



پیش‌بینی مقاومت برشی تیرهای عمیق بتن مسلح با استفاده از روش ماشین بردار پشتیبان حداقل مربعات وزن‌دار

محمد رضا محمدی زاده*، فرناز اسفندینا

دانشکده فنی و مهندسی، دانشگاه هرمزگان، بندرعباس، ایران.

تاریخچه داوری:

دریافت: ۱۳۹۸/۱۲/۲۶
بازنگری: ۱۳۹۹/۰۴/۲۳
پذیرش: ۱۳۹۹/۰۸/۱۲
ارائه آنلاین: ۱۳۹۹/۰۸/۱۳

کلمات کلیدی:

تیر عمیق بتن مسلح
مقاومت برشی
هوش مصنوعی
ماشین بردار پشتیبان حداقل مربعات
وزن‌دار

خلاصه: مقاومت برشی تیرهای عمیق بتن مسلح (RC) وابسته به پارامترهای مکانیکی و هندسی تیر تغییر مینماید. برآورد دقیق مقاومت برشی در تیرهای عمیق بتن مسلح یکی از اصلی‌ترین موضوعات در طراحی سازه‌های مهندسی است. با این حال، پیش‌بینی مقاومت برشی در این نوع تیرها از دقت بالایی برخوردار نیست. یکی از روش‌های تخمین نسبتاً دقیق مقاومت برشی استفاده از هوش مصنوعی می‌باشد. هوش مصنوعی دارای روش‌های مختلفی است که یکی از این روش‌ها استفاده از تکنیک هوش مصنوعی (AI) مبتنی بر روش ماشین بردار پشتیبان است. در این مطالعه برای پیش‌بینی ظرفیت برشی تیرهای عمیق بتن مسلح از روش ماشین بردار پشتیبان حداقل مربعات وزن‌دار (WLS-SVM) که روشی نسبتاً جدید و کارآمد است، استفاده شده است. برای این منظور ابتدا یک بانک اطلاعاتی شامل نتایج آزمایشگاهی مربوط به تیرهای عمیق بتن مسلح جمع‌آوری شد. سپس پس از تعیین پارامترهای ورودی و خروجی با کمک فرآیند آموزشی در روش WLS-SVM و با استفاده از بخشی از داده‌های جمع‌آوری شده، مدلی برای پیش‌بینی مقاومت برشی تیرهای عمیق بتن مسلح ایجاد شد. به منظور تعیین دقت روش WLS-SVM، نتایج به دست آمده با نتایج حاصل از سایر روش‌های هوش مصنوعی و آیین‌نامه‌های مختلف مورد ارزیابی و مقایسه قرار گرفت. بررسی‌های آماری نشان داد که روش WLS-SVM دارای بهترین عملکرد از نظر پارامترهای ارزیابی آماری ($R^2 = 0.9887$ ، $RMSE = 0.107$ ، $MAE = 0.478$ و $MAPE = 7.9/48$) نسبت به سایر روش‌ها هستند. بنابراین این مطالعه نشان می‌دهد که می‌توان از روش WLS-SVM به عنوان ابزاری کارآمد در طراحی تیرهای عمیق استفاده نمود.

۱- مقدمه

از تیرهای عمیق بتن مسلح (RC) غالباً به عنوان اعضای سازه‌ای و عناصر توزیع بار مانند ساخت صفحات تاشو، دیوارهای فونداسیونی، تسمه‌های انتقال و کلاهک‌های شمع در ساختمان‌های بلند استفاده می‌شود. با وجود سودمندی و محبوبیت این المان‌ها، تیرهای عمیق بتن مسلح از نظر طراحی متفاوت از سایر المان‌های سازه‌ای هستند. زیرا پارامترهای مختلفی در رفتار غیرخطی و مقاومت برشی آن‌ها نقش تعیین‌کننده را دارند. به دلیل رفتار پیچیده‌ی این تیرها، تعریف دقیق و یکسانی در خصوص آن‌ها که مورد تایید همه آیین‌نامه‌ها باشد وجود ندارد. اما در اکثر این آیین‌نامه‌ها، اگر نسبت دهانه (L) به عمق (D) در المان تیر کمتر از ۵ باشد را به عنوان تیر عمیق معرفی می‌نمایند. این نسبت در آیین‌نامه‌های اروپا، کانادا و آمریکا به ترتیب کمتر از ۲/۵، ۵ و ۴ است. به دلیل پیچیدگی مکانیزم برشی تیرهای عمیق

بتن مسلح و انواع پارامترهای موثر بر آن، ایجاد یک مدل کلی برای ارائه و برآورد دقیق از مقاومت برشی دشوار بوده و به همین دلیل مقدار دقیق مقاومت برشی این نوع تیرها با استفاده از یک حل بسته، قابل محاسبه نیستند [۱]. تا چندین دهه متوالی، مطالعات کمی به بررسی مقاومت برشی و تحلیل رفتار تیرهای عمیق بتن مسلح پرداخته‌اند. از جمله روش‌های کار شده در این زمینه می‌توان به مدل قفل و بست^۲ اشاره نمود. در دهه‌های گذشته، هوش مصنوعی (AI) موضوع تحقیقات گسترده در زمینه مهندسی عمران بوده است [۳ و ۲]. هوش مصنوعی با موفقیت مسائل پیچیده را شبیه‌سازی می‌نماید، به همین دلیل به یک روش پیش‌بینی قدرتمند تبدیل شده است. این موضوع طراحان سازه را قادر می‌سازد عملکرد سازه‌ای اعضای بتن مسلح را پیش‌بینی نمایند. استفاده از روش‌های هوش مصنوعی نشان داده است که می‌توان یک رابطه غیرخطی پیچیده بین ظرفیت برشی تیرهای عمیق

1 Reinforced Concrete

*نویسنده عهده‌دار مکاتبات: mrz_mohammadizadeh@hormozgan.ac.ir

- 2 Strut and Tie Method
- 3 Artificial Neural Network

حقوق مؤلفین به نویسندگان و حقوق ناشر به انتشارات دانشگاه امیرکبیر داده شده است. این مقاله تحت لایسنس آفرینندگی مردمی (Creative Commons License) در دسترس شما قرار گرفته است. برای جزئیات این لایسنس، از آدرس <https://www.creativecommons.org/licenses/by-nc/4.0/legalcode> دیدن فرمایید.



داده‌های آموزشی نسبتاً کوچک را دارد. علاوه بر این، با استفاده از SVM می‌توان روابط غیرخطی و پیچیده را نیز مدل‌سازی نمود. تاکنون از SVM در حوزه‌های مختلف مهندسی عمران استفاده شده است. به عنوان مثال، چن^۴ و همکاران به مطالعه و پیش‌بینی پارامترهای تغییر شکل و تنش در تونل به روش ماشین بردار پشتیبان پرداختند [۹]. لیو^۵ و همکاران از روش ماشین بردار پشتیبان برای مدل‌سازی مصرف انرژی در ساختمان استفاده نمودند [۱۰]. از دیگر مطالعات انجام شده در مهندسی عمران در خصوص یادگیری ماشین به عنوان یک ابزار مدل‌سازی پیشرفته می‌توان به کارهای اسار و ریس روحانی^۶، چو^۷ و همکاران، هوآنگ^۸ و همکاران و خطیبی نیا و عراقی اشاره داشت [۱۱-۱۴]. ماشین بردار پشتیبان حداقل مربعات (LS-SVM^۹) به عنوان بسطی از SVM مطرح است که شامل چندین ویژگی پیشرفته بوده و قابلیت آن توسط محاسبات سریع نشان داده شده است [۱۵]. روش LS-SVM برای حل مسائل پیچیده و غیرخطی در مهندسی استفاده شده است [۱۶]. به عنوان بخشی از فرآیند آموزش، روش LS-SVM از روش عملکرد حداقل مربعات برای استخراج مجموعه‌ای خطی از معادلات موجود در فضای دوگانه استفاده می‌کند. به این ترتیب، می‌توان پاسخ را با استفاده از روش‌های تکراری، مانند گرادیان مزدوج، به صورت منطقی از حل معادلات خطی به دست آورد. برای دستیابی به بیشترین بازده با استفاده از SVM و LS-SVM، باید مقادیر پارامتر مناسب برای هر دو گروه تعیین شود. پارامترهای SVM که باید از پیش مشخص شوند شامل پارامتر تنظیم (C) و پارامتر کرنل^{۱۰} RBF^{۱۱} (γ_1) هستند. انتخاب نامناسب برای پارامترهای تنظیم (C) و کرنل (γ_1) باعث می‌شود که پیش‌بینی مدل با دقت کمتری انجام شود. در همین حال، پارامترهای روش LS-SVM که باید از پیش مشخص شده باشند شامل پارامتر تنظیم (γ_2) و پارامتر کرنل RBF^{۱۱} (σ_2) هستند. شایان ذکر است که شناسایی مناسب‌ترین مقادیر پارامترهای ذکر شده یک موضوع چالش برانگیز بوده و یک مسئله بهینه‌سازی را پیش روی قرار می‌دهد [۱۷-۲۱]. روش ماشین بردار پشتیبان حداقل مربعات وزن دار (WLS-SVM^{۱۱}) حالت وزن دار LS-SVM است. در WLS-SVM با اختصاص دادن وزن به متغیرهای خطا، روش

