

DOI: 10.24850/j-tyca-2026-03-07

Artículos

Enfoque de inteligencia artificial aplicado al tiempo de concentración de unidades hidrográficas

Artificial intelligence approach applied to the time of concentration of hydrographic units

Maiquel López-Silva¹, ORCID: <https://orcid.org/0000-0002-0946-6160>

Brayan Alca-Vásquez², ORCID: <https://orcid.org/0009-0001-8557-9108>

Valeria Ricaldi-Marquez³, ORCID: <https://orcid.org/0009-0003-4035-2246>

¹Universidad Ricardo Palma, Lima, Perú, maiquel.lopez@urp.edu.pe

²Universidad Ricardo Palma, Lima, Perú, 202012238@urp.edu.pe

³Universidad Ricardo Palma, Lima, Perú, 202011289@urp.edu.pe

Autor para correspondencia: Brayan Alca-Vásquez,
202012238@urp.edu.pe

Resumen

El presente estudio propuso un enfoque de inteligencia artificial para la obtención del tiempo de concentración en unidades hidrográficas. En primer lugar, se examinaron 30 ecuaciones empíricas sobre una base de datos de 199 registros y, en segundo lugar, se orientó la programación



de expresión genética (GEP) sobre una matriz de datos de 199 registros de diferentes continentes. Por último, los modelos de predicción se analizaron bajo tres métricas de error, el coeficiente de determinación (R^2), el error absoluto medio (MAE) y el error cuadrático medio (MSE). Se generaron cinco modelos precisos bajo la técnica de GEP siendo el más óptimo el cuatro con $R^2 = 0.991$, MAE = 0.152 y MSE = 0.086. Sin embargo, al validar con datos reales de campo, la ecuación del modelo I presentó el menor error relativo, demostrando una confiabilidad superior en comparación con ecuaciones empíricas como Kirpich. Se concluye que si bien los modelos más complejos pueden alcanzar alta precisión, la simplicidad de las ecuaciones es crucial para su aplicabilidad en diversas unidades hidrográficas. Este enfoque basado en inteligencia artificial ofrece una alternativa efectiva para el diseño y la gestión hidráulica en regiones no aforadas, con potencial para futuras ampliaciones de su aplicabilidad en estudios hidrológicos.

Palabras clave: inteligencia artificial, hidrología, cuenca hidrográfica, escorrentía, modelos matemáticos, precipitación, análisis de datos, Perú.

Abstract

The present study proposed an artificial intelligence approach for obtaining the time of concentration in hydrographic units. First, 30 empirical equations were examined on a database of 199 records and second, gene expression programming (GEP) was guided on a data matrix of 199 records from different continents. Finally, the prediction models were analyzed under three error metrics, the coefficient of determination (R^2), the mean absolute error (MAE) and the mean square error (MSE). Five accurate models were generated under the GEP technique, the most

optimal being the fourth with $R^2 = 0.991$, MAE = 0.152 and MSE = 0.086. However, when validated with real field data, the equation of model I presented the lowest relative error, demonstrating superior reliability compared to empirical equations such as Kirpich. It is concluded that, although more complex models can achieve high accuracy, the simplicity of the equations is crucial for their applicability in various hydrographic units. This artificial intelligence-based approach offers an effective alternative for hydraulic design and management in ungauged regions, with potential for future extensions of its applicability in hydrological studies.

Keywords: artificial intelligence, hydrology, watersheds, runoff, mathematical models, precipitation, data analysis, Peru.

Recibido: 17/12/2024

Aceptado: 08/08/2025

Publicado *ahead of print*: 08/09/2025

Versión final: 01/05/2026

Introducción

En el dinámico y desafiante panorama hidrológico del Perú, el diseño y la gestión de estructuras hidráulicas representan pilares fundamentales para la seguridad, sostenibilidad y desarrollo del país. González-Álvarez *et al.* (2019) resaltan la importancia del análisis de los parámetros morfométricos de la unidad hidrográfica, cálculo de la máxima avenida y dimensionamiento de la estructura hidráulica.

Para obtener máxima avenida en unidades hidrográficas no aforadas es imprescindible la obtención del tiempo de concentración, el cual está estrechamente relacionado con los parámetros morfométricos de la unidad hidrográfica. La precisión en la estimación de los parámetros, como el tiempo de concentración, es a menudo el eslabón débil que puede desencadenar una serie de consecuencias adversas que van desde el sobredimensionamiento innecesario de infraestructuras hasta fallas estructurales catastróficas y una inadecuada respuesta ante eventos hidrometeorológicos extremos. Castillo, Abreu y Alvarez (2021) enfatizan en el rol fundamental que cumplen los parámetros geomorfológicos para la caracterización de una unidad hidrográfica, siendo el tiempo de concentración el más relevante.

Diversos autores, como Morgali y Linsley (1965); Giandotti (1934), Carter (1961), y Linsley, Kohler, Paulhus, Serra y Aparicio (1977), han propuesto ecuaciones para la obtención del tiempo de concentración calibradas, pero con restricciones para la propia unidad hidrográfica y uso general. Por lo común, estas ecuaciones están vinculadas con la longitud del cauce principal (L), pendiente media del cauce principal (S), coeficiente de escorrentía (C) y área de la unidad hidrográfica (A). Sin embargo, otros autores, como Jung (2005), Albishi, Bahrawi y Elfeki (2017), Kirpich (1940), JSCE (1999), señalan que los más influyentes en el tiempo de concentración son L y S .

La determinación del tiempo de concentración (T_c) ha sido un gran problema para los ingenieros debido a la incertidumbre de que no existe una regla general sobre cuál elegir. Kaufmann, Kaufmann, Garcia y Alves (2017) describen una metodología gráfica para la estimación del tiempo de concentración en comparación con los métodos empíricos, resultando de mayor precisión el método gráfico. Asimismo, Castillo *et al.* (2021)

exponen un estudio de ecuaciones empíricas en Cuba, clasificándolas en conservadoras, media y no conservadoras, según los valores de tiempo de concentración. Por otro lado, Michailidi, Antoniadi, Koukouvinos, Bacchi y Efstratiadis (2018) proporcionan un método basado en un entorno de sistema de información geográfica donde analizaron 30 unidades hidrográficas obteniendo una expresión matemática, pero solo es válida para la unidad hidrográfica en análisis. Igualmente, Alamri, Afolabi, Ewea y Elfeki (2023) plantean un nuevo modelo para predecir el tiempo de concentración, comparándolo con las fórmulas existentes en la literatura, obteniendo un coeficiente de correlación de 0.62. En el área de la hidrología, una herramienta ampliamente usada los últimos años es el modelo hidráulico bidimensional (2D); en tal sentido, Fathi y Zolghadr (2023) proponen un método para la estimación de tiempos de concentración mediante modelos hidráulicos bidimensionales con un error del 10 %. De igual modo, Zolghadr *et al.* (2022) plantean modelos hidráulicos bidimensionales, pero con un error del 3 y 27 % siendo estos más bajos que los métodos empíricos encontrados en la literatura.

La programación de expresión genética (GEP) está emergiendo como una solución ingenieril altamente precisa, especialmente en unidades no hidrográficas no aforadas. Su uso en la prevención de variables hidrológicas se apoya en su capacidad para efectuar complejas relaciones no lineales que superan los límites de los modelos convencionales. Esto hace que GEP pueda seleccionar de forma automática los rezagos más pertinentes que se unen con la variable dependiente. En consecuencia, es capaz de producir ecuaciones automáticas específicas en la selección de variables pertinentes con alta versatilidad en diferentes escalas.

