

## یادداشت تحقیقاتی

# پیش‌بینی عمق آبشستگی در پائین‌دست سرریز جامی شکل توسط مدل ماشین آموزش نیرومند و روش اعتبار سنجی چند لایه

محمد معین فلاحی<sup>۱</sup>، احمد رجبی<sup>۲\*</sup>، بهروز یعقوبی<sup>۳</sup>

۱ دانشجوی دکتری منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران  
۲ و ۳ استادیار منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

\*ahmad.rajabi1974@gmail.com

تاریخ دریافت: [۹۷/۰۳/۲۱]

تاریخ پذیرش: [۹۶/۱۱/۱۲]

## چکیده

در این مطالعه، عمق آبشستگی در پائین‌دست سرریزهای جامی با استفاده از مدل ماشین آموزش نیرومند شبیه‌سازی شد. نسخه اولیه ماشین آموزش نیرومند یک نوع شبکه عصبی تک لایه پیش‌خور است که ماتریس وزن ورودی را به صورت تصافی انتخاب کرده و وزن‌های خروجی را نیز به شکل تحلیل تعیین می‌نماید. علاوه بر این برای سنجش توانایی مدل‌های ماشین آموزش نیرومند از شبیه‌سازی‌های مونت کارلو استفاده می‌شود. شبیه‌سازی مونت کارلو یک طبقه‌بندی گسترده از الگوریتم‌های محاسباتی است که از نمونه‌گیری تصادفی برای محاسبه نتایج شبیه‌سازی‌ها استفاده می‌کند. همچنین از روش اعتبار سنجی چند لایه برای بررسی توانایی مدل‌های هوش مصنوعی بهره گرفته می‌شود. در روش اعتبار سنجی چند لایه ای، نمونه اصلی به طور تصادفی به  $k$  نمونه فرعی به اندازه مساوی تقسیم می‌شود. مزیت این روش، تکرار تصادفی نمونه‌های فرعی در روند آزمون و آموزش برای کلیه مشاهدات است و هر مشاهده دقیقاً یک‌بار برای اعتبار سنجی مورد استفاده قرار می‌گیرد. همچنین در این مطالعه برای اعتبار سنجی نتایج مدل‌سازی از مقادیر آزمایشگاهی عضویت  $a$  و همکاران (۲۰۰۵) استفاده و شش مدل ماشین آموزش نیرومند تعریف شد. با انجام تحلیل حساسیت مؤثرترین پارامتر آبشستگی معرفی شد. همچنین با تجزیه و تحلیل نتایج مدل‌های مختلف، مدل برتر معرفی شد. این مدل مقادیر آبشستگی را با دقت قابل قبولی پیش‌بینی کرد و تابعی از کلیه پارامترهای ورودی بود. به‌عنوان نمونه مقادیر ضریب تبیین و شاخص پراکندگی به ترتیب مساوی ۰/۹۹۳ و ۰/۰۷۱ بدست آمد.

**کلمات کلیدی:** عمق آبشستگی، سرریز جامی شکل، مدل‌سازی، ماشین آموزش نیرومند، اعتبار سنجی چند لایه

## ۱- مقدمه

دارای انرژی پتانسیل فراوانی است. به بیان دیگر هنگامی که جریان از روی سرریز تخلیه شده و به پای سرریز می‌رسد، دارای قدرت تخریبی بالایی است که این انرژی جنبشی باید به شکل مناسبی تلف شود، در غیر این صورت باعث تخریب بستر رودخانه و سازه‌های پائین‌دست می‌شود. یکی از راه

سرریزها برای کنترل و اندازه‌گیری تراز جریان استفاده می‌شوند. یکی از کاربردی‌ترین نوع سرریزها، سرریز اوجی است که برای تنظیم تراز آب جریان داخل دریاچه پشت سد استفاده می‌شود. به طور کلی به دلیل ارتفاع زیاد، جریان پشت سرریز

آزمایشگاهی عرض، عمق و فاصله حفره آبشستگی تا پای سرریز جامی شکل را برای شرایط مختلف مورد بررسی قرار دادند. آنها با تجزیه و تحلیل نتایج مطالعه مذکور یک سری معادله برای محاسبه پارامتری های یاد شده ارائه دادند [5]. کوکپینار و کوچوکعلی بیشینه عمق آبشستگی در پائین دست سرریزهای اوجی دارای باکت جامی شکل را مورد بررسی آزمایشگاهی نشان دادند که عمق آبشستگی تابعی از عدد فرود، عدد رینولدز جت، زاویه لبه سرریز و ابعاد رسوبات است [6].

به تازگی کاربرد مدل‌های متفاوت شبکه عصبی و نرو- فازی در پیش‌بینی پدیده‌های پیچیده و غیرخطی رشته‌های مختلف مهندسی به شکل قابل ملاحظه‌ای گسترش یافته است. علاوه بر این تکنیک‌های هوش مصنوعی به شکل گسترده‌ای برای شبیه‌سازی الگوی آبشستگی در پائین‌دست سرریزهای جامی شکل استفاده شده‌اند. عضمت ا. و همکاران به وسیله مدل‌های رگرسیون آماری و شبکه عصبی مصنوعی ابعاد حفره آبشستگی بعد از یک سرریز اوجی دارای باکت جامی را تخمین زدند و با بررسی مدل‌های محاسبات نرم مذکور نشان دادند که مدل هوش مصنوعی دارای دقت بیشتری است [7]. همچنین گوین و گونال توسط روش برنامه نویسی ژنتیک، آبشستگی موضعی در پائین دست سازه‌های هیدرولیکی را پیش‌بینی کردند [8]. توکلی‌زاده و کاشفی پور (۲۰۰۹) ابعاد حفره آبشستگی در پائین‌دست دریچه‌های کنترل را با استفاده از شبکه عصبی مصنوعی شبیه‌سازی کردند. آنها نتایج مدل عصبی را با روابط تجربی سایر پژوهشگران و مدل رگرسیونی مقایسه کردند [9]. صمدی و همکاران الگوی آبشستگی بعد از یک سرریز را به کمک مدل‌های درختی M5، طبقه‌بندی و رگرسیون پیش‌بینی کردند. آنها نشان دادند که مدل درختی M5 دارای دقت بیشتری است [10].

