



شاپا چاپی: ۲۴۸۰-۲۲۵۱

شاپا الکترونیکی: ۷۴۰۰-۲۲۵۰

نشریه حفاظت منابع آب و خاک

آدرس تارنما:

<https://wsrj.srbiau.ac.ir>

پست الکترونیک:

iauwsrj@srbiau.ac.ir

iauwsrj@gmail.com

سال یازدهم

شماره سه

بهار ۱۴۰۱

تاریخ دریافت:

۱۳۹۹/۰۷/۰۷

تاریخ پذیرش:

۱۴۰۱/۰۹/۲۷

صفحات: ۱۷-۳۰



تحلیل حساسیت پارامترهای مؤثر بر عمق آبشستگی در پائین دست پایه‌های پل جفت با استفاده از ماشین آموزش نیرومند

سیامک امیری^۱، محمد علی ایزدبخش^{۲*} و سعید شعبانلو^۳

(۱) دانشجوی دکتری منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه ایران.

(۲) استادیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه ایران.

(۳) دانشیار، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه ایران.

* ایمیل نویسنده مسئول: izadbakhsh.mohammad.ali@gmail.com

چکیده:

زمینه و هدف: آبشستگی موضعی به‌عنوان یکی از عوامل مهم که باعث گسیختگی سازه پل‌ها، موج‌شکن‌ها و اسکله‌ها می‌شود شناسایی شده است. پیچیدگی مکانیزم آبشستگی باعث شده است که این موضوع یکی از مهم‌ترین زمینه‌های مطالعاتی مهندسی عمران باشد. در سال‌های اخیر، مطالعات فراوانی بر روی آبشستگی موضعی اطراف پایه‌های پل انجام گرفته است. به دلیل اهمیت زیاد پیش‌بینی و تخمین الگوی آبشستگی در مجاورت پایه‌های پل مطالعات فراوانی بر روی این نوع از سازه‌ها انجام شده است.

روش پژوهش: در این مطالعه برای اولین بار با استفاده از روش جدید ماشین آموزش نیرومند (ELM)، عمق آبشستگی در مجاورت پایه‌های پل دوقلو شبیه‌سازی شد. ابتدا پارامترهای مؤثر شناسایی گردید و چهار مدل ELM توسعه داده شد. سپس به کمک شبیه‌سازی مونت کارلو و روش اعتبار سنجی ضربدری نتایج عددی اعتبار سنجی شدند. در ادامه تابع فعال‌سازی \sin به‌عنوان بهترین تابع فعال‌سازی تعیین شد. علاوه بر این نتایج ELM با مدل‌های شبکه عصبی مصنوعی مقایسه گردید که مدل‌های ELM مقادیر آبشستگی را با دقت بیشتری تخمین زدند. تحلیل عدم قطعیت برای مدل‌های برتر ELM و ANN اجرا گردید و برای مدل برتر یک رابطه پیشنهاد داده شد. برای کلیه پارامترهای ورودی تحلیل حساسیت مشتق نسبی (PDSA) نیز اجرا گردید.

یافته‌ها: در میان توابع فعال‌سازی موجود، تابع \sin دارای عملکردی بهینه در مقایسه با سایر توابع فعال‌سازی بود. با توجه به تجزیه و تحلیل نتایج مدل‌سازی، مدل ELM 1 به‌عنوان مدل برتر معرفی شد. این مدل تابعی از کلیه پارامترهای ورودی بود. همچنین با حذف عدد فرود دقت مدل عددی به شکل قابل ملاحظه‌ای کاهش یافت فلذا پارامتر مذکور نیز به‌عنوان مؤثرترین پارامتر در مدل‌سازی آبشستگی در اطراف پایه‌های پل دوقلو توسط مدل ماشین آموزش نیرومند شناسایی شد.

نتایج: با تجزیه و تحلیل نتایج مدل‌سازی، مدل برتر ELM معرفی گردید. نتایج مدل‌های ELM با مدل‌های ANN نیز مقایسه شد که نشان داده شد مدل‌های ELM مقادیر آبشستگی را با دقت بیشتری شبیه‌سازی می‌کنند. برای مدل برتر ELM یک رابطه برای محاسبه عمق حفره آبشستگی پیشنهاد داده شد و در ادامه تحلیل عدم قطعیت نشان داد که این مدل دارای عملکردی بیشتر از مقدار واقعی بود. علاوه بر این تحلیل حساسیت مشتق نسبی برای پارامترهای ورودی نشان داد که با افزایش عدد فرود مقدار تابع هدف (عمق آبشستگی) افزایش می‌یابد.

کلیدواژه‌ها: ماشین آموزش نیرومند، تحلیل حساسیت مشتق نسبی، عمق آبشستگی، پایه‌های پل جفت، تحلیل عدم قطعیت

مقدمه

برتری مدل برنامه‌نویسی بیان ژن است. این نویسندگان یک معادله برای تخمین مقادیر آبستتگی پیشنهاد دادند و بیان کردند که رابطه پیشنهادی را می‌توان در کاربردهای عملی استفاده کرد (Azamathulla, 2012). همچنین شریفی و همکاران با استفاده از ماشین بردار پشتیبان آبستتگی موضعی در مجاورت پایه‌های پل را مدل‌سازی کردند. آنها عملکرد ماشین بردار پشتیبان را با سایر الگوریتم‌های هوش مصنوعی و روابط تجربی مقایسه و نشان دادند که این مدل توانایی خوبی در شبیه‌سازی عمق آبستتگی‌ها در مجاورت پایه‌های پل از خود نشان داد (Sharafi et al., 2016). عظیمی و همکاران مدل ANFIS را برای پیش‌بینی آبستتگی در مجاورت گروه پایه‌های پل در شرایط آب صاف بهینه‌سازی نمودند. آنها برای بهینه‌سازی شبکه انفیس از الگوریتم تکامل تفاضلی (DE) و تجزیه مقادیر منفرد (SVD) استفاده نمودند و یک مدل نرو- فازی ترکیبی تحت عنوان ANFIS-DE/SVD برای شبیه‌سازی مقادیر آبستتگی‌ها توسعه دادند. آنها عملکرد الگوریتم ژنتیک را نیز مورد بررسی قرار دادند که مقایسه آن با الگوریتم تکامل تفاضلی نشان دهنده عملکرد بهتر الگوریتم DE بود (Azimi et al., 2016). علاوه بر این، ابتهاج و همکاران عمق آبستتگی در اطراف پایه‌های پل را با استفاده از ماشین آموزش نیرومند خود تطبیقی تخمین زدند. آنها عملکرد ماشین آموزش نیرومند خود تطبیقی را با شبکه عصبی مصنوعی و ماشین بردار پشتیبان مقایسه کردند و نشان دادند که این مدل ماشین یادگیری توانایی خوبی جهت مدل‌سازی آبستتگی‌ها از خود نشان داد (Ebtehaj et al., 2017). همچنین، ابتهاج و همکاران با استفاده از ماشین آموزش نیرومند، شبکه عصبی مصنوعی و ماشین بردار پشتیبان، مقادیر آبستتگی در مجاورت پایه‌های پل گروهی شبیه‌سازی کردند. آنها نشان دادند که ماشین آموزش نیرومند ابزار کارآمدی جهت شبیه‌سازی مقادیر آبستتگی‌ها بود. این نویسندگان عملکرد ماشین آموزش نیرومند را با مدل‌های رگرسیونی تجربی نیز مقایسه کردند و بیان کردند که دقت ماشین بردار نیرومند