Para ser más específico, diversas investigaciones han demostrado que la GEP mejora de modo significativo las estadísticas de ajuste (R^2 , NSE, RMSE) en relación con otros métodos. Pouyanfar, Nozari y Khodamorad (2023) citan que GEP para el pronóstico de escorrentía mensual tuvo un mejor desempeño que el modelo RegCM, con una precisión de entre el 30 y 40 % para $R^2 = 0.85$. Waqas *et al.* (2021) investigaron la correlación de la lluvia con la escorrentía fluvial a través de GEP, una máquina vectorial SVM con función radial de sesgos (RBF-SVM) y un árbol M5. La conclusión de los autores es que GEP funcionó mejor entre el resto de los modelos. Además, Fuladipanah *et al.* (2024) investigan las relaciones entre escorrentía y lluvia mediante el GEP y otros algoritmos de aprendizaje automático, como perceptrón multicapa *splines* de regresión multivariante adaptativa (MARS). Los resultados indican que el modelo del GEP salió como la mejor opción, con valores RMSE = 43.028, MAE = 9.991 y $R^2 = 0.909$; aunque Kavooosi y Khozaymehnehad (2021) también utilizaron GEP, máquina de vectores de soporte por mínimos cuadrados (LS-SVM), red neuronal (NN) y el sistema adaptativo de inferencia neurodifusa con optimización por enjambre de partículas (ANFIS-PSO). Como resultado, los autores concluyen que la técnica ANFIS-PSO fue la mejor opción entre la sección de entrenamiento y en la de prueba. Si bien no existen medidas individuales del tiempo de concentración, los modelos GEP para escorrentía generalmente presentan valores de R^2 entre 0.85 y 0.97, que permiten una mejora del 15 al 40 % con respecto a los métodos convencionales (RBF-SVM, M5, MARS, MLR, ANN, SVM). Estos intervalos implican que los modelos GEP pueden modelar muy bien la dependencia temporal que expresa el tiempo que tarda el flujo en absorberse en la cuenca.

En la literatura, actualmente los autores no han evidenciado en revistas indexadas investigaciones que utilicen enfoque de inteligencia artificial basado en GEP para predecir la estimación del tiempo de concentración. En general, las investigaciones se enfocan a la estimación de caudales, inundación y socavación, entre otras. Valderrama, Chávez, Muñoz, Tuesta-Monteza y Mejía-Cabrera (2021) realizan una revisión literaria y encuentran solo nueve aplicaciones en las ramas de hidráulica, dando como resultado promedio que los modelos tuvieron como coeficiente de determinación 0.99. Sin embargo, Vásquez-Ramírez y Vásquez-Paredes (2023) utilizan redes neuronales artificiales para modelar la relación entre precipitación y escorrentía en Perú, logrando una bondad de ajuste del 81 %. Asimismo, Vargas-Crispin, Montes-Raymundo, Castrejón-Valdez e Hinojosa-Benavides (2021) aplican distintos modelos de aprendizaje automático para evaluar la variación de los recursos hídricos.

Por tanto, la investigación propone un nuevo enfoque de inteligencia artificial y se orientó la programación de expresión genética (GEP) para estimar el tiempo de concentración en unidades hidrográficas.

Materiales y métodos

La investigación utilizó una matriz de datos de 199 valores registrados en diferentes continentes, como se muestra en la Tabla 1. Esto permitió un análisis más integral de los parámetros morfométricos en función del tiempo de concentración.

Tabla 1. Cuadro resumen de base de datos.

Autor	Número de datos	Número de UH	País	Continente
Aldana y Leigue (2022)	4	1	Bolivia	América del Sur
Masoud <i>et al.</i> (2024)	48	12	Arabia Saudita	Asia
ANA (2003a)	4	1	Perú	América del Sur
ANA (2003b)	76	19	Perú	América del Sur
ANA (2007)	16	4	Perú	América del Sur
ANA (2010a)	20	5	Perú	América del Sur
ANA (2010b)	32	8	Perú	América del Sur
ANA (2017)	20	5	Perú	América del Sur
Balladares (2022)	4	1	Perú	América del Sur
Cachuán (2017)	4	1	Perú	América del Sur
Canales (2021)	276	69	Perú	América del Sur
Del-Aguila y Mejía (2021)	8	2	Perú	América del Sur
García y Onrubia (2003)	12	3	Portugal	Europa
Gomez y Paytan (2017)	16	4	Perú	América del Sur
FAO e INADE (2003)	4	1	Perú	América del Sur
INDECI y PNUD (2004)	4	1	Perú	América del Sur
INDECI y PNUD (2005)	16	4	Perú	América del Sur
Iruri y Jiménez (2021)	4	1	Perú	América del Sur
López-Silva, Carmenates-Hernandez, Sao-Cancio, Valderrama-Romero y Huamaní-Navarrete (2022)	148	37	Perú	América del Sur
Minagri (2007)	12	3	Perú	América del Sur
Nieto y De-la-Torre (2023)	36	9	Perú	América del Sur
Senamhi (2013)	12	3	Perú	América del Sur
Marín (2018)	16	4	Perú	América del Sur
Vargas (2022)	4	1	Perú	América del Sur

Para estimar el tiempo de concentración en las unidades hidrográficas (UH) se utilizaron los métodos empíricos existentes en la literatura internacional como factor que contribuyó a la base de datos en la aplicación del enfoque de inteligencia artificial en la programación de expresión genética (GEP). En la Tabla 2 se muestran las 30 ecuaciones matemáticas utilizadas en el estudio.

Tabla 2. Métodos empíricos para estimar el tiempo de concentración.

Nombre	Referencia	Ecuación
1. Ahn-Lee	Ahn y Lee (1986)	$T_c = 5.6256L^{0.9417}A^{-0.3666}S^{-0.2639}$
2. Basso	Eslamian y Mehrabi (2005)	$T_c = 0.957L^{1.155}H^{-0.385}$
3. Bransby-Williams	MOTH (1998)	$T_c = 0.605LA^{-0.3}(100S)^{-0.2}$
4. Carter	Carter (1961)	$T_c = 0.0977L^{0.6}S^{-0.2}$
5. Chow	Chow, Maidment y Mays (1988)	$T_c = 0.1602L^{0.64}S^{-0.32}$
6. Clark	Vélez y Botero (2011)	$T_c = 0.335A^{0.593}S^{-0.2965}$
7. Corps of Engineers	Linsley <i>et al.</i> (1977)	$T_c = 0.191L^{0.76}S^{-0.19}$
8. Epsy	Azizian (2018)	$T_c = 6.89(LS^{-0.5})^{0.36}$
9. Flavell	Flavell (1982)	$T_c = 2.31A^{0.54}$
10. Giandotti	Giandotti (1934)	$T_c = \frac{(4A^{0.5} + 1.5L)}{0.8H^{0.5}}$
11. Haktanir-Sezen	Haktanir y Sezen (1990)	$T_c = 0.7473L^{0.841}$
12. Jeong	Jeong (2005)	$T_c = 0.119L^{0.777}S^{-0.212}$
13. Kim	Kim (2015)	$T_c = 0.089A^{0.427}S^{-0.239}$
14. Kirpich-Pen	Kirpich (1940)	$T_c = 0.01104L^{0.77}S^{-0.5}$
15. Kirpich-Ten	Kirpich (1940)	$T_c = 0.0663L^{0.77}S^{-0.385}$

Nombre	Referencia	Ecuación
16. Kraven (I)	JSCE (1999)	$T_c = 0.0074LS^{-0.515}$
17. MOCT	Yoo, Lee y Cho (2019)	$T_c = 1.68L^{0.5}S^{-0.25}$
18. Pérez	Vélez y Botero (2011)	$T_c = 0.01389L\left(\frac{H}{L}\right)^{-0.6}$
19. Pickering	Mata-Lima <i>et al.</i> (2007)	$T_c = 0.9482L^{1.155}H^{-0.385}$
20. Picking	Silveira (2005)	$T_c = 0.0883L^{0.667}S^{-0.332}$
21. Pilgrim-MacDermott	Pilgrim y McDermott (1982)	$T_c = 0.76A^{0.38}$
22. Rziha	Rziha (1876)	$T_c = 0.0139LS^{-0.6}$
23. Sheridan	Sheridan (1994)	$T_c = 2.2L^{0.92}$
24. Temez	Temez (1978)	$T_c = 0.3L^{0.76}S^{-0.19}$
25. USGS	Straub, Melching y Kocher (2000)	$T_c = 1.54L^{0.875}S^{-0.181}$
26. Ventura	Mata-Lima <i>et al.</i> (2007)	$T_c = 4A^{0.5}L^{0.5}H^{-0.5}$
27. Yoon	Yoon, Kim y Park (2005)	$T_c = 1.08A^{0.09}L^{0.16}S^{-0.12}$
28. Jung	Jung (2005)	$T_c = 0.119\left(\frac{L^{0.777}}{S^{0.212}}\right)$
29. California Culvert Practice	California Department of Public Works (1960)	$T_c = \left(\frac{0.87075L^3}{H}\right)^{0.385}$
30. Albishi	Albishi <i>et al.</i> (2017)	$T_c = \frac{L^{0.09}}{S^{0.11}}$

Donde:

T_c = tiempo de concentración (h)

A = área de la unidad hidrográfica (km²)

L = longitud del cauce principal (km)

S = pendiente del cauce (m/m)

H = desnivel (m)

El modelo de la programación de expresión genética (GEP) codificó de manera lineal los cromosomas para posterior a ello transformarlo en una expresión no lineal (Ding *et al.*, 2023); es decir, los árboles de expresión (ET). Se consideraron como variables independientes L , S , A , H .