با بررسی مطالعات گذشتگان مشاهده می‌شود که تاکنون تخمین آبشستگی در پائین‌دست سرریزهای اوجی دارای باکت جامی شکل توسط مدل ماشین آموزش نیرومند انجام نشده است. همچنین، از روش اعتبار سنجی چند لایه با  $k$  مساوی ۵ برای درستی‌آزمایی نتایج مدل‌های محاسبات نرم استفاده می‌شود. بنابراین در این مطالعه با استفاده از ماشین آموزش نیرومند و اعتبار سنجی چند لایه، عمق حفره آبشستگی بعد از

کارهای اتلاف انرژی مذکور استفاده از باکت جامی شکل در پای سرریز اوجی است. با تعبیه سازه هیدرولیکی جامی شکل، آب به هوا پرتاب شده و بعد از ترکیب با هوا انرژی آن به شکل قابل توجهی تلف می‌شود و در پائین‌دست سرریز اوجی فرود می‌آید. هر چند جریان فرود آمده در مقایسه با جریان قبل از باکت جامی شکل انرژی کمتری دارد اما در صورتی که مصالح پائین دست رسوبی باشند یک حفره آبشستگی در ناحیه مورد اشاره تشکیل می‌شود. با گذشت زمان و با افزایش ابعاد حفره آبشستگی، پایداری سازه‌ای سرریز اوجی به خطر افتاده و احتمال واژگونی یا نشست آن و متعاقباً تخریب سازه‌ای سرریز مذکور وجود دارد. به دلیل اهمیت موضوع مورد نظر، مطالعات آزمایشگاهی، تحلیلی و عددی فراوانی توسط پژوهشگران مختلف روی پیش‌بینی و تخمین حفره آبشستگی انجام شده است. بورمان و جولین یک مدل تحلیل با فرض جت جریان دو بعدی برای تخمین آبشستگی در پائین‌دست دریچه‌های کنترل ارائه دادند. آنها نتایج مدل مذکور را با اندازه‌گیری‌های آزمایشگاهی مورد مقایسه قرار دادند و با تجزیه و تحلیل نتایج مطالعه خود، معادله‌ای برای محاسبه ابعاد حفره آبشستگی ارائه نمودند که تابعی از سرعت، عمق جریان و ابعاد ذرات رسوب بود. همچنین آنها بیان کردند که همبستگی مدل تحلیلی و مقادیر آزمایشگاهی در حد قابل قبولی است [1]. در ادامه خوان و هگر در یک مطالعه آزمایشگاهی، الگوی جریان بعد از باکت جامی شکل برای دو حالت با و بدون صفحه منحرف کننده جریان برای شرایط هیدرولیکی و هندسی مختلف را مورد ارزیابی قرار دادند. آنها نشان دادند که وجود صفحه مذکور باعث کاهش آثار پدیده کاویتاسیون می‌شود [2]. سانه‌پا و هگر تاثیر جت جریان دایروی شکل روی الگوی آبشستگی را مورد بررسی آزمایشگاهی قرار دادند. آنها برای محاسبه عمق حفره آبشستگی یک رابطه پیشنهاد دادند [3]. درگاهی به صورت آزمایشگاهی، نیم‌رخ حفره آبشستگی در پائین‌دست سرریزهای اوجی را مورد مطالعه قرار داد. وی پارامترهای بدون بعد نسبت اعماق مزدوج، نسبت ابعاد رسوبات و زبری نسبی سازه محافظ واقع در پائین‌دست سرریز اوجی را به عنوان موثرترین پارامترها روی عمق حفره آبشستگی شناسایی نمود [4]. عضمت ا. و همکاران در قالب یک پژوهش

شبکه عصبی پیش‌رو تک لایه، با  $N$  گره مخفی، با وزن‌های ورودی انتخابی تصادفی و بایاس‌های لایه مخفی (و گره‌های مخفی که گره‌های تصادفی نامیده می‌شوند) به طور کامل می‌تواند  $n$  مشاهده متمایز را آموزش دهد. هوانگ و همکاران، ثابت کردند که اگر تابع فعال‌سازی در لایه مخفی به طور نامحدود قابل تشخیص باشد، وزن‌های ورودی و بایاس‌های لایه مخفی شبکه عصبی پیش‌رو تک لایه به طور تصادفی انتخاب می‌شوند. بعد از وزن‌های ورودی و بایاس‌های لایه مخفی، که به طور تصادفی انتخاب شدند، شبکه عصبی پیش‌رو تک لایه، به سادگی با یک سیستم خطی، وزن‌های خروجی را (ارتباط بین لایه مخفی و لایه خروجی) از طریق عملکرد معکوس ماتریس خروجی لایه مخفی تخمین زدند. براساس این نظریه، الگوریتم آموزشی ساده‌ای از شبکه عصبی پیش‌خور تک لایه به نام ماشین آموزش نیرومند پیشنهاد شد که سرعت یادگیری در آن بسیار سریع‌تر از الگوریتم آموزشی پیش‌رو برگشتی<sup>۳</sup> است، در حالی که اجرای عمومی بهتری هم به همراه دارد.

جدای از الگوریتم آموزشی سنتی، الگوریتم پیشنهاد شده به دست آوردن کوچک‌ترین خطای آموزشی و کمترین میانگین وزنی تمایل دارد و با بدست آوردن کوچک‌ترین خطای آموزشی و کمترین میانگین وزنی، بهترین و سریع‌ترین اجرا را در بر دارد. ساختار یک شبکه عصبی پیش‌خور با الگوریتم ماشین آموزش نیرومند در شکل (۱) نشان داده شده است.

شکل ۱. معماری ماشین آموزش نیرومند




Fig. 1. Architecture of ELM

سرریز جامی شکل تخمین زده می‌شود. برای این منظور ابتدا عوامل موثر روی حفره آبستنگی شناسایی شده، سپس شش مدل ماشین آموزش نیرومند تعریف می‌شود و با استفاده از تحلیل حساسیت، مدل برتر و پارامتر ورودی موثر شناسایی می‌شود.