بتن مسلح و همه پارامترهای تاثیرگذار در آن برقرار نمود و به تخمین‌های بسیار دقیق دست یافت. بنابراین، استفاده از روش‌های هوش مصنوعی به عنوان یک روش جدید و مبتکرانه، در حوزه مهندسی عمران مطرح است. در تحقیقات زیادی از روش‌های هوش مصنوعی و زیر مجموعه‌های مختلف آن مانند روش‌های فازی و الگوریتم‌های فرا ابتکاری در این حوزه استفاده شده است [۵ و ۴]. روند غالب در روش‌های هوش مصنوعی به این صورت هستند که برای دستیابی به مدل‌های کارآمدتر، مدل‌های جدیدی (مدل گروه) بر اساس ترکیب مدل‌های قبلی به گونه‌ای ایجاد می‌شود که مدل گروه جدید می‌تواند دارای دقت یادگیری بالاتر و همچنین دارای تنوع خطای کمتر در بین اعضا گروه باشد. بنابراین در مقایسه با روش استفاده از یادگیرنده تک ماشین با یک زیر مجموعه متفاوتی از داده‌های آموزشی، یا استفاده از یک یادگیرنده واحد و با پارامترهای آموزش متفاوت، به طور کلی روش استفاده از یادگیرنده‌های مختلف باعث ایجاد مدل‌های گروه قوی‌تر با قابلیت تعمیم زیاد را به دست می‌دهد. زیرا یادگیرنده‌های ماشین‌های مختلف ممکن است به صورت منطقی از خطای مشابه جلوگیری نمایند. علاوه بر این، داده‌های جامع آموزش می‌توانند به طور کامل در فرآیند آموزش به کار گرفته شوند، که در صورت داشتن داده‌های آموزشی محدود، این امر ضروری خواهد بود. چو و فام^۱ دریافتند که یک مدل گروه ترکیبی از دو یا چند یادگیرنده قدرتمند می‌تواند به طور قابل توجهی از مدل‌های گروه با یادگیرندگان واحد دارای عملکرد بالاتری باشد [۶]. به همین دلیل با تلفیق چندین یادگیرنده، می‌توان مشکلات پیش‌بینی ضعیف و واریانس نتایج را کاهش داد. زیرا نتایج کلی در چندین یادگیرنده می‌تواند دارای دقت بالاتری نسبت به نتایج یک یادگیرنده واحد باشد [۷]. روش ماشین بردار پشتیبان (SVM^۲) یکی از مهم‌ترین روش‌ها در حوزه هوش مصنوعی و مدل‌سازی‌های غیرخطی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر از جمله شبکه‌های عصبی برای طبقه بندی و تخمین توابع نشان داده است. ماشین بردار پشتیبان (SVM) یک روش یادگیری ماشینی است که در سال ۱۹۹۵ توسط واپنیک^۳ پیشنهاد شده است [۸]. SVM به عنوان یکی از قوی‌ترین روش‌ها در یادگیری ماشین، به گروه مدل‌های تحت نظارت تعلق دارد. در مقایسه با سایر روش‌های مشابه، SVM طیف وسیعی از خصوصیات مفید، مانند عملکرد بالاتر از حد متوسط، را به وجود می‌آورد و توانایی تولید مرزهایی با کیفیت بالا در تصمیم‌گیری مبتنی بر زیر مجموعه

4 Chen
5 Liu
6 Acar and Rais-Rohani
7 Chou
8 Hoang
9 Least Squares Support Vector Machine
10 Radial Basis Function Kernel
11 Weight Least Squares Support Vector Machine

1 Chou and Pham
2 Support Vector Machine
3 Vapnik

$$V_n = V_c + V_s \quad (3)$$

که در آن V_s به ترتیب زیر بیان می‌شود:

$$V_s = \left[\frac{A_v}{12s} \left(1 + \frac{L_n}{d} \right) + \frac{A_{vh}}{12s_2} \left(11 - \frac{L_n}{d} \right) \right] f_y d \quad (4)$$

در معادله فوق L_n طول موثر تیر، A_v مساحت میلگردهای برشی عمود بر آرماتور خمش طولی در فاصله s ، f_y تنش تسلیم خاموت‌ها، s فاصله خاموت‌ها، A_{vh} مساحت میلگردهای برشی موازی با آرماتور خمش طولی در فاصله s_2 و ρ_v نسبت میلگردهای برشی است. در آیین‌نامه CSA [۲۴] نیز همانند آیین‌نامه ACI مقاومت برشی کل تیر عمیق بتنی متشکل از دو مقاومت برشی به دست آمده از سهم بتن و مقاومت برشی به دست آمده از سهم میلگردهای برشی است. در آیین‌نامه CSA دو رابطه برای سهم برش بتن v_c بسته به مقدار آرماتورهای عرضی و عمق موثر تیر بر اساس رابطه (۵) ارائه شده است:

$$v_c = \frac{V_c}{b_w d} = 0.2 \sqrt{f'_c} \quad (5)$$

با شرط:

$$A_v \geq \frac{0.006 \sqrt{f'_c} b_w s}{f_{yv}} \quad \text{و} \quad d \leq 300 \text{mm} \quad (6)$$

یا

$$v_c = \frac{V_c}{b_w d} = \left(\frac{260}{1000 + d} \right) \sqrt{f'_c} \geq 0.1 \sqrt{f'_c} \quad (7)$$

با شرط:

$$A_v < \frac{0.006 \sqrt{f'_c} b_w s}{f_{yv}} \quad \text{و} \quad d > 300 \text{mm} \quad (8)$$

LS-SVM بهبود می‌یابد. این روش در مقایسه با LS-SVM توابع را به صورت دقیق‌تر پیش‌بینی می‌نماید. لذا WLS-SVM نسبت به LS-SVM از عملکرد بهتری برخوردار است [۲۲]. در مطالعه حاضر روش WLS-SVM برای پیش‌بینی ظرفیت برشی تیرهای عمیق بتن مسلح مورد استفاده قرار می‌گیرد. برای این منظور در بخشهای بعدی، در ابتدا به بررسی عملکرد WLS-SVM پرداخته می‌شود و سپس نتایج حاصل از پیش‌بینی صورت گرفته توسط این روش ارزیابی شده و با نتایج حاصل از آیین‌نامه‌های موجود و روش‌های مختلف هوش مصنوعی که در ادبیات فنی موجود است، مقایسه می‌شود.

