



Prediction of shear strength of deep beams of the reinforced concrete using weighted least squares support vector machine method

M. R. Mohammadizadeh*, F. Esfandnia

Department of Civil Engineering, Faculty of Technical and Engineering, University of Hormozgan, Bandar Abbas, Iran

ABSTRACT: The shear strength of deep reinforced concrete beams depends on the mechanical and geometrical properties of the beam. Accurate estimation of shear strength in deep reinforced concrete beams is one of the major issues in the design of engineering structures. However, some methods proposed to determine the shear strength in deep reinforced concrete beams do not have high accuracy. One method to accurately estimate shear strength is to use artificial intelligence (AI). Artificial intelligence has many different methods, one of which is the use of artificial intelligence-based on the support vector machine method. In this study, the weighted least squares support vector machine (WLS-SVM), which is a relatively new and efficient method for predicting the shear capacity of reinforced concrete beams, has been used. In this study, a database containing experimental results on deep reinforced concrete beams was first collected. Then, after determining the input and output parameters using a training process in WLS-SVM method and using a part of the collected data, a model was developed to predict the shear strength of deep reinforced concrete beams. In order to determine the accuracy of the WLS-SVM method, the results were compared with those obtained by other AI methods and different regulations. Statistical analysis showed that WLS-SVM has the best performance in terms of statistical evaluation parameters ($R^2 = 0.9887$, $RMSE = 0.107$, $MAE = 0.478$ and $MAPE = 9.48\%$) compared to the other method.

Review History:

Received: Mar. 16, 2020

Revised: Jul. 13, 2020

Accepted: Nov. 02, 2020

Available Online: Nov. 03, 2020

Keywords:

Deep beam of reinforced concrete

Shear strength

Artificial intelligence

Weighted least squares support vector machine

1- Introduction

Reinforced concrete deep beams are often used as structural members and load-distributing elements. It is difficult to create a general model to provide and accurately estimate the shear strength due to the complexity of the shear mechanism of deep reinforced concrete beams and the types of parameters affecting it [1]. In recent decades, artificial intelligence (AI) has been the subject of extensive research in the field of civil engineering. AI successfully simulates complex problems, so it has become a powerful predictive method. The support vector machine (SVM) method is one of the most important methods in the field of artificial intelligence and nonlinear modeling, which in recent years has shown good efficiency compared to older methods such as neural networks for classification and estimation of functions [2]. Studies conducted in civil engineering on machine learning as an advanced modeling tool include the studies of Chou et al., Hoang et al., And Khatibinia and Araghi [3-5]. The least squares support vector machine (LS-SVM) is an extension of SVM that includes several advanced features and its capability has been demonstrated by fast calculations [6]. The weighted least squares vector machine (WLS-SVM) method is the LS-SVM weighted mode. In the present study, the performance of WLS-SVM

is first examined and then the results of the prediction made by this method are evaluated and compared with the results of existing regulations and different methods of artificial intelligence available in the technical literature.

2- Laboratory data

In this study, the data set includes 214 test results of reinforced concrete deep beams. Input variables in WLS-SVM method corresponding to the parameters affecting the shear capacity of deep reinforced concrete beams were selected based on the regulations.

3- Research Methodology

Support vector machines (SVM) belong to the group of supervised models as one of the most powerful methods in machine learning. SVM has two main drawbacks: 1) the inability in exact regulating of kernel parameter and 2) their reliance on backup vectors alone to determine the decision boundary. Suykens et al. [6] solved various problems by introducing weighted least squares support vector machines (WLS-SVM), in which the LS-SVM method was improved by assigning weight to error variables. Considering the training sample data set equal to N , $\{(x_k, y_k)\}_{k=1}^N$ and with input data $x_i \in R^d$ and output data $y_i \in R$, WLS-SVM regression is formulated as an optimization problem in the initial weight space [7]:

*Corresponding author's email: nozar@ssau.ac.ir



$$\text{Minimize : } J(w,e) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^N \bar{v}_i e_i^2 \tag{1}$$

$$\text{subjected to : } y_i = w^T \phi(x_i) + b + e_i$$

$$i = 1, 2, \dots, N$$

Where $\phi(0):R^d \rightarrow R^{\bar{d}}$ is the operator that maps the input data space to higher dimensional spaces is provider of a weight function for the initial weight space. $b \in R$ And $e_i \in R$ provide error variables and one-way semester, respectively. In the initial weight space, the WLS-SVM method with the problem of optimization (Equation 1) and training is expressed as follows:

$$y(x) = w^T \phi(x) + b \tag{2}$$

4- Analysis of results

In this study, the data set was randomly divided for training and validation using k-fold cross-validation (k=3). The results of WLS-SVM method in training and validation phase are shown in Figures 1-a and 1-b, respectively.

