

کاربرد مدل‌های SVR و GRNN در تخمین حد اکثر عمق فرسایش در شرایط بستر متحرک در تلاقی رودخانه‌ها*

بهنام بلوجی^(۱) محمد رضا نیکو^(۲) محمود شفاعی بجستان^(۳) مریم دهقانی^(۴)

چکیده تلاقی رودخانه‌ها یکی از پیچیده‌ترین مکان‌ها در سیستم رودخانه‌ها می‌باشد که در تیجه آن، پیش‌بینی حد اکثر عمق آب‌شستگی (D_s) با استفاده از مدل‌های هوشمند که قادر به لحاظ این پیچیدگی‌ها می‌باشد امری مهم و ضروری می‌باشد. بنابراین در تحقیق حاضر، عملکرد دو مدل هوش مصنوعی به نام‌های SVR (با لحاظ روش‌های اعتبارسنجی مختلف، شامل *K-Fold train-test* و *K-Fold leave-one-out*) و GRNN مورد بررسی قرار گرفته است. نتایج حاصل نشان دادند که اگرچه تمام مدل‌ها در پیش‌بینی D_s دقیق‌ترین خوبی دارند؛ اما مدل SVR با روش اعتبارسنجی *train-test* دقیق‌تری را نشان می‌دهد (به ترتیب با $R^2 = 0.9566$ ، $MAE = 0.0124$ ، $MARE = 4.26$ ، $RMSE = 0.0168$ و $NSE = 0.993$)، و بعد از آن به ترتیب مدل‌های SVR *K-Fold*، SVR *leave-one-out* (در $K=9$) و مدل GRNN را می‌توان به عنوان دقیق‌ترین مدل‌ها در این تحقیق پیشنهاد نمود.

واژه‌های کلیدی تلاقی رودخانه‌ها، شرایط بستر متحرک، مدل SVR، روش‌های اعتبارسنجی، مدل GRNN.

Application of SVR and GRNN Models in Estimating Maximum Scour Depth at River Confluences under Live-Bed Condition

B. Balouchi

M. R. Nikoo

M. Shafai Bajestan

M. Dehghani

Abstract River confluences are one of the most complex places in river systems, that it is important to predict the maximum scour depth (D_s) at this place using intelligent systems that consider this complexity. Therefore, in this study, the performance of two artificial intelligence models, namely, SVR (considering different validation techniques including *train-test*, *K-Fold* and *leave-one-out*) and GRNN was evaluated. Results showed that, although all models show approximately good accuracy in predicting the D_s ; but, SVR with *train-test* validation method shows more accuracy (with R^2 , MAE , $MARE$, $RMSE$ and NSE of 95.66, 0.0124, 4.26, 0.0168 and 0.993, respectively), and after that SVR *K-Fold* (at $K=9$), SVR *leave-one-out*; and GRNN are the accurate models in this study, respectively.

Key Words River Confluences, Live-Bed Condition, SVR, Validation Methods, GRNN.

* تاریخ دریافت مقاله ۹۳/۱۱/۱ و تاریخ پذیرش آن ۹۵/۸/۲۶ می‌باشد.

(۱) دانشجوی دکتری عمران-آب، دانشکده مهندسی، دانشگاه شیراز.

(۲) نویسنده مسئول: استادیار، بخش مهندسی عمران و محیط زیست، دانشکده مهندسی، دانشگاه شیراز.

(۳) استاد، بخش سازه‌های هیدرولیکی، دانشکده مهندسی آب، دانشگاه شهید چمران، اهواز.

(۴) استادیار، بخش مهندسی عمران و محیط زیست، دانشکده مهندسی، دانشگاه شیراز.

آزمایش بر روی یک فلوم بسیار کوچک آزمایشگاهی به شکل ۷ به بررسی عوامل مؤثر بر حداکثر عمق فرسایش در محل تلاقی پرداخت. نامبرده نشان داد بیشترین عمق آبستنگی زمانی اتفاق می‌افتد که دبی کanal‌های بالا درست تلاقی یکسان باشد. بست (۱۹۸۸) به بررسی انتقال رسوب و رابطه آن با مورفولوژی بستر در محل تلاقی رودخانه‌ها با استفاده از نتایج فلوم آزمایشگاهی و اندازه‌گیری صحرایی پرداخت [23]. ایشان به این نتیجه رسید که با افزایش زاویه اتصال تلاقی حداکثر عمق آبستنگی افزایش می‌یابد. به‌منظور بررسی تغییر اندازه کanal در محل اتصال رودخانه‌ها با بستر درشت‌دانه، روی و روی (۱۹۸۸) اندازه‌گیری‌هایی بر روی ۳۰ محل اتصال در یک حوضه آبریز انجام دادند [24]. داده‌های اندازه‌گیری شده توسط آنها همراه با داده‌های جمع‌آوری شده از تحقیقات قبلی نشان داد که ظرفیت کلی کanal (سطح مقطع عبور جریان) در پایین‌دست بیشتر اتصال‌ها کاهش می‌یابد که دلیل آن را ناشی از افزایش سرعت جریان در محل اتصال دانستند. برقی و نظری (۱۳۸۲) به‌منظور بررسی الگوی رسوب و فرسایش در تقاطع کanal‌ها و اثر متغیرهایی چون قطر متوسط مصالح بستر، نسبت عرض کanal فرعی به اصلی و نسبت دبی کanal فرعی به دبی کل بر این الگو، آزمایش‌هایی را روی یک اتصال ۹۰ درجه انجام دادند [۲۵].

نتایج آزمایش‌ها نشان داد که حداکثر عمق آبستنگی در ابتدای ناحیه جداسدگی جریان اتفاق می‌افتد و حداکثر عمق آبستنگی با کاهش قطر متوسط مصالح بستر، کاهش نسبت دبی کanal اصلی به دبی کل و هم‌چنین کاهش عرض شاخه فرعی افزایش می‌یابد. از جمله محققان دیگری که به بررسی الگوهای فرسایش و رسوب‌گذاری در محل تلاقی رودخانه‌ها با استفاده از مدل فیزیکی پرداختند، قبادیان و شفاعی بجستان (۲۰۰۷) [26] می‌باشند. ایشان با انجام آزمایش‌های مختلف، تأثیر عواملی چون نسبت دبی کanal فرعی به دبی کل، نسبت پهنای کanal فرعی به

مقدمه

رودخانه‌ها مهم‌ترین منبع زندگی بشر می‌باشند. از این‌رو بررسی و شناخت عوامل تغییردهنده شکل و مورفولوژی رودخانه‌ها بسیار حائز اهمیت است. تلاقی رودخانه‌ها به‌دلیل شکل‌گیری جریان سه‌بعدی دارای الگوی جریان و رسوب بسیار پیچیده می‌باشد. این پیچیدگی تحت تأثیر متغیرهای هیدرولیکی و هندسی تلاقی رودخانه می‌باشد. از این‌رو در سال‌های اخیر بررسی و شناخت این متغیرها بسیار مورد توجه محققان قرار گرفته است. به‌منظور شناخت تأثیر متغیرهای مؤثر بر پیچیدگی الگوی رسوب و جریان در تلاقی رودخانه‌ها، تاکنون تحقیقات مختلفی انجام شده است. تحقیق پیرامون هیدرولیک جریان در تلاقی رودخانه‌ها، حدود هفت دهه پیش توسط تیلور (۱۹۴۴) انجام شد [1]. ایشان به بررسی تغییرات سطح آب در یک تلاقی رودخانه با دو زاویه ۴۵ و ۱۳۵ درجه پرداخت. از جمله مطالعات آزمایشگاهی انجام‌شده بر روی خصوصیات جریان و بدون حضور رسوب می‌توان به مطالعات ویراکون (۱۹۶۶) [2]، مودی و همکاران (۱۹۸۱) [3]، و گرتید (۱۹۶۶) [4]، بست (۱۹۸۴) [5]، رامامورتی و همکاران (۱۹۸۸) [6]، هاگر (۱۹۸۹) [7]، گورام و همکاران (۱۹۹۷) [8]، سو و همکاران (a و b) [۹,10]، وب و همکاران (۲۰۰۱) [11] و برقی و همکاران (۲۰۱۴) [12]، لیوبیمووا و همکاران (۲۰۱۴) [13] و کوئلهو (۲۰۱۵) [14] اشاره نمود. مطالعات ویراکون (۱۹۹۱) [۱۵]، بربروک و همکاران (۲۰۰۱) [۱۶]، هوانگ و همکاران (۲۰۰۲) [۱۷]، شکیبانیا و همکاران (۲۰۱۰) [۱۸]، گشتینه و همکاران (۲۰۱۲) [۱۹]، بارانیا و همکاران (۲۰۱۳) [۲۰]، و شریفی‌پور و همکاران (۲۰۱۵) [۲۱] به کارایی مدل‌های ریاضی سه‌بعدی برای شبیه‌سازی جریان در محل تلاقی کanal‌های صلب و بدون حضور رسوب می‌پرداختند. از جمله تحقیقاتی که در زمینه الگوی رسوب و فرسایش در محل تلاقی رودخانه‌ها انجام شده است، می‌توان به تحقیقات موسلى (۱۹۷۶) [22] اشاره نمود. ایشان با