۲- مقاومت برشی تیر عمیق بتن مسلح


روش‌های متعددی برای طراحی تیرهای عمیق استفاده شده است. آیین‌نامه بتن آمریکا (ACI) [۲۳] بر اساس مدلی موسوم به مدل خرابایی^۱ است، که در آن سهم بتن بر اساس نتایج تجربی ارائه شده است. رابطه ACI برای محاسبه مقاومت برشی تیر عمیق بر اساس روابط (۱)، (۲)، (۳) و (۴) هستند:

$$V_c = v_c b_w d = \left(3.5 - 2.5 \frac{M_u}{V_u d} \right) \times \left(1.9 \sqrt{f'_c} + 2.5 \rho_w \frac{V_u d}{M_u} \right) b_w d \quad (1)$$

که در این روابط، f'_c مقاومت فشاری ۲۸ روزه نمونه بتن سیلندری 15×30 آمریکا و ρ_w نسبت میلگردهای طولی است که با رابطه (۲) به دست می‌آید:

$$\rho_w = A_s / b_w d \quad (2)$$

پارامترهای V_u ، M_u ، b_w و d به ترتیب نیروی برشی، ممان خمشی در مقطع بحرانی، عرض تیر و عمق موثر تیر هستند. برای تیرهایی که در راستای عرضی نیز مسلح شده‌اند، مقاومت برشی اسمی تیر عمیق V_n شامل مقاومت برشی به دست آمده از سهم بتن V_c و مقاومت برشی به دست آمده از سهم میلگردها V_s خواهد بود:



شکل ۱. پارامترهای هندسی یک تیر عمیق بتن مسلح

Fig. 1. Geometric parameters of a deep reinforced concrete beam

بتن مسلح بر اساس روابط آیین‌نامه‌ای انتخاب شدند. به همین دلیل هشت عامل مؤثر، که به عنوان متغیرهای ورودی در روش WLS-SVM برای تخمین مقاومت برشی استفاده می‌شوند، عبارتند از: عمق مؤثر (d)؛ عرض جان تیر (b)؛ نسبت میلگردهای اصلی (ρ)؛ مقاومت فشاری بتن (f'_c)؛ نسبت میلگرد برشی عمودی (ρ_v)؛ نسبت میلگرد برشی افقی (ρ_h) و نسبت دهانه برش به عمق مؤثر (a/d). متغیر وابسته، مقاومت برشی نهایی تیرهای عمیق بتن مسلح (V/bd) است. جدول ۱ توصیفات آماری متغیرهای ورودی و خروجی را ارائه می‌دهد.

۴- روش شناسی تحقیق

ماشین‌های بردار پشتیبان (SVM) دارای دو ایراد اساسی هستند: (۱) عدم توانایی در تنظیم دقیق پارامتر هسته و (۲) تنها اتکاء آن‌ها به بردارهای پشتیبان برای تعیین مرز تصمیم‌گیری است. سویکنز^۱ و همکاران [۱۵] با معرفی ماشین‌های بردار پشتیبان حداقل مربعات وزن‌دار (WLS-SVM)، که در آن با اختصاص دادن وزن به متغیرهای خطا، روش LS-SVM بهبود یافته است، به حل مسائل مختلف پرداختند. با در نظر گرفتن مجموعه داده‌های نمونه آموزش برابر با N عدد، $\{(x_k, y_k)\}_{k=1}^N$ و با داده‌های ورودی $x_i \in R^d$ و داده‌های خروجی $y_i \in R$ ، رگرسیون WLS-SVM به عنوان مسئله بهینه‌سازی در فضای اولیه وزن به صورت زیر فرموله شده است [۳۳]:

سهم مقاومت برشی تیر عمیق از میلگردهای برشی همانند رابطه ارائه شده برای v_s در آیین‌نامه ACI است.

۳- داده‌های آزمایشگاهی

۳-۱- توصیف داده‌ها

در این مطالعه، مجموعه داده‌ها شامل ۲۱۴ نتیجه آزمایش تیر عمیق بتن مسلح است. این مجموعه داده‌ها از ۸ مطالعه مستقل انجام شده به دست آمده است. این داده‌ها شامل ۳۷ نمونه از مطالعه آزمایشگاهی کلارک^۱ [۲۵]، ۲۵ نمونه از مطالعه آزمایشگاهی کنگ^۲ و همکاران [۲۶]، ۵۲ نمونه از مطالعه آزمایشگاهی اسمیت و وانسیوتیس^۳ [۲۷]، ۱۲ نمونه از مطالعه آزمایشگاهی اندرسون و رامیرز^۴ [۲۸]، ۱۹ نمونه از مطالعه آزمایشگاهی تن^۵ و همکاران [۲۹]، ۵۳ نمونه از مطالعه آزمایشگاهی او و شین^۶ [۳۰]، ۴ نمونه از مطالعه آزمایشگاهی آگیلار^۷ و همکاران [۳۱] و ۱۲ نمونه از مطالعه آزمایشگاهی کواپنتر^۸ و همکاران [۳۲] به دست آمده است. شکل ۱ جزئیات تیر عمیق بتن مسلح را نشان می‌دهد. متغیرهای ورودی در روش WLS-SVM متناظر با پارامترهای تاثیرگذار در ظرفیت برشی تیرهای عمیق

- 1 Clark
- 2 Kong
- 3 Smith and Vantsiotis
- 4 Anderson and Ramirez
- 5 Tan
- 6 Oh and Shin
- 7 Aguilar
- 8 Quintero-Febres

جدول ۱. توصیف آماری پارامترهای ورودی و خروجی در مطالعه حاضر

Table 1. Statistical description of input and output parameters in the present study

| متغیرها | واحد | مقدار حداقل | مقدار حداکثر | میانگین | انحراف S.D. ¹ |
|--------------------------------------|------|-------------|--------------|---------|--------------------------|
| (d) عمق موثر | mm | ۲۱۶ | ۸۰۱ | ۴۲۰/۸ | ۱۰۸/۴۶ |
| (b) عرض جان تیر | mm | ۷۶ | ۳۰۵ | ۱۳۴/۲ | ۴۸/۹۵ |
| (f_c') مقاومت فشاری بتن | MPa | ۱۳/۸۰ | ۷۳/۶۰ | ۳۲/۳۵ | ۱۵/۹۳ |
| (a/d) نسبت دهانه برش به عمق موثر | - | ۰/۲۷ | ۲/۷۰ | ۱/۲۲ | ۰/۵۳ |
| (ρ) نسبت میلگردهای اصلی | % | ۰/۵۲ | ۴/۰۸ | ۱/۸۱ | ۰/۷۰ |
| (ρ_h) نسبت میلگرد برشی افقی | % | ۰/۰۰ | ۲/۴۷ | ۰/۳۲ | ۰/۴۵ |
| (ρ_v) نسبت میلگرد برشی عمودی | % | ۰/۰۰ | ۲/۶۵ | ۰/۵۴ | ۰/۶۶ |
| (V/bd) مقاومت برشی نهایی | MPa | ۱/۷۳ | ۱۳/۲۵ | ۵/۳۷ | ۲/۱۵ |

مستقیم w از رابطه (۹) غیرممکن است. بنابراین، راه حل‌های رگرسیون WLS-SVM با ساختن یک تابع لاگرانژی به دست می‌آید که در رابطه‌ی (۱۱) نشان داده شده است:

$$L(w, b, e_i, x) = j(w, e) - \sum_{i=1}^N \alpha_i (w^T \phi(x_i) + b + e_i - y_i) \quad (11)$$

که در آن α_i ضرایب لاگرانژی است. شرایط بهینه توسط رابطه (۱۲) تعیین می‌شود:

$$\frac{\partial L}{\partial w} = 0, \frac{\partial L}{\partial b} = 0, \frac{\partial L}{\partial e_i} = 0, \dots, \frac{\partial L}{\partial \alpha_i} = 0 \quad (12)$$

که همراه با حذف w و e نتیجه آن در سیستم کاروس-کوهن-تاگر (KKT)^۱ به ترتیب زیر خواهد بود:

$$\begin{aligned} \text{Minimize : } J(w, e) &= \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^N \bar{v}_i e_i^2 \\ \text{subjected to : } y_i &= w^T \phi(x_i) + b + e_i \\ i &= 1, 2, \dots, N \end{aligned} \quad (9)$$

که در آن $\phi(0): R^d \rightarrow R^{\bar{d}}$ اپراتوری است که فضای داده‌های ورودی را به فضایی با ابعاد بالاتر نگاشت می‌نماید. $w \in R^d$ ارائه دهنده تابع وزن برای فضای وزن اولیه است. $b \in R$ و $e_i \in R$ به ترتیب ارائه دهنده متغیرهای خطا و یک ترم یک طرفه هستند. در فضای وزن اولیه، روش WLS-SVM با مسئله بهینه‌سازی (رابطه ۹) و آموزش به صورت زیر بیان شده است:

$$y(x) = w^T \phi(x) + b \quad (10)$$

به طور کلی ساختار تابع $\phi(x)$ ناشناخته است. همچنین محاسبه این تابع در فضای مشخصه آن بسیار پیچیده است. از این رو، محاسبه غیر