آبستتگی موضعی به‌عنوان یکی از عوامل مهم که باعث گسیختگی سازه پل‌ها، موج‌شکن‌ها و اسکله‌ها می‌شود شناسایی شده است. پیچیدگی مکانیزم آبستتگی باعث شده است که این موضوع یکی از مهم‌ترین زمینه‌های مطالعاتی مهندسی عمران باشد. در سال‌های اخیر، مطالعات فراوانی بر روی آبستتگی موضعی اطراف پایه‌های پل انجام گرفته است. به دلیل اهمیت زیاد پیش‌بینی و تخمین الگوی آبستتگی در مجاورت پایه‌های پل مطالعات فراوانی بر روی این نوع از سازه‌ها انجام شده است. به‌عنوان مثال در سال‌های اخیر استفاده از محاسبات نرم برای پیش‌بینی مسائل پیچیده و غیرخطی به شکل قابل ملاحظه‌ای گسترش یافته است. از طرف دیگر مطالعات مختلفی نیز جهت پیش‌بینی الگوی آبستتگی در اطراف پل‌ها انجام گرفته است. ترنت و همکاران الگوی آبستتگی در اطراف پایه‌های پل را در شرایط هیدرولیکی آب شفاف و بستر متحرک با استفاده از شبکه عصبی مصنوعی مدل‌سازی نمودند. در این مطالعه نشان داده شد که شبکه عصبی مصنوعی مقادیر آبستتگی‌ها را با همبستگی مناسب و دقت قابل قبول تخمین زد (Trent et al., 1993). لیریانو و دی توسط مدل‌های شبکه عصبی مصنوعی عمق آبستتگی در خروجی کالورت‌ها را مدل‌سازی نمودند. آنها برای تخمین آبستتگی دو مدل مختلف ارائه نمودند و نشان دادند مدل‌های شبکه عصبی آنها مقادیر آبستتگی را با دقت مناسبی تخمین زد (Liriano and Day, 2001). آبستتگی پایه‌های پل دایروی شکل با استفاده از الگوریتم‌های مختلف شبکه عصبی توسط فیرات و گانگور مدل‌سازی گردید. این نویسندگان نشان دادند که شبکه عصبی مذکور مقادیر تابع هدف را با دقت قابل قبولی تخمین زد (Firat and Gungor, 2009). عظمت اله عمق آبستتگی در اطراف تکیه‌گاه جانبی پایه پل با شکل مختلف را با استفاده از مدل‌های برنامه‌نویسی بیان ژن و شبکه عصبی مصنوعی مدل‌سازی کرد که بررسی نتایج شبیه‌سازی نشان دهنده

مواد و روش‌ها

ماشین آموزش نیرومند (ELM) Extreme Learning Machine

یک الگوریتم یادگیری جدید با الگو از ساختار شبکه عصبی پیشخور تک لایه تحت عنوان ماشین آموزش نیرومند ارائه شده است (Huang et al., 2004). در این مدل، پارامترهای گره پنهان به صورت تصادفی انتخاب شده و وزن‌های خروجی به صورت تحلیل با استفاده از ماتریس معکوس تعمیم یافته مور-پنوس تعیین می‌شوند (Yua et al., 2015). روش ELM از مشکلات بسیاری همچون معیار توقف، نرخ یادگیری و دوره‌های یادگیری که مبتنی بر روش‌های یادگیری هستند و به وسیله روش‌های بر پایه گرادینان ایجاد می‌گردند، جلوگیری می‌کند.

فرض کنید که N نمونه دلخواه در مرحله آموزش به صورت $(x_i, y_i) \in R^n R^m (i = 1, 2, 3, \dots, m)$ با تعداد L گره پنهان وجود دارد. بنابراین، مدل SLFFNN با تابع انتقال $f(x)$ ، می‌تواند به صورت زیر بیان شود:

(۱)

$$\sum_{i=1}^L \beta_i f_i(x_j) = \sum_{i=1}^L \beta_i f_i(a_i \cdot b_i \cdot x),$$

$$j = 1, 2, 3, \dots, N$$

که در آن $a_i = [a_{i1}, a_{i2}, a_{i3}, \dots, a_{im}]^T$ بردار وزن ورودی متصل به گره لایه پنهان، b_i مقدار بایاس گره‌های لایه پنهان، $\beta_i = [\beta_{i1}, \beta_{i2}, \beta_{i3}, \dots, \beta_{im}]^T$ بردار وزن خروجی متصل به گره لایه پنهان می‌باشند. معادله فوق را می‌توان به شکل زیر بازنویسی کرد:

$$\sum_{i=1}^L \beta_i f_i(x_j) = H\beta \quad (۲)$$

(۳)

$$H = \begin{bmatrix} f(a_1 \cdot x_1 \cdot b_1) & \dots & f(a_L \cdot x_1 \cdot b_L) \\ \vdots & \ddots & \vdots \\ f(a_1 \cdot x_N \cdot b_1) & \dots & f(a_L \cdot x_N \cdot b_L) \end{bmatrix}_{N \times L}$$


(۴)

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}$$

به مراتب از مدل‌های رگرسیونی بهتر بود (Ebtehaj et al., 2018). عظیمی و همکاران شبکه انفیس را با استفاده از الگوریتم ژنتیک و تجزیه مقادیر منفرد بهینه‌سازی نمودند و با استفاده از این مدل بهینه مقادیر آبخستگی‌ها در اطراف تکیه‌گاه پل‌ها را شبیه‌سازی نمودند. آنها نشان دادند که عدد فرود و نسبت عمق جریان به ابعاد حفره آبخستگی مهم‌ترین پارامترهای ورودی جهت شبیه‌سازی پارامتر هدف بودند (Azimi et al., 2019).

بنکداری و همکاران آبخستگی در مجاورت تکیه‌گاه پایه‌های پل با اشکال مختلف را توسط ماشین آموزش نیرومند تخمین زدند. این نویسندگان معادله‌ای را برای محاسبه عمق آبخستگی در اطراف تکیه‌گاه‌های پل پیشنهاد دادند و عملکرد این مدل را با سایر مدل‌های هوش مصنوعی و روابط تجربی نیز مقایسه کردند و نشان دادند که ماشین آموزش نیرومند عملکرد بهتری از خود نشان داد (Bonakdari et al., 2020).

