

Research Paper

Estimating the scour depth of slope control structures with sharp-crested weir using artificial intelligence models

Shahram Mousavi*

Assistant Professor, Department of Civil Engineering, Miyaneh Branch, Islamic Azad University, Miyaneh, Iran.

Received: 2021/09/18

Revised: 2021/11/28

Accepted: 2022/01/05

Use your device to scan and read the article online



DOI:

10.30495/wej.2023.28992.2340

Keywords:

Scour, Sharp-crested weir, ANN, ANFIS, SVM

Abstract

Introduction: In free overfall spillways, waterfalls over the crown of the spillway almost vertically and impacts the downstream bed of the dams. Due to the high velocity and energy of the flow which impacts the erodible downstream bed, it may cause scouring close to the foundation of the dam and consequently threaten the stability of the dam.

Methods: In this study, artificial intelligence methods were used to estimate the scour depth of slope control structures with sharp-crested weir due to the complexity of the phenomenon. Three models including neural network, adaptive fuzzy neural system, and support vector machine (SVM) were used as artificial intelligence or black-box model to solve the problem.

Findings: The results showed that artificial intelligence methods are more efficient than conventional experimental methods in estimating the depth of downstream scours of slope control structures with sharp-crested weir. Using more parameters in the input of artificial intelligence models does not increase the accuracy of these models. It is because of increasing errors as a result of using more parameters in these models. In estimating the downstream scour depth of slope control structures with the sharp-crested weir in both calibration and validation stages, an adaptive fuzzy neural system model is up to 20% more reliable than the artificial neural network model and up to 8.5% than the support vector machine model.

Citation: Mousavi S. Estimating the scour depth of slope control structures with sharp-crested weir using artificial intelligence models. Water Resources Engineering Journal. 2023; 15 (55): 105-118.

***Corresponding author:** Shahram Mousavi

Address: Department of Civil Engineering, Miyaneh Branch, Islamic Azad University, Miyaneh, Iran.

Tell: +98 914923 2598

Email: mousavi481@gmail.com

Extended Abstract

Introduction

In the structure of the dams, spillways are constructed to discharge the water excess to the reservoir capacity. In free overfall spillways, waterfalls over the crown of the spillway almost vertically and impacts the downstream bed of the dams. Due to the high velocity and energy of the flow which impacts the erodible downstream bed, it may cause scouring close to the foundation of the dam and consequently threaten the stability of the dam. Thus, an accurate estimation of the scour depth is one of the important topics in hydraulic engineering. Although the physical-based numerical technique is widely used for temporal and/or spatial modeling of systems, some real-world conditions can have meaningful impacts on the modeling of scour depth of slope control structures with sharp-crested weir and restrict the use of such methods. As a result, these methods may be replaced by other techniques. In the situation where there is no sufficient field data and output accuracy is preferred over the perception of phenomena, a data-driven or black-box model can be properly subsided. Several studies have been performed to examine the susceptibility of artificial intelligence (AI) models for hydraulic modeling. Artificial neural networks (ANNs) as a black-box tool are the most popular and widely applied models in many practical applications. The feed-forward neural network (FFNN) as an ANN model has been broadly employed in the field of hydro-environment as a temporal forecasting technique. Three-layer FFNN with an input layer, an output layer and the hidden layer calibrated using the back-propagation algorithm is adequate for nonlinear temporal hydro-environmental modeling. The ANFIS as a universal function approximator has been applied in various practical applications. The ANFIS integrates both neural networks and fuzzy principles in a single framework of a hybrid artificial intelligent technique by catching the benefits of their best features. Mamdani-Assilian and Takagi-Sugeno are two techniques that have led to the wide use and the success of fuzzy inference systems. The

support-vector network is a new learning machine for two-group classification problems. The machine conceptually implements the following idea: input vectors are non-linearly mapped to a very high dimensional feature space. In this feature space, a linear decision surface is constructed. Special properties of the decision surface ensure the high generalization ability of the learning machine. The idea behind the support-vector network was previously implemented for the restricted case where the training data can be separated without errors.