رسوب‌گذاری به طور قابل ملاحظه‌ای کاهش می‌یابد. به طوری که برای مثال در عدد فرود ذره ۲/۷۶ و نسبت دبی ۰/۲ مقدار عمق آبشنستگی در مقایسه با اتصال لبه تیز برای نسبت‌های شعاع ۰/۲۸، ۰/۵ و ۱ به ترتیب به مقدار ۴۰، ۶۸ و ۱۰۰ درصد کاهش داشته است. هم‌چنین ارتفاع تپه رسوب‌گذاری برای نسبت‌های شعاع فوق به ترتیب ۲۳، ۶۶ و ۱۰۰ درصد کاهش داشته است. هم‌چنین بلوچی (۱۳۹۱) به بررسی تأثیر آورد رسوب در شاخه اصلی بر حداکثر عمق آبشنستگی در تلاقی رودخانه‌ها پرداختند [۳۰]. نتایج این تحقیق نشان داد که در حالت بستر متحرک (حالته که بار بستر حرکت می‌کند و آورد رسوب ایجاد می‌شود)، حداکثر عمق آبشنستگی بعد از گذشت مدت زمانی به طور متناوب، کاهش و افزایش می‌یابد. با پر و خالی شدن متناوب چاله فرسایشی به وسیله آورد رسوب بالادست، حداکثر عمق فرسایش نهایی نسبت به شرایط بستر غیرمتحرک (بدون بار زنده یا آورد رسوب) کاهش می‌یابد. به طور کلی، با افزایش نسبت دبی رسوب به دبی شاخه اصلی، کاهش نسبت دبی شاخه فرعی به دبی کل و کاهش عدد فرود ذره پایاب، نسبت حداکثر عمق آبشنستگی به عرض کanal پایین دست تلاقی (D_s/B_3) کاهش می‌یابد. در شرایط حداکثر آورد رسوب شاخه اصلی تلاقی رودخانه‌ها، مقدار حداکثر عمق آبشنستگی نسبت به حالت حداقل آورد رسوب (بدون تزريق رسوب)، ۳۵ درصد کاهش می‌یابد. هم‌چنین ایشان نشان داد که توپوگرافی بستر ایجاد شده در شرایط بستر متحرک، در مقایسه با شرایط بدون آورد رسوب کاملاً متفاوت می‌باشد و تپه رسوبی نیز تشکیل نمی‌شود.

امروزه به دلیل کارایی بالای مدل‌های هوش مصنوعی نظری مدل‌های ماشین بردار پشتیبان (SVM) و شبکه‌های عصبی مصنوعی برای پیش‌بینی مسائل غیرخطی و پیچیده، محققان بسیاری استفاده از این سیستم‌های هوشمند را مد نظر قرار داده‌اند. از جمله تحقیقات مرتبطی که در زمینه استفاده از مدل‌های

کanal اصلی، زاویه اتصال و عدد فرود ذره در پایین دست اتصال بر روی فرسایش و رسوب‌گذاری را مورد بررسی قرار دادند. نتایج آزمایش‌ها نشان داد که افزایش نسبت دبی، کاهش نسبت پهنا و افزایش زاویه اتصال باعث افزایش حداکثر عمق فرسایش بستر و ارتفاع نهایی تپه رسوب‌گذاری می‌شود. در حالی که افزایش عدد فرود ذره در پایاب باعث افزایش حداکثر عمق فرسایش بستر و کاهش ارتفاع تپه رسوب‌گذاری می‌شود. شفاعی بجستان و همتی (۲۰۰۸) به منظور تأثیر پارامترهایی چون نسبت اختلاف رقوم بستر دو کanal به عرض کanal اصلی، نسبت عرض کanal فرعی به کanal اصلی، نسبت دبی کanal فرعی به دبی کل در تلاقی رودخانه‌ها آزمایش‌هایی را انجام دادند [۲۷]. نتایج ایشان نشان داد که با افزایش اختلاف رقوم بستر دو کanal در نسبت دبی‌های بیشتر از ۰/۷۴ حداکثر عمق فرسایش و تپه رسوب‌گذاری افزایش و هم‌چنین با افزایش نسبت دبی حداکثر عمق فرسایش و تپه رسوب‌گذاری افزایش می‌یابد. برگعی و جباری (۲۰۱۰) به منظور بررسی فرسایش موضعی در تقاطع کanal‌ها و تأثیر متغیرهایی چون زاویه تلاقی، نسبت عرض کanal فرعی به اصلی، نسبت دبی کanal فرعی به دبی کل و نسبت سرعت متوسط پایین دست تلاقی به سرعت آستانه پایین دست آزمایش‌هایی را انجام دادند [۲۸]. نتایج آزمایش‌ها نشان داد که موقعیت حداکثر عمق فرسایشی با گذشت زمان به سمت دیواره بیرونی کanal و بالادست کanal اصلی پیش‌روی می‌کند. هم‌چنین، با کاهش عرض شاخه فرعی، افزایش نسبت دبی و افزایش زاویه تلاقی عمق چاله فرسایشی افزایش می‌یابد. محمدی (۱۳۹۰) به بررسی تأثیر شعاع گردشگی لبه پایین دست اتصال بر حداکثر عمق آبشنستگی در تلاقی رودخانه‌ها پرداخت [۲۹]. ایشان با انتخاب سه شعاع گردشگی متفاوت (R) به این نتیجه دست یافت که با افزایش شعاع گردشگی لبه پایین دست اتصال حداکثر عمق آبشنستگی و ارتفاع تپه

آبشنستگی با استفاده از مدل ماشین‌های بردار پشتیبان پرداخته خواهد شد. هم‌چنین، در این تحقیق سعی شده است تا یک نوع شبکه عصبی که بسیار کم مورد توجه محققان قرار گرفته، به نام روش شبکه عصبی رگرسیونی تعمیم داده شده یا GRNN (Generalized Regression Neural Network) نیز تدوین گردد و عملکرد مدل ماشین بردار پشتیبان با آن قیاس گردد.