در این مطالعه برای اولین بار با استفاده از روش جدید ماشین آموزش نیرومند (ELM)، عمق آبخستگی در مجاورت پایه‌های پل دوقلو شبیه‌سازی شد. ابتدا پارامترهای مؤثر شناسایی گردید و چهار مدل ELM توسعه داده شد. سپس به کمک شبیه‌سازی مونت کارلو و روش اعتبار سنجی ضربدری نتایج عددی اعتبار سنجی شدند. در ادامه تابع فعال‌سازی \sin به عنوان بهترین تابع فعال‌سازی تعیین شد. علاوه بر این نتایج ELM با مدل‌های شبکه عصبی مصنوعی مقایسه گردید که مدل‌های ELM مقادیر آبخستگی را با دقت بیشتری تخمین زدند. تحلیل عدم قطعیت برای مدل‌های برتر ELM و ANN اجرا گردید و برای مدل برتر یک رابطه پیشنهاد داده شد. برای کلیه پارامترهای ورودی تحلیل حساسیت مشتق نسبی (PDSA) نیز اجرا گردید.



شکل ۱. ساختار ماشین آموزش نیرومند
(Azimi et al., 2017)

توابع فعالیت غیرخطی ELM که در این مطالعه مورد بررسی قرار گرفته است شامل تابع پله‌ای (hardlim)، سیگموئید (sig)، سینوسی (sin)، بایاس مثلثی (tribas) و بایاس شعاعی (radbas) است. اثر هر یک از این توابع مورد بررسی قرار می‌گیرد و بهترین آن، جهت مقایسه با مدل‌های دیگر، مورد استفاده قرار می‌گیرد.

مدل آزمایشگاهی

در این تحقیق برای صحت سنجی نتایج مدل‌های ماشین آموزش نیرومند از مقادیر آزمایشگاهی وانگ و همکاران استفاده می‌شود. مدل آزمایشگاهی آنها شامل یک کانال مستطیلی به طول، عرض و ارتفاع ۱۲، ۰/۴۲ و ۰/۷ متر می‌باشد. آنها با نصب دو پایه پل به قطر ۶ سانتیمتر مقدار آبشستگی در اطراف آنها را گزارش نمودند. لازم به ذکر است که عمق اولیه لایه رسوب در این مطالعه آزمایشگاهی ۱۵ سانتیمتر و طول آن ۶ متر است و پایه‌های جفت با فاصله d در وسط لایه رسوبات واقع شده است. آنها ۱۴۱ مورد آزمایش را شامل شدت جریان (دبی)، عمق جریان، سرعت جریان، عمق آبشستگی، حداکثر عمق آبشستگی، قطر پایه پل‌ها و فاصله بین پایه‌ها گزارش کردند. در شکل ۲ طرح کلی مدل آزمایشگاهی به تصویر کشیده شده است (Wang et al., 2016).

(۵)

$$y = \begin{bmatrix} y_1^T \\ \vdots \\ y_L^T \end{bmatrix}_{N \times m}$$

در این معادلات J ماتریس خروجی لایه پنهان، β ماتریس خروجی وزن و T ماتریس برچسب (Label matrix) است. در این مدل، اولین مرحله تعیین مقادیر تصادفی وزن‌های ورودی α و بایاس گره لایه پنهان b در مرحله آموزش است. پس از تعیین این وزن‌ها و بایاس‌ها، ماتریس خروجی لایه پنهان می‌تواند از نمونه‌های ورودی به دست آید. بنابراین، آموزش SLFFNN به حل حداقل مربعات تبدیل می‌شود. پس از تعیین وزن‌های ورودی و بایاس‌های لایه پنهان، ماتریس خروجی لایه پنهان می‌تواند از نمونه‌های آموزش به دست آید. بنابراین، آموزش SLFFNN به حل حداقل مربعات تبدیل می‌شود. با معرفی تئوری ساماندهی (regularization) برای تبدیل ELM، تابع هدف به صورت زیر بیان می‌شود:

(۶)

$$\min L_{ELM} = \frac{1}{2} \|\beta\|^2 + \frac{c}{2} \|T - H\beta\|^2$$

حل حداقل مربعات معادله فوق، به صورت زیر می‌باشد:

$$V - CH^T(T - H\beta) = 0 \quad (7)$$

وقتی که تعداد نمونه‌های مرحله آموزش بیشتر از تعداد گره‌های لایه پنهان باشد، داریم:


(۸)

$$\beta = \left(\frac{1}{c} + H^T H \right)^{-1} H^T T$$


وقتی که تعداد نمونه‌های مرحله آموزش کمتر از تعداد گره‌های لایه پنهان باشد، داریم:

$$\beta = H^T \left(\frac{1}{c} + H H^T \right)^{-1} T \quad (9)$$

زمانی که تعداد نرون‌های گره پنهان به حد کافی بزرگ باشد، دقت رگرسیون این الگوریتم همیشه ثابت خواهد بود شکل 1، ساختار ELM را نشان می‌دهد.



شکل ۲. مدل آزمایشگاهی مورد مطالعه
(Wang et al., 2016)



شکل ۳. نحوه ترکیب پارامترهای مؤثر در مدل‌های عددی مختلف

در مطالعه حاضر به منظور بررسی توانایی مدل‌های عددی از شبیه‌سازی‌های مونت کارلو استفاده می‌شود. ایده اصلی روش شبیه‌سازی مونت کارلو بر 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 ریاضی که اغلب حل آنها با استفاده از روش‌های دیگر مقدور نیست استفاده می‌گردد. شبیه‌سازی مونت کارلو به‌طور کلی به‌وسیله توزیع احتمالی برای حل مسائل مختلف از قبیل بهینه‌سازی و انتگرال‌گیری عددی استفاده می‌شود. علاوه بر این از روش اعتبار سنجی چند لایه‌ای برای بررسی عملکرد مدل‌های مذکور بهره گرفته می‌شود.

آبخستگی در اطراف پایه پل‌ها

عمق آبخستگی در مجاورت گروه پایه‌های پل (d_s) تابعی از U_c و U ، h ، S_n ، d ، m ، D ، m ، d_{50} که به ترتیب برابر عمق آبخستگی، قطر متوسط ذرات رسوب، تعداد پایه‌های پل موازی با جهت جریان، قطر پایه‌های پل، فاصله مرکز به مرکز پایه‌های پل در جهت موازی با جریان، فاصله مرکز به مرکز پایه‌های پل در جهت عمود بر جریان، عمق جریان، سرعت متوسط جریان و سرعت بحرانی به علت حرکت اولیه بر روی رسوبات است. وانگ و همکاران (۲۰۱۶) آبخستگی را در مجاورت دو پایه که به فاصله d از هم قرار دارند اندازه‌گیری نمودند (Wang et al., 2016). در مطالعه آنها مقادیر U_c و S_n تقریباً ثابت هستند. با در نظر گرفتن گروه‌های بدون بعد رابطه معادله ۱ به صورت زیر بازنویسی می‌شود:

$$d_s/h = f(D/h, d/h, Fr) \quad (10)$$

Fr عدد فرود می‌باشد؛ بنابراین پارامترهای معادله ۱۰ به‌عنوان پارامترهای ورودی مدل‌های ماشین آموزش نیرومند در این مطالعه در نظر گرفته شدند. در شکل ۳ نحوه ترکیب پارامترهای ورودی (معادله ۱۰) برای مدل‌های ماشین آموزش نیرومند نشان داده شده است. به‌عنوان مثال مدل شماره ۱ تابعی از کلیخ پارامترهای ورودی بود و تأثیر هر یک از ورودی‌ها در مدل‌های شماره ۲ تا ۴ حذف گردید.

