

شبیه‌سازی الگوی آبستگي در مجاورت سرریزهای سنگی با استفاده ماشین آموزش نیرومند خارج از محدوده

امیرحسین عظیمی، سعید شعبانلو*، فریبرز یوسفوند، احمد رجبی و بهروز یعقوبی^۱

(تاریخ دریافت: ۱۳۹۹/۹/۱۷؛ تاریخ پذیرش: ۱۴۰۰/۲/۲۵)

چکیده

در این مطالعه، عمق حفره آبستگي در پائین‌دست سرریزهای سنگی با شکل‌های مختلف J ، I ، U و W توسط یک روش نوین هوش مصنوعی تحت عنوان ماشین آموزش نیرومند خارج از محدوده (ORELM) شبیه‌سازی شد. داده‌های مشاهداتی به دو دسته آموزش (۷۰ درصد) و تست (۳۰ درصد) تقسیم شدند. سپس تابع فعال‌سازی بهینه برای شبیه‌سازی عمق آبستگي در پائین‌دست سرریزهای سنگی انتخاب شد. در ادامه، با استفاده از پارامترهای ورودی که شامل نسبت طول سازه به عرض کانال (b/B)، عدد فرود تراکمی (F_d)، نسبت اختلاف عمق جریان بالادست و پائین‌دست سازه به ارتفاع سازه ($\Delta y/h_{st}$) و فاکتور شکل سازه (Φ)، یازده مدل مختلف ORELM برای تخمین عمق آبستگي توسعه داده شدند. با انجام یک تحلیل حساسیت، مدل برتر و مؤثرترین پارامترهای ورودی شناسایی شدند. مدل برتر مقادیر آبستگي‌ها را توسط پارامترهای بدون بعد b/B ، F_d ، $\Delta y/h_{st}$ شبیه‌سازی کرد. برای این مدل، مقادیر ضریب همبستگی (R)، شاخص عملکرد (VAF) و ضریب نش (NSC) برای مدل برتر در شرایط تست به ترتیب مساوی با ۰/۹۵۶، ۹۱/۳۷۸ و ۰/۹۰۸ بدست آمدند. همچنین، پارامترهای بدون بعد b/B ، $\Delta y/h_{st}$ به عنوان مؤثرترین پارامترهای ورودی شناسایی شدند. همچنین، نتایج مدل برتر با مدل ماشین آموزش نیرومند نیز مقایسه شدند که مدل ORELM دقت بیشتری داشت. علاوه بر این، تحلیل عدم قطعیت نشان داد که مدل ORELM مقادیر آبستگي‌ها را بیشتر از واقعیت تخمین زد. در ادامه، برای مدل برتر، یک تحلیل حساسیت مشتق نسبی (PDSA) اجرا گردید.

واژه‌های کلیدی: سرریزهای سنگی، آبستگي، ماشین آموزش نیرومند خارج از محدوده، تحلیل عدم قطعیت، تحلیل حساسیت مشتق نسبی

۱. گروه مهندسی آب، دانشکده کشاورزی، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

*: مسئول مکاتبات: پست الکترونیکی: saeid.shabanlou@gmail.com

مقدمه

رودخانه‌ها و کانال‌ها نقش بسزایی در توسعه تمدن بشری ایفا کرده‌اند. به‌طور کلی، بزرگترین شهرها در مجاورت رودخانه‌ها توسعه یافته‌اند. از رودخانه‌ها برای انتقال کالا به بالادست و پائین‌دست و همچنین دسترسی به آب‌های آزاد مانند دریاها و اقیانوس‌ها استفاده می‌شود. علاوه بر این، تأمین آب مورد نیاز جهت شرب، کشاورزی، صنعتی و سایر کاربری‌ها از آب درون رودخانه‌ها یا کانال‌های مصنوعی امکان‌پذیر است. لئوپولد (۶) بیان کرد که پایداری فرم کلی بستر و دیواره‌های یک رودخانه فرسایشی تابع هشت متغیر مختلف از قبیل شیب، عرض، عمق، سرعت، دبی، زبری، غلظت و ابعاد رسوبات است. به‌طور کلی، گردابه‌های ثانویه و تغییر جریان درون رودخانه‌های مستقیم و مثاندردی باعث افزایش تنش برشی دیواره می‌گردند. بنابراین، پایداری دیواره‌ها و بستر فرسایشی رودخانه‌ها و کانال‌ها از اهمیت بسزایی برخوردار بوده و در سال‌های اخیر روش‌های مختلفی برای محافظت از دیواره‌ها و بستر فرسایشی ارائه شده است. به‌عنوان مثال، پره‌های ایوا، صفحات مستغرق، صفحات منحرف کننده جریان، آبشکن‌های کناری، آبشکن تیغه‌ای و سرریزهای سنگی از جمله مهمترین سازه‌هایی هستند که برای محافظت از بستر و کناره‌های رودخانه و یا کانال مورد استفاده قرار گرفته‌اند. عموماً یک سازه محافظ باید معیارهای زیر را اقلان کند:

- حفظ نسبت عرض به عمق پایدار کانال
- حفظ پایداری کانال با توجه به مقدار تنش برشی برای جابجایی بزرگترین ذرات رسوب
- کاهش سرعت در مجاورت کناره‌ها، تنش برشی یا قدرت جریان
- اطمینان از پایداری سازه محافظ در حین وقوع سیلاب
- حفظ محل عبور ماهی‌ها در کلیه بخش‌های جریان
- فراهم کردن یا افزایش محل عبور قایق‌های تفریحی
- بهبود زیستگاه آبزیان
- سازگار بودن با طبیعت کانال

- کاهش هزینه‌های ساخت در مقایسه با سازه‌ها سنتی

- کاهش هزینه‌های نگهداری

- جلوگیری از رسوبگذاری، فرسایش و کاهش آبستگي در مجاورت پایه‌های پل و سایر سازه‌ها (۱۴).

بنابراین، با توجه به موارد گفته شده سرریزهای سنگی یکی از بهترین گزینه‌ها برای محافظت از پایداری رودخانه‌ها و کانال‌ها در برابر فرسایش محسوب می‌شوند. با توجه به اهمیت سرریزهای سنگی، مطالعات آزمایشگاهی فراوانی بر روی الگوی آبستگي در مجاورت این نوع از سازه‌ها انجام گرفته است. برای نمونه، راسجن (۱۴) معیارهایی برای طراحی سرریزهای سنگی به شکل‌های U ، W و J ارائه کرد. وی موقعیت قرارگیری، فاصله بین سرریزهای سنگی و کاربرد هر یک از این نوع سازه‌ها را تشریح کرد. اسکورلاک و همکاران (۱۵) یک مطالعه آزمایشگاهی و عددی بروی افت انرژی سرریزهای سنگی به شکل U انجام دادند. آنها برای شبیه‌سازی مقادیر افت انرژی از مدل عددی HEC-RAS استفاده کردند و نتایج این مدل را با نتایج آزمایشگاهی اعتبارسنجی کردند. همچنین، اسکورلاک و همکاران (۱۶) الگوی آبستگي در اطراف سرریزهای سنگی با شکل U ، W و A درون کانال مستقیم را در قالب یک مطالعه آزمایشگاهی مورد بررسی قرار دادند. آنها با استفاده از مقادیر آزمایشگاهی روابطی را برای محاسبه عمق آبستگي ارائه کردند و نشان دادند که این روابط از دقت مناسبی برخوردار بودند. در ادامه، اسکورلاک و همکاران (۱۷) سرریزهای سنگی را در محل خم‌های یک کانال روباز تعبیه کرد و الگوی جریان در مجاورت دیواره‌های داخلی و خارجی کانال مورد نظر مورد بررسی قرار دادند. آنها یک سری رابطه برای تخمین نسبت سرعت حداکثر دیواره‌های داخلی و خارجی پیشنهاد دادند. پاگلیارا و همکاران (۱۲) در قالب یک مطالعه آزمایشگاهی الگوی آبستگي در اطراف سرریزهای سنگی به شکل J واقع بر کانال‌های مستقیم را در شرایط آب زلال اندازه‌گیری کردند. آنها با تجزیه و تحلیل نتایج آزمایشگاهی نشان دادند که با افزایش عدد فرود، موقعیت حداکثر عمق آبستگي به سمت پائین‌دست منتقل می‌شود.

