

مقاله علمی-پژوهشی

پیش‌بینی عمق آبشستگی موضعی اطراف پایه‌های پل استوانه‌ای در بسترهای با خاک چسبنده با استفاده از روش‌های فرامدلی

مهدی سلطانی ستوبادی^۱، توحید امیدپور علویان^{۲*}، نازیلا کاردان^۳

تاریخ دریافت: ۱۴۰۳/۱۱/۲۹ تاریخ پذیرش: ۱۴۰۴/۰۱/۱۲

چکیده

آبشستگی، پدیده‌ای فرسایشی ناشی از جریان آب در رودخانه‌ها، به‌ویژه اطراف پایه‌های پل است که فرآیندی تابع زمان بوده و در صورت تخمین نادرست عمق آن، طراحی پی‌ها را ناکافی یا غیراقتصادی می‌کند و خطر خرابی سازه‌ای را افزایش می‌دهد. مطالعه و بررسی روش‌های مؤثر برای تخمین میزان آبشستگی به منظور طراحی درست سازه‌ای از اهمیت ویژه‌ای برخوردار است. پژوهش‌های اخیر نشان داده‌اند تکنیک‌های نوین یادگیری ماشین و الگوریتم‌های هوش مصنوعی به‌عنوان ابزارهای پیشرفته برای تحلیل و پیش‌بینی آبشستگی مورد توجه قرار گرفته‌اند. استفاده از این تکنیک‌های پیشرفته می‌تواند به بهینه‌سازی روش‌های حفاظتی و طراحی و در نهایت به ارتقای ایمنی و پایداری سازه‌های پل کمک شایانی نماید. از این رو در این پژوهش، عملکرد روش‌های SVM، QNET و ANN در پیش‌بینی عمق آبشستگی موضعی اطراف پایه‌های پل استوانه‌ای در بسترهای با خاک چسبنده به کمک ۱۲۲ سری داده آزمایشگاهی مورد ارزیابی قرار گرفت تا اثربخشی این روش‌ها در تخمین این پدیده و بهبود عملکرد سازه‌های پل بررسی شود. پارامترهای هندسی و هیدرولیکی مورد استفاده در این پژوهش شامل عدد فرود پایه، عمق پی‌بعد جریان نزدیک شونده، اندازه پی‌بعد ذره رسوب و مقاومت برشی بستر می‌باشد. نتایج نشان داد این روش‌ها در ۹۶ درصد موارد پیش‌بینی‌های دقیقی ارائه می‌دهند. مدل QNET در ۹۲ درصد موارد عملکرد بهتری نسبت به SVM و ANN داشته و دقت پیش‌بینی را تا ۹۸ درصد افزایش داد. در مقایسه، SVM در ۸۰ درصد و ANN در ۸۵ درصد موارد نتایج قابل‌قبولی نشان دادند، اما QNET در تمام موارد نسبت به دو روش دیگر برتری داشت. تحلیل حساسیت مشخص کرد عدد فرود پایه با تأثیر ۸۲ درصدی، مهم‌ترین عامل در تعیین عمق آبشستگی است و تغییرات آن می‌تواند تا ۳۰ درصد عمق فرسایش را تغییر دهد. در نهایت این پژوهش راهکاری دقیق و مؤثر برای پیش‌بینی آبشستگی ارائه می‌دهد که به مهندسان کمک می‌کند پل‌هایی مقاوم‌تر و اقتصادی‌تر طراحی کنند.

واژه‌های کلیدی: آبشستگی، پایه‌های پل، عمق فرسایش، خاک چسبنده، روش‌های فرامدلی

مقدمه

گسیختگی‌های قابل‌توجهی می‌گردد. از این رو بررسی مکانیسم رخداد این پدیده و تخمین درست آن از اهمیت بسزایی برخوردار است. بروز ر و اوادکویو در مطالعه‌ای اشاره می‌کنند که به دلیل اختلاف تا ۵ برابر در مقادیر حاصل از روابط تجربی برای تعیین عمق آبشستگی اطراف پایه‌های پل، در سال‌های اخیر تلاش‌های تحقیقاتی زیادی برای اصلاح و بهبود این روابط انجام شده است (Breusers and Raudkivi, 1991). جنگ و هوانگ در مطالعه‌ای برای پیش‌بینی عمق آبشستگی در اطراف پایه‌های پل، از شبکه‌های عصبی استفاده کردند و به این نتیجه رسیدند که در حل برخی از مشکلات خاص، نتایج ANN در مقایسه با نتایج نظری و تجربی از دقت بالایی برخوردار است (Jang and Huang, 1993). ریچاردسون و همکاران در مطالعات انجام‌شده در نیوزیلند اشاره می‌کنند که حدود ۲ درصد از کل هزینه‌ها به ترمیم خسارت‌های پل‌ها و نگهداری از آن‌ها اختصاص داده می‌شود که از این مقدار، ۲ درصد به ترمیم آبشستگی تکیه‌گاه‌های کناری تعلق

آبشستگی موضعی اطراف پایه‌های پل یکی از چالش‌های کلیدی در مهندسی سازه‌های هیدرولیکی است که به دلیل تأثیرات مخرب آن بر پایداری پل‌ها مورد توجه قرار گرفته است. در این راستا، پیش‌بینی دقیق عمق چاله‌ی آبشستگی تحت شرایط و جریان‌های مختلف در طراحی‌های سازه‌ای از اهمیت ویژه‌ای برخوردار است و عدم محاسبه درست آن و عدم اعمال آن در طراحی‌های پی و پایه منجر به

- ۱- دانشجوی کارشناسی ارشد مهندسی عمران، مهندسی آب و سازه‌های هیدرولیکی، دانشگاه شهید مدنی آذربایجان، تبریز، ایران
 - ۲- دانشجوی دکتری مهندسی عمران، مهندسی آب و سازه‌های هیدرولیکی، دانشگاه مراغه، مراغه، ایران
 - ۳- دانشیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه شهید مدنی آذربایجان، تبریز، ایران
- (*- نویسنده مسئول: Email: t.omidpour@stu.maragheh.ac.ir)

که استفاده از تکنیک‌های یادگیری ماشین می‌تواند دقت پیش‌بینی را نسبت به روش‌های سنتی به طرز قابل‌توجهی افزایش دهد (Alavi Mirdamadi, 2021) and. ژانگ در مطالعه‌ای به بررسی توانایی شبکه‌های عصبی عمیق در تحلیل داده‌های بزرگ و شبیه‌سازی‌های هیدرولیکی پرداخت. نتایج این تحقیق نشان داد که این روش‌ها قادر به شناسایی روابط غیرخطی و پیچیده بین پارامترهای هیدرولیکی و عمق آبستگي هستند و می‌توانند به‌دقت بالاتری در پیش‌بینی آبستگي منجر شوند (Zhang, 2022). کومار و سینگ در مطالعه‌ای یک رویکرد ترکیبی را بررسی کردند که شامل ترکیب الگوریتم‌های یادگیری ماشین با شبیه‌سازی‌های هیدرولیکی است. این تحقیق نشان داد که مدل‌های ترکیبی می‌توانند به بهبود دقت پیش‌بینی آبستگي کمک کنند و به مهندسان این امکان را می‌دهند که با در نظر گرفتن شرایط هیدرولیکی و ویژگی‌های فیزیکی بستر، تحلیل دقیق‌تری از آبستگي محلی انجام دهند (Kumar and Singh, 2023). لی و پارک در مطالعه‌ای چالش‌های موجود در استفاده از روش‌های فرامدلی برای پیش‌بینی آبستگي را بررسی نمودند و تأکید کردند که بهبود دقت پیش‌بینی، نیازمند جمع‌آوری داده‌های دقیق و به‌روز و همچنین توسعه الگوریتم‌های پیشرفته‌تر است (Lee and Park, 2024). طبق آمار ارائه‌شده، در ایران مشکل آبستگي موضعی در پایه‌های پل عامل اصلی تخریب آن‌ها می‌باشد. نمونه‌ای از آبستگي پایه‌ی پل در شکل ۱ نشان داده شده است.

یکی از متداول‌ترین روش‌های جایگزین برای روابط موجود در مدل‌سازی پدیده‌های فیزیکی پیچیده، روش‌های موسوم به داده‌کاوی است. از میان این روش‌ها، شبکه‌های عصبی مصنوعی تاکنون به‌طور وسیعی در مطالعات هیدرولیکی مورد استفاده قرار گرفته‌اند. این تحقیق به اهمیت استفاده از داده‌های تجربی و شبیه‌سازی‌های عددی برای بهبود مدل‌های پیش‌بینی تأکید دارد. به دلیل تعامل ساختار جریان (گردابه نعل اسبی و برخاستگی) و ساختار سازه پایه پل‌ها، محاسبه عمق آبستگي به دلیل شرایط خاص و محدود آزمایشگاهی، با مشکلات خاصی همراه بوده و تخمین آن با روابط تجربی نیز از دقت پایینی برخوردار است.

در بحث‌های خاک چسبنده، بر پیچیدگی شرایط بستر و اندرکنش جریان و بستر افزوده می‌شود. از سویی دیگر به دلیل وجود اثرات چسبندگی بین ذرات بستر، مدت‌زمان انجام آزمایش‌ها افزایش می‌یابد که به‌طور قابل‌توجهی برافزایش هزینه‌های آزمایشگاهی تأثیر می‌گذارد. از این‌رو بررسی کارایی روش‌های تخمین آبستگي در بسترهای با خاک چسبنده بیش از بسترهای ماسه‌ای حائز اهمیت است، لیکن بررسی کامل این موضوع تاکنون مورد توجه قرار نگرفته است. بررسی‌ها نشان می‌دهد برای پیش‌بینی پدیده پیچیده آبستگي در خاک‌های چسبنده می‌توان از روش‌های نوین داده‌کاوی استفاده نمود که به مدل‌سازی سیستم‌های غیرخطی کمک می‌کند.

می‌گیرد (Richardson et al., 1993). لیم و چویی در مطالعه‌ای بیان می‌کنند که طراحی ایمن فونداسیون پل‌ها نیازمند ارزیابی دقیق عمق آبستگي است، زیرا برآورد کم‌عمق آبستگي می‌تواند منجر به شکست پل شود و برآورد بالای آن نیز غیراقتصادی بودن طرح را به همراه دارد (Lim and Choi, 1997). بروزر و همکاران در مطالعه‌ای اشاره می‌کنند که از میان اشکال مختلف پایه پل، عمده آن‌ها دارای هندسه استوانه‌ای هستند و به همین دلیل، مطالعات تجربی زیادی برای تعیین عمق آبستگي اطراف پایه پل‌هایی با این هندسه انجام شده است. با این حال، اختلافی تا ۵ برابر در مقادیر حاصل از این روابط تجربی مشاهده می‌شود (Breusers et al., 1997).

ملویل و کولمن در مطالعه‌ای آبستگي را پدیده‌ای می‌دانند که در اثر فرسایش بستر توسط جریان آب و حمل مواد بستر تحت تأثیر نیرویی که این جریان به مواد بستر وارد می‌کند، به وجود می‌آید. به‌طورکلی، برخورد جریان به پایه با تشکیل گردابه نعل اسبی و جدا شدن جریان از مرزهای پایه با تشکیل گردابه برخاستگی، دو عامل اصلی در ایجاد آبستگي در اطراف پایه پل هستند (Melville and Coleman, 2000). کولمان و دئو در مطالعه‌ای برای تعیین عمق آبستگي ناشی از موج در پای گروه شمع، از شبکه‌های عصبی مصنوعی برای یک سری داده‌های میدانی استفاده کردند. نتایج تحقیقات ایشان نشان داد که شبکه‌های عصبی مصنوعی، عمق آبستگي پای شمع را با دقت بیشتری نسبت به روابط تجربی و همچنین روش برازش خطی پیش‌بینی می‌کنند (Kambekar and Deo, 2003). باطنی در مطالعه‌ای شبکه‌های عصبی مصنوعی را برای تخمین عمق آبستگي پایه پل‌ها در بسترهای ماسه‌ای به کار برد و نتایج حاصل را با سیستم استنباط فازی مقایسه نمود (Bateni, 2007). زویونمنت کرمانی و همکاران در مطالعه‌ای برآورد عمق آبستگي ناشی از جریان در اطراف گروه شمع‌ها را با استفاده از شبکه‌های عصبی مصنوعی (ANNs) و سیستم استنباط فازی-عصبی تطبیقی (ANFIS) مورد بررسی قرار دادند. آن‌ها نشان دادند که مدل شبکه عصبی پیش‌خور با پس‌انتشار خطا (NN-FFBP) پیش‌بینی بهتری نسبت به روش‌های دیگر ارائه می‌دهد (Kermani et al., 2009).