## ۲- مواد و روش‌ها

### ۲-۱- الگوریتم ماشین آموزش نیرومند<sup>۱</sup>

شبکه‌های عصبی پیش‌رو، به دلیل توانایی بالا برای تقریب‌سازی نگاشت‌های غیرخطی پیچیده بین نمونه‌های ورودی و پارامتر هدف مدل و همچنین برای بهبود مدل‌های موجود پدیده‌های طبیعی و مصنوعی که دسترسی به آن‌ها با روش‌های معمول مشکل است، مورد استفاده قرار می‌گیرند. از طرفی دیگر، فقدان یک الگوریتم آموزشی سریع برای شبکه‌های عصبی، از سال‌ها پیش وجود داشته است (هوانگ و همکاران) [11]. در کاربردهای واقعی، شبکه‌های عصبی در گروه‌های آموزشی محدود، آموزش داده می‌شوند. برای تقریب‌سازی توابع در گروه‌های آموزشی محدود، شبکه عصبی پیش‌رو با یکی لایه مخفی، با  $N$  گره مخفی و با تقریباً هر تابع فعال‌سازی غیرخطی، می‌تواند  $n$  مشاهده متمایز را آموزش دهد. این مورد که در هر الگوریتم آموزشی عملی از شبکه‌های عصبی پیش‌رو، وزن‌های ورودی (ارتباط بین لایه ورودی و اولین لایه مخفی) و بایاس‌های لایه مخفی باید تنظیم شود، باید مدنظر قرار گیرد.

به طور سنتی، همه پارامترهای شبکه عصبی پیش‌رو نیاز به تنظیم دارند. بنابراین یک وابستگی بین لایه‌های متفاوت (وزن‌ها و بایاس‌ها) وجود دارد. در دهه‌های گذشته، روش‌های گرایان کاهشی<sup>۲</sup>، اساساً در الگوریتم‌های آموزشی مختلف شبکه‌های عصبی استفاده می‌شد. اما مشاهده شد که روش آموزش گرایان کاهشی به دلیل گام‌های آموزشی نامناسب، بسیار کند است و گام‌های آموزشی تکراری بسیار زیادی برای بهتر اجرا کردن الگوریتم نیاز است.

1 Extreme Learning Machine (ELM)

2 reduced gradient method

همکاران استفاده می‌شود. مدل آزمایشگاهی مذکور شامل یک سرریز اوجی با باکت جامی شکل است که آنها مقادیر عمق آبشستگی ( $d_s$ ) در پائین‌دست سرریز جامی شکل را اندازه‌گیری نمودند. همچنین عضویت  $a$  و همکاران مقادیر هد کل ( $H$ )، عمق پایاب ( $d_w$ )، زاویه لبه باکت ( $\phi$ )، شعاع انحنا باکت ( $R$ )، اندازه متوسط رسوبات ( $d_{50}$ ) و دبی بر واحد عرض سرریز اوجی ( $q$ ) را اندازه‌گیری کردند. در جدول (۱) دامنه مقادیر آزمایشگاهی اندازه‌گیری شده توسط آنها مرتب شده است. علاوه بر این طرح کلی مدل آزمایشگاهی عضویت  $a$  و همکاران در قالب شکل (۲) به تصویر کشیده شده است.

جدول ۱. دامنه مقادیر آزمایشگاهی اندازه‌گیری شده توسط عضویت  $a$  و همکاران (۲۰۰۵)

Rang	Parameter
0.1-2791.7962	$H$ (m)
0.0-286.265	$d_w$ (m)
0.0-512.55	$d_s$ (m)
0.0-174.78	$\phi$ (Rad)
0.0-1.61	$R$ (m)
0.0-2.008	$d_{50}$ (m)
0.0-89.2042	$q$ ( $m^2/s$ )

Table 1. Range of experimental parameters measured by Azmathullah et al. (2005)

شکل ۲. طرح کلی مدل آزمایشگاهی عضویت  $a$  و همکاران (۲۰۰۵)




Fig. 2. Layout of Azmathullah et al. (2005) experimental model

### ۳-۱- آبشستگی در پایین‌دست سرریز جامی شکل

عضویت  $a$  و همکاران بیان نمودند که مقادیر حفره آبشستگی بعد از سرریز جامی شکل تابعی از  $q, H, R, \phi, d_w, d_{50}$  شتاب گرانش ( $g$ )، چگالی آب ( $\rho_w$ ) و چگالی رسوب ( $\rho_s$ ) است:

$$d_s = f(q, H, R, \phi, d_w, d_{50}, g, \rho_w, \rho_s) \quad (4)$$

همچنین با استفاده از نظریه  $\pi$  باکینگهام پنج گروه بدون بعد تعریف کردند:

$$d_s / d_w = f(q / \sqrt{gd_w^3}, H / d_w, R / d_w, d_{50} / d_w, \phi) \quad (5)$$

برای مجموعه‌ای از  $n$  نمونه مجزای برچسب‌دار دلخواه،  $\{(x_i, t_i) | x_i \in R^d, t_i \in R^k, i = 1, 2, \dots, n\}$  که تعداد گره‌های لایه ورودی و  $k$  تعداد نرون‌های لایه خروجی است، تابع خروجی ماشین آموزش نیرومند (با فرض یک نرون خروجی) و به ازای هر نمونه آموزشی ورودی ( $x$ )، به صورت زیر فرمول‌بندی می‌شود:

$$f_m(x) = \sum_{i=1}^m \beta_i h_i(x) = h(x)\beta \quad (1)$$

که  $m$  تعداد نرون‌های لایه پنهان،  $\beta = [\beta_1, \beta_2, \dots, \beta_m]^T$  بردار وزن‌های خروجی و  $h(x) = [h_1(x), h_2(x), \dots, h_m(x)]$  بردار خروجی لایه پنهان با توجه به ورودی  $x$  است.  $h(x)$  در واقع داده را از فضای ورودی به فضای ویژگی ماشین آموزش نیرومند ( $H$ ) نگاشت می‌کند، بنابراین  $h(x)$  یک نگاشت ویژگی است. توابع خروجی متفاوتی برای نرون‌های پنهان وجود دارد. تابع بکار برده شده در این مقاله تابع سیگموئید است که به صورت زیر تعریف می‌شود:

$$g(x, \theta) = \frac{1}{1 + \exp(- (w^T x + b))} \quad (2)$$

که در آن  $\theta = \{w, b\}$  پارامترهای تابع،  $g$  یک تابع غیر ثابت قطعه به قطعه پیوسته کراندار،  $w$  بردار وزن ورودی با ابعاد  $(d \times 1)$  و  $b$  بایاس نرون‌های پنهان هستند. ماتریس خروجی لایه پنهان ( $H_{n \times m}$ ) به صورت زیر تعریف می‌شود:

$$H = \begin{bmatrix} g(w_1^T x_1 + b_1) & \dots & g(w_m^T x_1 + b_m) \\ \vdots & \vdots & \vdots \\ g(w_1^T x_n + b_1) & \dots & g(w_m^T x_n + b_m) \end{bmatrix} \quad (3)$$