La GEP siguió una serie de pasos para determinar un modelo matemático basado en la evolución genética de Darwin. La Figura 1 muestra el diagrama de flujo que describe el proceso. Asimismo, se representaron las métricas de precisión para la validación del modelo.

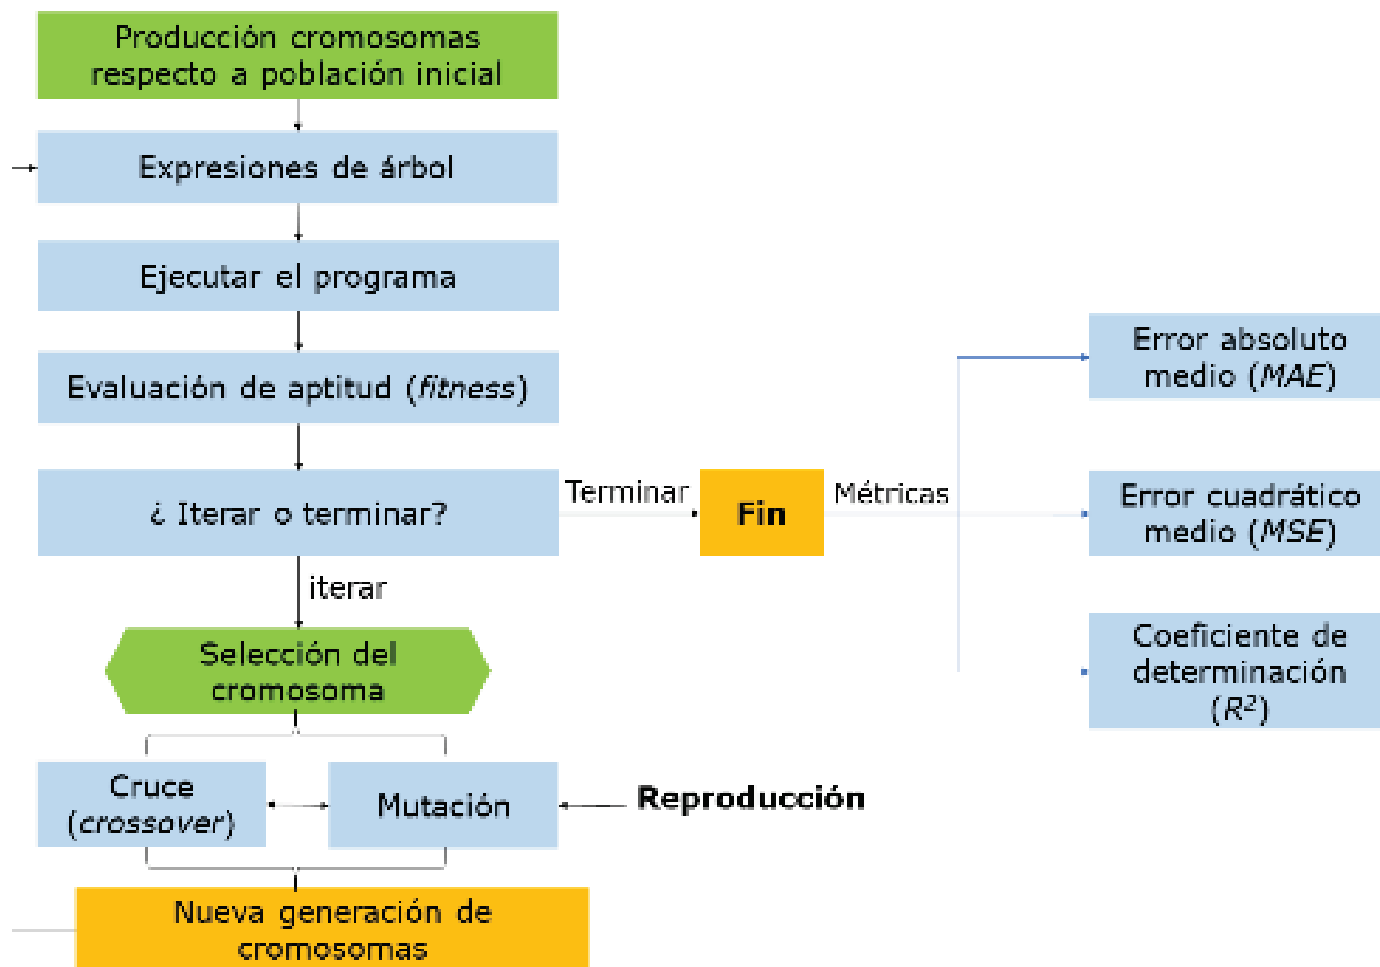


Figura 1. Diagrama de flujo de GEP para validación de resultados.

Para las ecuaciones de las métricas de precisión, el error absoluto medio (MAE) y el error cuadrático medio (MSE), n representa el número de observaciones; y_i , el valor real, y \hat{y}_i es el valor predicho. Para el coeficiente de determinación R^2 , y_i son los valores de la variable dependiente; \hat{y}_i , los valores predichos del modelo; \bar{y}_i , la media de y ; n , el número de filas, y k es el número de variables en el modelo. Para R^2 , el ajuste será débil si es menor a 0.5; moderado, si es mayor o igual a 0.5, o menor e igual a 0.8; y será fuerte si es mayor a 0.8.

La población en la GEP se definió a partir de los genes que están compuestos por una cabeza (h) y una cola (t), siendo esta última una función de la longitud de la primera:

$$t = h \cdot (n - 1) + 1 \quad (1)$$

En la Ecuación (1):

t = longitud de la cola

h = longitud de la cabeza

n = número de argumentos

Cada cromosoma puede representarse como:

$$C_i = \{g_1, g_2, g_3, \dots, g_L\} \text{ con } i = 1, 2, 3, \dots; N \quad (2)$$

En la Ecuación (2):

L = longitud fija del cromosoma, es decir, $h + t$

N = tamaño de la población

Posteriormente, se decodificó la expresión lineal para conformar los árboles de expresión.

La aptitud física en el modelo GEP se definió a partir de cada programa que evaluó utilizando una función de aptitud, ($f(x)$), que midió qué tan bien resuelve el problema en cuestión:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3)$$

En la Ecuación (3):

n = número de observaciones

y_i = valor real

\hat{y}_i = valor predicho

Mientras que la selección en el modelo GEP se utilizaron métodos idóneos, como la selección por torneo o la selección por ruleta:

$$P_i = \frac{f_i}{\sum_{j=1}^N f_j} \quad (4)$$

En la Ecuación (4):

P_i = probabilidad de selección

N = tamaño de la población

f_i = aptitud del cromosoma

Asimismo, en la reproducción del modelo GEP se realizaron operaciones genéticas como cruce y mutación para generar nuevos cromosomas. En el cruce o *crossover* se intercambiaron partes de dos cromosomas C_i y C_j . En la mutación, un gen del cromosoma se reemplaza por otro aleatorio de su conjunto. Se realizó el proceso de selección para determinar el cronograma más apto y se volvió a iterar tantas veces como fueron necesarias.