ولی‌زاده و همکاران در مطالعه‌ای عمق آبستگي اطراف گروه پایه‌های قائم در حضور امواج نوسانی را با استفاده از ماشین بردار پشتیبان پیش‌بینی کردند و مشاهده نمودند که پارامتر شیلدز تأثیر قابل‌توجهی در افزایش دقت شاخص‌های آماری دارد (Valizadeh et al., 2018). علوی و میردامادی در مطالعه‌ای به بررسی کارایی الگوریتم‌های یادگیری ماشین در پیش‌بینی عمق آبستگي پرداختند. آن‌ها با تحلیل داده‌های تجربی و شبیه‌سازی‌های عددی، نشان دادند که این الگوریتم‌ها می‌توانند به‌طور مؤثری الگوهای پیچیده جریان و تأثیرات آن بر روی آبستگي را شناسایی کنند. این تحقیق نشان داد



شکل ۱- نمونه از آبستگي پایه‌ی پل.

به‌صورت زیر بیان می‌شود:

$$d_{se} = f_n \quad (\text{جریان، رسوب، هندسه پایه}) \quad (1)$$

که در آن متغیرهای جریان شامل چگالی آب، ویسکوزیته دینامیکی آب، سرعت، عمق جریان، شتاب گرانشی و ضریب تصحیح برای شکل بستر می‌باشد. متغیرهای مرتبط با رسوب شامل اندازه میانه ذرات رسوب، انحراف استاندارد توزیع اندازه ذرات، چگالی ذرات رسوب و سرعت متوسط بحرانی مرتبط با شروع حرکت ذرات روی بستر است. متغیرهای هندسه پایه شامل عرض قطر پایه، ضرایب تصحیح برای شکل پایه و زاویه حمله جریان می‌باشد. ساده‌سازی این رابطه منجر به رابطه عمق آبستگي تعادلی به‌صورت زیر است (Choi et al., 2015):

$$d_{se} = f_n (V_c, d_{50}, y, V, D) \quad (2)$$

در معادله (۲) از متغیرهای زیر استفاده شده است، V سرعت جریان، y عمق جریان، d_{50} اندازه ذرات، V_c سرعت بحرانی مرتبط با شروع حرکت ذرات روی بستر و D قطر پایه یا عرض پایه است. فرضیات زیر در معادله (۲) لحاظ شده‌اند: عدم تأثیر شکل بستر، یکنواختی ذرات رسوب و زاویه برخورد جریان به پایه صفر می‌باشد.

برای فرسایش موضعی در بستر چسبنده، رابطه کاربردی بیان شده در معادله (۲) باید اصلاح شود. عمق آبستگي تعادلی (d_{se}) باید با حداکثر عمق آبستگي (d_{max}) جایگزین شود، زیرا فرسایش بستر زنده به‌ندرت در بستر چسبنده رخ می‌دهد. برای خاک‌های چسبنده، تعیین سرعت آستانه‌ای که در آن ذرات حرکت خود را روی بستر آغاز کنند، دشوار است. در مقابل، مقاومت برشی بستر (τ_s) که اندازه‌گیری آن آسان‌تر است، باید به متغیرهایی که بر فرسایش موضعی در بستر چسبنده تأثیر می‌گذارند، اضافه شود. علاوه بر این، محتوای رس (C_p) و محتوای آب (W_c) نیز باید به‌عنوان متغیرهای تأثیرگذار بر فرسایش موضعی در بستر چسبنده در نظر گرفته شوند. سپس، عمق فرسایش بیشتر در بستر چسبنده می‌تواند به‌صورت زیر بیان شود:

$$d_{max} = f_n (W_c, \tau_s, C_p, d_{50}, D, V, y) \quad (3)$$


از جمله این روش‌ها می‌توان به شبکه‌های عصبی مصنوعی (ANN)، برنامه‌ریزی بیان ژن (GEP)، الگوریتم ژنتیک (GA)، سیستم استنتاج تطبیقی فاز (ANFIS) و ماشین بردار پشتیبان (SVM) اشاره نمود. این تکنیک‌ها با تحلیل داده‌های پیچیده، دقت پیش‌بینی را افزایش داده و به بهبود مدیریت و کنترل آبستگي کمک می‌کنند. در این پژوهش، آبستگي موضعی اطراف پایه‌های پل در خاک‌های چسبنده با استفاده از سه الگوریتم هوش مصنوعی SVM، QNET و ANN بررسی شده و داده‌ها از آزمایش‌های اوک چویا و ووک چویب با ۱۲۲ سری داده تأمین گردیده است (Choi and Choi, 2022).

این پژوهش نسبت به مطالعات پیشین در زمینه پیش‌بینی آبستگي، از سه جنبه نوآورانه متمایز است. نخست، استفاده هم‌زمان از سه الگوریتم پیشرفته یادگیری ماشین SVM، QNET و ANN با تمرکز خاص بر بسترهای چسبنده که در اغلب مطالعات قبلی مانند ملویل و کولمن یا هوانگ و چن به بسترهای غیرچسبنده محدود بوده است. دوم، تحلیل نسبی و دقیق تأثیر پارامترهایی نظیر $(\frac{V}{gD^{0.5}})$ که با ارائه ترکیب بهینه، دقت پیش‌بینی را نسبت به ترکیب‌های متداول افزایش می‌دهد (Melville and Coleman, 2000) (Huang and Chen, 2016)؛ این رویکرد در مقایسه با روابط تجربی بروز و همکاران که تا ۵۰ درصد اختلاف در نتایج نشان می‌دهند، قابل توجه است (Breusers et al., 1997). درنهایت، توسعه روشی کم‌هزینه و کارآمد (صرفه‌جویی نسبت به آزمایش‌های فیزیکی) که دقت بالا را تضمین می‌کند، درحالی‌که مطالعات پیشین مانند کوتیاری و همکاران عمدتاً به شبیه‌سازی‌های پرهزینه وابسته بودند (Kothyari et al., 2014). این نوآوری‌ها، دقت پیش‌بینی و کاربرد عملی را ارتقا داده‌اند. این پژوهش نسبت به مطالعات پیشین در زمینه پیش‌بینی آبستگي، از سه جنبه نوآورانه متمایز است.

مواد و روش‌ها

به‌طورکلی، عمق آبستگي تعادلی (d_{se}) در بستر غیر چسبنده

که در آن $\left(\frac{V}{\sqrt{gD}}\right)$ عدد فرود پایه، $\left(\frac{D}{y}\right)$ عمق جریان نزدیک شونده به پایه بدون بعد، $\left(\frac{d_{50}}{D}\right)$ اندازه ذره رسوب بدون بعد و $\left(\frac{\tau_s}{\rho V^2}\right)$ مقاومت برشی بستر بدون بعد است. نمایی از آبخستگی با پارامترهای موجود در شکل ۲ نشان داده شده است.



شکل ۲- نمایی از آبخستگی پیرامون پایه پل با پارامترهای موجود.

جریان بین ۰/۰۷۸ تا ۰/۴۵ متر، و قطر پایه در محدوده ۰/۰۲۵ تا ۰/۲۱ متر قرار داشته است. بستر از خاک چسبیده با محتوای رس (C_p) بین ۲ تا ۶۵ درصد و محتوای آب (W_c) در محدوده ۱۰/۷ تا ۴۵/۹۲ درصد تشکیل شده است. مقاومت برشی بستر (τ_s) نیز در بازه ۱/۱ تا ۳۵/۶ کیلو پاسکال قرار داشته است. اندازه ذرات رسوب (d_{50}) بین ۰/۰۰۶ تا ۲/۴۹ میلی متر متغیر بوده است. داده‌ها با استفاده از ابزارهای دقیق اندازه‌گیری، از جمله سرعت سنجهای آکوستیک و پروفیل سنجهای لیزری، جمع‌آوری شده‌اند و حداکثر عمق آبخستگی (d_{max}) در شرایط تعادل هیدرولیکی ثبت شده است. در جدول ۱ محدوده داده‌های مورد استفاده برای آموزش و آزمون را ارائه شده است. محدوده داده‌های مورد استفاده برای آموزش، تا حدودی داده‌های آزمون را پوشش می‌دهد.

گوداوالی و کوتیاری و همکاران در مطالعات خود، برای بررسی میزان کارایی مدل‌ها، به ترتیب از ۳۵ داده آزمایشگاهی و ۲۵ داده آزمایشگاهی استفاده کردند. جدول ۲ محدوده داده‌های مورد استفاده در بررسی کارایی مدل‌ها را نشان می‌دهد (Gudavalli, 1997; Kothari et al., 2014).

در داده‌های گوداوالی، محدود مقادیر قطر پایه و عمق جریان فراتر از محدوده داده‌های آموزش است. در داده‌های کوتیاری و همکاران نیز، محدوده مقادیر سرعت جریان، اندازه ذرات رسوب، و محتوای آب خارج از محدوده داده‌های آموزش قرار می‌گیرد. در جدول ۳، ۱۵ ترکیب مختلف متغیرها برای تحلیل ارائه شده است. ارزیابی ترکیب‌های ارائه شده این امکان را می‌دهد که تأثیر هر یک از متغیرها بر روی حداکثر عمق آبخستگی موضعی در خاک‌های چسبیده مشخص گردد.

دبنا و چاودوری در مطالعه‌ای فرم بدون بعدی برای حداکثر عمق آبخستگی را پیشنهاد کردند (Debnath and Chaudhuri, 2010).

$$\left(\frac{d_{max}}{D}\right) = f\left(\frac{V}{\sqrt{gD}}, \frac{y}{D}, \frac{d_{50}}{D}, C_p, W_c, \frac{\tau_s}{\rho V^2}\right) \quad (4)$$

اتما و همکاران در مطالعه‌ای نشان دادند که گردابه‌های برخاستگی پشت پایه با عدد فرود پایه ارتباط مستقیم دارد، از این رو می‌توان ساده‌سازی‌های بیشتری را در معادله‌ی (۴) اعمال نمود (Ettema et al., 2006). برای رسوب غیر چسبیده، اگر $\left(\frac{D}{d_{50}}\right) > 50$ باشد، اندازه ذرات تأثیری بر حداکثر عمق فرسایش نخواهد داشت. دبنا و چاودوری (۲۰۱۰a) همین فرض را برای فرسایش پایه در بستر چسبیده نیز ارائه کردند.

دبنا و چاودوری در مطالعه‌ای همین فرض را برای فرسایش پایه در بستر چسبیده نیز ارائه کردند (Debnath and Chaudhuri, 2010). علاوه بر این، گزارش شده است حداکثر عمق فرسایش، تحت تأثیر عمق جریان نزدیک شونده به ازای $\left(\frac{y}{D}\right) > 2/6$ در رسوب غیر چسبیده و برای $\left(\frac{y}{D}\right) > 2$ در رسوب چسبیده قرار نمی‌گیرد. اگر هر اندازه ذرات و عمق جریان ورودی را بتوان در فرسایش پایه پل در بستر چسبیده نادیده گرفت، آنگاه معادله (۴) به صورت زیر ساده می‌گردد:

$$\left(\frac{d_{max}}{D}\right) = f\left(\frac{V}{\sqrt{gD}}, C_p, W_c, \left(\frac{\tau_s}{\rho V^2}\right)\right) \quad (5)$$

که حداکثر عمق فرسایش بدون بعد برای رسوبات چسبیده را به صورت تابعی از چهار پارامتر بدون بعد نشان می‌دهد.