در روش اعتبارسنجی چند لایه‌ای، نمونه اصلی است به‌طور تصادفی به k نمونه‌های فرعی به‌اندازه مساوی تقسیم شود. در بین نمونه‌های فرعی k ، یک نمونه فرعی به‌عنوان داده‌های اعتبارسنجی و باقی‌مانده آنها به‌عنوان داده‌های آزمون این مدل استفاده می‌شوند. سپس روند اعتبارسنجی چند لایه k بار تکرار می‌شود (برابر تعداد لایه‌ها)، هر کدام از نمونه‌های فرعی k دقیقاً یک‌بار به‌عنوان داده‌های اعتبارسنجی مورد استفاده قرار می‌گیرند. نتایج به‌دست آمده از k لایه‌ی مذکور متوسط‌گیری شده و به‌عنوان 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 (Azimi et al., 2019). همچنین طرح روش اعتبارسنجی چند لایه و نحوه برخورد با داده‌های آزمون و آموزش در شکل ۴ نشان داده است.

$$MAE = \frac{1}{n} \sum_{i=1}^n |(R)_{(Predicted)_i} - (R)_{(Observed)_i}| \quad (11)$$

$$MAPE = 100 \times \frac{1}{n} \sum_{i=1}^n \left(\frac{|R_{(Predicted)_i} - R_{(Observed)_i}|}{R_{(Predicted)_i}} \right) \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{(Predicted)_i} - R_{(Observed)_i})^2} \quad (13)$$

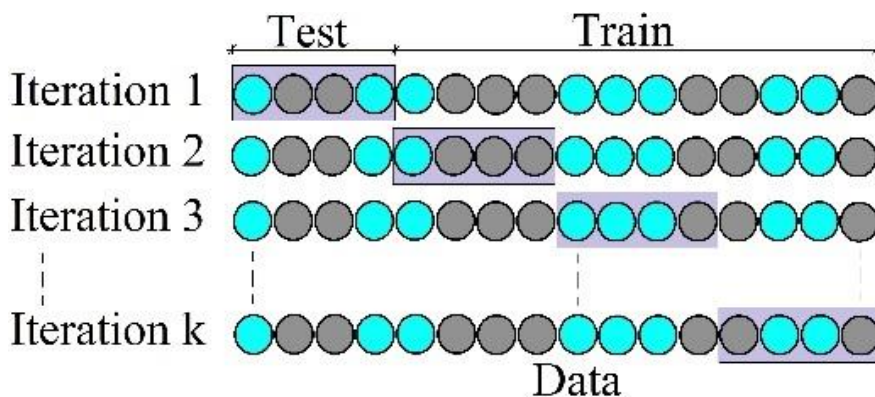
$$R^2 = \frac{\left(n \sum_{i=1}^n R_{(Predicted)_i} R_{(Observed)_i} - \sum_{i=1}^n R_{(Predicted)_i} \sum_{i=1}^n R_{(Observed)_i} \right)}{\left(n \sum_{i=1}^n (R_{(Predicted)_i})^2 - \sum_{i=1}^n (R_{(Predicted)_i}) \right)} \times \frac{\left(n \sum_{i=1}^n R_{(Predicted)_i} R_{(Observed)_i} - \sum_{i=1}^n R_{(Predicted)_i} \sum_{i=1}^n R_{(Observed)_i} \right)}{\left(n \sum_{i=1}^n (R_{(Observed)_i})^2 - \sum_{i=1}^n (R_{(Observed)_i}) \right)} \quad (14)$$

$$SI = \frac{RMSE}{(\bar{R})_{(Observed)}}$$

در این معادلات مقادیر $(R)_{(Predicted)_i}$ ، $(R)_{(Observed)_i}$ ، $(\bar{R})_{(Observed)_i}$ و n به‌ترتیب برابر مقادیر آزمایشگاهی، نتایج پیش‌بینی شده توسط مدل‌های عددی، میانگین مقادیر آزمایشگاهی و تعداد اندازه‌گیری‌های آزمایشگاهی هستند. در این مطالعه به‌منظور شناسایی مؤثرترین پارامتر ورودی، چهار مدل مختلف ترکیبی معرفی می‌شود.

معیارهای بررسی دقت مدل‌های عددی

در مطالعه حاضر به‌منظور ارزیابی دقت مدل‌های عددی از شاخص‌های آماری ضریب تبیین (R^2)، خطای جذر میانگین مربعات ($RMSE$)، درصد میانگین مطلق خطا ($MAPE$)، خطای مطلق میانگین (MAE) و شاخص پراکندگی (SI) به‌صورت زیر استفاده می‌شود:

