

مقاله علمی-پژوهشی

پیش‌بینی عمق و طول آبستگي اطراف خطوط لوله مدفون با استفاده از روش‌های یادگیری ماشین

توحید امیدپور علویان^۱، مهدی ماجدی اصل^{۲*}، میثم قلی نژادشام اسبی^۳، مهدی کوهدرق^۴

تاریخ دریافت: ۱۴۰۴/۱۱/۲۸ تاریخ پذیرش: ۱۴۰۵/۰۲/۲۷

چکیده

آبستگي موضعي پیرامون خطوط لوله مدفون در بستر رودخانه‌ها یکی از عوامل مهم ناپایداری بستر و آسیب‌پذیری زیرساخت‌های انتقال سیال به شمار می‌رود که در صورت برآورد نادرست می‌تواند منجر به خسارات فني، اقتصادی و زیست‌محیطی قابل توجه شود. از این رو، توسعه روش‌های دقیق برای پیش‌بینی هندسه چاله آبستگي نقش مهمی در طراحی ایمن و اقتصادی این سازه‌ها دارد. پژوهش‌های اخیر نشان داده‌اند که روش‌های یادگیری ماشین و الگوریتم‌های هوش مصنوعی به عنوان ابزارهای کارآمد برای تحلیل و پیش‌بینی پدیده‌های پیچیده هیدرولیکی مورد توجه قرار گرفته‌اند. در این پژوهش، عملکرد سه روش یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و الگوریتم k-نزدیک‌ترین همسایه (KNN) در پیش‌بینی هندسه چاله آبستگي موضعي شامل عمق حداکثر و طول حداکثر در حضور تیغه غیرقابل نفوذ بررسی شد. تحلیل‌ها بر پایه ۶۴ سری داده آزمایشگاهی انجام گرفت. پارامترهای هیدرولیکی و هندسی مورد استفاده شامل عدد فرود جریان، نسبت دفن اولیه لوله به عرض کانال و نسبت قطر لوله به عرض کانال بود. نتایج نشان داد که مدل شبکه عصبی مصنوعی با ضریب تعیین بیش از ۰/۹۶ در پیش‌بینی عمق و طول چاله آبستگي، عملکرد دقیق‌تر و پایدارتری نسبت به دو روش دیگر ارائه می‌دهد، در حالی که مدل‌های SVM و KNN دقت کمتری نشان دادند. همچنین نتایج تحلیل حساسیت مشخص کرد که نسبت دفن اولیه لوله به عرض کانال مهم‌ترین پارامتر مؤثر در تعیین هندسه آبستگي موضعي است. در مجموع، نتایج این پژوهش نشان می‌دهد که روش‌های یادگیری ماشین، به ویژه شبکه عصبی مصنوعی، می‌توانند به عنوان ابزاری مؤثر برای پیش‌بینی آبستگي و بهبود طراحی و ایمنی خطوط لوله مدفون در بستر رودخانه‌ها مورد استفاده قرار گیرند.

واژه‌های کلیدی: آبستگي موضعي، آنالیز حساسیت، تیغه غیرقابل نفوذ، خط لوله مدفون، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، یادگیری ماشین، k-نزدیک‌ترین همسایه

مقدمه

اطراف لوله ایجاد می‌کند که می‌تواند منجر به کاهش پایداری، خمش، شکست سازه‌ای و نشت سیالات شود. این خرابی‌ها علاوه بر هزینه‌های اقتصادی بالا، پیامدهای زیست‌محیطی جدی مانند آلودگی اکوسیستم‌های آبی را به دنبال دارند. عمق و شدت آبستگي به عوامل مختلفی از جمله پارامترهای هیدرولیکی (سرعت جریان، عدد فرود، عمق آب)، ویژگی‌های هندسی لوله (قطر و فاصله از بستر) و خصوصیات رسوبات بستر بستگی دارد. برای کنترل این پدیده، روش‌های حفاظتی مختلفی مانند دفن عمیق‌تر لوله، پوشش سنگی (ریپر) و نصب اختلال‌گرهای جریان پیشنهاد شده است. یکی از روش‌های مؤثر، استفاده از تیغه‌های نفوذناپذیر (spoilers) در زیر لوله است که با تغییر الگوی جریان و کاهش سرعت موضعي، فرایند پایینگ را محدود کرده و عمق نهایی آبستگي را کاهش می‌دهد. روش‌های پیش‌بینی کلاسیک عمدتاً تجربی یا نیمه‌تئوری هستند و به دلیل اتکا به داده‌های آزمایشگاهی محدود، در شرایط واقعی پیچیده دقت پایینی دارند. یک روش تحلیلی ساده برای برآورد حداکثر عمق

استفاده از خطوط لوله زیرزمینی برای انتقال نفت، گاز و آب، جزء کلیدی زیرساخت‌های انرژی و آبرسانی مدرن است. عبور این خطوط از بستر رودخانه‌ها با چالش مهم آبستگي موضعي همراه است. آبستگي ناشی از فرسایش ذرات بستر توسط جریان آب، حفره‌هایی

۱- دانشجوی دکترا مهندسی عمران، مهندسی آب و سازه‌های هیدرولیکی، دانشگاه مراغه، مراغه، ایران

۲- دانشیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه مراغه، مراغه، ایران

۳- دانشجوی کارشناسی ارشد مهندسی عمران، مهندسی آب و سازه‌های هیدرولیکی، دانشگاه مراغه، مراغه، ایران

۴- گروه مهندسی عمران، واحد ملکان، دانشگاه آزاد اسلامی، ملکان، ایران

(*- نویسنده مسئول: mehdi.majedi@gmail.com)

DOI: [10.22034/ijid.2026.575752.2671](https://doi.org/10.22034/ijid.2026.575752.2671)

آبشستگی زیر خطوط لوله، بر اساس تنش برشی بستر و تنش بحرانی ذرات رسوب ارائه شده است که ارزیابی مناسبی برای پایداری سازه‌های لوله‌ای فراهم می‌کند (Chao and Hennessy, 1972). توسعه زمانی فرآیند آبشستگی و الگوهای آن در اطراف لوله‌های روی بستر یا مدفون، با آزمایش‌های فیلومی در جریان یکنواخت بررسی شده است. نتایج نشان می‌دهد عمق و الگوی آبشستگی به شدت تحت تأثیر سرعت جریان، قطر لوله و موقعیت قرارگیری لوله نسبت به بستر است و تعمیم نتایج آزمایشگاهی به مقیاس واقعی با پارامترهای بی‌بعد امکان‌پذیر است (Kjeldsen et al., 1981). بررسی رفتار لوله‌های زیردریایی روی بستر فرسایش‌پذیر تحت امواج و جریان نیز حاکی از آن است که قطر لوله، سرعت جریان و ارتفاع لوله نسبت به بستر، نقش مهمی در تغییر الگوی جریان و فرسایش داشته و بر پایداری لوله تأثیر مستقیم دارند (Bijker and Leeuwestein, 1984). مطالعات نشان داده‌اند که پدیده پایپینگ عامل اصلی آغاز آبشستگی موضعی است و گردادیان هیدرولیکی بحرانی ناشی از اختلاف فشار بالا و پایین دست لوله، نقش کلیدی در شروع فرسایش دارد. استفاده از لایه‌های نفوذناپذیر زیر لوله می‌تواند از وقوع آن جلوگیری کند (Chiew, 1990). رابطه تجربی پیشنهادی برای پیش‌بینی حداکثر عمق آبشستگی نشان می‌دهد که بیشترین عمق زمانی رخ می‌دهد که لوله روی بستر صاف و تحت جریان یک‌جهته قرار گرفته و تنش برشی بحرانی برای حرکت رسوب برقرار باشد (Chiew, 1991). بررسی آبشستگی سه‌بعدی اطراف لوله‌های مدفون نیز تأکید دارد که پارامترهای بی‌بعد بر سرعت توسعه حفره و گسترش دهانه آبشستگی تأثیرگذار هستند (Wu and Chiew, 2012). در نهایت، آزمایش‌های انجام‌شده با اسپویلر طول ناحیه نصب‌شده زیر لوله مدفون نشان می‌دهد که این اسپویلر طول ناحیه آبشستگی را کاهش می‌دهد، اما ممکن است عمق آن را افزایش دهد. میزان این اثر به ابعاد لوله، سرعت جریان و هندسه اسپویلر وابسته است (Jabari et al., 2020). ویژگی‌های آبشستگی و پیش‌بینی عمق تعادلی آبشستگی در اطراف خطوط لوله پیگگی‌بک زیر دریا تحت اثر همزمان موج و جریان مورد بررسی قرار گرفته و نتایج آزمایشگاهی نشان می‌دهد که عمق آبشستگی تعادلی به شدت تحت تأثیر نسبت فاصله لوله‌ها، عدد شیلدز و شرایط هیدرودینامیکی جریان بوده و با افزایش پارامترهای هیدرودینامیکی میزان آبشستگی افزایش می‌یابد (Hu et al., 2022). در سال‌های اخیر، روش‌های داده‌محور و الگوریتم‌های یادگیری ماشین به دلیل توانایی مدل‌سازی روابط غیرخطی میان متغیرهای هیدرولیکی و هندسی، به ابزارهای قدرتمندی برای پیش‌بینی پدیده‌های پیچیده هیدرولیکی تبدیل شده‌اند. در حوزه تشخیص الگو، قانون نزدیک‌ترین همسایه (K-NN) به‌عنوان یکی از روش‌های پایه معرفی شده که حتی در ساده‌ترین حالت، بخش قابل توجهی از اطلاعات طبقه‌بندی را ارائه می‌دهد و

کران خطایش در نمونه‌های بزرگ قابل مقایسه با خطای بهینه بیز است (Cover and Hart, 1967). در زمینه آبشستگی خطوط لوله دریایی، ابتدا چارچوب‌های تجربی برای برآورد عمق آبشستگی مورد استفاده قرار گرفت (Ibrahim and Nalluri, 1986). متعاقباً، روش‌های هوشمند مانند سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) و تحلیل عدم قطعیت نشان دادند که مدل‌های داده‌محور دقت بالاتری نسبت به روابط رگرسیونی کلاسیک دارند. توسعه شبکه‌های عصبی مصنوعی (ANN) به‌عنوان ابزاری قوی در مدل‌سازی سیستم‌های پیچیده، نقش مهمی ایفا کرده است (Haykin, 1999). شبکه‌های عصبی پس‌انتشار به‌ویژه در استخراج الگوهای پنهان از داده‌های تاریخی عملکرد مناسبی نشان داده‌اند. کاربرد شبکه‌های عصبی مصنوعی در پیش‌بینی آبشستگی موضعی اطراف پایه‌های پل حاکی از دقت بالاتر این مدل‌ها نسبت به روابط تجربی موجود است (Choi and Jung, 2006). همچنین، مقایسه مدل‌های هوشمند مختلف نشان داد که مدل MLP/BP نسبت به RBF/OLS و ANFIS دقت بالاتری در پیش‌بینی عمق آبشستگی تعادلی و زمانی دارد و قطر پایه پل مهم‌ترین عامل مؤثر بر عمق آبشستگی تعادلی شناسایی شد (Bateni et al., 2007). در زمینه خطوط لوله دریایی، استفاده از شبکه‌های عصبی مصنوعی مبتنی بر الگوریتم پس‌انتشار خطا برای پیش‌بینی آبشستگی ناشی از امواج نشان داده است که مدل‌های ANN دقت بالاتری نسبت به روش‌های رگرسیونی دارند (Kim et al., 2013). بررسی اثر تغییر الگوی جریان و برداشت مصالح بر آبشستگی اطراف گروه پایه‌های پل در جریان زیربحرانی حاکی از آن است که به‌کارگیری تمهیدات تقویتی باعث کاهش قابل توجه عمق آبشستگی و کنترل گسترش آن در جهت‌های طولی و عرضی می‌شود (Majedi Asl et al., 2020). توسعه رابطه صریح با استفاده از روش برنامه‌ریزی بیان ژنی (GEP) و داده‌های شبیه‌سازی عددی نشان داد که مدل GEP نسبت به رگرسیون غیرخطی، ضریب تعیین بالاتر و خطای کمتری داشته و عملکرد بهتری در پیش‌بینی عمق آبشستگی دارد (Sen and Jalal, 2021). مطالعات مروری تأکید دارند که الگوریتم‌های تکاملی مانند PSO، GA و ABC با بهینه‌سازی ساختار و پارامترهای شبکه‌های عصبی، دقت مدل‌ها را در مسائل پیچیده افزایش می‌دهند (Abdulrasool et al., 2021). همچنین، بررسی آبشستگی اطراف خطوط لوله پیگگی‌بک تحت اثر همزمان موج و جریان نشان می‌دهد که عمق آبشستگی تعادلی به شدت تحت تأثیر نسبت فاصله بین لوله‌ها، عدد شیلدز و شرایط هیدرودینامیکی جریان قرار دارد (Hu et al., 2022). در سال‌های اخیر، مدل‌های یادگیری عمیق نیز در حوزه پیش‌بینی آبشستگی توسعه یافته‌اند. طراحی مدل شبکه عصبی عمیق با بهینه‌سازی هایپرپارامترها نشان داد که بهینه‌ساز Adam عملکرد پیش‌بینی را بهبود بخشیده و نیاز به آزمون و خطای دستی را