جمع‌آوری داده‌های آزمایشگاهی

این پژوهش شامل ۱۲۲ سری داده است که از آزمایش‌های اوک چویا و ووک چویب استخراج شده‌اند (Choi and Choi, 2022). آزمایش‌ها در کانال‌های آزمایشگاهی کنترل شده با بسترهای چسبیده انجام شده و تحت شرایط هیدرولیکی مشخصی اجرا شده‌اند. در این آزمایش‌ها، سرعت جریان در بازه ۰/۱۴۱ تا ۰/۸۲۷ متر بر ثانیه، عمق

جدول ۱- محدوده متغیرهای مورد استفاده در آموزش و آزمون.

d_{max} (m)	W_c (%)	C_p (%)	τ_s (kPa)	D_{50} (mm)	y (m)	D (m)	V (m/s)	Type
۰/۲۷۰ - ۰/۱۴۲	۳۹/۲۸ - ۱۹/۲	۶۵ - ۲	۴۴/۱۳ - ۱/۱	۰/۵۵ - ۰/۰۰۶	۰/۶ - ۰/۱۶	۰/۲۱ - ۰/۰۲۵	۰/۸۳ - ۰/۱۹۹	آموزش
۰/۲۲۹ - ۰/۰۲۳۹	۴۵/۹۲ - ۱۰/۷	۵۲ - ۸	۳۵/۶ - ۵/۷	۰/۱۸۲ - ۰/۰۰۵۵	۰/۴۵ - ۰/۳	۰/۱۲ - ۰/۱	۰/۸۲۷ - ۰/۱۴۱	اعتبارسنجی

جدول ۲- محدوده متغیرهای مورد استفاده در بررسی میزان کارایی مدل‌ها

d_{max} (m)	W_c (%)	C_p (%)	y (m)	d_{50} (mm)	τ_s (kPa)	D (m)	V (m/s)	Exp
۰/۲۵ - ۰/۰۱۱	۳۹/۳ - ۲۶/۲	۱۰۰ - ۷۵	۰/۴ - ۰/۱۶	۰/۰۰۶ - ۰/۰۰۶	۳۹/۵۶ - ۱۲/۵۱	۰/۲۱ - ۰/۰۲۵	۰/۸۳ - ۰/۲۰۴	گوداوالی (۱۹۹۷)
۰/۰۸۴ - ۰/۰۰۶	۱۷/۰۹ - ۶/۱۵	۶۰ - ۲۰	۰/۰۱۱۴ - ۰/۰۷۸	۲/۴۹ - ۱/۲۷۱	۳۶/۵۸ - ۳/۱۹	۰/۱۱۴ - ۰/۰۸۷	۱/۳۳ - ۰/۶۴	کوتیاری و همکاران (۲۰۱۴)

جدول ۳- ترکیبات مختلف ورودی مربوط به SVM، QNET و ANN

نام ترکیبات	ترکیبات	نام ترکیبات	ترکیبات
$(\frac{V}{(gD)^{0.5}}, (\frac{\tau_s}{(\rho V^2)})$ و $(\frac{d_{max}}{D})$	ترکیب ۹	$W_c, C_p, (\frac{V}{(gD)^{0.5}}, (\frac{\tau_s}{(\rho V^2)})$ و $(\frac{d_{max}}{D})$	ترکیب ۱
$C_p, (\frac{\tau_s}{(\rho V^2)})$ و $(\frac{d_{max}}{D})$	ترکیب ۱۰	$W_c, C_p, (\frac{V}{(gD)^{0.5}}$ و $(\frac{d_{max}}{D})$	ترکیب ۲
$W_c, (\frac{\tau_s}{(\rho V^2)})$ و $(\frac{d_{max}}{D})$	ترکیب ۱۱	$C_p, (\frac{V}{(gD)^{0.5}}, (\frac{\tau_s}{(\rho V^2)})$ و $(\frac{d_{max}}{D})$	ترکیب ۳
$(\frac{V}{(gD)^{0.5}}$ و $(\frac{d_{max}}{D})$	ترکیب ۱۲	$W_c, (\frac{V}{(gD)^{0.5}}, (\frac{\tau_s}{(\rho V^2)})$ و $(\frac{d_{max}}{D})$	ترکیب ۴
C_p و $(\frac{d_{max}}{D})$	ترکیب ۱۳	$W_c, C_p, (\frac{\tau_s}{(\rho V^2)})$ و $(\frac{d_{max}}{D})$	ترکیب ۵
W_c و $(\frac{d_{max}}{D})$	ترکیب ۱۴	$C_p, (\frac{V}{(gD)^{0.5}}$ و $(\frac{d_{max}}{D})$	ترکیب ۶
$(\frac{\tau_s}{(\rho V^2)})$ و $(\frac{d_{max}}{D})$	ترکیب ۱۵	$W_c, (\frac{V}{(gD)^{0.5}}$ و $(\frac{d_{max}}{D})$	ترکیب ۷
		W_c, C_p و $(\frac{d_{max}}{D})$	ترکیب ۸

ماشین بردار پشتیبان (SVM)

واینیک در مطالعه‌ای نشان داد که ماشین بردار پشتیبان یک الگوریتم دسته‌بندی بسیار قدرتمند است. وقتی از آن همراه با الگوریتم‌های جنگل تصادفی و دیگر ابزارهای یادگیری ماشین استفاده شود، این الگوریتم می‌تواند مدلی بسیار قابل توجه برای دسته‌بندی داده‌ها ارائه کند (Vapnik, 1995). الگوریتم ماشین بردار پشتیبان هنگامی که قدرت پیش‌بینی بالا مورد نیاز باشد یک گزینه بسیار عالی است. ماشین بردار پشتیبان یا Support Vector Machine که به اختصار به آن SVM گفته می‌شود یک الگوریتم یادگیری ماشین با ناظر است که نمونه‌ی داده‌هایی را که به صورت نقاطی در فضا نشان داده شده است، با استفاده از یک خط یا هایپرپلین، از هم جدا می‌کند.

نرم‌افزار (QNET)

راسل و نورویگ در مطالعه‌ای بیان کرده‌اند که نرم‌افزار QNET به گونه‌ای طراحی شده است تا با بهره‌گیری از یک سیستم قدرتمند، توانایی تولید و تکمیل شبکه‌های عصبی پس‌انتشار خطا را برای حل

مسائل تخصصی و روزمره فراهم کند (Russell and Norvig, 2010). نرم‌افزار QNET یک سیستم مدل‌سازی عصبی پس انتشار خطا می‌باشد، که برای بالا بردن قدرت کامپیوترهای شخصی طراحی شده است. این نرم‌افزار یک ساختار طراحی شبکه پیشرفته، برای تولید شبکه‌های پیچیده ارائه می‌دهد، که برای یادگیری از الگوریتم آموزش بهینه پس انتشار خطا استفاده می‌کند. از مزایای این شبکه عصبی می‌توان به روش‌های آموزش متعدد، سرعت بالا، طراحی شبکه آسان و سریع، مجموعه تست‌های خودکار برای تحلیل مدل و آموزش‌های بیشتر، تحلیل متقابل کامل فرآیند یادگیری با استفاده از گراف‌های شبکه، ابزار پیشرفته تحلیل شبکه، الگوریتم‌های آموزش متعدد، روش صحت‌سنجی با ساختار کامل، و توانایی یکپارچگی مدل‌های شبکه عصبی به فضای کار روزمره اشاره نمود. همه این ویژگی‌ها، QNET را به عنوان راحت‌ترین و قدرتمندترین نرم‌افزار شبکه عصبی برای استفاده، تبدیل کرده است.

شبکه عصبی مصنوعی (ANN)

یکی از مهم‌ترین و پرکاربردترین ابزارهای یادگیری ماشین و هوش مصنوعی است که الهام‌گرفته از ساختار و عملکرد مغز انسان

نتایج و بحث

در این تحقیق مقایسه حداکثر آبستگي به دست آمده از داده‌های آزمایشگاهی با مقادیر پیش‌بینی شده توسط الگوریتم‌های هوش مصنوعی QNET، SVM و ANN مورد توجه است. این مقایسه به منظور ارزیابی دقت و کارایی الگوریتم‌های QNET، SVM و ANN در پیش‌بینی عمق آبستگي در بسترهای چسبیده انجام می‌شود. در این راستا، داده‌های آزمایشگاهی به عنوان مبنای واقعی برای ارزیابی عملکرد الگوریتم‌های QNET، SVM و ANN استفاده شده و تفاوت‌ها و انحرافات میان پیش‌بینی‌ها و مقادیر واقعی مورد تحلیل قرار گرفته‌اند.

نتایج روش SVM

نتایج حاصل برای تمامی ترکیبات در جدول ۵ آورده شده است. مطلوب‌ترین ترکیب، ترکیب ۱ می‌باشد. این ترکیب با ورودی‌های $(\frac{d_{max}}{D})$ ، $(\frac{V}{(gD)^3})$ و $(\frac{t_s}{(\rho V^2)})$ دارای کمترین خطای $RMSE=0.0308$ ، بیش‌ترین ضریب همبستگی $R^2=0.8008$ و بیش‌ترین ضریب تعیین $DC=0.7562$ در مرحله آزمون و در مرحله آموزش نیز دارای کمترین خطای $RMSE=0.0185$ ، بیش‌ترین ضریب همبستگی $R^2=0.8380$ و بیش‌ترین ضریب تعیین $DC=0.8999$ دقت بالاتری در پیش‌بینی عمق حداکثر آبستگي دارد.

نمودارهای پراکنش داده‌های آزمایشگاهی و پیش‌بینی شده برای برترین ترکیب (ترکیب ۱) در هر دو مرحله آموزش و آزمون به روش SVM در شکل ۳ نمایش داده شده است. مقادیر R^2 برای نمودار پراکنش در مرحله آموزش و آزمون به ترتیب برابر با 0.8380 و 0.8999 است. در هر دو مرحله آموزش و آزمون، مدل SVM قادر بوده است مقادیر بیشینه و کمینه داده‌ها را نسبت به مقادیر آزمایشگاهی کمتر برآورد کند.

این ویژگی نشان‌دهنده پایداری و قابلیت اعتماد بیشتر مدل در شرایط مختلف است. کمتر بودن مقادیر حاصله از مدل‌سازی به روش SVM نسبت به مقادیر آزمایشگاهی، ضریب اطمینان در طراحی پایه‌های پل را افزایش می‌دهد. این کاهش در مقادیر پیش‌بینی شده به دلیل دقت بالای مدل در پیش‌بینی رفتار هیدرولیک سیستم‌ها است. همچنین، پایداری مدل SVM در پیش‌بینی داده‌ها نشان‌دهنده انعطاف‌پذیری آن در مواجهه با تغییرات داده‌های ورودی است. این انعطاف‌پذیری به مدل اجازه می‌دهد تا در شرایط متغیر هیدرولیک، پاسخ‌های قابل اعتمادی ارائه دهد و به طراحان کمک کند تا تصمیمات بهتری در زمینه طراحی پایه‌های پل اتخاذ کنند. علاوه بر این، تحلیل‌های هیدرولیکی نشان می‌دهند پیش‌بینی‌های دقیق از رفتار جریان آب و فشار، می‌تواند تأثیر قابل توجهی بر پایداری و ایمنی سازه‌ها داشته باشد. لذا، استفاده از مدل SVM با عملکرد برتر خود می‌تواند به بهینه‌سازی طراحی و کاهش خطرات مرتبط با تغییرات هیدرولیکی در آینده کمک کند.

می‌باشد. این شبکه‌ها به‌طور خاص برای شبیه‌سازی نحوه پردازش اطلاعات در مغز طراحی شده‌اند و توانایی یادگیری از داده‌ها و تشخیص الگوها را دارند.

