directora de escuela, y a su equipo de trabajo, por su constante gestión y compromiso con la excelencia académica. Asimismo, extendemos nuestro agradecimiento al M.I. Marco Antonio Hernández Aguilar por su apoyo y disposición.

## Referencias

- Abd-El-Hady-Rady, R. (2020). Prediction of local scour around bridge piers: artificial-intelligence-based modeling versus conventional regression methods. *Applied Water Science*, 10(2), 57. <https://doi.org/10.1007/s13201-020-1140-4>
- Amini-Baghdadorani, D., Ataie-Ashtiani, B., Beheshti, A., Hadjzaman, M., & Jamali, M. (2018). Prediction of current-induced local scour around complex piers: Review, revisit, and integration. *Coastal Engineering*, 133(43-58). <https://doi.org/10.1016/j.coastaleng.2017.12.006>
- Belmonte, H. (1990). *Puentes* (4ª ed.). La Paz, Bolivia: Imprenta Ramírez.

- Choi, S. U., & Choi, S. (2022). Prediction of local scour around bridge piers in the cohesive bed using support vector machines. *KSCE Journal of Civil Engineering*, 26(5), 2174-2182. <https://doi.org/10.1007/S12205-022-1803-9>
- Chou, J.-S., & Nguyen, N.-M. (2022). Scour depth prediction at bridge piers using metaheuristics-optimized stacking system. *Automation in Construction*, 140, 104297. <https://doi.org/10.1016/j.autcon.2022.104297>
- Ebtehaj, I., Bonakdari, H., Zaji, A. H., & Sharafi, H. (2019). Sensitivity analysis of parameters affecting scour depth around bridge piers based on the non-tuned, rapid extreme learning machine method. *Neural Computing and Applications*, 31(12), 9145-9156. <https://doi.org/10.1007/s00521-018-3696-6>
- Fuladipanah, M., Hazi, M. A., & Kisi, O. (2023). An in-depth comparative analysis of data-driven and classic regression models for scour depth prediction around cylindrical bridge piers. *Applied Water Science*, 13(12), 231. <https://doi.org/10.1007/s13201-023-02022-0>
- Ghumman, A. R., Haider, H., Al-Salamah, I. S., Shafiquzzaman, Md., Alodah, A., Alresheedi, M., Farooq, R., Ahmed, A., & Pasha, G. A. (2024). Local scour depth around bridge piers: performance evaluation of dimensional analysis-based empirical equations and AI techniques. *KSCE Journal of Civil Engineering*, 28(8), 3270-3285. <https://doi.org/10.1007/s12205-024-1161-x>
- Guevara, M. (2021). *Socavación en puentes*. Popayán, Colombia: Editorial Universidad del Cauca.

- Hassan, W. H., & Jalal, H. K. (2021). Prediction of the depth of local scouring at a bridge pier using a gene expression programming method. *SN Applied Sciences*, 3(2), 159. <https://doi.org/10.1007/s42452-020-04124-9>
- Khosravi, K., Khozani, Z. S., & Mao, L. (2021). A comparison between advanced hybrid machine learning algorithms and empirical equations applied to abutment scour depth prediction. *Journal of Hydrology*, 596, 126100. <https://doi.org/10.1016/j.jhydrol.2021.126100>
- Kim, T., Shahriar, A. R., Lee, W. D., Choi, Y., Kwon, S., & Gabr., M. A. (2025). Field data-based prediction of local scour depth around bridge piers using interpretable machine learning. *Transportation Geotechnics*, 52, 101567. <https://doi.org/10.1016/J.TRGEO.2025.101567>
- Kumar, V., Baranwal, A., & Das, B. S. (2024). Prediction of local scour depth around bridge piers: modelling based on machine learning approaches. *Engineering Research Express*, 6(1), 015009. <https://doi.org/10.1088/2631-8695/ad08ff>
- Landers, M. N., & Mueller, D. S. (1996). Evaluation of selected pier-scour equations using field data. *Transportation Research Record*, 1523(1), 186-195. <https://doi.org/10.1177/0361198196152300123>
- López-Silva, M., Carmenates-Hernández, D., Poma-Puente, R., Calderón-Rufasto, J., & Sanchez-Verastegui, W. (2024). Modelos de resistencia al flujo en río de montaña: semiempíricos, HEC-RAS y GEP. *Ingeniería Del Agua*, 28(2), 123-140. <https://doi.org/10.4995/ia.2024.20629>

- Moussa, Y. A. M. (2013). Modeling of local scour depth downstream hydraulic structures in trapezoidal channel using GEP and ANNs. *Ain Shams Engineering Journal*, 4(4), 717-722. <https://doi.org/10.1016/J.ASEJ.2013.04.005>
- Qi, M., Li, J., & Chen, Q. (2016). Comparison of existing equations for local scour at bridge piers: Parameter influence and validation. *Natural Hazards*, 82, 2089–2105. <https://doi.org/10.1007/s11069-016-2287-z>
- Rathod, P., & Manekar, V. L. (2022). Gene expression programming to predict local scour using laboratory and field data. *ISH Journal of Hydraulic Engineering*, 28(2), 143-151. <https://doi.org/10.1080/09715010.2020.1846144>
- MTC, Ministerio de Transportes y Comunicaciones. (2018). *Manual de hidrología, hidráulica y drenaje*. Lima, Perú: Ministerio de Transportes y Comunicaciones de Perú.
- Rocha, A. (2013). *Hidráulica de obras viales* (3ª. ed.). Lima, Perú: Fondo Editorial ICG. Recuperado de <https://www.gob.pe/institucion/mtc/normas-legales/4443017-20-2011-mtc-14>
- Rodríguez, A. (2020). *Puentes* (8ª ed.). Lima, Perú: Rodríguez, A.
- Wilson, K. V., & Eaton, G. P. (1995). Scour at selected bridge sites in Mississippi. Water-Resources Investigations Report. *U.S. Geological Survey*. <https://doi.org/10.3133/WRI944241>
- Zhang, L., Liu, J., Liu, Y., Lan, S., & Yang, J. (2022). Causes and statistical characteristics of bridge failures: A review. *Journal of Traffic and Transportation Engineering*, 9(3), 499-515. <https://doi.org/10.1016/j.jtte.2021.12.003>