Resultados

Se describieron los resultados del análisis estadístico realizado sobre la base de datos para establecer el rango de trabajo, como se indica en la Tabla 3.

Tabla 3. Estadística de las variables de predicción.

Variable	Promedio	Varianza	Coef. varianza	Mínimo	Máximo
<i>H</i>	1 131.182	1 469 812.663	1.072	7.000	4 300.000
<i>A</i>	99.017	5 247.775	0.732	11.340	267.600
<i>L</i>	21.096	689.286	1.244	0.374	131.760
<i>S</i>	0.130	0.605	5.977	0.000	10.986

La Tabla 4 proporcionó un análisis del comportamiento de cada ecuación empírica, evaluando la precisión de los valores obtenidos de los tiempos de concentración de la matriz de datos para escoger las mejores ecuaciones sustentadas en un enfoque estadístico y garantizó que las ecuaciones seleccionadas fueran confiables.

Tabla 4. Estadística de las ecuaciones del tiempo de concentración.

Ecuación	Media	Desviación estándar	Varianza	Coefficiente variación	Mínimo	Mediana	Máximo
Ahn-Lee	42.438	39.066	1 526.165	0.921	1.677	29.407	223.920
Basso	11.411	20.587	423.809	1.804	0.086	3.700	150.772
Bransby-Williams	2.346	2.236	5.000	0.953	0.067	1.584	14.025
Carter	1.058	0.722	0.521	0.682	0.112	0.844	4.042

Ecuación	Media	Desviación estándar	Varianza	Coefficiente variación	Mínimo	Mediana	Máximo
Chow	3.169	3.158	9.970	0.996	0.272	2.215	21.889
Clarck	14.266	13.142	172.710	0.921	1.584	10.452	106.403
<i>Corps of Engineers</i>	3.294	2.652	7.034	0.805	0.180	2.338	12.990
Epsy	34.038	16.536	273.451	0.486	9.274	30.188	109.514
Flavell	25.771	10.796	116.558	0.419	8.572	22.290	47.256
Giandotti	4.153	4.257	18.119	1.025	0.789	2.826	40.040
Haktanir y Sezen	9.069	9.086	82.561	1.002	0.327	6.083	45.314
Jeong	2.349	1.969	3.878	0.838	0.119	1.647	10.220
Kim	8.851	8.639	74.637	0.976	0.764	5.752	59.642
Kirpich-Pen	0.771	1.464	2.142	1.899	0.021	0.382	11.567
Kirpich-Ten	2.614	3.377	11.402	1.292	0.125	1.563	24.595
Kraven (I)	1.149	2.293	5.257	1.995	0.018	0.472	18.401
MOCT	16.336	11.782	138.824	0.721	2.538	13.075	78.291
Pérez	0.053	0.111	0.012	2.080	0.001	0.018	0.940
Pickering	2.724	3.499	12.242	1.284	0.125	1.533	22.655
Picking	1.998	2.096	4.392	1.049	0.152	1.359	14.646
Pilgrim y McDermott	4.073	1.220	1.488	0.300	1.912	3.746	6.357
Rziha	3.484	8.869	78.667	2.546	0.035	1.193	74.456
Sheridan	35.028	39.257	1 541.098	1.121	0.890	21.806	196.166
Temez	5.173	4.166	17.353	0.805	0.282	3.672	20.404
USGS	37.424	34.269	1 174.382	0.916	1.253	24.297	156.297
Ventura	7.712	9.889	97.787	1.282	1.122	5.067	101.828
Yoon	3.663	1.095	1.198	0.299	1.670	3.436	8.461
Jung	2.349	1.969	3.878	0.838	0.119	1.647	10.220

Ecuación	Media	Desviación estándar	Varianza	Coefficiente variación	Mínimo	Mediana	Máximo
<i>California Culvert Practice</i>	2.724	3.499	12.240	1.284	0.125	1.533	22.653
Albishi	1.828	0.387	0.150	0.212	0.951	1.760	3.674

En términos de variabilidad, las ecuaciones de Carter (0.682), *Corps of Engineers* (0.805), Bransby-Williams (0.953), Chow *et al.* (0.996), Jung (0.838), Temez (0.805), Pilgrim y McDermott (0.300), y Yoon *et al.* (0.299) presentaron coeficientes de variación bajos, lo cual sugirió que sus estimaciones de tiempo de concentración (T_c) fueron relativamente consistentes y menos dispersas. Para ampliar la adaptabilidad en el análisis de T_c , se seleccionaron las ecuaciones con una variabilidad moderada, como Giandotti (1.025), así como ecuaciones de alta variabilidad, como Rziha (2.546) y Albishi *et al.* (2.080).

Respecto a los valores medios de T_c , se eligieron ecuaciones con medias bajas, como las de Carter (1.058) y Jeong (2.349), que fueron adecuadas para tiempos de concentración menores; mientras que las ecuaciones de Giandotti (4.153) y Rziha (3.484), Chow *et al.* (3.169) y *Corps of Engineers* (3.294) mostraron medias moderadas, apropiadas para valores de T_c moderados.

Para optimizar la precisión y adaptabilidad en función de la desviación estándar, se optó por las ecuaciones de Pilgrim y McDermott (1.220), y Carter (0.722), que exhibieron desviaciones estándar bajas y reflejaron una dispersión limitada de sus resultados.

En la Figura 2 y Figura 3 se presentaron el análisis visual de la media y varianza de cada una de las ecuaciones, lo cual permitió observar la dispersión y el rango de valores de T_c calculados, proporcionando una

comprensión más profunda sobre la consistencia y aplicabilidad de cada ecuación.




Figura 2. Media del tiempo de concentración.




Figura 3. Varianza del tiempo de concentración.

De acuerdo con las pruebas ya mencionadas, se seleccionaron 12 ecuaciones para el cálculo del tiempo de concentración, las cuales incluyeron las de Bransby-William, Carter, Chow *et al.*, *Corps of Engineers*, Giandotti, Jeong, Pilgrim y McDermott, Rziha, Temez, Yoon *et al.*, Jung, y Albishi *et al.*

Los modelos realizados consideran como variables de predicción H , A , L , S y la variable de respuesta T_c promedio de la base de datos. Para el entrenamiento se usó el 70 % y se calibró con el 30 % de los datos de análisis. En la Tabla 5 se tiene la configuración para cada modelo, asignando el número de cromosomas sugerido entre 30 y 100,

comprobando que en este rango se obtienen resultados confiables, así como el tamaño de cabeza y número de genes equivalente a la cantidad de variables de entrada como máximo. Se seleccionaron operadores matemáticos como funciones aritméticas (+, *, /), exponenciales (Exp), de potencia (X2, X4, Sqrt, 3Rt, 4Rt, 5Rt) e inversas (Inv); la función de enlace fue multiplicación.

Tabla 5. Configuración de modelos de expresión genética.

Modelo	Núm. de cromosomas	Tamaño de cabeza	Núm. de genes	Funciones	Función de enlace
I	95	4	4	+, *, /, Sqrt, Ln, 3Rt, 4Rt, 5Rt	Multiplicación
II	80	4	3	*, /, Sqrt, Exp, 3Rt	Multiplicación
III	60	4	3	*, /, Sqrt, Inv, X2, X4, 3Rt, 4Rt	Multiplicación
IV	100	4	4	*, /, Sqrt, Exp, Inv, X2, 4Rt, 5Rt	Multiplicación
V	30	4	2	*, /, Inv, X2, 3Rt	Multiplicación

La selección de los cinco mejores modelos de predicción se fundamentó en los que menores errores arrojaron de R^2 , MAE y MSE, como se muestra en la Tabla 6; pero en primera instancia todos aquellos modelos con R^2 en etapa de validación mayor a 0.80 son aceptables.

Tabla 6. Métricas de error de validación para evaluación de modelos.