کردستانی (۱۰) پارامترهای مؤثر بر روی ابعاد حفره آبخستگی در مجاورت سازه‌های منحرف کننده‌ها در یک مطالعه آزمایشگاهی مورد ارزیابی قرار دادند. آنها دو نوع مورفولوژی بستر برای این نوع از سازه‌های محافظ تعریف کردند.

در مقابل، تکنیک‌های هوش مصنوعی توانایی بالایی در تخمین و شبیه‌سازی پدیده‌های مختلف خطی و غیرخطی دارند. این مدل‌های عددی دارای انعطاف‌پذیری بالایی هستند و ابزار کارآمدی برای صرفه‌جویی در زمان انجام مطالعات و اجرای مطالعات آزمایشگاهی هستند. به‌عنوان مثال، عظیمی و همکاران (۱) با استفاده از یک مدل هوش مصنوعی، الگوی آبخستگی در اطراف سازه‌های سنگی را شبیه‌سازی کردند. آنها با اجرای یک تحلیل حساسیت به معرفی مدل برتر عددی و مؤثرترین پارامترهای ورودی پرداختند.

علاوه بر این، بررسی پژوهش‌های گذشته نشان می‌دهد که محافظت از بستر رودخانه‌ها و کانال‌ها از اهمیت قابل ملاحظه‌ای برخوردار است و شناسایی عوامل مؤثر جهت ارائه یک طرح بهینه بسیار مهم است. از طرف دیگر، روش‌های هوش مصنوعی یک ابزار قدرتمند برای مدل‌سازی پدیده آبخستگی در پائین‌دست سازه‌های هیدرولیکی محسوب می‌شوند. علاوه بر این، مدل‌سازی آبخستگی در پائین‌دست سرریزهای سنگی توسط مدل‌های هوش مصنوعی شبیه‌سازی حاوی نکات مفیدی است که در این مطالعه اینکار توسط مدل نوین ماشین آموزش نیرومند خارج از محدوده (ORELM) انجام می‌شود. به عبارت دیگر، ابتدا پارامترهای ورودی برای شبیه‌سازی عمق آبخستگی معرفی می‌شوند. سپس بهینه‌ترین تابع فعال‌سازی مدل عددی انتخاب می‌شود. با استفاده از پارامترهای ورودی، یازده مدل ORELM تعریف شده و با انجام تحلیل حساسیت، مدل برتر و مؤثرترین پارامترهای ورودی شناسایی خواهند شد. نتایج مدل برتر ORELM با مدل ماشین آموزش نیرومند نیز مقایسه می‌شود. در ادامه یک تحلیل عدم قطعیت و تحلیل حساسیت عدم قطعیت اجرا خواهد شد. در انتها، یک کد کامپیوتری ساده برای محاسبه عمق آبخستگی در پائین-دست سرریزهای سنگی ارائه می‌شود.

همچنین آنها بیان کردند که عرض حفره آبخستگی حدوداً ۰/۷ تا ۰/۹ عرض کانال بود. همچنین، پاگلیارا و کردستانی (۹) ابعاد حفره آبخستگی در پائین‌دست سرریزهای سنگی با شکل I و U درون یک کانال مستطیلی را به‌صورت آزمایشگاهی اندازه‌گیری کردند. آنها با تغییر شرایط هیدرولیکی و هندسی جریان، ابعاد آبخستگی در شرایط آب زلال را اندازه‌گیری کردند و سپس با انجام تحلیل ابعادی، تأثیر پارامترهای مؤثر را مورد ارزیابی قرار دادند. لازم به ذکر است که آنها برای محاسبه عمق، طول و عرض حفره آبخستگی روابطی را ارائه کردند. پاگلیارا و همکاران (۱۱) مقادیر آبخستگی در پائین‌دست سرریزهای سنگی با شکل W درون یک کانال مستطیلی در شرایط آب زلال به‌صورت آزمایشگاهی اندازه‌گیری کردند. تجزیه و تحلیل نتایج آزمایشگاهی نشان داد که عمق پایاب نقش قابل توجهی در پیش‌بینی پارامترهای آبخستگی ایفا کرد. در ادامه، پاگلیارا و همکاران (۱۳) سرریزهای به شکل تنه درخت (log-Vanes) را برای کنترل آبخستگی درون مسیر مستقیم رودخانه‌ها را به‌صورت آزمایشگاهی در شرایط آب زلال اندازه‌گیری کردند. آنها با تغییر وضعیت قرارگیری این سازه‌ها مبادرت به ارزیابی الگوی آبخستگی در مجاورت این نوع از سازه‌ها پرداخته‌اند. لازم به ذکر است که در این مطالعه، حداکثر ابعاد دیون‌های تشکیل شده اندازه‌گیری شدند. محمودی کردستانی و پاگلیارا (۷) الگوی آبخستگی در پائین‌دست این سازه‌ها و سازه‌های منحرف کننده را با یکدیگر در قالب یک مطالعه آزمایشگاهی مورد مقایسه قرار دادند. آنها آزمایش‌ها را درون یک کانال مستقیم مستطیلی شکل در شرایط آب زلال برای رسوبات یکنواخت اجرا کردند. آنها با بررسی نتایج آزمایشگاهی نشان دادند که زاویه قرارگیری این نوع از سازه‌ها نقش قابل توجهی در نحوه شکل‌گیری حفره آبخستگی ایفا می‌کند. پاگلیارا و همکاران (۸) تأثیر نحوه چیدمان سازه‌های منحرف کننده را بر روی الگوی آبخستگی در اطراف این نوع از موانع را مورد مطالعه آزمایشگاهی قرار دادند. آنها نشان دادند که زاویه قرارگیری سازه‌های منحرف کننده‌ها و عمق پایاب مهمترین پارامترها بر روی الگوی آبخستگی بودند. همچنین پاگلیارا و

مواد و روش‌ها

ماشین آموزش نیرومند

یکی از روش‌هایی که به صورت گسترده برای حل مسائل غیرخطی در علوم مهندسی مورد استفاده قرار می‌گیرد، الگوریتم پس‌خور (BP) است. این الگوریتم یکی از رایج‌ترین الگوریتم‌ها جهت آموزش شبکه‌های عصبی چند لایه محسوب می‌شود. عمومیت یافتن الگوریتم BP، بخاطر سادگی و کاربردهای موفقیت‌آمیز آن در حل مسائل غیرخطی پیچیده می‌باشد. با وجود این، کاربردهای موفقیت‌آمیز این الگوریتم در یادگیری شبکه عصبی مصنوعی چندلایه، این الگوریتم ممکن است به نقاط مینیمم محلی در فضای پارامتر، همگرا شود. بنابراین، زمانی که الگوریتم BP همگرا می‌شود، نمی‌توان مطمئن شد که به یک جواب بهینه رسید. از طرفی، سرعت همگرایی الگوریتم BP، خیلی کند است. علاوه بر این، همگرایی الگوریتم BP، به انتخاب مقادیر اولیه وزن‌های شبکه، بردارهای بایاس و پارامترهای موجود در الگوریتم، مانند نرخ یادگیری، وابسته است و گاهی ممکن است برای دستیابی به عملکردی بهتر، به تعداد زیاد تکرار مراحل یادگیری، نیاز باشد. شبکه‌های عصبی مبتنی بر ماشین آموزش نیرومند، بر خلاف الگوریتم BP، نیازی به تنظیم پارامترهای لایه پنهان (وزن و بایاس) ندارد و این پارامترها به طور تصادفی انتخاب می‌شوند. هدف در این روش، رسیدن به کوچکترین خطای آموزش و کوچکترین هنجار وزن خروجی است. این الگوریتم عملکرد کلی خوبی را نتیجه می‌دهد و بسیار سریع اجرا می‌شود و مشکل کمینه محلی ندارد و حداقل مداخله انسانی را نسبت به الگوریتم BP دارد. ماشین آموزش نیرومند که توسط هوانگ و همکاران (۵) ارائه شده است، از معماری شبکه عصبی مصنوعی پیش‌خور تک لایه (SLFFNN) استفاده می‌کند. وزن‌های لایه ورودی به لایه پنهان به صورت تصادفی انتخاب می‌شوند و وزن‌های خروجی از طریق عملیات شبه معکوس بدست می‌آیند. روش ELM از قابلیت تعمیم‌پذیری بالاتر و زمان آموزش کمتری نسبت به شبکه عصبی معمولی برخوردار است. همچنین، این روش