خطوط لوله مدفون، به‌ویژه در حضور تیغه‌های نفوذناپذیر (spoilers)، همچنان نیازمند مطالعه بیشتر است. از این‌رو، در پژوهش حاضر عملکرد سه الگوریتم پرکاربرد ANN، SVM و KNN در پیش‌بینی هندسه چاله آبشستگی موضعی بررسی شده است. داده‌های مورد استفاده شامل نتایج آزمایشگاهی مرکز مطالعات رسوب خوزستان بوده و اثر پارامترهای هیدرولیکی و هندسی مختلف ارزیابی گردیده است. هدف اصلی، مقایسه عملکرد این مدل‌ها و ارائه مدلی دقیق‌تر برای پیش‌بینی عمق و طول چاله آبشستگی در اطراف خطوط لوله مدفون در بستر رودخانه است.

مواد و روش‌ها

این پژوهش بر پایه مجموعه‌ای متشکل از ۶۴ آزمایش هیدرولیکی کنترل شده در مقیاس آزمایشگاهی انجام پذیرفت که تمامی آزمایش‌ها در سال ۱۳۹۹ توسط جباری در آزمایشگاه تخصصی مرکز مطالعات رسوب و رسوب گذاری سازمان آب و برق خوزستان اجرا شده‌اند. هدف اصلی تحقیق، بررسی تأثیر سیستماتیک نصب یک تیغه نفوذناپذیر (غیرقابل تراوش) در زیر لوله مدفون (مستغرق) بر مشخصات هندسی چاله آبشستگی موضعی (شامل حداکثر عمق و طول گسترش چاله) و همچنین ارزیابی تطبیقی دقت و کارایی سه الگوریتم یادگیری ماشین پیشرفته، یعنی شبکه‌های عصبی مصنوعی (Artificial Neural Network; ANN)، ماشین بردار پشتیبان (Support Vector Machine; SVM) و الگوریتم k-نزدیک‌ترین همسایه (k-Nearest Neighbors; KNN)، در پیش‌بینی عمق حداکثر آبشستگی اطراف لوله تحت شرایط هیدرولیکی متنوع بود.

تمامی آزمایش‌ها در یک فلوم مستقیم با دیواره‌های شفاف از جنس پلکسی‌گلاس و مقطع مستطیلی به ابعاد طول ۱۲/۵ متر، عرض ۰/۳ متر و ارتفاع ۰/۶ متر اجرا گردید. به منظور استقرار لوله همراه با تیغه در بستر رسوبی، در فاصله ۴/۵ متری از بخش ابتدایی فلوم، یک مخزن مستطیلی به ابعاد طول ۱ متر، عرض ۰/۳ متر و عمق ۰/۱۵ متر در کف کانال ایجاد شد. پس از پر کردن کامل مخزن با رسوبات یکنواخت و دانه‌بندی کنترل شده، سطح فوقانی بستر با کف کلی فلوم کاملاً تراز و هم سطح گردید (شکل ۱). این طراحی امکان شبیه‌سازی شرایط واقعی رودخانه‌ای با تمرکز بر پدیده آبشستگی موضعی زیر سازه‌های خطی مدفون را فراهم آورد. با توجه به قابلیت‌های متمایز هر یک از الگوریتم‌های مورد بررسی از جمله توانایی ANN در مدل سازی روابط غیرخطی پیچیده، عملکرد برتر SVM در مدیریت داده‌های با ابعاد بالا و مقاومت در برابر نویز، و سادگی محاسباتی و کارایی بالای KNN در مسائل مبتنی بر الگوهای محلی ن مطالعه به طور جامع به تعیین الگوریتم بهینه از منظر دقت پیش‌بینی و قابلیت تعمیم در شرایط هیدرولیکی گوناگون پرداخت. به این منظور، هشت

کاهش می‌دهد (Asim et al., 2022).


مدل‌های یادگیری ماشین گروهی (Ensemble) نظیر GTB و MARS در پیش‌بینی آبشستگی اطراف تکیه‌گاه‌های پل، دقت بالاتری نسبت به سایر روش‌های هوشمند نشان داده‌اند (Marulasiddappa et al., 2024). استفاده از مدل‌های ترکیبی شامل SVM، Random Forest و Boosting، دقت پیش‌بینی عمق آبشستگی را نسبت به روابط تجربی کلاسیک افزایش داده است. شدت جریان و دانه‌بندی رسوبات از مهم‌ترین پارامترهای مؤثر شناسایی شدند (Andy et al., 2024). در سازه‌های حفاظتی ساحلی شیب‌دار نیز، الگوریتم SVM دقت بالاتری نسبت به سایر مدل‌های یادگیری ماشین ارائه کرده است (Habib et al., 2024). یک مطالعه مروری جامع تأکید کرده است که مدل‌های یادگیری ماشین در مقایسه با مدل‌های فیزیکی و روابط تجربی، توانایی بیشتری در در نظر گرفتن پیچیدگی فرآیند آبشستگی دارند. پارامترهایی مانند سرعت جریان، ویژگی‌های رسوب و مورفولوژی بستر، نقش تعیین‌کننده‌ای در دقت پیش‌بینی ایفا می‌کنند (Rahman and Chuan, 2024). تحقیق دیگری نشان داده است که مدل‌های هوش مصنوعی ANN، SVM و QNET با دقت بالا در پیش‌بینی عمق آبشستگی، ابزارهای مؤثری برای ارتقای ایمنی و بهینه‌سازی طراحی سازه‌های پل هستند (Soltani Sotobadi et al., 2025). در نهایت، ترکیب شبیه‌سازی‌های CFD با مدل‌های یادگیری ماشین به عنوان رویکردی نوین برای پیش‌بینی سریع عمق آبشستگی زیر خطوط لوله دریایی ارتعاشی تحت اثر همزمان امواج و جریان معرفی شده است. مدل‌های تجمیعی مبتنی بر شبکه عصبی چندلایه و XGBoost با استفاده از داده‌های عددی آموزش دیده و با دقت تقریبی ۹۰٪ عملکرد بهتری نسبت به روش‌های سنتی داشته‌اند. پارامترهای بی‌بعدی مانند عدد KC، سرعت کاهش یافته و عدد رینولدز نقش مهمی در تغییرات عمق آبشستگی دارند (Shi et al., 2026).

در تحقیقی، از ۳۶ داده آزمایشگاهی و سه روش هوش مصنوعی برای پیش‌بینی عمق آبشستگی موضعی اطراف خطوط لوله استفاده شد که نتایج نشان داد که روش شبکه عصبی مصنوعی (ANN) با مقادیر $DC=0.9925$ و $R^2=0.9932$ ، $RMSE=0.0272$ در مرحله آموزش، بهترین عملکرد را داشته و حذف پارامتر فاصله لوله از بستر منجر به کاهش چشمگیر دقت مدل شده است، که بیانگر تأثیر مستقیم این پارامتر بر عمق آبشستگی می‌باشد که پارامتر فاصله لوله از بستر تأثیر مستقیم و حیاتی بر عمق آبشستگی دارد (Majedi Asl et al., 2026).

با وجود پیشرفت‌های اخیر، بررسی همزمان عملکرد الگوریتم‌های مختلف یادگیری ماشین در پیش‌بینی هندسه چاله آبشستگی اطراف

ذرات بستر (d_{50})، عدد فرود (Fr)، نسبت سرعت جریان به سرعت بحرانی (U/U_c)، ضریب شکل ذرات و برخی شاخص‌های هیدرودینامیکی مرتبط با رژیم جریان و تعامل سیال رسوب که نقش تعیین‌کننده‌ای در شکل‌گیری و تکامل چاله آبستگي ایفا می‌کنند.

ترکیب متفاوت از متغیرهای ورودی طراحی و ارزیابی گردید (جدول ۱). این ترکیب‌ها شامل پارامترهای هیدرولیکی، هندسی و رسوبی کلیدی مؤثر بر فرآیند آبستگي بودند؛ از جمله سرعت میانگین جریان (U)، قطر خارجی لوله (D)، عمق جریان (y)، قطر متوسط




شکل ۱- پلان فلوم آزمایشگاهی (Jabari et al., 2020)

برسد. تیغه‌های نفوذناپذیر نیز از ورق پلکسی گلاس با ضخامت یک‌نواخت ۱ میلی متر ساخته گردیدند؛ این انتخاب با هدف کاهش اختلال هیدرودینامیکی ناشی از ضخامت تیغه و تمرکز حداکثری بر نقش عملکردی آن به عنوان مانع در برابر نفوذ جریان به زیر لوله و در نتیجه تغییر الگوی گردابه‌ها و برهم کنش‌های رسوبی صورت گرفت (شکل ۲). چنین طراحی‌ای تضمین می‌کند که تغییرات مشاهده شده در الگوی آبستگي عمدتاً به حضور و ابعاد تیغه نسبت داده شود، نه به عوامل جانبی ناشی از مصالح.

این رویکرد تجربی، که بر پایه ترکیب‌های کنترل شده متغیرها استوار است، زمینه مناسبی برای استخراج روابط تجربی، ارزیابی حساسیت مدل‌ها و در نهایت توسعه راهکارهای مهندسی مؤثر جهت حفاظت از سازه‌های خطی مدفون در بستر رودخانه‌ها فراهم می‌آورد.

این بخش از مطالعه به منظور بررسی سیستماتیک تأثیر نصب یک تیغه نفوذناپذیر زیر لوله مدفون بر کنترل و کاهش پدیده آبستگي موضعی اطراف آن طراحی گردید. در این راستا، چهار طول متفاوت برای تیغه (۰/۲، ۰/۳۱، ۰/۷۲ و ۱/۲۴ سانتی متر)، چهار قطر خارجی برای لوله (۴، ۳/۱، ۴/۸ و ۶/۲ سانتی متر) و چهار مقدار عدد فرود (۰/۴۲، ۰/۵، ۰/۵۸ و ۰/۶۷) به طور ترکیبی در نظر گرفته شد. این تنوع در پارامترها امکان تحلیل جامع و همزمان اثرات هندسی (ابعاد تیغه و لوله) و شرایط هیدرودینامیکی جریان (شدت جریان از طریق عدد فرود) بر عمق حداکثر و ابعاد کلی چاله آبستگي را فراهم آورد و به شناسایی الگوهای غالب در تعامل سیال، رسوب و سازه کمک کرد.