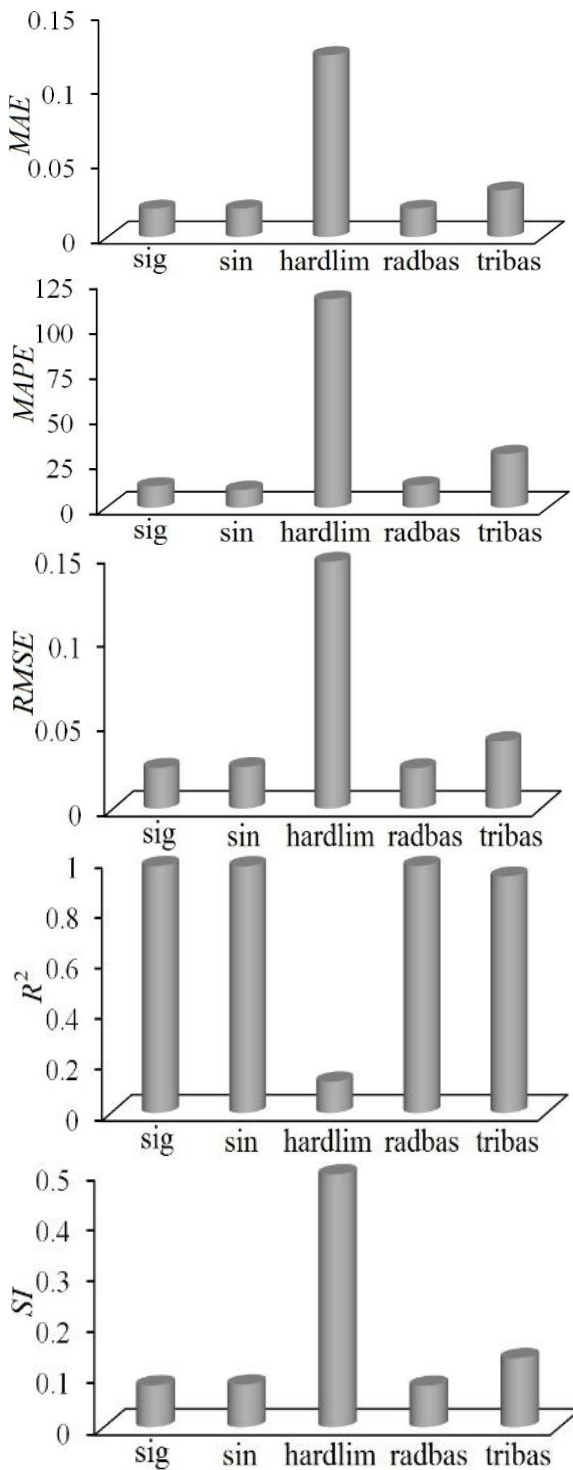


شکل ۴. نحوه برخورد روش اعتبارسنجی ضربدری با مقادیر مشاهداتی

توابع فعال‌سازی


در این قسمت به بررسی تابع فعال‌سازی بهینه جهت شبیه‌سازی آبخستگی در اطراف پایه‌های دوقلو پرداخته می‌شود. همان‌گونه که در بخش‌های قبل بیان شد، ماشین آموزش نیرومند دارای پنج تابع فعال‌سازی تحت عنوان- های *sigmoid*, *sin*, *hardlimit*, *tribas* و *radbas* است. علاوه بر این نتایج شاخص‌های آماری مختلف برای کلیه توابع فعال‌سازی مدل ماشین آموزش نیرومند در شکل ۵ نشان شده است. در شکل ۶ نحوه مدل‌سازی توابع فعال- سازی مذکور به تصویر کشیده است. برای تابع فعال‌سازی *sigmoid* مقادیر ضریب تبیین و شاخص پراکندگی به ترتیب برابر ۰/۹۷۶ و ۰/۰۸۲ به دست آمده است. علاوه بر این مقادیر *MAPE*، *RMSE* و *MAE* برای این تابع فعال- سازی به ترتیب برابر ۱۱/۸۶۱، ۰/۰۲۴ و ۰/۰۱۹ محاسبه شده‌اند. در مقابل مقدار شاخص‌های R^2 و *RMSE* برای تابع فعال‌سازی *sin* به ترتیب مساوی ۰/۹۷۵ و ۰/۰۲۵ هستند. این در حالی است که مقدار *MAE* برای این تابع فعال‌سازی برابر ۰/۰۱۹ تخمین زده شده است. تابع فعال- سازی *hardlimit* نیز مقادیر *SI*، *MAE* و R^2 را به ترتیب برابر ۰/۴۹۶، ۰/۱۲۲، ۰/۱۲۴ محاسبه شده است. در میان کلیه توابع فعال‌سازی، *hardlimit* دارای بیشترین مقدار خطا و کمترین همبستگی با نتایج آزمایشگاهی است. همچنین مقادیر ضریب تبیین و شاخص پراکندگی برای تابع فعال‌سازی *Radbas* به ترتیب مساوی ۰/۹۷۷ و ۰/۰۸۱ می‌باشند. بر اساس نتایج مدل‌سازی، مقادیر *MAE*، *MAPE* و *RMSE* برای تابع فعال‌سازی به ترتیب مساوی ۰/۰۱۹، ۱۲/۳۶۹ و ۰/۰۲۴ هستند. بر اساس بررسی توابع فعال‌سازی مدل ماشین آموزش نیرومند، تابع فعال‌سازی *sin* دارای بالاترین همبستگی با مقادیر آزمایشگاهی است و در ادامه جهت مدل‌سازی آبخستگی در مجاورت پایه- های پل جفت از این تابع فعال‌سازی استفاده می‌شود. همان‌طور که از شکل ۶ مشاهده می‌شود، در میان توابع فعال‌سازی موجود، تابع *sin* دارای عملکردی بهینه در مقایسه با سایر توابع فعال‌سازی است. به‌عنوان مثال تابع

فعال‌سازی *Hardlim* مقادیر آبخستگی را به‌صورت پلکانی پیش‌بینی نموده است. این تابع فعال‌سازی در شرایط مختلف دارای عملکردی کمتر از مقدار واقعی و بیشتر از مقدار واقعی است.



شکل ۵. مقایسه نتایج شاخص‌های آماری توابع فعال‌سازی مختلف

مختلف در جدول ۱ قابل مشاهده است. بر اساس نتایج شبیه‌سازی آبخستگی، مدل شماره ۱ (ELM 1) مقادیر ضریب تبیین و شاخص پراکندگی را به ترتیب برابر ۰/۹۷۵ و ۰/۰۸۴ محاسبه شده‌اند. برای مدل مذکور شاخص‌های MAE ، $MAPE$ و $RMSE$ به ترتیب مساوی ۰/۰۱۹، ۹/۹۱۶ و ۰/۰۲۵ تخمین زده شده‌اند. این مدل مقادیر آبخستگی را بر حسب کلیه (D/h ، d/h ، Fr) پارامترهای ورودی محاسبه می‌نماید. با توجه به نتایج مدل‌سازی‌ها، مدل ELM 1 دارای بیشترین همبستگی با نتایج آزمایشگاهی و کمترین خطا است. در این مطالعه برای شناسایی مؤثرترین پارامتر ورودی، سه مدل ELM با دو پارامتر ورودی معرفی شد، بدین گونه که با حذف هر یک از ورودی‌ها نتایج مدل‌سازی استخراج و مقادیر خطا محاسبه گردید. به‌عنوان مثال برای مدل ELM 2 تأثیر پارامتر عدد فرود نادیده گرفته شد. به عبارت دیگر مدل مذکور مقادیر آبخستگی را بر حسب (D/h ، d/h) مدل‌سازی می‌نماید. برای این مدل مقادیر SI و R^2 به ترتیب مساوی ۰/۵۱۰ و ۰/۰۷۳ می‌باشند. علاوه بر این شاخص‌های $RMSE$ و $MAPE$ به ترتیب برابر ۰/۱۵۱ و ۱۲۱/۷۲۱ هستند. مدل ELM 3 تابعی از (D/h ، Fr) است. برای این مدل تأثیر پارامتر بدون بعد d/h حذف گردیده است. برای این مدل مقادیر $RMSE$ ، R^2 و MAE به ترتیب مساوی ۰/۸۷۰، ۰/۰۵۶ و ۰/۰۴۳ محاسبه گردیده‌اند. برای ELM 3 مقدار شاخص پراکندگی برابر ۰/۱۹۱ و شاخص $MAPE$ نیز مساوی ۲۶/۱۹۱ محاسبه شده‌اند. برای ELM 4 نیز تأثیر پارامتر D/h نادیده گرفته شده است. این بدان معنا است که مدل مذکور تابعی از (d/h ، Fr) است. برای ELM 4 مقادیر ضریب تبیین و درصد میانگین مطلق خطا به ترتیب مساوی ۰/۹۷۴ و ۱۲/۶۵۱ تخمین زده شده‌اند. برای مدل مذکور شاخص‌های آماری $RMSE$ و MAE نیز به ترتیب برابر ۰/۰۲۵ و ۰/۰۱۹ محاسبه شده‌اند. بنابراین با توجه به تجزیه و تحلیل نتایج مدل‌سازی، مدل ELM 1 به‌عنوان مدل برتر معرفی می‌شود. این مدل تابعی از کلیه پارامترهای ورودی است. همچنین با حذف عدد فرود



