

# تخمین ضریب دبی سرریزهای کنگره‌ای توسط مدل‌های نوین هوش مصنوعی

شهاب الدین شفیعی<sup>۱</sup>، محسن نجارچی<sup>۲\*</sup>، سعید شعبانلو<sup>۳</sup>

۱- دانشجوی دکتری عمران، گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک.

۲- دانشیار گروه مهندسی عمران، واحد اراک، دانشگاه آزاد اسلامی، اراک.

۳- دانشیار گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه.

m-najarchi@iau-arak.ac.ir

تاریخ دریافت ۹۸/۰۶/۰۲ تاریخ پذیرش ۹۹/۰۶/۰۲

## چکیده

در این مقاله، برای اولین بار با استفاده از روش هوش مصنوعی نوین تحت عنوان ماشین آموزش نیرومند خارج از محدوده<sup>۱</sup> (ORELM) ضریب دبی سرریزهای کنگره‌ای تخمین زده شدند. در ابتدا، تعداد نرون<sup>۲</sup>های لایه مخفی بهینه مساوی با ۱۵ انتخاب شد. سپس نتایج توابع فعال<sup>۳</sup>سازی مختلف مورد ارزیابی قرار گرفت که دقیقترین تابع فعال<sup>۴</sup>سازی برای مدل هوش مصنوعی شناسایی شد. در ادامه، با استفاده از پارامترهای ورودی موثر روی ضریب دبی سرریزهای کنگره‌ای<sup>۵</sup>، هفت مدل ORELM مختلف توسعه داده شدند با انجام تحلیل حساسیت، مدل برتر و موثرترین پارامترهای ورودی شناسایی شدند. برای نمونه، مقادیر شاخص<sup>۶</sup>های آماری  $R^2$ ، RMSRE و NSC برای مدل برتر به ترتیب مساوی با ۰/۹۴۳، ۵/۲۲۴ و ۰/۹۴۰ محاسبه شدند. همچنین، پارامترهای ورودی نسبت هد روی سرریز به ارتفاع سرریز ( $H/P$ ) و نسبت عرض یک کنگره به ارتفاع سرریز ( $w/P$ ) به عنوان مهمترین پارامترهای ورودی شناسایی شدند. سپس برای مدل<sup>۷</sup>های هوش مصنوعی یک تحلیل عدم قطعیت اجرا و نشان داده شد که مدل ORELM دارای عملکردی بیشتر از واقعی بود.

**واژگان کلیدی:** سرریز کنگره‌ای، ضریب دبی، ماشین آموزش، تحلیل عدم قطعیت

## مقدمه

یکی از کاربردی‌ترین سازه‌های هیدرولیکی سرریزها هستند که کاربرد گسترده‌ای برای اندازه‌گیری دبی و تنظیم جریان درون کانال‌های باز، سیستم‌های آبیاری و شبکه‌های زهکشی دارند. به طور کلی، مهمترین پارامتر یک سرریز ضریب دبی طراحی بهینه سرریزها می‌باشد که از اهمیت زیادی برخوردار است. سرریزها به شکل‌های مختلفی وجود دارند اما به تازگی سرریزهای کنگره‌ای توجه بسیاری از مهندسين هیدرولیک و محیط زیست را به خود جلب کرده‌اند. سرریزهای کنگره‌ای در مقایسه با سرریزهای مستطیلی توانایی عبور آب بیشتری از روی خود دارند بنابراین از لحاظ هیدرولیکی یک نوع سرریز مطلوب و بهینه تلقی می‌شوند. به دلیل محبوبیت و کاربرد وسیع سرریزهای کنگره‌ای، مطالعات آزمایشگاهی، تحلیلی و هوش مصنوعی بسیاری روی رفتار هیدرولیکی آنها انجام شده‌اند.

تکنیک‌های مختلف هوش مصنوعی به شکل وسیعی برای تخمین و الگوسناسی پدیده‌های مختلف استفاده می‌شوند. این روش‌ها به دلیل دقت بالا، کاهش هزینه‌های آزمایشگاهی و صرفه‌جویی در زمان بسیار محبوب هستند. به تازگی این مدل‌ها برای شبیه‌سازی ضریب دبی انواع سرریزها استفاده شده‌اند. برای نمونه، زاجی و بنکداری در سال ۲۰۱۴ مقادیر ضریب دبی سرریزهای جانبی کنگره‌ای را توسط تکنیک‌های مختلف هوش مصنوعی از قبیل شبکه عصبی مصنوعی، بهینه‌سازی ازدحام ذرات<sup>۱</sup> و مدل‌های رگرسیونی تخمین زدند. آنها روابطی را برای محاسبه ضریب دبی این نوع از سرریزها ارائه کردند [1]. همچنین ابتهاج و همکاران در سال ۲۰۱۵ [2]، خوشبین و همکاران در سال ۲۰۱۶ [3]، روشنر و همکاران در سال ۲۰۱۶ [4]، عظیمی و همکاران در سال ۲۰۱۷ [5] (a) و عظیمی و همکاران در سال ۲۰۱۷ (b) [6] از تکنیک‌های مختلف هوش مصنوعی و محاسبات نرم برای شبیه‌سازی ضریب دبی سرریزها استفاده نمودند. سپس، حقیابی و همکاران در سال ۲۰۱۷ ضریب دبی سرریزهای

کنگره‌ای را توسط شبکه عصبی مصنوعی، مدل رگرسیونی و شبکه انفیس تخمین زدند. آنها نشان دادند که مدل انفیس دقت بیشتری داشت [7]. روشنر و همکاران در سال ۲۰۱۷ ضریب دبی سرریزهای کنگره‌ای را توسط مدل‌های انفیس و برنامه‌نویسی بیان ژن<sup>۲</sup> شبیه‌سازی نمودند. آنها بیان کردند که مدل برنامه‌نویسی بیان ژن دارای عملکرد بهتری برای تخمین ضریب دبی بود [8]. در ادامه، روشنر و همکاران در سال ۲۰۱۸ ماشین بردار پشتیبان<sup>۳</sup> را برای مدل‌سازی ضریب دبی سرریزهای کنگره‌ای و قوسی استفاده نمودند [9]. سالازار و کروک استون در سال ۲۰۱۹ رفتار هیدرولیکی و ضریب دبی سرریزهای کنگره‌ای قوسی را توسط ماشین‌های یادگیری؛ از قبیل جنگل‌های تصادفی و شبکه عصبی تخمین زدند [10]. سپس بیهان و همکاران در سال ۲۰۱۹ توسط رگرسیون بردار پشتیبان و ماشین آموزش نیرومند<sup>۶</sup> ضریب دبی سرریزهای کنگره‌ای را شبیه‌سازی کردند. نشان داده شد که ماشین آموزش مقادیر ضریب دبی را با دقت بیشتری تخمین زد [11]. با مرور مطالعات گذشتگان مشخص شد که مدل‌های مختلف هوش مصنوعی برای تخمین ضریب دبی سرریزهای کنگره‌ای استفاده شده‌اند. در مقابل، مدل ماشین آموزش نیرومند خارج از محدوده (ORELM) یک مدل هوش مصنوعی کاربردی برای حل مسائل مختلف است [12, 13, 14, 17].