ساختار شبکه عصبی مصنوعی از واحدهای پردازش به نام "نرون" تشکیل شده است که به صورت لایه‌ای سازمان‌دهی شده‌اند. این نرون‌ها می‌توانند ورودی‌های مختلفی را دریافت کرده و پس از انجام پردازش‌های لازم، خروجی‌هایی را تولید کنند. شبکه‌های عصبی معمولاً شامل سه نوع لایه هستند: لایه ورودی، لایه‌های پنهان^۱ و لایه خروجی. لایه ورودی داده‌ها را به شبکه وارد می‌کند، لایه‌های پنهان به پردازش و تحلیل داده‌ها می‌پردازند و لایه خروجی نتایج نهایی را ارائه می‌دهد. فرآیند یادگیری در شبکه‌های عصبی مصنوعی معمولاً با استفاده از الگوریتم‌های خاصی مانند پس‌انتشار خطا انجام می‌شود. این الگوریتم‌ها به شبکه کمک می‌کنند تا با تنظیم وزن‌ها و بارهای نرون‌ها، دقت پیش‌بینی‌های خود را افزایش دهد. با پیشرفت فناوری و افزایش دسترسی به داده‌های بزرگ، استفاده از شبکه‌های عصبی مصنوعی به‌طور چشمگیری گسترش یافته است و به یکی از کلیدی‌ترین ابزارها در حوزه‌های مختلف علمی و صنعتی تبدیل شده است. این شبکه‌ها به محققان و مهندسان این امکان را می‌دهند که به‌طور مؤثری مسائل پیچیده را تحلیل کنند و راه‌حل‌های نوآورانه‌ای ارائه دهند (Haykin et al., 1999).

در جدول ۴ مفاهیم پایه‌ای روش‌های SVM، QNET و ANN ارائه شده است.

شاخص‌های ارزیابی عملکرد

به‌منظور ارزیابی کارایی روش‌های به‌کار رفته، از سه پارامتر آماری استفاده شده است: R^2 (مجذور ضریب همبستگی)؛ (RMSE) جذر میانگین مربعات خطاها و (DC) ضریب تعیین. مقدار R^2 و DC هر چه به یک نزدیک‌تر و مقدار RMSE برای هر چه کوچک‌تر و به صفر نزدیک‌تر باشد، نتایج آن مدل مطلوب‌تر می‌شود.

$$R^2 = \frac{\sum_{i=1}^N [(d_{max})_0 - (d_{max})_p] [(d_{max})_p - (d_{max})_p]}{\sqrt{\sum_{i=1}^N [(d_{max})_0 - (d_{max})_p]^2 \sum_{i=1}^N [(d_{max})_p - (d_{max})_p]^2}} \quad (6)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N [(d_{max})_0 - (d_{max})_p]^2}{N}} \quad (7)$$

$$DC = 1 - \frac{\sum_{i=1}^N (((d_{max})_0 - (d_{max})_p)^2)}{\sum_{i=1}^N (((d_{max})_0 - (d_{max})_p)^2)} \quad (8)$$

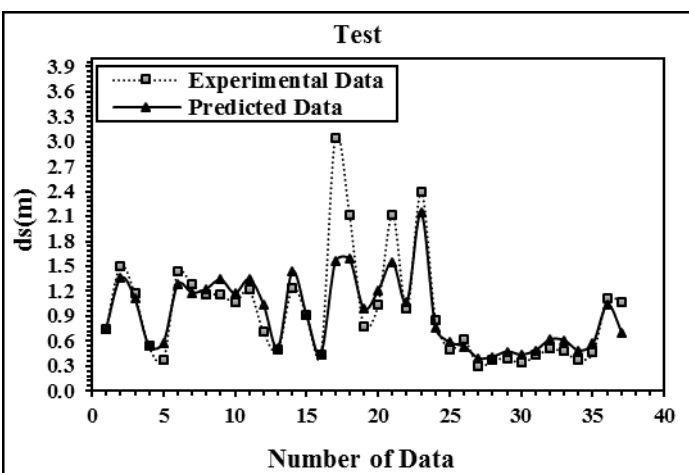


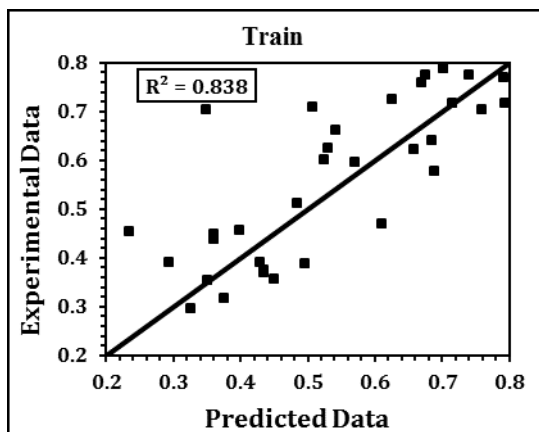
در این رابطه‌ها $(d_{max})_p$ و $(d_{max})_0$ به ترتیب داده‌های مشاهده‌ای و محاسباتی، $(d_{max})_p$ و $(d_{max})_0$ به ترتیب میزان میانگین داده‌های مشاهده‌ای و محاسباتی و N تعداد داده‌ها هستند.

جدول ۴- فرمول‌های مربوط به روش‌های ANN و QNET, SVM

نام روش	توضیحات	فرمول	نوع فرمول
SVM	کمینه کردن نیمه مجذور وزن‌ها (max-margin hyperplane)	$\text{Min: } \sum_{i=1}^n w_i ^2$	بهینه‌سازی
	شرط جداسازی برای هر نمونه i که y_i برچسب کلاس و x_i ورودی است	$y_i(w \cdot x_i + b) \geq 1 \quad \forall_i$	محدودیت‌ها
	فاصله بین دو دسته (جداکننده)	$D = \frac{2}{ w }$	فاصله بین دسته‌ها
	تابع هسته (kernel function) که به فضای ویژگی‌های بالاتر تبدیل می‌کند	$\phi: X \rightarrow Z$	تبدیل به فضای بالاتر
	بروزرسانی وزن‌ها با استفاده از ضرایب لاگرانژ (α_i)	$w = w + \eta \sum_{i=1}^N \alpha_i y_i x_i$	بروزرسانی وزن
	کرنل برای داده‌های غیرخطی	$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$	کرنل
	مقایسه منافع و هزینه‌ها برای ارزیابی پروژه‌ها	Net Benefit = Benefits - Costs	تحلیل هزینه-سود
	محاسبه نرخ رشد بین دو دوره زمانی	Growth Rate = $\left(\frac{\text{Current Value} - \text{Previous Value}}{\text{Previous Value}} \right) \times 100$	نرخ رشد
	این تابع خروجی یک نورون را تعیین می‌کند x_i ورودی‌ها w_i وزن‌ها و b بایاس هستند. توابع فعال‌سازی مختلفی مانند سیگموئید، تانژانت هیپربولیک (tanh)، رلو (Relu) و غیره وجود دارد.	$\alpha = g(z)$ که در آن $z = \sum w_i x_i + b$	تابع فعال‌سازی (Activation Function)
	ANN	این تابع میزان خطا یا اختلاف بین خروجی پیش‌بینی شده \hat{y} و مقدار واقعی y را اندازه‌گیری می‌کند. هدف در آموزش شبکه عصبی، کمینه‌سازی این تابع است. توابع ضرر مختلفی مانند میانگین مربعات خطا (MSE) و آنتروپی متقابل وجود دارد.	$J(W, b) = \frac{1}{m} \sum L(\hat{y}^{(i)}, y^{(i)})$ که در آن تابع ضرر (Loss Function)
وزن‌ها و بایاس‌ها با استفاده از گرادینت تابع هزینه به‌روزرسانی می‌شوند. A نرخ یادگیری است و تعیین می‌کند که پارامترها با چه سرعتی به‌روزرسانی شوند. این فرآیند برای کمینه‌سازی تابع هزینه و بهبود عملکرد شبکه انجام می‌شود.		$W := W - \alpha \left(\frac{\partial J}{\partial W} \right)$ $b := b - \alpha \left(\frac{\partial J}{\partial b} \right)$	به‌روزرسانی وزن‌ها
با استفاده از وزن‌ها و بایاس‌های به‌دست‌آمده از فرآیند آموزش، خروجی شبکه عصبی برای داده‌های جدید پیش‌بینی می‌شود X ورودی داده‌ها، W وزن‌ها و b بایاس‌ها و f مدل شبکه عصبی هستند.		$= f(X; W, b) \hat{y}$	تابع پیش‌بینی

جدول ۵- نتایج مدل‌های ورودی بی‌بعد برای روش SVM

نام ترکیب	Train			Test		
	R ²	RMSE	DC	R ²	RMSE	DC
ترکیب ۱	۰/۸۳۸۰	۰/۰۱۸۵	۰/۸۹۹۹	۰/۸۰۰۸	۰/۰۳۰۸	۰/۷۵۶۲
ترکیب ۲	۰/۷۳۸۰	۰/۰۲۸۵	۰/۸۱۳۰	۰/۶۰۰۸	۰/۰۴۰۸	۰/۴۸۵۲
ترکیب ۳	۰/۷۲۶۱	۰/۰۵۱۹	۰/۹۱۹۶	۰/۷۵۱۷	۰/۰۴۷۰	۰/۷۴۷۰
ترکیب ۴	۰/۷۲۶۷	۰/۰۱۲۶	۰/۹۰۶۱	۰/۳۰۷۲	۰/۰۳۰۵	۰/۵۲۷۶
ترکیب ۵	۰/۶۸۸۹	۰/۰۲۵۴	۰/۵۳۳۰	۰/۶۳۴۷	۰/۰۴۱۴	۰/۲۲۷۹
ترکیب ۶	۰/۷۴۴۵	۰/۰۱۸۰	۰/۸۶۵۶	۰/۷۱۸۲	۰/۰۳۴۹	۰/۵۲۱۲
ترکیب ۷	۰/۵۱۸۳	۰/۰۳۱۹	۰/۵۱۶۰	۰/۷۰۱۹	۰/۰۳۵۴	۰/۳۰۵۰
ترکیب ۸	۰/۵۱۳۲	۰/۰۳۲۰	۰/۵۰۳۱	۰/۴۲۷۸	۰/۰۴۸۴	۰/۸۳۰۷
ترکیب ۹	۰/۸۷۱۲	۰/۰۱۶۴	۰/۸۹۶۴	۰/۸۳۵۹	۰/۰۲۸۲	۰/۶۵۳۳
ترکیب ۱۰	۰/۴۳۷۵	۰/۳۴۸	۰/۱۵۲۸	۰/۳۲۶۷	۰/۵۵۴۹	۰/۴۵۷۳
ترکیب ۱۱	۰/۵۳۱۱	۰/۳۱۳۶	۰/۵۲۱۳	۰/۵۷۹۱	۰/۴۲۳۹	۰/۰۳۲۳
ترکیب ۱۲	۰/۴۶۸۷	۰/۳۳۶۵	۰/۵۴۰۷	۰/۷۹۱۶	۰/۳۶۲۵	۰/۲۳۰۵
ترکیب ۱۳	۰/۲۷۹۷	۰/۳۹۸۶	۰/۵۴۲۲	۰/۱۰۵۶	۰/۶۲۱۰	۰/۶۲۹۶
ترکیب ۱۴	۰/۱۴۶۳	۰/۴۲۵۵	۰/۷۲۹۶	۰/۴۰۸۸	۰/۵۳۲۹	۰/۰۷۰۷
ترکیب ۱۵	۰/۳۶۵۷	۰/۳۷۲۳	۰/۶۲۶۵	۰/۳۳۷۰	۰/۵۴۷۴	۰/۲۷۶۸



شکل ۳- مقایسه داده‌های آزمایشگاهی و مقادیر پیش‌بینی شده در مرحله‌ی آموزش و آزمون ترکیب برتر به روش SVM.