نسبت به سایر روش‌ها از مداخله انسانی کمتری برخوردار است. تمامی پارامترهای شبکه به صورت خودکار تعیین می‌شوند که این امر باعث جلوگیری از مداخله انسانی شده و این روش را در کاربردهای برخط، کارآمد می‌کند. روش ELM مزایای زیادی نسبت به همتایان خود دارد از جمله می‌توان به استفاده آسان، سرعت بالای آموزش، عدم رخداد اُورفیتینگ (overfitting)، قدرت تعمیم‌پذیری بالاتر و قابلیت استفاده از توابع فعال‌سازی مختلف، اشاره کرد.

ماشین آموزش نیرومند خارج از محدوده ORELM

روش ORELM به منظور غلبه بر مشکل‌های روش ماشین آموزش نیرومند کلاسیک در پیش‌بینی مجموعه داده‌هایی که دارای مقادیر خارج از محدوده می‌باشند، ارائه شد (۱۸). در این روش، از مفهوم پارامترهای اسپارسیسیت‌های ناپایدار استفاده شده است بطوریکه برای افزایش توانایی پیش‌بینی مدل از تابع فقدان هنجار l_1 در ترکیب با روش ماشین آموزش نیرومند استفاده می‌شود. در این مطالعه، با تعریف پارامتر C به عنوان یک پارامتر تنظیم‌کننده، نسبت بین خطای آموزش و هنجار وزن خروجی، محاسبه می‌شود. در واقع با استفاده از این پارامتر جهت افزایش عملکرد تعمیم‌پذیری مدل ORELM نسبت به ماشین آموزش نیرومند، حد وزن‌های خروجی و خطای آموزش به طور همزمان به صورت زیر (روابط ۱ و ۲) حداقل می‌شود:

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

در روش ORELM، جهت کاهش خطای آموزش (e)، وزن خروجی (w_0) در ماشین آموزش نیرومند با هنجار l_2 بررسی می‌شود:

(۲)

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

رابطه فوق، یک مسئله غیرهمگرا است. در روش ORELM برای حل آن از شکل تخفیف استفاده می‌شود. بدین صورت که هنجار l_1 با هنجار l_0 جایگزین می‌شود. در واقع با این کار، نه

انتها یک کد کامپیوتری برای تخمین عمق آبشستگی در پائین دست سرریزهای سنگی با شکل مختلف درون کانال‌های مستقیم ارائه خواهد شد.

مدل‌های آزمایشگاهی

برای صحت‌سنجی نتایج مدل‌های عددی از مقادیر آزمایشگاهی اندازه‌گیری شده توسط پاگیلارا و همکاران (۱۲)، پاگیلارا و کردستانی (۹)، پاگیلارا و همکاران (۱۱) بهره گرفته می‌شود. مدل‌های آزمایشگاهی سرریزهای سنگی با شکل J و W درون یک کانال مستطیلی افقی به طول ۲۰ متر ارتفاع ۰/۷۵ متر و عرض (B) مساوی ۰/۸ متر است. همچنین عمق آبشستگی در مجاورت سرریزهای سنگی با شکل I و U درون یک فلوم به طول، عرض و ارتفاع به ترتیب برابر با ۰/۳۴۲، ۰/۶۳ و ۰/۳۴۲ متر اندازه‌گیری شدند. آنها در مطالعه خود مبادرت به اندازه‌گیری عمق آبشستگی (Zm) در پائین دست تله سنگی با ارتفاع h_{st} و عرض b برای عدد فرودهای تراکمی (Fa) کردند. همچنین، اختلاف عمق جریان در بالادست و پائین دست تله سنگی برابر Δy است. طرح کلی مدل آزمایشگاهی مذکور در شکل ۱ قابل مشاهده است.

برای اعتبارسنجی نتایج مدل ماشین یادگیری ارائه شده در این مطالعه، داده‌ها با درصد‌های مختلف ۵۰٪ برای آموزش در مقابل ۵۰٪ آزمون، ۶۰٪ برای آموزش در مقابل ۴۰٪ آزمون، ۷۰٪ برای آموزش در مقابل ۳۰٪ آزمون و ۸۰٪ برای آموزش در مقابل ۲۰٪ آزمون مورد ارزیابی قرار گرفتند. اما ماشین یادگیری ORELM در وضعیتی که داده‌ها آزمایشگاهی به ۷۰٪ برای آموزش در مقابل ۳۰٪ آزمون بهترین نتیجه را ارائه کرد.

پاگیلارا و همکاران (۱۲)، پاگیلارا و کردستانی (۹)، پاگیلارا و همکاران (۱۱) در مطالعه آزمایشگاهی بیان کردند پارامترهایی که بر روی آبشستگی در پائین دست تله‌های سنگی مؤثر می‌باشند عبارتند از: عمق آبشستگی (Zm)، ارتفاع تله سنگی

تنها مشخصه پراکندگی تغییر نمی‌کند بلکه محدوده کلی همگرایی نیز به حداقل می‌رسد.

معیارهای بررسی مدل‌های هوش مصنوعی

در مطالعه حاضر به منظور ارزیابی دقت مدل‌های عددی معرفی شده از شاخص‌های آماری ضریب همبستگی (R)، شاخص عملکرد (VAF)، خطای مربعات میانگین ریشه (RMSE)، شاخص پراکندگی (SI)، خطای مطلق میانگین (MAE) و ضریب بهره‌وری نش ساتکلیف (NSC) به صورت زیر استفاده می‌شود (۲):

$$R = \frac{\sum_{i=1}^n (F_i - \bar{F})(O_i - \bar{O})}{\sqrt{\sum_{i=1}^n (F_i - \bar{F})^2 \sum_{i=1}^n (O_i - \bar{O})^2}} \quad (3)$$

$$VAF = \left(1 - \frac{\text{var}(F_i - O_i)}{\text{var}(F_i)}\right) \times 100 \quad (4)$$

