



Comparing the accuracy of individual and combined application of genetic algorithm and least squares of support vector machine in estimating scour depth of simple bridge piers

Mehdi Karami Moghadam^{*1}, Ata Amini²

1. Associate Professor, Department of Agriculture, Payame Noor University (PNU), Tehran, Iran, Email: m.karami.mo2014@pnu.ac.ir

2. Professor, Kurdistan Agricultural and Natural Resources Research and Education Center, AREEO, Sanandaj, Iran, Email: a.amini@areeo.ac.ir

| ARTICLE INFO | ABSTRACT |
|---|---|
| <p>Article type: Research Paper</p> <p>Article history Received: 10 February 2023 Revised: 04 March 2023 Accepted: 11 March 2023 Published online: 02 August 2023</p> <p>Keywords: Bridge Piers, Empirical Relationships, Genetic algorithm, LSSVM, Water resources.</p> | <p>One of the landscape management approaches is the construction of bridges along the rivers. On the other hand, the bridge scouring is a serious damage to river engineering as the main source of water and sustaining planet life. Accordingly, in this research, using field data, the accuracy of empirical methods, genetic algorithm (GA), least squares support vector machine (LSSVM), and combined method were compared in estimating scour depth of simple bridge piers. In the GA method, a number of empirical relationships were modified and the results of these modified relationships were compared with the measured scour values. In the LSSVM method, through the input of different independent parameters, model training was performed, and scour depth was predicted. In the combined method, using the LSSVM model from combining the results of different individual relations, the scour depth of the bridge piers was estimated. The results showed that modified relationships by genetic algorithm and LSSVM model have higher accuracy than empirical methods. Also, if only the parameters used in the empirical relationships are included as input parameters to the LSSVM model, the modified relationships have less error than the LSSVM model. The statistical evaluation criteria of RMSE, E, R², and NSE for the best state of the combined method were 0.4 m, 49%, 0.88, and 0.58 respectively in the training stage and 0.52 m, 50%, 0.7, and 0.38 respectively in the test stage. In general, the combined method estimates scouring depth with higher accuracy than other methods.</p> |

Citation: Karami Moghadam, M., & Amini, A. (2023). Comparing the accuracy of individual and combined application of genetic algorithm and least squares of support vector machine in estimating scour depth of simple bridge piers. *Iranian Journal of Rainwater Catchment Systems*, 11(2), 30-47.

DOR: 20.1001.1.24235970.1402.11.2.3.1

Publisher: Iranian Rainwater Catchment Systems Association

© Author(s)



***Corresponding author:** Mehdi Karami Moghadam

Address: Department of Agriculture, Payame Noor University (PNU), Tehran, Iran.

Tel: +989132530936

Email: m.karami.mo2014@pnu.ac.ir



Comparing the accuracy of individual and combined application of genetic algorithm and least squares of support vector machine in estimating scour depth of simple bridge piers

Mehdi Karami Moghadam^{*1}, Ata Amini²

1. Associate Professor, Department of Agriculture, Payame Noor University (PNU), Tehran, Iran, Email: m.karami.mo2014@pnu.ac.ir

2. Professor, Kurdistan Agricultural and Natural Resources Research and Education Center, AREEO, Sanandaj, Iran, Email: a.amini@areeo.ac.ir

EXTENDED ABSTRACT

Introduction: Among the reasons of the destruction of bridges is the scour of piers. High accuracy in the determination of scour depth is a voucher of the structure's lifetime. Inasmuch as the scour is a multifaceted process affected by many factors, the researchers have not reached a consensus yet in presenting a solution to figuring out the scour depth or reducing it. Through laboratory research, they have offered a bunch of empirical relations to estimate scour depth. However, being obtained in the lab and giving acceptable solutions only within a certain range of data, the improvement of these relations is a necessity that should be concomitant with other methods based on field data. Genetic algorithm, inter alia, is an approach based on random search and in which the natural biological modeling is a benchmark. The algorithm works on the likely responses having survived more generations giving closer estimations of the optimal solution. Among other artificial intelligence methods recently applied in the theme of sedimentation and hydraulics are the Support Vector Machine (SVM) and the Least Square Support Vector Machine (LSSVM). The SVM is an effective learning system based on the useful optimization theory which uses the inductive axiom of minimization of structural error and leads to a general optimal solution (Chou and Pham, 2013). Behzad et al. (2009) have predicted the daily flow using the statistics of a hydrometer station located on the Bakhtiari River by considering the statistics of the previous day. Their results show that the SVM model is more efficient in comparison with neural networks.

Methodology: In this research, using field data and genetic algorithm some empirical relations were modified and improved. By independent parameters as the input and the combined method along with the LSSVM, the scour depth was estimated. The idea of a genetic algorithm comes from the two principles of choice and generation in nature. Over time and due to genetic modification or mutation, nature vouches for the generation of more enhanced creatures. The genetic algorithm starts with an initial population of chromosomes and goes towards an optimal population. It is a search implement that through an objective function connects to the analytics tool. The technique of Support Vector Machine (SVM) was founded by Cortes and Vapnik (1995) based on Statistical Learning Theory which follows the minimizing structural risk. Suykens et al. (2002) proposed the Least Square Support Vector Machine which, in contrast to the SVM model, uses linear equations in solving the problem instead of quadratic programming. So, it has more computational accuracy relative to the classic SVM.

Results and Discussion: Figure 1 shows a comparison between the scours obtained from the empirical relation (Blench-Inglis I, 1962) and its improved relation via the genetic algorithm for the real scour values in the training stage. As observed, the modified relation predicts the scour values of the bridge pier with higher precision so that the values obtained in this fashion and the actual values are in a range closer to the one-to-one line. Besides, the scour values resulting from the empirical relation are in some cases negative which are improved in this way too. Table 1 contains the comparison of the indexes RMSE, E, and R^2 between the empirical relation of Froehlich (1988), as the most accurate empirical relation, its modified relation through the genetic algorithm, the best result of the LSSVM model with independent parameters, and that of the combined LSSVM at the training and test stage.

***Corresponding author:** Mehdi Karami Moghadam

Address: Department of Agriculture, Payame Noor University (PNU), Tehran, Iran.

Tel: +989132530936

Email: m.karami.mo2014@pnu.ac.ir




Figure 1- Comparison between observed scour value and (a) the value obtained by Blench-Inglis I (1962), (b) the value obtained by the improved relation via a genetic algorithm in the training stage.

Table 1- Comparison between different methods of estimation of scour depth of bridge pier

| Method | Train | | | | Test | | | |
|---|-------|----------|----------------|------|-------|----------|----------------|------|
| | E (%) | RMSE (m) | R ² | NSE | E (%) | RMSE (m) | R ² | NSE |
| Empirical relationship of Froehlich (1988) | 60 | 0.76 | 0.59 | 0.37 | 65 | 0.62 | 0.59 | 0.27 |
| Modified relationship of Froehlich (1988) using genetic algorithm | 58 | 0.69 | 0.67 | 0.38 | 59 | 0.58 | 0.65 | 0.32 |
| LSSVM model with independent input parameters | 43 | 0.43 | 0.88 | 0.63 | 68 | 0.58 | 0.63 | 0.36 |
| Combination LSSVM model | 49 | 0.40 | 0.88 | 0.58 | 50 | 0.52 | 0.70 | 0.38 |

Conclusion: This research can be briefly concluded as follows:

- The relations improved by the genetic algorithm had higher accuracy than the empirical ones.
- By choosing the width of the bridge pier, velocity, and depth of the flow as the inputs of LSSVM, we would see that the values of scour depth are more in agreement with the real scour values.
- The combined LSSVM method gives the scour depth more precisely than the other methods.

Ethical Considerations

Data availability statement: The datasets are available upon a reasonable request to the corresponding author.

Funding: This study was conducted as a research project and it has received financial support from the Payame Noor University (PNU).

Authors' contribution: Mehdi Karami Moghadam: Conducting all parts of the research and writing manuscript; Ata Amini: Revision.

Conflicts of interest: The author of this paper declared no conflict of interest regarding the authorship or publication of this article.

Acknowledgment: We would like to express our sincere gratitude to the Payame Noor University (PNU) for the financial and logistical support that significantly contributed to the research project.

مقایسه دقت کاربرد جداگانه و ترکیبی الگوریتم ژنتیک و حداقل مربعات ماشین بردار پشتیبان در تخمین عمق آبشستگی پایه‌های ساده پل‌ها

مهدی کرمی مقدم^{۱*}، عطا امینی^۲

۱. دانشیار، گروه کشاورزی، دانشگاه پیام نور، تهران، ایران، m.karami.mo2014@pnu.ac.ir

۲. استاد، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی کردستان، سنندج، ایران، a.amini@areeo.ac.ir

| چکیده | مشخصات مقاله |
|--|--|
| یکی از رویکردهای مدیریت سرزمین، احداث پل در امتداد مسیر رودخانه‌هاست. از طرفی، آبشستگی پل‌ها آسیب جدی به مهندسی رودخانه به‌عنوان منبع اصلی آب و حفظ حیات در کره زمین است. بر همین اساس، در این پژوهش با استفاده از داده‌های میدانی، دقت روش‌های روابط تجربی، الگوریتم ژنتیک (GA)، حداقل مربعات ماشین بردار پشتیبان (LSSVM) و روش ترکیبی در تخمین عمق آبشستگی پایه‌های ساده پل‌ها مقایسه شد. در روش GA، تعدادی از روابط تجربی اصلاح و نتایج حاصل از این روابط اصلاح شده با مقادیر واقعی آبشستگی مقایسه شد. در روش LSSVM، از طریق ورودی پارامترهای مختلف مستقل، آموزش مدل انجام و مقدار عمق آبشستگی پیش‌بینی شد. در روش ترکیبی، با استفاده از مدل LSSVM از ترکیب نتایج روابط مختلف منفرد، مقدار عمق آبشستگی پایه پل تخمین زده شد. نتایج نشان داد که روابط اصلاح شده توسط الگوریتم ژنتیک و مدل LSSVM دقت بالاتری نسبت به روابط تجربی دارند. همچنین چنانچه تنها پارامترهای استفاده شده در روابط تجربی به‌عنوان پارامترهای ورودی به مدل LSSVM لحاظ شوند، روابط اصلاح شده خطای کمتری نسبت به مدل LSSVM دارند. شاخص‌های ارزیابی RMSE، E، R ² و NSE برای بهترین حالت روش ترکیبی در مرحله آموزش به ترتیب ۰/۴ متر، ۴۹ درصد، ۰/۸۸ و ۰/۵۸ و در مرحله آزمون به ترتیب ۰/۵۲ متر، ۵۰ درصد، ۰/۷ و ۰/۳۸ هستند. در مجموع روش ترکیبی، عمق آبشستگی را با دقت بالاتری نسبت به دیگر روش‌ها تخمین می‌زند. | <p>نوع مقاله: پژوهشی</p> <p>تاریخچه مقاله دریافت: ۲۱ بهمن ۱۴۰۱ بازنگری: ۱۳ اسفند ۱۴۰۱ پذیرش: ۲۰ اسفند ۱۴۰۱ انتشار برخط: ۱۱ مرداد ۱۴۰۲</p> <p>واژه‌های کلیدی: منابع آب، پایه پل، روابط تجربی، الگوریتم ژنتیک، LSSVM.</p> |

استناد: کرمی مقدم، مهدی، و امینی، عطا. (۱۴۰۲). مقایسه دقت روش‌های الگوریتم ژنتیک، حداقل مربعات ماشین بردار پشتیبان و روش ترکیبی در تخمین عمق آبشستگی پایه‌های ساده پل‌ها. *سامانه‌های سطوح آبگیر باران*، ۱۱(۲): ۳۰-۴۷.