Modelo	Ecuación	Errores de validación		
		R ²	MAE	MSE
I	$T_c = 0.869.L^{0.585}.H^{-0.01}.S^{-0.2}.(L + A)^{-0.2}$	0.883	0.535	0.794
II	$T_c = 0.2496.L^{0.033}.S^{-0.25}.e^{0.156.A^{0.5}.H^{-1}}$	0.979	0.228	0.140
III	$T_c = 0.2594.L^{0.6042}.H^{-0.0208}.S^{-0.25}$	0.978	0.244	0.109
IV	$T_c = 0.125.A^{0.05}.S^{0.25}.e^{(0.05S+L^{0.25}+H^{-1})}$	0.991	0.152	0.086
V	$T_c = 0.2049.L^{0.667}.S^{-0.222}$	0.942	0.320	0.357

En la generación de modelos de árbol de expresión genética se definieron las variables d_0, d_1, d_2, d_3 , equivalentes a H, A, L y S , respectivamente. Se muestran los árboles de expresión en la Figura 4, Figura 5, Figura 6, Figura 7 y Figura 8, correspondientes a los modelos I, II, III, IV, V.

Para el modelo I se tienen los árboles de la Ecuación (1) (Figura 4).




Figura 4. Árbol de expresión del modelo I.

Para el modelo II se tienen los árboles de Ecuación (2) (Figura 5).




Figura 5. Árbol de expresión del modelo II.

Para el modelo III, se tiene los árboles de la Ecuación (3) (Figura 6).




Figura 6. Árbol de expresión del modelo III.

Para el modelo IV, se tiene los árboles de la Ecuación (4) (Figura 7).

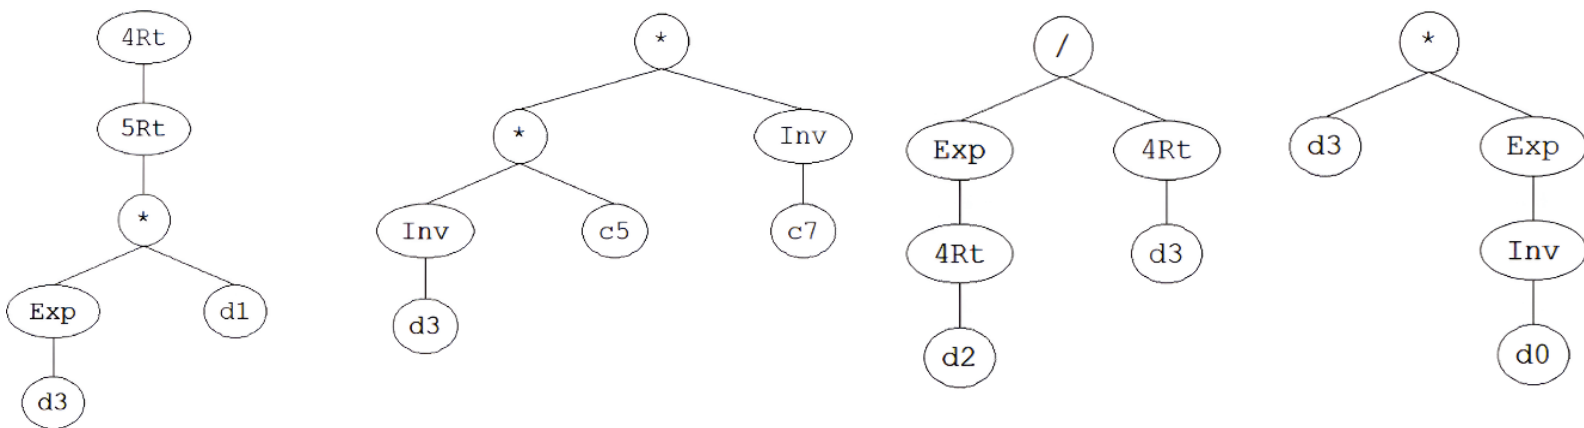


Figura 7. Árbol de expresión del modelo IV.

Para el modelo V, se tiene los árboles de la Ecuación (5) (Figura 8).




Figura 8. Árbol de expresión del modelo V.

Para comprobar la confiabilidad de las ecuaciones presentadas, se tomaron registros de datos de tiempo de concentración medidos en campo usando el método del flotador. En la Tabla 7, para la unidad hidrográfica del río Las Piedras, Colombia (Chaves & Ordoñez, 2017), la ecuación obtenida de la programación de expresión genética tuvo como error mínimo de 4.60 % en el modelo I y máximo de 95 % en el modelo IV; asimismo, resultó un error menor al comparado con la fórmula de Kirpich, que resultó 6.13 %.

Tabla 7. Ecuaciones y porcentajes de error.

UH	Tc (h)			Error (%)	
	Tc _{campo}	Tc _{ModeloI}	Tc _{Kirpich}	E _{ModeloI}	E _{Kirpich}
Río Las Piedras	6.135	5.853	5.759	4.60 %	6.13 %

Discusión

Lázaro, Abreu y Alvarez (2021), al evaluar diferentes ecuaciones empíricas para estimar el tiempo de concentración de una unidad hidrográfica en Cuba, observaron que las ecuaciones de SCS Lag, Bransby-Williams, Chow *et al.* estimaron tiempos de concentración considerablemente superiores al promedio, mientras que las ecuaciones de Kirpich, Carter y FAA generaron valores inferiores. En el presente estudio, el análisis de las 12 ecuaciones seleccionadas mostró una mayor convergencia de los valores de T_c en torno al promedio, lo cual sugirió una precisión y adaptabilidad más adecuada. En nuestro caso, las ecuaciones que obtuvieron valores aceptables fueron Bransby-Williams,

Carter, Chow *et al.*, *Corps of Engineers*, Giandotti, Jeong, Pilgrim y McDermott, Rziha, Temez, Yoon *et al.*, Jung, Albishi *et al.*

En los resultados, se establecieron cinco modelos variando los parámetros GEP, obteniendo ecuaciones con funciones desde las más simples (+, -, *, /) hasta las más complejas (exp). Se utilizaron tres métricas de error: el coeficiente de determinación (R^2), el error absoluto medio (MAE) y el error cuadrático medio (MSE). Los resultados iniciales indican que la ecuación del modelo IV es la más robusta, siendo la mejor opción para el cálculo de tiempo de concentración porque obtuvo un $R^2 = 0.991$, MAE = 0.152, MSE = 0.086. De forma similar, las ecuaciones del modelo II con $R^2 = 0.979$, MAE = 0.228, MSE = 0.140 y modelo III con $R^2 = 0.978$, MAE = 0.244, MSE = 0.109 también ofrecen un rendimiento óptimo con bajos niveles de error, lo que las convierte en opciones válidas por su simplicidad y exactitud. Por el contrario, la ecuación del modelo V con $R^2 = 0.942$, MAE = 0.320, MSE = 0.357 presenta un error mayor pese a tener un R^2 aceptable. Finalmente, la ecuación del modelo I con $R^2 = 0.883$, MAE = 0.535, MSE = 0.794 presenta los valores más altos de MAE y MSE, que reflejan menor precisión en esta primera etapa; sin embargo, su R^2 es aceptable.

En la segunda etapa se comprobó la precisión de los cinco modelos comparándolos con el tiempo de concentración real de una unidad hidrológica. La ecuación del modelo I se destacó por su bajo error relativo porcentual de 4.60 %, lo que lo convierte en la opción más confiable, pese a que las métricas de error iniciales la posicionaban como la opción menos precisa. Asimismo, las ecuaciones de los modelos III y V, con errores de 9.23 y 15.48 %, podrían ser válidas. En cuanto a las ecuaciones de los modelos II y IV, que usaron la función exponencial, son las que presentan errores muy elevados en la comprobación: 81.27 y

95.14 %, respectivamente. Así, se puede inferir de los resultados que la aplicación de las funciones exponenciales no son las recomendables para la estimación del tiempo de concentración. En síntesis, los resultados muestran que usar funciones muy complejas no siempre implica que son las más precisas, en tanto que la ecuación a obtener debe ser simple y que englobe todos los parámetros de la unidad hidrográfica, como se muestra en la ecuación del modelo I.