شکل ۶. مقایسه مقادیر آبخستگی پیش‌بینی شده توسط توابع فعال-سازی مختلف با مقادیر آزمایشگاهی

پیش‌بینی آبخستگی توسط ماشین آموزش نیرومند

در این قسمت به ارزیابی مدل برتر در پیش‌بینی الگوی آبخستگی در مجاورت پایه‌های دوقلو پرداخته می‌شود. همچنین مؤثرترین پارامتر نیز معرفی می‌گردد. همان‌طور که در بخش‌های قبل عنوان شد، در این مطالعه چهار مدل عددی متمایز توسعه داده شده‌اند. مقایسه نتایج شاخص‌های آماری مدل‌های ماشین آموزش نیرومند

شبکه عصبی مصنوعی

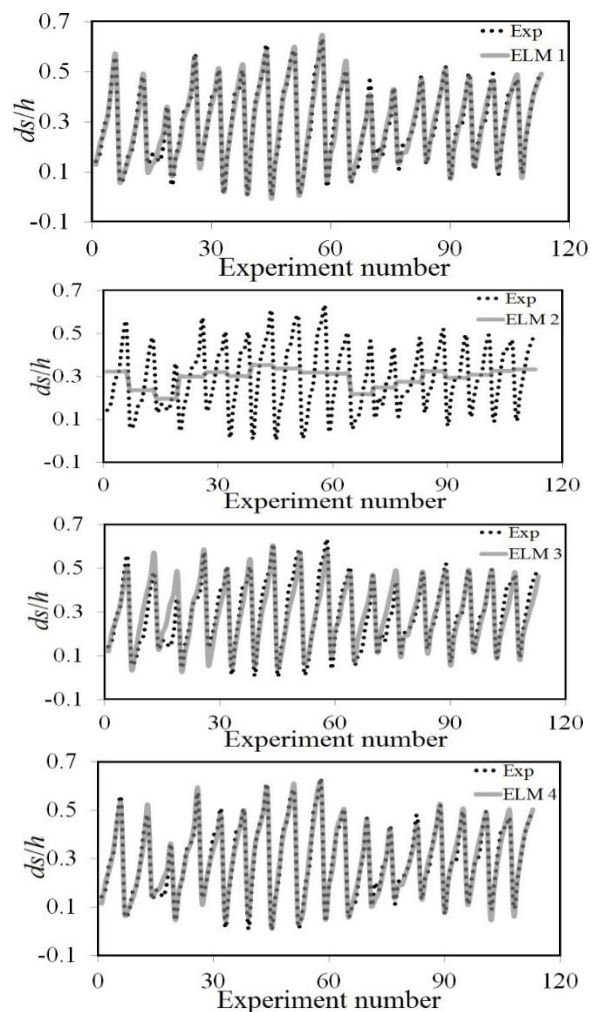
در این قسمت به بررسی دقت مدل‌های شبکه عصبی مصنوعی پرداخته می‌شود. مقایسه شاخص‌های آماری مختلف در شکل ۸ قابل مشاهده است. همچنین مقایسه مقادیر آبستگي مشاهداتی و شبیه‌سازی شده در قالب شکل ۹ به تصویر کشیده شده است. مدل شماره یک مقادیر آبستگي را بر حسب کلیه پارامترهای ورودی پیش‌بینی می‌کند. برای این مدل مقادیر خطای جذر میانگین مربعات برابر 0.053 و مقدار شاخص پراکندگی نیز مساوی 0.179 تخمین زده شده‌اند. همچنین مقدار شاخص R^2 برای این مدل برابر 0.909 پیش‌بینی گردیده است. علاوه بر این مقادیر $MAPE$ و MAE برای مدل شماره یک به ترتیب برابر $15/751$ و 0.031 می‌باشد.

در مطالعه حاضر به منظور شناسایی پارامتر مؤثر بر روی الگوی آبستگي تأثیر پارامترهای ورودی در سه مرحله مختلف حذف شده و مدل‌های ANN شماره ۲ تا ۴ توسعه داده می‌شوند. به عنوان مثال برای مدل شماره ۲ مقادیر $MAPE$ ، $RMSE$ و MAE به ترتیب برابر $105/885$ ، 0.164 و 0.138 محاسبه شده است. همچنین مقادیر ضریب تبیین و شاخص پراکندگی مدل مذکور به ترتیب برابر $0.731E-07$ و 0.556 تخمین زده شده‌اند. در بین مدل‌های با ۲ پارامتر ورودی، ANN 2 دارای بیشترین مقدار خطا است. در مدل شماره ۳ مقدار شاخص R^2 مساوی 0.822 و SI نیز برابر 0.228 به دست آمده است. این در حالی است که مقادیر $RMSE$ و MAE به ترتیب برای مدل شماره ۳ مساوی 0.067 و 0.050 تخمین زده شده است. برای مدل شماره ۴ مقادیر $MAPE$ و $RMSE$ به ترتیب برابر $11/176$ و 0.036 هستند. علاوه بر این مقادیر شاخص پراکندگی و ضریب تبیین به ترتیب مساوی 0.122 و 0.947 تخمین زده شده‌اند. در میان مدل‌های شبکه عصبی مصنوعی، مدل ANN 4 دارای بالاترین مقدار همبستگی با مقادیر مشاهداتی است. برای مدل‌های شبکه عصبی مصنوعی با حذف پارامتر D/h دقت شبیه‌سازی‌ها به شکل قابل توجهی کاهش یافت. بنابراین برای این حالت D/h مؤثرترین پارامتر ورودی شناسایی شد.









دقت مدل عددی به شکل قابل ملاحظه‌ای کاهش یافت فلذا پارامتر مذکور نیز به عنوان مؤثرترین پارامتر در مدل-سازی آبستگي در اطراف پایه‌های پل دوقلو توسط مدل ماشين آموزش نيرومند شناسایی می‌شود. علاوه بر این در شکل ۷ مقایسه مقادیر آبستگي پیش‌بینی شده توسط مدل‌های ماشين آموزش نيرومند مختلف با مقادیر آزمایشگاهی نشان داده شده است.

جدول ۱. مقایسه نتایج شاخص‌های آماری مدل‌های ماشين آموزش نيرومند مختلف

	R^2	$MAPE$	$RMSE$	SI	MAE
ELM 1	0.975	9.916	0.024	0.083	0.019
ELM 2	0.073	121.721	0.150	0.509	0.127
ELM 3	0.870	26.190	0.056	0.190	0.042
ELM 4	0.973	12.651	0.025	0.085	0.019




شکل ۷. مقایسه مقادیر آبستگي پیش‌بینی شده توسط مدل‌های ماشين آموزش نيرومند مختلف با مقادیر آزمایشگاهی



شکل ۹. مقایسه مقادیر پیش‌بینی شده توسط مدل‌های شبکه عصبی مصنوعی مختلف با مقادیر آزمایشگاهی


مقایسه مدل‌های برتر

در ادامه به بررسی دقت مدل‌های برتر ANN و ELM پرداخته می‌شود. در شکل ۱۰ نمودارهای پراکندگی مدل‌های برتر ماشین آموزش نیرومند و شبکه عصبی مصنوعی به تصویر کشیده شده است. بر اساس نتایج مدل‌سازی‌ها، مدل ماشین آموزش نیرومند دارای همبستگی بالاتری در مقایسه با مدل شبکه عصبی مصنوعی است.




