

تخمین عمق آبشستگی در اطراف سرریزهای مستغرق با استفاده از مدل نوین ماشین آموزش نیرومند

علی عزیزپور^۱
محمد علی ایزدبخش^{۲*}
احمد رجبی^۳
سعید شعبانلو^۴

چکیده

آبشستگی در مجاورت سازه‌های هیدرولیکی یکی از مهمترین پارامترهای طراحی این نوع از سازه‌های آبی در محیط‌های فرسایشی محسوب می‌شود. در این مطالعه با استفاده از روش نوین ماشین آموزش نیرومند الگوی آبشستگی در پائین دست سرریزهای مستغرق پیش‌بینی شد. در مطالعه حاضر برای بررسی توانایی دقت مدل عددی از روش شبیه‌سازی‌های مونت کارلو بهره گرفته شد. علاوه بر این، به منظور صحت سنجی دقت مدل‌های عددی از روش اعتبار سنجی ضربدری استفاده گردید. در ادامه با توجه به پارامترهای ورودی، پنج مدل عددی ماشین آموزش نیرومند توسعه داده شد. در ابتدا، بهینه ترین تعداد نرون های لایه مخفی برای مدل عددی محاسبه شد. سپس تابع فعال‌سازی بهینه برای مدل عددی انتخاب شد. تحلیل توابع فعال‌سازی نشان داد که تابع sigmoid مقادیر تابع هدف را با دقت بیشتری تخمین زد. همچنین نتایج تحلیل حساسیت نشان داد که مدل برتر مقادیر آبشستگی را بر حسب U_0/U_c , z/h_t , d_{50}/h_t تخمین زد. این مدل مقادیر آبشستگی در پائین دست سرریزهای مستغرق را با دقت قابل قبولی تخمین زد به عنوان مثال مقادیر ضریب تبیین و شاخص پراکندگی برای این مدل به ترتیب مساوی با ۰/۸۸۰ و ۰/۱۲۷ محاسبه شد. علاوه بر این، پارامتر بدون بعد سرعت U_0/U_c به عنوان موثرترین پارامتر ورودی شناسایی شد. در نهایت یک ماتریس برای محاسبه عمق آبشستگی برای مهندسين بدون نیاز به دانش قبلی در مورد ماشین آموزش نیرومند ارائه شد.

واژه‌های کلیدی:

سرریز مستغرق، آبشستگی، مدل سازی، ماشین آموزش نیرومند

۱. دانشجوی دکتری منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران
۲. استادیار سازه های آبی، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران (email: izadbakhsh.mohammad.ali@gmail.com)
۳. استادیار منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران
۴. دانشیار منابع آب، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

مقدمه

به طور کلی، آبشستگی اطراف سازه های مختلف از قبیل صفحات مستغرق، تکیه گاه های کناری، پایه های پل و سایر سازه ها باعث کاهش پایداری سازه های دریایی و رودخانه ای می شود. بنابراین، شناخت کافی از روند آبشستگی اهمیت بسیاری برخوردار است و به همین دلیل مطالعات آزمایشگاهی ثنوری و عددی فراوانی بر روی الگوی آبشستگی توسط محققین مختلف انجام شده است. به عنوان مثال، بویان و همکاران^۱ در سال ۲۰۰۷ در یک مطالعه آزمایشگاهی تاثیر سرریز سنگی W شکل بر روی کنترل رسوب درون مجاری غیر مستقیم را مورد بررسی قرار دادند. آنها بیان نمودند که موقعیت قرار گیری سرریز سنگی نقش قابل ملاحظه ای در کنترل رسوب دارد.

اسکرلک و همکاران^۲ در سال ۲۰۱۱ در یک مطالعه الگوی جریان در اطراف یک سرریز سنگی U شکل را به صورت آزمایشگاهی و عددی مورد مطالعه قرار دادند. آنها برای شبیه سازی یک بعدی از مدل HEC-RAS استفاده نمودند. گوان و همکاران^۳ در سال ۲۰۱۴ در یک تحقیق آزمایشگاهی به ارزیابی الگوی آبشستگی در اطراف سرریزهای مستغرق مستطیلی پرداختند. در مطالعه آنها تاثیر رژیم جریان بر روی الگوی آبشستگی در مجاورت سرریزهای مستغرق مورد بحث قرار گرفت. آنها همچنین برای محاسبه ابعاد حفره آبشستگی یک رابطه ارائه کردند. پترسون و همکاران^۴ در سال ۲۰۱۵ محافظت از پایه های پل در مقابل آبشستگی واقع در محیط های دریایی برای اثرات امواج و جریان را مورد مطالعه آزمایشگاهی قرار دادند. آنها برای محافظت از پایه های پل از مصالح سنگی با ابعاد مختلف استفاده نمودند. علاوه بر این گوان و همکاران در سال ۲۰۱۶ مقادیر آبشستگی در پائین دست سرریزهای مستغرق را مورد بررسی آزمایشگاهی قرار