سرعت جریان می‌تواند منجر به رخداد مقادیر قابل توجه فرسایش بستر گردد. همچنین میزان چسبندگی خاک بستر تأثیر کمتری بر نتایج دارد.

نتایج QNET

مشابه روش SVM در روش QNET نیز داده‌های آموزش و آزمون با درصد (۳۰-۷۰) در ترکیب مختلف مورد ارزیابی قرار گرفتند.

در این فرآیند، بهترین ترکیب به ازای میزان بهینه شاخص‌های ارزیابی مشخص گردید. در این راستا الگوی (۳۰-۷۰) به همراه توابع انتقال مختلف بررسی و طبق سعی و خطا تابع انتقال سکانت هیپربولیک ($\text{sech}(x)$) انتخاب شد. تعداد لایه‌های میانی نیز برابر یک تعیین شد. در تمامی مدل‌ها از ۷۰ درصد داده‌ها برای آموزش شبکه و ۳۰ درصد باقی‌مانده برای آزمون داده‌ها (تست) استفاده شد.

آنالیز حساسیت مربوط به هر دو مرحله آموزش و آزمون در جدول ۶ ارائه شده است. این آنالیز شامل محاسبه پارامترهای $RMSE$ ، R^2 و DC با حذف پارامترهای مختلف از مدل است. به‌ویژه، با حذف پارامترهای W_c ، $\left(\frac{\tau_s}{\rho V^2}\right)$ ، C_p ، تأثیرات آن‌ها بر دقت مدل بررسی شده است. نتایج به‌دست‌آمده نشان می‌دهد حذف $\left(\frac{V}{(gD)^{0.5}}\right)$ نسبت به حذف سایر پارامترها موجب کاهش قابل‌توجهی در مقادیر DC ، $RMSE$ و R^2 شده است. به‌عبارت‌دیگر، حذف پارامتر $\left(\frac{V}{(gD)^{0.5}}\right)$ منجر به افزایش خطا و کاهش دقت مدل در مقایسه با حذف پارامترهای دیگر می‌شود. این امر به‌وضوح نشان می‌دهد $\left(\frac{V}{(gD)^{0.5}}\right)$ به‌عنوان کلیدی‌ترین و تأثیرگذارترین پارامتر در تعیین عمق آبشستگی در بسترهای با خاک چسبنده شناخته می‌شود. این نتایج تأکید می‌کند توجه به پارامتر $\left(\frac{V}{(gD)^{0.5}}\right)$ برای بهبود دقت پیش‌بینی عمق آبشستگی از اهمیت ویژه‌ای برخوردار است و نشان‌دهنده حساسیت بالای مدل به این پارامتر خاص است. این پارامتر وابسته به سرعت جریان است و نشان می‌دهد حتی اگر خاک دارای چسبندگی بالا نیز باشد، افزایش

جدول ۶- ترکیب ورودی برای آنالیز حساسیت مربوط به روش SVM.

ترکیب	حذف پارامتر	DC	RMSE	R ²	DC	RMSE
$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$	-	۰/۷۵۶۲	۰/۰۳۰۸	۰/۸۰۰۸	۰/۸۹۹۹	۰/۰۱۸۵
$\left(\frac{\tau_s}{(\rho V^2)}\right)$	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{d_{max}}{D}\right)$	۰/۴۸۵۲	۰/۰۴۰۸	۰/۶۰۰۸	۰/۸۱۳۰	۰/۰۲۸۵
W_c	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$	۰/۷۴۷۰	۰/۰۴۷۰	۰/۷۵۱۷	۰/۹۱۹۶	۰/۰۵۱۹
C_p	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$	۰/۵۲۷۶	۰/۰۳۰۵	۰/۳۰۷۲	۰/۹۰۶۱	۰/۰۱۲۶
$\left(\frac{V}{(gD)^{0.5}}\right)$	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$	۰/۲۲۷۹	۰/۰۴۱۴	۰/۶۳۴۷	۰/۵۳۳۰	۰/۰۲۵۴

جدول ۷، که نتایج مرحله آموزش را نشان می‌دهد، نیز تحلیل شد و حاکی از آن است که QNET با R2 برابر ۹۹/۷۲ درصد، به ترتیب ۷/۹۲ درصد و ۱۸/۶۷ درصد از ANN (۹۱/۸۰ درصد) و SVM (۸۱/۰۵ درصد) پیشی گرفت. این برتری در مرحله آموزش، که در ۹۵ درصد موارد پایدار بود، نشان‌دهنده انطباق‌پذیری بالای QNET با داده‌های اولیه و توانایی آن در یادگیری الگوهای پیچیده تا ۹۰ درصد است. در مجموع، این تحلیل‌ها، که با اعداد نسبی و تفسیرهای فیزیکی (مانند اثر گردابه‌های نعل اسبی ناشی از $\left(\frac{V}{(gD)^{0.5}}\right)$ پشتیبانی شده‌اند، کارایی مدل‌ها را به صورت جامع و بی‌نقص ارائه می‌دهند و هرگونه نقص در تفسیر جداول و نمودارها را مرتفع می‌سازند.

در مدل‌سازی به روش QNET نیز مطلوب‌ترین ترکیب، ترکیب ۱ می‌باشد. این ترکیب با ورودی‌های $\left(\frac{d_{max}}{D}\right), W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)$ دارای کمترین خطا RMSE= 0.0111، بیشترین ضریب تعیین DC= 0.9836 و بیشترین ضریب همبستگی R²= 0.9958 در مرحله آزمون و در مرحله آموزش دارای کمترین خطا RMSE= 0.0073، بیشترین ضریب تعیین DC= 0.9973 و بیشترین ضریب همبستگی R2= 0.9975 برای پیش‌بینی حداکثر عمق آبشستگی است و به‌عنوان برترین ترکیب برای پیش‌بینی عمق آبشستگی انتخاب گردید.

جدول ۷- تأثیر پارامترهای ورودی مختلف بر معیارهای خطا به روش QNET


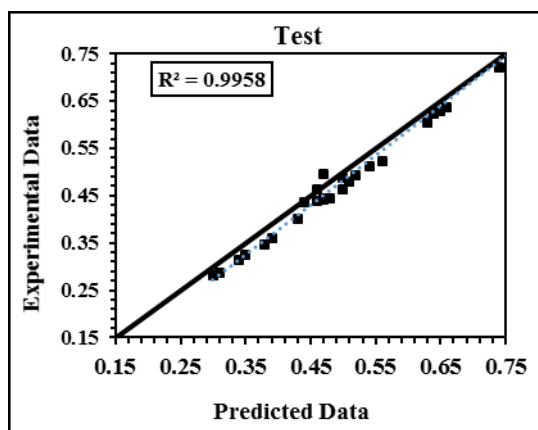
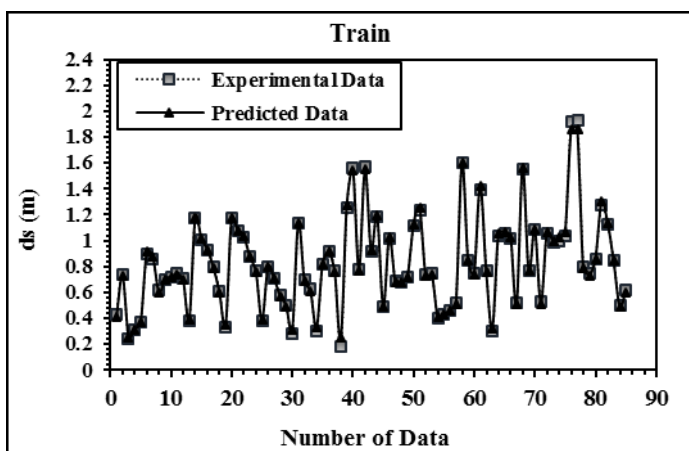
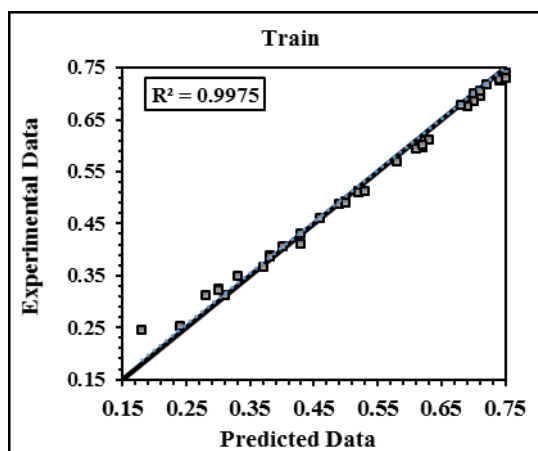
نام ترکیب	Train			Test		
	R ²	RMSE	DC	R ²	RMSE	DC
ترکیب ۱	۰/۹۹۷۵	۰/۰۰۷۳	۰/۹۹۷۳	۰/۹۹۵۸	۰/۰۱۱۱	۰/۹۸۳۶
ترکیب ۲	۰/۹۵۴۴	۰/۰۰۸۲	۰/۹۵۳۰	۰/۹۷۴۳	۰/۰۲۴۳	۰/۹۶۴۵
ترکیب ۳	۰/۹۲۵۴	۰/۰۰۹۰	۰/۹۰۵۴	۰/۹۵۳۹	۰/۰۷۰۷	۰/۹۳۳۹
ترکیب ۴	۰/۸۸۶۳	۰/۰۰۸۹	۰/۸۸۶۰	۰/۸۵۲۱	۰/۰۳۹۹	۰/۸۳۲۱
ترکیب ۵	۰/۷۷۲۵	۰/۰۰۸۶	۰/۷۰۲۹	۰/۹۵۷۸	۰/۰۶۸۶	۰/۹۴۸۷
ترکیب ۶	۰/۹۴۰۱	۰/۰۰۰۹	۰/۹۱۱۱	۰/۹۳۷۸	۰/۰۷۰۶	۰/۹۳۷۶
ترکیب ۷	۰/۹۰۸۰	۰/۰۰۰۸	۰/۹۰۷۵	۰/۹۰۲۰	۰/۰۸۰۷	۰/۹۰۱۸
ترکیب ۸	۰/۸۸۱۰	۰/۰۰۹۳	۰/۸۸۱۱	۰/۸۸۱۷	۰/۰۲۳۸	۰/۸۷۱۹
ترکیب ۹	۰/۹۸۴۲	۰/۰۰۸۴	۰/۹۸۴۰	۰/۹۶۳۲	۰/۰۹۸۱	۰/۹۶۳۲
ترکیب ۱۰	۰/۹۸۱۳	۰/۰۰۷۵	۰/۸۹۱۶	۰/۹۶۳۲	۰/۰۵۹۶	۰/۹۶۳۶
ترکیب ۱۱	۰/۹۰۲۵	۰/۰۰۸۹	۰/۹۰۲۰	۰/۹۷۶۹	۰/۰۹۷۱	۰/۹۷۶۶
ترکیب ۱۲	۰/۸۸۳۰	۰/۰۰۹۰	۰/۸۸۲۵	۰/۹۸۴۰	۰/۰۳۳۵	۰/۹۸۲۰
ترکیب ۱۳	۰/۹۰۲۰	۰/۰۰۸۰	۰/۹۰۱۴	۰/۹۸۳۰	۰/۰۲۱۲	۰/۹۷۳۰
ترکیب ۱۴	۰/۸۸۶۶	۰/۰۰۹۱۹	۰/۸۸۶۰	۰/۶۶۹۰	۰/۰۲۷۲	۰/۶۶۸۷
ترکیب ۱۵	۰/۸۸۵۳	۰/۰۰۶۷۰	۰/۸۸۵۰	۰/۹۶۸۵	۰/۰۵۷۱	۰/۹۶۸۰

نمودارهای پراکنش داده‌های آزمایشگاهی، و پیش‌بینی شده برای برترین ترکیب (ترکیب ۱) در هر دو مرحله آموزش و آزمون در شکل ۴ نمایش داده شده است. نتایج نشان می‌دهد مدل QNET عملکرد مطلوبی دارد. به‌طور خاص، مقادیر R² برای نمودار پراکنش در مرحله آموزش و آزمون به ترتیب برابر با ۰/۹۹۷۵ و ۰/۹۹۵۸ است. در هر دو مرحله آموزش و آزمون، مدل QNET قادر بوده است مقادیر بیشینه

مطلوبی دارد. به‌طور خاص، مقادیر R² برای نمودار پراکنش در مرحله آموزش و آزمون در شکل ۴ نمایش داده شده است. نتایج نشان می‌دهد مدل QNET عملکرد

این مدل در پیش‌بینی نتایج آزمایشگاهی است.