Materials and Methods

In this study, artificial intelligence methods were used to estimate the scour depth of slope control structures with sharp-crested weir due to the complexity of the phenomenon. Three models including neural network, adaptive fuzzy neural system, and support vector machine (SVM) were used as artificial intelligence or black-box model to solve the problem. 225 data were used in order to simulate scour depth of slope control structures with sharp-crested weir. In the present study, about 70% of collected data were used for the calibration and the remaining for the validation of the artificial intelligence models. The performance of the AI model is evaluated based on some efficiency criteria in both calibration and verification steps. Some common efficiency criteria employed in hydro-environmental problems are as correlation coefficient (R); root means square error (RMSE); standard error of estimates SEE); coefficient of determination (R²); mean absolute error (MAE). Two evaluation criteria employed in the present study are root mean square error and coefficient of determination.

Findings

The results of modeling of the downstream scour depth of slope control structures with sharp-crested weir using artificial intelligence models show that the efficiency of the neural network, adaptive neural-fuzzy system, and support machine vector methods are appropriated in predicting

scour depth. This can be a result of the nonlinearity and complexity of the nature of the phenomenon. The results showed that artificial intelligence methods are more efficient than conventional experimental methods in estimating the depth of downstream scours of slope control structures with sharp-crested weir.

Discussion

Using more parameters in the input of artificial intelligence models does not increase the accuracy of these models. It is because of increasing errors as a result of using more parameters in these models. So, input parameters should be chosen carefully. In estimating the downstream scour depth of slope control structures with the sharp-crested weir in both calibration and validation stages, an adaptive fuzzy neural system model is up to 20% more reliable than the artificial neural network model and up to 8.5% than the support vector machine model. This may be due to the efficiency of the fuzzy concept to overcome the uncertainties of the phenomenon.

Conclusion

The uncertainty and complexity of the hydraulic process have caused data-driven models such as artificial neural networks, adaptive neuro-fuzzy inference systems, and support vector machines to be used in estimating the scour depth of slope control structures with sharp-crested weir. The result of the adaptive fuzzy neural system model was more reliable than artificial neural network and support vector machine models in both calibration and validation stages due to the capability of fuzzy system theory to handle the uncertainties of the hydraulic process.

Ethical Considerations compliance with ethical guidelines

The cooperation of the participants in the present study was voluntary and accompanied by their consent.

Funding

No funding.

Authors' contributions

Design and conceptualization: Shahram Mousavi.

Methodology and data analysis: Shahram Mousavi.

Supervision and final writing: Shahram Mousavi

Conflicts of interest

The authors declared no conflict of interest.

مقاله پژوهشی

تخمین عمق آبشستگی سازه‌های کنترل شیب با سرریز لبه تیز با استفاده از مدل های هوش مصنوعی

شهرام موسوی*

۱-استادیار، گروه مهندسی عمران، واحد میانه، دانشگاه آزاد اسلامی، میانه، ایران

چکیده

مقدمه: عدم قطعیت پارامترهای فیزیکی فرایند عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز، نتایج مدل سازی را تحت تأثیر قرار می‌دهند.

روش: در این تحقیق، از روش‌های هوش مصنوعی برای تخمین مقدار عمق آبشستگی سازه‌های کنترل شیب با سرریز لبه تیز به دلیل پیچیدگی پدیده استفاده شد. از سه مدل شبکه عصبی، سیستم عصبی فازی تطبیقی و ماشین بردار پشتیبان به‌عنوان روش‌های هوش مصنوعی یا جعبه سیاه برای حل مسئله استفاده گردید. به‌منظور شبیه‌سازی عمق آبشستگی در سازه‌های کنترل شیب با سرریز لبه تیز از ۲۲۵ داده استفاده شد. در تمامی مدل‌ها، از ۷۰ درصد داده‌ها برای واسنجی و از ۳۰ درصد داده‌ها برای صحت سنجی در روش‌های هوش مصنوعی استفاده به عمل آمد.