دادند. آنها با تجزیه و تحلیل نتایج مطالعه خود یک رابطه برای محاسبه مقادیر آبشستگی در اطراف سازه های هیدرولیکی مذکور پیشنهاد دادند. در سال های اخیر محاسبات نرم در پیش بینی پدیده های پیچیده همچون مکانیزم انتقال رسوب و آبشستگی اطراف سازه های مختلف به شکل گسترده ای افزایش یافته است. به عنوان مثال، باطنی و همکاران^۵ در سال ۲۰۰۷ با استفاده از مدل شبکه عصبی عمق آبشستگی وابسته به زمان را در اطراف پایه های پل دایروی شکل تخمین زدند. نتایج مطالعه آنها نشان داد که موثرترین پارامتر بر روی عمق آبشستگی، قطر پایه پل است. اعتماد شهیدی و همکاران^۶ در سال ۲۰۱۵ با استفاده از مدل درختی M5 عمق آبشستگی در اطراف پایه های پل را مدل سازی نمودند. آنها نتایج مدل عددی خود را با روابط تجربی مقایسه کردند که این مقایسه نشان داد که دقت مدل M5 بیشتر است. علاوه بر این، عظیمی و همکاران^۷ در سال ۲۰۱۷ با ترکیب الگوریتم های تفاضل تکاملی و انفیس مقادیر آبشستگی در مجاورت گروه پایه های پل را تخمین زدند. آنها ده مدل ترکیبی برای شناسایی مدل برتر و موثرترین پارامتر در شبیه سازی مقادیر آبشستگی در اطراف گروه پایه های پل ارائه نمودند. همچنین، آفاخانی افشار و همکاران در سال ۱۳۸۹ با هدف کاهش اثرات آبشستگی موضعی ایجاد شکاف در پایه پل و نیز شبیه سازی آن با قرارگیری دو پایه در مجاورت یکدیگر مورد بررسی آزمایشگاهی قرار دادند. آنها به این نتیجه رسیدند که در تک پایه استوانه ای به قطر مشخص با افزایش عرض شکاف از قدرت گردابه های نعل اسبی و جریان رو به پائین کاسته شده و در نتیجه عمق آبشستگی نیز کاهش می یابد. جلیلی و قمشی در سال ۱۳۹۲ در یک مطالعه آزمایشگاهی تأثیرات طوقه مشبک و ساده بر آبشستگی پایه پل مکعبی شکل را مورد مطالعه آزمایشگاهی قرار دادند. آنها بیان نمودند که

⁵ Bateni et al.

⁶ Etemad-Shahidi et al.

⁷ Azimi et al.

¹ Bhuiyan et al.

² Scurlock et al.

³ Guan et al.

⁴ Petersen et al.

نصب طوق از تماس مستقیم جریان پایین رونده در جلو پایه با بستر رودخانه جلوگیری می کند و قدرت گرداب نعل اسبی را به صورت محسوسی کاهش می دهد. آنها تصریح نمودند که نتایج آزمایشات تا ۳۰٪ کاهش در عمق بیشینه آبشستگی را پیش بینی می کند. همچنین با کاهش فرود جریان در تمامی طوقه ها با درصدهای بازشدگی مختلف، میزان آبشستگی کاهش یافت. حسینی و همکاران در سال ۱۳۹۵ تغییرات عمق آبشستگی اطراف گروه پایه کج مستقر بر گروه شمع در شرایط مختلف تراز کارگذاری و ضخامت سر شمع، آرایش و قطر شمعها، به صورت آزمایشگاهی بررسی نمودند. آنها بیان کردند که برای ترازهای نسبی کارگذاری سر شمع بالای بستر، با افزایش ضخامت نسبی سر شمع مقدار بیشینه عمق آبشستگی برای هندسه و قطرهای مختلف شمع، بهطور متوسط ۲۰ درصد افزایش می یابد. همان گونه که مشاهده می شود، مطالعات فراوانی توسط محققین مختلفی بر روی آبشستگی در اطراف سازه های هیدرولیکی مختلف انجام شده است. از طرفی تخمین آبشستگی در اطراف سرریزهای مستغرق دارای نکات مهم و اجرایی برای محققین علم هیدرولیک و محیط زیست است و به عنوان مهمترین هدف تحقیق حاضر در نظر گرفته می شود که تاکنون به در قالب محاسبات نرم مورد بررسی قرار نگرفته است. به عبارت دیگر، در مطالعه حاضر آبشستگی در اطراف سرریزهای مستغرق توسط یک روش نوین هوش مصنوعی تحت عنوان ماشین آموزش نیرومند مدل سازی می شود. همچنین، مدل برتر برای تخمین عمق آبشستگی و موثرترین پارامتر ورودی معرفی می شود.