1 Karush-Kohn-Tucker

در نتیجه روش WLS-SVM به ترتیب زیر به دست می‌آید:

$$y(x) = \sum_{i=1}^N \alpha_i K(x_i, x) + b \quad (18)$$

تابع $K(x_i, \bar{x}_j)$ در واقع یک تابع در فضای اولیه است که به صورت ضرب داخلی دو بردار در فضای ویژگی بیان می‌شود. به جهت معادل‌سازی تابع $K(x_i, \bar{x}_j)$ با ضرب داخلی دو بردار در فضای ویژگی، بایستی یک تابع $K(x_i, \bar{x}_j)$ معین مثبت متقارن شود که در شرط مرسر صدق نماید. ماشین بردار پشتیبان معمولاً با سه تابع کرنل پایه شعاع گاوسی RBF، چند جمله‌ای و تابع کرنل خطی مورد استفاده قرار می‌گیرد. در روش WLS-SVM، معمولاً از تابع پایه شعاع گاوسی RBF، به عنوان تابع کرنل که به صورت زیر فرمول‌بندی شده است، استفاده می‌شود [۱۵]:

$$K_{RBF}(x, \bar{x}) = \exp\left(-\frac{\|x - \bar{x}\|^2}{\sigma^2}\right) \quad (19)$$

که در آن σ^2 یک ثابت حقیقی و مثبت است و معمولاً عرض کرنل نامیده می‌شود. ساختار WLS-SVM در شکل ۲ نشان داده شده است.

۵- پردازش داده‌ها

به منظور نرمال‌سازی داده‌های مربوط به پارامترهای مختلف ورودی و پارامتر خروجی، از رابطه (۲۰) استفاده شده است. عملیات نرمال‌سازی بایستی قبل از بسیاری از روش‌های داده‌کاوی مانند شبکه‌های عصبی، SVM و K Means انجام شود. نرمال‌سازی باعث می‌شود که تمامی پارامترهای ورودی به صورت یکسان توسط روش بررسی شوند و تأثیر یکی از پارامترهای ورودی بیشتر از سایر پارامترها نباشد.

$$x_i^n = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (20)$$

در رابطه فوق، x_i داده‌های مورد استفاده، x_{\min} کمترین مقدار x ، x_{\max} بیشترین مقدار x در کل مجموعه داده‌ها و x_i^n به مقدار نرمال شده داده‌ها اشاره دارند.

$$\begin{bmatrix} \Omega + V_Y & I_N^T \\ I_n & 0 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} y \\ 0 \end{bmatrix} \quad (13)$$

که در آن:

$$V_Y = \text{diag} \left\{ \frac{1}{\gamma \bar{v}_1}, \dots, \frac{1}{\gamma \bar{v}_N} \right\} \quad (14)$$

$$\Omega_{i,j} = \langle \phi(x_i), \phi(x_j) \rangle_H, \\ i, j = 1, 2, \dots, N$$

$$y = [y_1, \dots, y_N]^T; I_N^T [1, \dots, 1]; \\ \alpha = [\alpha_1, \dots, \alpha_N] \quad (15)$$

فاکتورهای وزن \bar{v}_N توسط ویدودو و یانگ^۱ به صورت زیر داده شده است [۳۴]:

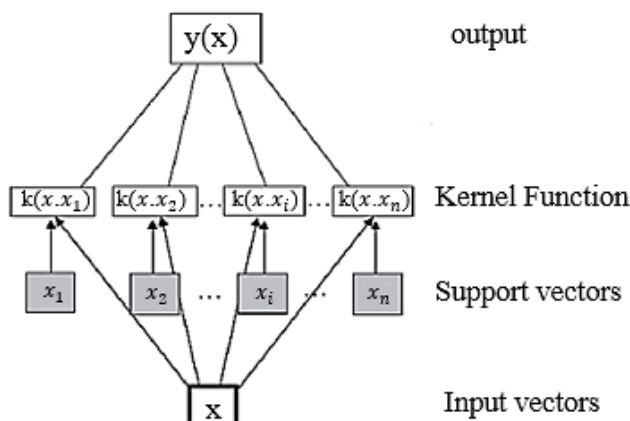
$$\bar{v}_k = \begin{cases} 1 & \text{if } \left| \frac{e_i}{\hat{s}} \right| \leq c_1 \\ \frac{c_2 - \left| \frac{e_i}{\hat{s}} \right|}{c_2 - c_1}, & \text{if } c_1 \leq \left| \frac{e_i}{\hat{s}} \right| \leq c_2 \\ 10^{-4} & \text{otherwise} \end{cases} \quad (16)$$

که در آن \hat{s} یک تخمین قوی از انحراف معیار متغیرهای خطا در متغیرهای $\left(e_i = \frac{a_i}{D_{ii}^{-1}} \right)$ است. ثابت‌های c_1 و c_2 به ترتیب برابر با ۲/۵ و ۳ در نظر گرفته می‌شوند. D_{ij}^{-1} به i امین المان قطری اولیه ماتریس معکوس D دلالت دارد که همان ماتریس سمت چپ در رابطه (۱۳) است. بر اساس تئوری مرسر^۲، کرنل $K(\cdot, \cdot)$ ، به طوری انتخاب می‌شود که:

$$K(x_i, \bar{x}_j) = \langle \phi(x_i), \phi(x_j) \rangle_H; \\ i, j = 1, 2, \dots, N \quad (17)$$

1 Widodo and Yang

2 Mercers



شکل ۲. ساختار روش WLS-SVM
 Fig. 2. Structure of WLS-SVM method

جدول ۲. تنظیم پارامترهای کنترل اولیه

Table 2. Adjust the initial control parameters

| نماد | کران پایین | کران بالا | مرجع | پارامترها |
|-------------------|------------|-----------|-----------|---------------------------------|
| C | 10^{-5} | 10^5 | [۲۱] | پارامتر تنظیم در روش SVM |
| γ_1 | 10^{-5} | 10^5 | [۲۱] | پارامتر کرنل RBF در روش SVM |
| γ_2 | 10^{-5} | 10^5 | [۲۱ و ۱۸] | پارامتر تنظیم در روش WLS-SVM |
| σ^2 | 10^{-5} | 10^5 | [۲۱ و ۱۸] | پارامتر کرنل RBF در روش WLS-SVM |
| (α, β) | ۰ | ۱ | | ضرایب یادگیری جمعی |

۵-۲- ارزیابی روش WLS-SVM با استفاده از k-fold
 برای پیش‌بینی مدل نیاز است که داده‌ها به دو دسته آموزش و صحت‌سنجی تقسیم شوند. روش‌های ساده‌ای برای تقسیم داده‌ها به دو دسته آموزش و صحت‌سنجی وجود دارد. در این روش‌ها کارایی مدل به خوبی نشان داده نمی‌شود. زیرا هر یک از آن‌ها به این مسئله که کدام داده‌ها برای آموزش و کدام داده‌ها برای تست انتخاب شوند بسیار وابستگی دارند. همین

۵-۱- پارامترهای اولیه
 قبل از آغاز حلقه جستجو در درون دامنه‌های از پیش تعریف شده، شش پارامتر $(C, \gamma_1, \gamma_2, \sigma^2, \alpha \text{ and } \beta)$ را باید به عنوان پارامترهای اولیه تقریب زد. تنظیم پارامترها در روش‌های مختلف ماشین بردار پشتیبان به طور مؤثر باعث بهبود کارایی مدل می‌شود. جدول ۲ محدوده ای برای هر یک از این پارامترها ارائه می‌دهد [۲۱-۱۷].