تمامی لوله‌ها از جنس PVC با سطح صاف و مقاوم در برابر خوردگی انتخاب شدند تا اثرات سطحی و زبری غیرضروری به حداقل



شکل ۲- لوله استوانه‌ای و نصب تیغه عمودی (Jabari et al., 2020)

Elliott and Hager، عمق جریان در تمامی سری‌های آزمایش ثابت و برابر با ۱۸ سانتی‌متر نگه داشته شد. این انتخاب عمق، نسبت عرض به عمق جریان (B/y) را به مقداری کافی بزرگ رساند تا اثرات دیواره‌ها بر پروفیل سرعت و در نتیجه بر فرآیند آبشستگی به حداقل برسد و تمرکز بر پدیده آبشستگی موضعی ناشی از حضور لوله و تیغه حفظ گردد. در ابتدای هر سری آزمایش، دبی جریان ورودی با استفاده از سرریز مثلثی ۶۰ درجه در ابتدای فلوم اندازه‌گیری و تنظیم شد. لوله مجهز به تیغه نفوذناپذیر در فاصله ۴/۵ متری از ابتدای کانال درون لایه رسوبی نصب گردید و سطح بستر با استفاده از اربابه متحرک مجهز به تیغه تسطیح‌کننده کاملاً هموار شد تا ناهمواری‌های اولیه حذف شود. پیش از راه‌اندازی پمپ، دریچه خروجی انتهایی بسته شد و آب زلال به صورت تدریجی وارد کانال گردید تا بستر رسوبی بدون ایجاد ریل یا اختلال موضعی اشباع شود. این فرآیند حدود ۲۰ تا ۳۰ دقیقه به طول انجامید. پس از اشباع کامل بستر، پمپ با دبی کم راه‌اندازی و دبی جریان به تدریج از طریق شیر فلکه اصلی تا مقدار هدف افزایش یافت. در ادامه، با تنظیم همزمان شیر ورودی و دریچه کنترل پایین‌دست، عمق جریان روی ۱۸ سانتی‌متر تثبیت شد.

مدت زمان هر آزمایش ۶ ساعت در نظر گرفته شد تا آبشستگی موضعی به شرایط نزدیک به تعادل دینامیکی برسد. در پایان آزمایش، پمپ خاموش شد و آب به آرامی از فلوم تخلیه گردید تا توپوگرافی بستر دستخوش تغییر نشود. پس از تخلیه کامل آب، توپوگرافی نهایی بستر اطراف لوله با استفاده از دستگاه عمق سنج لیزری با دقت میلی‌متری برداشت شد. نقاط برداشت در دو جهت طولی و عرضی کانال با فاصله ۲ سانتی‌متر تعیین گردید تا هندسه چاله آبشستگی و حداکثر عمق و گستره آن با دقت مناسب ثبت شود (شکل ۳).

به منظور جلوگیری از تشکیل ریل‌ها (ripples) در سطح بستر رسوبی و حفظ شرایط بستر مسطح در طول آزمایش‌ها، بر اساس توصیه‌های Raudkivi and Ettema، قطر متوسط ذرات (d_{50}) باید بزرگ‌تر از ۰/۷۲ میلی‌متر باشد. علاوه بر این، برای به حداقل رساندن تأثیر ناهمگنی دانه‌بندی رسوبات بر الگوی آبشستگی موضعی و افزایش قابلیت تکرارپذیری نتایج، انحراف معیار هندسی (geometric standard deviation, σ_g) دانه‌بندی باید کمتر از ۱/۳ نگه داشته شود. با رعایت این معیارها، لایه‌ای از ماسه طبیعی رودخانه‌ای با قطر متوسط $d_{50} = 1/59$ میلی‌متر و $\sigma_g \approx 1/3$ انتخاب گردید. این مواد رسوبی به ضخامت تقریبی ۱۵ سانتی‌متر در مخزن بستر فلوم قرار گرفتند تا شرایط بستر یکنواخت و پایدار برای شبیه‌سازی دقیق پدیده آبشستگی موضعی فراهم آید. تمامی آزمایش‌ها در رژیم آب زلال (clear-water scour) اجرا شدند؛ بنابراین، به منظور جلوگیری از فرسایش عمومی بستر (general scour) و انتقال رسوبات از بالادست به سمت لوله، سرعت میانگین جریان (U) همواره کمتر از سرعت بحرانی آغاز حرکت ذرات (u_c) نگه داشته شد. در این راستا، نسبت سرعت برشی به سرعت برشی بحرانی (τ/τ_c) بر پایه منحنی شیلدز (Shields curve) برابر با ۰/۹۳ تعیین گردید. بر این اساس، آزمایش‌ها در چهار دبی مختلف جریان شامل ۰/۰۲۵، ۰/۰۳۰، ۰/۰۳۵ و ۰/۰۴ مترمکعب بر ثانیه انجام پذیرفت که مقادیر نسبت سرعت میانگین جریان به سرعت بحرانی (U/U_c) به ترتیب ۰/۵۹، ۰/۷۲، ۰/۸۴ و ۰/۹۵ را نتیجه داد. این محدوده نسبت‌ها امکان بررسی سیستماتیک تأثیر شدت جریان بر عمق آبشستگی در شرایط نزدیک به آستانه حرکت ذرات را فراهم آورد. علاوه بر این، به منظور حذف یا کاهش اثرات زبری دیواره‌های جانبی فلوم (sidewall roughness effects) بر الگوی جریان و توزیع سرعت، مطابق با توصیه‌های



شکل ۳- آبشستگی در زیر لوله با نصب تیغه در انتهای آزمایش (Jabari et al., 2020)


پیشرفته یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و k-نزدیک‌ترین همسایه (KNN) به

به منظور مدل‌سازی و پیش‌بینی دقیق عمق آبشستگی موضعی در اطراف خطوط لوله مدفون مجهز به تیغه نفوذناپذیر، سه الگوریتم

داده‌ها به بازه [۱،۰] به منظور بهبود همگرایی و پایداری الگوریتم‌ها، (iii) تقسیم داده‌ها به مجموعه‌های آموزش و آزمون (معمولاً با نسبت‌های ۷۰:۳۰ یا ۸۰:۲۰)، (iv) تنظیم ابرپارامترهای مدل‌ها شامل تعداد لایه‌ها و نرون‌ها در ANN، پارامترهای کرنل و C در SVM و تعداد همسایگان k در KNN، (v) آموزش و بهینه‌سازی مدل‌ها، (vi) ارزیابی دقت پیش‌بینی بر اساس داده‌های آزمون و در نهایت (vii) مقایسه مقادیر پیش‌بینی‌شده با داده‌های اندازه‌گیری‌شده از طریق نمودارهای پراکندگی (scatter plots) و تحلیل خطاها. مقایسه همزمان این سه الگوریتم، که هر یک توانمندی متفاوتی در مدل‌سازی روابط غیرخطی، مدیریت داده‌های محدود و مقاومت در برابر نویز دارند، امکان شناسایی روش برتر از نظر دقت پیش‌بینی، کارایی محاسباتی و قابلیت تعمیم به شرایط واقعی رودخانه‌ای را فراهم می‌کند. این رویکرد علاوه بر کمک به درک بهتر فرآیند آبشستگی پیرامون خطوط لوله مدفون، زمینه توسعه ابزارهای پیش‌بینی کارآمد و مقرون‌به‌صرفه برای طراحی و حفاظت سازه‌های هیدرولیکی را نیز فراهم می‌سازد.

کار گرفته شد. این مدل‌ها با هدف شناسایی روابط پیچیده و غیرخطی میان پارامترهای هیدرولیکی، هندسی و رسوبی نظیر نسبت طول تیغه به قطر لوله (L/D)، نسبت عمق جریان به قطر لوله (y/D)، عدد فرود جریان (Fr)، نسبت دفن اولیه لوله (e/D) و سایر متغیرهای مؤثر با متغیر هدف یعنی عمق حداکثر آبشستگی (ds) توسعه یافتند. داده‌های مورد استفاده، حاصل ۶۴ سری آزمایش هیدرولیکی کنترل‌شده (جباری، ۱۳۹۹)، پس از پیش‌پردازش و نرمال‌سازی، به صورت تصادفی به دو مجموعه آموزش و آزمون تقسیم شدند تا دقت مدل‌ها و قابلیت تعمیم آن‌ها ارزیابی شود. عملکرد الگوریتم‌ها با استفاده از شاخص‌های آماری رایج شامل ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE) و ضریب تبیین (DC) سنجیده شد تا میزان دقت پیش‌بینی هر روش در شرایط مختلف هیدرولیکی و هندسی به صورت جامع بررسی گردد.

شکل ۴ به صورت شماتیک فلوچارت مراحل توسعه و پیاده‌سازی سه الگوریتم مورد استفاده را نشان می‌دهد. این مراحل شامل: (i) جمع‌آوری و پیش‌پردازش داده‌های ورودی و خروجی، (ii) نرمال‌سازی



شکل ۴- فلوچارت روش‌های انجام شده در پژوهش حاضر

یادگیری مبتنی بر پیش‌رانش و پس‌انتشار خطا، قادر به استخراج روابط غیرخطی و الگوهای پنهان در داده‌ها هستند. این ویژگی امکان تحلیل تعاملات پیچیده میان پارامترهای هیدرولیکی، هندسی و رسوبی را فراهم کرده و معمولاً به افزایش دقت پیش‌بینی در شرایط هیدرولیکی متنوع منجر می‌شود. در مقابل، الگوریتم KNN به عنوان یک روش یادگیری مبتنی بر نمونه، با استفاده از معیارهای فاصله در فضای ویژگی، پیش‌بینی‌های محلی را بر اساس نزدیک‌ترین همسایگان انجام می‌دهد و در شناسایی الگوهای وابسته به شرایط محلی مانند سرعت جریان، قطر لوله، عمق جریان و نسبت دفن اولیه (e/D) کارآمد است. به منظور ارزیابی نظام‌مند عملکرد این الگوریتم‌ها و تعیین ترکیب مناسب متغیرهای ورودی، هشت مجموعه متفاوت از پارامترهای کلیدی تعریف و آزمایش شد. جدول ۱ این ترکیبات

هر یک از الگوریتم‌های یادگیری ماشین مورد استفاده در این پژوهش، شامل شبکه‌های عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و الگوریتم k-نزدیک‌ترین همسایه (KNN)، با بهره‌گیری از قابلیت‌های منحصربه‌فرد خود به مدل‌سازی روابط پیچیده میان متغیرهای ورودی و عمق آبشستگی موضعی می‌پردازند. الگوریتم SVM با تکیه بر اصل کمینه‌سازی ریسک ساختاری و استفاده از توابع کرنل برای نگاشت غیرخطی داده‌ها به فضای ویژگی با ابعاد بالاتر، توانایی مناسبی در مدیریت مجموعه داده‌های محدود، نویزی یا دارای توزیع پیچیده دارد و از این‌رو برای پیش‌بینی پدیده‌های هیدرولیکی مانند آبشستگی، به‌ویژه در شرایط داده‌های آزمایشگاهی محدود، روش قابل اعتمادی محسوب می‌شود. شبکه‌های عصبی مصنوعی (ANN) نیز با ساختار چندلایه و سازوکار

ورودی را به همراه توصیف هر متغیر و محدوده تغییرات آن‌ها ارائه می‌دهد و چارچوب داده‌های آموزشی و آزمون مدل‌ها را مشخص می‌کند.