DOR: 20.1001.1.24235970.1402.11.2.3.1



© نویسندگان

ناشر: انجمن علمی سیستم‌های سطوح آبگیر باران ایران

* نویسنده مسئول: مهدی کرمی مقدم

نشانی: گروه کشاورزی، دانشگاه پیام نور، تهران، ایران.

تلفن: ۰۹۱۳۲۵۳۰۹۳۶

پست الکترونیکی: m.karami.mo2014@pnu.ac.ir

مقدمه

آبشستگی پدیده‌ای است طبیعی که به واسطه جریان آب رودخانه‌ها و یا سیلاب به وجود آمده و نتیجه آن فرسایش، انتقال و سائیدن مواد از کف، سواحل و اطراف پایه‌های پل است (Breusers et al., 1977). از آن‌جا که پدیده آبشستگی فرآیندی بسیار پیچیده است و عوامل زیادی در شکل‌گیری آن مؤثرند، محققان هنوز موفق به ارائه روش دقیقی برای محاسبه عمق حفره آبشستگی و یا کاهش آن نشده‌اند (Amini et al., 2014). در چند دهه گذشته خطراتی که آبشستگی متوجه پایداری سازه‌های هیدرولیکی می‌نماید در سراسر جهان توجه همه‌جانبه را به خود جلب کرده است (Pandey et al., 2018; Moradinejad et al., 2019). ضرورت بررسی پدیده آبشستگی زمانی آشکار می‌شود که عمق آبشستگی قابل‌ملاحظه باشد به‌گونه‌ای که این عمق به پی سازه‌های رودخانه‌ای برسد و پایداری این سازه‌ها را در معرض خطر قرار داده و نهایتاً موجب تخریب آن‌ها شود. بنابراین شناخت این پدیده، پیش‌بینی عمق و نیز دیگر ابعاد حفره آبشستگی برای افزایش پایداری سازه‌های هیدرولیکی از جمله پلها امری بسیار ضروری است (Khaledi et al., 2021).

برخی از محققان که به بررسی پدیده آبشستگی پایه پل به‌صورت آزمایشگاهی پرداخته‌اند، سعی کرده‌اند با در نظر گرفتن پارامترهای مؤثر در این پدیده، رابطه‌ای تجربی را برای تخمین عمق آبشستگی پایه پل ارائه دهند. به تناسب شکل پایه‌های پل روابط تجربی زیادی استخراج شده‌اند. علاوه بر پایه‌های ساده، تحقیقات گسترده‌ای بر گروه پایه‌های ساده (Hosseini & Amini, 2015; Amini et al., 2012) و نیز پایه‌های مرکب انجام شده است (Amini & Mohammad, 2017). برخی از این روابط، عمق آبشستگی را با دقت بالاتری تخمین می‌زنند ولی اکثر این روابط به‌دلیل این‌که در شرایط آزمایشگاهی به‌دست آمده‌اند، فقط در شرایط خاصی جواب می‌دهند و هنگام استفاده از آن‌ها در رودخانه‌های طبیعی دارای خطا هستند. بنابراین لازم است این‌گونه روابط با استفاده از روش‌های امروزی اصلاح شوند (Bui et al., 2020). اخیراً روش‌های داده‌کاوی^۱ برای تخمین عمق آبشستگی پایه پل به‌کار برده شده است (Amini et al., 2021). از جمله این روش‌های هوش مصنوعی، الگوریتم ژنتیک^۲ (GA)، روش ماشین بردار پشتیبان^۳ (SVM)، روش کم‌ترین مربعات ماشین بردار پشتیبان^۴ (LSSVM)، برنامه‌ریزی بیان ژن^۵ (GEP) و شبکه عصبی مصنوعی^۶ (ANN) هستند. Yu et al. (2006) در مطالعه‌ای با استفاده از SVM به پیش‌بینی سطح رقمی سیل در رودخانه سن-یانگ تایوان پرداختند. نتایج نشان داد که مدل به‌خوبی سطح آب رودخانه را برای ۱ تا ۶ ساعت بعد پیش‌بینی می‌کند. Behzad et al. (2009) با استفاده از آمار یک ایستگاه هیدرومتری واقع بر روی رودخانه بختیاری، جریان روزانه را با در نظر گرفتن آمار روز قبل پیش‌بینی کردند. نتایج پژوهش آن‌ها نشان داد مدل SVM عملکرد بهتری نسبت به شبکه‌های عصبی دارد.

Botsis et al. (2011) بارش-رواناب روزانه حوزه آبخیزی واقع در کالیفرنیا را شبیه‌سازی کردند. مدل SVM با سه نوع تابع کرنل^۷ با مدل ANN مقایسه شد. در نهایت ماشین بردار پشتیبان شبیه‌سازی دقیق‌تری از بارش رواناب داشت. روش‌های الگوریتم ژنتیک و ماشین بردار پشتیبان در زمینه تخمین عمق آبشستگی نیز به‌کار برده شده‌اند. Bateni et al. (2007a,b) نشان دادند که هوش مصنوعی و سامانه‌های استنتاج عصبی فازی نسبت به دیگر روش‌ها، عمق آبشستگی را با دقت بیش‌تری تخمین می‌زنند. غضنفری هاشمی و اعتماد شهیدی (۱۳۹۱) و Geol (2015) با استفاده از روش SVM عمق آبشستگی اطراف پایه پل را پیش‌بینی نمودند. نتایج آن‌ها حاکی از عملکرد خوب این روش در تخمین عمق آبشستگی بود. اقبالی و همکاران (۱۳۹۲) روند توسعه زمانی ابعاد آبشستگی را در اطراف تکیه‌گاه‌های دیوار باله‌ای^۸ با استفاده از الگوریتم ژنتیک بررسی کردند. نتایج آن‌ها نشان داد روش الگوریتم ژنتیک به‌خوبی می‌تواند توسعه زمانی عمق آبشستگی را مدل کند. Sharafi et al. (2016) از روش SVM با توابع کرنل مختلف جهت پیش‌بینی عمق آبشستگی پایه پل استفاده و نشان دادند روش SVM چندجمله‌ای، عمق آبشستگی را با دقت بالاتری نسبت به روش‌های ANN، ANFIS و معادلات بر پایه رگرسیون غیرخطی پیش‌بینی می‌کنند. Sreedhara et al. (2019) کاربرد SVM و ANFIS را برای پیش‌بینی عمق آبشستگی اطراف پایه پل ارزیابی کردند. آن‌ها بیان کردند که مدل SVM می‌تواند به‌عنوان یک روش جایگزین دقیق و کارآمد در این زمینه مورد استفاده قرار گیرد. Majedi – Asl et al. (2020) عمق آبشستگی اطراف پایه‌های پل با شکل‌های مختلف را با استفاده از الگوریتم SVM تخمین

¹ Data mining

² Genetic algorithm

³ Support vector machine

⁴ Least square support vector machine

⁵ Gene expression programming

⁶ Artificial neural networks

⁷ Kernel

⁸ Wing-wall abutments

زدند و نتایج را با GEP و مدل رگرسیون غیرخطی مقایسه کردند. نتایج آن‌ها حاکی از دقت بالاتر الگوریتم SVM داشت. همچنین، تحلیل حساسیت نشان داد به ترتیب عدد فرود، اندازه رسوبات و زاویه برخورد جریان بیش‌ترین تأثیر را در آبستگي پایه پل دارند. تخمین عمق آبستگي پایه پل با استفاده از روابط تجربی منفرد ممکن است برای یک شرایط خاص جواب مناسبی ارائه دهد. اخیراً محققان در علوم مختلف به روش ترکیب مدل‌ها به منظور افزایش دقت تخمینی مکانی و زمانی روی آورده‌اند. با فرض اینکه هر رابطه منفرد تنها می‌تواند در یک یا چند شرایط هیدرولیکی خاص نتایج قابل قبولی ارائه دهد، انتظار می‌رود نتیجه‌ای که از ترکیب روش‌های منفرد به دست می‌آید، جامع‌تر و دقیق‌تر از هر یک از روش‌ها باشد. تاکنون تحقیقاتی در این زمینه نیز انجام شده است. Shamseldin et al. (1997) از روش‌های ترکیبی میانگین ساده و میانگین وزنی و شبکه عصبی به منظور پیش‌بینی سیلاب استفاده نمودند. Tahmasebi et al. (2016) جهت تخمین دبی سیلاب از روش‌های ترکیبی و شبکه‌های عصبی استفاده کردند. نتایج نشان داد ترکیب داده‌های چند مدل منفرد، دبی سیلاب را با دقت بالاتری تخمین می‌زند. Dobarco et al. (2017) نشان دادند مدل‌های ترکیبی نسبت به مدل‌های منفرد دارای خطای کمتر و همبستگی بیش‌تر در تهیه نقشه‌های بافت خاک سطحی دارند. غزنوی و همکاران (۱۳۹۹) با استفاده از مدل LSSVM و روش‌های ترکیبی، عمق آبستگي پایین دست سازه‌های تثبیت بستر را مورد بررسی قرار دادند. نتایج آن‌ها نشان داد ترکیب روابط منفرد عمق آبستگي به روش‌های مختلف، می‌تواند دقت پیش‌بینی را بهبود بخشد. Seifollahi et al. (2021) با در نظر گرفتن متغیرهای قطر پایه، سرعت متوسط و بحرانی جریان، قطر متوسط رسوبات و عمق جریان، مقدار آبستگي اطراف پایه‌های پل را توسط روش شبکه عصبی موجکی^۱ تخمین زدند. نتایج آن‌ها نشان داد این روش نسبت به دیگر روش‌های معمول شبکه عصبی مؤثرتر است. Zarbazoo Siahkali et al. (2021) عمق آبستگي اطراف پایه‌های پل دایره‌ای با خاک گیرچسبنده را توسط روش‌های شبکه عصبی مصنوعی، دسته‌بندی گروهی داده‌ها^۲ (GMDH)، مدل‌سازی رگرسیون غیرپارامتری چند متغیره اسپیلاین^۳ (MARS) و مدل‌های پردازش گوسین (کریجینگ^۴) تخمین زدند. با مقایسه نتایج این روش‌ها و مقادیر واقعی آبستگي مشخص شد کریجینگ روش دقیق‌تری نسبت به دیگر روش‌هاست. Delavari et al. (2022) از چندین روش شبکه عصبی برای تخمین آبستگي اطراف پایه‌های پل استفاده کردند. نتایج آن‌ها نشان داد روش شبکه عصبی پرسپترون چند لایه^۵ (MLP) و روش دسته‌بندی گروهی داده‌ها (GMDH) نسبت به روش رگرسیون خطی چندگانه^۶ (MLR) عملکرد بهتری دارند. Tola et al. (2023) با بررسی آبستگي‌های اخیر پایه پل، روش‌های مختلف استفاده از داده‌ها جهت ورودی مدل ماشین بردار پشتیبان را ارائه دادند. آن‌ها در نتایج خود مزایا و محدودیت‌های هر روش را مورد بررسی قرار دادند.

در این پژوهش مقایسه تخمین عمق آبستگي اطراف پایه پل به چهار روش شامل روابط تجربی، الگوریتم ژنتیک، مدل LSSVM و روش ترکیبی انجام شد. استفاده از انواع روش‌های تخمین، استفاده از داده‌های میدانی با حذف محدودیت‌های آزمایشگاهی و از همه مهم‌تر ترکیب روابط اصلاح شده توسط الگوریتم ژنتیک در روش ترکیبی، از نوآوری این تحقیق است.