ضریب تعیین (R^2)، درصد میانگین خطای مطلق ($MAPE^1$)، میانگین خطای مطلق (MAE^2) و ریشه میانگین-مربع خطا ($RMSE$) که خطای اعتبارسنجی متوسط را نشان می‌دهد، مقایسه شد. هر چه ضرایب R^2 و R به ۱ نزدیک‌تر باشند، مقادیر پیش‌بینی شده به مقادیر واقعی نزدیک‌تر خواهند بود. به طور مشابه، مقادیر نسبتاً کم، برای ضرایب MAE ، $MAPE$ و $RMSE$ حاکی از دقت بالا در نتایجی است که روش WLS-SVM پیش‌بینی می‌کند. معادلات (۲۱) - (۲۵) فرمول ریاضی معیارهای ارزیابی عملکرد پیشنهادی را نشان می‌دهند:

$$RMSE = \sqrt{\left[\left(\frac{1}{n} \right) \times \sum_{i=1}^n [p_i - y_i]^2 \right]} \quad (21)$$

$$MAE = \left(\frac{1}{n} \right) \times \sum_{i=1}^n (|p_i - y_i|) \quad (22)$$

$$MAPE = \left(\frac{1}{n} \right) \times \sum_{i=1}^n (|p_i - y_i| / y_i) \times 100 \quad (23)$$

$$R = \frac{n \sum y_i \times p_i - (\sum y_i)(\sum p_i)}{\sqrt{(n(\sum y_i^2) - (\sum y_i)^2) \times (n(\sum p_i^2) - (\sum p_i)^2)}} \quad (24)$$

$$R^2 = \left(\frac{n \sum y_i \times p_i - (\sum y_i)(\sum p_i)}{\sqrt{(n(\sum y_i^2) - (\sum y_i)^2) \times (n(\sum p_i^2) - (\sum p_i)^2)}} \right)^2 \quad (25)$$

که p_i مقدار پیش‌بینی شده و y_i مقدار واقعی و n اندازه نمونه است. هیستوگرام متغیرهای ورودی در شکل ۳ و هیستوگرام متغیر خروجی در شکل ۴ نشان داده شده است.

۶- نتایج

در این مطالعه، مجموعه داده‌ها با استفاده از اعتبارسنجی متقاطع k -fold ($k=3$) به صورت تصادفی برای آموزش و صحت‌سنجی تقسیم شده است. جهت ساخت مدل پیش‌بینی مقاومت برشی تیرهای عمیق بتن مسلح با استفاده از روش WLS-SVM، از یک بخش آموزشی و یک بخش صحت‌سنجی استفاده شد. داده‌های موجود در بخش صحت‌سنجی برای

وابستگی باعث می‌شود گاهی دقت مدل بالاتر و گاهی دقت آن پایینتر باشد. برای رفع این مشکل و بیان دقیق‌تر کارایی مدل پیشنهاد شده در این تحقیق از روش اعتبارسنجی k -fold که معمولاً در بسیاری از مطالعات استفاده می‌شود، بهره‌گیری شده است [۳۵]. اعتبارسنجی ضربدری k -fold یکی از عمومی‌ترین انواع اعتبارسنجی ضربدری است که به صورت بسیار گسترده در هوش مصنوعی استفاده می‌شود. در این نوع اعتبارسنجی تعداد تقسیم‌ها، معمولاً متناسب با تعداد نقاط داده‌ها هستند. در انتخاب تعداد برابر با k ، باید اطمینان حاصل شود که تعداد نقاط داده‌ها در زیر مجموعه آموزش و زیر مجموعه صحت‌سنجی، حاوی تنوع متناسب بوده و همان توزیع را نشان دهند. در این مطالعه، از ۶۷٪ داده‌ها به عنوان نسبت زیر مجموعه آموزش و ۳۳٪ برای زیر مجموعه صحت‌سنجی استفاده شده است که می‌توان با اجرای روش اعتبارسنجی سه‌گانه این اعداد را به دست آورد تا اطمینان حاصل شود که تمامی زیر مجموعه‌ها از توزیع یکسانی برخوردار است. با استفاده از رویکرد اعتبارسنجی متقابل، داده‌های آموزش به صورت تصادفی به سه زیر مجموعه متقابل منحصر به فرد گروه‌بندی شدند. در هر تکرار، از یک زیر مجموعه برای فرآیند اعتبارسنجی و دو زیر مجموعه دیگر برای فرآیند آموزش استفاده شد. به این ترتیب، این مطالعه اطمینان حاصل می‌نماید که هر مجموعه داده حداقل یک بار در هر دو مرحله آموزش و صحت‌سنجی استفاده می‌شود. از آنجا که در مطالعه حاضر از روش اعتبارسنجی متقاطع سه برابر ($k=3$) استفاده شده است، هر مجموعه در فرآیند بهینه‌سازی پارامتر، سه بار آموزش داده می‌شود. به این ترتیب، سه مقدار مختلف از میانگین خطای اعتبارسنجی برای تابع هدف به دست خواهد آمد. به این ترتیب، میانگین نتایج حاصل از این سه زیر مجموعه نشان دهنده یک روش مفید برای پیش‌بینی عملکرد کلی در روش WLS-SVM است.

۵-۳- پیش‌بینی با روش WLS-SVM

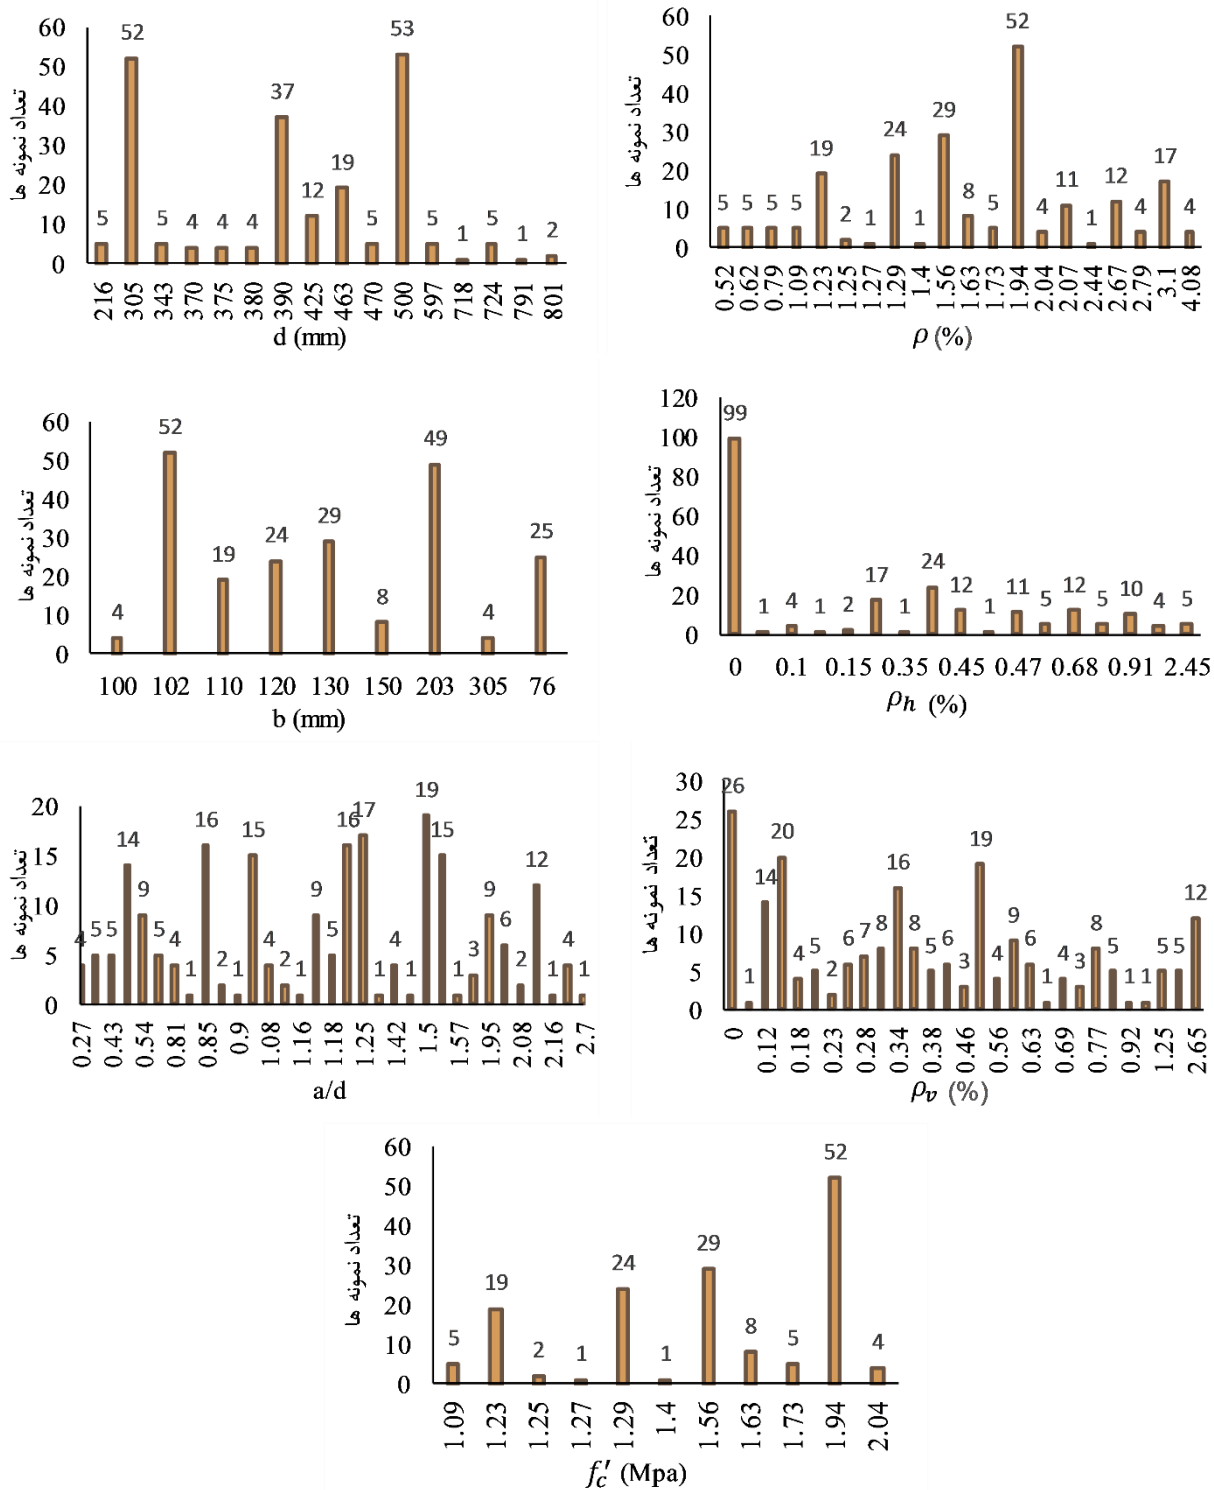
در این مرحله، روش WLS-SVM برای پیش‌بینی، فرآیند آموزشی خود را با استفاده از مقادیر اولیه $(C, \gamma_1, \gamma_2, \sigma^2)$ آغاز نموده و سپس اعتبارسنجی مدل ساخته شده با استفاده از داده‌های صحت‌سنجی، انجام می‌شود. این نکته حائز اهمیت است که برای دستیابی به بیشترین دقت تخمین، داده‌ها پردازش می‌شوند.