مواد و روش ها

ماشین آموزش نیرومند^۱ (ELM)

یکی از روش هایی که به صورت گسترده برای حل مسائل غیرخطی در علوم مهندسی مورد استفاده قرار می گیرد، الگوریتم (BP) backpropagation است. این الگوریتم یکی از رایج ترین الگوریتم ها جهت آموزش شبکه های عصبی چند لایه است. عمومیت یافتن الگوریتم BP، بخاطر سادگی و کاربردهای موفقیت آمیز آن در حل مسائل غیرخطی پیچیده می باشد. علیرغم موفقیت های این الگوریتم در یادگیری multi-layer feed forward neural network، این الگوریتم ممکن است به نقاط مینیمم محلی در فضای پارامتر، همگرا شود. بنابراین زمانی که الگوریتم BP همگرا می شود، نمی توان 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 وزن های 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. شبکه های عصبی مبتنی بر Extreme Learning Machine (ELM)، بر خلاف الگوریتم BP، نیازی به تنظیم پارامترهای لایه پنهان (وزن و بایاس) ندارد و این پارامترها به طور تصادفی انتخاب می شوند. هدف در این روش، رسیدن به کوچکترین خطای آموزش و کوچکترین norm وزن خروجی است. این الگوریتم عملکرد کلی خوبی را نتیجه می دهد و بسیار سریع اجرا می شود و مشکل کمینه محلی ندارد و حداقل مداخله انسانی را نسبت به الگوریتم BP دارد. ELM که توسط هووانگ و همکاران^۲ در سال ۲۰۰۶ ارائه شده است، از معماری single layer feed forward neural network (SLFFNN) استفاده می کند. وزن های لایه ورودی به لایه پنهان به صورت تصادفی انتخاب می شوند و وزن های خروجی از طریق عملیات شبه معکوس بدست می آیند. روش ELM از قابلیت تعمیم پذیری

² Huang et al.

1 Extreme Learning Machine



شکل (۲): مدل آزمایشگاهی ونگ و همکاران (۲۰۱۸)

آبشستگی در پائین دست سرریزهای مستغرق

و ونگ و همکاران (۲۰۱۸) مقدار آبشستگی در مجاورت سرریزهای مستغرق (d_s) را بر حسب چگالی رسوب (ρ_s)، چگالی آب (ρ)، ویسکوزیته سینماتیکی سیال (ν)، شتاب گرانش (g)، عمق متوسط جریان ورودی (h_0)، عمق پایاب (h_t)، سرعت متوسط جریان ورودی (U_0)، سرعت متوسط بحرانی جریان ورودی (U_c)، قطر متوسط ذرات رسوب (d_{50})، انحراف استاندارد قطر ذرات رسوب (σ_s)، عرض سرریز (b)، ارتفاع سرریز (z) و شیب بالادست سرریز (α) در نظر گرفتند.

(۱)


$$ds = f(\rho_s, \rho, \nu, g, h_0, h_t, U_0, U_c, d_{50}, \sigma_s, b, z, \alpha)$$

آنها با ثابت در نظر گرفتن مشخصات هندسی مدل آزمایشگاهی چهار گروه بدون بعد تعریف نمودند و معادله ۱ به صورت زیر بازنویسی شد:

$$ds/h_t = f\left(\frac{U_0}{U_c}, \frac{z}{h_t}, \frac{d_{50}}{h_t}, \frac{2\alpha}{\pi}\right) \quad (2)$$

بنابراین در مطالعه حاضر تاثیرات پارامترهای بدون بعد معادله ۲ به عنوان پارامترهای ورودی مدل های هوش مصنوعی ELM در نظر گرفته می شود. در شکل (۳) نحوه ترکیب پارامترهای ورودی برای مدل های عددی نشان داده شده است.

بالتر و زمان آموزش کمتری نسبت به شبکه عصبی برخوردار است. همچنین، این روش نسبت به سایر روش ها از مداخله انسانی کمتری برخوردار است. تمامی پارامترهای شبکه به صورت خودکار تعیین می شوند که این امر باعث جلوگیری از مداخله انسانی شده و این روش را در کاربردهای برخط، کارآمد می کند. روش ELM مزایای زیادی نسبت به همتایان خود دارد از جمله این برتری ها می توان به استفاده آسان، سرعت بالای آموزش، عدم رخداد overfitting، قدرت تعمیم بالاتر و قابلیت استفاده از توابع فعال سازی، اشاره کرد. شکل (۱)، یک معماری از شبکه ELM با تعداد L نرون پنهان را نشان می دهد که (a_i, b_i) پارامترهای لایه پنهان شامل وزن ورودی به لایه پنهان و وزن های Bias هستند و β_L وزن لایه پنهان L به نرون خروجی است.




شکل (۱): معماری شبکه ELM

مدل آزمایشگاهی

در این مطالعه برای صحت سنجی نتایج مدل عددی از مقادیر آزمایشگاهی اندازه گیری شده توسط ونگ و همکاران^۱ استفاده می شود. مدل آزمایشگاهی آنها شامل یک فلوم به طول ۱۲ متر، عمق ۰/۳۸ متر و عرض ۰/۴۴ متر اندازه گیری شده است. شکل کلی مدل آزمایشگاهی و نحوه آبشستگی در پائین دست سرریز مستغرق در شکل (۲) به تصویر کشیده شده است.

¹ Wang et al.

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 ۴ فرض شده است. همچنین طرح روش اعتبار‌سنجی چند لایه و نحوه برخورد با داده‌های آزمون و آموزش در شکل (۴) نشان داده است.




شکل (۴): نحوه برخورد روش اعتبار‌سنجی ضربدری با مقادیر مشاهداتی

بحث و نتیجه‌گیری

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 نسبی خطا ($MARE$), شاخص عملکرد (VAF) و شاخص پراکندگی (SI) به صورت (۳) تا (۷) استفاده می‌شود.