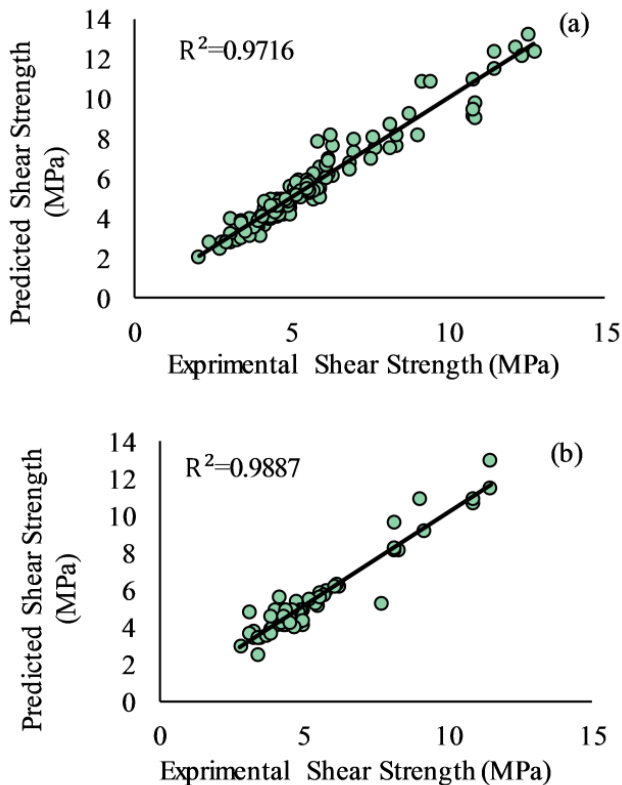


Fig. 1. Comparison of shear capacity predicted in the present study with laboratory shear capacity values (a) Results from the training phase of data (b) Results from the data validation phase

Table 1. Comparison of prediction results obtained from WLS-SVM method with the results in different regulations and artificial intelligence methods

Method	$\frac{V_{actual}}{V_{predicted}}$	MAPE (%)	MAE (MPa)	Ref ¹
ACI318-11	0.571	16.21	1.225	[8]
CSA	0.574	18.91	0.825	[9]
GSA	0.147	10.87	0.506	[1]
Optimized SVM	0.9189	8.26	0.4035	[10]
MLR-Reg Tree	0.9285	10.00	0.5150	[10]
WLS-SVM	0.998	9.48	0.478	C.S. ²

¹Refrence, ²Current Study

The results show that the WLS-SVM method with a value of $R^2=0.9716$ in the experimental stage and a value of $R^2=0.9887$ in the validation stage ($R^2>0.95$) has achieved very good results for the trained model. Comparison of results obtained from WLS-SVM method, CSA and ACI regulations, results from gravitational search algorithm (GSA), SVM method using SOS optimizer and multiple linear regression method (Tree MLR-Reg) is shown in Table 1. According to Table 1, it can be seen that the WLS-SVM method has better results than other comparison methods of artificial intelligence and CSA and ACI regulations.

5- Conclusions

In this study, a new artificial intelligence method called WLS-SVM was used to predict the shear strength of deep concrete beams. Using eight different input parameters in WLS-SVM method, the values of coefficients R2, RMSE, MAEP and MAE for this method were calculated. Comparison of the results obtained from this method with other artificial intelligence methods as well as different regulations show that the accuracy of the WLS-SVM method with the square root of the mean square error is $RMSE=0.107$, the coefficient of determination is $R^2=0.9887$, the percentage of mean absolute error is $MAEP=9.48\%$ and mean absolute error $MAE=0.478$ is much higher than other existing artificial intelligence methods and regulations.