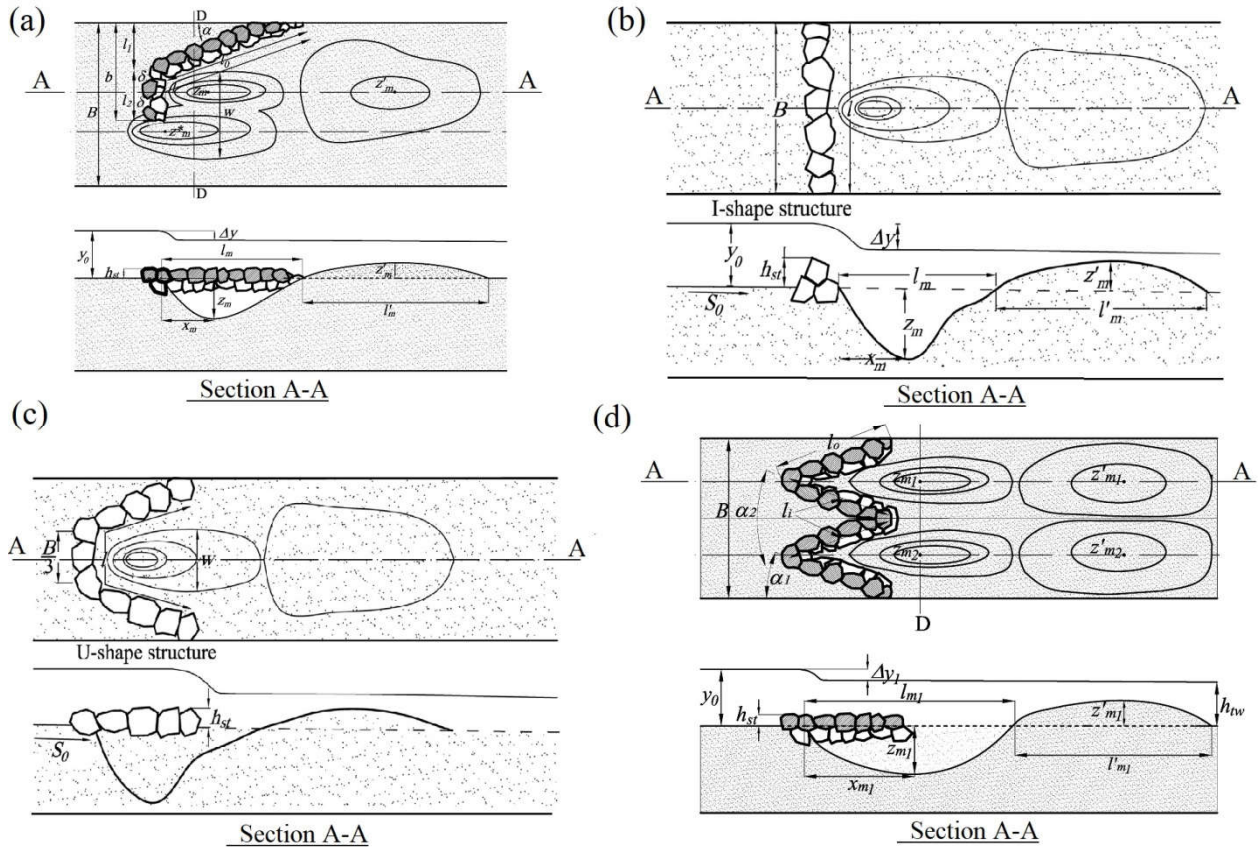
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F_i - O_i)^2} \quad (5)$$

$$SI = \frac{RMSE}{\bar{O}} \quad (6)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |F_i - O_i| \quad (7)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (8)$$

در اینجا O_i مقادیر مشاهداتی، F_i مقادیر پیش‌بینی شده به وسیله مدل‌های عددی، \bar{O} میانگین مقادیر مشاهداتی و n برابر تعداد مقادیر مشاهداتی است. در بخش‌های بعدی، در ابتدا توابع فعال‌سازی مختلف مورد بررسی قرار می‌گیرند. سپس با انجام یک تحلیل حساسیت، مدل برتر و مؤثرترین پارامترهای ورودی شناسایی می‌شوند. علاوه بر این، مدل برتر ORELM با مدل ELM مقایسه می‌شود. همچنین، تحلیل عدم قطعیت و تحلیل حساسیت مشتق نسبی برای مدل برتر اجرا می‌شود. در



شکل ۱. طرح کلی مدل آزمایشگاهی سرریزهای سنگی (a) شکل J، (b) شکل I، (c) شکل U و (d) شکل W

در اینجا F_d عدد فرود تراکمی می‌باشد بنابراین، در این مطالعه، پارامترهای معادله ۱۱ به‌عنوان پارامترهای ورودی در نظر گرفته می‌شود. به بیان دیگر، ۱۱ مدل عددی با استفاده از ترکیب‌های مختلف به‌منظور شناسایی پارامتر مؤثر معرفی می‌شوند. در شکل ۲ نحوه ترکیب پارامترهای بدون بعد معادله ۱۱ نشان داده شده است.

بحث و نتایج

تحلیل حساسیت

در این بخش به تجزیه و تحلیل نتایج مدل‌های عددی ORELM پرداخته می‌شود. همان‌گونه که در قسمت‌های قبل بیان شد، در این مطالعه برای شناسایی مدل برتر و مؤثرترین پارامترهای ورودی یازده مدل ORELM مختلف توسعه داده

(h_{st}) ، عرض تله‌سنگی (b)، عرض کانال اصلی (B)، اختلاف عمق جریان در بالادست و پائین‌دست تله سنگی برابر (Δy) ، دبی جریان (Q)، چگالی رسوب و آب (ρ_s, ρ) ، شتاب گرانش (g) و قطر متوسط رسوبات (d_{50}) . بنابراین، رابطه ۹ به‌صورت زیر بیان نوشته می‌شود:

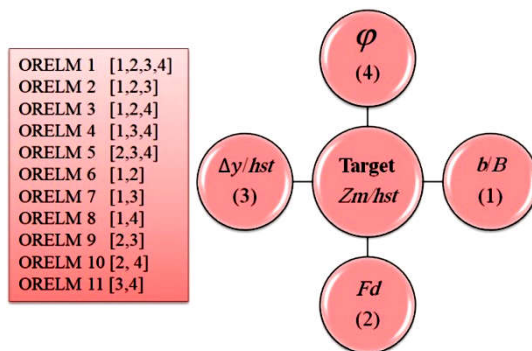
$$f(Z_m, h_{st}, b, B, \Delta y, Q, \rho_s, \rho, g, d_{50}) = 0 \quad (9)$$

پاگیلار و همکاران (۱۱) با آنالیز ابعادی نشان داد که آبستگي در پائین‌دست تله سنگی تابعی از پارامترهای بدون بعد زیر است (رابطه ۱۰):