شکل ۸. مقایسه نتایج شاخص‌های آماری مدل‌های شبکه عصبی مصنوعی مختلف


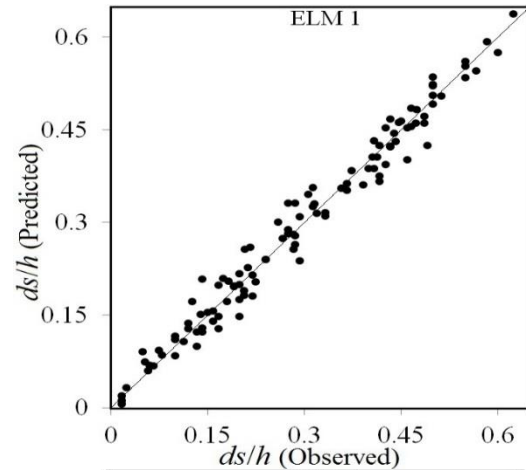
ELM 1 Error<5% ■
 5%<Error<10% ■
 Error>10% ■



ANN4 Error<5% ■
 5%<Error<10% ■
 Error>10% ■



شکل ۱۱. نمودار توزیع خطا برای مدل‌های برتر ماشین آموزش نیرومند و شبکه عصبی مصنوعی



شکل ۱۰. نمودارهای پراکندگی مدل‌های برتر ماشین آموزش نیرومند و شبکه عصبی مصنوعی




تحلیل عدم قطعیت

در این قسمت تحلیل عدم قطعیت مدل‌های ANN 4 و ELM 1 اجرا می‌شود. تحلیل عدم قطعیت برای ارزیابی خطای پیش‌بینی شده توسط مدل‌های عددی مورد استفاده قرار می‌گیرد که در آن مقدار خطای پیش‌بینی شده توسط مدل عددی (e_j) به صورت تفاضل بین مقادیر تراز آب زیرزمینی پیش‌بینی شده (P_j) و مقادیر مشاهداتی (T_j) محاسبه می‌گردد ($e_j = P_j - T_j$). همچنین مقدار میانگین خطای پیش‌بینی شده به صورت $\bar{e} = \sum_{j=1}^n e_j$ به دست می‌آید. علاوه بر این مقدار انحراف استاندارد مقادیر خطای پیش‌بینی شده نیز به صورت $S_e = \sqrt{\sum_{j=1}^n (e_j - \bar{e})^2 / n - 1}$ تعریف می‌شود. منفی بودن مقدار \bar{e} نشان دهنده عملکرد underestimated بودن مدل عددی است. در مقابل مثبت بودن \bar{e} به معنای عملکرد overestimated بودن مدل عددی مذکور است.

در ادامه به بررسی توزیع خطا برای مدل‌های برتر شبکه عصبی مصنوعی و ماشین آموزش نیرومند پرداخته می‌شود. در شکل ۱۱ نتایج توزیع خطا برای مدل‌های ANN 4 و ELM 1 به تصویر کشیده شده است. بر اساس نتایج مدل‌سازی، حدوداً ۷۷ درصد نتایج مدل ANN 4 دارای خطایی کمتر از ۷۷ درصد است. همچنین تقریباً ۴ درصد مقادیر آبخستگی تخمین زده شده توسط این مدل دارای خطایی بین ۵ تا ۱۰ درصد هستند. علاوه بر این تقریباً یک پنجم نتایج مدل ANN 4 مقدار خطایی بیشتر از ۱۰ درصد هستند. با توجه به نتایج توزیع خطا، حدوداً نیمی از مقادیر آبخستگی مدل‌سازی شده توسط ELM 1 مقدار خطایی کمتر از ۵ درصد هستند و ۲۰ درصد این نتایج خطایی بین ۵ تا ۱۰ درصد دارند. همچنین حدوداً یک سوم نتایج مدل‌سازی شده توسط ELM 1 خطایی بیشتر از ده درصد دارند.

جدول ۲. نتایج تحلیل عدم قطعیت برای مدل‌های ANN 4 و ELM 1

مدل‌ها	تعداد نمونه‌ها	متوسط خطای پیش-بینی شده	انحراف استاندارد	Se	محدوده عدم قطعیت	دامنه ۹۵٪ خطای پیش-بینی شده
ANN 4	۱۱۳	۰/۰۰۲	۰/۰۳۶	۰/۰۰۳ ± ۰/۰۰۷		۰/۰۰۹ و -۰/۰۰۵
ELM 1	۱۱۳	۵/۴۱۴E-۰۸	۰/۰۲۵	۰/۰۰۲ ± ۰/۰۰۵		۰/۰۰۵ و -۰/۰۰۵



شکل ۱۲. نتایج تحلیل حساسیت مشتق نسبی برای پارامترهای

ورودی مدل برتر ELM

لازم به ذکر است که با استفاده از پارامترهای \bar{e} و S_e یک باند اطمینان در اطراف مقادیر پیش‌بینی از یک خطا توسط Wilson score method بدون continuity correction تولید می‌شود. در ادامه با استفاده از $1 \pm 6.4 S_e$ به صورت تقریبی منجر به ۹۵٪ باند اطمینان می‌گردد. در جدول ۲ نیز پارامترهای به دست آمده برای تحلیل عدم قطعیت مدل‌های ANN 4 و ELM 1 مرتب شده است. با توجه به تحلیل عدم قطعیت، مدل‌های ANN 4 و ELM 1 دارای عملکردی overestimated هستند. علاوه بر این 95% prediction error interval نتایج آبخستگی تخمین زده شده توسط ELM 1 بین -0.005 و 0.005 می‌باشند

تحلیل حساسیت مشتق نسبی (PDSA)

در ادامه به انجام تحلیل حساسیت مشتق نسبی برای مدل برتر و واسنجی پارامترهای ورودی پرداخته می‌شود. تحلیل حساسیت مشتق نسبی یکی از مهم‌ترین روش‌ها برای شناسایی الگوی تغییرات پارامترهای ورودی است (Azimi et al, 2017). به‌طور کلی تحلیل حساسیت مشتق نسبی مثبت به معنای افزایش تابع هدف (ضریب دبی) است و در مقابل منفی بودن آن به معنی کاهش یافتن مقدار خروجی است. نتایج تحلیل حساسیت مشتق نسبی برای پارامترهای ورودی مدل برتر ELM در شکل ۱۲ نشان داده شده است. به‌عنوان مثال برای پارامترهای D/h و d/h مقادیر PDSA برای بخشی از این پارامترها مثبت و برای بخش دیگر منفی محاسبه شده است. این در حالی است که مقدار PDSA برای کلیه مقادیر عدد فرود مثبت محاسبه گردید.