References

- [1] Gandomi, A.H., Yun, G.J. and Alavi, A.H., 2013. "An evolutionary approach for modeling of shear strength of RC deep beams". Materials and Structures, 46(12), pp.2109-2119.
- [2] Vapnik, V.N., 1995. The nature of statistical learning theory, Springer, New York.
- [3] Chou, J.S., Yang, K.H. and Lin, J.Y., 2016. "Peak shear strength of discrete fiber-reinforced soils computed by machine learning and metaensemble methods". Journal of Computing in Civil Engineering, 30(6), p.04016036.
- [4] Hoang, N.D., Tran, X.L. and Nguyen, H., 2020. "Predicting ultimate bond strength of corroded reinforcement and surrounding concrete using a metaheuristic optimized

- least squares support vector regression model”. *Neural Computing and Applications*, 32(11), pp.7289-7309.
- [5] Khatibinia, M., Araghi, M., 2019. “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), 233-250.
- [6] Suykens, J.A.K., Van Gestel, T., De Brabanter, J., De Moor, B. and Vandewalle, J., 2002. *Least squares support vector machines.* (World Scientific Publishing: Singapore).
- [7] Li, H.S., Lü, Z.Z. and Yue, Z.F., 2006. “Support vector machine for structural reliability analysis”. *Applied Mathematics and Mechanics*, 27(10), pp.1295-1303.
- [8] ACI Committee and International Organization for Standardization, 2008. *Building code requirements for structural concrete (ACI 318-08) and commentary.* American Concrete Institute.
- [9] Canadian, C.S.A., 1994. *Building Code, Design of Concrete Structures: Structures (Design)-A National Standard of Canada (CAN-A23. 3-94), Clause 11.1. 2,* Canadian Standards Association.
- [10] Prayogo, D., Cheng, M.Y., Widjaja, J., Ongkowijoyo, H. and Prayogo, H., 2017. “Prediction of concrete compressive strength from early age test result using an advanced metaheuristic-based machine learning technique”. In *ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction*, 34.

HOW TO CITE THIS ARTICLE

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) 853-856

DOI: 10.22060/ceej.2020.18122.6775





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

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
وزن دار

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 وزن دار (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 تعیین کننده 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 (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 معیار
(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	۳۳/۳۵	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]:

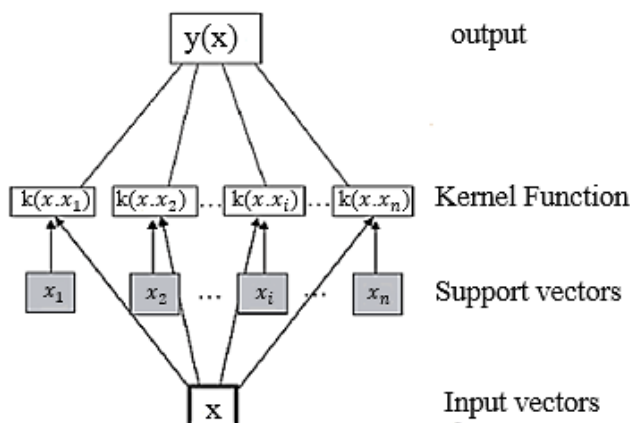
$$\bar{v}_k = \begin{cases} 1 & \text{if } \left| \frac{e_i}{\hat{s}} \right| \leq c_1 \\ \frac{c_2 - \left| \frac{e_i}{\hat{s}} \right|}{c_2 - c_1}, & \text{if } c_1 \leq \left| \frac{e_i}{\hat{s}} \right| \leq c_2 \\ 10^{-4} & \text{otherwise} \end{cases} \quad (16)$$

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

۵-۱- پارامترهای اولیه

قبل از آغاز حلقه جستجو در درون دامنه‌های از پیش تعریف شده، شش پارامتر $(C, \gamma_1, \gamma_2, \sigma^2, \alpha$ 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].