ماتریس وزن‌های خروجی با روش معکوس تعمیم یافته به صورت  $\beta = H^+ T$  بدست می‌آید که  $H^+$  معکوس تعمیم یافته مور-پنسور ماتریس  $H$  است. زمانی که  $H^T H$  نامنفرد است  $H^+$  به صورت  $H^+ = (H^T H)^{-1} H^T$  و زمانی که  $H H^T$  نامنفرد است  $H^+$  به صورت  $H^+ = (H H^T)^{-1} H$  محاسبه می‌شود.

### ۳-۲ مدل آزمایشگاهی

در مطالعه حاضر برای درستی آزمایشی نتایج مدل‌های محاسبات نرم از مقادیر آزمایشگاهی اندازه‌گیری شده توسط عضویت  $a$  و

چند لایه ای برای بررسی عملکرد مدل‌های مذکور استفاده می‌شود. در روش اعتبارسنجی چند لایه ای، نمونه اصلی است به طور تصادفی به  $k$  نمونه‌های فرعی به اندازه مساوی تقسیم می‌شوند. در بین نمونه‌های فرعی  $k$ ، یک نمونه فرعی به عنوان داده‌های آموزش و باقی مانده آنها به عنوان داده‌های آزمون این مدل استفاده می‌شوند. سپس روند اعتبارسنجی  $k$  بار تکرار می‌شود (برابر تعداد لایه‌ها)، هر کدام از نمونه‌های فرعی  $k$  دقیقاً یکبار به عنوان داده‌های آموزش مورد استفاده قرار می‌گیرند. نتایج بدست آمده از  $k$  لایه‌ی مذکور متوسط‌گیری شده و به عنوان یک تخمین ارائه می‌شود. مزیت این روش، تکرار تصادفی نمونه‌های فرعی در روند آزمون و آموزش برای کلیه مشاهدات است و هر مشاهده دقیقاً یکبار برای اعتبارسنجی مورد استفاده قرار می‌گیرد. در این مطالعه مقدار  $k$  برابر با ۵ فرض شده است. طرح کلی روش اعتبارسنجی چند لایه نیز در شکل (۴) قابل مشاهده است. همچنین در این مطالعه برای انتخاب بهینه‌ترین ابتدا تعداد نرون‌های لایه مخفی برابر ۲ انتخاب شد. سپس با استفاده از روش سعی و خطا تعداد نرون‌های لایه مخفی اضافه و مقادیر خطا محاسبه شد. این فرایند تا مرحله‌ای که مقدار خطا ثابت شد ادامه یافت. در شرایطی که مقدار خطا ثابت شد تعداد نرون‌های لایه مخفی مساوی ۱۰ بود.

#### ۴- بحث و نتیجه‌گیری

در این مطالعه برای بررسی دقت مدل‌های ماشین آموزش نیرومند از شاخص‌های آماری ضریب تبیین ( $R^2$ )، درصد میانگین نسبی خطا ( $MARE$ )، خطای جذر میانگین مربعات ( $RMSE$ ) و شاخص پراکندگی ( $SI$ ) به صورت زیر استفاده می‌شود:

شکل ۴. طرح کلی روش اعتبارسنجی چند لایه

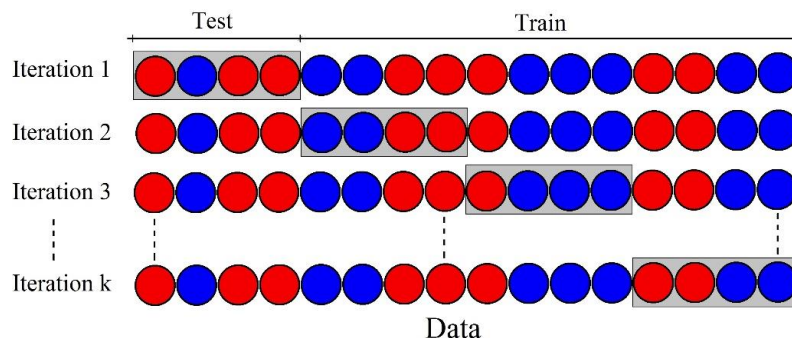


Fig. 4. Layout of multi-layer validation method

بنابراین در مطالعه حاضر تاثیر پارامترهای بدون بعد رابطه (۵) به عنوان پارامترهای ورودی مدل‌های ماشین آموزش نیرومند استفاده می‌شوند. در این مطالعه، برای انجام تحلیل حساسیت با استفاده از پارامترهای ورودی، شش مدل متمایز ماشین آموزش نیرومند تعریف شد. در شکل (۳) چگونگی ترکیب پارامترهای ورودی برای توسعه مدل‌های شش‌گانه ماشین آموزش نیرومند نشان داده شده است.