مواد و روش تحقیق

در این تحقیق با به‌کارگیری داده‌های عمق آبستگي میدانی موجود در چندین پایه پل، تعدادی از روابط تجربی توسط الگوریتم ژنتیک اصلاح شد. همچنین با آموزش مدل LSSVM از طریق دخالت دادن پارامترهای مختلف مؤثر در آبستگي پایه پل، مقدار عمق آبستگي توسط این روش پیش‌بینی شد. در روش ترکیبی با استفاده از مدل LSSVM، از ترکیب نتایج روابط مختلف تجربی هم‌چنین ترکیب نتایج روابط اصلاح شده توسط الگوریتم ژنتیک، مقدار عمق آبستگي پایه پل تخمین زده شد. در نهایت، علاوه بر ارزیابی مقدار خطای هر کدام از روش‌ها، نتایج حاصل از روش‌های مختلف با یکدیگر مقایسه شد.

¹ Wavelet

² Group method of data handling

³ Multivariate adaptive regression splines

⁴ Kriging

⁵ Multi-layer perceptron

⁶ Multiple linear regression

روابط تجربی

به استناد گزارش مدیریت بزرگراه‌های فدرال آمریکا^۱ (FHWA)، تعداد هشت رابطه تجربی تخمین عمق آبخستگی پایه‌های ساده پل‌ها شامل Blench- Inglis-Poona II (1949), Inglis-Poona I (1949), Froehlich-Design (1996), Froehlich (1988), Shen (1997), Inglis I (1962), Inglis II (1962), Blench-Inglis II (1962), Breusers (1965) و Richardson & Davis (2001) مورد بررسی قرار گرفتند.

الگوریتم ژنتیک

الگوریتم ژنتیک یک ابزار جستجوست که توسط یک تابع هدف به ابزار تحلیل ارتباط پیدا می‌کند (کرمی‌مقدم و همکاران، ۱۳۹۷). متلب^۲ یک محیط محاسباتی و زبان برنامه‌نویسی است که کاربردهای فراوانی در رشته‌های مختلف علوم و مهندسی دارد. در این پژوهش با استفاده از برنامه‌نویسی در محیط متلب، مراحل مختلف الگوریتم ژنتیک جهت بهینه کردن ضرایب روابط تجربی مورد بررسی تهیه شد. در این الگوریتم، ابتدا یک جمعیت اولیه از کروموزوم‌ها که در واقع اعداد تصادفی هستند، انتخاب می‌شوند. این اعداد همان ضرایب و توان‌های ثابت موجود در معادلات تجربی هستند. در مرحله بعد با استفاده از عملگرهای جهش و تقاطع، جمعیت جدیدی ایجاد می‌شود. به‌کار بردن این جمعیت‌ها به‌عنوان ضرایب و توان‌های روابط تجربی، مقدار عمق آبخستگی محاسبه و با مقدار واقعی مقایسه می‌شود. کروموزوم‌هایی که دارای خطای کم‌تری باشند را به‌عنوان جمعیت جدید انتخاب و این الگوریتم تکرار می‌شود. جهت ارزیابی و مقایسه عمق آبخستگی حاصل از روابط اصلاح شده با مقدار واقعی عمق آبخستگی، از شاخص‌های خطای جذر میانگین مربعات (RMSE)، درصد خطا (E) و ضریب همبستگی (R^2) استفاده شد. اجرای الگوریتم ژنتیک تا زمانی ادامه پیدا می‌کند که شاخص‌های RMSE و E بین نتایج حاصل از روابط اصلاح شده با مقادیر واقعی آبخستگی حداقل و مقدار شاخص ضریب همبستگی (R^2) بین این دو حداکثر شود.

مدل LSSVM

روش ماشین بردار پشتیبان (SVM) مانند دیگر روش‌های هوش مصنوعی بر پایه الگوریتم داده‌کاوی عمل می‌کند. در این روش مجموعه‌ای از داده‌های ورودی-خروجی به یک سیستم ارائه می‌شود. سیستم سعی می‌کند یک تابع بین داده‌های ورودی و خروجی بیاموزد. Suykens et al. (2002) روش حداقل مربعات ماشین بردار پشتیبان (LSSVM) را ارائه نمودند. این مدل بر خلاف مدل SVM به جای مساله برنامه‌نویسی درجه دوم در حل، از معادلات خطی استفاده می‌نماید. بنابراین دقت محاسباتی بالاتری نسبت به ماشین بردار پشتیبان کلاسیک دارد. مدل رگرسیونی LSSVM از رابطه (۱) پیروی می‌کند (غزنوی و همکاران، ۱۳۹۹).

$$y(x_i) = w^T \phi(x_i) + b \quad (1)$$

که در آن ϕ ، w^T ، b ، x و y به‌ترتیب تابع کرنل^۳، ترانهاده بردار ضرایب، اربیی تابع رگرسیونی، متغیرهای مستقل و وابسته هستند که از طریق حداقل‌سازی تابع هدف در رابطه (۲) تعیین می‌شود.

$$\min_{w,b} j(w,e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^n e_i^2 \quad (2)$$

در رابطه بالا محدودیتی به‌صورت رابطه (۳) در نظر گرفته می‌شود.

$$y_i = w^T \phi(x_i) + b + e_i \quad (3)$$

که در آن‌ها w بردار ضرایب، γ پارامتر تنظیم‌کننده بخش خطا، e_i خطای داده‌های آموزشی و n تعداد داده‌ها هستند. در این روش توابع کرنل مختلفی شامل خطی، چندجمله‌ای، گوسین و سیگموئید قابل استفاده است. در این تحقیق از تابع کرنل گوسین استفاده شد.

مدل ترکیبی

به شکل ریاضی اگر n رابطه منفرد تخمین عمق آبخستگی وجود داشته باشد، به‌طور کلی فرآیند ترکیب به‌صورت رابطه ۴ بیان می‌شود (سیدیان و فتح‌آبادی، ۱۳۹۵):

$$S_{c,i} = F(S_{1,i}, S_{2,i}, \dots, S_{n-1,i}, S_{n,i}) \quad (4)$$

که $S_{z,i}$ نتیجه حاصل از رابطه z ام در دوره زمانی i ام و $S_{c,i}$ نتیجه حاصل از ترکیب n رابطه تخمین عمق آبخستگی در دوره زمانی i ام هستند.

¹ Federal highway administration

² MATLAB

³ Kernel Function

داده‌های مورد استفاده

اطلاعات و داده‌های مورد استفاده در این پژوهش به‌وسیله سازمان^۱ FHWA ارائه شده است که مربوط به پل‌های موجود در ایالت متحده بوده و تمام داده‌ها از طریق میدانی جمع‌آوری شده‌اند (Mueller & Wagner, 2005). این داده‌ها شامل عمق واقعی آبستگي پایه پل، پارامترهای هیدرولیکی جریان نظیر عمق و سرعت جریان، سرعت بحرانی، پارامترهای هندسی رسوب نظیر قطر متوسط رسوبات رودخانه و پارامترهای هندسی پایه پل مانند طول و عرض پایه پل، شکل پایه پل هستند. تعداد کل داده‌های مورد استفاده ۴۷۸ می‌باشد. در روش‌های الگوریتم ژنتیک، مدل LSSVM و روش ترکیبی، ۸۰ درصد داده‌های میدانی برای آموزش و ۲۰ درصد آن‌ها برای آزمون استفاده شد.

پارامترهای مؤثر انتخاب شده در آبستگي پایه پل

پارامترهای مختلفی در تعیین عمق آبستگي در اطراف پایه پل‌های ساده تأثیر دارند. این پارامترها به‌صورت رابطه ۵ قابل ارائه هستند (سیدیان و فتح‌آبادی، ۱۳۹۵).

$$S = f(\rho, \rho_s, \sigma, \phi, V, y, L, B, D_{50}, u_c, \alpha, \theta, \nu, g) \quad (5)$$

که S عمق آبستگي، ρ و ρ_s به ترتیب جرم مخصوص آب و رسوب، σ انحراف هندسی ذرات، ϕ پارامتر شکل پایه، V سرعت جریان، y عمق جریان، L و B به ترتیب طول و عرض پایه پل، D_{50} قطر متوسط ذرات رسوب کف، u_c سرعت بحرانی، α زاویه برخورد جریان با پایه پل، θ پارامتر شیلدز، ν لزجت سینماتیک و g شتاب ثقل هستند. با لحاظ نمودن روابط پیشنهادی مختلف تجربی که در این پژوهش مورد بررسی قرار گرفتند، مشخص شد محققان به تناسب شرایط آزمایشگاهی خود، صرفاً تعدادی از این پارامترها را در روابط خود به کار برده‌اند. مهم‌ترین این پارامترها به‌صورت رابطه (۶) است (Richardson & Davis, 2001).

$$S = f(\phi, V, y, B, D_{50}, u_c, \theta, \nu, g) \quad (6)$$

شاخص‌های ارزیابی

جهت مقایسه نتایج حاصل از روابط تجربی، روابط اصلاح شده توسط الگوریتم ژنتیک، مدل LSSVM و روش ترکیبی با مقادیر واقعی عمق آبستگي، از شاخص‌های خطای جذر میانگین مربعات RMSE، درصد خطای E، ضریب همبستگی R^2 و ضریب کارایی NSE استفاده شد. (رابطه‌های ۷ تا ۱۰) (Amini et al., 2019; Nash and Sutcliffe, 1970):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - B_i)^2}{n}} \quad (7)$$

$$E = \frac{1}{n} \sum_{i=1}^n \frac{|A_i - B_i|}{B_i} \times 100 \quad (8)$$

$$R^2 = \frac{\left[\sum_{i=1}^n (A_i - \bar{A})(B_i - \bar{B}) \right]^2}{\left[\sum_{i=1}^n (A_i - \bar{A})^2 \sum_{i=1}^n (B_i - \bar{B})^2 \right]} \quad (9)$$

$$NSE = 1 - \frac{\sum_{i=1}^n |B_i - A_i|^j}{\sum_{i=1}^n |B_i - \bar{B}|^j} \quad j=1 \quad (10)$$

در این روابط A_i مقادیر آبستگي حاصل از هر کدام از روش‌ها، B_i مقادیر اندازه‌گیری شده (واقعی) آبستگي، n تعداد داده‌ها و \bar{A} و \bar{B} به ترتیب میانگین مقادیر A_i و B_i هستند. هر چه خطای RMSE و E کمتر و مقدار NSE نزدیک‌تر به یک باشد، مقادیر به‌دست آمده از روابط، مدل LSSVM و روش ترکیبی، تخمین دقیق‌تری از عمق آبستگي است.

¹ Federal high way administration

نتایج و بحث

روابط تجربی و الگوریتم ژنتیک

مقدار عمق آبستنگی با استفاده از ۸ رابطه تجربی شامل (Shen (1997), Froehlich (1988), Froehlich-Design (1996), Inglis-Poona I (1949), Inglis-Poona II (1949), Blench-Inglis I (1962), Blench-Inglis II (1962) و Breusers (1965) تخمین زده شد. همچنین با استفاده از روش الگوریتم ژنتیک، روابط فوق اصلاح شد. در این روش با استفاده از الگوریتمی که در محیط برنامه‌نویسی تهیه شد، ضرایب و توان‌های یک رابطه تجربی مشخص به‌نحو تغییر می‌کند تا منجر به دقیق‌ترین رابطه جهت تخمین عمق آبستنگی شود. به این منظور اجرای الگوریتم ژنتیک تا زمانی ادامه پیدا می‌کند که شاخص‌های RMSE و E بین نتایج حاصل از روابط اصلاح شده با مقادیر واقعی آبستنگی حداقل و مقدار شاخص ضریب همبستگی بین این دو (R^2) حداکثر شود. جدول ۱ روابط تجربی محققان (روابط A تا H) و روابط اصلاح شده آن‌ها به‌وسیله الگوریتم ژنتیک (روابط I تا P) را نشان می‌دهد. در جدول ۲ مقادیر شاخص‌های ارزیابی (% E, RMSE (m) و ضریب همبستگی R^2 بین نتایج حاصل از روابط محققان و نیز روابط اصلاح شده با نتایج واقعی در مرحله آموزش و آزمون آورده شده است.