جدول ۱- ترکیبات مختلف ورودی مربوط به مدل‌های (ANN), (SVM), (KNN)

ترکیب	پارامترهای مؤثر
سناریو اول	
ترکیب ۱	$\frac{Hs_{max}}{B}, \frac{D}{B}, Fr, \frac{e}{B}$
ترکیب ۲	$\frac{Hs_{max}}{B}, \frac{D}{B}, \frac{e}{B}$
ترکیب ۳	$\frac{Hs_{max}}{B}, \frac{D}{B}, Fr$
ترکیب ۴	$\frac{Hs_{max}}{B}, Fr, \frac{e}{B}$
سناریو دوم	
ترکیب ۵	$\frac{Ls_{max}}{B}, \frac{D}{B}, Fr, \frac{e}{B}$
ترکیب ۶	$\frac{Ls_{max}}{B}, \frac{D}{B}, \frac{e}{B}$
ترکیب ۷	$\frac{Ls_{max}}{B}, \frac{D}{B}, Fr$
ترکیب ۸	$\frac{Ls_{max}}{B}, Fr, \frac{e}{B}$

بوده که طی فرآیند آموزش تعیین می‌شوند و تابع کرنل $K(x_i, x)$ امکان مدل‌سازی روابط غیرخطی بین متغیرها را فراهم می‌سازد. بدین ترتیب، روش SVM قادر است رفتار غیرخطی پدیده آبشستگی موضعی اطراف لوله‌ها را با دقت مناسبی پیش‌بینی نماید.

روش k-نزدیک‌ترین همسایه (KNN)

الگوریتم k-نزدیک‌ترین همسایه (KNN) یکی از روش‌های ساده و در عین حال کارآمد یادگیری ماشین مبتنی بر نمونه است که در مسائل طبقه‌بندی و رگرسیون کاربرد گسترده‌ای دارد. این الگوریتم بر اصل شباهت داده‌ها استوار است و فرض می‌کند نمونه‌هایی که در فضای ویژگی به یکدیگر نزدیک هستند، رفتار یا مقدار خروجی مشابهی دارند. برخلاف بسیاری از روش‌های یادگیری ماشین، KNN فاقد مرحله آموزش صریح بوده و تمامی داده‌های آموزشی را ذخیره می‌کند. در مرحله پیش‌بینی، برای هر نمونه جدید، فاصله آن تا داده‌های آموزشی محاسبه شده و k نزدیک‌ترین همسایه انتخاب می‌شوند.

شبکه عصبی مصنوعی (ANN)

شبکه‌های عصبی مصنوعی (Artificial Neural Networks; ANN) از قدرتمندترین ابزارهای یادگیری ماشین هستند که با الهام از سازوکار پردازش اطلاعات در مغز انسان توسعه یافته‌اند. این شبکه‌ها از مجموعه‌ای از نوروها تشکیل شده‌اند که در لایه‌های ورودی، پنهان و خروجی سازمان‌دهی شده و از طریق وزن‌های سیناپسی به یکدیگر متصل می‌شوند. یادگیری در ANN به صورت تدریجی و با تنظیم وزن‌ها از طریق الگوریتم‌های بهینه‌سازی نظیر

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان (SVM) نخستین بار توسط Vapnik و همکاران (۱۹۶۳) برای مسائل تشخیص الگو و طبقه‌بندی معرفی شد و در سال ۱۹۹۵ برای حالت‌های غیرخطی تعمیم یافت. این روش به دلیل اتکا بر اصل کمینه‌سازی ریسک ساختاری و بیشینه‌سازی حاشیه جداسازی، از توان تعمیم‌پذیری بالایی برخوردار بوده و در مسائل طبقه‌بندی و رگرسیون کاربرد گسترده‌ای دارد. در SVM، فرآیند مدل‌سازی شامل دو مرحله آموزش و آزمون است. در مرحله آموزش، مدل با استفاده از داده‌های آموزشی، ابرصفحه‌ای با حداکثر حاشیه تفکیک تعیین می‌کند. در مسائل غیرخطی، داده‌ها با استفاده از توابع کرنل به فضای ویژگی با ابعاد بالاتر نگاشت می‌شوند تا امکان جداسازی یا برازش مناسب فراهم گردد. فرم کلی تابع در حالت غیرخطی به صورت زیر بیان می‌شود:

$$b + \alpha_i y_i K(X_i, X) \sum_{i=1}^N = f(X) \quad (1)$$

که K کرنل و α_i ضرایب لاگرانژ هستند.

همچنین در روش ماشین بردار پشتیبان برای مسائل رگرسیونی (SVR)، رابطه بین متغیرهای ورودی و خروجی به صورت ترکیبی خطی از توابع کرنل بیان می‌شود. فرم کلی تابع پیش‌بینی در این روش به صورت زیر تعریف می‌گردد:

$$b + \alpha_i K(x_i, x) \sum_{i=1}^N = \hat{y} \quad (2)$$

که در این رابطه، $\hat{y}$ مقدار پیش‌بینی شده عمق آبشستگی موضعی، x بردار ورودی شامل پارامترهای هیدرولیکی و هندسی مؤثر و x_i داده‌های آموزشی می‌باشند. ضرایب α_i وزن بردارهای پشتیبان

پایاده سازی مدل ها

در این پژوهش، مدل های پیش بینی عمق آبشستگی با استفاده از سه الگوریتم یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و الگوریتم k-نزدیک ترین همسایه (KNN) توسعه داده شدند. کلیه مراحل شامل تنظیم پارامترها، آموزش و ارزیابی عملکرد مدل ها در نرم افزار Statistica نسخه ۱۴,۰,۰,۱۵ انجام شد. این نرم افزار به دلیل برخورداری از ابزارهای پیشرفته تحلیل آماری و ماثول های تخصصی یادگیری ماشین، امکان طراحی شبکه های عصبی چندلایه، انتخاب کرنل و تنظیم ابرپارامترها در SVM و پایاده سازی کارآمد KNN را فراهم می کند؛ ازاین رو به عنوان پلتفرم محاسباتی اصلی این مطالعه انتخاب شد.

شاخص های ارزیابی عملکرد

در این پژوهش، به منظور ارزیابی دقت و کارایی مدل های شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و الگوریتم k-نزدیک ترین همسایه (KNN)، از سه شاخص آماری متداول شامل ریشه میانگین مربعات خطا (RMSE)، ضریب کارایی (DC) و ضریب تعیین (R^2) استفاده شد. در روابط مربوط به این شاخص ها، X_{obs} و X_{pred} به ترتیب نشان دهنده مقادیر مشاهده شده و پیش بینی شده متغیر خروجی هستند. متغیر خروجی X نیز بسته به سناریوی مورد بررسی، بیانگر عمق آبشستگی موضعی (HS) یا طول آبشستگی (LS) است. شاخص RMSE میزان اختلاف بین مقادیر مشاهده شده و پیش بینی شده را نشان می دهد و مقادیر کمتر آن بیانگر دقت بالاتر مدل در پیش بینی است. ضریب کارایی DC میزان توانایی مدل در بازتولید مقادیر مشاهده شده را نسبت به میانگین داده های مشاهده ای نشان می دهد و هرچه مقدار آن به ۱ نزدیک تر باشد، عملکرد مدل مطلوب تر است. همچنین، ضریب تعیین (R^2) بیانگر میزان برازش و شدت ارتباط بین مقادیر مشاهده شده و پیش بینی شده است و مقادیر بالاتر آن نشان دهنده توانایی بیشتر مدل در تبیین تغییرات متغیر خروجی می باشد.

در روابط ۷ تا ۹، $\left(\left(\frac{X}{B}\right)_p\right)$ و $\left(\left(\frac{X}{B}\right)_o\right)$ به ترتیب بیانگر مقادیر بدون بعد مشاهده شده و پیش بینی شده متغیر X اعم از HS یا LS بوده و N تعداد کل داده ها را نشان می دهد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N \left(\left(\frac{X}{B}\right)_o - \left(\frac{X}{B}\right)_p\right)^2}{N}} \quad (7)$$

$$DC = 1 - \frac{\sum_{i=1}^N \left(\left(\frac{X}{B}\right)_o - \left(\frac{X}{B}\right)_p\right)^2}{\sum_{i=1}^N \left(\left(\frac{X}{B}\right)_o - \left(\frac{X}{B}\right)_o\right)^2} \quad (8)$$

$$R^2 = \left(\frac{\sum_{i=1}^N \left(\left(\frac{X}{B}\right)_o - \left(\frac{X}{B}\right)_o\right) \left(\left(\frac{X}{B}\right)_p - \left(\frac{X}{B}\right)_p\right)}{\sqrt{\sum_{i=1}^N \left(\left(\frac{X}{B}\right)_o - \left(\frac{X}{B}\right)_o\right)^2 \sum_{i=1}^N \left(\left(\frac{X}{B}\right)_p - \left(\frac{X}{B}\right)_p\right)^2}} \right)^2 \quad (9)$$

گرایان نزولی و پس انتشار خطا انجام می شود، به گونه ای که خطای بین خروجی پیش بینی شده و مقدار واقعی به حداقل برسد. به دلیل قابلیت شناسایی و مدل سازی روابط غیرخطی و تعاملات چندمتغیره، شبکه های عصبی در تحلیل سیستم های پیچیده مهندسی جایگاه ویژه ای دارند. در حوزه مهندسی آب و هیدرولیک، ANN به طور گسترده برای پیش بینی عمق آبشستگی موضعی به کار رفته و با استفاده از داده های آزمایشگاهی قادر است روابط میان متغیرهای هیدرولیکی (مانند سرعت جریان و عدد فرود)، ویژگی های هندسی (قطر لوله، نسبت دفن اولیه، طول تیغه) و خصوصیات رسوب را با دقت بالایی بازتولید کند. این ویژگی سبب می شود ANN نسبت به روابط تجربی کلاسیک، دقت بیشتر و تعمیم پذیری بالاتری در شرایط متنوع جریان و بستر ارائه دهد. در ساختار ANN، خروجی هر نورون از ترکیب وزنی ورودی ها به همراه بایاس محاسبه شده و سپس از یک تابع فعال سازی غیرخطی مانند ReLU، سیگموئید یا تانژانت هیپربولیک عبور می کند. فرم کلی این فرایند به صورت زیر بیان می شود:

$$b + X_i W_i \sum = net \quad (3)$$

$$f(net) = y \quad (4)$$

که در آن X_i ورودی ها، W_i وزن ها و f تابع فعال سازی است.

ورودی خالص (Net Input)

محاسبه مجموع وزنی ورودی ها:

$$net = \sum_{i=1}^N w_i x_i + b \quad (5)$$

که در آن X_i ورودی ها، w_i وزن های قابل یادگیری، و b بایاس (عرض از مبدا) می باشد.

خروجی نورون (Output Activation):

اعمال تابع فعال سازی غیرخطی (f) به ورودی خالص:

$$y = f(net) \quad (6)$$

که در آن y خروجی نهایی نورون و f تابع فعال سازی می باشد.

در این پژوهش، از KNN در حالت رگرسیون استفاده شد و پارامتر k (تعداد همسایگان) بر اساس آزمون و خطا و روش اعتبارسنجی متقابل بهینه سازی گردید تا کمترین خطا در پیش بینی عمق آبشستگی حاصل شود. این روش به دلیل سادگی، عدم نیاز به فرضیات پیچیده در مورد توزیع داده ها و عملکرد خوب در مجموعه داده های کوچک تا متوسط، گزینه مناسبی برای مقایسه با ANN و SVM در پیش بینی پدیده آبشستگی موضعی اطراف لوله های مجهز به تیغه نفوذناپذیر بود.

نتایج و بحث

این پژوهش با هدف ارزیابی و مقایسه عملکرد سه روش یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و الگوریتم k-نزدیک‌ترین همسایه (KNN) در پیش‌بینی عمق آبستنگی پیرامون خطوط لوله مستغرق عبوری از رودخانه‌ها انجام شد. برای این منظور، ۶۴ مجموعه داده تجربی استخراج شده از آزمایش‌های جباری (۱۳۹۹) در آزمایشگاه مرکز مطالعات رسوب سازمان آب و برق خوزستان مورد استفاده قرار گرفت. این داده‌ها طیفی از شرایط هیدرولیکی و هندسی مختلف در حضور تیغه نفوذناپذیر را شامل می‌شدند و امکان بررسی تأثیر پارامترهای مؤثر بر کنترل آبستنگی را فراهم کردند.