مواد و روش‌ها

در این تحقیق، از نتایج مطالعات آزمایشگاهی بلوجی (۱۳۹۱) [۳۰] به منظور آموزش و صحت‌سنجی مدل‌های هوش مصنوعی استفاده شده است. در شکل (۱) شماتیک تجهیزات مورد استفاده در این تحقیق نشان داده شده است. آب موجود در مخزن ذخیره آب به وسیله پمپی به مخزن تنظیم هد آب فرستاده می‌شود و سپس حجم آب مورد نیاز به وسیله شیرهای یک‌طرفه‌ای به سمت مخزن کanal اصلی و فرعی فرستاده می‌شود. پس از این‌که تلاطم آب در مخزن‌های اصلی و فرعی به وسیله صفحاتی مشبک گرفته شد، آب به آرامی وارد کanal‌های اصلی (با دبی Q₁) و کanal فرعی (با دبی Q₂) می‌گردد. طول کanal اصلی و فرعی به ترتیب ۲۶ نه و سه متر می‌باشد. پهنای کanal اصلی و فرعی ۲۶ سانتی‌متر در نظر گرفته شد. دبی کل ورودی به سیستم با استفاده از یک دستگاه دبی‌سنجد با دقت ۰/۰۱ لیتر در ثانیه اندازه‌گیری شد. علاوه بر این، سرریز مثلثی نصب شده در ابتدای کanal اصلی، وظیفه اندازه‌گیری دبی ورودی به کanal را برعهده دارد. یک دریچه کشویی در انتهای کanal اصلی نصب شد که با باز یا بسته نمودن آن می‌توان عمق پایاب را تنظیم نمود. در انتهای کanal اصلی نیز آب به وسیله لوله‌ای به مخزن ذخیره آب برمی‌گردد.

هوشمند انجام شده است می‌توان به کمبکار و دئو (۲۰۰۳) اشاره نمود که با استفاده از مدل‌های شبکه عصبی به پیش‌بینی حداکثر عمق فرسایش در اطراف شمع‌ها پرداخت [۳۱]. باطنی و همکاران (۲۰۰۷) کارایی سیستم استنتاج فازی (ANFIS) و شبکه عصبی را در پیش‌بینی عمق فرسایش در پایه پل‌ها بررسی نمودند [۳۲]. هم‌چنین عظمت الله‌ی (۲۰۰۸) [۳۳] تقریباً در تحقیقی مشابه با باطنی و همکاران (۲۰۰۷) به منظور پیش‌بینی عمق فرسایش در پایین‌دست سرریز اوجی پرداختند. عایدین (۲۰۱۰) [۳۴]، ایسماعیل و همکاران (۲۰۱۳) [۳۵] و چنگ و همکاران (۲۰۱۴) [۳۶] در بررسی‌هایی جداگانه و متفاوت به پیش‌بینی الگوی رسوب و عمق آبشنستگی اطراف پایه‌های پل پرداختند.

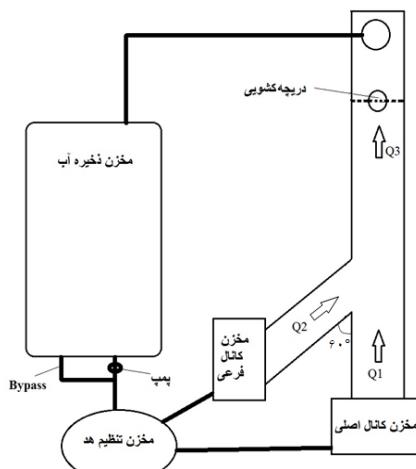
در زمینه کاربرد مدل‌های بردار پشتیبان نیز هونگ و همکاران (۲۰۱۲) [۳۷] و جهانگیرزاده و همکاران (۲۰۱۴) [۳۸]، به ترتیب به بررسی کارایی مدل ماشین پشتیبان بردار در تعیین ابعاد طوقه و عمق آبشنستگی اطراف پایه پل پرداختند. هم‌چنین پال و همکاران (۲۰۱۱) [۳۹]، و غضنفری هاشمی و اعتماد شهیدی (۱۳۹۱) در تحقیقات مختلفی به پیش‌بینی عمق آبشنستگی اطراف پایه پل با استفاده از مدل ماشین بردار پشتیبان پرداختند [۴۰]. هوشیاری‌پور (۱۳۹۲) با استفاده از تکنیک ماشین بردار پشتیبان به پیش‌بینی ابعاد چاله فرسایشی در پایین‌دست یک پرتتاب‌کننده جامی شکل پرداخت [۴۱].

مرور پیشینه مطالعات نشان‌دهنده این است که تاکنون بررسی کارایی مدل ماشین‌های بردار پشتیبان و شبکه‌های عصبی مصنوعی در تخمین حداکثر عمق آبشنستگی در تلاقی رودخانه‌ها در شرایط بستر متحرک انجام نشده است. از طرفی با توجه به بررسی منابع موجود این مدل‌ها نشان داده‌اند که کارایی خوبی در تخمین پارامترهای مهندسی رودخانه دارند. بنابراین در تحقیق حاضر به بررسی کارایی تخمین حداکثر عمق

در معادله (۱) Re عدد رینولدز، F_g عدد فرود ذره و W_e عدد ویر می‌باشد. سایر پارامترها نیز در بخش مقدمه توضیح داده شده‌اند. از آنجایی که در مدل کanal‌های باز ابعاد به‌گونه‌ای انتخاب می‌شوند که تأثیر نیروهای کششی سطحی و لرجه سیال بسیار کم است، بنابراین از تأثیر اعداد رینولدز و ویر صرف‌نظر شد. از طرفی، برای شرایط جریان زیر بحرانی نیز از تأثیر شیب کف بر عمق آب‌شستگی موضعی و ارتفاع رسوب‌گذاری در محل تلاقی نیز چشم‌پوشی شد (گورام و همکاران، ۱۹۹۷ [۸]). هم‌چنین، در این تحقیق زاویه تلاقی ثابت (۶۰ درجه)، عرض فلوم ثابت، اختلاف ارتفاع بین دو کف فلوم صفر، شعاع اتصال لبه پایین دست تلاقی ثابت و تیزگوش می‌باشد. درنهایت، پس از ساده‌سازی پارامترهای بی بعد رابطه زیر حاصل می‌شود:

$$\frac{D_s}{B_3} = f\left(\frac{Q_2}{Q_3}, \frac{Q_b}{Q_3}, F_g\right) \quad (2)$$

که در معادله بالا، D_s حداقل عمق آب‌شستگی و V_3 عدد فرود ذره پایاب ($V_3 = \frac{\sqrt{g(G_s - 1)d_{50}}}{\rho}$) سرعت جریان در پایین دست تلاقی و G_s چگالی ویژه ذرات رسوب برابر $2/65$ می‌باشد. در مطالعاتی که تاکنون انجام شده است به‌دلیل سختی و پیچیدگی کار، شرایط به‌گونه‌ای در نظر گرفته شده بود که در کanal‌های بالادست تلاقی حرکت بار بستر صورت نگیرد. بنابراین، از تأثیر عبارت Q_b صرف‌نظر شد. بنابراین هدف تحقیق بلوچی (۱۳۹۱) [۳۰]، بررسی تأثیر آورد رسوب شاخه اصلی (Q_b)، در شرایط مختلف هیدرولیکی بر روی حداقل عمق آب‌شستگی با استفاده از دستگاه تزریق رسوب طراحی و کالیبره شده، انتخاب گردید. جدول (۱) تحلیل آماری پارامترهای بی بعد مورد استفاده در این تحقیق را نشان می‌دهد؛ که در واقع پارامترهای ورودی و خروجی مدل‌های هوشمند می‌باشند (برای اطلاعات بیشتر به مرجع [۳۰] مراجعه شود).