جدول ۱- روابط تجربی و روابط اصلاح شده توسط الگوریتم ژنتیک در تخمین مقدار آبستنگی پایه پل

Table 1- Empirical relationships and modified relations via genetic algorithm in estimating of scour depth of bridge pier

| Method | Empirical relationship | Symbol | Modified relationship using GA | Symbol |
|-------------------------|---|--------|---|--------|
| Shen (1971) | $S = 0.00022 \left(\frac{VB}{v} \right)^{0.619}$ | A | $S = 0.0000116 \left(\frac{VB}{v} \right)^{0.78}$ | I |
| Froehlich (1988) | $S = 0.32 \phi g^{-0.1} V^{0.2} y^{0.36} B^{0.62} D_{50}^{-0.08}$ | B | $S = 0.32 \phi g^{-0.33} V^{0.70} y^{0.37} B^{0.48} D_{50}^{-0.14}$ | J |
| Froehlich-Design (1996) | $S = 0.32 \phi g^{-0.1} V^{0.2} y^{0.36} B^{0.62} D_{50}^{-0.08} + B$ | C | $S = -10 \phi g^{-0.82} V^{-0.63} y^{-0.46} B^{1.84} D_{50}^{0.24} + B$ | K |
| Inglis-Poona (1949) | II $S = 1.73 B^{0.22} y^{0.78} - y$ | D | $S = 1.261 B^{0.117} y^{0.9512} - y$ | L |
| *Blench-Inglis (1962) | II $S = 1.53 B^{0.25} V^{0.5} D_{50}^{-0.125} y^{0.5} - y$ | E | $S = 1.23 B^{0.094} V^{0.057} D_{50}^{-0.02} y^{0.92} - y$ | M |
| **Inglis-Poona (1949) | I $S = 1.7 B^{0.22} V^{0.52} y^{0.52} - y$ | F | $S = 1.15 B^{0.1062} V^{0.0276} y^{0.9458} - y$ | N |
| **Blench-Inglis (1962) | I $S = 1.8 B^{0.25} y^{0.75} - y$ | G | $S = 1.16 B^{0.117} y^{0.9512} - y$ | O |
| Breusers (1965) | $S = 1.4B$ | H | $S = 0.75B$ | P |

*: Units are English units in feet, except D_{50} , which is in millimeters.

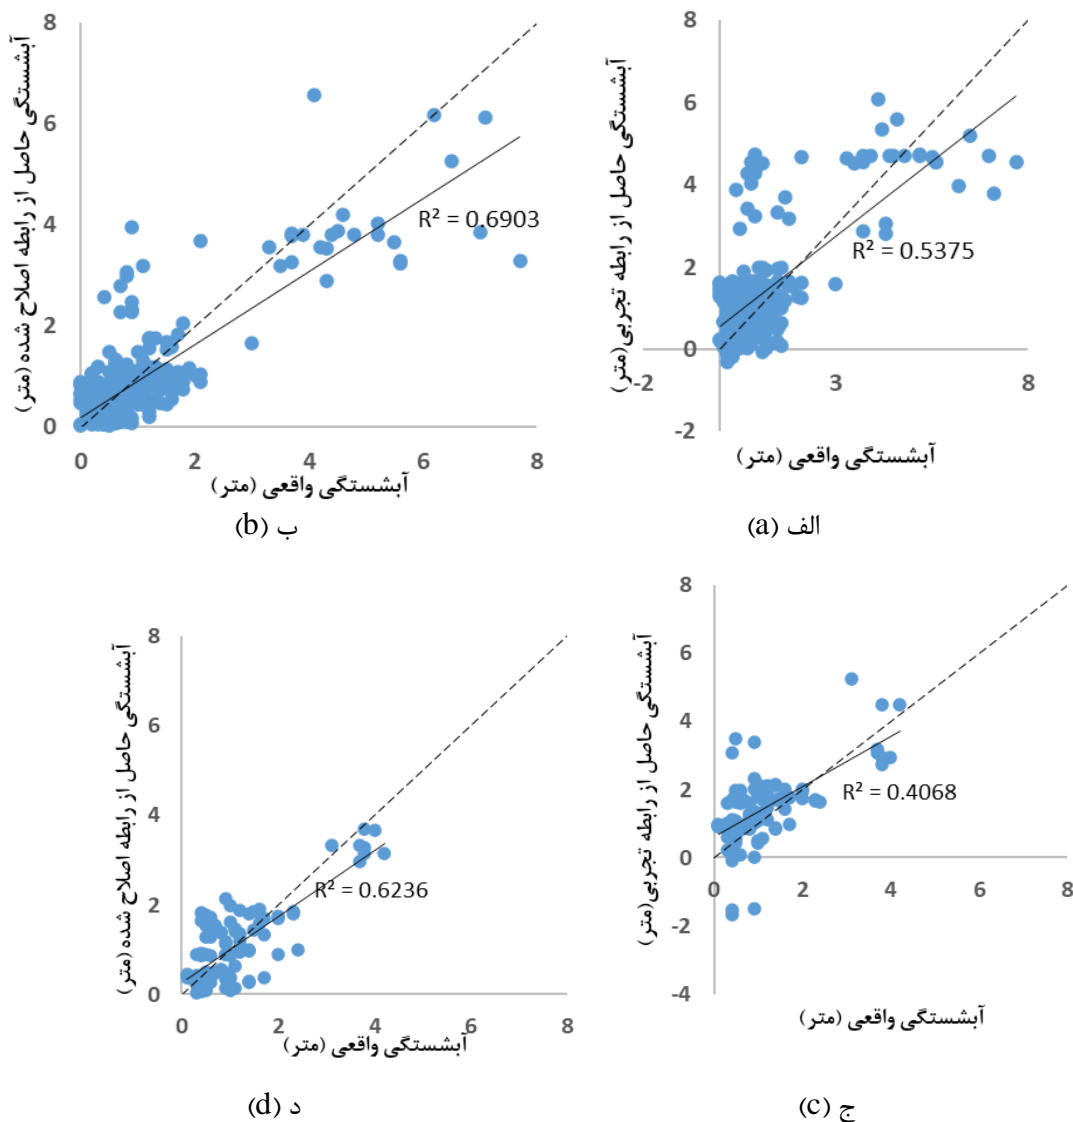
** : Units are English units in feet.

جدول ۲- شاخص‌های ارزیابی تخمین عمق آبستنگی برای روابط تجربی و روابط اصلاح شده در مرحله آموزش و آزمون

Table 2- Evaluation indices values in estimating scour depth for empirical relationships and modified relations in training and test stages

| Method | Stage | Empirical relationship | | | | Modified relationship using GA | | | |
|-------------------------|-------|------------------------|----------|-------|-------|--------------------------------|----------|-------|-------|
| | | E (%) | RMSE (m) | R^2 | NSE | E (%) | RMSE (m) | R^2 | NSE |
| Shen (1971) | Train | 134 | 1.11 | 0.47 | -0.11 | 68 | 0.84 | 0.51 | 0.23 |
| | Test | 165 | 1.05 | 0.48 | 0.19 | 68 | 0.68 | 0.49 | 0.26 |
| Froehlich (1988) | Train | 60 | 0.76 | 0.59 | 0.37 | 58 | 0.69 | 0.67 | 0.38 |
| | Test | 65 | 0.62 | 0.59 | 0.27 | 59 | 0.58 | 0.65 | 0.32 |
| Froehlich-Design (1996) | Train | 212 | 1.71 | 0.60 | -0.79 | 71 | 0.69 | 0.65 | 0.33 |
| | Test | 230 | 1.91 | 0.55 | -1.28 | 67 | 0.59 | 0.62 | 0.35 |
| Inglis-Poona II (1949) | Train | 103 | 0.84 | 0.57 | 0.14 | 62 | 0.65 | 0.69 | 0.38 |
| | Test | 118 | 0.85 | 0.46 | 0.04 | 70 | 0.60 | 0.62 | -0.29 |
| Blench-Inglis II (1962) | Train | 178 | 1.82 | 0.32 | -0.81 | 61 | 0.62 | 0.72 | 0.40 |
| | Test | 153 | 1.96 | 0.06 | -1.06 | 62 | 0.57 | 0.65 | -0.24 |
| Inglis-Poona I (1949) | Train | 250 | 2.24 | 0.23 | -1.38 | 61 | 0.65 | 0.69 | 0.07 |
| | Test | 255 | 1.98 | 0.06 | -1.51 | 68 | 0.58 | 0.64 | 0.32 |
| Blench- Inglis I (1962) | Train | 109 | 0.9 | 0.54 | 0.08 | 62 | 0.65 | 0.69 | 0.37 |
| | Test | 128 | 0.93 | 0.41 | -0.04 | 70 | 0.60 | 0.62 | -0.29 |
| Breusers (1965) | Train | 174 | 1.35 | 0.53 | -0.38 | 74 | 0.80 | 0.53 | 0.07 |
| | Test | 197 | 1.46 | 0.43 | -0.67 | 81 | 0.72 | 0.43 | -0.20 |

همان‌طور که جدول ۲ نشان می‌دهد، مقادیر شاخص‌های خطای RMSE و E برای رابطه تجربی (Froehlich (1988) در هر دو مرحله آموزش و آزمون نسبت به روابط دیگر کم‌تر و ضریب کارایی NSE به یک نزدیک‌تر است (۰/۳۷ و ۰/۲۷ به ترتیب در مرحله آموزش و آزمون). بنابراین این رابطه نسبت به دیگر روابط تجربی دقیق‌تر است. سیدیان و فتح‌آبادی (۱۳۹۵) نشان دادند رابطه Shen (1971) و Froehlich (1988) به ترتیب یکی از کم‌دقت‌ترین و دقیق‌ترین روابط در پیش‌بینی عمق آبستگي پایه پل هستند که با نتایج این پژوهش هم‌خوانی دارد. با اصلاح روابط محققان در این پژوهش با استفاده از الگوریتم ژنتیک، مقادیر خطای RMSE و E کاهش، ضریب کارایی NSE به یک نزدیک‌تر و ضریب همبستگی R^2 افزایش یافته است.



شکل ۱- مقایسه مقدار آبستگي واقعی و آبستگي حاصل از (الف) رابطه Blench-Inglis I (1962) (آموزش)، (ب) رابطه اصلاح شده Blench-Inglis I (1962) (آزمون)، (ج) رابطه Blench-Inglis I (1962) (آموزش)، (د) رابطه اصلاح شده Blench-Inglis I (1962) (توسط الگوریتم ژنتیک)

Figure 1- Comparison between actual (observed) scour values and (a) the values obtained by Blench-Inglis I (1962) (Train), (b) the values obtained by the modified relationship via genetic algorithm (Train), (c) the values obtained by Blench-Inglis I (1962) (Test), (d) the values obtained by the modified relationship (Test) via genetic algorithm

روابط اصلاح شده Froehlich-Design (1996) و Inglis-Poona I (1949) بیش‌ترین و رابطه Froehlich (1988) کم‌ترین کاهش درصد خطای RMSE و E را دارند. با اصلاح رابطه Inglis-Poona I (1949) به‌وسیله الگوریتم ژنتیک، شاخص‌های ارزیابی RMSE و E در مرحله آزمون به ترتیب ۷۰ و ۷۳ درصد کاهش را نشان می‌دهد در حالی که برای رابطه Froehlich (1988) این کاهش

به ترتیب برابر ۶ و ۹ درصد است. بنابراین الگوریتم ژنتیک کم‌ترین تأثیر را بر روی رابطه Froehlich (1988) داشته است. برخی از روابط مانند Blench-Inglis II (1962) مقدار خطای RMSE و E نسبتاً زیاد (به ترتیب ۱/۸۲ متر و ۱۷۸ درصد) و ضریب NSE کوچک (منفی) دارند (۰/۸۱-) که پس از اصلاح، مقادیر خطاها کاهش و ضریب کارایی افزایش چشم‌گیری پیدا کرده و به ترتیب به ۰/۶۲ متر، ۶۱ درصد و ۰/۴۰ رسید. شکل ۱ مقایسه مقدار آبستتگی به دست آمده از رابطه تجربی Blench-Inglis I (1962) و رابطه اصلاح شده آن به وسیله الگوریتم ژنتیک در مقابل مقادیر واقعی آبستتگی در مرحله آموزش و آزمون را نشان می‌دهد. در این شکل خطوط منقطع و ممتد به ترتیب خطوط یک‌به‌یک و خطوط بهترین برازش داده‌ها هستند.