در این مطالعه، پارامترهای مؤثر بر پدیده آبستنگی به صورت بدون بعد بیان شدند تا قابلیت تعمیم نتایج افزایش یابد. برای مدل‌سازی عمق آبستنگی، هشت ترکیب مختلف از متغیرهای ورودی در نظر گرفته شد که شامل نسبت عمق آبستنگی به قطر لوله (D/ds)، نسبت طول تیغه به قطر لوله (D/L)، نسبت عمق جریان به قطر لوله (D/h)، عدد فرود (Fr) و نسبت دفن اولیه لوله (D/e) بودند. این ترکیب‌ها به گونه‌ای انتخاب شدند که اثر حضور یا حذف هر پارامتر بر دقت پیش‌بینی مدل‌ها قابل ارزیابی باشد و متغیرهای کلیدی کنترل‌کننده آبستنگی شناسایی شوند. برای توسعه مدل‌ها، داده‌ها به دو بخش آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم شدند تا از بیش‌برازش جلوگیری شده و توان تعمیم‌پذیری مدل‌ها ارزیابی گردد. همچنین پیش از فرآیند آموزش، داده‌ها نرمال‌سازی شدند تا اثر تفاوت مقیاس متغیرها کاهش یابد.

به منظور بهبود عملکرد مدل‌ها، فرآیند تنظیم ابرپارامترها برای هر الگوریتم انجام شد؛ به طوری که در مدل ANN تعداد لایه‌ها و نورون‌ها، در مدل SVM نوع کرنل و پارامترهای جریمه و در مدل KNN تعداد همسایگان با استفاده از روش اعتبارسنجی متقابل بهینه‌سازی شدند. برای ارزیابی کمی دقت مدل‌ها نیز معیارهایی نظیر ریشه میانگین مربعات خطا (RMSE)، ضریب تعیین (R^2) و ضریب نش-ساتکلیف (DC) در مراحل آموزش و آزمون مورد استفاده قرار گرفت. این رویکرد امکان مقایسه دقیق عملکرد مدل‌ها و شناسایی روش کارآمدتر برای پیش‌بینی عمق آبستنگی در کاربردهای مهندسی هیدرولیک را فراهم ساخت.

نتایج روش ANN

جدول ۲ خلاصه‌ای از نتایج ارزیابی آماری عملکرد مدل شبکه عصبی مصنوعی (ANN) را برای ترکیب‌های مختلف ورودی، بر اساس شاخص‌های ریشه میانگین مربعات خطا (RMSE)، ضریب تعیین (R^2) و ضریب نش-ساتکلیف (DC) ارائه می‌دهد. تحلیل این

نتایج نشان می‌دهد که در هر دو سناریوی تعریف شده، ترکیب اول به عنوان ترکیب بهینه ورودی، بالاترین دقت و کمترین خطا را در مراحل آموزش و آزمون به خود اختصاص داده است. این موضوع بیانگر توانایی بالای مدل ANN در بازتولید رفتار غیرخطی عمق آبستنگی و انطباق مناسب با داده‌های آزمایشگاهی می‌باشد.

$$\left(\frac{e}{B}\right), Fr, \left(\frac{D}{B}\right), \left(\frac{Hs_{max}}{B}\right).$$

در سناریوی اول که ترکیب ورودی شامل نسبت حداکثر عمق آبستنگی به عرض لوله ($\frac{Hs_{max}}{B}$)، نسبت قطر لوله به عرض ($\frac{D}{B}$)، عدد فرود (Fr) و نسبت دفن اولیه لوله ($\frac{e}{B}$) است، مدل ANN در مرحله آموزش به مقادیر $RMSE = 0.2093$ ، $R^2 = 0.9957$ و $DC = 0.9972$ دست یافت. همچنین در مرحله آزمون، مقادیر $RMSE = 0.3493$ ، $R^2 = 0.9805$ و $DC = 0.9794$ به دست آمد که نشان‌دهنده دقت بسیار بالا، پایداری مناسب و عدم بروز بیش‌برازش در مدل می‌باشد. این نتایج بیانگر آن است که پارامترهای هیدرولیکی و هندسی انتخاب شده در این سناریو، نقش تعیین‌کننده‌ای در پیش‌بینی دقیق عمق آبستنگی دارند.

در سناریوی دوم که ترکیب ورودی شامل نسبت حداکثر طول آبستنگی به عرض لوله ($\frac{Ls_{max}}{B}$)، نسبت قطر لوله به عرض ($\frac{D}{B}$)، عدد فرود (Fr) و نسبت دفن اولیه لوله ($\frac{e}{B}$) است، عملکرد مدل ANN همچنان قابل قبول ارزیابی شد، هرچند دقت آن نسبت به سناریوی اول اندکی کاهش یافت. در این سناریو، مقادیر شاخص‌ها در مرحله آموزش به ترتیب $RMSE = 2.134$ ، $R^2 = 0.9821$ و $DC = 0.9866$ و در مرحله آزمون $RMSE = 2.331$ ، $R^2 = 0.9640$ و $DC = 0.9617$ محاسبه گردید. این کاهش نسبی دقت نشان می‌دهد که استفاده از پارامترهای مرتبط با طول آبستنگی، نسبت به عمق آبستنگی، تأثیر کمتری در بهبود توان پیش‌بینی مدل ANN دارد. به طور کلی، نتایج حاصل از هر دو سناریو نشان می‌دهد که روش شبکه عصبی مصنوعی قادر است عمق آبستنگی اطراف خطوط لوله را با دقت بالایی پیش‌بینی نماید. با این حال، مقایسه شاخص‌های آماری بیانگر برتری نسبی سناریوی اول نسبت به سناریوی دوم است که این موضوع اهمیت انتخاب صحیح پارامترهای ورودی، به‌ویژه پارامترهای مرتبط با عمق آبستنگی، را در فرآیند مدل‌سازی برجسته می‌سازد.





شکل ۵ نمودارهای پراکنش مقادیر مشاهده شده آزمایشگاهی و مقادیر پیش‌بینی شده توسط مدل شبکه عصبی مصنوعی (ANN) را برای بهترین ترکیب ورودی (ترکیب اول) در مراحل آموزش و آزمون و در دو سناریوی تعریف شده نشان می‌دهد. بررسی این نمودارها بیانگر تطابق مناسب بین داده‌های پیش‌بینی شده و مقادیر واقعی و در نتیجه عملکرد قابل قبول مدل ANN در بازتولید رفتار پدیده آبستنگی است. مقادیر ضریب تعیین (R^2) نیز نشان‌دهنده همبستگی

آبشستگی را با دقت مناسبی پیش‌بینی کند. در مقابل، در سناریوی دوم پراکندگی نقاط افزایش یافته و مدل در برخی موارد تمایل به کم‌برآوردی مقادیر حدی نشان می‌دهد که احتمالاً ناشی از حساسیت کمتر پارامترهای ورودی این سناریو نسبت به تغییرات عمق آبشستگی است.


قوی میان داده‌های آزمایشگاهی و خروجی‌های مدل هستند. در سناریوی اول، مقدار (R^2) برای مراحل آموزش و آزمون به ترتیب برابر با ۰/۹۹۵۷ و ۰/۹۸۰۵ و در سناریوی دوم به ترتیب ۰/۹۸۱۶ و ۰/۸۸۳۶ به دست آمد. تحلیل کیفی نمودارها نشان می‌دهد که در سناریوی اول، توزیع نقاط در اطراف خط ۴۵ درجه از یک‌نواختی مطلوبی برخوردار بوده و مدل قادر است مقادیر حداقل و حداکثر عمق

جدول ۲- نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی (ANN) برای ترکیب‌های مختلف ورودی در دو سناریوی پیشنهادی

سناریو اول						
TRAIN			TEST			
DC	R^2	RMSE	DC	R^2	RMSE	نام ترکیب
۰/۹۹۷۲	۰/۹۹۵۷	۰/۲۰۹۳	۰/۹۷۹۴	۰/۹۸۰۵	۰/۳۴۹۳	ترکیب ۱
۰/۸۷۲۶	۰/۸۴۸۶	۰/۹۲۷۸	۰/۸۰۳۸	۰/۸۲۹۶	۱/۰۳۲	ترکیب ۲
۰/۴۹۸۵	۰/۳۹۱۳	۲/۴۵۱	۱۹/۶۶	۰/۲۴۴۱	۲/۶۳۳	ترکیب ۳
۰/۸۴۳۳	۰/۷۸۰۸	۱/۲۴۸	۰/۳۸۶۶	۰/۵۴۸۳	۱/۸۷۹	ترکیب ۴
سناریو دوم						
۰/۹۸۶۶	۰/۹۸۲۱	۲/۱۳۴	۰/۹۶۱۷	۰/۹۶۴۰	۲/۳۳۱	ترکیب ۵
۰/۹۰۱۰	۰/۸۶۶۷	۵/۳۹۲	۰/۷۶۲۸	۰/۷۶۴۴	۷/۸۸۲	ترکیب ۶
۶۶/۴۸	۰/۵۱۹۲	۱۱/۱۵	۰/۱۵۳۳	۰/۲۵۱۲	۱۱/۲۲	ترکیب ۷
۰/۶۰۶۹	۰/۴۷۳۶	۳/۱۰۱۷	۰/۳۶۷۷	۰/۳۹۷۷	۹/۳۴	ترکیب ۸



(الف)



(ب)

شکل ۵- نمودار پراکنش داده‌های آزمایشگاهی و پیش‌بینی شده مرحله آموزش و آزمون مربوط به روش ANN (الف: سناریو اول، ب: سناریو دوم)

نتایج روش SVM

شناسایی شده است. در سناریوی اول، مقادیر شاخص‌های آماری برای ترکیب اول در مرحله آموزش به ترتیب برابر با $R^2 = 0.9826$ ، $RMSE = 0.2167$ و $DC = 0.9816$ و در مرحله آزمون برابر با $R^2 = 0.8688$ ، $RMSE = 0.3826$ و $DC = 0.8836$ به دست آمد. این نتایج بیانگر توانایی مناسب مدل SVM در یادگیری روابط غیرخطی میان پارامترهای ورودی و خروجی و بازتولید قابل قبول رفتار داده‌های آزمایشگاهی در مرحله آزمون است. در سناریوی دوم نیز ترکیب اول همچنان بهترین عملکرد را در میان ترکیب‌های مختلف نشان داد، هرچند دقت پیش‌بینی نسبت به سناریوی اول کاهش یافت. در این سناریو، مقادیر شاخص‌ها در مرحله آموزش به ترتیب $R^2 = 0.9770$ ، $RMSE = 1.382$ و $DC = 0.9785$ و در مرحله آزمون $R^2 = 0.6538$ ، $RMSE = 3.602$ و $DC = 0.6725$ محاسبه گردید. کاهش مقادیر R^2 و DC و افزایش $RMSE$ در این سناریو نشان

جدول ۳ خلاصه نتایج ارزیابی آماری عملکرد مدل ماشین بردار پشتیبان (SVM) را برای تمامی ترکیب‌های ورودی، بر اساس شاخص‌های ضریب تعیین (R^2)، ریشه میانگین مربعات خطا ($RMSE$) و ضریب نش-ساتکلیف (DC) ارائه می‌دهد. در این پژوهش، مدل SVM با استفاده از تابع کرنل RBF پیاده‌سازی شد و پارامتر گاما (γ) از طریق آزمون و خطا تعیین گردید؛ به گونه‌ای که مقادیر مختلف این پارامتر بررسی و عملکرد هر حالت بر اساس شاخص‌های آماری ارزیابی شد و در نهایت مقدار بهینه بر مبنای بهترین نتایج آماری انتخاب گردید. بررسی مقادیر شاخص‌های ارائه‌شده در جدول ۳ نشان می‌دهد که در هر دو سناریوی مورد مطالعه، ترکیب اول در مقایسه با سایر ترکیب‌ها از عملکرد بهتری برخوردار بوده و به عنوان ترکیب بهینه ورودی برای مدل SVM

مقایسه دو سناریو حاکی از آن است که سناریوی اول از نظر دقت پیش بینی و پایداری آماری عملکرد بهتری نسبت به سناریوی دوم دارد. این موضوع اهمیت انتخاب صحیح پارامترهای ورودی را در استفاده از مدل SVM برای پیش بینی عمق آبشستگی برجسته می سازد و کاربرد این روش را به عنوان ابزاری قابل اطمینان در تحلیل مسائل مشابه تأیید می کند.