در معادلات مذکور مقادیر $(R)_{(Observed)i}$, $(R)_{(Predicted)i}$, $(\bar{R})_{(Observed)i}$ و n به‌ترتیب برابر مقادیر آزمایشگاهی، نتایج پیش‌بینی شده توسط مدل‌های عددی، میانگین مقادیر آزمایشگاهی و تعداد اندازه‌گیری‌های آزمایشگاهی می‌باشند. نزدیک بودن مقادیر $RMSE$, $MARE$ و SI به عدد صفر نشان دهنده دقت بالای مدل عددی است. علاوه بر این نزدیک بودن شاخص R^2 به عدد یک حاکی همبستگی بالای مدل عددی مذکور است. به طور کلی مدل برتر دارای VAF بزرگتری در مقایسه با سایر مدل‌های عددی است.



شکل (۳): نحوه ترکیب پارامترهای ورودی برای مدل‌های هوش مصنوعی

در این تحقیق جهت ارزیابی توانایی مدل‌های ماشین آموزش نیرومند از شبیه‌سازی‌های مونت کارلو^۱ استفاده می‌شود. شبیه‌سازی‌های مونت کارلو یک طبقه‌بندی گسترده از الگوریتم‌های محاسباتی است که از نمونه‌گیری تصادفی برای محاسبه نتایج عددی استفاده می‌کند. ایده اصلی این روش بر 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 دیگر مقدور نیست استفاده می‌گردد. شبیه‌سازی مونت کارلو به‌طور کلی به وسیله توزیع احتمالی برای حل مسائل مختلف از قبیل بهینه‌سازی و انتگرال‌گیری عددی استفاده می‌شود. علاوه بر این از روش اعتبار‌سنجی چند لایه ای^۲ برای بررسی عملکرد مدل‌های مذکور بهره گرفته می‌شود. در روش اعتبار‌سنجی چند لایه ای، نمونه اصلی است به طور تصادفی به k نمونه‌های فرعی به اندازه 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 بدست آمده از k لایه‌ی مذکور

² k-fold cross validation

¹ Monte Carlo simulations

تعیین تعداد نرون‌های لایه مخفی

تغییرات شاخص‌های آماری مختلف در مقابل تغییرات تعداد نرون‌های لایه مخفی تصویر کشیده شده است.

در بخش اول به بررسی تعداد نرون‌های لایه مخفی مدل ماشین آموزش نیرومند پرداخته می‌شود. در شکل (۵) نحوه


$$MARE = 100 \times \frac{1}{n} \sum_{i=1}^n \left(\frac{|R_{(Predicted)_i} - R_{(Observed)_i}|}{R_{(Predicted)_i}} \right) \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (R_{(Predicted)_i} - R_{(Observed)_i})^2} \quad (4)$$

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

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)} \right) \times 100 \quad (6)$$



$$SI = \frac{RMSE}{(R)_{(Observed)}} \quad (7)$$



همان طور که مشاهده می‌شود با افزایش تعداد نرون‌های لایه مخفی دقت مدل عددی به شکل قابل توجهی افزایش می‌یابد. تعداد اولیه نرون‌های لایه مخفی از یک شروع شده و تا ۱۷ ادامه یافت. بهینه‌ترین تعداد نرون لایه مخفی مساوی با ۱۷ در نظر گرفته شد. به عنوان مثال مقادیر R^2 ، $RMSE$ و SI برای این تعداد نرون لایه مخفی به ترتیب مساوی ۰/۸۴۹، ۰/۱۱۰ و ۰/۱۴۲ بدست آمدند. علاوه بر این مقادیر $MARE$ و VAF برای تعداد نرون‌های لایه مخفی مساوی با ۱۷ به ترتیب مساوی با ۰/۱۵۱ و ۸۴/۸۹۰ محاسبه شدند. بنابراین در ادامه تعداد نرون‌های لایه مخفی بهینه سازی شده مساوی با ۱۷ در نظر گرفته شد.


۴۵..... تخمین عمق آبشستگی در اطراف سرریزهای مستغرق با استفاده از مدل نوین ماشین آموزش نیرومند

داده شده است. در شکل (۸) نحوه مدل سازی توابع فعال سازی مذکور به تصویر کشیده است. برای تابع فعال سازی sigmoid مقادیر ضریب تبیین و شاخص پراکندگی به ترتیب برابر ۰/۸۴۹ و ۰/۱۴۲ بدست آمده است. علاوه بر این مقادیر $RMSE$ ، $MARE$ و VAF برای این تابع فعال سازی به ترتیب برابر ۰/۱۵۱، ۰/۱۱۰ و ۸۴/۸۹۰ محاسبه شده اند. در مقابل مقدار شاخص های R^2 و $RMSE$ برای تابع فعال سازی sin به ترتیب مساوی ۰/۸۳۳ و ۰/۱۱۶ هستند. این در حالی است که مقدار $MARE$ برای این تابع فعال سازی برابر ۰/۱۵۵ تخمین زده شده است. تابع فعال سازی hardlimit نیز مقادیر SI ، $MARE$ و R^2 را به ترتیب برابر ۰/۲۹۴، ۰/۲۶۰، ۰/۳۵۷ محاسبه شده است. در میان کلیه توابع فعال سازی، hardlimit دارای بیشترین مقدار خطا و کمترین همبستگی با نتایج آزمایشگاهی است. همچنین مقادیر ضریب تبیین و شاخص پراکندگی برای تابع فعال سازی Radbas به ترتیب مساوی ۰/۸۲۷ و ۰/۲۹۴ می باشند. بر اساس نتایج مدل سازی، مقادیر VAF ، $MARE$ و $RMSE$ برای تابع فعال سازی tribas به ترتیب مساوی ۷۸/۶۷۹، ۰/۱۵۴ و ۰/۱۳۱ هستند. بر اساس بررسی توابع فعال سازی مدل ماشین آموزش نیرومند، تابع فعال سازی sig دارای بالاترین همبستگی با مقادیر آزمایشگاهی است و در ادامه جهت مدل سازی آبشستگی در پائین دست سرریزهای مستغرق از این تابع فعال سازی استفاده می شود.