همان‌طور که شکل ۱ نشان می‌دهد رابطه اصلاح شده، مقادیر آبستتگی پایه پل را با دقت بالاتری پیش‌بینی می‌کند و نقاط حاصل از رابطه اصلاح شده و مقادیر واقعی در محدوده نزدیک‌تر به خط یک‌به‌یک قرار دارند. ضمن اینکه در برخی موارد مقدار آبستتگی حاصل از رابطه تجربی منفی است که با اصلاح این رابطه، مقادیر آبستتگی نیز اصلاح شده است. در رابطه تجربی اکثر داده‌ها در بالای خط یک‌به‌یک قرار دارند که نشان از بیش برآوردی این رابطه است در حالی که در رابطه اصلاح شده نتایج کم‌برآورد و بیش‌برآورد عمق آبستتگی تقریباً به یک اندازه است. سیدیان و فتح‌آبادی (۱۳۹۵) جهت پیش‌بینی حداکثر عمق آبستتگی پیرامون پایه پل، برخی از روابط تجربی جدول ۱ را با روش‌های الگوریتم‌های هوشمند مقایسه کردند. نتایج آن‌ها نشان داد روش‌های مبتنی بر هوش مصنوعی نسبت به روابط تجربی دقت بالاتری در پیش‌بینی عمق آبستتگی دارند که با نتایج این پژوهش مطابقت دارد. Jamei & Ahmadianfar (2020) نیز در تحقیقات خود اشاره کردند که پیش‌بینی عمق آبستتگی پایه پل با استفاده از الگوریتم ژنتیک نسبت به روش‌هایی مانند روابط تجربی، برنامه‌ریزی بیان ژن و رگرسیون چندخطی نتیجه بهتری ارائه می‌دهد.

مدل LSSVM با پارامترهای مستقل

در مدل LSSVM جهت پیش‌بینی عمق آبستتگی پایه پل، پارامترهایی با بیش‌ترین تأثیرگذاری بر عمق آبستتگی به‌عنوان ورودی مدل انتخاب می‌شوند. در این تحقیق انتخاب پارامترهای تأثیرگذار در مدل LSSVM به دو روش مورد استفاده قرار گرفت. در روش اول به‌صورت تصادفی پارامترهایی از رابطه ۶ به‌عنوان ورودی مدل انتخاب و پس از گرفتن خروجی از مدل، شاخص‌های ارزیابی مورد بررسی قرار گرفت. در روش دوم پارامترهای ورودی برای مدل LSSVM مطابق با پارامترهای به‌کار رفته در روابط تجربی است.

روش تصادفی انتخاب متغیرهای ورودی

در روش تصادفی، گزینه‌های مختلف برای پارامترهای ورودی انتخاب شد که نتایج آن در جدول ۳ نشان داده شده است.

جدول ۳- شاخص‌های ارزیابی مقادیر خروجی مدل LSSVM در مرحله آموزش و آزمون با پارامترهای ورودی مختلف
Table 3- Evaluation indices values for the results of the LSSVM model at the training and test stages with different input parameters

| Row | Input parameters for LSSVM model | Train | | | | Test | | | |
|-----|----------------------------------|-------|----------|----------------|------|-------|----------|----------------|------|
| | | E (%) | RMSE (m) | R ² | NSE | E (%) | RMSE (m) | R ² | NSE |
| 1 | $\phi, V, y, B, D_{50}, u_c, v$ | 38 | 0.35 | 0.92 | 0.67 | 81 | 0.71 | 0.54 | 0.21 |
| 2 | $\phi, V, y, B, D_{50}, u_c$ | 38 | 0.33 | 0.92 | 0.67 | 81 | 0.75 | 0.53 | 0.20 |
| 3 | ϕ, V, y, B, D_{50} | 40 | 0.37 | 0.90 | 0.65 | 74 | 0.63 | 0.59 | 0.29 |
| 4 | ϕ, V, y, B | 44 | 0.39 | 0.90 | 0.62 | 71 | 0.62 | 0.59 | 0.31 |
| 5 | V, y, B, D_{50} | 43 | 0.43 | 0.88 | 0.63 | 68 | 0.58 | 0.63 | 0.36 |
| 6 | V, y, B, u_c | 43 | 0.39 | 0.89 | 0.62 | 77 | 0.65 | 0.58 | 0.28 |
| 7 | V, y, B | 46 | 0.43 | 0.87 | 0.60 | 65 | 0.58 | 0.63 | 0.36 |
| 8 | V, y | 52 | 0.47 | 0.84 | 0.56 | 66 | 0.94 | 0.40 | 0.15 |
| 9 | V, y, u_c | 45 | 0.42 | 0.87 | 0.61 | 76 | 0.83 | 0.47 | 0.17 |
| 10 | V, y, θ | 52 | 0.46 | 0.85 | 0.56 | 65 | 0.96 | 0.40 | 0.16 |
| 11 | V, y, B, v | 47 | 0.42 | 0.87 | 0.59 | 65 | 0.59 | 0.63 | 0.36 |
| 12 | V, y, B, g | 46 | 0.42 | 0.87 | 0.60 | 66 | 0.58 | 0.64 | 0.35 |
| 13 | V, y, B, g, v | 47 | 0.42 | 0.87 | 0.60 | 65 | 0.58 | 0.63 | 0.36 |
| 14 | V, B, v | 46 | 0.37 | 0.90 | 0.63 | 74 | 0.74 | 0.44 | 0.21 |
| 15 | y, B | 57 | 0.58 | 0.75 | 0.48 | 61 | 0.5 | 0.72 | 0.41 |

در حالتی که شاخص‌های ارزیابی در مرحله آموزش و آزمون به یکدیگر نزدیک و مقدار خطای آن‌ها کم و ضریب کارایی آن‌ها به یک نزدیک‌تر باشد، پارامترهای ورودی مناسب‌ترین خواهد بود. همان‌طور که در جدول ۳ مشخص است در حالتی که پارامترهای ورودی y ، B و D_{50} انتخاب شود (ردیف ۵)، شاخص‌های ارزیابی در مرحله آموزش و آزمون به یکدیگر نزدیک‌تر و مقادیر خطای آن‌ها کم خواهد بود. ضمن این‌که با اضافه کردن پارامترهای ثابت g و v (ردیف‌های ۱۱ تا ۱۳)، تغییری در نتایج حاصل نمی‌شود. این موضوع بیان‌گر تأثیرگذاری کم این متغیرها در عمق آبستگی است. نتایج ردیف ۵ به‌عنوان بهترین نتیجه در روش تصادفی انتخاب شد که در ردیف اول جدول ۴ با علامت (*) مشخص شده است.

انتخاب متغیرها متناسب با روابط تجربی

در روش دوم متغیرهای ورودی برای مدل LSSVM، همان پارامترهای دخیل در روابط تجربی و روابط اصلاح شده توسط الگوریتم ژنتیک انتخاب و نتایج خروجی آن با مقادیر واقعی آبستگی مقایسه شد. نتایج این روش به همراه نتایج روابط تجربی و اصلاح شده در جدول ۴ آورده شده است. در هر کدام از ردیف‌های جدول ۴، پارامترهای مؤثر در آبستگی برای هر سه روش LSSVM، رابطه تجربی محقق و رابطه اصلاح شده یکسان است. به‌عنوان مثال پارامترهای دخیل در رابطه تجربی (Shen 1971) و رابطه اصلاح شده آن شامل سرعت جریان (V)، عرض پایه پل (B)، و لزجت سینماتیک (ν) است. لذا این سه پارامتر به‌عنوان پارامترهای ورودی مدل LSSVM انتخاب شد که نتایج آن به همراه نتایج روابط تجربی و اصلاح شده در ردیف ۲ جدول ۴ آمده است.

جدول ۴- مقادیر شاخص‌های ارزیابی روابط تجربی، روابط اصلاح شده و خروجی مدل LSSVM در مرحله آموزش و آزمون

Table 4- Evaluation indices values, empirical relationships, modified relationships, and results of the LSSVM model at the training and test stages with different input parameters

| Row | Method | Stage | LSSVM | | | | Modified relationship using GA | | | | Empirical relationship | | | |
|-----|-------------------------|-------|-------|----------|----------------|------|--------------------------------|----------|----------------|-------|------------------------|----------|----------------|-------|
| | | | E (%) | RMSE (m) | R ² | NSE | E (%) | RMSE (m) | R ² | NSE | E (%) | RMSE (m) | R ² | NSE |
| 1 | LSSVM (*) | Train | 43 | 0.43 | 0.88 | 0.63 | - | - | - | - | - | - | - | - |
| | | Test | 68 | 0.58 | 0.63 | 0.36 | - | - | - | - | - | - | - | - |
| 2 | Shen (1971) | Train | 45 | 0.37 | 0.90 | 0.64 | 68 | 0.84 | 0.50 | 0.23 | 134 | 1.11 | 0.47 | -0.11 |
| | | Test | 76 | 0.74 | 0.44 | 0.19 | 68 | 0.68 | 0.49 | 0.26 | 165 | 1.05 | 0.48 | 0.19 |
| 3 | Froehlich (1988) | Train | 40 | 0.37 | 0.90 | 0.65 | 58 | 0.69 | 0.67 | 0.38 | 60 | 0.76 | 0.59 | 0.37 |
| | | Test | 74 | 0.64 | 0.59 | 0.30 | 59 | 0.58 | 0.65 | 0.32 | 65 | 0.62 | 0.59 | 0.27 |
| 4 | Froehlich-Design (1996) | Train | 40 | 0.37 | 0.90 | 0.65 | 71 | 0.69 | 0.65 | 0.33 | 212 | 1.71 | 0.60 | -0.79 |
| | | Test | 74 | 0.64 | 0.59 | 0.30 | 67 | 0.59 | 0.62 | 0.35 | 230 | 1.91 | 0.55 | -1.28 |
| 5 | Inglis-Poona II (1949) | Train | 56 | 0.58 | 0.75 | 0.48 | 62 | 0.65 | 0.69 | 0.38 | 103 | 0.84 | 0.57 | 0.14 |
| | | Test | 69 | 0.68 | 0.51 | 0.27 | 70 | 0.60 | 0.62 | -0.29 | 118 | 0.85 | 0.46 | 0.04 |
| 6 | Blench-Inglis II (1962) | Train | 43 | 0.43 | 0.88 | 0.62 | 61 | 0.62 | 0.72 | 0.40 | 178 | 1.82 | 0.32 | -0.81 |
| | | Test | 68 | 0.58 | 0.63 | 0.35 | 62 | 0.57 | 0.65 | -0.24 | 453 | 1.96 | 0.06 | -1.06 |
| 7 | Inglis-Poona I (1949) | Train | 46 | 0.43 | 0.87 | 0.60 | 61 | 0.65 | 0.69 | 0.07 | 250 | 2.24 | 0.23 | -1.38 |
| | | Test | 66 | 0.58 | 0.63 | 0.36 | 68 | 0.58 | 0.64 | 0.32 | 255 | 1.98 | 0.06 | -1.51 |
| 8 | Blench-Inglis I (1962) | Train | 56 | 0.58 | 0.75 | 0.48 | 62 | 0.65 | 0.69 | 0.37 | 109 | 0.90 | 0.54 | 0.08 |
| | | Test | 69 | 0.68 | 0.51 | 0.27 | 70 | 0.60 | 0.62 | -0.29 | 128 | 0.93 | 0.41 | -0.04 |
| 9 | Breusers (1965) | Train | 58 | 0.59 | 0.74 | 0.45 | 74 | 0.80 | 0.53 | 0.07 | 174 | 1.35 | 0.53 | -0.38 |
| | | Test | 83 | 0.92 | 0.40 | 0.18 | 81 | 0.72 | 0.43 | -0.20 | 197 | 1.46 | 0.43 | -0.67 |