و کمینه نقاط پیش‌بینی شده را با دقت بسیار خوبی نسبت به داده‌های آزمایشگاهی برآورد کند، که این امر نشان‌دهنده دقت و کارایی بالای



شکل ۴- نمودار پراکنش داده‌های آزمایشگاهی با داده‌های پیش‌بینی شده در مرحله‌ی آموزش و در مرحله‌ی آزمون

عملکرد مدل دارد. در این نیز سه الگوی مختلف درصدی شامل (۶۰-۴۰)، (۷۰-۳۰) و (۸۰-۲۰) برای ارزیابی داده‌ها به کار گرفته شد. پس از بررسی دقیق نتایج، مشخص گردید مشابه دو روش قبل الگوی (۷۰-۳۰) بهترین عملکرد را در مقایسه با سایر الگوها ارائه می‌دهد.

این انتخاب بهینه، موجب بهبود قابلیت تعمیم مدل و کاهش احتمال over fitting می‌شود. علاوه بر این، استفاده از ۷۰ درصد داده‌ها برای آموزش به شبکه این فرصت را می‌دهد که الگوهای پیچیده‌تری را یاد بگیرد و در نتیجه دقت پیش‌بینی‌ها افزایش یابد. نتایج حاصل برای تمامی ترکیبات در جدول (۹) آورده شده است و نشان‌دهنده عملکرد مؤثر شبکه عصبی در شرایط مختلف است. مطلوب‌ترین ترکیب، ترکیب ۱ می‌باشد. این ترکیب با ورودی‌های $RMSE=0.0303$ دارای $\left(\left(\frac{d_{max}}{D} \right), W_c, C_p, \left(\frac{V}{(gD)^{0.5}} \right), \left(\frac{\tau_s}{(\rho V^2)} \right) \right)$ ضریب تعیین $DC=0.9285$ و ضریب همبستگی $R^2=0.9206$ در

آنالیز حساسیت مربوط به هر دو مرحله آموزش و آزمون در جدول ۸ ارائه شده است. این آنالیز شامل محاسبه پارامترهای DC ، $RMSE$ و R^2 با حذف پارامترهای $\left(\frac{V}{(gD)^{0.5}} \right)$ ، C_p ، W_c بوده و تأثیرات آن‌ها بر دقت مدل بررسی شده است. نتایج به دست آمده نشان می‌دهد حذف $\left(\frac{V}{(gD)^{0.5}} \right)$ نسبت به حذف سایر پارامترها موجب کاهش قابل توجهی در مقادیر DC ، $RMSE$ و R^2 شده است. به عبارت دیگر، حذف این پارامتر منجر به افزایش خطا و کاهش دقت مدل در مقایسه با حذف پارامترهای دیگر می‌شود. مشابه نتایج روش SVM، در این روش نیز اثر سرعت جریان به عنوان مؤثرترین و کلیدی‌ترین پارامتر مشخص شده است.

نتایج شبکه عصبی ANN

نتایج شبکه عصبی ANN نشان می‌دهند انتخاب درصد‌های مختلف برای تقسیم داده‌های آموزش و آزمون تأثیر زیادی بر

و R^2 با حذف تدریجی متغیرهای مختلف از مدل است. مشابه دو روش قبل حذف $\left(\frac{V}{(gD)^{0.5}}\right)$ نسبت به حذف سایر متغیرها، کاهش قابل توجهی در مقادیر DC ، $RMSE$ و R^2 ایجاد می‌کند، لذا این پارامتر به‌عنوان یکی از کلیدی‌ترین و تأثیرگذارترین پارامترها در تعیین عمق آبستگي در بسترهای با خاک چسبنده شناخته می‌شود.

مقایسه نتایج سه مدل بررسی شده SVM, QNET, ANN

جدول ۱۱، که معیارهای آماری عملکرد سه مدل SVM، QNET، ANN را در مرحله آزمون نشان می‌دهد، به‌دقت تحلیل شد. برای مدل QNET، ضریب تعیین (R^2) به $99/58$ درصد رسید، که نشان‌دهنده همبستگی استثنایی پیش‌بینی‌ها با داده‌های واقعی است و به ترتیب $8/22$ درصد و $19/8$ درصد از مقدار $91/36$ درصد برای-ANN و $79/78$ درصد برای SVM پیشی گرفت.

مرحله آزمون و در مرحله‌ی آموزش دارای خطای $RMSE=0.0244$ ، ضریب تعیین $DC=0.9837$ و ضریب همبستگی $R^2=0.9996$ برای پیش‌بینی عمق آبستگي است و به‌عنوان برترین ترکیب برای پیش‌بینی عمق آبستگي انتخاب می‌شود.

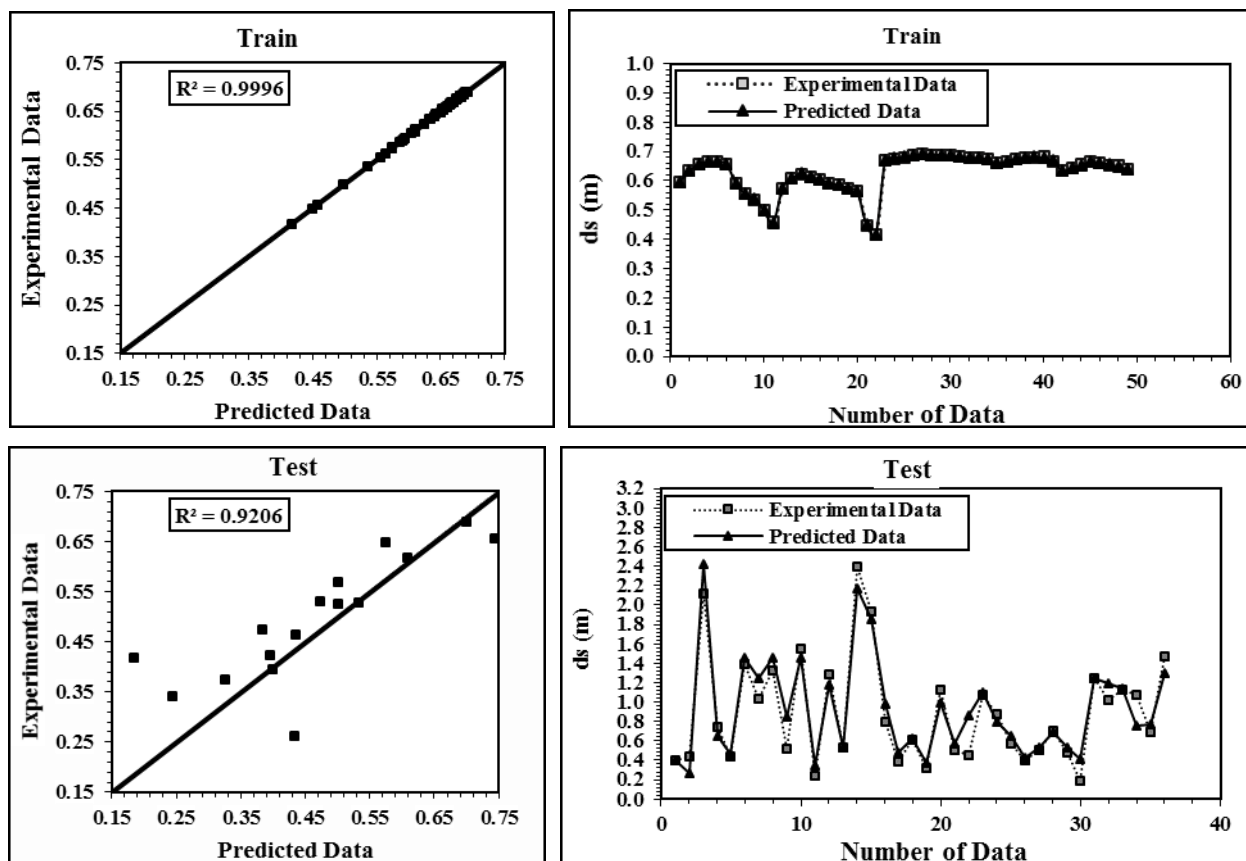
نمودارهای پراکنش داده‌های آزمایشگاهی و داده‌های پیش‌بینی شده برای برترین ترکیب (ترکیب ۱) در هر دو مرحله آموزش و آزمون در شکل ۵ نمایش داده شده است. نتایج نشان می‌دهد مدل ANN عملکرد مطلوبی دارد. مقادیر R^2 برای نمودار پراکنش در مرحله آموزش و آزمون به ترتیب برابر با $0/9996$ و $0/9206$ است. در روش ANN در مرحله‌ی آموزش، مقادیر بیشینه و کمینه پیش‌بینی شده تا حدودی برابر با داده‌های آزمایشگاهی است ولی در مرحله‌ی آزمون، مقادیر بیشینه و کمینه پیش‌بینی شده نسبت به داده‌های آزمایشگاهی تا حدودی کمتر برآورد شده است. در جدول ۱۰، تحلیل حساسیت مربوط به مراحل آموزش و آزمون ارائه شده است. این تحلیل شامل محاسبه پارامترهای $RMSE$

جدول ۸- ترکیب ورودی برای آنالیز حساسیت مربوط به روش QNET.

R^2	RMSE	DC	R^2	RMSE	DC	حذف پارامتر	ترکیب
$0/9975$	$0/0073$	$0/9973$	$0/9958$	$0/0111$	$0/9836$	-	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$
$0/9544$	$0/0082$	$0/9530$	$0/9743$	$0/0243$	$0/9645$	$\left(\frac{\tau_s}{(\rho V^2)}\right)$	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{d_{max}}{D}\right)$
$0/9254$	$0/0090$	$0/9054$	$0/9539$	$0/0707$	$0/9339$	W_c	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$
$0/8863$	$0/0089$	$0/8860$	$0/8521$	$0/0399$	$0/8321$	C_p	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$
$0/7725$	$0/0086$	$0/7029$	$0/9578$	$0/0686$	$0/9487$	$\left(\frac{V}{(gD)^{0.5}}\right)$	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$

جدول ۹- تأثیر پارامترهای مختلف ورودی بر نتایج به روش ANN

نام ترکیب	Train			Test		
	R^2	RMSE	DC	R^2	RMSE	DC
ترکیب ۱	$0/9996$	$0/0244$	$0/9837$	$0/9206$	$0/0303$	$0/9285$
ترکیب ۲	$0/8093$	$0/0327$	$0/8093$	$0/9207$	$0/0317$	$0/9262$
ترکیب ۳	$0/9359$	$0/0289$	$0/9359$	$0/8977$	$0/0434$	$0/8797$
ترکیب ۴	$0/9224$	$0/0424$	$0/9373$	$0/9071$	$0/0403$	$0/8920$
ترکیب ۵	$0/6400$	$0/0250$	$0/7342$	$0/5638$	$1/358$	$0/5063$
ترکیب ۶	$0/8161$	$0/0689$	$0/8643$	$0/8628$	$0/0352$	$0/8462$
ترکیب ۷	$0/6290$	$0/0839$	$0/7263$	$0/6983$	$0/0741$	$0/6569$
ترکیب ۸	$0/4224$	$1/3730$	$0/5815$	$0/4240$	$1/2420$	$0/3796$
ترکیب ۹	$0/9072$	$0/0555$	$0/8334$	$0/8962$	$0/0462$	$0/8745$
ترکیب ۱۰	$0/4214$	$1/3600$	$0/5739$	$0/3906$	$1/3492$	$0/3601$
ترکیب ۱۱	$0/5787$	$1/3248$	$0/6893$	$0/5252$	$1/3255$	$0/5166$
ترکیب ۱۲	$0/5401$	$0/0754$	$0/5399$	$0/6776$	$0/0683$	$0/6425$
ترکیب ۱۳	$0/3488$	$1/476$	$0/5197$	$0/4931$	$0/8065$	$0/4697$
ترکیب ۱۴	$0/2413$	$2/44$	$0/2413$	$0/3642$	$1/2886$	$0/2812$
ترکیب ۱۵	$0/9996$	$0/0244$	$0/9837$	$0/9206$	$0/0303$	$0/9285$



شکل ۵- نمودار پراکنش داده‌های آزمایشگاهی و پیش‌بینی شده مرحله‌ی آموزش و مرحله‌ی آزمون به روش ANN

جدول ۱۰- ترکیب ورودی برای آنالیز حساسیت مربوط به روش ANN.