۵-۴- شاخصه‌های کارکرد

عملکرد روش WLS-SVM با استفاده از ضریب همبستگی (R)


1 Mean Absolute Percentage Error

2 Mean Absolute Error




شکل ۳. هیستوگرام متغیرهای ورودی

Fig. 3. Histogram of the input variables



شکل ۴. هیستوگرام متغیرهای خروجی

Fig. 4. Histogram of the output variables



شکل ۵. فرآیند تنظیم و همگرایی پارامترها

Fig. 5. The process of adjusting and the convergence of parameters

، بایستی مناسب‌ترین مقادیر برای پارامتر تنظیم (γ_2) و پارامتر کرنل $RBF(\sigma_2)$ ، تعیین شود. در این مطالعه، با استفاده از فرآیند سعی و خطا، بهترین مقدار پارامترهای تنظیم‌کننده در روش WLS-SVM مشخص شد. جدول ۳ مقادیر بهینه پارامترهای تنظیم‌کننده در روش WLS-SVM را نشان می‌دهد. در شکل ۵ عملکرد آموزش مدل با استفاده از روش WLS-SVM بر اساس پارامترهای تنظیم‌کننده نشان داده شده است. با توجه به شاخصه‌های کارکرد (ضرایب R^2 ، R ، MAE ، $MAPE$)، می‌توان مشاهده نمود که روش WLS-SVM مقادیری نزدیک به عدد ۱ برای ضرایب R و R^2 همچنین مقادیری نزدیک به عدد

آزمایش مدل آموزش داده شده و استقرار یافته استفاده شده است. در مجموع با استفاده از اعتبارسنجی متقاطع k-fold با $k=3$ ، تعداد ۱۷۱ داده که به صورت تصادفی انتخاب شده‌اند، به عنوان بخش آموزشی و ۴۳ داده برای صحت‌سنجی استفاده شد. بخش آموزش نیز به دو مجموعه زیر داده تقسیم می‌شود. مجموعه آموزش در درجه اول برای متناسب سازی مدل استفاده خواهد شد. مجموعه صحت‌سنجی نیز جهت اعتبارسنجی عملکرد آموزش قبلی و تنظیم دقیق مدل آموزش دیده استفاده می‌شود.


۶-۱ فاز آموزش و انتخاب پارامترها

برای دستیابی به بیشترین بازده با استفاده از روش WLS-SVM

جدول ۳. پارامترهای تنظیم کننده به دست آمده برای روش WLS-SVM در فاز آموزش

Table 3. The obtained adjusting parameters for WLS-SVM method in training phase

| WLS-SVM | | |
|----------------------------|------------|------------|
| پارامترها | γ_2 | σ_2 |
| مقدار انتخاب شده در مطالعه | ۵/۱۲۹۲ | ۳/۱۰۳۶ |




شکل ۶. مقایسه نتایج به دست آمده برای شاخصه‌های کارکرد (ضرایب R^2 , MAPE, MAE, RMSE) در اجراهای مختلف

Fig. 6. Comparison of results obtained for performance indicators (coefficients R^2 , MAPE, MAE, RMSE) in different executions

۶-۲- فاز صحت‌سنجی و نتایج حاصل از پیش‌بینی مدل با استفاده از پارامترهای تنظیم کننده در جدول ۳ و مدل آموزش دیده، نتایج روش WLS-SVM در فاز آموزش و صحت‌سنجی به ترتیب در شکل ۷-الف و ۷-ب نشان داده شده است. نتایج نشان می‌دهند که روش WLS-SVM با مقدار $R^2 = ۰/۹۷۱۶$ در مرحله آزمایش و مقدار $R^2 = ۰/۹۸۸۷$ در مرحله صحت‌سنجی ($R^2 \geq ۰/۹۵$) نتایج بسیار خوبی را برای مدل آموزش دیده به دست آورده است. این موضوع بیانگر این است که روش WLS-SVM در پیش‌بینی مقاومت برشی تیرهای عمیق بتن مسلح از دقت بسیار بالایی برخوردار است. همچنین به دلیل

صفر را برای ضرایب MAPE، RMSE و MAE تولید کرده است. بنابراین، پارامترهای تنظیم کننده بهینه و مدل، آماده پیش‌بینی مجموعه داده آزمایش جدید هستند. شکل ۶ مقایسه میان تعداد اجراهای مختلف روش WLS-SVM و نتایج به دست آمده از پارامترهای آماری را نشان می‌دهد. با توجه به شکل، می‌توان مشاهده نمود که در اجرای نوزدهم ضرایب MAPE، MAE و RMSE مقادیر کمتری نسبت به سایر اجراها دارند. همچنین در این اجرا ضرایب R^2 و R نسبت به سایر اجراها به عدد ۱ نزدیک‌تر هستند.



شکل ۷. مقایسه ظرفیت برشی پیش‌بینی شده در مطالعه حاضر با مقادیر ظرفیت برشی آزمایشگاهی (الف) نتایج حاصل از فاز آموزش داده‌ها (ب) نتایج حاصل از فاز صحت‌سنجی داده‌ها

Fig. 7. Comparison of the predicted shear capacity in the present study with Experimental shear capacity, (a) Results obtained from the training phase of data (b) Results obtained from the validation phase of data

نشان می‌دهد. نتایج نشان می‌دهند که روش پیشنهادی WLS-SVM به مطلوب‌ترین مقادیر برای $R^2 = 0.9887$ ، $RMSE = 0.107$ MPa، $MAE = 0.478$ MPa و $MAPE = 9.48\%$ می‌رسد. همچنین با توجه به جدول ۴، می‌توان دریافت که روش WLS-SVM نسبت به سایر روش‌های مقایسه‌ای هوش مصنوعی از نتایج بهتری برخوردار است. مقایسه نتایج به دست آمده از روش WLS-SVM، آیین‌نامه‌های CSA و ACI و همچنین نتایج حاصل از الگوریتم جستجوی گرانشی (GSA^۳) که یک الگوریتم بهینه‌سازی مبتنی بر قانون گرانش و برهم کنش‌های انبوه است، در جدول ۵ نشان داده شده است.