علاوه بر این، تاکنون روش نوین ماشین آموزش نیرومند خارج از محدوده برای مدل‌سازی ضریب دبی سرریزهای کنگره‌ای استفاده نشده که در این مقاله برای اولین بار این روش جدید برای تخمین ضریب دبی استفاده شد. این روش دارای دقت بالا و سرعت زیادی در طی فرایند شبیه‌سازی است و توانایی ارائه رابطه برای تخمین تابع هدف را دارد. همچنین، در این مطالعه از روش اعتبارسنجی چند لایه برای اعتبار سنجی مدل‌های هوش مصنوعی و تحلیل عدم قطعیت

2. Gene Expression Programming (GEP)
3. Support Vector Machine (SVM)
4. Machine learning
5. Support Vector Regression
6. Extreme Learning Machine (ELM)

1. Particle swarm optimization

برای شناسایی چگونگی عملکرد مدل‌ها استفاده شد. سپس، مدل برتر و موثرترین پارامترهای ورودی شناسایی شدند.

## ۲. مواد و روش‌ها

### ۲-۱. ماشین آموزش نیرومند (ELM)

یکی از روش‌هایی که به صورت گسترده برای حل مسائل غیرخطی در علوم مهندسی استفاده می‌شود، الگوریتم پس-خور<sup>۲</sup> (BP) است. این الگوریتم یکی از رایج‌ترین الگوریتم‌ها برای آموزش شبکه‌های عصبی چند لایه است. عمومیت یافتن الگوریتم BP، بخاطر سادگی و کاربردهای موفقیت آمیز آن در حل مسائل غیرخطی پیچیده است. با وجود موفقیت‌های این الگوریتم در یادگیری شبکه عصبی مصنوعی چندلایه، این الگوریتم ممکن است به نقاط مینیمم محلی در فضای پارامتر، همگرا شود. بنابراین زمانی که الگوریتم BP همگرا می‌شود، نمی‌توان مطمئن شد که به یک جواب بهینه رسیده باشیم. از طرفی، سرعت همگرایی الگوریتم BP، خیلی کند است. از این گذشته، همگرایی الگوریتم BP، به انتخاب مقادیر اولیه وزن‌های شبکه، بردارهای بایاس و پارامترهای موجود در الگوریتم، مانند نرخ یادگیری، وابسته است و گاهی ممکن است برای دستیابی به عملکردی بهتر، به تعداد زیاد تکرار مراحل یادگیری، نیاز باشد. شبکه‌های عصبی مبتنی بر ماشین آموزش نیرومند، بر خلاف الگوریتم BP، نیازی به تنظیم پارامترهای لایه پنهان (وزن و بایاس) ندارد و این پارامترها به طور تصادفی انتخاب می‌شوند. هدف در این روش، رسیدن به کوچکترین خطای آموزش و کوچکترین نرم<sup>۳</sup> وزن خروجی است. این الگوریتم عملکرد کلی خوبی را ارائه می‌کند و بسیار سریع اجرا می‌شود و مشکل کمینه محلی را ندارد و حداقل مداخله انسانی را نسبت به الگوریتم BP دارد (گدفلو و همکاران ۲۰۱۶) [15]. ماشین آموزش نیرومند که توسط هانگ و همکاران در سال ۲۰۰۶ ارائه شده است [16]، از معماری شبکه عصبی مصنوعی پیش‌خور تک لایه،

(SLFFNN) استفاده می‌کند. وزن‌های لایه ورودی به لایه پنهان به صورت تصادفی انتخاب می‌شوند و وزن‌های خروجی از طریق عملیات شبه معکوس بدست می‌آیند. روش ELM از قابلیت تعمیم‌پذیری بالاتر و زمان آموزش کمتری نسبت به شبکه عصبی برخوردار است. تمامی پارامترهای شبکه به صورت خودکار تعیین می‌شوند که این امر باعث جلوگیری از مداخله انسانی شده و این روش را در کاربردهای برخت، کارآمد می‌کند. روش ELM مزایای زیادی نسبت به همتایان خود دارد از جمله این برتری‌ها می‌توان به استفاده آسان، سرعت بالای آموزش، عدم رخداد بیش‌برازش، قدرت تعمیم‌پذیری بالاتر و قابلیت استفاده از توابع فعال‌سازی، اشاره کرد.

### ماشین آموزش نیرومند خارج از محدوده

روش ماشین آموزش نیرومند خارج از محدوده (ORELM) (ژانگ و لئو در سال ۲۰۱۵) به منظور غلبه بر مشکلات روش ماشین آموزش نیرومند کلاسیک در پیش‌بینی مجموعه داده‌هایی که دارای خارج از محدوده هستند، ارائه شده است [17]. در این روش، از مفهوم پارامترهای اسپارسیته‌های ناپایدار استفاده شده است به طوری که برای افزایش توانایی پیش‌بینی مدل از تابع فقدان هنجار  $\ell_1$  در ترکیب با روش ماشین آموزش نیرومند استفاده می‌شود. در این مطالعه با تعریف پارامتر C به عنوان یک پارامتر تنظیم‌کننده، نسبت بین خطای آموزش و هنجار وزن خروجی، محاسبه می‌شود. در واقع با استفاده از این پارامتر برای افزایش عملکرد تعمیم‌پذیری مدل ماشین آموزش نیرومند خارج از محدوده نسبت به ماشین آموزش نیرومند، حد وزن‌های خروجی و خطای آموزش به طور هم‌زمان به صورت زیر حداقل می‌شود [17]:

$$\min_{w_0} C \|T - Hw_0\|_2^2 + \|w_0\|_2^2 \quad (1)$$

در روش ORELM، برای کاهش خطای آموزش (e)، وزن خروجی در  $(w_0)$  مدل ماشین آموزش نیرومند را با هنجار  $\ell_2$  بررسی می‌شود [17]:

1. Extreme Learning Machine
2. Back Propagation
3. norm
4. Single layered feed-forward neural network

$$\min_{w_0} C \|e\|_0 + \|w_0\|_2^2 \quad \text{subject to } T - Hw_0 = e \quad (2)$$

رابطه فوق، یک مسئله غیرهمگرا است. در روش ORELM برای حل آن از شکل تخفیف استفاده می‌شود. بدین صورت که هنجار  $\ell_1$  با هنجار  $\ell_0$  جایگزین می‌شود. در واقع با این کار، نه تنها مشخصات پراکندگی تغییر نمی‌کند بلکه محدوده کلی همگرایی نیز به کمترین می‌رسد.