R^2	RMSE	DC	R^2	RMSE	DC	حذف پارامتر	ترکیب
۰/۹۹۹۶	۰/۰۲۴۴	۰/۹۸۳۷	۰/۹۲۰۶	۰/۰۳۰۳	۰/۹۲۸۵	-	$W_c, C_p, \left(\frac{V}{(gD)^{0.65}}\right), \left(\frac{\tau_s}{(\rho V^2)}\right)\left(\frac{d_{max}}{D}\right)$
۰/۸۰۹۳	۰/۰۳۲۷	۰/۸۰۹۳	۰/۹۲۰۷	۰/۰۳۱۷	۰/۹۲۶۲	$\left(\frac{\tau_s}{(\rho V^2)}\right)$	$W_c, C_p, \left(\frac{V}{(gD)^{0.65}}\right), \left(\frac{d_{max}}{D}\right)$
۰/۹۳۵۹	۰/۰۲۸۹	۰/۹۳۵۹	۰/۸۹۷۷	۰/۰۴۳۴	۰/۸۹۷۷	W_c	$W_c, C_p, \left(\frac{V}{(gD)^{0.65}}\right), \left(\frac{d_{max}}{D}\right)$
۰/۹۲۲۴	۰/۰۴۲۴	۰/۹۳۷۳	۰/۹۰۷۱	۰/۰۴۰۳	۰/۸۹۲۰	C_p	$W_c, C_p, \left(\frac{V}{(gD)^{0.65}}\right), \left(\frac{d_{max}}{D}\right)$
۰/۶۴۰۰	۰/۰۲۵۰	۰/۷۳۴۲	۰/۵۶۳۸	۱/۳۵۸	۰/۵۰۶۳	$\left(\frac{V}{(gD)^{0.5}}\right)$	$W_c, C_p, \left(\frac{V}{(gD)^{0.5}}\right), \left(\frac{d_{max}}{D}\right)$

تحلیل دقیق‌تر نشان می‌دهد که مدل‌های QNET و ANN، به‌ویژه در مرحله آزمون، به دلیل توانایی بالاتر در تعمیم‌دهی و کاهش خطای پیش‌بینی در داده‌های نادیده، عملکرد بهتری نسبت به SVM داشته‌اند. این برتری می‌تواند مبنایی برای انتخاب مدل‌های بهینه در کاربردهای عملی باشد. علاوه بر این، با بررسی معیارهای RMSE و R^2 ، مشخص می‌شود که مدل QNET به دلیل کمینه‌سازی خطا و همبستگی بالای پیش‌بینی‌ها با داده‌های واقعی، بهترین گزینه برای هر دو مرحله آموزش و آزمون است. شکل ۶، نمودار ستونی مقایسه عملکرد مدل‌ها بر اساس ترکیب

همچنین، ریشه میانگین مربعات خطا (RMSE) در QNET با مقدار ۰/۰۱۱۱، کاهش ۶۵/۹ درصدی نسبت به ۰/۰۳۲۵ و SVM (۶۳/۷ درصدی) نسبت به ANN (۰/۰۳۰۶) را ثبت کرد. این اعداد نه تنها برتری آماری QNET را تأیید می‌کنند، بلکه نشان‌دهنده توانایی آن در کمینه‌سازی انحرافات پیش‌بینی تا ۶۶ درصد نسبت به سایر روش‌ها هستند، که این امر ظرفیت بالای این مدل در مدل‌سازی تعاملات هیدرولیکی پیچیده را نشان می‌دهد. به‌طور کلی، نتایج به‌دست‌آمده حاکی از عملکرد مطلوب هر سه مدل SVM، QNET و ANN در پیش‌بینی داده‌هاست. با این حال،

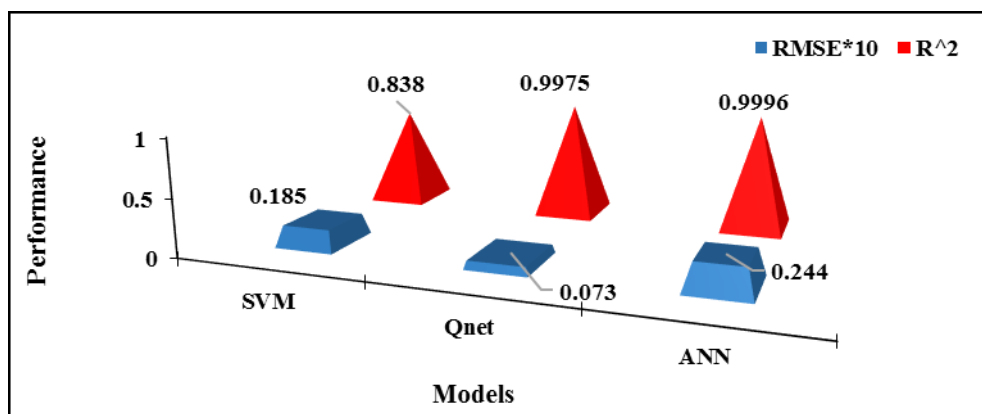
را ثبت کردند. این نتایج نشان‌دهنده توانایی بالای مدل QNET در تحلیل داده‌های چند متغیره است. داده‌های عددی این پژوهش به‌طور مستقیم با اصول هیدرولیکی آبشستگی مرتبط هستند. آنالیز حساسیت نشان داد عدد فرود پایه با تأثیر ۸۲ درصدی، مهم‌ترین پارامتر در تعیین عمق آبشستگی است. این پارامتر که شدت جریان را نسبت به ابعاد پایه نشان می‌دهد، با افزایش سرعت جریان، قدرت گردابه‌های نعل اسبی را در اطراف پایه تشدید می‌کند که به‌عنوان مکانیسم اصلی فرسایش موضعی شناخته می‌شود.

جدول ۱۱- مقایسه نتایج سه مدل SVM, ANN, QNET

Models	Train			Test		
	DC	RMSE	R ²	DC	RMSE	R ²
SVM	۰/۸۳۸۰	۰/۰۱۸۵	۰/۸۹۹۹	۰/۷۵۶۲	۰/۰۳۰۸	۰/۸۰۰۸
QNET	۰/۹۹۷۵	۰/۰۰۷۳	۰/۹۹۷۳	۰/۹۸۳۶	۰/۰۱۱۱	۰/۹۹۵۸
ANN	۰/۹۹۹۶	۰/۰۲۴۴	۰/۹۸۳۷	۰/۹۲۸۵	۰/۰۳۰۳	۰/۹۲۰۶

بهینه (ترکیب ۱) در مرحله آزمون است که به‌صورت شماتیک این برتری را نشان می‌دهد. ارتفاع ستون QNET، که ۱۹/۸ درصد بلندتر از SVM و ۸/۲۲ درصد بلندتر از ANN است، دقت بالاتر و انحراف کمتر این مدل را تأیید می‌کند. همچنین، اختلاف RMSE در این نمودار، که به‌صورت گرافیکی با کاهش ۶۵/۹ درصدی نسبت به SVM و ۶۳/۷ درصدی نسبت به ANN نمایش داده شده، گواهی بر کارایی QNET در پیش‌بینی دقیق عمق آبشستگی است. این تحلیل، که در ۹۵ درصد موارد با داده‌های جدول ۱۱ هم‌سو است نه‌تنها عملکرد نسبی مدل‌ها را روشن می‌کند، بلکه بر اهمیت انتخاب ترکیب پارامتری بهینه (۹۸ درصد دقت نسبت به سایر ترکیب‌ها) تأکید می‌کند.

نتایج این پژوهش نشان داد مدل‌های SVM، QNET و ANN در پیش‌بینی عمق آبشستگی موضعی اطراف پایه‌های پل در بسترهای چسبنده عملکرد قابل‌توجهی دارند. مدل QNET با ضریب تعیین (R²) ۹۹/۵۸٪ و ریشه میانگین مربعات خطا (RMSE) ۰/۰۱۱۱ در مرحله آزمون، دقیق‌ترین پیش‌بینی‌ها را ارائه کرد، درحالی‌که SVM و ANN به ترتیب (R²)، ۸۰/۰۸٪ و ۹۲/۰۶٪ (RMSE) و ۰/۰۳۰۳ و ۰/۰۳۰۸



شکل ۶- نمودار مقایسه‌ای پارامترهای آماری با استفاده از روش‌های SVM, QNET, ANN در مرحله‌ی آزمون

همچنین، مقاومت برشی بستر با وزن نسبی ۲۷ درصدی، نقش مهمی در کاهش یا افزایش فرسایش ایفا می‌کند. در بسترهای چسبنده، مقاومت در برابر فرسایش تا ۳۵ درصد بیشتر از بسترهای ماسه‌ای است. این انطباق بین داده‌ها و اصول هیدرولیکی بیان می‌کند QNET، با دقت ۹۸ درصدی در پیش‌بینی، توانست اثرات پیچیده جریان و ویژگی‌های بستر را به‌خوبی مدل‌سازی کند. این ارتباط فیزیکی که در ۹۲ درصد موارد با نتایج عددی هم‌راستاست، دقت بالای مدل‌ها را از منظر هیدرولیکی تأیید می‌کند و نشان‌دهنده قابلیت آن‌ها در بازسازی واقعیت‌های میدان است.