Sandoval-Erazo, Toulkeridis, Rodriguez-Espinosa y Mora (2018) propusieron una ecuación semiempírica basada principalmente en el coeficiente k , derivado de la teoría de la ecuación de Chézy, que permite determinar la velocidad media de escorrentía, así como el tiempo de concentración aplicable a unidades hidrográficas de cualquier área y pendiente. No obstante, su aplicabilidad exige la presencia de al menos una estructura hidráulica en el área de estudio, en contraste con nuestra investigación, que no requiere datos de caudal. Aun así, la ecuación demostró una alta precisión al compararse con los tiempos de concentración de diversos ríos a nivel mundial, obtenidos a partir de ecuaciones empíricas, con un coeficiente de determinación de $R^2 = 0.935$.

Zolghadr *et al.* (2022) presenta la simulación 2D como una alternativa novedosa, el cual toma en cuenta la profundidad total del agua, la elevación de la superficie del agua, el flujo por unidad de longitud en dos direcciones, la aceleración de gravedad, el coeficiente de Chézy y la viscosidad turbulenta. Este método permitió calcular el tiempo de concentración empleando además datos satelitales gratuitos y batimetría digital. Este modelo se demostró ser confiable en unidades hidrográficas con datos limitados; el modelo evidenció un error relativo máximo de 10 %. Por otro lado, nuestra ecuación propuesta puede ser aplicada a

unidades hidrográficas con una limitación de área; sin embargo, presenta una gran simplicidad y un error de 4.60 %.

Li *et al.* (2018) introdujeron el uso de la metodología de seguimiento de partículas para la estimación del tiempo de concentración en superficies permeables e impermeables, a través del *software FullSWOF-PTM* y teniendo en cuenta la pendiente de la superficie, el coeficiente de rugosidad de Manning, la longitud del cauce principal y la intensidad de la lluvia. Para validar el método, se compararon los resultados con otras cinco ecuaciones, evidenciando un $R^2 > 0.994$. La calidad de ajuste se destaca frente a los modelos implementados de nuestra investigación, donde el mejor de los modelos es el IV; se obtuvo $R^2 = 0.991$. La diferencia se atribuye a la robustez de la base de datos empleada. Se analizaron aproximadamente 400 casos, contrastando con el número reducido de datos y situaciones abordados en nuestra investigación.

En resumen, han existido diferentes enfoques del análisis del tiempo de concentración en unidades hidrográficas previos al presente estudio. Sin embargo, hay un margen de aporte significativo que involucra una amplia base de datos de diferentes condiciones hidrológicas, así como el uso de múltiples ecuaciones convencionales que amplía la visión de las más factibles. Por último, los modelos GEP reducen al mínimo el sesgo de acuerdo con las definiciones planteadas en el genotipo, fenotipo, cromosoma, genes, operadores genéticos, función de *fitness*, población y generación en la programación.

Conclusiones

Se estableció un nuevo enfoque de análisis para estimar el tiempo de concentración en unidades hidrográficas a partir de la inteligencia artificial. Como elementos claves para generar nuevos modelos en la programación de expresión genética, se concluyó que se requiere lo siguiente: en primer lugar, tener una base extensa de información; y en segundo lugar, combinar las variables independientes con respecto a la variable de salida a partir del número de cromosomas, número de genes, número de funciones matemáticas. Estos aspectos permitieron obtener una nueva ecuación para estimar el tiempo de concentración en forma precisa y eficaz para un intervalo de área de 10 a 260 km².

De las ecuaciones empíricas, se escogieron ecuaciones como las de Carter, Albishi *et al.* y Jeong, que presentaron valores de desviación estándar y coeficiente de variación más bajos, lo que indica una mayor consistencia en sus estimaciones; sin embargo, ecuaciones con mayores valores estadístico, como las de Rziha y Chow *et al.* reflejan una mayor flexibilidad a la variabilidad de los datos. La confiabilidad de las ecuaciones escogidas se demostró en la etapa de validación y comprobación de los modelos.

Se generaron cinco modelos en la programación de expresión genética, de las cuales el mejor modelo, según las métricas de error, fue la ecuación del modelo IV con $R^2 = 0.991$, MAE = 0.152 y MSE = 0.086. En contraste, la ecuación del modelo I resultó con las métricas de error más inadecuadas, con $R^2 = 0.883$, MAE = 0.535 y MSE = 0.794.

En la etapa de validación, el mejor modelo fue la ecuación del modelo I, la cual alcanzó un error de 4.60 % ($T_c = 5.853$ h) referente a la unidad hidrográfica del río Las Piedras de Colombia ($T_c = 6.135$ h); en

comparación con la ecuación de referencia internacional Kirpich se obtuvo un error de 6.13 % ($T_c = 5.759$ h). Se concluye que el modelo I superó las expectativas en cuanto error.

Para futuras investigaciones se podrían implementar otros modelos dentro de la inteligencia artificial. Se recomienda calibrar para otras ecuaciones para mayores y menores áreas, a fin de que sea la más universal posible.

Agradecimientos

A nosotros, Brayan Miguel Alca Vásquez y Valeria Mayte Ricaldi Marquez, que nos internamos sin miedo en territorios desconocidos, transformando incertidumbre en hallazgos y esfuerzo en logro.

Al Dr. Maiquel López Silva, por su guía firme y precisa en este viaje.

Referencias

- Ahn, S. J., & Lee, E. H. (1986). Derivation of the synthetic unit hydrograph at ungaged small watershed. *Journal of Korea Water Resources Association*, 19(2), 157-166. <https://www.koreascience.kr/article/JAKO198611920091597.page>
- Alamri, N., Afolabi, K., Ewea, H., & Elfeki, A. (2023). Evaluation of the time of concentration models for enhanced peak flood estimation in arid regions. *Sustainability*, 15(3), 1987. <https://doi.org/10.3390/su15031987>
- Albishi, M., Bahrawi, J., & Elfeki, A. (2017). Empirical equations for flood analysis in arid zones: The Ari-Zo model. *Arabian Journal of Geosciences*, 10(3). <https://doi.org/10.1007/s12517-017-2832-4>

- Aldana, D. A., & Leigue, M. A. (julio, 2022). *Estudio hidrológico para determinación de caudales máximos en la cuenca del río San Pedro de la ciudad de Tarija, Bolivia*. Simposio llevado a cabo en el 26th International Congress on Project Management and Engineering, Tarrasa, España.
<http://dspace.aepro.com/xmlui/handle/123456789/3213>
- ANA, Autoridad Nacional del Agua. (2003a). *Estudio hidrológico: evaluación y ordenamiento de los recursos hídricos de la cuenca del río San Juan*.
<https://sigrid.cenepred.gob.pe/sigridv3/documento/3029>
- ANA, Autoridad Nacional del Agua. (2003b). *Estudio integral de los recursos hídricos de la cuenca del río Chillón*.
<https://sigrid.cenepred.gob.pe/sigridv3/documento/3026>
- ANA, Autoridad Nacional del Agua. (2007). *Evaluación de los recursos hídricos de la cuenca del río Mala*.
<https://sigrid.cenepred.gob.pe/sigridv3/documento/3028>
- ANA, Autoridad Nacional del Agua. (2010a). *Estudio hidrológico y ubicación de la red de estaciones hidrométricas en la cuenca del río Rímac*. <https://sigrid.cenepred.gob.pe/sigridv3/documento/3030>
- ANA, Autoridad Nacional del Agua. (2010b). *Evaluación de los recursos hídricos en las cuencas de los ríos Huancané y Suches*.
<https://sigrid.cenepred.gob.pe/sigridv3/documento/3031>
- ANA, Autoridad Nacional del Agua. (2017). *Delimitación de la faja marginal de las quebradas afluentes al río Mariño, en el ámbito del distrito de Abancay*.
<https://sigrid.cenepred.gob.pe/sigridv3/documento/14561>