شکل (۵): تغییرات تعداد نرون های لایه مخفی در برابر شاخص های آماری مختلف


در شکل (۶) مقایسه مقادیر آبشستگی شبیه سازی توسط مدل هوش مصنوعی با استفاده از ۱۷ نرون لایه مخفی و نمودار پراکندگی نشان داده شده است. همان طور که مشاهده می شود، دقت مدل عددی با این تعداد نرون لایه مخفی در حد قابل قبولی است.



شکل (۶): نمودار پراکندگی و مقایسه مقادیر آبشستگی مشاهداتی و شبیه سازی شده توسط نرون های لایه مخفی بهینه شده


توابع فعال سازی

در این قسمت به بررسی تابع فعال سازی بهینه جهت شبیه سازی آبشستگی در اطراف پایه های دوقلو پراخته می شود. همان گونه که در بخش های قبل بیان شد، ماشین آموزش نیرومند دارای پنج تابع فعال سازی تحت عنوان های sigmoid، sin، hardlimit، Tribas و Radbas است. علاوه بر این نتایج شاخص های آماری مختلف برای کلیه توابع فعال سازی مدل ماشین آموزش نیرومند در شکل (۷) نشان




شکل (۸): مقایسه مقادیر آبشستگی پیش‌بینی شده توسط توابع فعال‌سازی مختلف با مقادیر آزمایشگاهی

علاوه بر این نمودارهای پراکندگی برای توابع فعال‌سازی مختلف مدل ماشین آموزش نیرومند در قالب شکل (۹) به تصویر کشیده شده است. با توجه به نتایج مدل‌سازی، تابع فعال‌سازی sig مقادیر تابع هدف را در مقایسه با سایر توابع فعال‌سازی با دقت بیشتر تخمین زد و این تابع فعال‌سازی دارای همبستگی بالایی با مقادیر مشاهداتی است.



شکل (۷) مقایسه نتایج شاخص‌های آماری توابع فعال‌سازی مختلف


همان‌طور که از شکل (۸) مشاهده می‌شود، در میان توابع فعال‌سازی موجود، تابع sig دارای عملکردی بهتر در مقایسه با سایر توابع فعال‌سازی داشت. به عنوان مثال تابع فعال‌سازی Hardlim مقادیر آبشستگی را به صورت پلکانی پیش‌بینی نموده است. این تابع فعال‌سازی در شرایط مختلف دارای عملکردی کمتر از مقدار واقعی^۱ و بیشتر از مقدار واقعی^۲ است.



² Overestimate performance

¹ Underestimate performance


در این قسمت به ارزیابی مدل برتر در پیش‌بینی الگوی آبستگی در مجاورت پایه‌های دو قلو پرداخته می‌شود. همچنین موثرترین پارامتر نیز معرفی می‌گردد. همان‌طور که در بخش‌های قبل عنوان شد، در این مطالعه پنج مدل هوش مصنوعی متمایز توسعه داده شده‌اند. مقایسه نتایج شاخص‌های آماری مدل‌های ماشین آموزش نیرومند مختلف در شکل (۱۰) قابل مشاهده است. بر اساس نتایج شبیه‌سازی آبستگی، مدل شماره ۱ (ELM 1) مقادیر ضریب تبیین و شاخص پراکندگی را به ترتیب برابر ۰/۸۴۹ و ۰/۱۴۲ محاسبه شده‌اند. برای مدل مذکور شاخص‌های VAF ، $MARE$ و $RMSE$ به ترتیب مساوی ۸۴/۸۹۰، ۰/۱۵۱ و ۰/۱۱۰ تخمین زده شده‌اند. این مدل مقادیر آبستگی را بر حسب کلیه پارامترهای ورودی $2\alpha/\pi$ ، d_{50}/h_t ، z/h_t ، U_0/U_c محاسبه می‌نماید. در این مطالعه برای شناسایی موثرترین پارامتر ورودی، چهار مدل ELM با سه پارامتر ورودی معرفی شد، بدین گونه که با حذف هر یک از ورودی‌ها نتایج مدل‌سازی استخراج و مقادیر خطا محاسبه گردید. به عنوان مثال برای مدل ELM 2 تاثیر پارامتر $2\alpha/\pi$ نادیده گرفته شد. به عبارت دیگر مدل مذکور مقادیر آبستگی را بر حسب U_0/U_c ، z/h_t ، d_{50}/h_t مدل‌سازی می‌نماید. در میان کلیه مدل‌های عددی مدل ELM 2 دارای بیشترین دقت در شبیه‌سازی آبستگی در پائین دست سرریزهای مستغرق است. برای این مدل مقادیر SI و R^2 به ترتیب مساوی ۰/۱۲۷ و ۰/۸۸۰ می‌باشند. علاوه بر این شاخص‌های $RMSE$ و $MARE$ به ترتیب برابر ۰/۰۹۸ و ۰/۱۲۱ هستند. مدل ELM 3 تابعی از $2\alpha/\pi$ ، z/h_t ، U_0/U_c است. برای این مدل تاثیر پارامتر بدون بعد d_{50}/h_t حذف گردیده است. برای این مدل مقادیر R^2 ، $RMSE$ و VAF به ترتیب مساوی ۰/۸۴۳، ۰/۱۱۲ و ۸۴/۲۶۸ محاسبه گردیده‌اند. برای ELM 3 مقدار شاخص پراکندگی برابر ۰/۱۴۵ و شاخص $MARE$ نیز مساوی ۰/۱۵۴ محاسبه شده‌اند. برای ELM 4 نیز تاثیر پارامتر z/h_t نادیده گرفته شده است. این بدان معنا است که مدل مذکور تابعی از