شکل ۱ شماتیک تجهیزات آزمایشگاهی (اقتباس از [۳۰])

سپس به منظور پیدا کردن پارامترهای بی بعد مهم در این تحقیق، آنالیز ابعادی پارامترهای مؤثر در تلاقی رودخانه‌ها به روش π -باکینگهام انجام گردید. این پارامترها عبارتند از: Q_1 دبی کanal اصلی در بالادست تلاقی، Q_2 دبی کanal فرعی و Q_3 دبی کanal اصلی در پایین دست تلاقی، Y_3 عمق پایاب، g شتاب ثقل، μ ویسکوزیتۀ دینامیکی سیال، ρ جرم حجمی آب، s نیروی کشش سطحی، B_3 پهنای کanal اصلی در بالادست، B_2 پهنای کanal فرعی، B_3 پهنای کanal اصلی در پایین دست تلاقی، θ زاویه اتصال، S_0 شیب کف کanal در محل تلاقی و Z اختلاف رقوم بستر دو کanal، R شعاع اتصال لبه پایین دست، d_{50} اندازه متوسط ذرات رسوبی، ρ_s جرم مخصوص ذرات رسوب، σ انحراف معیار هندسی ذرات و φ زاویه ایستایی ذرات رسوب می‌باشد (بلوچی، ۱۳۹۱ [۲۴]). با تجزیه تحلیل و آنالیز ابعادی پارامترهای مؤثر در تلاقی رودخانه‌ها، روابط کلی شامل پارامترهای بدون بعد استخراج شد. رابطه (۱) این پارامترهای بی بعد را نشان می‌دهد:

$$\frac{D_s}{B_3} = f\left(\frac{Q_2}{Q_3}, \frac{Q_b}{Q_3}, \frac{B_1}{B_2}, \frac{B_3}{B_{50}}, \frac{y_3}{d_{50}}, \theta, S_0, \frac{\rho_s}{\rho}, W_e, \frac{\Delta Z}{B_2}, F_g, Re\right) \quad (1)$$

جدول ۱ تحلیل آماری پارامترهای بی بعد استفاده شده در تحقیق

شاخص‌های آماری					پارامتر
انحراف از معیار	میانگین	حداکثر	حداقل		
۰/۰۸	۰/۱۹۵	۰/۳	۰/۱		نسبت دبی (Q_r)
۱/۰۷	۰/۱۸	۰/۷	۰		نسبت آورد رسوپ (Q_b / Q_3)
۰/۱۲	۶/۷۲	۸/۲۲	۵/۰۴		عدد فرود ذره (F_g)
۰/۰۸	۰/۳۱۳	۰/۴۸۵	۰/۱۹۶		نسبت حداکثر عمق آبستگی ($\frac{D_s}{B_3}$)

به همراه وزن‌ها، بهینه‌سازی می‌شود. علاوه بر آن SVMs می‌توانند خروجی‌های احتمالاتی نیز داشته باشند. ماشین‌های بردار پشتیبانی، یک شیوه نسبتاً جدید و قدرتمند برای خوشه‌بندی (کلاس‌بندی) و تشخیص الگو می‌باشند (نیکو و کراچیان، ۱۳۸۹ [۴۲]).

در ساده‌ترین حالت ممکن کلاس‌بندی، ماشین‌های بردار پشتیبانی یک ابرصفحه جداساز خطی با حداکثر حاشیه (Maximum Margin) را جستجو می‌کند. در مواردی که کلاس‌های داده‌شده اطلاعات، در فضای ورودی اولیه به شکل خطی جداپذیر نیستند، در ابتدا ماشین‌های بردار پشتیبان فضای ورودی اولیه را به فضای مشخص با ابعاد بالاتر تبدیل می‌کنند. این تبدیل می‌تواند توسط توابع تصویرکننده (توابع کرنل) مختلف غیرخطی مانند توابع RBF (Radial Basis Function) انجام شود. پس از مرحله تبدیل غیرخطی، ماشین‌های بردار پشتیبان در این فضای مشخص جدید یک ابرصفحه جداساز خطی بهینه (با حداکثر حاشیه) را جستجو می‌کنند. ماشین‌های بردار پشتیبان رگرسیونی (SVR) زیرمجموعه‌ای از ماشین‌های بردار پشتیبان (SVM) هستند که در آنها مسئله اولیه زیر حل می‌شود:

$$\text{Min } \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n \xi_i \quad (3)$$

با توجه به محدودیت:

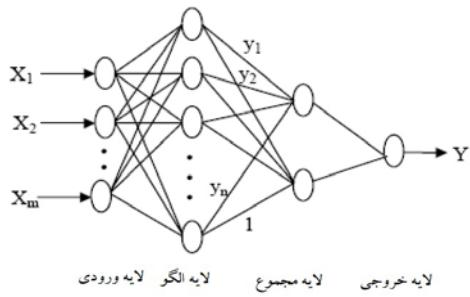
$$\begin{aligned} \xi_i &\geq 0, \quad i = 1, \dots, n \\ y_i (\mathbf{w}^T \varphi(\mathbf{x}_i) + b) &\geq 1 - \xi_i \end{aligned} \quad (4)$$

در تحقیق حاضر با استفاده از داده‌های آزمایشگاهی تحقیق بلوجی (۱۳۹۱) [۳۰] مدل‌های ماشین‌های بردار پشتیبان و شبکه عصبی رگرسیونی تعمیم داده شده (GRNN) برای پیش‌بینی حداکثر عمق آبستگی در تلاقی رودخانه‌ها در شرایط بستر متحرک مورد ارزیابی قرار گرفتند. لازم به ذکر است که در تحقیق حاضر نسبت $\frac{Q_2}{Q_3}$ نسبت دبی (Q_r)، نسبت آورد رسوپ و نسبت $\frac{D_s}{B_3}$ نسبت حداکثر عمق آبستگی نامیده شده‌اند.

مدل‌های هوشمند

مدل ماشین بردار پشتیبان رگرسیونی (SVR) برخلاف روش‌های نظری شبکه‌های عصبی مصنوعی که درجهت حداقل کردن خطای خطای (تجربی) طراحی شده‌اند، ماشین‌های بردار پشتیبان مبتنی بر حداقل کردن خطای ساختاری هستند. به عبارت ساده‌تر ساختار سیستم مانند شبکه‌های عصبی از ابتدا مشخص نمی‌باشد و در طول فرآیند آموزش علاوه بر حداقل سازی خطای (تجربی)، خطای ساختاری نیز حداقل می‌شود و بهینه‌ترین ساختار سیستم نیز تعیین می‌گردد. این ماشین‌ها دارای قدرت بالاتری نسبت به بقیه روش‌های یادگیری برای داده‌های غیرآموزشی (داده‌های آزمایش) می‌باشند. در مدل‌های کلاسیک مانند شبکه‌های عصبی مصنوعی، ساختار شبکه قبل از آموزش مشخص است و عملاً بهینه نمی‌شود ولی در مدل‌های SVM ساختار شبکه نیز

دارند. لایه الگو دارای n بعد است و محاسبات مربوط به تابع انتقال گوسین را انجام می‌دهد. لایه مجموع، مجموع n بعد لایه الگو می‌باشد و درنهایت نیز لایه خروجی، که خروجی مدل را می‌دهد (لی و همکاران، ۲۰۰۶). ([44]



شکل ۲ ساختار مدل GRNN

خروچی مدل شبکه عصبی رگرسیونی تعمیم یافته (y) از رابطه زیر به دست می‌آید (لی و همکاران، ۲۰۰۶): ([44]

$$y(x) = \frac{\sum_{i=1}^n y_i \exp(-D_i^2 / 2\sigma^2)}{\sum_{i=1}^n \exp(-D_i^2 / 2\sigma^2)} \quad (8)$$

$$D_i^2 = (x - x_i)^T (x - x_i) \quad (9)$$

در این روابط D_i یک تابع اسکالر می‌باشد که در رابطه (9) تعریف شده است، σ پارامتر پخش (spread)، x ورودی متانظر با y ، x_i ورودی متناظر با y_i می‌باشد.