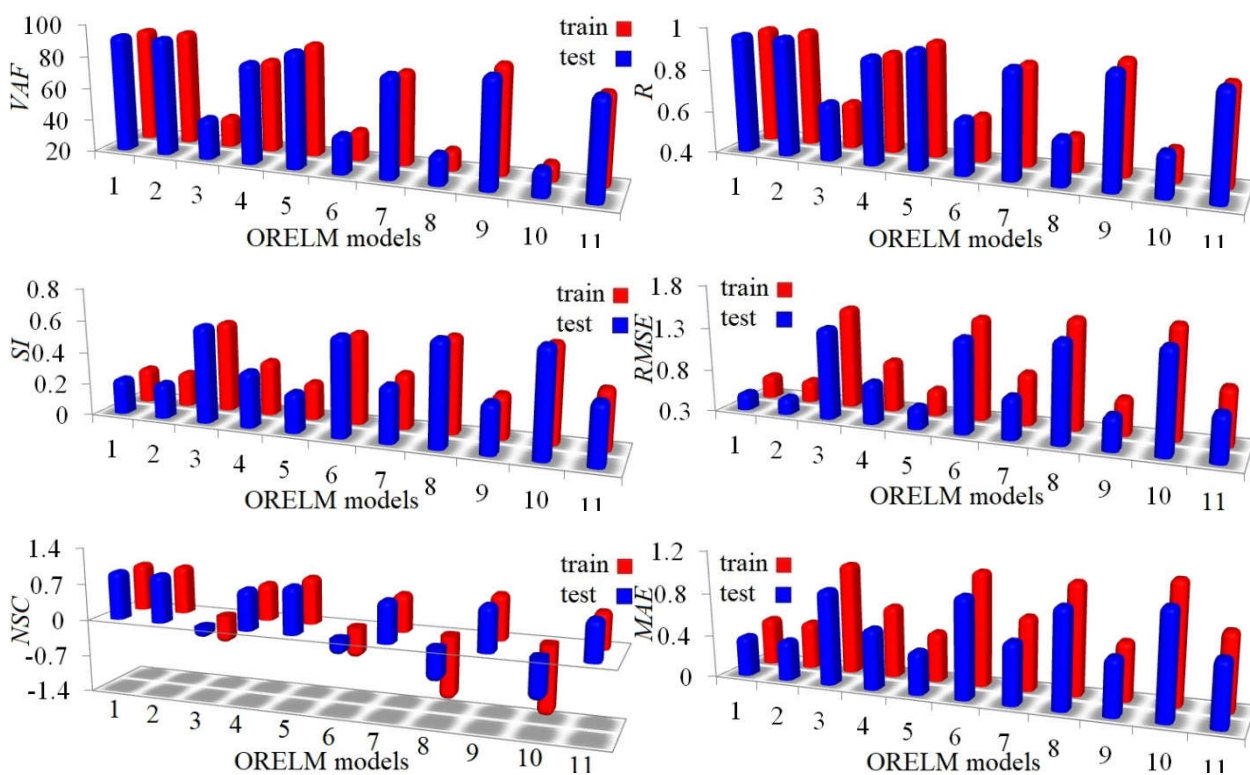
$$Z_m/h_{st} = f(b/B, F_d, \Delta y/h_{st}) \quad (10)$$

علاوه بر این، ضریب شکل سرریزهای سنگی با شکل J، I، U و W نیز با ϕ نشان داده می‌شود. بنابراین معادله ۱۱ به‌صورت زیر بازنویسی می‌شود:

$$Z_m/h_{st} = f(b/B, F_d, \Delta y/h_{st}, \phi) \quad (11)$$



شکل ۲. نحوه ترکیب پارامترهای ورودی به مدل



شکل ۳. نتایج شاخص‌های آماری برای مدل‌های ORELM (رنگی در نسخه الکترونیکی)

به ترتیب مساوی ۰/۹۵۴، ۰/۲۱۶ و ۹۱/۰۴۹ بدست آمدند. برای این مدل مقادیر RMSE و NSC در وضعیت آموزش به ترتیب مساوی با ۰/۵۰۲ و ۰/۹۲۱ محاسبه شدند. این درحالیست که مدل ORELM 2 مقادیر تابع هدف را بر حسب پارامترهای $b/B, F_d, \Delta y/h_{st}$ شبیه‌سازی می‌کند. برای ORELM 2 در

شده است. در شکل ۳ نتایج کلیه شاخص‌های آماری برای مدل‌های ORELM 1 تا ORELM 11 با همدیگر مقایسه شده است. مدل ORELM 1 مقادیر آبخستگی را بر حسب کلیه پارامترهای ورودی $(b/B, F_d, \Delta y/h_{st}, \varphi)$ تخمین می‌زند. برای ORELM 1 در شرایط تست مقادیر VAF و SI، R

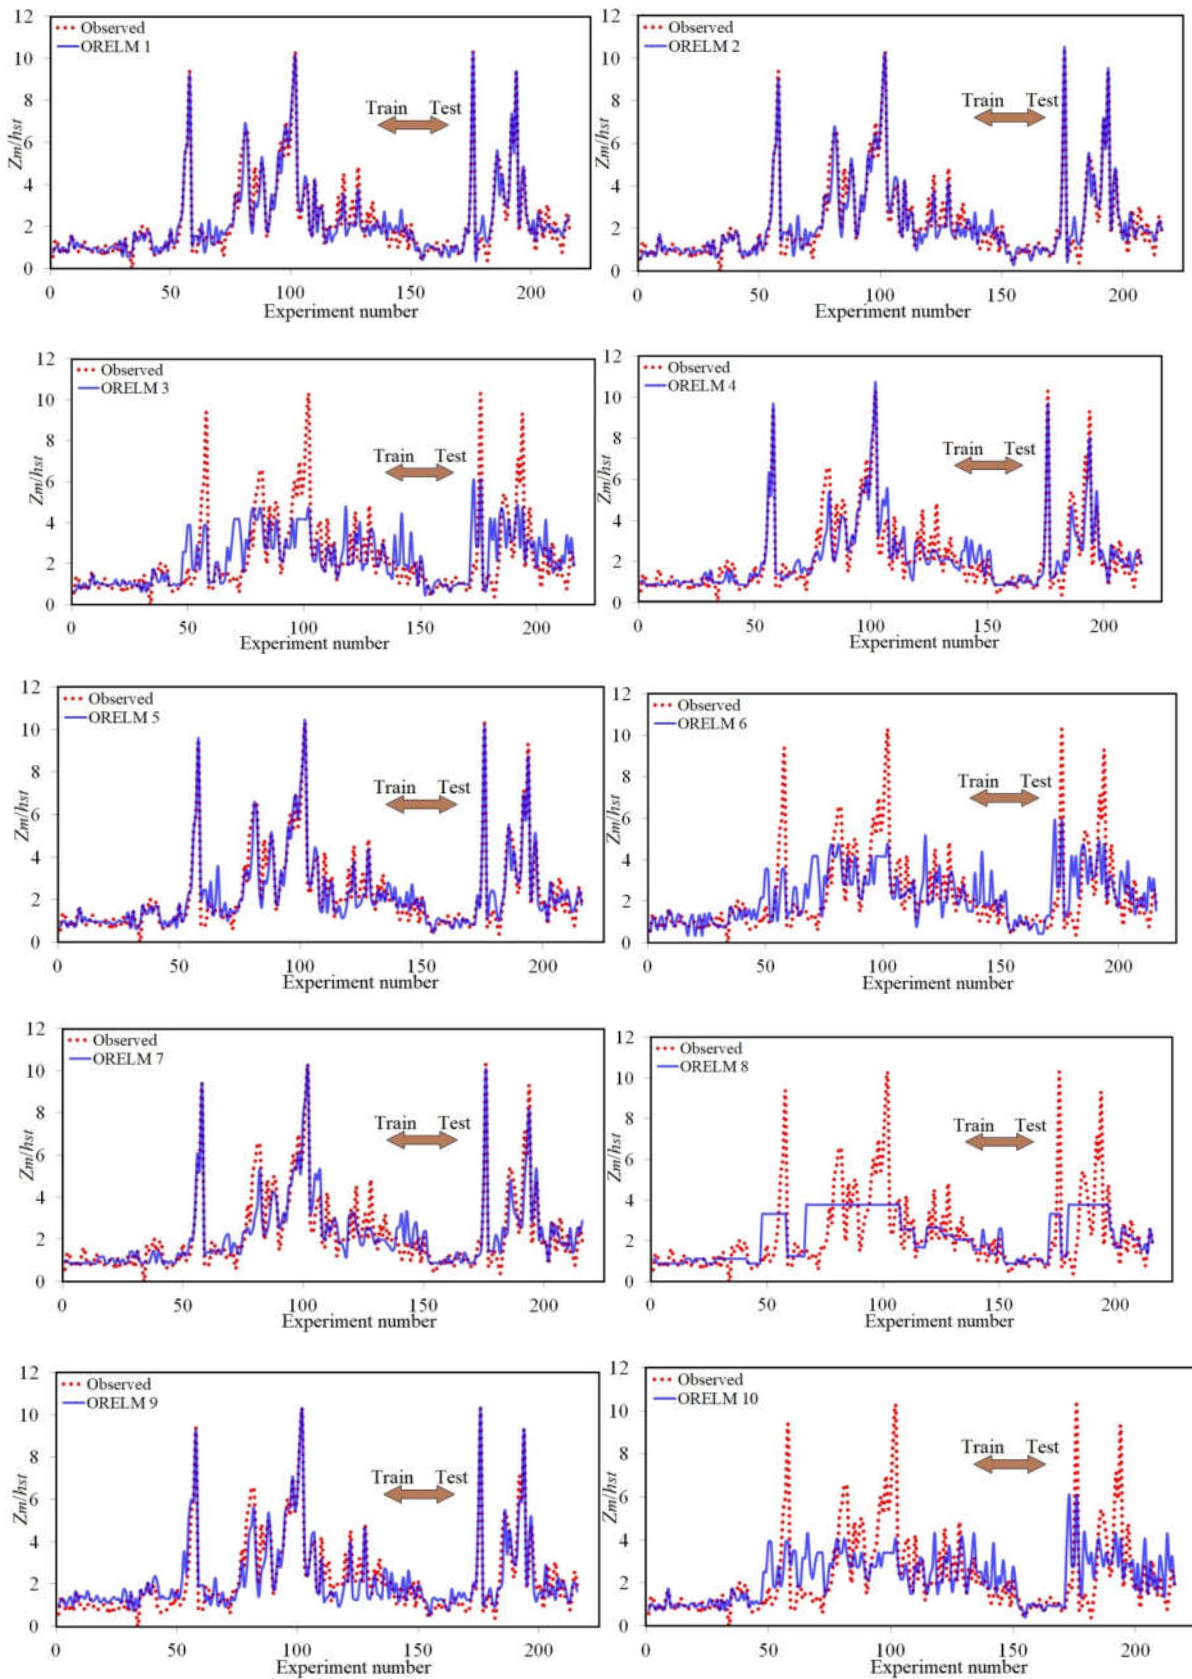
مدل 9 ORELM محاسبه می‌شوند. برای این مدل هوش مصنوعی مقادیر NSC، VAF و RMSE در وضعیت تست به ترتیب مساوی با ۰/۸۴۲، ۸۶/۴۳۲ و ۰/۷۲۳ بدست آمدند. مقادیر آبخستگی‌ها توسط مدل 10 ORELM توسط پارامترهای بدون بعد F_d, φ شبیه‌سازی می‌کند. برای مدل 10 ORELM مقادیر شاخص‌های آماری MAE، NSC و R در وضعیت آزمون به ترتیب مساوی با ۰/۹۸۲، ۰/۷۵۳- و ۰/۶۰۳ تخمین زده شدند. با توجه به نتایج شبیه‌سازی‌ها، مدل 10 ORELM دارای کمترین دقت در میان کلیه مدل‌های هوش مصنوعی است. مقادیر RMSE، MAE و R برای مدل 11 ORELM در شرایط تست به ترتیب مساوی با ۰/۹۵۸، ۰/۷۱۱ و ۰/۸۶۵ محاسبه شدند.