می دهد که پارامترهای ورودی مبتنی بر طول آبشستگی، نسبت به پارامترهای مرتبط با عمق آبشستگی، حساسیت کمتری در بهبود دقت مدل SVM دارند.



به طور کلی، نتایج به دست آمده نشان می دهد که روش SVM قادر است الگوهای موجود در داده های آزمایشگاهی را با دقت مناسبی شناسایی کرده و آن ها را در مرحله آزمون بازسازی نماید. با این حال،


جدول ۳- نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی (SVM) برای ترکیب های مختلف ورودی در دو سناریوی پیشنهادی

سناریو اول						
TRAIN			TEST			نام ترکیب
DC	R ²	RMSE	DC	R ²	RMSE	
۰/۹۸۲۶	۰/۹۸۱۶	۰/۲۱۶۷	۰/۸۶۸۸	۰/۸۸۳۶	۰/۳۸۲۶	ترکیب ۱
۰/۸۶۸۶	۰/۸۳۷۸	۰/۵۹۱۷	۰/۶۴۸۶	۰/۷۳۰۹	۰/۲۰۰۲	ترکیب ۲
۰/۴۴۹۷	۰/۳۹۱۱	۱/۲۰۲۹	۰/۲۱۵۲	۰/۱۸۴۰	۱/۳۶۴۴	ترکیب ۳
۰/۸۶۶۱	۰/۷۶۷۹	۰/۶۴۵۱	۰/۳۹۷۱	۰/۴۹۴۴	۱/۲۱۳۳	ترکیب ۴
سناریو دوم						
۰/۹۷۷۰	۰/۹۷۸۵	۱/۳۸۲۶	۰/۶۵۳۸	۰/۶۷۲۵	۳/۶۰۲۱	ترکیب ۵
۰/۹۱۲۵	۰/۸۶۹۵	۲/۷۳۳۵	۰/۶۲۶۴	۰/۷۰۸۶	۷/۰۵۱۴	ترکیب ۶
۰/۷۷۳۵	۰/۶۶۲۱	۴/۶۵۷۷	۰/۳۲۳۹	۰/۰۲۳۶	۰/۲۳۵۷	ترکیب ۷
۰/۵۵۶۸	۰/۴۸۱۹	۵/۵۶۸۶	۰/۱۳۶۵	۰/۲۸۴۹	۶/۲۶۸۳	ترکیب ۸

مراحل آموزش و آزمون به ترتیب برابر با ۰/۹۸۱۶ و ۰/۸۸۳۶ و در سناریوی دوم به ترتیب معادل ۰/۹۷۸۵ و ۰/۶۷۲۵ می باشد. بررسی توزیع نقاط پیرامون خط برابری نشان می دهد که در سناریوی اول، مدل توانسته است مقادیر حدی شامل بیشینه و کمینه داده های آزمایشگاهی را با دقت مناسبی بازتولید کند. در مقابل، در سناریوی دوم تمایل مدل به بیش برآورد مقادیر حدی نسبت به داده های واقعی مشاهده می شود که بیانگر حساسیت کمتر این سناریو در بازنمایی دقیق تغییرات پدیده مورد بررسی است.

شکل ۶ پراکنش مقادیر اندازه گیری شده آزمایشگاهی و مقادیر برآورد شده توسط مدل را برای بهترین ترکیب ورودی (ترکیب اول) در مراحل آموزش و آزمون و برای هر دو سناریوی مورد بررسی نمایش می دهد. ارزیابی بصری این نمودارها حاکی از عملکرد مناسب مدل و انطباق قابل قبول نتایج پیش بینی با داده های واقعی است. ضرایب تعیین به دست آمده بیانگر وجود همبستگی قوی و رابطه ای نزدیک به خطی میان مقادیر مشاهده شده و مقادیر برآورد شده می باشند که نشان دهنده دقت بالای مدل در پیش بینی پدیده مورد مطالعه است. مقادیر R² محاسبه شده برای نمودارهای پراکنش در سناریوی اول در





(ب)

شکل ۶- نمودار پراکنش داده‌های آزمایشگاهی و پیش‌بینی شده مرحله آموزش و آزمون مربوط به روش SVM (الف: سناریو اول، ب: سناریو دوم)

نتایج روش KNN

همسایه (KNN) را برای ترکیب‌های مختلف ورودی بر اساس شاخص‌های ضریب تعیین (R^2)، ریشه میانگین مربعات خطا

جدول ۴ نتایج ارزیابی آماری عملکرد الگوریتم k-نزدیک‌ترین

(RMSE) و ضریب نش-ساتکلیف (DC) در مرحله آزمون ارائه می‌دهد. تحلیل مقادیر این شاخص‌ها نشان می‌دهد که در هر دو سناریوی بررسی شده، ترکیب اول در مقایسه با سایر ترکیب‌ها از عملکرد بهتری برخوردار بوده و به‌عنوان ترکیب بهینه ورودی برای مدل KNN شناسایی شده است.

در سناریوی اول، مقادیر شاخص‌های آماری برای ترکیب اول در مرحله آزمون به ترتیب برابر با $R^2 = 0.6844$ ، $RMSE = 0.7623$ و $DC = 0.7866$ محاسبه گردید که بیانگر توانایی مناسب مدل KNN در پیش‌بینی مقادیر خروجی و بازنمایی قابل قبول تغییرات داده‌های آزمایشگاهی است. همچنین در سناریوی دوم، نتایج حاصل از مرحله آزمون شامل $R^2 = 0.6828$ ، $RMSE = 4.5028$ و $DC = 0.8352$ می‌باشد که نشان دهنده عملکرد نسبتاً مطلوب مدل، هرچند با افزایش

خطای پیش‌بینی نسبت به سناریوی اول، است. مقایسه نتایج دو سناریو حاکی از آن است که الگوریتم KNN قادر است الگوهای موجود در داده‌ها را بدون نیاز به فرضیات پیچیده آماری شناسایی کرده و در مرحله آزمون با دقت مناسبی بازتولید نماید. با این حال، تغییر در مقادیر شاخص‌ها نشان می‌دهد که حساسیت مدل KNN به نوع پارامترهای ورودی قابل توجه است. به‌طور کلی، نتایج حاصل تأیید می‌کند که ترکیب اول در هر دو سناریو به‌عنوان بهترین ترکیب ورودی عمل کرده و روش KNN می‌تواند به‌عنوان ابزاری قابل اعتماد برای پیش‌بینی پدیده آبشستگی در کاربردهای مشابه مورد استفاده قرار گیرد، به‌ویژه در شرایطی که حجم داده‌ها محدود و ساختار روابط غیرخطی باشد.

جدول ۴- نتایج ارزیابی عملکرد مدل شبکه عصبی مصنوعی (KNN) برای ترکیب‌های مختلف ورودی در دو سناریوی پیشنهادی

سناریو اول			
TEST			
نام ترکیب	RMSE	R^2	DC
ترکیب ۱	۰/۷۶۲۳	۰/۷۸۶۶	۰/۶۸۴۴
ترکیب ۲	۰/۸۳۳۹	۰/۷۱۴۷	۰/۶۲۲۲
ترکیب ۳	۱/۵۴۲۱	۰/۰۴۱۶	۱/۵۴۲۱
ترکیب ۴	۱/۱۹۲	۰/۴۵۰۶	۰/۰۲۵۶
سناریو دوم			
ترکیب ۵	۴/۵۰۲۸	۰/۸۳۵۲	۰/۶۸۲۸
ترکیب ۶	۴/۵۲۵۰	۰/۷۵۱۵	۰/۶۹۸۴
ترکیب ۷	۸/۰۳۹۰	۰/۱۴۰۰	۰/۰۸۱۹
ترکیب ۸	۶/۸۶۱۷	۰/۴۰۱۷	۰/۳۲۰۱

مقادیر حدی نسبت به داده‌های واقعی مشاهده می‌شود که می‌تواند ناشی از حساسیت بیشتر مدل به نوع پارامترهای ورودی در این سناریو باشد.


آنالیز حساسیت

آنالیز حساسیت از مراحل کلیدی در ارزیابی مدل‌های یادگیری ماشین است و با سنجش اثر حذف هر متغیر ورودی، میزان اهمیت نسبی پارامترها در پیش‌بینی عمق حداکثر آبشستگی موضعی (ds) را تعیین می‌کند. این فرایند علاوه بر کمک به تفسیر مدل، زمینه‌ای برای انتخاب مجموعه ورودی‌های بهینه و اولویت‌بندی پارامترهای ضروری در مطالعات آزمایشگاهی، میدانی و طراحی‌های مهندسی فراهم می‌سازد. در این پژوهش، آنالیز حساسیت با روش حذف تک‌متغیره (Leave-One-Out) و مطابق چارچوب تعریف‌شده در بخش ANN انجام شد. برای هر سه الگوریتم شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و k-نزدیک‌ترین همسایه

شکل ۷ نمودارهای پراکنش مقادیر اندازه‌گیری شده آزمایشگاهی و مقادیر برآوردشده توسط الگوریتم k-نزدیک‌ترین همسایه (KNN) را برای بهترین ترکیب ورودی (ترکیب اول) در مرحله آزمون و برای هر دو سناریوی مورد بررسی نشان می‌دهد. ارزیابی این نمودارها بیانگر تطابق قابل قبول نتایج پیش‌بینی شده با داده‌های واقعی و عملکرد مناسب مدل KNN در شبیه‌سازی رفتار پدیده مورد مطالعه است. ضرایب تعیین به‌دست آمده نشان دهنده وجود همبستگی نسبتاً قوی و رابطه‌ای نزدیک به خطی میان مقادیر مشاهده‌شده و مقادیر برآوردشده می‌باشند که حاکی از دقت مطلوب پیش‌بینی‌ها است. مقادیر R^2 محاسبه شده برای نمودارهای پراکنش مربوط به سناریوی اول و سناریوی دوم در مرحله آزمون به ترتیب برابر با ۰/۷۸۶۶ و ۰/۸۳۵۲ می‌باشد. بررسی توزیع نقاط نسبت به خط برابری نشان می‌دهد که در سناریوی اول، مدل KNN توانسته است مقادیر حدی شامل بیشینه و کمینه داده‌های آزمایشگاهی را با دقت مناسبی بازتولید نماید. در مقابل، در سناریوی دوم تمایل مدل به بیش برآورد

ورودی‌ها) است. در گام نخست، ترکیب کامل ورودی‌ها به‌عنوان حالت پایه در نظر گرفته شد. سپس اثر حذف جداگانه سه پارامتر بی‌بعد Fr (عدد فرود)، e/B (نسبت دفن اولیه لوله) و D/B (نسبت قطر لوله به عرض کانال) بر مقادیر $RMSE$ و DC بررسی گردید.