شکل ۳. چگونگی ترکیب پارامترهای ورودی برای توسعه مدل‌های شش-

گانه ماشین آموزش نیرومند




Fig. 3. Combination trend of input parameters for developing six ELM models

همچنین، در این مقاله برای ارزیابی توانایی مدل‌های ماشین آموزش نیرومند از شبیه‌سازی مونت کارلو استفاده می‌شود. شبیه‌سازی مونت کارلو یک طبقه‌بندی گسترده از الگوریتم‌های محاسباتی است که از نمونه‌گیری تصادفی برای محاسبه نتایج شبیه‌سازی استفاده می‌کند. ایده اصلی این روش بر اساس استفاده از تصمیم‌گیری تصادفی مسائلی که ممکن است در اصل قطعی باشند را حل می‌کند. روش مونت-کارلو معمولاً برای شبیه‌سازی سیستم‌های فیزیکی و ریاضیاتی که اغلب حل آنها با استفاده از روش‌های دیگر مقدور نیست استفاده می‌شود. شبیه‌سازی مونت کارلو به طور کلی به وسیله توزیع احتمالی برای حل مسائل مختلف از قبیل بهینه‌سازی و انتگرال‌گیری عددی استفاده می‌شود [12]. علاوه بر این، از روش اعتبارسنجی

$$R^2 = \frac{\left( n \sum_{i=1}^n R_{(Predicted)_i} R_{(Observed)_i} - \sum_{i=1}^n R_{(Predicted)_i} \sum_{i=1}^n R_{(Observed)_i} \right)^2}{\left( n \sum_{i=1}^n (R_{(Predicted)_i})^2 - \sum_{i=1}^n (R_{(Predicted)_i}) \right) \left( n \sum_{i=1}^n (R_{(Observed)_i})^2 - \sum_{i=1}^n (R_{(Observed)_i}) \right)} \quad (6)$$

نیرومند با چهار پارامتر ورودی، مدل ELM3 دارای بیشترین دقت و کمترین مقدار خطا است. این مدل مقادیر آبستگي را بر حسب  $q/\sqrt{qd_w^3}, H/d_w, R/d_w, \phi$  پیش‌بینی کرده است و تاثیر پارامتر  $d_{50}/d_w$  نادیده گرفته شده است. برای ELM3 مقادیر  $R^2$  و  $SI$  به ترتیب مساوی ۰/۹۹۲ و ۰/۰۷۲ محاسبه شده است. لازم به ذکر است که درصد میانگین مطلق خطا و خطای جذر میانگین مربعات برای این مدل نیز به ترتیب مساوی ۱۲/۳۴۳ و ۰/۲۴۵ بدست آمده است. برای شبیه‌سازی مقادیر عمق حفرهای آبستگي توسط مدل ELM4 تاثیر  $R/d_w$  نادیده گرفته شده و این مدل تابعی از پارامترهای بدون بعد  $q/\sqrt{qd_w^3}, H/d_w, d_{50}/d_w, \phi$  برای این مدل مقادیر شاخص‌های  $MAPE$  و  $RMSE$  به ترتیب برابر ۱۰/۳۸۲ و ۰/۳۹۲ محاسبه شده است.

$$MARE = \frac{1}{n} \sum_{i=1}^n \left| \frac{R_{(Predicted)_i} - R_{(Observed)_i}}{R_{(Observed)_i}} \right| \quad (7)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{(Predicted)_i} - R_{(Observed)_i})^2} \quad (8)$$


$$SI = \frac{RMSE}{\overline{(R)}_{(Observed)}} \quad (9)$$

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

لازم به ذکر است که نتایج شاخص‌های آماری مختلف در قالب شکل (۵) نشان داده شده است. علاوه بر این نمودارهای پراکندگی برای مدل‌های ELM مختلف در شکل (۶) به تصویر کشیده شده است. در این مطالعه مدل ELM 1 مقادیر آبستگي را بر حسب کلیه پارامترهای ورودی شبیه‌سازی می‌کند. برای این مدل مقادیر ضریب تبیین و شاخص پراکندگی به ترتیب مساوی ۰/۹۹۳ و ۰/۰۷۱ بدست آمده است. همچنین مقادیر درصد میانگین مطلق خطا و خطای جذر میانگین مربعات برای ELM1 به ترتیب برابر ۸/۸۹۱ و ۰/۲۴۰ تخمین زده شده است. در میان کلیه مدل‌های مختلف، ELM1 دارای بالاترین همبستگی با مقادیر آزمایشگاهی و کمترین مقدار خطا است.

در ادامه پنج مدل ماشین آموزش نیرومند با چهار پارامتر ورودی توسعه داده شده‌اند. به‌عنوان نمونه مدل ELM2 مقادیر تابع هدف را بر حسب  $q/\sqrt{qd_w^3}, H/d_w, R/d_w, d_{50}/d_w$  شبیه‌سازی می‌کند. به بیان دیگر در این مدل تاثیر زاویه لبه باکت ( $\phi$ ) حذف شده است. برای مدل مذکور مقدار شاخص‌های آماری  $R^2$ ،  $MAPE$  و  $RMSE$  به ترتیب مساوی ۰/۹۹۲، ۱۰/۴۹۰ و ۰/۲۵۶ محاسبه شدند. همچنین برای این مدل مقدار  $SI$  برابر ۰/۰۷۶ است. در میان کلیه مدل‌های ماشین آموزش