در شکل ۴ نیز مقایسه بین مقادیر آبخستگی‌های مشاهداتی و شبیه‌سازی شده توسط مدل‌های ORELM نشان داده شده است. همان‌طور که نشان داده شد، مدل 2 ORELM به‌عنوان بهترین مدل ماشین یادگیری که مقادیر تابع هدف را با بیشترین دقت و کمترین خطا تخمین زد معرفی می‌شود. در مقابل مدل 10 ORELM بدترین عملکرد را در میان مدل‌های هوش مصنوعی تعریف شده در این مطالعه از خود به نمایش گذاشت. بنابراین، با توجه به نتایج مدل‌های عددی، مدل 2 ORELM به‌عنوان مدل برتر شناسایی می‌شود. این مدل مقادیر تابع هدف را توسط پارامترهای بدون بعد $b/B, F_d, \Delta y/h_{st}$ تخمین زد. لازم به ذکر است که پارامترهای بدون بعد $b/B, \Delta y/h_{st}$ مهمترین پارامترهای ورودی شناسایی شدند.

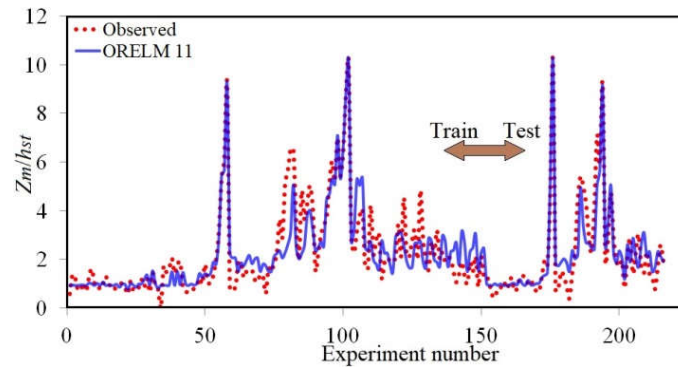
مقایسه با ELM

در این قسمت نتایج مدل 2 ORELM که به‌عنوان مدل برتر شناسایی شد، با مدل ELM مقایسه می‌شود. نمودارهای پراکندگی هر دو مدل برای وضعیت‌های آموزش و تست در شکل ۵ نشان داده شده است. بر اساس نتایج بدست آمده، مدل هوش مصنوعی ORELM دارای عملکرد بهتری در مقایسه با مدل ELM است. برای نمونه، مقادیر VAF برای مدل