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

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

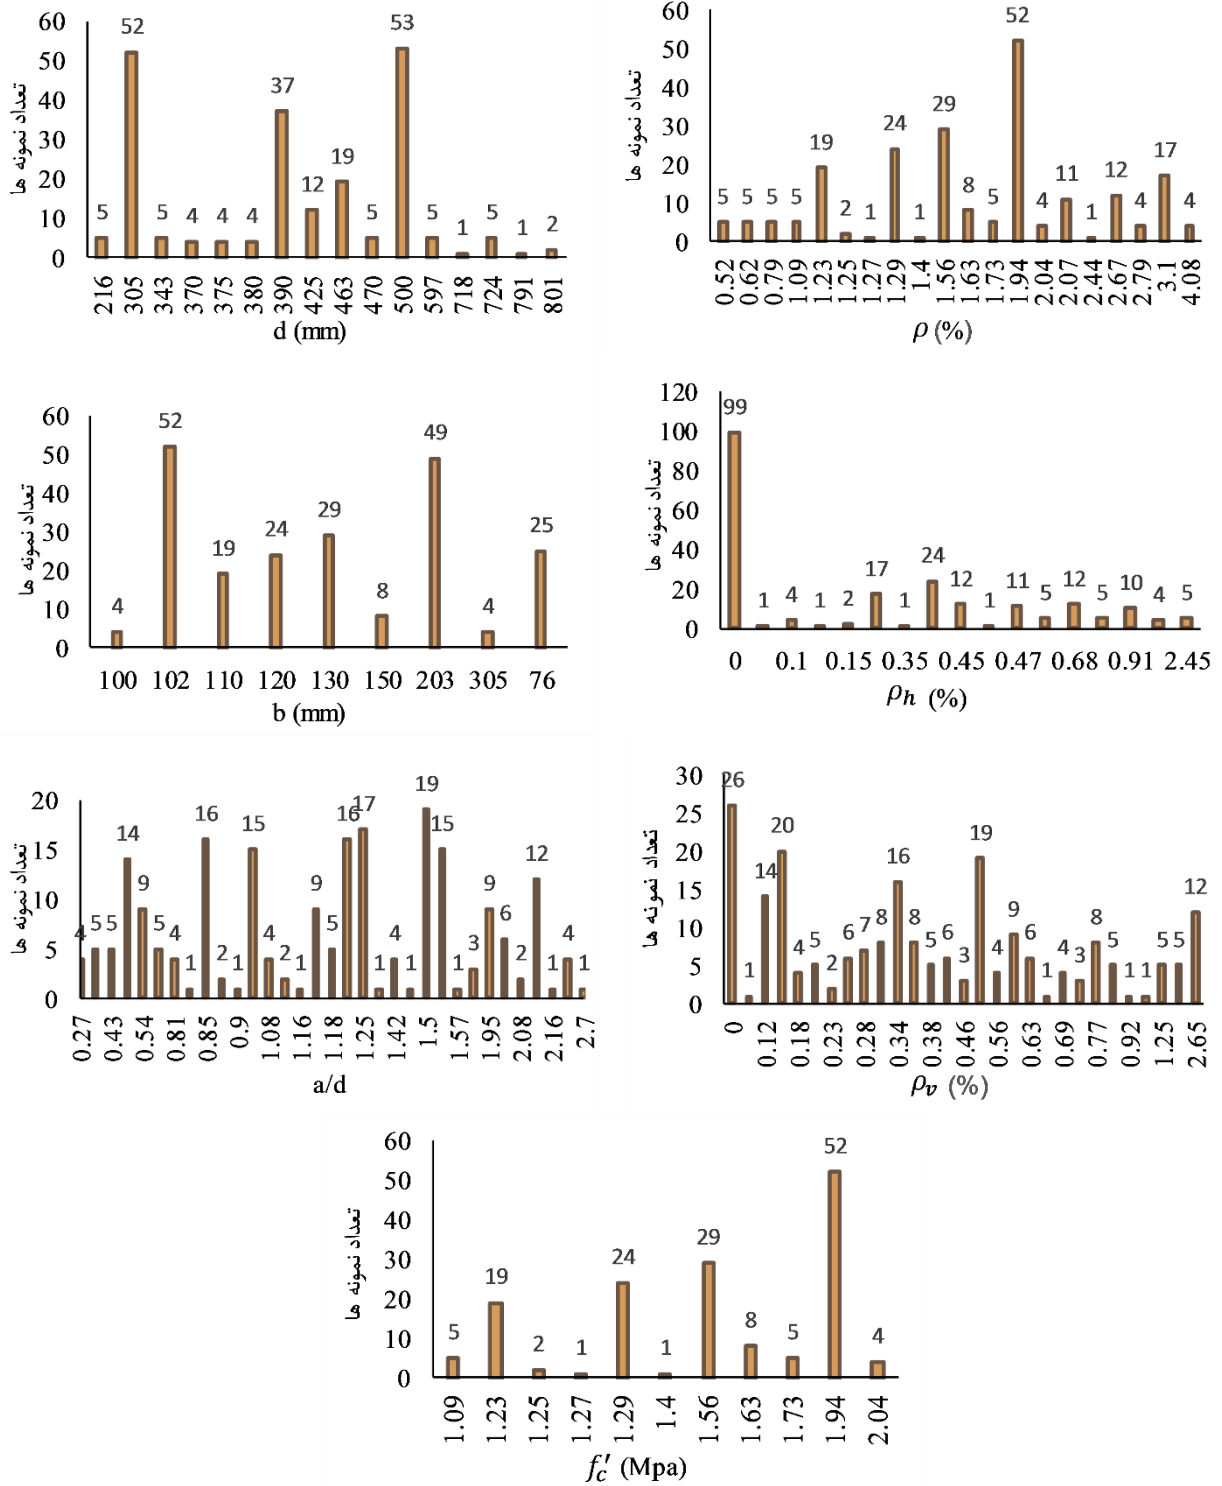
در این مرحله، روش WLS-SVM برای پیش‌بینی، فرآیند آموزشی خود را با استفاده از مقادیر اولیه $(C, \gamma_1, \gamma_2, \sigma^2)$ آغاز نموده و سپس اعتبارسنجی مدل ساخته شده با استفاده از داده‌های صحت‌سنجی، انجام می‌شود. این نکته حائز اهمیت است که برای دستیابی به بیشترین دقت تخمین، داده‌ها پردازش می‌شوند.