همان‌طور که در جدول ۴ مشخص است، در مرحله آموزش شاخص‌های RMSE و E در روابط تجربی حداکثر و در نتایج حاصل از LSSVM حداقل است. همچنین ضریب همبستگی R² در روابط تجربی حداقل و در نتایج حاصل از مدل LSSVM حداکثر است. ضریب کارایی NSE نیز در مدل LSSVM نسبت به دو روش دیگر به یک نزدیک‌تر است. این موضوع نشان می‌دهد که آموزش توسط مدل LSSVM به‌خوبی انجام شده است. در مرحله آزمون میزان خطا در روابط تجربی حداکثر است و بیش‌تر از روابط اصلاح شده توسط الگوریتم ژنتیک و خروجی مدل LSSVM است. با توجه به نتایج مرحله آزمون، مقدار شاخص‌های خطا و ضریب همبستگی بین خروجی روابط اصلاح شده و خروجی مدل LSSVM به یکدیگر نزدیک هستند. با این حال ضریب کارایی NSE در مدل LSSVM نسبت به روش الگوریتم ژنتیک به یک نزدیک‌تر است.

در حالت بدون محدودیت برای پارامترهای ورودی مدل حداقل مربعات ماشین بردار پشتیبان (که در جدول ۴ با $LSSVM^*$ نشان داده شده است)، اگرچه در مرحله آموزش مقدار خطای RMSE آن تقریباً مشابه با دیگر حالات است، اما اولاً در مرحله آزمون این خطا نسبت به حالات دیگر کم‌تر بوده و ثانیاً در این حالت اختلاف خطا بین مرحله آموزش و آزمون ناچیز است. به عبارتی دیگر مدل خوب آموزش دیده است. لذا در حالتی که ورودی $LSSVM$ پارامترهای B, y, V و D_{50} هستند، این مدل مقدار عمق آبستتگی را بهتر تخمین می‌زند. هنگامی که از پارامترهای رابطه Shen (1971) شامل B, V و v به‌عنوان ورودی مدل $LSSVM$ استفاده می‌شود، اگرچه در مرحله آموزش مقادیر خطای RMSE و E (به ترتیب ۰/۳۷ متر و ۴۵ درصد) نسبت به رابطه تجربی Shen (1971) و رابطه اصلاح شده آن کم‌تر و ضریب کارایی NSE به یک نزدیک‌تر است (۰/۶۴)، ولی همان‌طور که در مرحله آزمون مشاهده می‌شود مقادیر خطاها به ترتیب به ۰/۷۴ متر و ۷۶ درصد و ضریب کارایی به ۰/۱۹ تغییر کرده است. بنابراین با ورودی‌های مذکور آموزش مدل به‌خوبی صورت نگرفته است. به عبارتی دیگر هنگامی که فقط داده‌های سرعت (V)، عرض پایه پل (B) و لزجت سینماتیکی آب (v) موجود باشد، استفاده از رابطه اصلاح شده توسط الگوریتم ژنتیک نسبت به مدل $LSSVM$ ارجحیت دارد و این دو روش از معادله تجربی Shen (1971) جواب بهتری را تخمین می‌زنند.

رابطه Froehlich (1988) یکی از روابطی است که عمق آبستتگی را با دقت بهتری نسبت به دیگر روابط پیش‌بینی می‌کند. هنگامی که پارامترهای این رابطه به‌عنوان ورودی مدل $LSSVM$ انتخاب شود، با وجود مقادیر خطای پایین در مرحله آموزش، این مقادیر در مرحله آزمون افزایش قابل توجهی یافته است. این نتیجه نشان می‌دهد که با این ورودی‌ها آموزش مدل به‌خوبی صورت نمی‌گیرد. در این حالت نیز ابتدا استفاده از رابطه اصلاح شده توسط الگوریتم ژنتیک سپس مدل $LSSVM$ و در انتها رابطه محقق به ترتیب دارای دقت هستند. خطای مربوط به رابطه تجربی Inglis-Poona II (1949) نسبت به رابطه اصلاح شده آن و مدل $LSSVM$ بیش‌تر است ضمن این که در رابطه اصلاح شده توسط الگوریتم ژنتیک و مدل $LSSVM$ خطای مربوط به مرحله آموزش و آزمون و نتایج این دو روش به یکدیگر نزدیک است. در مرحله آزمون ضریب کارایی NSE در مدل $LSSVM$ ، رابطه اصلاح شده و رابطه تجربی به ترتیب ۰/۲۷، ۰/۲۹- و ۰/۰۴ است. بنابراین در صورتی که فقط داده‌های عرض پایه پل (B) و عمق جریان (y) در دسترس باشد، استفاده از روش $LSSVM$ و پس از آن الگوریتم ژنتیک پیشنهاد می‌شود.

روابط تجربی Froehlich-Design (1996)، Blench-Inglis II (1962) و Inglis-Poona I (1949) در مرحله آموزش و آزمون نسبت به روابط اصلاح شده توسط الگوریتم ژنتیک و مدل $LSSVM$ دارای مقادیر خطای بسیار زیادی است. بنابراین استفاده از روابط اصلاح شده و مدل $LSSVM$ نسبت به روابط محققان پیشنهاد می‌شود.

به‌طور کلی می‌توان گفت مدل $LSSVM$ و روابط اصلاح شده مقادیر آبستتگی را با دقت بالاتری نسبت به روابط اصلی محققان تخمین می‌زنند. چنان‌چه به لحاظ استفاده از پارامترهای مختلف برای ورودی مدل $LSSVM$ محدودیتی نباشد، با انتخاب پارامترهای B, y, V و D_{50} به‌عنوان پارامترهای ورودی، این مدل مقادیر آبستتگی را بهتر تخمین می‌زند. در مقابل چنان‌چه محدود به استفاده از پارامترهای دخیل در روابط باشیم، در برخی از روابط اصلاح شده توسط الگوریتم ژنتیک نسبت به مدل $LSSVM$ ، خطای کم‌تر بوده ولی ضریب کارایی کم‌تری نیز دارند. سیدیان (۱۳۹۴) نتیجه گرفت پارامترهای مؤثر تعیین شده در پدیده آبستتگی پایه پل توسط سه روش آزمون گاما، تحلیل مؤلفه‌های اصلی و رگرسیون گام به گام، دقت کمی در تخمین عمق آبستتگی دارند اما تکنیک ماشین بردار پشتیبان توانسته با استفاده از پارامترهای دارای بعد، تخمین قابل قبولی ارائه دهد. همچنین، Hoang & Đức, Majedi-Asl et al. (2020) (2019) و Goel (2015) به عملکرد بهتر الگوریتم ماشین بردار پشتیبان نسبت به روابط تجربی و دیگر الگوریتم‌های پیش‌بینی عمق آبستتگی پایه پل اشاره کردند.

روش ترکیبی

در این روش، ترکیب نتایج حاصل از روابط مختلف به‌عنوان ورودی مدل $LSSVM$ استفاده شد. این روابط از A تا H برای روابط تجربی و از I تا P برای روابط اصلاح شده توسط الگوریتم ژنتیک در جدول ۱ مشخص شده است. جدول ۵ شاخص‌های ارزیابی نتایج بین مقادیر اندازه‌گیری شده و نتایج حاصل از ترکیب روابط مختلف را نشان می‌دهد.

جدول ۵ نشان می‌دهد در برخی حالت‌ها با ترکیب نتایج روابطی مانند B و D ، شاخص‌های خطا در مرحله آموزش بسیار پایین است ولی این شاخص‌ها در مرحله آزمون افزایش چشم‌گیری یافته است و لذا مدل با ترکیب نتایج این روابط، پیش‌بینی خوبی برای داده‌های آزمون ندارد. با ترکیب روابط B و D ، شاخص $RMSE$ ، E و NSE در مرحله آموزش برابر ۰/۲۸ متر، ۳۵ درصد و ۰/۷۳ و در مرحله آزمون ۰/۹۵ متر، ۹۸ درصد و ۰/۰۰۹ است. همچنین، با ترکیب روابط P, L, J و I مقادیر این شاخص‌ها در مرحله آموزش به ترتیب ۰/۳۲ متر، ۴۲

درصد و ۰/۶۶ و در مرحله آزمون ۱/۰۳ متر، ۱۰۸ درصد و ۰/۱۰- است. بنابراین حالتی از ترکیب روابط نتایج قابل قبولی دارد که اولاً دارای حداقل مقادیر شاخص‌های خطای RMSE و E، حداکثر R^2 و مقدار NSE نزدیک‌تری به یک باشد و ثانیاً شاخص‌های ارزیابی بین مرحله آموزش و آزمون به یکدیگر نزدیک باشند. این حالت در ترکیب نتایج روابط تجربی A, B, C, D و E با شاخص‌های RMSE, E, R^2 و NSE به ترتیب ۰/۴۳ متر، ۵۲ درصد، ۰/۸۶ و ۰/۵۵ در مرحله آموزش و ۰/۶۱، ۶۶ درصد، ۰/۵۸ و ۰/۳۳ در مرحله آزمون و ترکیب روابط اصلاح شده I, J, K, L و M به ترتیب با مقادیر شاخص‌های ۰/۴ متر، ۴۹ درصد، ۰/۸۸ و ۰/۵۸ در مرحله آموزش و ۰/۵۲ متر، ۵۰ درصد، ۰/۷۰ و ۰/۳۸ در مرحله آزمون حاصل شد. همان‌طور که از اعداد مشخص است نتیجه بهترین ترکیب نتایج روابط تجربی و روابط اصلاح شده تقریباً به هم نزدیک بوده و در کل با توجه به مقادیر این جدول، در مرحله آموزش در اکثر حالات ترکیب روابط تجربی محققان نسبت به ترکیب روابط اصلاح شده دارای شاخص‌های RMSE و E پایین‌تر و R^2 بالاتری است. برعکس در مرحله آزمون ترکیب روابط تجربی محققان نسبت به ترکیب روابط اصلاح شده دارای شاخص‌های RMSE و E بالاتر و R^2 پایین‌تری است. به‌طور کلی ترکیب نتایج روابط اصلاح شده عمق آبستنگی را بهتر پیش‌بینی می‌کند. در جدول ۶ مقایسه مقادیر شاخص‌های E, RMSE, R^2 و NSE را بین رابطه تجربی (Froehlich (1988) به‌عنوان دقیق‌ترین رابطه تجربی، رابطه اصلاح شده آن توسط الگوریتم ژنتیک، بهترین نتیجه مدل LSSVM با پارامترهای مستقل و LSSVM ترکیبی را در مرحله آموزش و آزمون نشان می‌دهد.