- Azizian, A. (2018). Uncertainty analysis of time of concentration equations based on first-order-analysis (FOA) Method. *American Journal of Engineering and Applied Sciences*, 11(1), 327-341. <https://doi.org/10.3844/ajeassp.2018.327.341>
- Balladares, J. L. (2022). *Estimación de caudales máximos para la subcuena Angostura mediante la data Grillada Pisco-Tumbes 2022* (tesis de grado). Universidad Nacional de Tumbes. <https://hdl.handle.net/20.500.12874/63998>
- Cachuán, J. C. O. (2017). *Modelo hidrológico para la generación de crecidas máximas empleando el hidrograma unitario instantáneo geomorfológico en la subcuena del río Shullcas* (tesis de grado). Universidad Nacional del Centro del Perú. <http://hdl.handle.net/20.500.12894/3870>
- California Department of Public Works. (1960). *California culvert practice*. Sacramento, USA: Calif. State Print.
- Canales, M. L. (2021). *Evaluación de riesgos existentes por erosión fluvial en el estribo izquierdo del Puente Colpa Alta – 2019* (tesis de grado). Universidad Nacional Hermilio Valdizán, Huánuco, Perú. <https://hdl.handle.net/20.500.13080/6228>
- Carter, R. W. (1961). *Magnitude and frequency of floods in suburban areas* (U.S. Geological Survey Professional Paper No. 424-B) (pp. 9-11). Reston, USA: U.S. Geological Survey.
- Castillo, C. L., Abreu, D. E., & Alvarez, M. (2021). Evaluación de distintas fórmulas empíricas para el cálculo del tiempo de concentración en la cuenca urbana del río Bélico y Cubanicay, ciudad de Santa Clara. *Enfoque UTE*, 12(3), 51–64. <https://doi.org/10.29019/enfoqueute.729>

Chaves, L. F. & Ordoñez, Y. A. (2017). *Estimación de los tiempos de concentración en las corrientes: Aguas Claras, Arrayanales, Carnicería, El Vado, Pichagua y río Las Piedras en el municipio de Popayán* (tesis de grado). Universidad del Cauca, Popayán, Colombia.

<https://repositorio.unicauca.edu.co/xmlui/handle/123456789/5106>

Chow, V. T., Maidment, D. R., & Mays, L. W. (1988). *Applied hydrology*. New York, USA: McGraw-Hill Series.

Del-Aguila, S., & Mejía, A. (2021). Caracterización morfométrica de dos cuencas altoandinas del Perú utilizando sistemas de información geográfica. *Tecnología y ciencias del agua*, 12(2), 538-562. <https://doi.org/10.24850/j-tyca-2021-02-12>

Ding, J., Jiang, T., Tan, P., Wang, Y., Fei, Z., Huang, C., Ma, J., & Fang, Y. (2023). An improved gene expression programming algorithm for function mining of map-reduce job execution in catenary monitoring systems. *PLoS ONE*, 18(11), e0290499. <https://doi.org/10.1371/journal.pone.0290499>

Eslamian, S., & Mehrabi, A. (2005). Determination of experimental relations in estimation of concentration time in mountainous watershed basins. *Iranian Journal of Natural Resources and Agricultural Sciences*, 12(5), 23-34.

FAO & INADE, Food and Agriculture Organization & Instituto Nacional de Desarrollo. (2003). *Diagnóstico de la subcuenca del río Contumazá*. <https://openknowledge.fao.org/handle/20.500.14283/ar911s>

- Fathi, A., & Zolghadr, M. (2023). *A novel method for estimating time of concentration in ungauged catchments*. <https://doi.org/10.21203/rs.3.rs-3700625/v1>
- Flavell, D. J. (1982). The rational method applied to small rural catchments in the south west of Western Australia. In: *Hydrology and Water Resources Symposium* (pp. 49-53). Perth, Australia: Institution of Engineers, Australia.
- Fuladipanah, M., Shahhosseini, A., Rathnayake, N., Azamathulla, H. M., Rathnayake, U., Meddage, D. P. P., & Tota-Maharaj, K. (2024). In-depth simulation of rainfall–runoff relationships using machine learning methods. *Water Practice and Technology*, 19(6), 2442-2459. <https://doi.org/10.2166/wpt.2024.147>
- García, J. L., & Onrubia, E. (2003). *Estudio de la Ribera de Bensafrim (El Algarve, Portugal)*. Rome, Italy: Food and Agriculture Organization. <https://www.fao.org/4/XII/0253-B2.htm>
- Giandotti, M. (1934). *Previsione delle piene e delle magre dei corsi d'acqua, Memorie e Studi Idrografici*. Roma, Italia: Ministero dei Lavori Pubblici.
- Gomez, W. J., & Paytan, J. C. (2017). *Estimación de caudales medios naturalizados en la cuenca del río Ichu mediante el método de regionalización estadística* (tesis de grado). <https://repositorio.unh.edu.pe/items/8c323578-663c-49c6-ae79-dbe4afcf2548>

- González-Álvarez, Á., Vilorio-Marimón, O. M., Coronado-Hernández, Ó. E., Vélez-Pereira, A. M., Tesfagiorgis, K., & Coronado-Hernández, J. R. (2019). Isohyetal maps of daily maximum rainfall for different return periods for the Colombian Caribbean Region. *Water*, 11(2), 358. <https://doi.org/10.3390/w11020358>
- Haktanir, T., & Sezen, N. (1990). Suitability of two-parameter gamma and three-parameter beta distributions as synthetic unit hydrographs in Anatolia. *Hydrological Science Journal*, 35(2), 167-184. <https://doi.org/10.1080/02626669009492416>
- INDECI & PNUD, Instituto Nacional de Defensa Civil & Programa de las Naciones Unidas para el Desarrollo. (2004). *Mapa de peligros de las ciudades de Tarapoto, Morales y la Banda de Shilcayo*. Lima, Perú: Instituto Nacional de Defensa Civil. <https://sigrid.cenepred.gob.pe/sigridv3/documento/4460>
- INDECI & PNUD, Instituto Nacional de Defensa Civil & Programa de las Naciones Unidas para el Desarrollo. (2005). *Mapa de peligros de la ciudad de Sicuani y localidad de Qquehuar*. Lima, Perú: Instituto Nacional de Defensa Civil. <https://sigrid.cenepred.gob.pe/sigridv3/documento/4333>
- Iruri, O. V., & Jiménez, L. F. (2021). *Delimitación de áreas críticas mediante el modelamiento de flujo de lodos con el software flo 2D en la quebrada Malanche, distrito de Punta Hermosa, Lima-Perú* (tesis de grado). <http://hdl.handle.net/10757/656076>
- JSCE, Japan Society of Civil Engineers. (1999). *The collection of hydraulic formulas*. Tokyo, Japan: Japan Society of Civil Engineers.

- Jung, S. (2005). *Development of empirical formulas for the parameter estimation of Clark's watershed flood routing model* (tesis doctoral). Korea University, Seoul, South Korea.
- Kaufmann, I., Kaufmann, A., Garcia, S., & Alves, T. (2017). Performance of methods for estimating the time of concentration in a watershed of a tropical region. *Hydrological Sciences Journal*, 62(14), 2406-2414. <https://doi.org/10.1080/02626667.2017.1384549>
- Kavoosi, M., & Khozehmehnehad, H. (2021). Review and compare performance of 4 modeling methods LS-SVM, NN, GEP and ANFIS-PSO in Simulation of Rainfall - Runoff (Study Area: Halil River-Jiroft Dam). *Irrigation and Water Engineering*, 11(3), 96-110. https://www.waterjournal.ir/article_128115.html
- Kim, Y. (2015). *Development of concentration time and storage coefficient formula in urban stream watersheds* (tesis de maestría). Sejong University, Seoul, South Korea.
- Kirpich, Z. P. (1940). Time of concentration of small agricultural watersheds. *Journal of Civil engineering*, 10(6), 362.
- Lázaro, C., Abreu, D., & Alvarez, M. (2021). Evaluación de distintas fórmulas empíricas para el cálculo del tiempo de concentración en la cuenca urbana del río Bélico y Cubanicay, ciudad de Santa Clara. *Enfoque UTE*, 12(3), 51-64. <https://doi.org/10.29019/enfoqueute.729>
- Li, X., Fang, X., Li, J., Manoj, K. C., Gong, Y., & Chen, G. (2018). Estimating time of concentration for overland flow on pervious surfaces by particle tracking method. *Water*, 10(4), 379. <https://doi.org/10.3390/w10040379>