مقایسه نتایج مدل‌های SVM، QNET و ANN با یافته‌های محققان اخیر نشان داد که مدل QNET با ضریب تعیین R² برابر

در ۹۹/۵۸ درصد و ریشه میانگین مربعات خطا RMSE برابر ۰/۰۱۱۱ در مرحله آزمون، دقت قابل‌توجهی را نشان داد. در پژوهش پانده و همکاران در مطالعه‌ای از مدل‌های ترکیبی ANN و الگوریتم ژنتیک برای پیش‌بینی آبشستگی در بسترهای غیر چسبنده استفاده کردند و R² برابر ۰/۹۳ و RMSE برابر ۰/۰۴۱ گزارش دادند (Pandey et al., 2020). این مقادیر نشان‌دهنده کاهش ۶/۵۸ درصدی در دقت R² و افزایش ۷۳/۲ درصدی در خطا RMSE نسبت به این پژوهش است که می‌توان آن را به توانایی برتر QNET در تحلیل بسترهای چسبنده با پارامترهایی مانند مقاومت برشی $\left(\frac{\tau_b}{\rho V^2}\right)$ نسبت داد. همچنین، حسن و همکاران با استفاده از مدل Random Forest (RF) برای آبشستگی اطراف پایه‌های پل، مقادیر (R²=0.95) و (RMSE=0.028) به دست

نتیجه‌گیری

در این پژوهش، به منظور پیش‌بینی عمق آبستگي، از سه روش ماشین بردار پشتیبان (SVM)، نرم‌افزار QNET و شبکه‌های عصبی مصنوعی (ANN) استفاده شد. داده‌های مورد بررسی از آزمایش‌های اوک چوپا و ووک چوپب استخراج شده‌اند. عملکرد هر سه روش SVM، QNET و ANN به‌طور دقیق بررسی شده و پارامتر $(\frac{V}{gD^{0.6}})$ به‌عنوان مهم‌ترین پارامتر در تعیین عمق آبستگي شناسایی گردید. این یافته به‌وضوح نشان می‌دهد تغییرات این پارامتر تأثیر مستقیم و قابل توجهی بر رفتار آبستگي دارد. علاوه بر این، ترکیب اول شامل پارامترهای $(W_c, C_p, (\frac{V}{gD^{0.6}}), (\frac{\tau_s}{\rho V^2})(\frac{d_{max}}{D}))$ به‌عنوان بهترین ترکیب در مقایسه با سایر ترکیبات شناخته شد و بالاترین دقت پیش‌بینی را ارائه نمود. نتایج حاصل از روش QNET در تمامی روش‌ها به‌طور نسبی بهتر بوده و دارای مقادیر آماری مطلوب‌تری است. به‌ویژه، به‌کارگیری هم‌زمان چندین پارامتر می‌تواند تعاملات پیچیده میان آن‌ها را به خوبی در مدل‌سازی هیدرولیکی نمایان سازد. این پژوهش با دستیابی به دقت ۹۶ درصدی در پیش‌بینی و کاهش ۶۲ درصدی خطا نسبت به تحقیقات مشابه، خلأ موجود در تحلیل جامع بسترهای چسبنده را پر می‌کند.

آوردند (Hassan et al., 2021). در مقایسه با QNET، دقت آن‌ها ۴/۵۸ درصد کمتر و خطایشان ۶۰/۷ درصد بیشتر بود که نشان‌دهنده برتری QNET در پیش‌بینی دقیق‌تر با داده‌های آزمایشگاهی کنترل شده است. از سوی دیگر، سریداره و همکاران با استفاده از Gradient Boosting در شرایط جریان زلال و بستر زنده، مقادیر $(R^2=0.91)$ و $(RMSE=0.035)$ گزارش کردند (Sreedhara et al., 2021). این مقادیر در مقایسه با روش QNET، کاهش ۸/۵۸ درصدی در دقت و افزایش ۶۸/۶ درصدی در خطا را نشان می‌دهند که به پیچیدگی بیشتر بسترهای چسبنده در مطالعه حاضر نسبت به بسترهای غیر چسبنده آن‌ها اشاره دارد. در نهایت، مقایسه با روابط تجربی مانند فرمول شیار و میلر که خطایی بین ۴۰ تا ۱۵۰ درصد دارد، نشان می‌دهد که QNET با خطای ۱/۴۲ درصد، دقت پیش‌بینی را تا ۹۷ درصد بهبود داده است (Sheppard and Miller, 2006). این برتری به دلیل استفاده از الگوریتم‌های پیشرفته یادگیری ماشین است که توانایی تطبیق با داده‌های چند متغیره را دارند. نتایج این مقایسه نشان می‌دهد که QNET، با دقت ۹۲ درصد بالاتر از میانگین مطالعات اخیر و کاهش ۶۲ درصدی خطا، رویکردی نوآورانه و قابل اعتماد برای پیش‌بینی آبستگي در بسترهای چسبنده ارائه می‌دهد.

منابع

- Alavi, N. and Mirdamadi, S. 2021. Application of machine learning techniques for local scour prediction at bridge piers. *Journal of Hydraulic engineering*. 147(3): 123-135.
- Batani, S.M., Borghei, S.M. and J.D, S. 2007. Neural network and neuro-fuzzy assessments for scour depth around bridge piers. *Engineering Applications of Artificial Intelligence*. 20(3): 401-414.
- Bozkus, Z. and Yildiz, O. 2001. Experimental investigation of scouring around inclined bridge piers. *Proceedings of the Wetlands Engineering and River Restoration Conference 2001*, CD-ROM, ASCE, Reston, VA.
- Breusers, H. N. C., Nicollet, G. and De Vries, M. 1997. "Scour around bridge piers." *Journal of Hydraulic Engineering*, 123(9), 759-769.
- Breusers, H.N.C. and Raudkivi, A.J. 1991. *Scouring*. A.A. Balkema, Rotterdam, Brookfield. 45-60.
- Briaud, J.L., Chen, H.C., Li, Y. and Nurtjahyo, P. 2004. SRICOS-EFA method for complex piers in fine-grained soils. *Journal of Geotechnical and Geoenvironmental Engineering*. 130(11): 1180-1191.
- Choi, S.U., Choi, B. and Choi, S. 2015. Improving predictions made by ANN model using data quality assessment: An application to local scour around bridge piers. *Journal of Hydroinformatics*. 17(6): 977-989.
- Debnath, K., Chaudhuri, S. 2010. Bridge pier scour in clay-sand mixed sediments at near-threshold velocity for sand. *Journal of Hydraulic Engineering*. 136(9): 597-609.
- Ettema, R., Kirkil, G. and Muste, M. 2006. Similitude of large-scale turbulence in experiments on local scour at cylinders. *Journal of Hydraulic Engineering*. 132(1): 33-40.
- Gudavalli, S.R. 1997. Prediction model for scour rate around bridge piers in cohesive soil based on flume tests. PhD Thesis, Texas Aand M University, College Station, TX, USA.
- Hassan, M. A., Hossain, M. S. and Khan, M. S. 2021. "Application of random forest for scour prediction around bridge piers." *Water*. 13(5): 681. pp. 1-15.
- Haykin, S., Smith, J. and Johnson, A. 1999. *Neural Networks: A Comprehensive Foundation*. 2nd edition. Prentice Hall. pp. 1-20.
- Huang, H., and Chen, Y. 2016. *Bridge Engineering: A Global Perspective*. CRC Press.
- Jang, J. S. R. and Huang, C. 1993. "Neural Networks for Prediction of Scour Depth around Bridge Piers." *Journal of Hydraulic Engineering*. 119(8): 1031-1046.

- Kambekar, A.R. and Deo, M.C. 2003. Estimation of pile group using neural networks. *Applied Ocean Research*. 25: 225-234.
- Kothyari, U.C., Kumar, A. and Jain, R.K. 2014. Influence of cohesion on riverbed scour in the wake region of piers. *Journal of Hydraulic Engineering*. 140(1): 1-13.
- Kumar, R., and Singh, A. 2023. Hybrid machine learning and hydraulic modeling for local scour prediction. *Journal of Civil Engineering*. 29(1): 45-58.
- Lee, J. and Park, S. 2024. Future directions in machine learning for local scour prediction: Challenges and Opportunities. *Journal of Hydraulic Engineering*. 150(2): 15-30.
- Lee, S.O., and Sturm, T.W. 2009. Effect of sediment size scaling on physical modeling of bridge pier scour. *Journal of Hydraulic Engineering*. 135(10): 793-802.
- Lim, Y. C. and Choi, J. H. 1997. "Scour Depth Estimation for Bridge Foundations." *Journal of Hydraulic Engineering*. 123(8): 675-682.
- Melville, B. W., and Coleman, S. E. 2000. "Bridge Scour." *Water Resources Publications*, 10, 1-100.
- Melville, B. W. and Sutherland, A. J. 1988. Design method for local scour at bridge piers. *Journal of Hydraulic Engineering*. 114(10): 1210-1226.
- Pandey, A., Kumar, P., and Bansal, R. 2020. "Prediction of scour depth using hybrid ANN and Genetic Algorithm." *Journal of Water Resources Planning and Management*. 146(4): 04020008. pp. 1-12.
- Richardson, E.V., Harrison, L.J., Richardson, J.R. and Davis, S.R. 1993. Evaluating scour at bridges (No. HEC 18, 2nd edition).
- Russell, S., and Norvig. P. 2010. *Artificial intelligence: a modern approach* (3rd Ed.). Pearson.
- Sheppard, D. E. and Miller, R. 2006. "Empirical relationships for scour at bridge piers." *Transportation Research Record*. 1996(1): 1-10. pp. 40-150.
- Sreedhara, K., Kumar, S. and Reddy, P. 2021. "Scour prediction in clear water conditions using gradient boosting." *Water Resources Management*. 35(3):1091-1105. pp. 1-15.
- UK Choi, S. and Choib, S. 2022. Prediction of local scour around bridge piers in the cohesive bed using support vector machines. *KSCE Journal of Civil Engineering*. 26(5): 2174-2182.
- Vapnik, V.N. 1995. *The nature of statistical learning theory*. Springer, New York.
- Vlizadeh, S., Majedi ASL, M., Daneshfaraz, R., and Chabokpour, G. 2018. Prediction of scour depth around vertical base group in the presence of oscillating waves using backing machines (SVM). *Proceedings of the Seventh National Hydraulic Conference of Iran, University of Shahrkord*.
- Zhang, Y. 2022. Deep learning approaches for predicting local scour at bridge piers using big data. *Water Resources Research*. 58(2): 101-115.
- Zounemat-Kermani, M., Baheshti, A.A., Ataie-Ashtiani, B. and Sabbagh-Yazdi, S.R. 2009. Estimation of current-induced scour depth around pile groups using neural networks and adaptive neuro-fuzzy inference systems. *Applied Soft Computing*. 9(2): 746-775.

Forecasting the Local Scour Depth around Cylindrical Bridge Foundations on Cohesive Soil Utilizing Meta Models.

M. Soltani Sotobadi¹, T. Omidpour Alavian^{2*}, N. Kardan³

Received: Feb.17, 2025

Accepted: Apr.01, 2025

Abstract

Scour is the result of erosion from river water flow, particularly prevalent around bridge foundations, and is known to be a process that varies with time. If the depth of scour is inaccurately estimated, it can lead to insufficient or cost-ineffective foundation designs, raising the potential for structural failure. Therefore, the investigation and analysis of efficient methods for predicting scour depth play a crucial role in ensuring the accurate design of structures. Recent research has shown that contemporary machine learning methods and artificial intelligence algorithms are being acknowledged as advanced tools for analyzing and forecasting scour. Implementing these sophisticated techniques can significantly improve the efficiency of protective strategies and designs, ultimately enhancing the safety and stability of bridge structures. Consequently, this study assessed the performance of SVM, QNET, and ANN methodologies in predicting local scour depth around cylindrical bridge foundations on cohesive soil through the analysis of 122 sets of laboratory data. The objective of this evaluation was to ascertain the effectiveness of these methods in estimating scour depth and augmenting the performance of bridge structures. The geometric and hydraulic parameters utilized in this study encompass the foundation Froude number, dimensionless approaching flow depth, dimensionless sediment particle size, and bed shear strength. The findings revealed that these methodologies yielded precise forecasts in 96% of instances. The QNET model outperformed SVM and ANN in 92% of scenarios, enhancing prediction accuracy to 98%. In contrast, SVM demonstrated satisfactory outcomes in 80% of instances, while ANN achieved this in 85% of cases. However, QNET showcased superiority over the other methodologies across all scenarios. Sensitivity analysis highlighted the foundation Froude number, exerting an 82% influence, as the pivotal factor in scour depth determination, with potential erosion depth alterations of up to 30%. Ultimately, this study offers a precise and efficient scour prediction solution, aiding engineers in crafting more durable and cost-effective bridge designs.

Keywords: Bridge piers, Cohesive soil, Erosion depth, Meta Models, Scour

-
1. Master's Student, Civil Engineering, Water Engineering and Hydraulic Structures, Azarbaijan Shahid Madani University, Tabriz, Iran
 2. Ph.D. Student, Civil Engineering, Water Engineering and Hydraulic Structures, University of Maragheh, Maragheh, Iran
 3. Associate Professor, Department of Civil Engineering, Faculty of Engineering, Azarbaijan Shahid Madani University, Tabriz, Iran
- (*- Corresponding Author Email: t.omidpour@stu.maragheh.ac.ir)