(KNN)، و برای هر دو سناریو، عملکرد مدل‌ها در مراحل آموزش (TRAIN) و آزمون (TEST) بر اساس شاخص‌های $RMSE$ و DC ارزیابی شد. در این شاخص‌ها، افزایش $RMSE$ و کاهش مقدار DC نشان‌دهنده افت دقت مدل نسبت به حالت مرجع (ترکیب کامل



(ب)


شکل ۷- نمودار پراکنش داده‌های آزمایشگاهی و پیش‌بینی شده مرحله آزمون مربوط به روش KNN (الف: سناریو اول، ب: سناریو دوم)

نشان‌دهنده اهمیت محدودتر این متغیر نسبت به دو پارامتر دیگر است. این نتیجه با رفتار فیزیکی فرآیند نیز سازگار است، چراکه در شرایط آزمایشگاهی حاضر، موقعیت اولیه لوله و رژیم جریان نقش بسیار مهم‌تری نسبت به هندسه نسبی لوله در کنترل عمق آبشستگی ایفا می‌کنند. بر اساس جمع‌بندی نهایی، رتبه‌بندی تاثیر پارامترها در تمامی مدل‌ها و هر دو سناریو به‌صورت $e/B \gg Fr > D/B$ حاصل شد. این رتبه‌بندی نشان می‌دهد که نسبت دفن اولیه لوله مهم‌ترین پارامتر کنترل‌کننده عمق آبشستگی است و باید در طراحی عبور خطوط لوله از بستر رودخانه‌ها به‌ویژه در حضور تیغه‌های غیرقابل نفوذ به‌عنوان اولویت اصلی مورد توجه قرار گیرد. انطباق نتایج مدل‌های داده‌محور با اصول فیزیکی پدیده نیز نشان می‌دهد که مدل‌های به‌کاررفته علاوه بر دقت پیش‌بینی مناسب، از اعتبار مهندسی قابل قبولی برخوردار هستند.


نتایج نشان داد که حذف پارامتر e/B بیشترین افزایش $RMSE$ و بیشترین کاهش DC را به‌ویژه در مرحله آزمون ایجاد می‌کند. این موضوع بیانگر حساسیت بسیار بالای مدل‌ها نسبت به این پارامتر و نقش کلیدی آن در کنترل عمق آبشستگی است. از منظر فیزیکی، کاهش e/B نشان‌دهنده قرارگیری لوله در نزدیکی بستر است؛ وضعیتی که موجب افزایش گرادیان فشار در زیر لوله، تشدید جریان زیرسطحی و تقویت گردابه‌های موضعی می‌شود و در نهایت به رشد چاله آبشستگی می‌انجامد. حذف عدد فرود (Fr) نیز موجب افت محسوس عملکرد مدل‌ها شد، اما شدت اثر آن کمتر از پارامتر e/B بود. عدد فرود به‌عنوان شاخص رژیم جریان، نقش مهمی در شدت گردابه‌ها، الگوی جریان و قابلیت جابه‌جایی رسوب دارد و بنابراین حذف آن مستقیماً بر دقت مدل‌ها اثر می‌گذارد. در مقابل، حذف پارامتر D/B کمترین تغییر را در مقادیر $RMSE$ و DC ایجاد کرد که

جدول ۵- آنالیز حساسیت مربوط به روش‌های ANN, SVM, KNN هر دو سناریو

روشن ANN							
سناریو اول							
TRAIN			TEST			حذف پارامتر	نام ترکیب
DC	R ²	RMSE	DC	R ²	RMSE		
۹۹۷۲/۰	۰/۹۹۵۷	۲۰۹۳/۰	۹۷۹۴/۰	۹۸۰۵/۰	۳۴۹۳/۰	-	ترکیب ۱
۸۷۲۶/۰	۸۴۸۶/۰	۹۲۷۸/۰	۸۰۳۸/۰	۸۲۹۶/۰	۰۳۲/۱	Fr	ترکیب ۱
۴۹۸۵/۰	۳۹۱۳/۰	۴۵۱/۲	۶۶/۱۹	۲۴۴۱/۰	۶۳۳/۲	$\frac{e}{B}$	ترکیب ۱
۸۴۳۳/۰	۷۸۰۸/۰	۲۴۸/۱	۳۸۶۶/۰	۵۴۸۳/۰	۸۷۹/۱	$\frac{D}{B}$	ترکیب ۱
سناریو دوم							
۹۸۶۶/۰	۰/۹۸۲۱	۱۳۴/۲	۹۶۱۷/۰	۹۶۴۰/۰	۳۳۱/۲	-	ترکیب ۱
۹۰۱۰/۰	۸۶۶۷/۰	۳۹۲/۵	۷۶۲۸/۰	۷۶۴۴/۰	۸۸۲/۷	Fr	ترکیب ۱
۴۸/۶۶	۵۱۹۲/۰	۱۵/۱۱	۱۵۳۳/۰	۲۵۱۲/۰	۲۲/۱۱	$\frac{e}{B}$	ترکیب ۱
۶۰۶۹/۰	۴۷۳۶/۰	۳/۱۰۱۷	۳۶۷۷/۰	۳۹۷۷/۰	۳۴/۹	$\frac{D}{B}$	ترکیب ۱
روشن SVM							
سناریو اول							
TRAIN			TEST			حذف پارامتر	نام ترکیب
DC	R ²	RMSE	DC	R ²	RMSE		
۰/۹۸۲۶	۰/۹۸۱۶	۰/۲۱۶۷	۰/۸۶۸۸	۰/۸۸۳۶	۰/۳۸۲۶	-	ترکیب ۱
۰/۸۶۸۶	۰/۸۳۷۸	۰/۵۹۱۷	۰/۶۴۸۶	۰/۷۳۰۹	۰/۲۰۰۲	Fr	ترکیب ۱
۰/۴۴۹۷	۰/۳۹۱۱	۱/۲۰۳۹	۰/۲۱۵۲	۰/۱۸۴۰	۱/۳۶۴۴	$\frac{e}{B}$	ترکیب ۱
۰/۸۶۶۱	۰/۷۶۷۹	۰/۶۴۵۱	۰/۳۹۷۱	۰/۴۹۴۴	۱/۲۱۳۳	$\frac{D}{B}$	ترکیب ۱
سناریو دوم							
۰/۹۷۷۰	۰/۹۷۸۵	۱/۳۸۷۶	۰/۶۵۳۸	۰/۶۷۲۵	۳/۶۰۲۱	-	ترکیب ۱
۰/۹۱۲۵	۰/۸۶۹۵	۲/۷۳۳۵	۰/۶۲۶۴	۰/۷۰۸۶	۷/۰۵۱۴	Fr	ترکیب ۱
۰/۷۷۳۵	۰/۶۶۲۱	۴/۶۵۷۷	۰/۳۲۳۹	۰/۰۲۳۶	۰/۲۳۵۷	$\frac{e}{B}$	ترکیب ۱
۰/۵۵۶۸	۰/۴۸۱۹	۵/۵۶۸۶	۰/۱۳۶۵	۰/۲۸۴۹	۶/۲۶۸۳	$\frac{D}{B}$	ترکیب ۱
روشن KNN							
سناریو اول							
TRAIN			TEST			حذف پارامتر	نام ترکیب
DC	R ²	RMSE	DC	R ²	RMSE		
۰/۶۸۴۴	۰/۷۸۶۶	۰/۷۶۲۳	۰/۷۶۲۳	۰/۷۶۲۳	۰/۷۶۲۳	-	ترکیب ۱
۰/۶۲۲۲	۰/۷۱۴۷	۰/۸۳۳۹	۰/۸۳۳۹	۰/۸۳۳۹	۰/۸۳۳۹	Fr	ترکیب ۱
۱/۵۴۲۱	۰/۰۴۱۶	۱/۵۴۲۱	۱/۵۴۲۱	۱/۵۴۲۱	۱/۵۴۲۱	$\frac{e}{B}$	ترکیب ۱
۰/۰۲۵۶	۰/۴۵۰۶	۱/۱۹۲	۱/۱۹۲	۱/۱۹۲	۱/۱۹۲	$\frac{D}{B}$	ترکیب ۱
سناریو دوم							
۰/۶۸۲۸	۰/۸۳۵۲	۴/۵۰۲۸	۴/۵۰۲۸	۴/۵۰۲۸	۴/۵۰۲۸	-	ترکیب ۱
۰/۶۹۸۴	۰/۷۵۱۵	۴/۵۲۵۰	۴/۵۲۵۰	۴/۵۲۵۰	۴/۵۲۵۰	Fr	ترکیب ۱
۰/۰۸۱۹	۰/۱۴۰۰	۸/۰۳۹۰	۸/۰۳۹۰	۸/۰۳۹۰	۸/۰۳۹۰	$\frac{e}{B}$	ترکیب ۱
۰/۳۲۰۱	۰/۴۰۱۷	۶/۸۶۱۷	۶/۸۶۱۷	۶/۸۶۱۷	۶/۸۶۱۷	$\frac{D}{B}$	ترکیب ۱



(الف)



(ب)

شکل ۸- نمودارهای جعبه‌ای مقایسه توزیع خطاهای پیش‌بینی هندسه چاله آبخستگی موضعی در مجموعه آزمون برای سه مدل یادگیری ماشین ANN، SVM و KNN مربوط به هر دو سناریو

محور عمودی مقدار خطای پیش‌بینی را نشان می‌دهد. جعبه‌ها بازه بین‌چارکی (IQR)، خط میانی میانه خطا، سبیل‌ها حدود ۱/۵ برابر IQR و نقاط بیرونی داده‌های پرت را نمایش می‌دهند. در سناریوی اول، مدل ANN کمترین پراکندگی خطا و میانه‌ای نزدیک به صفر دارد که بیانگر دقت و پایداری بالای آن است. روش SVM بیشترین پراکندگی و پرت‌های متعدد را نشان می‌دهد که احتمالاً ناشی از حساسیت این الگوریتم به نمونه‌های مرزی یا ناهمگونی داده‌هاست. مدل KNN از نظر میزان پراکندگی بین ANN و SVM قرار

مقایسه نتایج سه روش بررسی شده (ANN, SVM, QNET) شده شکل ۸ نمودارهای جعبه‌ای مقایسه خطاهای پیش‌بینی سه مدل ANN، SVM و KNN را در مجموعه آزمون نشان می‌دهد؛ به‌طوری‌که شکل (الف) مربوط به سناریوی اول، یعنی پیش‌بینی عمق حداکثر آبخستگی (Hsmax) با ترکیب ورودی برتر (ترکیب ۱) و شکل (ب) مربوط به سناریوی دوم، یعنی پیش‌بینی طول حداکثر چاله آبخستگی (Lsmax) با ترکیب ورودی برتر (ترکیب ۵) است. در هر دو نمودار، محور افقی مدل‌ها (KNN, SVM, ANN, EXP) و

صورت $e/B \gg Fr > D/B$ به دست آمد. به طور کلی، یافته‌ها نشان می‌دهد که ANN ابزاری کارآمد برای پیش‌بینی هندسه آبستگي در حضور تیغه‌های حفاظتی است و می‌تواند در طراحی و مدیریت ریسک خطوط لوله به کار گرفته شود. استفاده از مدل‌های ترکیبی و داده‌های میدانی در پژوهش‌های آینده می‌تواند دقت و قابلیت تعمیم نتایج را افزایش دهد.