### مدل آزمایشگاهی

در این مطالعه، برای درستی آزمایشی نتایج مدل‌های هوش مصنوعی از مقادیر آزمایشگاهی اندازه‌گیری شده توسط کومار و همکاران (۲۰۱۱) [18] و سیمونز (۲۰۱۴) [19] استفاده می‌شود. مدل آزمایشگاهی کومار و همکاران (۲۰۱۱) [18] شامل یک کانال مستطیلی به طول ۱۲ متر، عرض ۰/۲۸ متر و عمق ۰/۴۱ متر است. سرریز از صفحات فولادی ساخته شده که در فاصله ۱۱ متری از ورودی کانال مستطیلی نصب شده است. همچنین مدل آزمایشگاهی سیمونز (۲۰۱۴) [19] در یک کانال مستطیلی به طول ۱۴/۶ متر، عرض ۱/۲ متر و ارتفاع ۰/۹ متر انجام شده است. شیب کانال در کلیه اندازه‌گیری‌ها برابر صفر و کانال افقی بود. در این مطالعات دبی جریان ( $Q$ )، هد کل روی تاج سرریز ( $H_T$ )، ارتفاع تاج سرریز ( $P$ )، زاویه دیواره-های کنگره‌ها ( $\alpha$ )، طول تاج سرریز ( $L_c$ )، کل عرض سرریز کنگره‌ای ( $W$ )، طول راس کنگره ( $A$ ) و عرض یک کنگره ( $w$ ) استفاده می‌شود. در شکل (۱) طرح کلی مدل آزمایشگاهی کومار و همکاران [18] و سیمونز [19] به تصویر کشیده شده است. علاوه بر این دامنه مقادیر آزمایشگاهی مورد استفاده همچنین ضریب دبی سرریزهای کنگره‌ای تابعی از پارامترهای زیر است [8, 9]:

$$C_d = f(Fr, H_T/P, \alpha, L_c/W, A/w, w/P) \quad (3)$$

بنابراین در این مطالعه برای محاسبه ضریب دبی توسط مدل هوش مصنوعی از پارامترهای بدون بعد رابطه ۳ استفاده می‌شود. چگونگی ترکیب پارامترهای ورودی برای توسعه مدل-های هوش مصنوعی در شکل (۲) نشان داده شده است.

برای شبیه‌سازی ضریب دبی توسط ORELM برای مقادیر آزمایشگاهی گزارش شده توسط کومار و همکاران [18] و سیمونز [19] در جدول (۱) مرتب شده است. تعداد داده‌های آزمایشگاهی برابر با ۴۷۰ است که برای افزایش انعطاف پذیری مدل‌های هوش مصنوعی از این دو مدل آزمایشگاهی متمایز استفاده شد.

شکل ۱. طرح کلی مدل آزمایشگاهی (a) کومار و همکاران [18] (b) سیمونز [19]




Fig.1. Schematic of numerical models (a) Kumar et al. (2011) (b) Seamons (2014)

### ضریب دبی

به طور کلی ضریب دبی سرریزها از رابطه زیر محاسبه می‌شود [8, 9]:

$$C_d = \frac{3}{2} \frac{Q}{\sqrt{2g} L_c H_T^{3/2}} \quad (3)$$

شکل ۲. چگونگی ترکیب پارامترهای ورودی برای مدل‌های هوش مصنوعی




Fig. 2. Combinations of input parameters for numerical models

جدول ۱. محدوده مقادیر آزمایشگاهی کومار و همکاران [14] و سیمونز [15]

| Parameter           | Fr    |       | HT/P  |       | $\alpha(\text{degree})$ |     | Lc/W  |       | A/w |       | w/P   |       |
|---------------------|-------|-------|-------|-------|-------------------------|-----|-------|-------|-----|-------|-------|-------|
| Range               | min   | max   | min   | max   | min                     | max | min   | max   | min | max   | min   | max   |
| Kumar et al. (2011) | 0.001 | 0.111 | 0.186 | 6.968 | 15                      | 90  | 0.5   | 1.932 | 0   | 0     | 2.593 | 3.043 |
| Seamons (2014)      | 0.017 | 0.445 | 0.053 | 0.835 | 12                      | 12  | 1.869 | 2.210 | 0   | 0.120 | 1.892 | 2.017 |

Table.1. Range of Kumar et al. (2011) and Seamons (2014) experimental data

### معیارهای بررسی دقت مدل‌های هوش مصنوعی

در این مقاله، برای سنجش دقت مدل‌های هوش مصنوعی از شاخص‌های آماری ضریب تبیین ( $R^2$ )، خطای جذر میانگین مربعات ( $RMSE$ )، خطای نسبی مطلق میانگین ( $MARE$ )، خطای نسبی مربع میانگین ریشه ( $RMSRE$ ) ضریب بهره‌وری نش ساتکلیف ( $NSC$ ) به صورت زیر استفاده می‌شود [6]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{(Predicted)_i} - R_{(Observed)_i})^2} \quad (5)$$

$$MARE = 100 \times \frac{1}{n} \sum_{i=1}^n \frac{|R_{(Predicted)_i} - R_{(Observed)_i}|}{R_{(Observed)_i}} \quad (6)$$

$$RMSRE = 100 \times \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{R_{(Predicted)_i} - R_{(Observed)_i}}{R_{(Observed)_i}} \right)^2} \quad (7)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (R_{(Observed)_i} - R_{(Predicted)_i})^2}{\sum_{i=1}^n (R_{(Observed)_i} - \bar{R}_{(Observed)_i})^2} \quad (8)$$

$$R^2 = \frac{(n \sum_{i=1}^n R_{(Predicted)_i} R_{(Observed)_i} - \sum_{i=1}^n R_{(Predicted)_i} \sum_{i=1}^n R_{(Observed)_i})^2}{(n \sum_{i=1}^n (R_{(Predicted)_i})^2 - \sum_{i=1}^n R_{(Predicted)_i}) (n \sum_{i=1}^n (R_{(Observed)_i})^2 - \sum_{i=1}^n R_{(Observed)_i})} \quad (9)$$

در معادلات مذکور مقادیر  $(R)_{(Predicted)_i}$ ،  $(R)_{(Observed)_i}$  و  $(\bar{R})_{(Observed)_i}$  به ترتیب برابر مقادیر آزمایشگاهی، نتایج پیش‌بینی شده توسط مدل‌های هوش مصنوعی، میانگین مقادیر آزمایشگاهی و تعداد اندازه‌گیری‌های آزمایشگاهی هستند.