نتیجه‌گیری

نتایج مدل‌های ELM با مدل‌های ANN نیز مقایسه شد که نشان داده شد مدل‌های ELM مقادیر آبخستگی را با دقت بیشتری شبیه‌سازی می‌کنند. برای مدل برتر ELM یک رابطه برای محاسبه عمق حفره آبخستگی پیشنهاد داده شد و در ادامه تحلیل عدم قطعیت نشان داد که این مدل دارای عملکردی بیشتر از مقدار واقعی بود. علاوه بر این تحلیل حساسیت مشتق نسبی برای پارامترهای ورودی نشان داد که با افزایش عدد فرود مقدار تابع هدف (عمق آبخستگی) افزایش می‌یابد.

در مطالعه حاضر با استفاده از روش جدید ماشین آموزش نیرومند یک مدل عددی برای تخمین آبخستگی در اطراف پایه‌های پل دوقلو ارائه گردید. همچنین با استفاده از پارامترهای ورودی، چهار مدل ELM توسعه داده شد که برای بررسی دقت مدل آنها از شبیه‌سازی‌های مونت کارلو و برای اعتبار سنجی نتایج عددی از روش اعتبار سنجی ضربدری استفاده گردید. سپس بهینه‌ترین تابع فعال‌سازی ELM معرفی شد. همچنین با تجزیه و تحلیل نتایج مدل‌سازی، مدل برتر ELM معرفی گردید.

Reference:

- Azamathulla, H.M. 2012. Gene-expression programming to predict scour at a bridge abutment. *Journal of Hydroinformatics*, 14(2): 324-331.
- Azimi, H., Bonakdari, H. and Ebtehaj, I. 2017. 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.
- Azimi, H., Bonakdari, H., and Ebtehaj, I. 2019. Gene expression programming-based approach for predicting the roller length of a hydraulic jump on a rough bed. *ISH Journal of Hydraulic Engineering*, 1-11.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Shabanlou, S., Talesh, S. H. A., and Jamali, A. 2019. A Pareto design of evolutionary hybrid optimization of ANFIS model in prediction abutment scour depth. *Sādhanā*, 44(7), 1-14.
- Azimi, H., Bonakdari, H., Ebtehaj, I., Talesh, S.H.A., Michelson, D.G. and Jamali, A. 2016. Evolutionary Pareto optimization of an ANFIS network for modeling scour at pile groups in clear water condition. *Fuzzy Sets and Systems*, 319: 50-69.
- Bonakdari, H., Moradi, F., Ebtehaj, I., Gharabaghi, B., Sattar, A. A., Azimi, A. H., and Radecki-Pawlik, A. 2020. A non-tuned machine learning technique for abutment scour depth in clear water condition. *Water*, 12(1), 301.
- Ebtehaj, I., Bonakdari, H., Moradi, F., Gharabaghi, B., and Khozani, Z. S. 2018. An integrated framework of Extreme Learning Machines for predicting scour at pile groups in clear water condition. *Coastal Engineering*, 135, 1-15.
- Ebtehaj, I., Sattar, A. M., Bonakdari, H., and Zaji, A. H. 2017. Prediction of scour depth around bridge piers using self-adaptive extreme learning machine. *Journal of Hydroinformatics*, 19(2), 207-224.
- Firat, M. and Gungor, M. 2009. Generalized regression neural networks and feed forward neural networks for prediction of scour depth around bridge piers. *Advances in Engineering Software*, 40(8): 731-737.
- Huang, G.B., Zhu, Q.Y. and Siew, C.K. 2004. Extreme learning Machine: a new learning scheme of feedforward neural networks. *International Joint Conference on Neural Networks*, 2: 985-90.
- Liriano, S.L. and Day, R.A. 2001. Prediction of scour depth at culvert outlets using neural networks. *Journal of Hydroinformatics*, 3(4): 231-238.
- Sharafi, H., Ebtehaj, I., Bonakdari, H. and Zaji, A.H. 2016. Design of a support vector machine with different kernel functions to predict scour depth around bridge piers. *Natural Hazards*, 84(3): 2145-2162.
- Trent, R., Gagarin, N. and Rhodes, J. 1993. Estimating pier scour with artificial neural networks. In *Hydraulic Engineering*, (1043-1048). ASCE.
- Wang, H., Tang, H., Liu, Q. and Wang, Y. 2016. Local scouring around twin bridge piers in open-channel flows. *Journal of Hydraulic Engineering*, 142(9): 06016008.
- Yua, L., Danninga, Z. and Hongbinga C. 2015. Prediction of length-of-day using extreme learning machine. *Geodesy and Geodynamics* 16(2): 151-159.



Print ISSN: 2251-7480
Online ISSN: 2251-7400

Journal of
**Water and Soil
Resources Conservation
(WSRCJ)**

Web site:

<https://wsrcj.srbiau.ac.ir>

Email:

iauwsrcj@srbiau.ac.ir
iauwsrcj@gmail.com

**Vol. 11
No. 3
Spring 2022**

Received:
2020-09-28

Accepted:
2021-12-18

Pages: 17-30



Sensitivity Analysis of Parameters Affecting Scour Depth at Downstream of Twin Bridge Piers Using Extreme Learning Machine

Siamak Amiri¹, Mohammad Ali Izadbakhsh^{2*} and Saeid Shabanlou³

1) Ph.D. Candidate, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

2) Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

3) Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

*Corresponding author email: izadbakhsh.mohammad.ali@gmail.com

Abstract:

Background and Aim: Local scouring has been identified as one of the important factors that cause the structure of bridges, breakwaters, and piers to rupture. The complexity of the scouring mechanism has made this one of the most important fields of civil engineering studies. In recent years, many studies have been performed on local scouring around bridge piers. Due to the great importance of predicting and estimating the scour pattern in the vicinity of bridge piers, many studies have been done on this type of structure.

Method: In this study, for the first time, using a new extreme learning machine (ELM) method, the scour depth near the foundations of the twin bridges was simulated. First, effective parameters were identified and four ELM models were developed. Then, numerical results were validated using Monte Carlo simulation and the cross-validation method. Then the sin activation function was determined as the best activation function. In addition, ELM results were compared with artificial neural network (ANN) models that ELM models estimated scour values more accurately. Uncertainty analysis was performed for the superior ELM and ANN models and a relationship was proposed for the superior model. Partial derivative sensitivity analysis (PDSA) was also performed for all input parameters.

Results: Among the existing activation functions, the sin function had the optimal performance compared to other activation functions. According to the analysis of modeling results, ELM 1 model was introduced as the superior model. This model was a function of all input parameters. Also, by removing the landing number, the accuracy of the numerical model was significantly reduced, so the mentioned parameter was identified as the most effective parameter in scouring modeling around the bases of the twin bridges by the model of Strength training machine.

Conclusion: By analyzing the modeling results the superior ELM model was introduced. The results of ELM models were also compared with ANN models, which showed that ELM models simulate scour values more accurately. For the superior ELM model, a relation was proposed to calculate the scour hole depth, and further uncertainty analysis showed that this model had a higher performance than the actual value. In addition, the relative derivative sensitivity analysis for the input parameters showed that with increasing the landing number, the value of the objective function (scour depth) increases.

Keywords: Extreme Learning Machine (ELM), Partial derivative sensitivity analysis (PDSA), Scour depth, Twin bridge piers, Uncertainty analysis