یافته‌ها: آنالیز حساسیت نسبت به پارامترهای ورودی در هر سه مدل پیشنهادی نشان داد که اعمال پارامترهای عرض سرریز، ارتفاع ریزش آب، ارتفاع آب روی تاج، اختلاف ارتفاع آب در بالادست و پایین دست، قطر متوسط ذرات و عمق آب در پایین دست، کارایی مدل‌ها را بهبود می‌دهد. در تخمین میزان عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز در هر دو مرحله واسنجی و صحت سنجی، مدل سیستم عصبی فازی تطبیقی نسبت به مدل شبکه عصبی تا ۲۰ درصد و نسبت به مدل ماشین بردار پشتیبان تا ۸/۵ درصد بر اساس معیارهای رایج در ارزیابی مدل‌ها، قابلیت اطمینان بیشتری دارد که این امر می‌تواند به دلیل توانایی تئوری فازی در غلبه بر عدم قطعیت پارامترهای موثر در تخمین میزان عمق آبشستگی باشد. **نتیجه‌گیری:** نتایج مدل سازی میزان عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز با استفاده از مدل‌های هوش مصنوعی نشان می‌دهد که کارایی این مدل‌ها در پیش‌بینی مقادیر آبشستگی مناسب هستند و نسبت به روش‌های تجربی رایج در زمینه دقیق‌تر می‌باشند که این امر می‌تواند به علت غیرخطی و پیچیده بودن طبیعت مسئله باشد.

تاریخ دریافت: ۱۴۰۰/۰۶/۲۷

تاریخ داوری: ۱۴۰۰/۰۹/۰۷

تاریخ پذیرش: ۱۴۰۰/۱۰/۱۵

از دستگاه خود برای اسکن و خواندن مقاله به صورت آنلاین استفاده کنید



DOI:

10.30495/wej.2023.28992.2340

واژه‌های کلیدی:

آبشستگی، سرریز لبه تیز، شبکه عصبی، سیستم عصبی فازی تطبیقی، ماشین بردار پشتیبان.

* نویسنده مسئول: شهرام موسوی

نشانی: گروه مهندسی عمران، دانشکده فنی و مهندسی، واحد میانه، دانشگاه آزاد اسلامی، میانه، ایران.

تلفن: ۰۹۱۴۹۲۳۲۵۹۸

پست الکترونیکی: mousavi481@gmail.com

۱- مقدمه

بیان ژن عمل می‌کند و همچنین عملکرد روش‌های هوشمند نسبت به روابط کلاسیک موجود منجر به نتایج بهتری می‌شود (۱۰). اگر چه تکنیک‌های عددی مبتنی بر فیزیک به طور گسترده برای مدل‌سازی زمانی و یا مکانی سیستم‌های آب و محیط‌زیست بکار برده می‌شوند، در برخی شرایط ساده‌سازی‌های در نظر گرفته شده می‌تواند تأثیر معنی‌داری بر مدل‌سازی جریان آب داشته باشد و کاربرد این روش‌ها را محدود سازد. در نتیجه زمانی که داده‌های می‌دانی کافی نباشند یا دقت خروجی مهم‌تر از مفهوم فیزیکی مسئله باشد، مدل‌های جعبه سیاه یا داده‌محور می‌توانند جایگزین این روش‌ها شوند (۱۱). عدم قطعیت و پیچیدگی فرایندهای هیدرولیکی باعث شده‌اند تا مدل‌های داده‌محور از قبیل شبکه‌های عصبی مصنوعی (Artificial Neural Networks (ANNs))، و سیستم عصبی-فازی تطبیقی ((ANFIS)) و ماشین‌های بردار پشتیبان (Support Vector Machines (SVM)) و ماشین‌های بردار پشتیبان (Support Vector Machines (SVM)) مطالعات متعددی برای ارزیابی مدل‌های هوش مصنوعی در مدل‌سازی هیدرولیکی و هیدرولوژیکی انجام شده است (۱۲، ۱۳، ۱۴، ۱۵، ۱۶، ۱۷).