شاخص‌های آماری معرفی شده، مقایسه همزمانی از میانگین و واریانس از مدل‌ها را ارائه نمی‌کنند. بنابراین شاخص اطلاعات آکیای ( $AIC$ ) برای مقایسه ضریب دبی

در این مطالعه، برای بررسی توانایی مدل‌های هوش مصنوعی از شبیه‌سازی‌های مونت کارلو استفاده می‌شود. ایده اصلی شبیه‌سازی مونت کارلو این است که با استفاده از تصمیم‌گیری تصادفی مسائلی که ممکن است در اصل قطعی باشند را حل می‌کند. روش‌های مونت-کارلو معمولاً برای شبیه‌سازی سیستم‌های فیزیکی و ریاضیاتی که اغلب حل آنها با استفاده از روش‌های معمول مقدور نیست استفاده می‌شود. شبیه‌سازی مونت کارلو به طور کلی به وسیله توزیع احتمالی برای حل مسائل مختلف از قبیل بهینه‌سازی و انتگرال‌گیری هوش مصنوعی استفاده می‌شود. در شبیه‌سازی مونت کارلو، کل سیستم به تعداد دفعات زیادی اجرا می‌شود (برای نمونه ۱۰۰۰ بار). با هر بار شبیه‌سازی، تحقق سیستم گفته می‌شود. برای هر تحقق، تمام پارامترهای غیرقطعی نمونه‌برداری می‌شود (یعنی یک مقدار تصادفی از توزیع اختصاصی مربوط به هر پارامتر، انتخاب می‌شود). سپس این سیستم در طول زمان شبیه‌سازی تکرار می‌شود (با معین بودن مجموعه پارامترهای ورودی) به گونه‌ای که کارایی سیستم بتواند محاسبه شود. این امر منتج به ایجاد تعداد زیادی نتیجه مستقل و جداگانه می‌شود، که هر کدام نمایشگر یک "آینده" احتمالی برای سیستم هستند (یعنی یک مسیر احتمالی که سیستم احتمالاً با گذشت زمان دنبال خواهد کرد). نتایج تحقق‌های مستقل سیستم به شکل توزیع‌های احتمالی خروجی‌های ممکن درخواهند آمد. در نتیجه، خروجی‌ها به صورت مقادیر تک نیستند، بلکه توزیع احتمال هستند.

### 1. Monte Carlo simulations

پیش‌بینی شده با ضریب دبی آزمایشگاهی به‌صورت زیر معرفی می‌شود:

$$AIC = n \times \ln(RMSE) + 2k \quad (10)$$

در اینجا  $k$  برابر تعداد پارامترهای تخمین زده شده مورد استفاده در مدل هوش مصنوعی است. پارامتر  $AIC$  به‌عنوان یک معیار برای هماهنگی مناسب یک مدل آماری در نظر گرفته می‌شود. همچنین این شاخص به‌عنوان ابزاری برای انتخاب مدل استفاده می‌شود و به‌طور همزمان پیچیدگی و دقت مدل هوش مصنوعی را توصیف می‌کند.

## بحث و نتایج

در ادامه، چگونگی انتخاب بهینه‌ترین تعداد نرون‌های لایه مخفی، نتایج اعتبارسنجی چند لایه ۱ و بهترین تابع فعال‌سازی ارائه می‌شود. سپس نتایج مدل‌های ORELM 1 تا ORELM 7 مورد تجزیه و تحلیل قرار می‌گیرد. در ادامه، یک تحلیل عدم قطعیت برای این مدل‌های اجرا می‌شود. علاوه بر این، برای مدل برتر یک رابطه ارائه و برای پارامترهای ورودی یک تحلیل حساسیت مشتق نسبی انجام می‌شود.

## تعداد نرون‌های لایه مخفی

در این قسمت، حساسیت مدل هوش مصنوعی نسبت به تعداد نرون‌های لایه مخفی ارزیابی می‌شود. به بیان دیگر، ابتدا تعداد نرون‌ها مساوی با پنج فرض شد و با افزایش آنها دقت مدل هوش مصنوعی بررسی شد و این فرایند تا زمانی که نرون‌ها مساوی با ۴۵ شد ادامه یافت. لازم به ذکر است که بهینه‌ترین تعداد نرون‌های لایه مخفی برای شرایطی که دقت مدل هوش مصنوعی در حد قابل قبولی است و زمان محاسبات نیز مناسب است انتخاب می‌شود. پارامتر دیگری که برای انتخاب تعداد نرون‌های لایه مخفی بهینه در نظر گرفته می‌شود شاخص  $AIC$  است که برای حالتی که این شاخص به کمترین مقدار خود می‌رسد تعداد نرون‌های لایه مخفی متناظر با آن انتخاب می‌شود. با این

تفسیر، تعداد نرون‌های لایه مخفی بهینه مساوی با ۱۵ انتخاب شد. در این شرایط مقادیر  $RMSE$ ،  $AIC$  و  $NSC$  به‌ترتیب مساوی با -۱۴۱۲/۵۱، ۰/۰۳۰ و ۰/۹۴۰ بودند. نتایج تغییرات شاخص‌های آماری در برابر تعداد نرون‌های لایه مخفی در شکل (۳) قابل مشاهده است. همچنین، شاخص‌های  $R^2$ ،  $RMSRE$  و  $MARE$  برای مدلی که تعداد نرون‌های لایه مخفی مساوی با ۲۵ بود به ترتیب برابر با ۰/۹۴۳، ۵/۲۲۴ و ۳/۹۶۸ تخمین زده شدند.

## روش درستی آزمایی چند لایه

در این مقاله برای اعتبارسنجی نتایج مدل‌های هوش مصنوعی از روش درستی آزمایی چند لایه استفاده شد. برای این کار داده‌های مشاهداتی به پنج دسته مساوی تقسیم شدند و هر بار یک دسته از این داده‌ها برای برای تست مدل هوش مصنوعی و مابقی برای آموزش آن استفاده شدند. این فرایند پنج بار تکرار شد و هر دسته دقیقاً یکبار برای آموزش و یکبار برای آزمون مورد استفاده قرار گرفتند. این روش باعث افزایش انعطاف مدل هوش مصنوعی در هنگام برخورد با داده‌های مشاهداتی شد و می‌توان گفت که مدل هوش مصنوعی توانایی مدل‌سازی محدوده بیشتری از داده‌های آزمایشگاهی را داشت. در شکل (۴) چگونگی سازوکار روش درستی آزمایی چند لایه با ۵ لایه با مقادیر مشاهداتی قابل مشاهده است. همچنین، نتایج شاخص‌های آماری مختلف برای نتایج روش اعتبارسنجی چند لایه و برای کل داده‌ها در شکل (۵) نشان داده است. همان‌گونه که دیده می‌شود، بیشترین مقدار  $R^2$  برای حالت  $K=4$  بدست آمد ( $R^2=0.954$ ). این در حالی است که برای  $K=5$  مقادیر  $RMSE$  و  $MARE$  به‌ترتیب مساوی با ۰/۰۳۴ و ۴/۴۰۸ تخمین زده شدند.