آموزش و صحت‌سنجی مدل‌ها

در این تحقیق، ابتدا با استفاده از ۷۰ درصد از داده‌های آزمایشگاهی موجود (۳۸ آزمایش)، مدل‌های شبکه عصبی رگرسیونی تعمیم یافته (GRNN) و ماشین بردار پشتیبان رگرسیونی (SVR) آموزش داده شدند. سپس، با استفاده از ۳۰ درصد دیگر داده‌ها، صحت‌سنجی مدل‌ها انجام گردید.

به دلیل وجود شرایط پیچیده در بخش آزمایشگاهی و در اختیار داشتن تعداد داده‌های آزمایشگاهی محدود؛

که مسئله دوگان آن برابر است با:

$$\text{Min } \frac{1}{2} \alpha^T Q \alpha - e^T \alpha \quad (5)$$

$$0 \leq \alpha_i \leq C, i = 1, \dots, l, \quad (6)$$

با توجه به محدودیت:

$$y^T \alpha = 0 \quad (7)$$

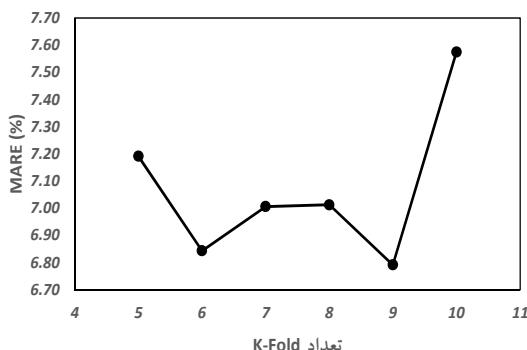
که در آن e برداری (ماتریسی) است که همه درایه‌های آن برابر ۱ هستند. $w \in \mathbb{R}^n$ بوده و α_i و C به ترتیب متغیرهای غیرمنفی کمبود (Variables Slack) و ضریب لاگرانژ می‌باشند. حد بالای α_i و $C > 0$ می‌باشد. Q یک ماتریس یک در یک مثبت نیمه‌معین می‌باشد، به طوری که $Q_{ij} \equiv y_i y_j K(x_i, x_j)$ و $K(x_i, x_j) \equiv \varphi(x_i)^T \varphi(x_j)$ تابع کرنل می‌باشد. در اینجا بردارهای آموزشی x_i ، توسط تابع φ به یک فضای داده با ابعاد بیشتر تصویر می‌شوند (نیکو و کراچیان، ۱۳۸۹ [۴۲]). در این روش مقادیر بهینه پارامترهای C ، α_i با سعی و خطاب منظور نیل به بهترین نتایج تعیین می‌گردند.

مدل شبکه عصبی رگرسیون تعمیم یافته (GRNN) شبکه عصبی رگرسیون تعمیم یافته (GRNN)، یک نوع از شبکه عصبی می‌باشد که به وسیله دونالد اسپیچ در سال ۱۹۹۱ مطرح شده است [43]. این نوع از شبکه‌های عصبی از سری شبکه‌های پیش‌رو با ناظر در آموزش هستند. این شبکه‌ها معمولاً برای تقریب توابع به کار می‌روند، و حساسیت کم‌تری نسبت به مسائل با ورودی‌های غیرایستادارند که به دلیل رفتار پایه شعاعی یکان پنهان آن است. این شبکه‌ها نیازی به آموزش مکرر ندارند. الگوریتم GRNN براساس نظریه رگرسیون غیرخطی بنا شده است. به جز روند آموزشی لایه دوم، بقیه نکات آن همچون روش RBF است. ساختار شبکه GRNN در شکل (۲) نشان داده شده است. به صورت خلاصه، این مدل دارای ۴ لایه می‌باشد: لایه ورودی، لایه الگو، لایه مجموع و لایه خروجی. لایه ورودی شامل بردارهای ورودی می‌باشد، که بعد

و همچنین مدل GRNN نشان می‌دهد. همان‌طور که در شکل (۴) نشان داده شده است، به‌طور کلی تمام مدل‌ها دقت تقریباً خوبی را نشان می‌دهند، اما با توجه به مقادیر R^2 برای مدل SVR (۰/۹۵۶۶) در مقایسه با سایر مدل‌ها به‌نظر می‌رسد که این مدل بهترین کارایی را از خود نشان می‌دهد. در ادامه با استفاده از شاخص‌های آماری، آزمون دقت‌سنجی مدل‌ها به‌طور کامل ارائه می‌شوند.

شکل (۵) مقایسه نتایج حاصل از مدل‌های هوشمند تحقیق حاضر را با نتایج داده‌های مشاهداتی در مقابل تعداد کل داده‌ها نشان می‌دهد. با توجه به این شکل نیز کاملاً مشخص است که مدل SVR عادی در قیاس با سایر مدل‌ها، هم خوانی خوبی با داده‌های مشاهداتی نشان می‌دهد.

در شکل (۵) به‌منظور قیاس هرچه بهتر دو گام آموزش و تست در دو مدل SVR و GRNN، داده‌های گام آموزش و تست نیز مشخص شده‌اند. هرچند بحث کم و بیش‌ شبیه‌سازی (بیش برازش) در خود مدل‌ها کنترل می‌شود، اما با توجه به شکل (۵) و مقایسه نتایج دو مدل SVR و GRNN با داده‌های مشاهداتی، مشخص هست که بیش‌ شبیه‌سازی و کم‌ شبیه‌سازی در مدل‌ها نیز صورت نگرفته است. در ادامه به صورت کمی، آنالیز دقت‌سنجی برای تمام مدل‌ها و همچنین گام آموزش و تست نشان داده خواهد شد.



شکل ۳ مقایسه نتایج مدل SVR با روش اعتبارسنجی K-Fold برای K های مختلف

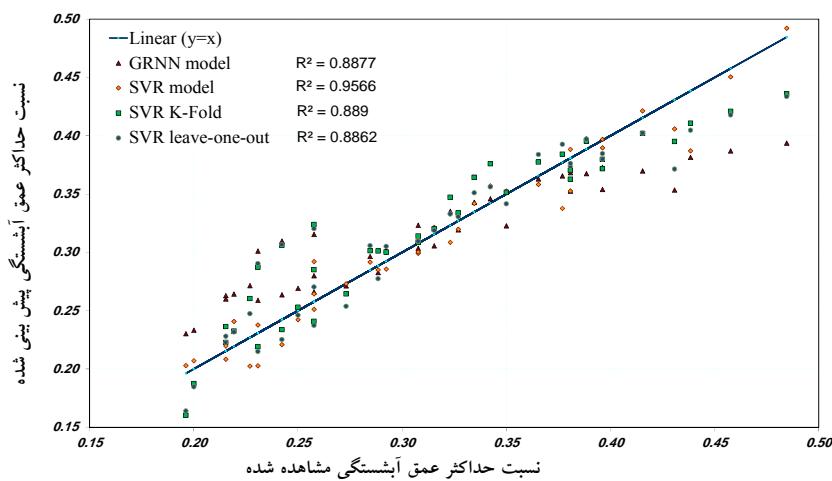
علاوه بر روش ذکرشده فوق برای مدل SVR، از روش K-Fold cross-validation (K-Fold) و روش leave-one-out نیز استفاده شده است. در روش K-Fold داده‌ها به K زیرمجموعه افزایش می‌شوند. از این K زیرمجموعه، هر بار یکی برای اعتبارسنجی و K-1 تای دیگر برای آموزش به کار می‌روند. این روال K بار تکرار می‌شود و همه داده‌ها دقیقاً یک‌بار برای آموزش و یک‌بار برای اعتبارسنجی به کار می‌روند. درنهایت، میانگین نتیجه این K بار اعتبارسنجی به عنوان یک تخمین نهایی برگزیده می‌شود. در روش leave-one-out در هر مرحله یکی از داده‌ها برای اعتبارسنجی بیرون گذاشته می‌شود و بقیه داده‌ها برای آموزش استفاده می‌شوند. این روش درواقع همان روش K-Fold است که در آن K برابر تعداد داده‌ها درنظر گرفته شده است [45].