شکل (۹): نمودارهای پراکندگی برای توابع فعال‌سازی مختلف

نتایج مدل‌های ماشین آموزش نیرومند




همچنین در شکل‌های (۱۱) و (۱۲) مقایسه مقادیر آبشستگی شبیه‌سازی شده توسط مدل‌های مختلف ELM و نمودارهای پراکندگی آنها به ترتیب نشان داده شده است. بنابراین با توجه به تجزیه و تحلیل نتایج مدل‌سازی، مدل ELM 2 به عنوان مدل برتر معرفی می‌شود. این مدل تابعی از U_0/U_c ، z/h_t ، d_{50}/h_t بود. همچنین با حذف U_0/U_c دقت مدل عددی به شکل قابل ملاحظه‌ای کاهش یافت فلذا پارامتر مذکور نیز به عنوان موثرترین پارامتر در مدل‌سازی آبشستگی در اطراف سرریزهای مستغرق توسط مدل ماشین آموزش نیرومند شناسایی شد.





برای 4 ELM مقادیر ضریب U_0/U_c ، d_{50}/h_t ، $2\alpha/\pi$ تبیین و درصد میانگین نسبی خطا به ترتیب مساوی ۵۱۳/۰ و ۲۴۲/۰ تخمین زده شده‌اند. برای مدل مذکور شاخص‌های آماری $RMSE$ و VAF نیز به ترتیب برابر ۱۹۷/۰ و ۳۰۶/۵۱ محاسبه شده‌اند. علاوه بر این مدل ELM 5 مقادیر تابع هدف را برحسب z/h_t ، d_{50}/h_t ، $2\alpha/\pi$ تخمین زد. به عبارت دیگر، برای شبیه‌سازی آبشستگی در پائین‌دست سرریزهای مستغرق تاثیر U_0/U_c حذف شده است. با توجه به نتایج مدل‌سازی مقادیر تابع هدف توسط مدل‌های هوش مصنوعی، مدل ELM 5 دارای بیشترین مقدار خطا بود. به عنوان مثال مقادیر VAF ، $MARE$ و SI برای این مدل به ترتیب مساوی ۲۸/۶۳۵، ۳۷۰/۰ و ۳۰۹/۰ بدست آمدند.





شکل (۱۰): مقایسه نتایج شاخص‌های آماری مدل‌های ماشین آموزش نیرومند مختلف



شکل (۱۲): نمودارهای پراکندگی برای مدل‌های مختلف ماشین آموزش نیرومند



شکل (۱۱): مقایسه مقادیر آبشستگی پیش‌بینی شده توسط مدل‌های ماشین آموزش نیرومند با مقادیر آزمایشگاهی



با توجه به نتایج مدل‌سازی‌های عددی، مدل ELM 2 به عنوان مدل برتر معرفی شد. این مدل مقادیر عمق آبشستگی را بر حسب U_0/U_c , z/h_t , d_{50}/h_t تخمین می‌زند. شکل کلی

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

در اینجا $OutW$ ، BHN ، $\ln V$ ، $\ln W$ به ترتیب شامل ماتریس وزن‌های ورودی، متغیرهای ورودی، بایاس نرون‌های

مقایسه با مدل های دیگر

در ادامه نتایج مدل برتر یا همان مدل ELM 2 با سایر مدل های هوش مصنوعی از قبیل شبکه عصبی مصنوعی^۱ (ANN) و انفیس (ANFIS^۲) مقایسه می شود. نتایج این مقایسه در جدول (۱) مرتب شده است. همان گونه که ملاحظه می شود، مدل ELM مقادیر آبه سستی ها را با دقت بیشتری در مقایسه با روش های ANN و ANFIS پیش بینی می کند. به عنوان مثال، مقدار R^2 برای مدل های ELM، ANN و ANFIS به ترتیب مساوی با ۰/۸۸۰، ۰/۷۶۲ و ۰/۸۰۷ محاسبه شده است. علاوه بر این، مقدار شاخص عملکرد برای مدل های ANN و ANFIS به ترتیب برابر با ۷۶/۲۳۴ و ۸۰/۶۵۳ بدست آمده اند. لازم به ذکر است که دقت مدل ANFIS از مدل ANN بیشتر است و مدل ELM از هر دو این مدل ها عملکرد بهتری دارد.