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.

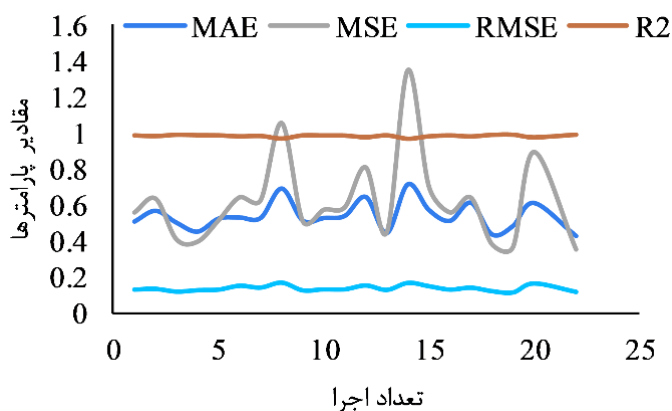
۶-۱ فاز آموزش و انتخاب پارامترها

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



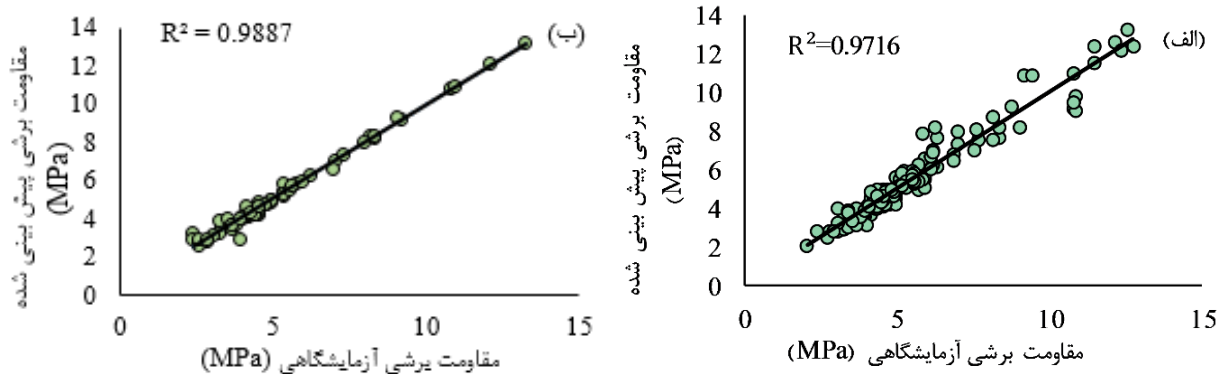
شکل ۶. مقایسه نتایج به دست آمده برای شاخصه‌های کارکرد (ضرایب R^2 , MAPE, MAE, RMSE) در اجراهای مختلف

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^1 ، (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