منابع

- Abdolrasol, M. G. M., Hussain, S. M. S., Ustun, T. S., Sarker, M. R., Hannan, M. A., Mohamed, R., Abd Ali, J., Mekhilef, S. and Milad, A. 2021. Artificial neural networks based optimization techniques: A review. *Electronics*. 10(21): 2689. <https://doi.org/10.3390/electronics10212689>
- Asim, M., Rashid, A. and Ahmad, T. 2022. Scour modeling using deep neural networks based on hyperparameter optimization. *ICT Express*. 8(3): 357–362. <https://doi.org/10.1016/j.ict.2021.09.012>
- Bateni, S. M., Borghei, S. M. and Jeng, D. S. 2007. Neural network and neuro-fuzzy assessments for scour depth around bridge piers. *Engineering Applications of Artificial Intelligence*. 20(3): 401–414. <https://doi.org/10.1016/j.engappai.2006.06.012>
- Bijker, E. and Leeuwestein, W. 1984. Interaction between pipelines and the seabed under the influence of waves and currents. *Proceedings / Springer*. https://doi.org/10.1007/978-94-009-4958-4_28
- Chao, J. L. and Hennessy, P. V. 1972. Local scour under ocean outfall pipelines. *Journal (Water Pollution Control Federation)*. 44(7): 1443–1447.
- Chiew, Y. M. 1990. Mechanics of local scour around submarine pipelines. *Journal of Hydraulic Engineering*. 116(4): 515–529. [https://doi.org/10.1061/\(ASCE\)0733-9429\(1990\)116:4\(515\)](https://doi.org/10.1061/(ASCE)0733-9429(1990)116:4(515))
- Chiew, Y. M. 1991. Prediction of maximum scour depth at submarine pipelines. *Journal of Hydraulic Engineering*. 117(4): 452–466. [https://doi.org/10.1061/\(ASCE\)0733-9429\(1991\)117:4\(452\)](https://doi.org/10.1061/(ASCE)0733-9429(1991)117:4(452))
- Choi, S. U. and Jung, S. H. 2006. Prediction of local scour around bridge piers using artificial neural networks. *JAWRA Journal of the American Water Resources Association*. 42(2): 487–494. <https://doi.org/10.1111/j.1752-1688.2006.tb03852.x>
- Cover, T. M. and Hart, P. E. 1967. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*. 13(1): 21–27. <https://doi.org/10.1109/TIT.1967.1053964>
- Habib, M. A., Abolfathi, S., O'Sullivan, J. J. and

می‌گیرد. همچنین ANN نزدیک‌ترین توزیع خطا به داده‌های واقعی (EXP) را نشان می‌دهد. در سناریوی دوم، اگرچه مقیاس خطا به دلیل دامنه بزرگ‌تر متغیر هدف افزایش یافته است، الگوی عملکرد مدل‌ها مشابه سناریوی اول باقی می‌ماند. ANN همچنان بالاترین دقت را با کوچک‌ترین IQR و کمترین خطای میانه نشان می‌دهد، در حالی که SVM بیشترین میزان پراکندگی و پرت‌ها را دارد. مدل KNN عملکردی متوسط داشته و پراکندگی آن بیشتر از ANN اما کمتر از SVM است. پرت‌های مشاهده‌شده، به‌ویژه در SVM، عمدتاً مربوط به نمونه‌هایی با طول چاله بسیار بزرگ هستند که پیش‌بینی آن‌ها برای همه مدل‌ها دشوار بوده است.

مقایسه کلی دو سناریو:

با وجود تفاوت اساسی در متغیر هدف (عمق حداکثر در سناریوی اول در مقابل طول حداکثر در سناریوی دوم) و افزایش مقیاس خطاها در سناریوی دوم، الگوی نسبی عملکرد سه مدل در هر دو حالت تقریباً یکسان باقی مانده است؛ به طوری که شبکه عصبی مصنوعی (ANN) در هر دو سناریو کمترین خطای مرکزی (میانه پایین تر)، کمترین پراکندگی و کمترین تعداد پرت را از خود نشان می‌دهد. در حالی که SVM بیشترین نوسان و حساسیت و KNN عملکردی متوسط را داشته است.

نتیجه‌گیری

در این پژوهش، توانایی سه الگوریتم یادگیری ماشین شامل شبکه عصبی مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و k -نزدیک‌ترین همسایه (KNN) برای پیش‌بینی عمق و طول چاله آبستگي موضعی پیرامون خطوط لوله مدفون در بستر رودخانه در حضور تیغه غیرقابل نفوذ، با استفاده از داده‌های آزمایشگاهی کنترل شده مورد ارزیابی قرار گرفت. نتایج نشان داد که مدل ANN در هر دو سناریوی بررسی شده عملکردی به طور معنی‌دار برتر نسبت به دو الگوریتم دیگر دارد؛ به گونه‌ای که کمترین مقادیر RMSE و بیشترین ضرایب تبیین و هماهنگی را در مراحل آموزش و آزمون ارائه داد و توزیع خطای آن در نمودارهای جعبه‌ای نزدیک‌ترین رفتار را به داده‌های واقعی نشان داد. در مقابل، SVM بیشترین پراکندگی خطا و حساسیت به داده‌های حدی را داشت و عملکرد KNN در سطحی میانی قرار گرفت. تحلیل حساسیت مبتنی بر حذف تک‌متغیره بیان کرد که نسبت دفن اولیه لوله به عرض کانال (e/B) مهم‌ترین ورودی مؤثر بر دقت مدل‌ها است و حذف آن بیشترین کاهش عملکرد را ایجاد می‌کند. پس از آن، عدد فرود (Fr) نقش قابل توجهی در کنترل شدت جریان و هندسه آبستگي داشت، در حالی که نسبت D/B کمترین اثر نسبی را نشان داد. بنابراین، رتبه اهمیت پارامترها به

- Science. 24(2): 69–85.
- Majdi Asl, M., Faraji, A., Omidpour Alavian, T. and Kouhdaragh, M. 2026. Investigation of scour depth around pipelines crossing rivers using artificial intelligence methods. *Iranian Journal of Soil and Water Research*. 57(3): 567–587. <https://doi.org/10.22059/ijswr.2026.402770.670011>
- Marulasiddappa, S. B., Patil, A. P., Kuntoji, G., Praveen, K. M. and Naganna, S. R. 2024. Prediction of scour depth around bridge abutments using ensemble machine learning models. *Neural Computing and Applications*. 36: 1369–1380. <https://doi.org/10.1007/s00521-023-09109-4>
- Nandi, B., Patel, G. and Das, S. 2024. Prediction of maximum scour depth at clear water conditions: Multivariate and robust comparative analysis between empirical equations and machine learning approaches using extensive reference metadata. *Journal of Environmental Management*. 354: 120349. <https://doi.org/10.1016/j.jenvman.2024.120349>
- Rahman, F. and Chavan, R. 2024. Machine learning application in prediction of scour around bridge piers: A comprehensive review. *Archives of Computational Methods in Engineering*. <https://doi.org/10.1007/s11831-024-10167-7>
- Shi, Y., Wei, J., Yang, H., Li, S. and Li, Y. P. 2026. Prediction of local scour beneath vibrating submarine pipelines subjected to waves and currents based on CFD and machine learning approach. *Ocean Engineering*. 345: 123777. <https://doi.org/10.1016/j.oceaneng.2025.123777>
- Soltani Sotobadi, M., Omidpour Alavian, T. and Kardan, N. 2025. Forecasting the Local Scour Depth around Cylindrical Bridge Foundations on Cohesive Soil Utilizing Meta Models. *Iranian Journal of Irrigation and Drainage*. 19(2): 275–290.
- Vapnik, V. N. 1995. *The Nature of Statistical Learning Theory*. Springer-Verlag.
- Wu, Y. and Chiew, Y. M. 2012. Three-dimensional scour at submarine pipelines in unidirectional steady current. *Scour and Erosion: Proceedings of the 6th International Conference on Scour and Erosion*. 45–54. [https://doi.org/10.1061/41147\(392\)45](https://doi.org/10.1061/41147(392)45)
- Salaudinn, M. 2024. Efficient data-driven machine learning models for scour depth predictions at sloping sea defences. *Frontiers in Built Environment*. 10: 1343398. <https://doi.org/10.3389/fbuil.2024.1343398>
- Hassan, W. H. and Jalal, H. K. 2021. Prediction of the depth of local scouring at a bridge pier using a gene expression programming method. *SN Applied Sciences*. 3: 159. <https://doi.org/10.1007/s42452-020-04048-1>
- Haykin, S. 1999. *Neural networks: A comprehensive foundation* (2nd ed.). Prentice-Hall.
- Hu, R., Wang, X., Liu, H., Leng, H. and Lu, Y. 2022. Scour characteristics and equilibrium scour depth prediction around a submarine piggyback pipeline. *Journal of Marine Science and Engineering*. 10(3): 350. <https://doi.org/10.3390/jmse10030350>
- Ibrahim, A. and Nalluri, C. 1986. Scour prediction around marine pipelines. *Proceedings of the 5th International Symposium on Offshore Mechanics and Arctic Engineering*. 679–684.
- Jabari, V., Masjedi, A., Haidarnejad, M., Kamanbedast, A. A. and Bordbar, A. 2020. Control of scour around the submarine pipelines in the river bed. *Iranian Journal of Watershed Management Science & Engineering*. 14(48).
- Jabari, V., Masjedi, A., Heidarnejad, M., Kamanbedast, A. and Bordbar, A. 2020. Scour control around submerged pipeline on the river bed using an impermeable spoiler. *Ain Shams Engineering Journal*. 12(4). <https://doi.org/10.1016/j.asej.2020.09.001>
- Kim, K., Cho, J., Lee, H. and Oh, H. 2013. Prediction of the scour depth around the pipeline exposed to waves using neural networks. *Journal of the Korean Geoenvironmental Society*. 14(5): 1–10.
- Kjeldsen, S. P., Gjørsvik, O., Bringaker, K. G. and Jacobsen, J. 1981. Local scour near offshore pipelines. *Proceedings of the Second International Conference on Port and Ocean Engineering under Arctic Conditions*.
- Majedi Asl, M., Daneshfaraz, R. and Valizadeh, S. 2020. A laboratory study of longitudinal, transverse and topography of the scouring of bridge pier group with sand mining. *Journal of Water and Soil*

Prediction of Scour Depth and Length around Buried Pipelines Using Machine Learning Methods

T. Omidpour Alavian¹, M. Majedi Asl^{2*}, M. Golinejad Sham Asbi³, M. Kouhdaragh⁴

Recived: Feb.17, 2025

Accepted: May.17, 2026

Abstract

Local scour around buried pipelines in riverbeds is one of the major factors contributing to bed instability and the vulnerability of fluid-transport infrastructure. Incorrect estimation of scour geometry can lead to significant technical, economic, and environmental damages. Therefore, the development of reliable methods for predicting scour-hole geometry plays an important role in the safe and economical design of such structures. Recent studies have shown that machine learning techniques and artificial intelligence algorithms have attracted considerable attention as effective tools for analyzing and predicting complex hydraulic phenomena. In this study, the performance of three machine learning approaches, namely artificial neural networks (ANN), support vector machines (SVM), and the k-nearest neighbors (KNN) algorithm, was evaluated for predicting the geometry of local scour holes, including maximum scour depth and maximum scour length, around buried pipelines in the presence of an impermeable plate. The analysis was conducted using 64 sets of laboratory experimental data. The hydraulic and geometric input parameters included the flow Froude number, the ratio of initial burial depth of the pipeline to channel width (e/B), and the ratio of pipeline diameter to channel width (D/B). The results indicated that the ANN model achieved more accurate and stable predictions than the other methods, with coefficients of determination (R^2) greater than 0.96 for predicting both scour depth and scour length, while the SVM and KNN models showed comparatively lower accuracy. Sensitivity analysis also revealed that the ratio of initial burial depth to channel width (e/B) is the most influential parameter affecting local scour geometry. Overall, the findings demonstrate that machine learning approaches, particularly artificial neural networks, can serve as effective tools for predicting scour and improving the design and safety of buried pipelines in riverbeds.

Keywords: Artificial Neural Network, Buried Pipeline, Impermeable Blade, Machine Learning, Local scour, Support Vector Machine, k-Nearest Neighbors, Sensitivity Analysis

1- Ph.D. Candidate, Department of Civil Engineering, Water Engineering and Hydraulic Structures, University of Maragheh, Maragheh, Iran

2- Associate Professor, Department of Civil Engineering, Faculty of Engineering, University of Maragheh, Maragheh, Iran

3- Master's Student, Department of Civil Engineering, Water Engineering and Hydraulic Structures, University of Maragheh, Maragheh, Iran

4- Department of Civil Engineering, Malekan Branch, Islamic Azad University, Malekan, Iran

(*Corresponding Author Email: majedi@maragheh.ac.ir-mehdi.majedi@gmail.com)