جدول (۱): مقایسه نتایج مدل برتر با مدل های شبکه عصبی

مصنوعی و انفیس

مدل	R^2	MAE	RMSE	SI	MARE
ELM 2	۰/۸۸۰	۸۸/۲	۰/۹۸	۰/۱۲۷	۰/۱۲۱
ANN	۰/۷۶۲	۷/۲۳۴	۰/۱۳۸	۰/۱۷۹	۰/۱۶۶
ANFIS	۰/۸۰۷	۸/۶۵۳	۰/۱۲۴	۰/۱۶۱	۰/۱۶۶

نتیجه گیری

در این مطالعه، آبه سستی در اطراف سرریزهای مستغرق با استفاده از مدل ماشین آموزش نیرومند مدل سازی می شود. به طور کلی این مطالعه دارای دو جنبه نوآوارانه می باشد. اول اینکه بررسی آبه سستی در اطراف سرریزهای مستغرق به صورت عددی تاکنون مورد بررسی قرار نگرفته است. دوم

لایه مخفی و وزن های خروجی هستند. مقادیر هر یک از این ماتریس ها به صورت روابط زیر ارائه می شوند:

$$InV = \begin{bmatrix} \frac{U_0}{U_c} \\ \frac{z}{h_t} \\ \frac{d_{50}}{h_t} \end{bmatrix} \quad (9)$$

$$InW = \begin{bmatrix} -0.006 & -0.980 & -0.078 \\ 0.336 & 0.586 & -0.242 \\ 0.072 & -0.070 & 0.142 \\ -0.706 & 0.00005 & -0.791 \\ -0.144 & -0.942 & -0.323 \\ 0.864 & 0.573 & -0.607 \\ -0.623 & -0.103 & -0.525 \\ -0.585 & 0.435 & -0.467 \\ 0.166 & -0.815 & -0.054 \\ -0.444 & 0.926 & 0.958 \\ 0.559 & -0.514 & -0.990 \\ -0.532 & 0.099 & 0.501 \\ -0.729 & -0.741 & 0.812 \\ 0.541 & -0.986 & -0.854 \\ -0.966 & 0.884 & 0.321 \\ 0.784 & 0.040 & -0.177 \\ -0.817 & -0.654 & -0.988 \end{bmatrix} \quad (10)$$

$$BHN = \begin{bmatrix} 0.606 \\ 0.217 \\ 0.186 \\ 0.032 \\ 0.608 \\ 0.694 \\ 0.298 \\ 0.404 \\ 0.011 \\ 0.514 \\ 0.645 \\ 0.828 \\ 0.420 \\ 0.549 \\ 0.273 \\ 0.655 \\ 0.078 \end{bmatrix} \quad (11)$$

$$OutW = \begin{bmatrix} -11694.1 \\ -12064.1 \\ 19802.89 \\ -39212.7 \\ 169.3662 \\ 13671.78 \\ 47172.65 \\ -6365.48 \\ -2841.61 \\ 3205.383 \\ 37718.92 \\ -6331.3 \\ 4651.522 \\ -14646 \\ 1712.995 \\ -36380.4 \\ -1138.64 \end{bmatrix} \quad (12)$$

² Adaptive neuro fuzzy inference system

¹ Artificial Neural Network (ANN)

۲. جلیلی، ا. قمشی، م. مطالعه آزمایشگاهی بررسی تأثیر طوقه مشبک و ساده بر آبشستگی پایه پل مکعبی شکل. دوازدهمین کنفرانس هیدرولیک ایران، کرج، گروه مهندسی آبیاری و آبادانی دانشگاه تهران، ۱۳۹۲.

۳. حسینی س. س، اسمعیلی ورکی، م. فضل‌اولی، ر. مطالعه آزمایشگاهی آبشستگی اطراف گروه پایه کج مستقر بر گروه شمع. نشریه دانش آب و خاک، ۱۳۹۵؛ ۲۶(۲)، ۱۳۵-۱۴۷.