۷- نتیجه‌گیری

در این مطالعه از یک روش جدید هوش مصنوعی به نام WLS-SVM برای پیش‌بینی مقاومت برشی تیرهای عمیق بتن مسلح استفاده شد. برای این منظور در ابتدا به جمع‌آوری مقادیر پارامترهای موثر بر مقاومت برشی پرداخته و تعداد ۲۱۴ داده آزمایشگاهی انتخاب شدند. با استفاده از هشت پارامتر ورودی مختلف در روش WLS-SVM مقادیر ضرایب R^2 ، $RMSE$ ، $MAPE$ و MAE برای این روش محاسبه شد. این مطالعه نشان داد که روش WLS-SVM به عنوان یک ابزار محاسباتی قدرتمند مطرح بوده و می‌تواند به منظور تجزیه و تحلیل روابط پیچیده بین پارامترهای

پایین بودن ضریب MAPE و نزدیکی این ضریب به عدد صفر، مقاومت برشی پیش‌بینی شده با استفاده از روش WLS-SVM قابل اعتماد است. بنابراین، این روش برای طراحی و پیش‌بینی مقاومت برشی تیرهای عمیق بتن مسلح قابل قبول خواهد بود. علاوه بر این، نتایج آماری نشان می‌دهد که روش پیشنهادی WLS-SVM می‌تواند با دستیابی به اختلافات جزئی بین مقادیر ارزیابی عملکرد در مراحل آموزش و تست، از بروز مشکلات عمده جلوگیری نماید.

۶-۳- مقایسه روش WLS-SVM با سایر روش‌های هوش مصنوعی برای ارزیابی بهتر قابلیت روش WLS-SVM، عملکرد این روش با سایر روش‌های هوش مصنوعی مقایسه شد. این روش‌ها عبارتند از: (۱) روش SVM بدون در نظر گرفتن پارامترهای تنظیم کننده، (۲) روش LS-SVM بدون در نظر گرفتن پارامترهای تنظیم کننده، (۳) روش SVM با استفاده از بهینه‌ساز SOS^۱، (۴) روش LS-SVM با استفاده از بهینه‌ساز SOS، (۵) روش رگرسیون خطی چندگانه (Tree MLR-Reg)^۲، و (۶) روش ترکیبی SVM و حالت خطی SVM بدون در نظر گرفتن پارامترهای تنظیم کننده (SVM-LSVM)^[۱۷]. جدول ۴ نتایج حاصل از روش‌های مورد مقایسه را با توجه به مقادیر متوسط و انحراف استاندارد

1 Symbiotic organisms search
2 Multiple Linear Regression

3 Gravitational Search Algorithm

جدول ۴. مقایسه نتایج به دست آمده از روش WLS-SVM با سایر روش‌های هوش مصنوعی

Table 4. Comparison of WLS-SVM results with other artificial intelligence methods

| نتایج حاصل از صحت‌سنجی | | | | | | روش‌ها |
|------------------------|-----------|----------|---------|--------|----------------|------------------|
| مرجع | RMSE(MPa) | MAE(MPa) | MAPE(%) | R | R ² | |
| [۱۷] | ۱/۲۱۶۷ | ۰/۹۰۴۰ | ۱۶/۵۱ | ۰/۸۷۱۷ | ۰/۷۵۹۸ | SVM |
| [۱۷] | ۰/۷۳۶۰ | ۰/۵۶۶۹ | ۱۲/۲۷ | ۰/۹۲۷۱ | ۰/۸۵۲۵ | LS-SVM |
| [۱۷] | ۰/۵۵۰۸ | ۰/۴۰۳۵ | ۸/۲۶ | ۰/۹۵۸۶ | ۰/۹۱۸۹ | Optimized SVM |
| [۱۷] | ۰/۵۵۱۴ | ۰/۴۰۸۴ | ۸/۰۹ | ۰/۹۵۸۶ | ۰/۹۱۸۹ | Optimized LS-SVM |
| [۱۷] | ۰/۶۷۹۹ | ۰/۵۱۵۰ | ۱۰/۰۰ | ۰/۹۶۳۶ | ۰/۹۲۸۵ | MLR-Reg Tree |
| [۱۷] | ۰/۷۸۱۲ | ۰/۵۹۴۰ | ۱۱/۳۱ | ۰/۹۱۵۶ | ۰/۸۳۸۳ | SVM-LSVM |
| مطالعه حاضر | ۰/۱۰۷ | ۰/۴۷۸ | ۹/۴۸ | ۰/۹۹۴۵ | ۰/۹۸۸۷ | WLS-SVM |

جدول ۵. مقایسه نتایج پیش‌بینی به دست آمده از روش WLS-SVM با نتایج موجود در آیین‌نامه‌های مختلف و الگوریتم GSA

Table 5. Comparison of prediction results obtained from WLS-SVM method with the results in different cods and GSA algorithm

| مرجع | MAE(MPa) | MAPE(%) | Vactual / Vpredicted | روش‌ها |
|-------------|----------|---------|----------------------|-----------|
| [۲۳] | ۱/۲۲۲۵ | ۱۶/۲۱ | ۰/۵۷۱ | ACI318-11 |
| [۲۴] | ۰/۸۲۵ | ۱۸/۹۱ | ۰/۵۷۴ | CSA |
| [۱] | ۰/۵۰۶ | ۱۰/۸۷ | ۰/۱۴۷ | GSA |
| مطالعه حاضر | ۰/۴۷۸ | ۹/۴۸ | ۰/۹۹۸ | WLS-SVM |

| | |
|------------|---------------------------------|
| β | ضریب یادگیری جمعی |
| α_i | ضرایب لاگرانژی |
| γ_1 | پارامتر کرنل RBF در روش SVM |
| γ_2 | پارامتر کرنل RBF در روش WLS-SVM |
| ρ_v | نسبت میلگردهای برشی |
| ρ_w | نسبت میلگردهای طولی |
| σ^2 | عرض کرنل |

منابع

- [1] A.H. Gandomi, G.J. Yun, A.H. Alavi, An evolutionary approach for modeling of shear strength of RC deep beams, *Materials and Structures*, 46(12), (2013), 2109-2119.
- [2] D. Tien Bui, V.H. Nhu, N.D. Hoang, Prediction of soil compression coefficient for urban housing project using novel integration machine learning approach of swarm intelligence and Multi-layer Perceptron Neural Network, *Advanced Engineering Informatics*, 38, (2018), 593-604.
- [3] S. Moosazadeh, E. Namazi, H. Aghababaei, A. Marto, H. Mohamad, M. Hajihassani, Prediction of building damage induced by tunnelling through an optimized artificial neural network, *Engineering with Computers*, 35, (2018), 579-591.
- [4] S.V. Alavi Nezhad Khalil Abad, M. Yilmaz, D. Jahed Armaghani, A. Tugrul, Prediction of the durability of limestone aggregates using computational techniques, *Neural Computing and Applications*, 29(2), (2016), 423-433, 2016.
- [5] P.G. Asteris, M. Nikoo, Artificial bee colony-based neural network for the prediction of the fundamental period of infilled frame structures, *Neural Computing and Applications*, 31(9), (2019), 4837-4847.
- [6] J.S. Chou, A.D. Pham, Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength, *Construction and Building Materials*, 49,(2013), 554-563.
- [7] T. Hancock, R. Put, D. Coomans, Y. Vander Heyden, Y. Everingham, A performance comparison of modern

مختلف در پیش‌بینی مقاومت برشی تیرهای عمیق بتن مسلح مورد استفاده قرار گیرد. مقایسه‌ی نتایج به دست آمده از این روش با سایر روش‌های هوش مصنوعی و همچنین آیین‌نامه‌های مختلف نشان می‌دهند دقت روش WLS-SVM با ریشه دوم میانگین مربعات خطا $RMSE = 0.107$ ، ضریب تعیین $R^2 = 0.9887$ ، درصد میانگین خطای مطلق $MAEP = 9.48\%$ و میانگین خطای مطلق $MAE = 0.478$ به مراتب بسیار بالاتر از سایر روش‌های هوش مصنوعی و آیین‌نامه‌های موجود می‌باشد. این مطالعه نشان می‌دهد که روش WLS-SVM با عملکردی مناسب به لحاظ دقت می‌تواند به عنوان یک روش جایگزین برای پیش‌بینی مقاومت برشی در تیرهای عمیق بتن مسلح با سایر روش‌های هوش مصنوعی و آیین‌نامه‌های مختلف، مورد استفاده قرار گیرد. در نهایت، می‌توان نتیجه گرفت که روش WLS-SVM این مزیت را دارد که به راحتی در معماری‌های موازی قابل اجرا می‌باشد و در این روش زمان پردازش داده‌ها در مقایسه با سایر روش‌ها، با دستیابی به نتایج مشابه، به شدت کاهش می‌یابد.