شکل ۵. نتایج شاخص‌های آماری مختلف برای مدل‌های شش‌گانه ELM




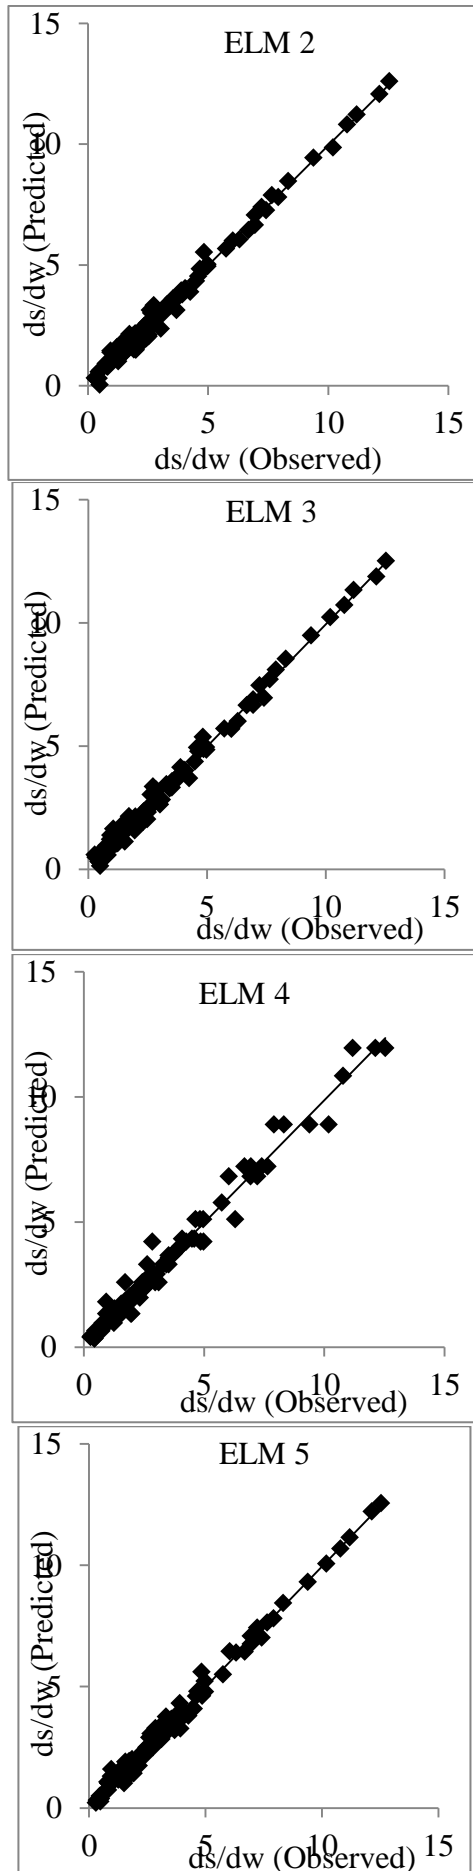
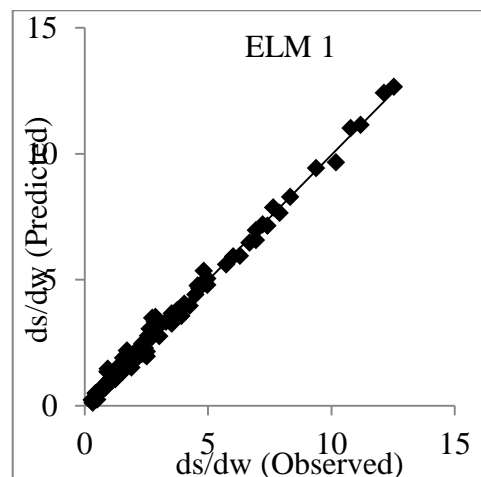


Fig. 5. Results of different statistical indices for six ELM models

همچنین شاخص پراکندگی و ضریب تبیین برای ELM 4 به ترتیب برابر ۰/۱۱۶ و ۰/۹۸۰ تخمین زده شده است. در ادامه به ارزیابی دقت شکل (۵) پرداخته می شود. برای این مدل مقادیر شاخص های آماری  $RMSE$ ،  $MAPE$  و  $SI$  به ترتیب مساوی ۰/۲۵۲، ۹/۷۵۲ و ۰/۰۷۴ محاسبه شده است. مدل مذکور مقادیر آبخستگی ها را بر حسب  $\phi$ ،  $d_{50}/d_w$ ،  $R/d_w$ ،  $q/\sqrt{qd_w^3}$  مدل سازی می کند. به عبارت دیگر برای ELM 5 تاثیر  $H/d_w$  حذف شده است. مقدار ضریب تبیین برای مدل ELM 5 مساوی ۰/۹۹۲ بدست آمده است. لازم به ذکر است که در میان کلیه مدل های ماشین آموزش نیرومند، شکل (۶) دارای کمترین دقت و بیشترین مقدار خطا است. به عنوان نمونه مقادیر  $R^2$  و  $SI$  برای ELM 6 به ترتیب ۰/۸۲۹ و ۰/۳۳۸ محاسبه شده است. برای مدل سازی آبخستگی توسط ELM 6 تاثیر  $q/\sqrt{qd_w^3}$  نادیده گرفته شده است. این مدل تابعی از  $\phi$ ،  $d_{50}/d_w$ ،  $R/d_w$ ،  $H/d_w$  می باشد. برای این مدل شاخص های آماری  $MAPE$  و  $RMSE$  به ترتیب ۳۱/۴۳۲ و ۱/۱۴۶ محاسبه شده است.

شکل ۶. نمودارهای پراکندگی مدل های مختلف ماشین آموزش نیرومند



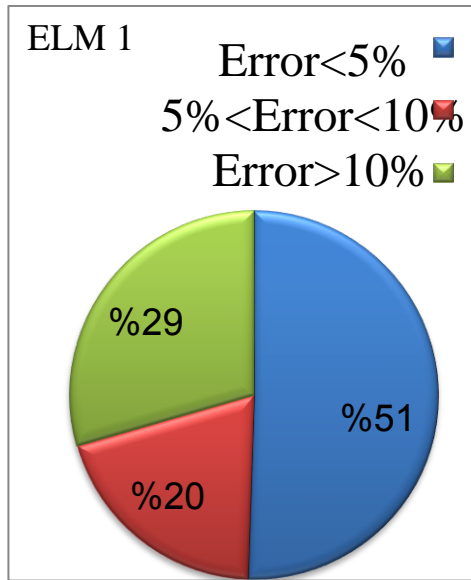


Fig. 8. Error distribution for ELM 1

۴-۲- تحلیل عدم قطعیت

در این مطالعه به منظور بررسی دقت مدل برتر، تحلیل عدم قطعیت انجام می شود. به طور کلی تحلیل عدم قطعیت برای توصیف خطای پیش بینی شده توسط یک مدل اجرا می شود. مقدار خطای پیش بینی شده توسط مدل های هوش مصنوعی ( $e_j$ ) به صورت اختلاف بین مقادیر پیش بینی شده ( $P_j$ ) و مقادیر مشاهداتی ( $T_j$ ) معرفی می شود ( $e_j = P_j - T_j$ ). همچنین مقدار میانگین خطای پیش بینی شده به صورت استاندارد مقادیر خطای پیش بینی شده نیز به صورت  $\bar{e} = \sum_{j=1}^n e_j$  محاسبه می شود. در مقابل مقدار انحراف استاندارد  $S_e = \sqrt{\sum_{j=1}^n (e_j - \bar{e})^2 / n - 1}$  معرفی می شود. منفی بودن مقدار  $\bar{e}$  نشان دهنده عملکرد کمتر از مقدار واقعی<sup>۱</sup> بودن مدل است. این در حالی است که مثبت بودن  $\bar{e}$  به معنای عملکردی بیشتر از مقدار واقعی<sup>۲</sup> است. با استفاده از پارامترهای  $\bar{e}$  و  $S_e$  یک باند اطمینان در اطراف مقادیر پیش بینی از یک خطا توسط روش امتیاز ویلسون<sup>۳</sup> بدون تصحیح پیوسته<sup>۴</sup> تعریف می شود. در ادامه با استفاده از  $\pm 1.64 S_e$  به صورت تقریبی منجر به ۹۵ درصد باند اطمینان می گردد. با توجه به نتایج تحلیل عدم قطعیت، مقدار  $\bar{e}$  برای ELM1 برابر ۰/۰۰۹ بدست آمد.