### 1. K-fold cross validation

شکل ۴. طرح کلی روش درستی آزمایی چند لایه برای K=5




Fig. 4. layout of K-fold cross validation for K=5

شکل ۵. شاخص‌های آماری مختلف برای نتایج اعتبارسنجی چند لایه




Fig. 5. Different statistical indices for K-fold cross validation results

شکل ۳. تغییرات تعداد نرون‌های لایه مخفی در برابر شاخص‌های آماری




Fig. 3. Changes of number of hidden layer neurons versus statistical indices





Fig.6. Statistical indices for results of different activation functions


شکل ۷. مقایسه ضریب دبی شبیه‌سازی شده توسط توابع فعال‌سازی مختلف با مقادیر مشاهداتی



## توابع فعال‌سازی

مدل ELM دارای پنج تابع فعال‌سازی با نام‌های  $\sin$ ,  $\text{sig}$ ,  $\text{radbas}$ ,  $\text{tribas}$  و  $\text{hardlim}$  است که در ادامه آنها را بررسی می‌کنیم. به عبارت دیگر، بهینه‌ترین تابع فعال‌سازی برای تخمین ضریب دبی سرریزهای کنگره‌ای انتخاب می‌شود. در شکل (۶) نیز شاخص‌های آماری برای نتایج توابع فعال‌سازی مختلف به تصویر کشیده شده است. علاوه بر این، مقایسه ضریب دبی شبیه‌سازی شده با مقادیر مشاهداتی برای این توابع فعال‌سازی در شکل ۷ قابل مشاهده است. بر اساس نتایج مدل‌سازی، مقادیر  $R^2$ ،  $\text{RMSE}$  و  $\text{NSC}$  برای تابع فعال-سازی  $\text{sig}$  به ترتیب برابر با ۰/۹۴۳، ۰/۰۳۰ و ۰/۹۴۰ بودند. این در حالی است که برای تابع  $\sin$  مقادیر  $\text{MARE}$  و  $\text{RMSRE}$  به ترتیب مساوی با ۳/۹۶۸ و ۵/۲۲۴ محاسبه شدند. همچنین، مقدار  $R^2$  برای توابع فعال‌سازی  $\text{radbas}$ ،  $\text{tribas}$  و  $\text{hardlim}$  به ترتیب برابر با ۰/۰۰۸، ۰/۰۶۴ و ۰/۱۸۱ تخمین زده شدند. بنابراین با توجه به نتایج شبیه‌سازی‌ها، تابع فعال-سازی  $\text{sig}$  برای مدل هوش مصنوعی انتخاب می‌شود.

شکل ۶. شاخص‌های آماری برای نتایج توابع فعال‌سازی مختلف






Fig.7. Comparison of discharge coefficient simulated by different activation functions with observational values

## مدل‌های ORELM

در این بخش به ارزیابی مدل‌های ORELM 1 تا ORELM 7 پرداخته می‌شود. در شکل (۸) شاخص‌های آماری برای مدل‌های ORELM مختلف نشان داده شده است. همچنین مقایسه ضریب دبی شبیه‌سازی شده با مقادیر مشاهداتی به همراه نمودارهای پراکندگی این مدل‌ها در شکل (۹) قابل مشاهده است. مدل ORELM 1 مقادیر ضریب دبی سرریزهای کنگره‌ای را توسط کلیه پارامترهای ورودی  $Fr, H_T/P, \alpha, L_c/W, A/w, w/P$  تخمین زد. برای این مدل مقادیر NSC، MARE و RMSE به ترتیب مساوی با ۰/۹۴۰، ۳/۹۶۸ و ۰/۰۳۰ محاسبه شدند. این در حالی است که شاخص‌های آماری  $R^2$  و RMSRE برای ORELM 1 نیز به ترتیب برابر با ۰/۹۴۳ و ۵/۲۲۴ بودند. در این مطالعه، شش مدل ORELM 2 تا ORELM 7 مقدار ضریب دبی را بر حسب پنج پارامتر ورودی تخمین زدند. به عنوان مثال ORELM 2 مقادیر تابع هدف را توسط  $Fr, H_T/P, \alpha, L_c/W, A/w$  شبیه‌سازی کرد و تاثیر  $w/P$  نادیده گرفته شد. برای این مدل، مقادیر  $R^2$ ، RMSE و MARE به ترتیب برابر با ۰/۹۲۵، ۰/۰۳۴ و ۴/۵۳۰ محاسبه شدند. علاوه بر این، مقادیر NSC و RMSRE برای ORELM 2 به ترتیب مساوی با ۰/۹۱۹ و ۵/۷۶۲ بدست آمدند.

همچنین برای ORELM 3 مقادیر MARE و  $R^2$  به ترتیب با ۴/۴۱۴ و ۰/۹۳۶ بودند. این مدل تابعی از پارامترهای  $Fr, H_T/P, \alpha, L_c/W, w/P$  بود و تاثیر  $A/w$  برای آن حذف شد. این در حالی است که شاخص‌های آماری NSC و RMSE برای