با توجه به پیشینه تحقیق صورت گرفته و پیچیدگی پدیده آبستنگی در سازه‌های کنترل شیب، در این تحقیق به منظور تخمین عمق آبستنگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز از روش‌های هوش مصنوعی (ANN، ANFIS، SVM) به عنوان مدل‌های جعبه سیاه و ابزار کاربردی جدید برای شرایط واقعی و آزمایشگاهی استفاده شده‌است. توانایی هر یک از مدل‌های هوش مصنوعی به کار گرفته شده بررسی و با روش‌های کلاسیک مقایسه شده‌اند.

۲- مواد و روش‌ها

۲-۱- داده‌های سازه‌های کنترل شیب با سرریز

لبه تیز

به‌منظور مدل‌سازی عمق آبستنگی در سازه‌های کنترل شیب با سرریز لبه تیز (شکل ۱)، نتایج اطلاعات مربوط به ۲۲۷ آزمایش آبستنگی به شرح جدول ۱ مورد استفاده قرار گرفت.



شکل ۱- آبستنگی سازه کنترل شیب با سرریز لبه (۱)

آبستنگی موضعی پایین‌دست یک سازه کنترل شیب با یک سرریز لبه تیز واقع در بستر آبرفتی یک پدیده پیچیده در تخمین پتانسیل حداکثر عمق فرسایش یافته است. در زمان شروع فرایند آبستنگی، انتقال رسوبات موضعی نسبتاً فعال است در حالی که در زمان نزدیک شدن به شرایط تعادل منجر به مکانیزم کاملاً هیدرولیکی می‌شود که در آن بستر فرسایش یافته ناشی از توازن جرم بین ذرات نهشته شده و انتقال داده شده از داخل حوضچه می‌باشد (۱). Rouse و Ferro روابطی برای عمق آبستنگی نسبت به زمان با در نظر گرفتن پارامترهای هندسی و دبی جریان ارائه دادند (۲، ۳). به‌منظور تعیین حد عمق آبستنگی، بررسی‌های متعدد به‌ویژه در خصوص تحلیل داده‌ها توسط Mason و Arumugam انجام شد (۴). Hoffmans برای تخمین حداکثر عمق آبستنگی از روش نیمه تحلیلی بر اساس قانون دوم نیوتن استفاده کرد (۵). مطالعات صورت‌گرفته در زمینه آبستنگی ناشی از جت مدور با ریزش قائم در بستر با مصالح غیرچسبنده نشان داد که عمق آبستنگی تابعی از عدد فرود ذره است (۶). در تحقیق دیگر، برای تخمین آبستنگی موضعی در پایین‌دست سازه‌های کنترل شیب، نشان داده شد که نسبت عمق آب بالادست و ارتفاع سرریز برای اندازه‌گیری عمق آبستنگی ایجاد شده برای هر دو حالت آزمایشگاهی کوچک‌مقیاس و بزرگ مقیاس قابل‌استفاده است (۱). در تحقیق دیگری، تأثیر ارتفاع و شیب تاج سرریزهای مستغرق بر الگوی فرسایش و رسوب در قوس ۹۰ درجه تند بررسی و نتایج نشان داد که تغییر در ارتفاع و شیب تاج سرریز مستغرق اثر قابل‌ملاحظه‌ای بر کاهش ماکزیمم ارتفاع نسبی توده رسوبی ندارد (۷). صلبی و همکاران مطالعاتی در زمینه تخمین حداکثر عمق آبستنگی در پایاب حوضچه آرامش انجام دادند و نتیجه گرفتند که میزان آبستنگی در طول زمان نیز نشان می‌دهد سرعت فرایند فرسایش پذیری و تشکیل حفره در آغاز آزمایشها بسیار زیاد بوده و با گذشت زمان از میزان آن کاسته می‌شود و حفره آبستنگی به حالت پایدار می‌رسد (۸). تحقیق آزمایشگاهی در زمینه بررسی آزمایشگاهی پارامترهای مؤثر در طراحی جت هیدرولیکی غیرهمفاز در کاهش آبستنگی قوس ۹۰ درجه صورت گرفت و در این روش یک لوله منفذدار در امتداد قوس روی بستر قرار گرفته که دبی هوا از دو انتهای آن به درون جریان اصلی تزریق می‌شود؛ نتایج نشان دادند با نصب سازه جت غیرهمفاز ماکزیمم آبستنگی موجود در قوس بیرونی به میانه فلوام منتقل می‌گردد (۹). Roushangar et al (۲۰۱۶) در پژوهشی دیگر، از روش‌های تجربی، روش شبکه عصبی مصنوعی و روش برنامه‌نویسی ژن برای تخمین حداکثر عمق آبستنگی پایین‌دست سازه‌های کنترل با استفاده از داده‌های میدانی و آزمایشگاهی، استفاده گردید. در این تحقیق، پارامترهای هندسی و هیدرولیکی بالادست و پایین‌دست سرریزها و سازه‌های کنترل شیب در قالب ورودی‌های مختلف روش‌های هوشمند در نظر گرفته شدند. نتایج به‌دست‌آمده نشان داد که در مورد هر سه سازه سرریز منتهی به پرتاب‌کننده جامی، سازه‌های کنترل شیب لبه‌تیز و سازه‌های کنترل شیب مایل، روش شبکه‌های عصبی پیش‌خور بهتر از روش برنامه‌ریزی