1 Underestimate  
2 Overestimate  
3 Wilson score method  
4 continuity correction

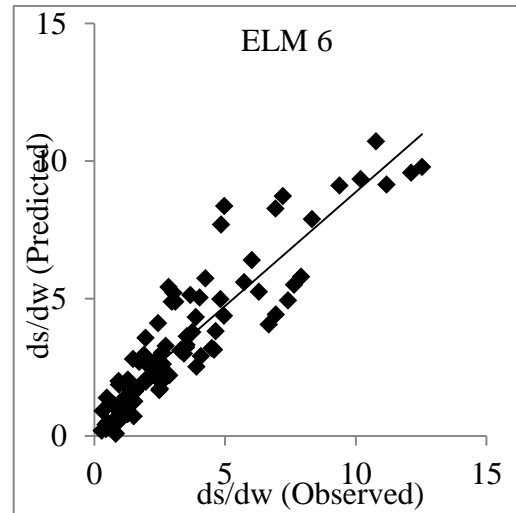


Fig. 6. Scatter graphs for extreme learning machine different models

بنابراین بر اساس تجزیه و تحلیل نتایج کلیه مدل های ماشین آموزش نیرومند، مدل شماره یک (ELM 1) به عنوان مدل برتر شناسایی می شود. همچنین با توجه به تحلیل حساسیت پارامترهای ورودی، پارامتر  $q / \sqrt{qd_w^3}$  موثرترین پارامتر ورودی معرفی شد.

۴-۱- مقایسه مدل برتر با سایر مدل های محاسبات نرم

در ادامه نتایج شاخص های آماری مدل برتر ELM با مدل های برتر توسعه داده شده توسط عضمت ا. و همکاران، (۲۰۰۸ و ۲۰۰۵)، گوپل (۲۰۰۸) و ایوبلو و همکاران (۲۰۱۱) در جدول (۲) مقایسه شده است. همان گونه که مشاهده می شود مدل ELM در مقایسه مدل های پیشنهادی از دقت بیشتری برخوردار است. به عنوان نمونه مقدار شاخص R برای مدل ELM 1، عضمت ا. و همکاران و گوپل به ترتیب مساوی با ۰/۹۹۶، ۰/۹۹۰ و ۰/۹۵۰ بدست آمده است.

جدول ۲. مقایسه شاخص های آماری ELM 1 با سایر مدل ها

RMSE	R	model
0.240	0.996	ELM 1
1.67	0.990	Azmathullah et al. (2005)
-	0.950	Azmathullah et al. (2008)
0.031	0.950	Goel (2008)
0.552	0.978	Ayoubloo et al. (2011)

Table 2. Comparison of statistical indices for ELM 1 and other models

شکل ۸. توزیع خطای مدل ELM 1



- [6] Kökpinar M. A. & Kucukali S. 2016 Effect of particle size on flip bucket scour. *Canadian Journal of Civil Engineering*, 43(8), 759-768.
- [7] Azmathullah H. M., Deo M. C. & Deolalikar P. B. 2005 Neural networks for estimation of scour downstream of a ski-jump bucket. *Journal of Hydraulic Engineering*, 131(10), 898-908.
- [8] Guven A. & Gunal M. 2008 Genetic programming approach for prediction of local scour downstream of hydraulic structures. *Journal of Irrigation and Drainage Engineering*, 134(2), 241-249.
- [9] Zadeh A. T. & Kashefipour S. M. 2008 Modeling local scour on loose bed downstream of grade-control structures using artificial neural network. *Journal of applied science*, 8(11), 2067-2074.
- [10] Samadi M., Jabbari E. & Azamathulla H. M. 2014 Assessment of M5' model tree and classification and regression trees for prediction of scour depth below free overfall spillways. *Neural Computing and applications*, 24(2), 357-366.
- [11] Huang G. B., Zhu Q. Y. & Siew C. K. 2006 Extreme Learning Machine: Theory and Applications. *Neurocomputing*, 70(1-3), 489-501.
- [12] Sattar A. M. & Gharabaghi B. 2015 Gene expression models for prediction of longitudinal dispersion coefficient in streams. *Journal of Hydrology*, 524, 587-596.
- [13] Azamathulla H. M., Deo M. C. & Deolalikar P. B. 2008 Alternative neural networks to estimate the scour below spillways. *Advances in Engineering Software*, 39(8), 689-698.
- [14] Goel A. 2008 Estimation of scour downstream of spillways using SVM modeling. In *Proceedings of the World Congress on Engineering and Computer Science WCECS*, 22-24.
- [15] Ayoubloo M. K., Azamathulla H. M., Ahmad Z., Ghani A. A., Mahjoobi J. & Rasekh A. 2011 Prediction of scour depth in downstream of ski-jump spillways using soft computing techniques. *International Journal of Computers and Applications*, 33(1), 92-97.

علاوه بر این، مقدار ۹۵ درصد فاصله خطای پیش‌بینی برای ELM 1 بین ۰/۰۴۱- و ۰/۰۵۸+ بود. بر اساس نتایج تحلیل عدم قطعیت، مدل ELM1 دارای عملکردی بیشتر از مقدار واقعی هستند.