جدول ۵- شاخص‌های ارزیابی مقادیر خروجی مدل ترکیبی LSSVM در مرحله آموزش و آزمون با ترکیب روابط مختلف

Table 5- Evaluation indices values for the results of the combination LSSVM model at the training and test stages with the combination of different relationships

| Combination of different relationship | Train | | | | Test | | | |
|---------------------------------------|-------|----------|-------|------|-------|----------|-------|-------|
| | E (%) | RMSE (m) | R^2 | NSE | E (%) | RMSE (m) | R^2 | NSE |
| A, B | 47 | 0.42 | 0.87 | 0.58 | 88 | 0.80 | 0.30 | 0.11 |
| B, D | 35 | 0.28 | 0.94 | 0.73 | 98 | 0.95 | 0.46 | 0.009 |
| A, B, C | 40 | 0.33 | 0.92 | 0.66 | 105 | 0.91 | 0.36 | -0.04 |
| A, B, D | 51 | 0.45 | 0.85 | 0.55 | 72 | 0.68 | 0.49 | 0.27 |
| B, D, G | 52 | 0.54 | 0.78 | 0.51 | 81 | 0.75 | 0.50 | 0.24 |
| A, B, C, D | 37 | 0.32 | 0.92 | 0.68 | 118 | 0.99 | 0.34 | -0.13 |
| A, B, C, F | 37 | 0.31 | 0.93 | 0.68 | 98 | 0.87 | 0.46 | 0.009 |
| A, B, D, G | 51 | 0.44 | 0.86 | 0.55 | 70 | 0.67 | 0.51 | 0.27 |
| A, B, D, H | 36 | 0.31 | 0.93 | 0.69 | 119 | 1.01 | 0.35 | -0.16 |
| A, B, C, D, E | 52 | 0.43 | 0.86 | 0.55 | 66 | 0.61 | 0.58 | 0.33 |
| A, B, C, D, F | 36 | 0.31 | 0.93 | 0.69 | 111 | 1.01 | 0.42 | -0.15 |
| A, B, D, G, H | 39 | 0.33 | 0.82 | 0.67 | 109 | 0.91 | 0.38 | -0.04 |
| A, B, C, D, E, F | 50 | 0.42 | 0.87 | 0.57 | 71 | 0.67 | 0.52 | 0.27 |
| A, B, C, D, E, F, G | 51 | 0.43 | 0.87 | 0.56 | 67 | 0.63 | 0.56 | 0.31 |
| A, B, C, D, E, F, G, H | 49 | 0.41 | 0.87 | 0.58 | 72 | 0.66 | 0.54 | 0.27 |
| I, J | 61 | 0.56 | 0.77 | 0.46 | 58 | 0.60 | 0.65 | 0.34 |
| J, L | 59 | 0.59 | 0.74 | 0.48 | 58 | 0.51 | 0.71 | 0.41 |
| I, J, K | 54 | 0.45 | 0.85 | 0.54 | 68 | 0.64 | 0.55 | 0.29 |
| I, J, L | 47 | 0.36 | 0.90 | 0.61 | 77 | 0.55 | 0.68 | 0.33 |
| J, L, O | 58 | 0.59 | 0.74 | 0.46 | 58 | 0.52 | 0.71 | 0.41 |
| I, J, K, L | 48 | 0.39 | 0.89 | 0.58 | 69 | 0.50 | 0.72 | 0.39 |
| I, J, K, N | 49 | 0.39 | 0.89 | 0.58 | 69 | 0.51 | 0.71 | 0.39 |
| I, J, L, O | 47 | 0.37 | 0.9 | 0.60 | 75 | 0.53 | 0.69 | 0.36 |
| I, J, L, P | 42 | 0.32 | 0.92 | 0.66 | 108 | 1.03 | 0.47 | -0.10 |
| I, J, K, L, M | 49 | 0.40 | 0.88 | 0.58 | 50 | 0.52 | 0.70 | 0.38 |
| I, J, K, L, N | 49 | 0.39 | 0.89 | 0.58 | 67 | 0.56 | 0.66 | 0.34 |
| I, J, L, O, P | 45 | 0.35 | 0.91 | 0.63 | 92 | 0.88 | 0.47 | 0.003 |
| I, J, K, L, M, N | 48 | 0.38 | 0.89 | 0.59 | 72 | 0.58 | 0.63 | 0.32 |
| I, J, K, L, M, N, O | 48 | 0.38 | 0.89 | 0.59 | 72 | 0.62 | 0.59 | 0.29 |
| I, J, K, L, M, N, O, P | 46 | 0.36 | 0.90 | 0.61 | 79 | 0.70 | 0.55 | 0.20 |

جدول ۶- مقایسه روش‌های مختلف تخمین عمق آبشستگی پایه پل

Table 6- Comparison between different methods of estimation of scour depth of bridge pier

| Method | Train | | | | Test | | | |
|---|-------|----------|----------------|------|-------|----------|----------------|------|
| | E (%) | RMSE (m) | R ² | NSE | E (%) | RMSE (m) | R ² | NSE |
| Empirical relationship of Froehlich 1988 | 60 | 0.76 | 0.59 | 0.37 | 65 | 0.62 | 0.59 | 0.27 |
| Modified relationship of Froehlich 1988 using genetic algorithm | 58 | 0.69 | 0.67 | 0.38 | 59 | 0.58 | 0.65 | 0.32 |
| LSSVM model with independent input parameters | 43 | 0.43 | 0.88 | 0.63 | 68 | 0.58 | 0.63 | 0.36 |
| Combination LSSVM model | 49 | 0.40 | 0.88 | 0.58 | 50 | 0.52 | 0.70 | 0.38 |

رابطه تجربی (Froehlich (1988) با وجود این‌که در بین دیگر روابط تجربی دارای بهترین تخمین عمق آبشستگی است، ولی همان‌طور که در جدول ۶ مشخص است، نسبت به سه روش دیگر دارای بیش‌ترین مقدار خطای RMSE در مرحله آموزش و آزمون است. رابطه اصلاح شده (Froehlich (1988)، مدل LSSVM با پارامترهای ورودی مستقل و مدل LSSVM ترکیبی در رتبه‌های بعدی قرار دارند. ضمن این‌که این رابطه ضریب کارایی NSE کم‌تری نسبت به سه روش دیگر دارد. در رابطه تجربی (Froehlich (1988) مقدار RMSE در مرحله آموزش ۷۶ سانتی‌متر و در مرحله آزمون ۶۲ سانتی‌متر است. در مقابل در مدل LSSVM ترکیبی این پارامتر به ترتیب ۴۰ و ۵۲ سانتی‌متر در مرحله آموزش و آزمون حاصل شده است. همچنین مقدار درصد خطا (E) برای رابطه تجربی (Froehlich (1988) در مرحله آموزش و آزمون به ترتیب ۶۰ و ۶۵ درصد و در مدل LSSVM ترکیبی به ترتیب ۴۹ و ۵۰ درصد است. شاخص ضریب همبستگی (R²) برای مدل LSSVM ترکیبی بیش‌تر از دیگر روش‌هاست. مقدار ضریب کارایی (NSE) برای رابطه تجربی (Froehlich (1988) در مرحله آموزش و آزمون به ترتیب ۰/۳۷ و ۰/۲۷ و در مدل LSSVM ترکیبی به ترتیب ۰/۵۸ و ۰/۳۸ درصد است که در روش ترکیبی به یک نزدیک‌تر است. بنابراین به‌طور کلی می‌توان گفت مدل ترکیبی LSSVM و پس از آن مدل LSSVM با پارامترهای ورودی مستقل، عمق آبشستگی را بهتر از روابط تجربی و روابط اصلاح شده توسط الگوریتم ژنتیک تخمین می‌زنند.

سیدیان و فتح‌آبادی (۱۳۹۵) نیز با ترکیب برخی از روابط تجربی منفرد در جدول ۱ به این نتیجه رسیدند که روش‌های ترکیبی باعث بهبود نتایج پیش‌بینی عمق آبشستگی می‌شوند. نتایج این تحقیق نیز نشان داد علاوه بر ترکیب روابط تجربی منفرد، ترکیب روابط اصلاح شده توسط الگوریتم ژنتیک نیز تخمین دقیق‌تری از عمق آبشستگی پایه پل ارائه می‌دهد. غزنوی و همکاران (۱۳۹۹) نیز نتیجه گرفتند ترکیب روابط منفرد حداکثر عمق آبشستگی با استفاده از LSSVM می‌تواند دقت پیش‌بینی را نسبت به دیگر روش‌ها مانند میانگین گرنجر-راماناتان بهبود بخشد. در همین راستا، Siwek et al. (2009)، Chou & Pham (2013) و Jovanović et al. (2015) به‌طور کلی به این نتیجه رسیدند که انواع مختلف شبکه‌های عصبی که مبتنی بر هوش مصنوعی می‌باشند، در مقایسه با مدل‌های منفرد عملکرد بهتری را ارائه می‌دهند که با نتایج به‌دست آمده از روش ترکیبی LSSVM در این تحقیق هم‌خوانی دارد.

نتیجه‌گیری

در این تحقیق تخمین عمق آبشستگی با استفاده از روش‌های مختلف مورد مقایسه و ارزیابی قرار گرفت. ابتدا توسط الگوریتم ژنتیک، برخی از روابط تجربی اصلاح شد. سپس مدل LSSVM به دو صورت مورد ارزیابی قرار گرفت. در یک حالت پارامترهای مستقل هندسی و هیدرولیکی و در حالت دیگر پارامترهای دخیل در روابط تجربی یا روابط اصلاح شده توسط الگوریتم ژنتیک به‌عنوان پارامترهای ورودی مدل انتخاب شد. همچنین در روش ترکیبی، نتایج مختلف روابط تجربی و اصلاح شده توسط الگوریتم ژنتیک به‌عنوان پارامترهای ورودی مدل در نظر گرفته شد. جهت مقایسه این روش‌ها از شاخص‌های ارزیابی RMSE، E، R² و NSE استفاده شد. مهم‌ترین نتایج این تحقیق به شرح ذیل است:

- روابط اصلاح شده توسط الگوریتم ژنتیک از دقت بالایی نسبت به روابط تجربی برخوردار است.
- در صورتی که عرض پایه پل، سرعت، عمق جریان و قطر متوسط ذرات به‌عنوان پارامترهای ورودی مدل LSSVM انتخاب شود، نتایج عمق آبشستگی مطابقت بیش‌تری با مقادیر واقعی آبشستگی دارد. این موضوع بیان‌گر تأثیرگذاری بیش‌تر این متغیرها بر عمق آبشستگی است.
- مقادیر شاخص‌های ارزیابی RMSE، E، R² و NSE برای روش LSSVM ترکیبی در مرحله آموزش به ترتیب ۰/۴ متر، ۴۹ درصد، ۰/۸۸ و ۰/۵۸ و در مرحله آزمون به ترتیب ۰/۵۲ متر، ۵۰ درصد، ۰/۷ و ۰/۳۸ هستند.
- روش LSSVM ترکیبی، عمق آبشستگی را با دقت بالاتری نسبت به دیگر روش‌ها تخمین می‌زند.

ملاحظات اخلاقی

دسترسی به داده‌ها: داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

حمایت مالی: این پژوهش در قالب پروژه تحقیقاتی انجام شده و از دانشگاه پیام نور حمایت مالی دریافت نموده است.

مشارکت نویسندگان: مهدی کرمی مقدم: انجام و نگارش بخش‌های مختلف مقاله؛ عطا امینی: ویرایش مقاله.

تضاد منافع نویسندگان: نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

سپاس‌گزاری: این مقاله قسمتی از نتایج پروژه تحقیقاتی است. نگارندگان مقاله از دانشگاه پیام نور برای حمایت مالی این پروژه قدردانی می‌نمایند.