جدول ۱ داده‌های آزمایشگاهی عمق آبخستگی در سازه-های کنترل شیب با سرریز لبه تیز (۱)

Model	Number of variables	Number of data
Veronese(1937)	6	36
Mossa(1998)	8	19
D'agostino(1994)	11	114
Chow(1959)	7	13
Falciai and Giacomini (1978)	7	29
Lenzi et al. (2000)	7	13

مدل ANFIS به‌عنوان یک تابع تخمین‌گر عمومی در بسیاری از مسائل کاربردی مورد استفاده قرار گرفته است. در این تحقیق، به‌منظور غلبه بر عدم قطعیت پدیده از مدل شبکه عصبی-فازی تطبیقی برای مدل‌سازی عمق آبخستگی در سازه‌های کنترل شیب با سرریز لبه تیز استفاده شده است. این مدل در برگیرنده دو مدل فازی و عصبی در یک ساختار می‌باشد. بخش فازی رابطه‌ای بین متغیرهای ورودی و خروجی برقرار نموده و پارامترهای مربوط به توابع عضویت بخش فازی به‌وسیله شبکه عصبی تعیین می‌گردد؛ بنابراین ویژگی‌های هر دو مدل فازی و عصبی در شبکه عصبی-فازی تطبیقی نهفته است (۲۱، ۲۲). دو نوع تکنیک شناخته شده‌ای می‌باشند که به‌صورت وسیع به کار برده شده‌اند و در سیستم فازی مطلوب بوده‌اند. در این تحقیق از روش فازی مرتبه اول سوگنو برای مدل‌سازی عمق آبخستگی در سازه‌های کنترل شیب با سرریز لبه تیز استفاده شده است.

برای یک مدل فازی مرتبه اول سوگنو با دو ورودی، یک خروجی و دو تابع عضویت برای هر یک از ورودی‌ها، یک مدل شبکه عصبی-فازی تطبیقی معمولی تشکیل می‌شود (۲۲). در این حالت فرض می‌گردد که سیستم فازی دارای ورودی x و y و یک خروجی f می‌باشد. برای چنین مدلی قوانین معمولی با در نظر گرفتن دو قانون فازی اگر-سپس (If-then rules) به صورت زیر تعریف می‌گردد.