۸- فهرست علائم

علائم انگلیسی

| | |
|-----------|-------------------------------------------------------------------|
| A_v | مساحت میلگردهای برشی عمود بر آرماتور خمش طولی، m^2 |
| $A_{v/h}$ | مساحت میلگردهای برشی موازی با آرماتور خمش طولی، m^2 |
| b_w | عرض تیر، m |
| C | پارامتر تنظیم |
| d | عمق موثر تیر، m |
| e_i | متغیرهای خطا |
| f_y | تنش تسلیم خاموت‌ها، MPa |
| L_n | طول موثر تیر، m |
| M_u | ممان خمشی در مقطع بحرانی، N.m |
| V_c | مقاومت برشی به دست آمده از سهم بتن، N |
| V_n | مقاومت برشی اسمی تیر عمیق، N |
| V_s | مقاومت برشی به دست آمده از سهم میلگردها، N |
| V_u | نیروی برشی، N |
| w | تابع وزن |
| f'_c | مقاومت فشاری ۲۸ روزه نمونه بتن سیلندری 15×30 آمریکا، MPa |

علائم یونانی

α ضریب یادگیری جمعی

- squares support vector machines inference model and artificial bee colony optimization, *Landslides*, 14(2), (2016), 447–458.
- [17] D. Prayogo, M.Y. Cheng, J. Widjaja, H. Ongkowijoyo, H. Prayogo, Prediction of concrete compressive strength from early age test result using an advanced metaheuristic-based machine learning technique, international symposium on automation and robotics in construction, (2017), 856–863.
- [18] M.Y. Cheng, D. Prayogo, Y.W. Wu, Prediction of permanent deformation in asphalt pavements using a novel symbiotic organisms search–least squares support vector regression, *Neural Computing and Applications*, 31(10), (2018), 6261.6273.
- [19] I. Aljarah, A.M. Al-Zoubi, H. Faris, M.A. Hassonah, S. Mirjalili, H. Saadeh, Simultaneous feature selection and support vector machine optimization using the grasshopper optimization algorithm, *Cognitive Computation*, 10(3), (2018), 478–495.
- [20] H. Faris, M.A. Hassonah, A.M. Al-Zoubi, S. Mirjalili, I. Aljarah, A multi-verse optimizer approach for feature selection and optimizing SVM parameters based on a robust system architecture, *Neural Computing and Applications*, 30(8), (2017), 2355–2369.
- [21] N.D. Hoang, A.D. Pham, Hybrid artificial intelligence approach based on metaheuristic and machine learning for slope stability assessment: A multinational data analysis, *Expert Systems with Applications*, 46, (2016), 60–68,
- [22] J.A. Suykens, J. De Brabanter, L. Lukas, J. Vandewalle, Weighted least squares support vector machines: robustness and sparse approximation, *Neurocomput*, 48(1), (2002), 85-105.
- [23] ACI-318, ACIC 318-11: Building Code Requirements for Structural Concrete and Commentary. American Concrete Institute, 2011.
- [24] Canadian Standards Association (CSA), Design of concrete structures: Structures (design)—a national standard of Canada. CAN-A23.3-94, Clause 11.1.2, statistical techniques for molecular descriptor selection and retention prediction in chromatographic QSRR studies, *Chemometrics and Intelligent Laboratory Systems*, 76(2), (2005), 185–196.
- [8] V.N. Vapnik, *The nature of statistical learning theory*, Springer, New York, 1995.
- [9] R. Chen, P. Zhang, H. Wu, Prediction of shield tunneling induced ground settlement using machine learning techniques, *Frontiers of Structural and Civil Engineering*, 13(6), (2019), 1363-1378.
- [10] Z. Liu, D. Wu, Y. Liu, Z. Han, L. Lun, J. Gao, G. Jand, G. Cao, Accuracy analyses and model comparison of machine learning adopted in building energy consumption prediction, *Energy Exploration & Exploitation*, 37(4), (2019), 1426-1451.
- [11] E. Acar, M. Rais-Rohani, Ensemble of metamodells with optimized weight factors, *Structural and Multidisciplinary Optimization*, 37(3), (2008), 279–294.
- [12] J.S. Chou, K.H. Yang, J.Y. Lin, Peak shear strength of discrete fiber-reinforced soils computed by machine learning and metaensemble methods, *Journal of Computing in Civil Engineering*, 30(6), (2016).
- [13] N.D. Hoang, X.L. Tran, H. Nguyen, Predicting ultimate bond strength of corroded reinforcement and surrounding concrete using a metaheuristic optimized least squares support vector regression model, *Neural Computing and Applications*, (2019), 1-21.
- [14] M. Khatibinia, M. Araghi, Modeling of flow number of asphalt mixtures using a multi-kernal based support vector machine approach, *International Journal of Optimization in Civil Engineering*, 9(2), (2019), 233-250.
- [15] J.A.K. Suykens, T.V. Gestel, J.D. Brabanter, B.D. Moor, J. Vandewalle, *Least squares support vector machines*, World Scientific Publishing Company, Singapore, 2002.
- [16] D. Tien Bui, T.A. Tuan, N.D. Hoang, N.Q. Thanh, D.B. Nguyen, N. Van Liem, B. Pradhan, Spatial prediction of rainfall-induced landslides for the Lao Cai area (Vietnam) using a hybrid intelligent approach of least

- design procedures for shear strength of deep reinforced concrete beams , ACI Structural Journal, 99(4), (2002), 539–548.
- [32] C.G. Quintero-Febres, G. Parra-Montesinos, J.K. Wight, Strength of struts in deep concrete members designed using strut and tie method, ACI Structural Journal, 103(4), (2006), 577–586.
- [33] H. Li, Z. Lü, Z. Yue, Support vector machine for structural reliability analysis, Applied Mathematics and Mechanics, 27(10), (2006), 1295–1303.
- [34] A. Widodo, B. Yang, Wavelet support vector machine for induction machine fault diagnosis based on transient current signal, Expert Systems with Applications, 35(1-2), (2008), 307–316, 2008.
- [35] N.D. Hoang, D. Tien Bui, K.W. Liao, Groutability estimation of grouting processes with cement grouts using Differential Flower Pollination Optimized Support Vector Machine, Applied Soft Computing, 45, (2016), 173–186.
- Toronto, 1994.
- [25] A.P. Clark, Diagonal tension in reinforced concrete beams, ACI Journal, 48(10), (1951), 145–156.
- [26] F.K. Kong, P.J. Robins, D.F. Cole, Web reinforcement effects on deep beams, ACI Journal, 67(12), (1970), 1010–1018.
- [27] K.N. Smith, A.S. Vantsiotis, Shear strength of deep beams, ACI Journal, 79(3), (1982), 201–213.
- [28] N.S. Anderson, J.A. Ramirez, Detailing of stirrup reinforcement, ACI Structural Journal, 86(5), (1989), 507–515.
- [29] K.H. Tan, F.K. Kong, S. Teng, L. Guan, High-strength concrete deep beams with effective span and shear span variations, ACI Journal, 92(4), (1995), 392-405.
- [30] J.K. Oh, S.W. Shin, Shear strength of reinforced highstrength concrete deep beams, ACI Structural Journal, 98(2), (2001), 164–173.
- [31] G. Aguilar, A.B. Matamoros, G.J. Parra-Montesinos, J.A. Ramirez, J.K. Wight, Experimental evaluation of

چگونه به این مقاله ارجاع دهیم

M. R. Mohammadzadeh, F. Esfandnia, Prediction of shear strength of deep beams of the reinforced concrete using weighted least squares support vector machine method, Amirkabir J. Civil Eng., 53(9) (2021) 3867-3882.

DOI: 10.22060/ceej.2020.18122.6775