4. Azimi H, Bonakdari H, Ebtehaj I, Talesh SHA, Michelson DG, Jamali A. Evolutionary Pareto optimization of an ANFIS network for modeling scour at pile groups in clear water condition. *Fuzzy Sets and Systems*, (2017); 319, 50-69.
5. Bateni SM, Jeng DS, Melville BW. Bayesian neural networks for prediction of equilibrium and time-dependent scour depth around bridge piers. *Advances in Engineering Software*. (2007); 38(2), 102-111.
6. Bhuiyan F, Hey RD, Wormleaton PR. Hydraulic evaluation of W-weir for river restoration. *Journal of Hydraulic Engineering*. (2007). 133(6), 596-609.
7. Etemad-Shahidi A, Bonakdar L, Jeng DS. Estimation of scour depth around circular piers: applications of model tree. *Journal of Hydroinformatics*. (2015); 17(2), 226-238.
8. Guan D, Melville BW, Friedrich H. Live-bed scour at submerged weirs. *Journal of Hydraulic Engineering*. (2014). 141(2), 04014071.
9. Guan D, Melville B, Friedrich H. Local scour at submerged weirs in sand-bed channels. *Journal of Hydraulic Research*. (2016); 54(2), 172-184.
10. Huang GB, Zhu QY, Siew CK. Extreme learning machine: theory and applications. *Neurocomputing*. (2006); 70(1-3), 489-501.
11. Petersen TU, Sumer BM, Fredsøe J, Raaijmakers TC, Schouten JJ. Edge scour at scour protections around piles in the marine Environment-Laboratory and field investigation. *Coastal Engineering*. (2015); 106, 42-72.
12. Scurlock SM, Thornton CI, Abt SR. One-dimensional modeling techniques for energy dissipation in U-weir grade-control structures. In *World Environmental and Water Resources Congress: Bearing Knowledge for Sustainability*, (2011); 2496-2507.
13. Wang L, Melville BW, Guan D. Effects of upstream weir slope on local scour at submerged weirs. *Journal of Hydraulic Engineering*. (2018); 144(3), 04018002.

اینکه ماشین آموزش نیرومند جز مدل‌های عددی جدید است که تاکنون در این زمینه بکار گرفته نشده است. در ادامه خلاصه‌ای از مهمترین نتایج تحقیق حاضر ارائه می‌شود. برای شناسایی پارامتر موثر پنج مدل متفاوت ماشین آموزش نیرومند توسعه داده شد. به منظور بررسی توانایی مدل‌های عددی از شبیه سازی‌های مونت کارلو استفاده شد. از روش اعتبار سنجی چند لایه ای برای بررسی عملکرد مدل‌های مذکور بهره گرفته شد. با حذف هر یک از پارامترهای ورودی چهار مدل با سه پارامتر ورودی توسعه داده شد. مقدار ضریب تبیین برای ELM 1 مساوی با ۰/۸۴۹ محاسبه شده است. علاوه بر این، مقادیر شاخص آماری درصد میانگین نسبی خطا و خطای جذر میانگین مربعات برای این مدل به ترتیب مساوی ۰/۱۵۱ و ۰/۱۱۰ بدست آمد. برای مدل ELM 2 نتایج شاخص‌های آماری R^2 ، $MARE$ و $RMSE$ به ترتیب مساوی ۰/۸۸۰، ۰/۱۲۱ و ۰/۰۹۸ محاسبه شد. برای ELM 3 مقادیر $MARE$ و $RMSE$ به ترتیب برابر ۰/۱۵۴ و ۰/۱۱۲ بدست آمد. بر اساس تجزیه و تحلیل نتایج مدل‌های پنج گانه ELM مدل ELM 2 به عنوان مدل برتر معرفی می‌گردد. با توجه به تحلیل حساسیت مشاهده می‌گردد با حذف پارامتر U_0/U_c دقت مدل سازی به شکل قابل توجهی کاهش یافت فلذا این پارامتر موثرترین پارامتر شناسایی شد.

مراجع

۱. آقاخانی افشار، افغفور مغربی، م. اسماعیلی، ک. بررسی آزمایشگاهی اثر هندسه شکاف بر کاهش آبشستگی موضعی پایه پل ها. پنجمین کنگره ملی مهندسی عمران، مشهد، دانشگاه فردوسی مشهد، ۱۳۸۹.

Estimation of Scour Depth around Submerged Weirs Using the Novel Approach Extreme Learning Machine

Ali Azizpor^۱
Mohammad Ali IzadBakhsh^{۲*}
Ahmad Rajabi^۳
Saeid Shabanlou^۴

Abstract

Scour in vicinity of hydraulic structures is considered as one of the most important parameters to design the structures. In this study, scour pattern at downstream of submerged weirs was predicted using the novel method "Extreme Learning Machine". In current study, in order to survey the accuracy of the numerical model, the Monte Carlo Simulations (MCs) was employed. In addition, the k-fold cross validation was utilized so as to validate the results of numerical models. Then, regarding with input parameters, five ELM models were developed. Firstly, the number of optimized hidden neurons for soft computing model was calculated. Next, the best activation function for numerical model was chosen. Analysis of activation function showed that the sigmoid activation function predicted the scour around submerged weirs with more accuracy. Additionally, results of sensitivity analysis proved that the superior model estimated the scour in terms of U_0/U_c , z/h_t , d_{50}/h_t . This model simulated the scour around submerged weirs with reasonable accuracy, for instance, determination coefficient and scatter index were computed 0.880 and 0.127, respectively. Moreover, the velocity parameter U_0/U_c was identified as the most effective input variable. Finally, a matrix was provided to estimate the scour depth for engineers without previous knowledge of Extreme Learning Machine.

Keywords:

Submerged weir, Scour, Modeling, Extreme Learning Machine.

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

^{2*} Assistance Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah. Iran

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

⁴ Associate Professor, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah. Iran