ORELM 3 به ترتیب برابر با ۰/۹۳۲ و ۰/۰۳۲ بدست آمدند. باید خاطر نشان کرد که مدل ORELM 4 مقادیر ضریب دبی را توسط  $Fr, H_T/P, \alpha, A/w, w/P$  مدل‌سازی کرد و تاثیر پارامتر  $L_c/W$  نادیده گرفته شد. برای این مدل مقادیر RMSRE، MARE و NSC به ترتیب مساوی با ۵/۲۱۹، ۴/۱۳۵ و ۰/۹۴۰ محاسبه شدند. همچنین شاخص‌های آماری  $R^2$  و RMSE به ترتیب برابر با ۰/۹۴۳ و ۰/۰۳۰ بدست آمدند. برای تخمین ضریب دبی توسط ORELM 5 تاثیر پارامتر  $\alpha$  حذف شد. به عبارت دیگر، این مدل مقادیر ضریب دبی را بر حسب  $Fr, H_T/P, L_c/W, A/w, w/P$  پیش‌بینی نمود. برای ORELM 5 مقادیر  $R^2$ ، RMSE و MARE به ترتیب برابر با ۰/۹۳۵، ۰/۰۳۲ و ۴/۳۲۹ محاسبه شدند. این در حالی است که مدل ORELM 6 مقادیر تابع هدف را توسط پارامترهای  $Fr, H_T/P, \alpha, L_c/W, A/w, w/P$  شبیه‌سازی کرد. به بیان دیگر، برای تخمین ضریب دبی توسط این مدل تاثیر پارامتر  $H_T/P$  حذف شد. برای این مدل مقادیر RMSE، MARE و  $R^2$  به ترتیب مساوی با ۰/۰۳۷، ۴/۸۶۱ و ۰/۹۱۲ محاسبه شدند. همچنین مقادیر NSC و RMSRE برای مدل ORELM 6 به ترتیب برابر با ۰/۹۰۳ و ۶/۸۱۳ تخمین زده شدند. باید توجه شود که در میان کلیه مدل‌های هوش مصنوعی، مدل ORELM 6 کمترین دقت را داشت. برای شبیه‌سازی ضریب دبی توسط ORELM 7 تاثیر پارامتر  $Fr$  نادیده گرفته شد و این مدل مقادیر تابع هدف را توسط پارامترهای  $H_T/P, \alpha, L_c/W, A/w, w/P$  شبیه‌سازی کرد. برای این مدل، مقادیر شاخص‌های آماری  $R^2$ ، RMSE و NSC به ترتیب مساوی با ۰/۹۳۷، ۰/۰۳۱ و ۰/۹۳۳ محاسبه شدند. علاوه بر این، مقادیر RMSRE و MARE برای ORELM 7 به ترتیب برابر با ۵/۴۶۷ و ۴/۲۳۲ بودند. بر اساس نتایج مدل‌سازی، مدل ORELM 1 بیشترین دقت را برای شبیه‌سازی ضریب دبی سرریزهای کنگره‌ای داشت. این در حالی است که پارامترهای  $H_T/P$  و  $w/P$  به ترتیب موثرترین پارامترهای ورودی شناسایی شدند.

شکل ۸. شاخص‌های آماری مختلف برای نتایج مدل‌های ORELM مختلف






Fig.8. Different statistical indices for results of different ORELM models



شکل ۹. مقایسه ضریب دبی شبیه‌سازی شده با مشاهداتی و نمودارهای پراکندگی برای مدل‌های مختلف ORELM






Fig.9. Comparison of simulated discharge coefficient with observational data and scatter plots for different ORELM models

۱۰. نتایج توزیع خطا برای مدل‌های ORELM




Fig.10. Results of error distribution for ORELM models

همچنین، توزیع خطا برای مدل‌های ORELM، ELM در شکل (۱۰) نشان داده شده است. به عنوان مثال، تقریباً ۷۱٪ نتایج مدل ORELM دارای خطایی کمتر از ۵٪ بودند. این در حالی بود که تقریباً یک چهارم ضریب دبی‌های شبیه‌سازی شده توسط این مدل خطایی بین ۵ تا ۱۰ درصد داشتند. همچنین حدوداً ۵۴٪ نتایج مدل ELM خطایی کمتر از ۵٪ داشتند و تنها ۱۱٪ این نتایج خطایی بیشتر از ۱۰٪ به خود اختصاص دادند.

## تحلیل عدم قطعیت

در ادامه تحلیل عدم قطعیت برای مدل‌های ELM, ORELM انجام شد. تحلیل عدم قطعیت برای سنجش خطای پیش‌بینی شده توسط مدل‌های هوش مصنوعی و بررسی نحوه عملکرد این مدل‌ها اجرا می‌شود. به طور کلی خطای پیش‌بینی شده توسط مدل هوش مصنوعی برابر است با مقادیر شبیه‌سازی شده توسط مدل هوش مصنوعی ( $P_i$ ) منهای مقادیر مشاهداتی ( $O_i$ ) است ( $e_i = P_i - O_i$ ). همچنین، میانگین خطای پیش‌بینی شده به صورت  $e = \sum_{i=1}^n e_i$  محاسبه می‌شود. همچنین، انحراف استاندارد مقادیر خطای پیش‌بینی شده به صورت  $S_e = \sqrt{\sum_{i=1}^n (e_i - \bar{e})^2 / n - 1}$  می‌باشد. لازم به ذکر است که منفی بودن مقدار  $\bar{e}$  نشان می‌دهد که مدل هوش مصنوعی دارای عملکردی کمتر از واقعیت است و مثبت بودن  $\bar{e}$  به

معنای بیشتر از واقعیت بودن مدل هوش مصنوعی است. همچنین، با استفاده از پارامترهای  $\bar{e}$  و  $S_e$  یک باند اطمینان در اطراف مقادیر خطای پیش‌بینی توسط روش ویلسون بدون تحصح پیوسته ایجاد می‌شود. سپس با استفاده از  $\pm 1.64 S_e$  به صورت تقریبی منجر به ۹۵٪ باند اطمینان می‌گردد که با ۹۵٪ PEI نشان داده می‌شود. پارامترهای تحلیل عدم قطعیت مدل‌های ELM, ORELM در جدول ۲ مرتب شده‌اند. در این جدول عرض باند عدم قطعیت با WUB نشان داده می‌شود. با توجه به نتایج تحلیل عدم قطعیت، مدل‌های ELM, ORELM دارای عملکردی بیشتر از واقعیت بودند. همچنین، ۹۵٪ PEI برای مدل ORELM بین ۰/۰۰۲۷۰ تا ۰/۰۰۲۷۰- بود. این در حالی است که عرض باند عدم قطعیت برای مدل ELM تقریباً برابر با ۰/۰۰۳۴۱- محاسبه شد.

جدول ۲. پارامترهای تحلیل عدم قطعیت مدل‌های ELM, ORELM

| Model | $\bar{e}$ | $S_e$ | WUB      | 95% PEI             |
|-------|-----------|-------|----------|---------------------|
| ORELM | 8.992E-11 | 0.030 | -0.00270 | -0.00270 to 0.00270 |
| ELM   | 3.209E-09 | 0.038 | -0.00341 | -0.00341 to 0.00341 |

Table 2. Uncertainty analysis parameters for ORELM, ELM models

## مدل برتر

با توجه به اینکه مدل ORELM 1 به عنوان مدل برتر

شناسایی شد، یک رابطه برای آن به صورت زیر ارائه می‌شود.

$$C_d = \left[ \frac{1}{(1 + \exp(\ln W \times \ln V + BHN))} \right] \times OutW \quad (12)$$

در اینجا به ترتیب شامل ماتریس وزن‌های ورودی، ماتریس متغیرهای ورودی، ماتریس بایاس نرون‌های مخفی و ماتریس وزن‌های خروجی هستند. مقادیر این ماتریس‌ها به صورت زیر ارائه می‌شود:

$$\ln V = \begin{bmatrix} H_T/P \\ \alpha \\ L_c/W \\ A/w \\ w/P \end{bmatrix} \quad (13)$$