منابع

۱. اقبالی، پروین، دانشفراز، رسول، و ثاقبیان، سید مهدی (۱۳۹۲). شبیه‌سازی روند توسعه زمانی ابعاد حفره آبستستگی اطراف آبشکن بالدار با استفاده از برنامه‌ریزی بیان ژنی. *دانش آب و خاک*، ۲۳(۱)، ۱۷۷-۱۸۸. https://water-soil.tabrizu.ac.ir/article_206_38.html
۲. سیدیان، مرتضی (۱۳۹۴). استفاده از روش‌های نوین در تعیین پارامترهای موثر بر آبستستگی پایه پل. *مهندسی آبیاری و آب/ایران*، ۵(۳)، ۱۶-۱. https://www.waterjournal.ir/article_73653.html?lang=fa
۳. سیدیان، مرتضی، و فتح‌آبادی، ابوالحسن (۱۳۹۵). تخمین عمق آبستستگی پایه‌های پل با استفاده از روش‌های آماری و الگوریتم‌های هوشمند. *مهندسی عمران و محیط زیست*، ۴۶(۸۳)، ۱۳-۱. https://ceej.tabrizu.ac.ir/article_5185_0.html?lang=fa
۴. غزنوی، سمیه، سیدیان، مرتضی، فتح‌آبادی، ابوالحسن، و فراستی، معصومه (۱۳۹۹). ارزیابی روش‌های مختلف وزن‌دهی برای پیش‌بینی عمق آبستستگی پایین‌دست سازه‌های تثبیت بستر. *هیدرولیک*، ۱۵(۱)، ۴۳-۲۵. https://jhyd.iha.ir/article_105686.html
۵. غضنفری هاشمی، سمانه، و اعتماد شهیدی، امیر (۱۳۹۱). پیش‌بینی عمق آب‌ستستگی اطراف پایه پل با استفاده از ماشین‌های بردار پشتیبان. *مهندسی عمران مدرس*، ۱۲(۲)، ۳۳-۳۶. https://jhyd.iha.ir/article_105686.html
۶. کرمی مقدم، مهدی، و سبزواری، تورج (۱۳۹۷). اصلاح روابط عمق آبستستگی پایه پل با استفاده از الگوریتم ژنتیک. *محیط زیست و مهندسی آب*، ۴(۲)، ۱۱۴-۱۰۱. https://www.jewe.ir/article_68749.html

References

1. Amini, A., & Mohammad, T. A. (2017). Local scour prediction around piers with complex geometry. *Marine Georesources and Geotechnology*, 35(6), 857-864. doi:10.1080/1064119X.2016.1256923
2. Amini, A., Abdeh Kolahchi, A., Al-Ansari, N., Karami Moghadam, M., & Mohammad, T. (2019). Application of TRMM precipitation data to evaluate drought and its effects on water resources instability. *Applied Sciences*, 9(24), 5377. doi:10.3390/app9245377
3. Amini, A., Hamidi, S., Shirzadi, A., Behmanesh, J., & Akib, S. (2021). Efficiency of artificial neural networks in determining scour depth at composite bridge piers. *International Journal of River Basin Management*, 19(3), 327-333. doi:10.1080/15715124.2020.1742138
4. Amini, A., Melville, B. W. & Ali, T. M. (2014). Local scour at piled bridge piers including an examination of the superposition method. *Canadian Journal of Civil Engineering*, 41(5), 461-471. doi:10.1139/cjce-2011-0389
5. Amini, A., Melville, B. W., Ali, T. M., & Ghazali, A. H. (2012). Clear-water local scour around pile groups in shallow-water flow. *Journal of Hydraulic Engineering*, 138(2), 177-185. doi:10.1061/(ASCE)HY.1943-7900.0000488
6. Bateni, S. M., Borgheib, S. M., & Jeng, D. S. (2007a). Neural network and neuro-fuzzy assessments for scour depth around bridge piers. *Engineering Applications of Artificial Intelligence*, 20, 401-414.
7. Bateni, S. M., Jeng, D. S., & Melville, B.W. (2007b). Bayesian neural networks for prediction of equilibrium and time-dependent scour depth around bridge piers. *Advances in Engineering Software*, 38, 102-111.
8. Behzad, M., Asghari, K., Eazi, M., & Palhang, M. (2009). Generalization performance of support vector machines and neural networks in runoff modeling. *Expert Systems with Applications*, 36(4), 7624-7629.
9. Botsis, D., Latinopoulos, P., & Diamantaras, K. (2011). Rainfall-runoff modeling using support vector regression and artificial neural networks. *12th International Conference on Environmental Science and Technology (CEST2011)*, Rhodes, Greece, 8-10.
10. Breusers, H. N. C., Nicollet, G., & Shen, H. W. (1977). Local scour around cylindrical piers. *Journal of Hydraulic Research*, 15(3), 211-252.
11. Bui, D.T., Shirzadi, A., Amini, A., Shahabi, H., Al-Ansari, N., Hamidi, S., & Ghazvinei, P. T. (2020). A hybrid intelligence approach to enhance the prediction accuracy of local scour depth at complex bridge piers. *Sustainability*, 12(3), 1063. doi:10.3390/su12031063

12. Chou, J. S. and Pham, A. D. (2013). Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength. *Construction and Building Materials*, 49, 554-563.
13. Delavari, E., Saadat, M., & Basirat, S. (2022). Scour depth prediction around bridge abutment protected by spur dike using soft computing tools and regression methods. *Journal of Hydraulic Structures*, 7(4), 10-25.
14. Dobarco, M. R., Arrouays, D., Lagacherie, P., Ciampalini, R., & Saby, N. P. (2017). Prediction of topsoil texture for Region Centre (France) applying model ensemble methods. *Geoderma*, 298, 67-77.
15. Eghbali, P., Daneshfaraz, R., & Saghebani, S. M. (2013). Simulation of temporal development of scour hole around a wing-wall abutment using gene expression programming. *Water and Soil Science*, 23(1), 177-188. [In Persian]
16. Ghazanfari Hashemi, S., & Etemad-Shahidi, A. (2012). Prediction of scour depth around bridge pier by support vector machines. *Modares Civil Engineering*, 12(2), 23-36. URL: <http://mcej.modares.ac.ir/article-16-5542-fa.html> [In Persian]
17. Ghaznavi, S., Seyedian, S. M., Fathabadi, A., & Farasati, M. (2020). Evaluation of different weighting methods to predict scour depth on grade control structures. *Journal of Hydraulics*, 15(1), 25. [In Persian]
18. Goel, A. (2015). Predicting bridge pier scour depth with SVM. *International Journal of Civil and Environmental Engineering*, 9(2), 211-216.
19. Hoang, N. D., & Đức, H. N. (2019). Estimation of scour depth around bridge piers using a least squares support vector machine program developed in Visual C#. NET. *DTU Journal of Science and Technology*, 5(36), 03-09.
20. Hosseini, R., & Amini, A. (2015). Scour depth estimation methods around pile groups. *KSCE Journal of Civil Engineering*, 19(7), 2144-2156. doi:10.1007/s12205-015-0594-7
21. Jamei, M., & Ahmadianfar, I. (2020). Prediction of scour depth at piers with debris accumulation effects using linear genetic programming. *Marine Georesources & Geotechnology*, 38(4), 468-479. <https://doi.org/10.1080/1064119X.2019.1595793>
22. Jovanović, R. Ž., Sretenović, A. A., & Živković, B. D. (2015). Ensemble of various neural networks for prediction of heating energy consumption. *Energy and Buildings*, 94, 189-199.
23. Karami Moghadam, M., & Sabzevari, T. (2018). Modification of bridge piers scour depth equations using genetic algorithm. *Environment and Water Engineering*, 4(2), 101-114. [In Persian]
24. Khaledi, V., Amini, A., & Bahrami, J. (2021). Physical simulation of scour width and length variation around complex piers under clear water condition. *Marine Georesources and Geotechnology*, 39(9), 1107-1114. doi:10.1080/1064119X.2020.1807661
25. Majedi-Asl, M., Daneshfaraz, R., Fuladipannah, M., Abraham, J., & Bagherzadeh, M. (2020). Simulation of bridge pier scour depth base on geometric characteristics and field data using support vector machine algorithm. *Journal of Applied Research in Water and Wastewater*, 7(2), 137-143. <https://doi.org/10.22126/arww.2021.5747.1189>
26. Moradinejad, A., Saneie, M., Ghaderi, A., & Shahri, S. M. Z. (2019) Experimental study of flow pattern and sediment behavior near the intake structures using the spur dike and skimming wall. *Applied Water Science*, 9, 195. 10.1007/s13201-019-1069-7
27. Mueller, S. D., & Wagner, R. C. (2005). Field observations and evaluations of streambed scour at bridges, Federal Highway Administration Research and Technology. FHWA-RD (2005) Report No. FHWA-RD-03-052, Geological Survey Water Resources Division 9818 Bluegrass Parkway Louisville, U.S.
28. Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models: Part I – a discussion of principles. *Journal of Hydrology*, 10, 282–290.
29. Pandey, M., Sharma, P. K., Ahmad, Z., & Singh, U. K. (2018). Experimental investigation of clear-water temporal scour variation around bridge pier in gravel. *Environmental Fluid Mechanics*, 18, 871–890.
30. Richardson, E. V., & Davis, S. R. (2001). Evaluating scour at bridges (No. FHWA-NHI-01-001). United States. *Federal Highway Administration. Office of Bridge Technology*.
31. Seifollahi, M., Lotfollahi-Yaghin, M. A., Kalateh, F., Daneshfaraz, R., Abbasi, S., & Abraham, J. P. (2021). Estimation of the local scour from a cylindrical bridge pier using a compilation Wavelet model and Artificial Neural Network. *Journal of Hydraulic Structures*, 7(3), 1-22.
32. Seyedian, M. (2015). Determinations of affecting parameters on bridge pier scour using new methods. *Irrigation and Water Engineering*, 5(3), 1-16. [In Persian]
33. Seyedian, S. M., & Fathabadi, A. (2017). Estimation of bridge pier scour using statistical methods and intelligent algorithms. *Civil and Environmental Engineering*, 46(83), 13-1. [In Persian]
34. Shamseldin, A. Y., O'connor, K. M., & Liang, G. C. (1997). Methods for combining the outputs of different rainfall-runoff models. *Journal of Hydrology*, 197 (1-4), 203-229.
35. Sharafi, H., Ebtehaj, I., Bonakdari, H., & HosseinZaji, A. (2016). Design of a support vector machine with different kernel functions to predict scour depth around bridge piers. *Natural Hazards*, 84, 2145-2162. <https://doi.org/10.1007/s11069-016-2540-5>

36. Siwek, K., Osowski, S., & Szupiluk, R. (2009). Ensemble neural network approach for accurate load forecasting in a power system. *International Journal of Applied Mathematics and Computer Science*, 19(2), 303-315.
37. Sreedhara, B. M., Rao, M., & Mandal, S. (2019). Application of an evolutionary technique (PSO–SVM) and ANFIS in clear-water scour depth prediction around bridge piers. *Neural Computing and Applications*, 31, 7335-7349.
38. Suykens, J. A., De Brabanter, J., Lukas, L., & Vandewalle, J. (2002). Weighted least squares support vector machines: robustness and sparse approximation. *Neurocomputing*, 48(1), 85-105.
39. Tahmasebi Biragani, Y., Yazdandoost, F., & Ghalkhani, H. (2016). Flood forecasting using artificial neural networks: An application of multi-model data fusion technique. *Journal of Hydraulic Structures*, 2(2), 62-73. DOI: 10.22055/jhs.2016.12853
40. Tola, S., Tinoco, J., Matos, J. C., & O'Brien, E. (2023). Scour detection with monitoring methods and machine learning algorithms—A critical review. *Applied Sciences*, 13(3), 1661.
41. Yu, P. S., Chen, S. T., & Chang, I.F. (2006). Support vector regression for real-time flood stage forecasting. *Journal of Hydrology*, 328(3), 704-716.
42. Zarbazoo Siahkali, M., Ghaderi, A., Bahrpeyma, A., Rashki, M., & Safaeian Hamzehkolaei, N. (2021). Estimating pier scour depth: comparison of empirical formulations with ANNs, GMDH, MARS, and Kriging. *Artificial Intelligence and Data Mining*, 9(1), 109-128.