لازم به ذکر است که در تمام روش‌ها، پارامترهای بی بعد عدد فرود ذره (F_g)، نسبت دبی (Q_r/Q_i) و نسبت آورد رسوب (Q_b/Q_3) به عنوان ورودی مدل‌ها؛ و پارامتر بی بعد نسبت حداکثر عمق آبستگی (D_s/B_3) به عنوان خروجی مدل‌ها درنظر گرفته شده است.

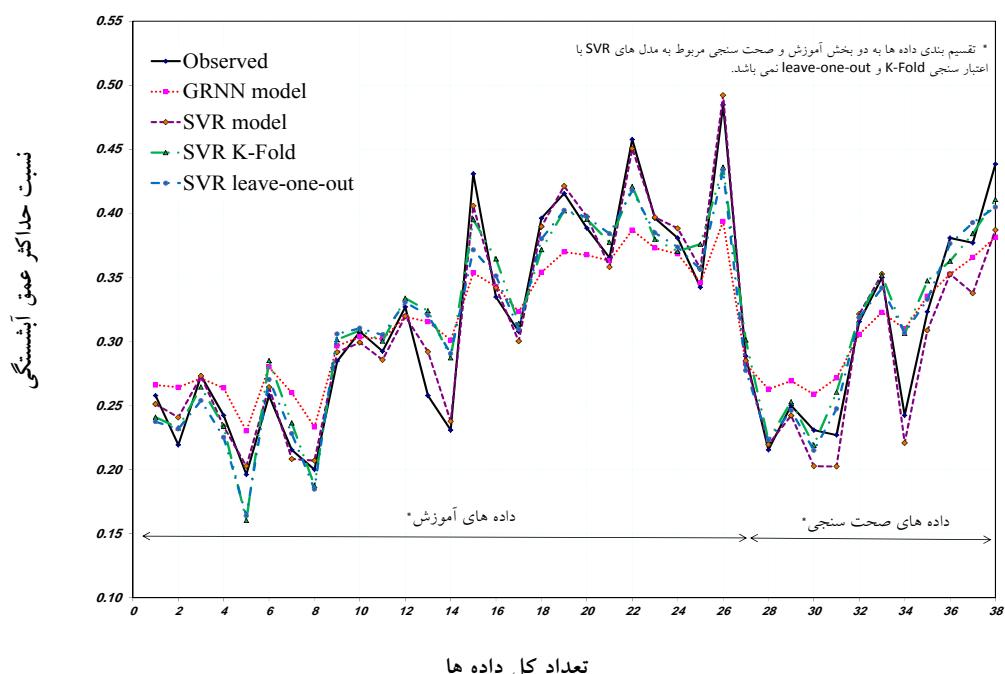
نتایج و بحث

شکل (۳) نتایج شاخص MARE (Mean Absolute Error) را برای مدل SVR با روش اعتبارسنجی K-Fold برای K های مختلف نشان می‌دهد. با توجه به این شکل، نتایج در $K=9$ بهترین عملکرد را نشان می‌دهند ($MARE=6.79$). بنابراین می‌توان مدل آموزش داده شده به ازای $K=9$ را به عنوان برترین مدل SVR در روش اعتبارسنجی K-Fold معرفی نمود و در ادامه نتایج آن را با سایر روش‌ها مقایسه کرد.

شکل (۴) مقایسه نسبت حداکثر عمق آبستگی مشاهده شده با پیش‌بینی شده را برای مدل‌های SVR با اعتبارسنجی عادی (train-test)، K-Fold و leave-one-



شکل ۴ مقایسه نسبت حداکثر عمق آبستینگی مشاهده شده با پیش‌بینی شده



شکل ۵ مقایسه عملکردهای مدلها در مقابل تعداد کل داده‌ها

این شاخص‌ها از آنها به دست می‌آیند در ادامه نشان داده شده است:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i \text{ observed} - Y_i \text{ estimated})^2} \quad (10)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i \text{ observed} - Y_i \text{ estimated}| \quad (11)$$

به منظور بررسی دقیق‌تر عملکرد و دقت مدل‌ها، از شاخص‌های خطای آماری معروف از جمله ریشه میانگین مربع خطای RMSE (Root Mean Square Error)، میانگین خطای مطلق MAE (Mean Absolute Error)، میانگین خطای نسبی MARE (Mean Absolute Relative Error)، میانگین خطای نسبی NSE (Absolute Relative Error Nash–Sutcliffe Efficiency) استفاده شده است. روابطی که

out تقریباً یکسان می‌باشد (به ترتیب برابر با ۸۸/۷۷ و ۸۸/۶۲ و ۸۸/۶۹) هم‌چنین با توجه به جدول (۲) مشخص است که مقادیر شاخص MAE برای دو مدل SVR leave-one-out و SVR K-Fold یکسان می‌باشد (به ترتیب برابر با ۰/۰۲۰۸ و ۰/۰۲۰۲)؛ درحالی‌که این شاخص نشان‌دهنده عملکرد ضعیف‌تری نسبت به سایر مدل‌ها برای مدل GRNN می‌باشد (با مقدار برابر با ۰/۰۳). هم‌چنین می‌توان روندی مشابه شاخص MAE برای مدل‌های GRNN، SVR leave-one-out و SVR K-Fold، SVR K-Fold، GRNN one-out، برای شاخص‌های (مبتنی بر داده‌های کل) استفاده شده در این تحقیق باستفاده از پنج شاخص آماری R², MAE, MARE و RMSE می‌باشد. RMSE (به ترتیب برابر با ۰/۰۲۶۶، ۰/۰۲۶۵ و ۰/۰۲۶۵) نیز مشاهده نمود. مقادیر شاخص NSE برای مدل‌های SVR leave-one-out و SVR K-Fold، GRNN one-out، SVR K-Fold و درنهایت مدل GRNN را به عنوان دقیق‌ترین مدل در این تحقیق به منظور تخمین حداکثر عمق فرسایش در شرایط بستر متحرک در تلاقی رودخانه‌ها پیشنهاد نمود.

$$\text{MARE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i \text{ observed} - Y_i \text{ estimated}}{Y_i \text{ estimated}} \right| * 100\% \quad (12)$$

$$\text{NSE} = 1 - \frac{\sum_{i=1}^N (Y_i \text{ observed} - Y_i \text{ estimated})^2}{\sum_{i=1}^N (Y_i \text{ observed} - \mu_{\text{observed}})^2} \quad (13)$$

که در این روابط، N تعداد داده‌ها، Y_i مقادیر خروجی مدل‌ها ($\frac{D_s}{B_3}$) و μ_{observed} میانگین داده‌های مشاهداتی می‌باشد.

جدول (۲) و آنالیز دقتسنجی مدل‌های استفاده شده در این تحقیق با استفاده از پنج شاخص ساختاری (MARE, MAE, R², RMSE و NSE) می‌باشد. به منظور ساده‌تر و جامع‌تر بودن مقایسه مدل‌ها، این پنج شاخص برای کل داده‌ها، داده‌های آموزش و داده‌های leave-one-out و Fold دوره آموزش و تست ندارند) محاسبه شده‌اند. با توجه به جدول (۲)، مقادیر شاخص‌های R², MAE, MARE و RMSE برای کل داده‌ها در مدل SVR عادی به ترتیب برابر با ۰/۰۱۶۸، ۰/۰۱۶۸، ۰/۰۱۶۸ و ۰/۹۹۳ می‌باشد که این مقادیر نشان‌دهنده دقیق‌تر این مدل در قیاس با سایر مدل‌ها می‌باشد. مقادیر R² برای کل داده‌ها در مدل‌های GRNN، SVR leave-one-out و SVR K-Fold می‌باشد.