## ۵- نتیجه‌گیری

در مطالعه حاضر عمق آبستگي بعد از باکت جامی شکل به وسیله مدل بسیار جدید ماشین آموزش نیرومند تخمین زده شد. همچنین برای اعتبار سنجی نتایج مدل‌های هوش مصنوعی از روش اعتبار سنجی چند لایه استفاده شد. با توجه به پارامترهای ورودی، شش مدل ماشین آموزش نیرومند تعریف شد و با تجزیه و تحلیل مدل‌های مذکور مدل برتر برای پیش‌بینی عمق آبستگي معرفی شد. این مدل مقادیر آبستگي را بر حسب کلیه پارامترهای ورودی پیش‌بینی کرد. لازم به ذکر است که دقت مدل برتر بسیار مناسب بود به گونه‌ای که مقادیر درصد میانگین مطلق خطا و خطای جذر میانگین مربعات برای آن به ترتیب برابر ۸/۸۹۱ و ۰/۲۴۰ محاسبه شد. علاوه بر این مقدار ضریب اختلاف متوسط برای مدل برتر برابر ۰/۹۹۱ بدست آمد. سپس به منظور بدست آوردن پارامتر موثر از روش تحلیل حساسیت استفاده شد بدین گونه که تاثیر هر یک از پارامترهای ورودی حذف و مدل‌سازی انجام شد. بعد از انجام تحلیل حساسیت، پارامتر بدون بعد دبی بر واحد عرض  $\left( q / \sqrt{qd^3_w} \right)$  به عنوان موثرترین پارامتر ورودی شناسایی شد.

## References

## ۶- منابع

- [1] Bormann N. E. & Julien P. Y. 1991 Scour downstream of grade-control structures. *Journal of Hydraulic Engineering*, 117(5), 579-594.
- [2] Juon R. & Hager W. H. 2000 Flip Bucket Without and with Deflectors, *Journal of Hydraulic Engineering*, 126(11), 837-845.
- [3] Canepa S. & Hager W. H. 2003 Effect of jet air content on plunge pool scour. *Journal of Hydraulic Engineering*, 129(5), 358-365.
- [4] Dargahi B. 2003 Scour development downstream of a spillway. *Journal of hydraulic research*, 41(4), 417-426.
- [5] Azmathullah H. M., Deo M. C., Bhajantri M. R. & Deolalikar P. B. 2004 Scour at the base of flip-bucket spillways. *ISH Journal of Hydraulic Engineering*, 10(2), 121-129.

# Prediction the Scour Depth at Downstream of Bucket Spillway Using the Extreme Learning Machine and K-Fold Cross Validation

Mohammad Moein Fallahi<sup>1</sup>, Ahmad Rajabi<sup>2\*</sup>, Behrouz Yaghoubi<sup>3</sup>

1. Ph.D. Student of Water Resources, Water Engineering Department, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

2, 3. Assistant Professor of Water Resources, Water Engineering Department, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

## Abstract

The ogee spillways are constructed to regulate the flow in reservoir of dams. When the excess waters overflow the ogee spillway, the velocity at toe of spillway is pretty high and the flow has a huge amount of energy. The bucket spillway is used in order to reduce the amount of such energy. Next, the trajectory flow combines with air and the flow loses its energy significantly. If the materials at downstream of spillway are erodible, the probability of the scour exist; as a result, the stability of spillway endangers. Therefore, the prediction of scour hole depth in this area is quite significant. In this study, the depth of scour at downstream of the bucket spillway simulated using the Extreme Learning Machine (ELM) model. One of the most popular methods based on the artificial intelligence is the feed-forward neural network (FFNN). The training speed of this algorithm is very low. It's due to the use of the gradient based algorithms such as the back propagation (BP) which has low speed and the adjustment of the parameters related to the network is iterative. The extreme learning machine (ELM) is a Single Layer Feed-Forward Neural Network (SLFFNN) which selects the number of nodes randomly and determines the output weights analytically. This algorithm is much faster than conventional neural networks and has a good generalization performance. The use of this method has had a good performance in different fields and its comparison with FFNN-BP has showed that this method in addition to reduce high computational costs has a higher accuracy. In current study, to evaluate the performance of ELM models, the Monte Carlo simulation (MCs) is applied. Monte Carlo simulation is a broad class of computational algorithms that rely on repeated random sampling to obtain numerical results. Their essential idea is using randomness to solve problems that might be deterministic in principle. They are often used in physical and mathematical problems and are most useful when it is difficult or impossible to use other approaches. Monte Carlo simulation is mainly used in different problems such as optimization and numerical integration from a probability distribution. Also in this study, the k-fold Cross Validation (k-fold) is used for evaluating the models ability. In k-fold cross validation method, the original sample is randomly partitioned into k equal sized subsamples. In the k subsamples, a single subsample is retained as the validation data for testing the specific model, and the remaining k-1 subsamples are used as training data. The cross-validation process is then repeated k times (the folds), with each of the k subsamples used exactly once as the validation data. The k results from the folds can then be averaged to produce a single estimation. The advantage of this method over repeated random sub-sampling is that all observations are used for both training and validation, and each observation is used for validation exactly once. The k value was considered 5 in this study. In this study, to validate the results of numerical models, the Azmathullah et al. (2005) experimental measurements were used. They measured the scour depth at the downstream of bucket spillway. Next, the effective parameters on scour depth were identified and six ELM models defined. In other words, one model simulated the scour depth with combination of five input parameters including the discharge dimensionless parameter, the ratio of the total head to the tailwater depth ( $H/d_w$ ), the ratio of the bucket radius to the tailwater depth ( $R/d_w$ ), the ratio of the mean sediment size to the tailwater depth ( $d_{50}/d_w$ ) and lip angle of bucket, and five models predicted the output variable using four input parameters. In addition, the sensitivity analysis was carried out in order to identify the effective factor. This sensitivity analysis showed that the discharge dimensionless parameter was the most effective factor. Also, the superior model was introduced by analyzing the results of all models. This model had reasonable accuracy and was the function of all input parameters. For example, the determination coefficient and scatter index were obtained 0.993 and 0.071, respectively. Also, The RMSE and MAPE for this model were obtained 0.240 and 8.891, respectively. Additionally, the maximum, minimum and average discrepancy ratios for the superior model were respectively calculated 1.567, 0.360 and 0.991.

**Keywords:** Scour depth, Bucket spillway, Modeling, Extreme Learning Machine, k-fold Cross Validation