## مقایسه با مدل رگرسیونی

در این قسمت نتایج مدل برتر ORELM با یک مدل رگرسیون خطی چند منظوره مقایسه می‌شود. لازم به ذکر است که مدل رگرسیونی مذکور (معادله ۱۱) توسط نرم‌افزار مینی تب استخراج شده است. مقادیر ضریب تبیین و ضریب نش برای این مدل رگرسیونی به ترتیب مساوی ۰/۸۹۲ و ۰/۹۰۳ محاسبه شده‌اند. همچنین، مقادیر RMSE و MARE برای این رابطه به ترتیب مساوی با ۰/۰۳۹ و ۵/۲۷۰ تخمین زده شده‌اند. همان‌گونه که مشاهده می‌شود. مدل ORELM عملکرد بهتری در مقایسه با این مدل رگرسیونی دارد.

$$C_d = 0.581 - 0.821(Fr) - 0.026(H_T/P) - 0.001(\alpha) - 0.010(L_c/W) - 0.356(A/w) + 0.090(w/P) \quad (11)$$

|                                      |        |         |        |        |         |        |        |        |          |            |      |
|--------------------------------------|--------|---------|--------|--------|---------|--------|--------|--------|----------|------------|------|
|                                      | -0.207 |         | 0.902  | -0.934 | -0.944  | 0.483  | -0.740 | 0.871  |          | -2519.530  |      |
|                                      | -0.253 |         | 0.266  | -0.905 | -0.965  | -0.321 | 0.470  | -0.254 |          | 497798.800 |      |
|                                      | 0.562  |         | 0.878  | 0.699  | -0.151  | 0.734  | 0.536  | -0.305 |          | -1.374     |      |
|                                      | 0.973  |         | -0.005 | -0.027 | -0.636  | -0.130 | -0.535 | -0.620 |          | -929.785   |      |
|                                      | 0.838  |         | -0.145 | 0.149  | 0.240   | -0.592 | -0.647 | -0.779 |          | -1.899     |      |
| تخمین ضریب دبی سرریزهای کنگره‌ای ... | 0.918  | شهاب    | -0.718 | -0.178 | -0.0005 | 0.748  | -0.604 | -0.512 |          | 2475       |      |
| $BHN =$                              | 0.511  | $InW =$ | -0.985 | 0.094  | 0.859   | 0.995  | 0.939  | -0.300 | $OutW =$ | -287.400   |      |
|                                      | -0.820 |         | 0.209  | -0.370 | -0.605  | -0.175 | -0.905 | -0.690 |          | 3187.964   |      |
|                                      | -0.652 |         | -0.366 | -0.901 | 0.224   | 0.641  | -0.600 | -0.383 |          | -1.171     |      |
|                                      | 0.358  |         | 0.068  | 0.084  | -0.615  | -0.827 | 0.625  | 0.329  |          | 492.649    |      |
|                                      | -0.417 |         | -0.308 | 0.141  | -0.012  | 0.293  | 0.343  | -0.162 |          | 0.050      |      |
|                                      | -0.427 |         | -0.289 | 0.684  | 0.412   | 0.877  | -0.653 | -0.226 |          | 201.914    |      |
|                                      | -0.904 |         | -0.237 | 0.909  | 0.172   | 0.682  | -0.602 | 0.554  |          | -7.908     |      |
|                                      | -0.492 |         | 0.652  | 0.224  | 0.293   | -0.118 | -0.378 | 0.449  |          | 46.588     | (۱۴) |

## نتیجه‌گیری

در این مطالعه برای اولین بار، با استفاده از یک روش هوش مصنوعی نوین تحت عنوان ماشین آموزش نیرومند خارج از محدوده (ORELM) ضریب دبی سرریزهای کنگره‌ای شبیه‌سازی شد. برای اعتبار سنجی نتایج مدل‌سازی از روش اعتبارسنجی چند لایه با  $K=5$  استفاده گردید. سپس با تجزیه و تحلیل نتایج مدل‌سازی، بهینه‌ترین تعداد نرون‌های لایه مخفی برابر با 15 و دقیق‌ترین تابع فعال‌سازی (sigmoid) برای مدل هوش مصنوعی انتخاب شدند. در ادامه با استفاده از پارامترهای ورودی، ۷ مدل ORELM تعریف شدند و با تحلیل حساسیت مدل برتر و موثرترین پارامترهای ورودی شناسایی شدند. مدل برتر مقادیر ضریب دبی را با استفاده از کلیه پارامترهای ورودی شامل  $Fr, H/P, \alpha, L/W, A/w, w/P$  تخمین زد. این مدل دقت قابل قبولی برای مدل‌سازی ضریب دبی سرریزهای کنگره‌ای داشت. به‌عنوان مثال، مقادیر MARE و RMSE برای این مدل به ترتیب مساوی با ۳/۹۶۸ و ۰/۰۳۰ محاسبه شدند. همچنین، پارامترهای نسبت هد روی سرریز به ارتفاع سرریز ( $H/P$ ) و نسبت عرض یک کنگره به ارتفاع سرریز ( $w/P$ ) موثرترین پارامترهای ورودی شناسایی شدند. همچنین با انجام یک تحلیل عدم قطعیت نشان داده شده که مدل‌های ORELM و ELM دارای عملکردی بیشتر از مقدار واقعی بود.

به‌طور کلی، هر چند که مدل ORELM دارای عملکرد قابل قبولی برای شبیه‌سازی ضریب دبی است اما دارای محدودیت‌هایی نیز هست. به‌عنوان مثال، ضرایب این الگوریتم قابلیت تنظیم توسط کاربر را ندارند و دخالت کاربر برای این مدل عددی به حداقل رسیده است. علاوه بر این، این مدل هوش مصنوعی توانایی ارائه یک رابطه صریح را ندارد و خروجی آن به‌صورت ماتریس است.

## اعلام تعارض منافع

نویسندگان اعلام می‌کنند که هیچ نوع تعارض منافع وجود ندارد.