جدول ۲ آنالیز دقتسنجی مدل‌ها با استفاده از شاخص‌های خطای آماری

شاخص‌های آماری					نام مدل
NSE	RMSE (m)	MARE (%)	MAE (m)	R ² (%)	
۰/۷۶۴۴	۰/۰۳۸۷	۹/۲۴	۰/۰۲۹۳	۸۸/۸۳	داده‌های آموزش
۰/۷۳۸۹	۰/۰۳۷۰	۱۰/۵	۰/۰۳۲	۸۸/۹۵	
۰/۷۵۸	۰/۰۳۸۲	۹/۶	۰/۰۳	۸۸/۷۷	
۰/۹۹۷۶	۰/۰۱۱۴	۳	۰/۰۰۹	۹۸	داده‌های آموزش
۰/۸۷۵۷	۰/۰۲۵۵	۷/۳۷	۰/۰۲۰۷	۹۶/۴۱	
۰/۹۹۳	۰/۰۱۶۸	۴/۲۶	۰/۰۱۲۴	۹۵/۶۶	
۰/۸۸۲۸	۰/۰۲۶۶	۶/۷۹	۰/۰۲۰۸	۸۸/۹	کل داده‌ها
۰/۹۷۷۶	۰/۰۲۶۵	۷/۶۲	۰/۰۲	۸۸/۶۲	کل داده‌ها
					SVR (K-Fold)
					SVR (leave-one-out)

نوین به نام‌های مدل ماشین‌های بردار پشتیبان K-رگرسیونی (SVR) با روش اعتبارسنجی train-test و Fold leave-one-out، و مدل شبکه عصبی رگرسیون تعیین‌یافته (GRNN) مورد بررسی قرار گرفته است، که نتایج آن عبارتند از:

۱. در این تحقیق، مدل SVR K-Fold به‌ازای K-Fold برابر با ۹ بهترین نتایج را نشان می‌دهد (MARE=6.79).

۲. هرچند به‌طور کلی تمام مدل‌ها دقت نسبتاً قابل قبولی را از خود نشان می‌دهند؛ اما نتایج آنالیز SVR train-test دقت‌سنگی نشان می‌دهد که مدل دقت بسیار بهتری نسبت به سایر روش‌ها در این تحقیق دارد (به‌ترتیب با R^2 , MAE, MARE و RMSE به‌ترتیب با ۰/۰۳۷، ۰/۰۳۲، ۰/۰۳۸۹ و ۰/۰۴۱، ۰/۰۴۵، ۰/۰۴۶ و ۰/۰۴۷؛ و برای کل داده‌ها)، و بعد از آن SVR K-Fold به‌ترتیب مدل SVR leave-one-out و درنهایت مدل GRNN را می‌توان به عنوان دقیق‌ترین مدل در این تحقیق به‌منظور تخمین حداقل عمق فرسایش در شرایط بستر متحرک در تلاقي رودخانه‌ها درنظر گرفت.

نتایج این تحقیق برای شرایط و محدوده پارامترهای ذکر شده در این تحقیق صادق می‌باشند. برای شرایط دیگر، پیشنهاد می‌گردد که بررسی‌های مجدد انجام شود.

به‌منظور بررسی دقت دوره آموزش و تست در مدل SVR و GRNN، آنالیز دقت‌سنگی برای این دوره‌ها نیز در جدول (۲) ارائه شده است. برای دوره آموزش مدل GRNN، شاخص‌های آماری R^2 , MAE, RMSE و NSE به‌ترتیب برابر با ۰/۰۲۹۳، ۰/۰۲۸۷، ۰/۰۲۴۴ و ۰/۰۲۹۳ برابر با ۰/۰۱۱۴، ۰/۰۰۹، ۰/۰۰۹ و ۰/۹۹۷۶ می‌باشد، که این اعداد نشان‌دهنده دقت بالای مدل SVR در گام آموزش نسبت به مدل GRNN می‌باشد. در دوره تست نیز شاخص‌های آماری R^2 , MAE, MARE و RMSE به‌ترتیب با ۰/۰۹۵، ۰/۰۴۱، ۰/۰۴۲ و ۰/۰۴۳۲ برابر با ۰/۰۲۰۷، ۰/۰۲۵۵، ۰/۰۲۷ و ۰/۰۲۷۵۷ می‌باشد، که این اعداد نیز نشان‌دهنده دقت بالای مدل SVR در گام تست نسبت به مدل GRNN می‌باشد. بنابراین در قیاس مدل SVR با روش اعتبارسنجی train-test، مدل SVR هم در بخش آموزش و هم در بخش تست نتایج بهتری نسبت به مدل GRNN در این تحقیق نشان می‌دهد.

نتیجه‌گیری

با توجه به فقدان یک سیستم هوشمند در پیش‌بینی حداقل عمق آبستگی در تلاقي رودخانه‌ها در حالت بستر متحرک، در تحقیق حاضر دو مدل هوش مصنوعی

مراجع

1. Taylor, E.H., "Flow characteristics at rectangular open channel confluence", *Transactions of ASCE*, No. 109, pp. 893–902, (1944).
2. Webber, N.B., Greated, C.A., "An investigation of flow behavior at the junction of rectangular channel", *Proceedings of the Institution of Civil Engineers.*, Thomas telford Lte., London, Vol. 34, pp. 321-334, (1966).
3. Modi, P.N; Ariel, P.D., Dandekar, M.M., "Conformal mapping for channel junction flow" , *Journal of Hydraulic Engineering.*, No. 107(12), pp. 1713-1733, (1981).
4. Best, J.L, Reid, I., "Separation zone at open channel junctions", *Journal of Hydraulic Engineering.*, ASCE, No. 100(11), pp. 1588-1594, (1984).

5. Best, J.L., "Flow dynamics at river channel confluences: Implications for sediment transport and bed morphology", Recent Devel. In Fluvial Sedimentology, SEPM Spec. Publ. 39, Etheridge, F.G; Floers, R.M., Harvey, M.D., eds., pp. 27-35, (1987).
6. Ramamurthy, A.S., Carballada, L.B., Tran, D.M., "Combining open channel flow at right angled junctions ", *Journal of Hydraulic Engineering.*, ASCE, No. 114(12), pp.1449-1460, (1988).
7. Hager, W.H., "Transition flow in channel junctions", *Journal of Hydraulic Engineering.*, ASCE, No. 115(2), pp. 243-259, (1989).
8. Gurram, S.K., Karki, K.S., Hager, W.H., "Subcritical junction flow", *Journal of Hydraulic Engineering.*, ASCE, No. 123(5), pp. 447-455, (1997).
9. Hsu, C.C., Wu, F.S., Lee, W.J., " Flow at 90 equal width open channel junction", *Journal of Hydraulic Engineering.*, ASCE, No. 124(2), pp.186-191, (1998a).
10. Hsu, C.C., Lee, W.J., Chang, C.H., "Subcritical open channel junction flow", *Journal of Hydraulic Engineering.*, ASCE, No. 124(8), pp. 847-855, (1998b).
11. Weber, L.J., Schumate, E.D., Mawer, N., "Experimentals on flow at a 90° open channel Junction", *Journal of Hydraulic Engineering.*, ASCE, No. 127, pp. 340–350, (2001).
12. برگی، س.م.، سخاچی‌فر، س.م.، دائمی، ع.، "بررسی آزمایشگاهی اتصال کانال‌ها"، مجموعه مقالات ششمین سمینار بین‌المللی مهندسی روودخانه، اهواز، صص. ۶۱۹-۶۱۱، (۱۳۸۱).
13. Lyubimova, T., Lepikhin, A., Konovalov, V., Parshakova, Y., Tiunov, A., "Formation of the density currents in the zone of confluence of two rivers", *Journal of Hydrology*, No. 508, pp. 328–342, (2014).
14. Coelho, M.M.L.P., "Experimental determination of free surface levels at open channel junctions", *Journal of Hydraulic Engineering.*, Research, No. 53(3), pp. 394-399, (2015).
15. Weerakoon, S.B., Kawahara, Y., Tamia, N., "Three dimensional flow structure in channel confluences of rectangular section", *Proceeding, 24th IAHR congress.*, pp. 373-380, (1991).
16. Bradbrook, K.F., Lane, S.N., Richards, K.S., Biron, P.M., Roy, A.G., "Role of bed discordance at asymmetrical river confluences", *Journal of Hydraulic Engineering.*, No. 127, pp. 351-368, (2001).
17. Huang, J.L., Weber, L.J., Yong, G.L., "Three Dimensional Numerical Study of Flows in Open Channel Junctions flow", *Journal of Hydraulic Engineering.*, ASCE, No. 128(3), pp. 268-280, (2002).
18. Shakibainia, A., Majdzadeh Tabatabai, M.R., Zarrati, A.R., "Three-dimensional numerical study of flow structure in channel confluences", *Canadian Journal of Civil Engineering.*, No. 37(5), pp. 772-781, (2010).