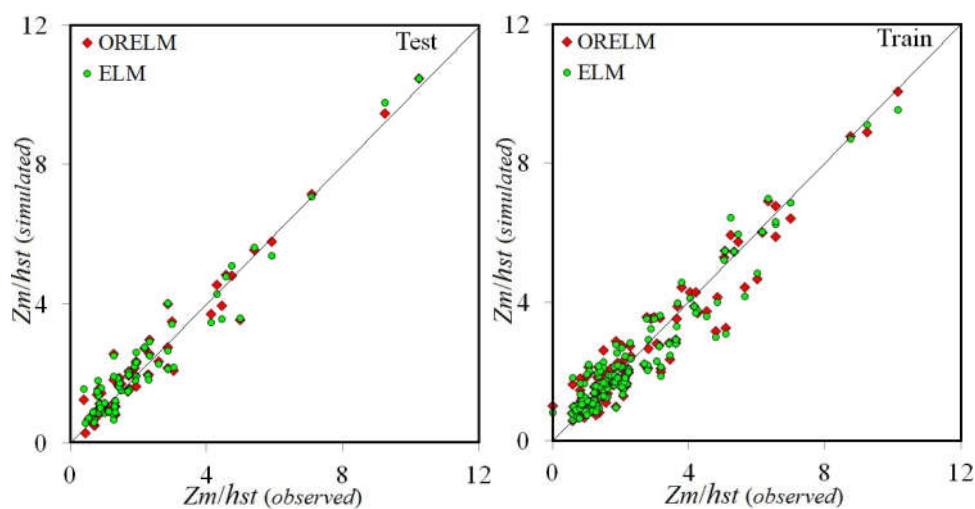
شرایط آموزش مقادیر SI، MAE و RMSE به ترتیب برابر ۰/۲۱۹، ۰/۳۷۴ و ۰/۴۹۸ هستند. در مقابل، مقادیر R، NSC و VAF برای مدل 2 ORELM در وضعیت تست به ترتیب مساوی با ۰/۹۵۶، ۰/۹۰۸ و ۹۱/۳۷۸ محاسبه شدند. گفتنی است که در میان کلیه مدل‌های ORELM، مدل 2 ORELM دارای کمترین خطا و بیشترین همبستگی با مقادیر آزمایشگاهی است. علاوه بر این، مدل 3 ORELM مقادیر عمق آبخستگی‌ها را بر حسب پارامترهای $b/B, F_d, \varphi$ مدل‌سازی می‌نماید. برای مدل هوش مصنوعی مذکور شاخص‌های آماری MAE، RMSE و NSC در وضعیت تست به ترتیب مساوی با ۱/۰۴۱، ۱/۴۹۴ و ۰/۵۱۷- تخمین زده شدند. همچنین، مدل 4 ORELM مقادیر تابع هدف را به‌وسیله پارامترهای ورودی شامل $b/B, \Delta y/h_{st}, \varphi$ مدل‌سازی می‌کند. برای مدل 4 ORELM شاخص‌های آماری VAF، SI و R در وضعیت آموزش به ترتیب مساوی با ۸۱/۹۵۱، ۰/۳۴۷ و ۰/۹۰۵ محاسبه شدند. این درحالیست که مدل 5 ORELM مقدار آبخستگی‌ها را توسط $F_d, \Delta y/h_{st}, \varphi$ تخمین می‌زند. برای مدل 5 ORELM در وضعیت تست، مقادیر شاخص‌های آماری NSC، RMSE و SI به ترتیب برابر با 6.1×10^{-1} ، ۰/۸۸۷ و ۰/۲۳۱ بدست آمده‌اند. همچنین، مقادیر تابع هدف توسط مدل 6 ORELM با استفاده از پارامترهای $b/B, F_d$ شبیه‌سازی می‌کند. مقادیر R، MAE و VAF برای مدل 6 ORELM در شرایط تست به ترتیب مساوی با ۰/۶۲۱، ۱/۰۶۳ و ۳۸/۵۳۶ هستند. در مقابل، مدل 7 ORELM مقادیر آبخستگی در مجاورت سرریزهای سنگی را توسط پارامترهای $b/B, \Delta y/h_{st}$ شبیه‌سازی می‌نماید. برای وضعیت آموزش مدل 7 ORELM، مقادیر VAF، SI و NSC به ترتیب برابر با ۷۷/۵۲۹، ۰/۳۴۳ و ۰/۷۰۹ برآورد شدند. علاوه بر این، مدل 8 ORELM مقادیر آبخستگی‌ها را توسط پارامترهای بدون بعد $b/B, \varphi$ محاسبه می‌نماید که مقادیر RMSE، MAE و VAF برای این مدل در شرایط آموزش به ترتیب مساوی ۱/۴۵۳، ۰/۹۱۳ و ۳۸/۴۷۱ محاسبه شدند. با استفاده از پارامترهای بدون بعد $F_d, \Delta y/h_{st}$ مقادیر تابع هدف توسط



شکل ۴: مقایسه مقادیر آبشستگی شبیه‌سازی شده توسط مدل‌های مختلف ORELM (رنگی در نسخه الکترونیکی)



ادامه شکل ۴



شکل ۵. نمودارهای پراکنده برای ORELM و ELM (رنگی در نسخه الکترونیکی)


تحلیل حساسیت

در این قسمت تحلیل حساسیت مدل‌های ORELM و ELM انجام می‌شود. تحلیل عدم قطعیت برای سنجش خطای پیش‌بینی شده توسط مدل‌های عددی و بررسی نحوه عملکرد این مدل‌ها اجرا می‌شود. به‌طور کلی خطای پیش‌بینی شده توسط مدل عددی برابر است با مقادیر شبیه‌سازی شده توسط مدل عددی (P_i) منهای مقادیر مشاهداتی (O_i) است به صورت $(e_i = P_i - O_i)$. همچنین، میانگین خطای پیش‌بینی شده به صورت $\bar{e} = \sum_{i=1}^n e_i$ محاسبه می‌شود. همچنین، انحراف استاندارد مقادیر خطای پیش‌بینی شده به صورت $S_e = \sqrt{\sum_{i=1}^n (e_i - \bar{e})^2 / n - 1}$ می‌باشد. گفتنی است که

در شرایط آموزش به‌ترتیب مساوی با R ORELM و ELM هستند. همچنین مقادیر شاخص‌های آماری، NSC و RMSE برای مدل ELM در شرایط تست به‌ترتیب برابر با ۰/۹۳۸، ۰/۴۹۸ و ۰/۹۳۴ بدست آمده‌اند. گفتنی است که مقدار SI برای ORELM و ELM در شرایط تست به‌ترتیب برابر با ۰/۲۱۲ و ۰/۲۲۴ بدست آمدند. الگوریتم ORELM در مقایسه با مدل کلاسیک ELM مقادیر آبهستگی‌ها را با دو درصد همبستگی بیشتر شبیه‌سازی کرد. این درحالیست که مدل ORELM مقادیر تابع هدف را با تقریباً ۸ درصد خطای کمتر در مقایسه با مدل ساده ELM پیش‌بینی کرد.

جدول ۱. پارامترهای تحلیل عدم قطعیت مدل‌های ELM و ORELM

Model	Number of samples	\bar{e}	S_e	WUB	95% PEI
ORELM	216	1.131E-05	0.499	-0.067	-0.0669 to 0.0669
ELM	216	-1.130E-05	0.527	-0.071	-0.0707 to 0.0707



شکل ۶. نتایج PDSA برای مدل برتر

WUB برای مدل‌های ORELM و ELM به ترتیب مساوی با $-0/067$ و $-0/071$ بدست آمده‌اند.

تحلیل حساسیت مشتق نسبی

در این قسمت به اجرای تحلیل حساسیت مشتق نسبی (PDSA) (Partial derivative sensitivity analysis) برای مدل برتر (ORELM 2) و ارزیابی پارامترهای ورودی پرداخته می‌شود. به‌طور کلی، PDSA یکی از مهم‌ترین روش‌ها برای شناسایی الگوی تغییرات پارامترهای ورودی است. گفتنی است که PDSA مثبت به معنای افزایش تابع هدف (آبشستگی) است و در مقابل منفی بودن آن به معنی کاهش یافتن مقدار خروجی است. در این تحلیل، مشتق نسبی هر پارامتر ورودی نسبت تابع هدف محاسبه می‌شود (۳). به بیان دیگر مشتق نسبی $f(x)$ برای هر متغیر ورودی محاسبه می‌شود و در شکل ۶ قابل مشاهده است. همان‌طور که در بخش‌های قبل بیان شد، مدل ORELM 2 مقادیر آبشستگی‌ها را بر حسب

منفی بودن مقدار \bar{e} نشان می‌دهد که مدل عددی دارای عملکردی کمتر از مقادیر واقعی است و مثبت بودن \bar{e} به معنای عملکردی بیشتر از واقعی، مدل عددی است. همچنین، با استفاده از پارامترهای \bar{e} و S_e یک باند اطمینان در اطراف مقادیر خطای پیش‌بینی ایجاد می‌شود. سپس با استفاده از $\pm 1.96S_e$ به صورت تقریبی منجر به 95% باند اطمینان می‌شود که با 95% PEI نشان داده می‌شود (۴). پارامترهای تحلیل عدم قطعیت مدل‌های برتر در جدول ۱ مرتب شده‌اند. در این جدول، عرض باند عدم قطعیت با WUB نشان داده می‌شود. با توجه به نتایج تحلیل عدم قطعیت، مدل ORELM دارای عملکردی بیشتر از مقادیر واقعی و مدل ELM عملکردی کمتر از مقادیر واقعی دارد. گفتنی است که WUB برای مدل‌های ORELM و ELM به ترتیب مساوی با -0.0669 و -0.0707 است. عرض باند عدم قطعیت محاسبه شده برای مدل ORELM باریکتر از مدل ELM تخمین زده شده است. به بیان دیگر مقادیر

و مؤثرترین پارامترهای ورودی معرفی شدند. مدل برتر ORELM مقادیر تابع هدف را با دقت مناسبی تخمین زد. برای نمونه، مقادیر RMSE، SI و NSC برای شرایط تست به ترتیب مساوی با ۰/۵۶۱، ۰/۲۱۲ و ۰/۹۰۸ تخمین زده شدند. همچنین، پارامترهای نسبت طول سازه به عرض کانال (b/B) و نسبت اختلاف عمق جریان بالادست و پائین دست سازه به ارتفاع سازه ($\Delta y/h_{st}$) به عنوان مؤثرترین پارامترهای ورودی معرفی شدند. نتایج مدل ORELM با ELM نیز مقایسه شد که مدل ORELM دقت بیشتری داشت. با انجام یک تحلیل حساسیت نحوه عملکرد مدل برتر مشخص شد و تحلیل حساسیت مشتق نسبی نشان داد که با افزایش مقدار پارامترهای ورودی $F_d, \Delta y/h_{st}$ مقدار PDSA با کاهش همراه شد.