## منابع و مراجع

- [1] Zaji A.H. & Bonakdari H. 2014. Performance evaluation of two different neural network and particle swarm optimization methods for prediction of discharge capacity of modified triangular side weirs. *Flow Measurement and Instrumentation*, 40, 149-156.
- [2] Ebtehaj I., Bonakdari H., Zaji A.H., Azimi H. & Sharifi A. 2015. Gene expression programming to predict the discharge coefficient in rectangular side weirs. *Applied Soft Computing*, 35, 618-628.
- [3] Khoshbin F., Bonakdari H., Ashraf Talesh S.H., Ebtehaj I., Zaji A.H. & Azimi H. 2016. Adaptive neuro-fuzzy inference system

- Learning Algorithms for Arced Labyrinth Spillways. *Water*, 11(3), 544.
- [11] Bilhan O., Emiroglu M.E., Miller C.J. & Ulas M. 2019. The evaluation of the effect of nappe breakers on the discharge capacity of trapezoidal labyrinth weirs by ELM and SVR approaches. *Flow Measurement and Instrumentation*, 64, 71-82.
- [12] Barros A.L.B. & Barreto G.A. 2013. Building a robust extreme learning machine for classification in the presence of outliers. In International Conference on *Hybrid Artificial Intelligence Systems*, Springer, 588-597.
- [13] Chen C., Yan C. & Li Y. 2015. A robust weighted least squares support vector regression based on least trimmed squares. *Neurocomputing*, 168, 941-946.
- [14] Yuan Z., Wang X., Cao J., Zhao H. & Chen B. 2018. Robust Matching Pursuit Extreme Learning Machines. *Scientific Programming*, 1-10.
- [15] Goodfellow I., Bengio Y. & Courville, A. 2016. Deep learning. MIT press.
- [16] Huang G.B., Zhu Q.Y. & Siew, C.K. 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70(1), 489-501.
- [17] Zhang K. & Luo M. 2015. Outlier-robust extreme learning machine for regression problems. *Neurocomputing*, 151, 1519-1527.
- [18] Kumar S., Ahmad Z. & Mansoor T. 2011. A new approach to improve the discharging capacity of sharp-crested triangular plan form weirs. *Journal of Flow Measurement and Instrumentation*, 22(3), 175-180.
- [19] Seamons T.R. 2014. Labyrinth weirs: a look into geometric variation and its effect on efficiency and design method predictions. Master of Science thesis. Utah State University. USA.
- multi-objective optimization using the genetic algorithm/singular value decomposition method for modelling the discharge coefficient in rectangular sharp-crested side weirs. *Engineering Optimization*, 48(6), 933-948.
- [4] Roushangar K., Khoshkanar R. & Shiri J. 2016. Predicting trapezoidal and rectangular side weirs discharge coefficient using machine learning methods", *ISH Journal of Hydraulic Engineering*, 22(3), 254-261.
- [5] Azimi H., Shabanlou S., Ebtehaj I., Bonakdari H. & Kardar S. 2017a. Combination of computational fluid dynamics, adaptive neuro-fuzzy inference system, and genetic algorithm for predicting discharge coefficient of rectangular side orifices. *Journal of Irrigation and Drainage Engineering*, 143(7), 04017015.
- [6] Azimi H., Bonakdari H. & Ebtehaj, I. 2017b. Sensitivity analysis of the factors affecting the discharge capacity of side weirs in trapezoidal channels using extreme learning machines. *Flow Measurement and Instrumentation*, 54, 216-223.
- [7] Haghiabi A.H., Parsaie A. & Ememgholizadeh S. 2017. Prediction of discharge coefficient of triangular labyrinth weirs using Adaptive Neuro Fuzzy Inference System. *Alexandria Engineering Journal*.
- [8] Roushangar K., Alami M.T., Majedi Asl M. & Shiri J. 2017. Modeling discharge coefficient of normal and inverted orientation labyrinth weirs using machine learning techniques. *ISH Journal of Hydraulic Engineering*, 23(3), 331-340.
- [9] Roushangar K., Alami M.T., Shiri J. & Asl, M.M. 2018. Determining discharge coefficient of labyrinth and arced labyrinth weirs using support vector machine. *Hydrology Research*, 49(3), 924-938.
- [10] Salazar F. & Crookston, B.M. 2019. A Performance Comparison of Machine

# Estimation of labyrinth weir discharge coefficient by modern artificial intelligence models

Shahabodin Shafiei<sup>1</sup>, Mohsen Najarchi<sup>2†</sup>, Saeid Shabanlou<sup>3</sup>

<sup>1</sup> Ph.D. Candidate, Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran

<sup>2</sup> Associate Professor, Department of Civil Engineering, Arak Branch, Islamic Azad University, Arak, Iran

<sup>2</sup> Associate Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

m-najarchi@iau-arak.ac.ir

## Abstract

Generally, labyrinth weirs pass more water compared to their equivalent rectangular weirs. Thus, these types of weirs are popular amongst hydraulic and environmental engineers. In this paper, for the first time, a novel artificial intelligence (AI) technique called "outlier robust extreme learning machine (ORELM)" is used to estimate the discharge coefficient of labyrinth weirs. The ORELM method has been proposed in order to overcome the difficulties of the classical ELM in predicting datasets with outliers. In this method, the concept of "sparsity characteristic of outliers" is used. Also, in this study, to verify the results of the numerical models the experimental measurements conducted by Kumar et al. (2011) and Seamons (2014) are employed. The experimental model established by Kumar et al. (2011) is composed of a rectangular channel with a length of 12m, a width of 0.28m and a depth of 0.41m. The weir is made of steel sheets and placed at an 11m distance from rectangular channel inlet. Also, Seamons (2014) experimental model has been set up in a rectangular channel with the length, width and height of 14.6m, 1.2m and 0.9m, respectively. First, the number of the hidden layer neurons initials from 5 and continues to 45 and the most optimal number the hidden layer neurons are taken into account equal to 5. In this study, the Monte Carlo simulations are used for examining the abilities of the numerical models. The main idea of this method is based on solving problems which might be actual in nature using random decision-making. The Monte-Carlo methods are usually implemented for simulating physical and mathematical systems which are not solvable by means of other methods. In this paper, the K-fold cross validation method is employed for validating the results of the numerical models. To this end, the observational data are divided into five equal sets and each time one set of these data is used for testing the numerical model and the rest for training it. This procedure is repeated five times and each test is used exactly once to train and once to test. This method increases the flexibility of the numerical model when dealing with the observational data, and it can be said that the numerical model has the ability to model a greater range of laboratory data. For instance, the maxim value of  $R^2$  is obtained for the  $K=4$  case ( $R^2=0.954$ ), while for the  $K=5$  case the values of RMSE and MARE are estimated 0.034 and 4.408, respectively. After that, different activation functions are evaluated in order to detect the most accurate one for the numerical model. Subsequently, six different ORELM models are developed using the parameters affecting the discharge coefficient of labyrinth weirs. Also, the superior model and the most effective input parameters are identified through a sensitivity analysis. For example, the values of  $R^2$ , RMSRE and NSC for the superior model are calculated 0.943, 5.224 and 0.940, respectively. Furthermore, the ratio of the head above the weir to the weir height ( $H_T/P$ ) and the ratio of the width of a single cycle to the weir height ( $w/P$ ) are introduced as the most important input parameters. Also, the results of the ORELM superior model are compared with the artificial intelligence models including the extreme learning machine, artificial neural network and the support vector machine and it is concluded that ORELM has a better performance. Then, an uncertainty analysis is conducted for the ORELM, ELM, ANN and SVM models and it is proved that ORELM has an overestimated performance.

**Keywords:** Labyrinth weir, Discharge coefficient, Machine learning, Uncertainty analysis