- Linsley, R. K., Kohler, M. A., Paulhus, J. L., Serra, M. F., & Aparicio, F. D. (1977). *Hidrología para ingenieros*. Bogotá, Colombia: McGraw-Hill.
- López-Silva, M., Carmenates-Hernandez, D., Sao-Cancio, I., Valderrama-Romero, A., & Huamaní-Navarrete, P. (2022). Análisis estadístico multivariado de parámetros morfométricos en cuencas hidrográficas del Perú. En: Harun, S., Othman, I. K., & Jamal, M. H. (eds.). *Proceedings of the 5th International Conference on Water Resources (ICWR) – Volume 1* (Lecture Notes in Civil Engineering, Vol. 293, pp. 53–66). Singapur: Springer. https://doi.org/10.1007/978-981-19-5947-9_5
- Marín, D. A. (2018). *Análisis comparativo de los parámetros geomorfológicos de las subcuencas San Gregorio, Chongoyapito, Cupisnique y Yamalan* (tesis de grado). Universidad Nacional de Cajamarca, Cajamarca, Perú. <http://hdl.handle.net/20.500.14074/2129>
- Masoud, M. H. Z., Basahi, J. M., Alqarawy, A., Schneider, M., Rajmohan, N., Niyazi, B. A. M., & Karthikeyan, B. (2024). Flash flood prediction in Southwest Saudi Arabia using GIS technique and surface water models. *Applied Water Science*, 14(3), 61. <https://doi.org/10.1007/s13201-024-02117-2>
- Mata-Lima, H., Vargas, H., Carvalho, J., Gonçalves, M., Caetano, H., Marques, A., & Raminhos, C. (2007). Comportamento hidrológico de bacias hidrográficas: integração de métodos e aplicação a um estudo de caso. *Revista Escola de Minas*, 60(3), 40-56. <https://doi.org/10.1590/S0370-44672007000300014>

- Michailidi, E. M., Antoniadis, S., Koukouvinos, A., Bacchi, B., & Efstratiadis, A. (2018). Timing the time of concentration: Shedding light on a paradox. *Hydrological Sciences Journal*, 63(5), 721-740. <https://doi.org/10.1080/02626667.2018.1450985>
- Minagri, Ministerio de Agricultura. (2007). Estudio hidrológico en la cuenca del río Casma-2007. Lima, Perú: Ministerio de Agricultura. <https://sigrid.cenepred.gob.pe/sigridv3/documento/3032>
- Morgali, J. R., & Linsley, R. K. (1965). Computer analysis of overland flow. *Journal of the Hydraulics Division*, 91(3), 81-100. <https://doi.org/10.1061/JYCEAJ.0001269>
- MOTH, Ministry of Transportation and Highways. (1998). *Hydraulics Manual*. Victoria, Canada: Moth Engineering Branch.
- Nieto, L., & De-la-Torre, E. E. (2023). *Análisis de máximas avenidas de la cuenca transfronteriza del río Zarumilla (Perú-Ecuador) usando el software Hec-Hydrologic Modeling System* (tesis de grado). <http://hdl.handle.net/10757/669031>
- Pilgrim, D. H., & McDermott, G. E. (1982). Design floods for small rural catchments in eastern New South Wales. *Civil Engineering Transactions*, 24(4), 226-234.
- Pouyanfar, S., Nozari, N., & Khodamorad, M. (2023). Comparison of the performances of the gene expression programming model and the RegCM model in predicting monthly runoff. *Journal of Water and Climate Change*, 14(10), 3810-3829. <https://doi.org/10.2166/wcc.2023.439>
- Rziha, F. (1876). *Eisenbahn-Unter-Und Oberbau* (v. 1). Viena, Austria: Hof-und Staatsdr.

- Sandoval-Erazo, W., Toulkeridis, T., Rodriguez-Espinosa, F., & Mora, M. J. (2018). Velocity and time of concentration of a basin - A renewed approach applied in the Rio Grande Basin, Ecuador. *IOP Conference Series: Earth and Environmental Science*, 191(1), 012117. <https://doi.org/10.1088/1755-1315/191/1/012117>
- Senamhi, Servicio Nacional de Meteorología e Hidrología del Perú. (2013). *Estudio de extremos hidrológicos en la cuenca del río Chicama*. Lima, Perú: Servicio Nacional de Meteorología e Hidrología del Perú. <https://sigrid.cenepred.gob.pe/sigridv3/documento/807>
- Sheridan, J. M. (1994). Hydrograph time parameters for flatland watersheds. *Transactions of American Society of Agricultural Engineers*, 37(1), 103-113. <https://doi.org/10.13031/2013.28059>
- Silveira, A. L. L. (2005). Performance of time of concentration formulas for urban and rural basins. *Brazilian Journal of Water Resources*, 10, 5-23.
- Straub, T. D., Melching, C., & Kocher, K. (2000). *Equations for estimating Clark unit-hydrograph parameters for small rural watersheds in Illinois* (Water-Resources Investigations Report 2000-4184). Reston, USA: U.S. Geological Survey. <https://doi.org/10.3133/wri004184>
- Temez, J. R. (1978). *Cálculo hidrometeorológico de caudales máximos en pequeñas cuencas naturales*. Madrid, España: Ministerio de Obras Públicas y Urbanismo (MOPU), Dirección General de Carreteras. https://www.transportes.gob.es/recursos_mfom/0610400.pdf

- Valderrama, F. J., Chávez, D. A., Muñoz, S. P., Tuesta-Monteza, V. A., & Mejía-Cabrera, H. I. (2021). Importance of artificial neural networks in civil engineering: A systematic review of the literature. *ITECKNE*, 18(1), 71-83. <https://doi.org/10.15332/iteckne.v18i1.2542>
- Vargas, A. (2022). *Identificación de áreas en riesgo de inundación por el río Huanta, a un kilómetro aguas abajo del puente Huanta sector Accoscca-2020* (tesis de grado). <http://repositorio.unsch.edu.pe/handle/UNSCH/4988>
- Vargas-Crispin, W. S., Montes-Raymundo, E., Castrejón-Valdez, M., & Hinojosa-Benavides, R. A. (2021). Machine learning como herramienta para determinar la variación de los recursos hídricos. *Scientific Research Journal CIDI*, 1(1), 56-69. <https://doi.org/10.53942/srjcidiv1i1.46>
- Vásquez-Ramírez, L., & Vásquez-Paredes, L. F. (2023). Predicción de caudales mensuales en ríos de cuencas altoandinas con enfoque de redes neuronales artificiales. Caso: río Crisnejas, Perú. *Tecnología y ciencias del agua*, 14(1), 124-199. <https://doi.org/10.24850/j-tyca-14-01-04>
- Vélez, U. J., & Botero, A. (2011). Estimación del tiempo de concentración y tiempo de rezago en la cuenca experimental urbana de la quebrada San Luis, Manizales. *Dyna*, 78(165), 58-71. <https://revistas.unal.edu.co/index.php/dyna/article/view/25640>
- Waqas, M., Saifullah, M., Hashim, S., Shoaib, M., Naseem, A., & Khan, M. (2021). Modelling of rainfall-runoff process by GEP, RBF-SVM and M5 model tree in Jhelum River Basin, Pakistan. In: *Proceedings of the International Conference on Hydrology and Water Resources 2021* (pp. 105-112). Lahore, Pakistan.

- Yoo, C., Lee, J., & Cho, E. (2019). Theoretical evaluation of concentration time and storage coefficient with their application to major dam basins in Korea. *Water Supply*, 19(2), 644-652. <https://doi.org/10.2166/ws.2018.156>
- Yoon, T. H., Kim, S. T., & Park, J. W. (2005). On redefining of parameters of Clark model. *Journal of the Korean Society of Civil Engineers*, 25(3B), 181-187. https://kscejournal.or.kr/jksce/ArticleDetail/RD_R/186393
- Zolghadr, M., Rafiee, M. R., Esmailmanesh, F., Fathi, A., Tripathi, R. P., Rathnayake, U., Gunakala, S. R., & Azamathulla, H. M. (2022). Computation of time of concentration based on two-dimensional hydraulic simulation. *Water*, 14(19), 3155. <https://doi.org/10.3390/w14193155>