برای افزایش شبیه سازی کرد. برای نمونه، با افزایش مقدار پارامترهای ورودی $F_d, \Delta y/h_{st}$ مقدار PDSA با کاهش همراه است. علاوه بر این، برای $F_d, \Delta y/h_{st}$ مقادیر PDSA مثبت بدست آمده اند. درحالی که بیشتر PDSA محاسبه شده برای پارامتر ورودی b/B دارای علامت مثبت هستند.

نتیجه گیری

در این مطالعه برای اولین بار با استفاده از یک مدل هوش مصنوعی نوین تحت عنوان ماشین آموزش نیرومند خارج از محدوده (ORELM) عمق آبستنگی در پائین دست سرریزهای سنگی با شکل های مختلف از جمله U، I، و W شبیه سازی شد. در ابتدا، داده های آزمایشگاهی به دو دسته آموزش و تست تقسیم شدند. در ادامه، کلیه پارامترهای اثرگذار بر روی عمق حفره آبستنگی شناسایی شدند و با استفاده از آنها یازده مدل ORELM تعریف شد. با انجام یک تحلیل حساسیت، مدل برتر

منابع مورد استفاده

1. Azimi, A. H., S. Shabanlou, F. Yosefvand, A. Rajabi and B. Yaghoubi. 2020. Estimation of scour depth around cross-vane structures using a novel non-tuned high-accuracy machine learning approach. *Sādhanā* 45(1): 1-10.
2. Azimi, H. and H. Shiri. 2020. Dimensionless Groups of Parameters Governing the Ice-Seabed Interaction Process. *Journal of Offshore Mechanics and Arctic Engineering* 142(5): 051601.
3. Azimi, H. and H. Shiri. 2020. Ice-Seabed interaction analysis in sand using a gene expression programming-based approach. *Applied Ocean Research* 98: 102120.
4. Azimi, H. and H. Shiri. 2021. Sensitivity analysis of parameters influencing the ice-seabed interaction in sand by using extreme learning machine. *Natural Hazards* 106(3): 2307-2335.
5. Huang, G. B., Q. Y. Zhu and C. K. Siew. 2006. Extreme learning machine: theory and applications. *Neurocomputing* 70(1-3): 489-501.
6. Leopold, L. B., M. G. Wolman and J. P. Miller. 1964. *Fluvial Processes in Geomorphology*. WH Freeman and Co, San Francisco, USA.
7. Mahmoudi Kurdistani, S. and S. Pagliara. 2015. Scour characteristics downstream of grade-control structures: Log-vane and log-deflectors comparison. *In: World Environmental and Water Resources Congress, Austin, Texas*.
8. Pagliara, S., L. Hassanabadi and S. M. Kurdistani. 2015. Clear water scour downstream of log deflectors in horizontal channels. *Journal of Irrigation and Drainage Engineering* 141(9): 04015007.
9. Pagliara, S. and S. M. Kurdistani. 2013. Scour downstream of cross-vane structures. *Journal of Hydro-Environment Research* 7(4): 236-242.
10. Pagliara, S. and S. M. Kurdistani. 2017. Flume experiments on scour downstream of wood stream restoration structures. *Geomorphology* 279: 141-149.
11. Pagliara, S., S. M. Kurdistani and L. Cammarata. 2013. Scour of clear water rock W-weirs in straight rivers. *Journal of Hydraulic Engineering* 140(4): 06014002.
12. Pagliara, S., S. M. Kurdistani and I. Santucci. 2013. Scour downstream of J-Hook vanes in straight horizontal channels. *Acta Geophysica* 61(5): 1211-1228.
13. Pagliara, S., L. Sagvand Hassanabadi and S. Mahmoudi Kurdistani. 2015. Log-vane scour in clear water condition. *River Research and Applications* 31(9): 1176-1182.

14. Rosgen, D. L. 2001. The Cross-Vane, W-Weir and J-Hook Vane Structures Their Description, Design and Application for Stream Stabilization and River Restoration. *In: Wetlands Engineering and River Restoration Conference*, Reno, Nevada, United States.
15. Scurlock, S., C. I. Thornton and S. R. Abt. 2011. One-dimensional modeling techniques for energy dissipation in U-weir grade-control structures. *In: Proceedings of the 2011 World Environmental and Water Resources Congress*, American Society of Civil Engineers, California, USA.
16. Scurlock, S. M., C. I. Thornton and S. R. Abt. 2011. Equilibrium scour downstream of three-dimensional grade-control structures. *Journal of Hydraulic Engineering* 138(2): 167-176.
17. Scurlock, S. M., A. L. Cox, C. I. Thornton and D. C. Baird. 2012. Maximum velocity effects from vane-dike installations in channel bends. *In: ASCE Congress World Environmental and Water Resources*, Albuquerque, New Mexico, United States.
18. Zhang, K. and M. Luo. 2015. Outlier-robust extreme learning machine for regression problems. *Neurocomputing*, 151: 1519-1527.

Simulation of Scour Pattern Around Cross-Vane Structures Using Outlier Robust Extreme Learning Machine

A. H. Azimi, S. Shabanlou*, F. Yosefvand, A. Rajabi and B. Yaghoubi¹

(Received: December 7-2020; Accepted: May 15-2021)

Abstract

In this research, the scour hole depth at the downstream of cross-vane structures with different shapes (i.e., J, I, U, and W) was simulated utilizing a modern artificial intelligence method entitled "Outlier Robust Extreme Learning Machine (ORELM)". The observational data were divided into two groups: training (70%) and test (30%). Then, using the input parameters including the ratio of the structure length to the channel width (b/B), the densimetric Froude number (F_d), the ratio of the difference between the downstream and upstream depths to the structure height ($\Delta y/h_{st}$), and the structure shape factor (φ), eleven different ORELM models were developed for estimating the scour depth. Subsequently, the superior model and also the most effective input parameters were identified through the conduction of uncertainty analysis. The superior model simulated the scour values by the dimensionless parameters b/B , F_d , $\Delta y/h_{st}$. For this model, the values of the correlation coefficient (R), the variance accounted for (VAF), and the Nash-Sutcliffe efficiency (NSC) for the superior model in the test mode were obtained 0.956, 91.378, and 0.908, respectively. Also, the dimensionless parameters b/B and $\Delta y/h_{st}$ were detected as the most effective input parameters. Furthermore, the results of the superior model were compared with the extreme learning machine model and it was concluded that the ORELM model was more accurate. Moreover, an uncertainty analysis exhibited that the ORELM model had an overestimated performance. Besides, a partial derivative sensitivity analysis (PDSA) model was performed for the superior model.

Keywords: Cross-vane structures, Scour, Outlier robust extreme learning machine, Uncertainty analysis, Partial derivative sensitivity analysis

1. Department of Water Engineering, Faculty of Agriculture, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

*: Corresponding author, Email: saeid.shabanlou@gmail.com