19. Ghostine, R., Vazquez, J., Terfous, A., Mose, R., Ghenaim A., "Comparative study of 1D and 2D flow simulations at open-channel junctions", *Journal of Hydraulic Research*, No. 50(2), pp. 164-170, (2012), DOI: 10.1080/00221686.2012.661563.
20. Baranya, S., Olsen, N.R.B., Józsa, J., "Flow analysis of a river confluence with field measurements and RANS model with nested grid approach", *River Research and Applications*, No. 31(1), pp. 28-41, (2013), DOI: 10.1002/rra.2718.
21. Sharifipour, M., Bonakdari, H., Zaji, A.H., Shamshirband, S., "Numerical investigation of flow field and flowmeter accuracy in open-channel junctions", *Engineering Applications of Computational Fluid Mechanics*, No. 9(1), pp. 280-290, 2015, DOI: 10.1080/19942060.2015.1008963.
22. Mosley, M.P., "An experimental study of channel confluences", *Journal of Geology*, No. 84, pp. 535-562, (1976).
23. Best, J.L., "Sediment transport and bed morphology at river channel confluences", *Journal of Association OF Sedimentologists*, No. 35, pp. 481-498, (1988).
24. Roy, G.A., Roy, R., "Changes in channel Size at river Confluences with coarse bed material", *Earth surface processes and Land forms*, No. 13, pp. 77-84, (1988).
۲۵. برگی، س. م.، نظری، ا.، "بررسی آزمایشگاهی الگوی رسوب در تقاطع کانال‌ها"، مجموعه مقالات ششمین کنفرانس بین‌المللی مهندسی عمران، اصفهان، صص. (۱۳۸۲)، ۲۴۷-۲۵۵.
26. Ghobadian, R., Shafai Bejestan, M., "Investigation of sediment patterns at river confluence", *Journal of Applied Science*, No. 7(10), pp. 1372-1380, (2007).
27. Shafai Bejestan, M., Hemmati, M., "Scour depth at river confluence of unequal bed level", *Journal of Applied Science*, No. 8(9), pp. 1766-1770, (2008).
28. Borghei, S.M., Sahebari Jabbari, A., "Local scour at open channel junctions", *Journal of Hydraulic Research*, No. 48(4), pp. 538-542, (2010).
۲۹. محمدی، ص.، "بررسی تأثیر گردشگری لب پایین دست محل اتصال بر الگوی رسوب در تلاقی رودخانه‌ها"، پایان‌نامه کارشناسی ارشد، دانشگاه شهید چمران، اهواز، (۱۳۹۰).
۳۰. بلوچی، ب.، "بررسی تأثیر آورد رسوب شاخه اصلی بر الگوی رسوب در محل تلاقی رودخانه‌ها"، پایان‌نامه کارشناسی ارشد، دانشگاه شهید چمران، اهواز، (۱۳۹۱).
31. Kambekar, A.R., Deo, M.C., "Estimation of pile group scour using neural networks", *Journal of Applied Ocean Research*, No. 25, pp. 225-234, (2003).
32. Bateni, S.M., Borghei, S.M., Jeng, D.S., "Neural network and neuro-fuzzy assessments for scour depth around bridge piers", *Journal of Engineering Applications of Artificial Intelligence*, No. 20, pp. 401-414, (2007).
33. Azamathulla, H.M.D., Deo, M.C., Deolalikar, P.B., "Alternative neural networks to estimate the scour below spillways", *Journal of Advances in Engineering Software*, No. 39, pp. 689-698, (2008).

34. Abidin, K., "Artificial neural network study of observed pattern of scour depth around bridge piers", *Journal of Computers and Geotechnics*, No. 37, pp. 413–418, (2010).
35. Ismail, A., Jeng, D.S., Zhang, L.L., Zhang, J.S., "Predictions of bridge scour: Application of a feed-forward neural network with an adaptive activation function", *Journal of Engineering Applications of Artificial Intelligence*, No. 26, pp. 1540–1549, (2013).
36. Cheng, M., Cao, M., Wu, Y., "Predicting equilibrium scour depth at bridge piers using evolutionary radial basis function neural network", *Journal of Computing in Civil Engineering*, (2014).
37. Hong, J., Goyal, M.K., Chiew, Y., Chua L.H.C., "Predicting time-dependent pier scour depth with support vector regression", *Journal of Hydrology*, pp. 241–248, (2012).
38. Jahangirzadeh, A., Shamshirband, S., Aghabozorgi, S., Akib, S., Basser, H., Anuar, N.B., Kiah, M.L.M., "A Cooperative Expert Based Support Vector Regression (Co-ESVR) System to Determine Collar Dimensions around Bridge Pier", *Neurocomputing journal*, (2014).
39. Pal, M., Singh, N.K., Tiwari, N.K., "Support vector regression based modeling of pier scour using field data", *Engineering Applications of Artificial Intelligence*, No. 24(5), pp. 911–916, (2011).
۴۰. غضنفری هاشمی، س.، اعتماد شهیدی، ا.، "پیش‌بینی عمق آبستنگی اطراف پایه پل با استفاده از ماشین‌های بردار پشتیبان"، مجله علمی-پژوهشی عمران مدرس، شماره ۱۲ (۲)، صص. ۳۶-۲۳. (۱۳۹۱).
۴۱. هوشیاری‌پور، ف.، نوری، ر.ا.، "استفاده از تکنیک ماشین بردار پشتیبان در پیش‌بینی ابعاد چاله آبستنگی پایین دست یک پرتابه جامی‌شکل"، مجله آب و مهندسی محیط زیست ایران، شماره ۱ (۱)، صص. ۴۵-۳۵. (۱۳۹۲).
۴۲. نیکو، م.ر.، کراچیان، ر.، "پنهان‌بندی کیفی منابع آب سطحی با استفاده از ماشین‌های بردار پشتیبان احتمالاتی و شبکه‌های بیزی"، چهارمین همایش تخصصی مهندسی محیط زیست، دانشگاه تهران. (۱۳۸۹).
43. Specht, D.F., "A General Regression Neural Network", *IEEE Transaction on Neural Networks*, No. 2(6), pp. 568–576, (1991).
44. Li, C.F., Zhang, J.B., Wang, S.T., "Comparative Study on Input-Expansion-Based Improved General Regression Neural Network and Levenberg-Marquardt BP Network", *Lecture Notes in Computer Science*, No. 4113, pp. 83-93, (2006).
45. Mehmani, A., Chowdhury, S., Messac, A., "Predictive quantification of surrogate model fidelity based on modal variations with sample density", *Structural and Multidisciplinary Optimization*, No. 52 (2), pp. 353–373, (2015).