Rule 1: If $\mu(x)$ is A_1 and $\mu(y)$ is B_1 ; then $f_1 = p_1x + q_1y + r_1$

Rule 2: If $\mu(x)$ is A_2 and $\mu(y)$ is B_2 ; then $f_2 = p_2x + q_2y + r_2$

که متغیرهای A_1, A_2, B_1 و B_2 به ترتیب توابع عضویت برای ورودی‌های x و y هستند و $p_1, q_1, r_1, p_2, q_2, r_2$ پارامترهای تابع خروجی می‌باشند. بنابراین در این حالت فرمول بندی در شبکه عصبی-فازی تطبیقی از یک آرایش شبکه عصبی پنج لایه پیشرو پیروی می‌کند. اطلاعات بیشتر در زمینه مدل ANFIS را می‌توان در منابع (۲۱، ۲۳) مشاهده نمود.

۲-۲-۳- مدل ماشین بردار پشتیبان

ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می‌گردد. در مدل رگرسیون SVM تابعی مرتبط با متغیر وابسته Y که خود تابعی از چند متغیر مستقل X است، برآورد میشود (۲۴). مشابه سایر مسائل رگرسیونی فرض می‌شود رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $f(x)$ به علاوه مقداری نوفه (خطای مجاز ε) مشخص شود (رابطه ۱ و ۲) (۲۵).

$$f(x) = W^T \phi(x) + b \quad (1)$$

$$y = f(x) + noise \quad (2)$$

که W بردار ضرایب، b ثابت مشخصه‌های تابع رگرسیونی و ϕ تابع کرنل است. این مورد با آموزش مدل SVM توسط مجموعه‌ای از نمونه‌ها (مجموعه آموزش) محقق می‌شود.

بر اساس جدول ۱ و مطابق شکل ۱، پارامترهای به کار رفته توسط Veronese(1937) شامل $(Q, s, b, b/B, h_0/h)$ است که در آن Q دبی و B عرض کانال می‌باشد؛ Mossa(1998) از پارامترهای $(z, h_0, h, Q/B, s, XS, d_{50})$ استفاده نمود که در آن d_{50} قطر متوسط ذرات بستر است؛ پارامترهای مورد استفاده توسط D'agostino(1994) شامل $(b, z, h_0, h, Q/b, s, XS, h_d, XD, d_{50}, d_{90})$ است؛ Chow(1959) و Falciai and Giacomini (1978) از پارامترهای $(z, h_0, h, Q/B, s, d_{50})$ استفاده کردند (۱). با توجه به عوامل تاثیر گذار در عمق آبخستگی اغلب پارامترها در مدل‌های مذکور مشترک می‌باشند و به نظر می‌رسد با توجه به نتایج تحقیقات مذکور، استفاده از تعداد پارامترهای بیشتر به علت ماهیت غیر خطی و پیچیده بودن پدیده، خطای مدل‌سازی را به همان نسبت افزایش می‌دهد.

۲-۲-۲- مدل‌های هوش مصنوعی

روش‌های هوش مصنوعی به‌عنوان مدل‌های جعبه سیاه به‌صورت گسترده در مسائل مختلف به کار گرفته شده‌اند (۱۱). در این تحقیق سه نوع تکنیک هوش مصنوعی برای مدل‌سازی عمق آبخستگی در سازه‌های کنترل شیب با سرریز لبه تیز، شامل شبکه عصبی، سیستم عصبی-فازی تطبیقی و ماشین بردار پشتیبان مورد استفاده قرار گرفته است.

۲-۲-۱- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی به‌عنوان یک ابزار جعبه سیاه بسیار متداول و به طور گسترده در بسیار از مسائل کاربردی استفاده شده است. شبکه عصبی پیشرو به‌صورت وسیع در مسائل آب و محیط‌زیست به‌عنوان یک تکنیک پیش‌بینی زمانی به کار رفته است (۱۸). شبکه عصبی پیشرو با یک لایه ورودی، یک لایه خروجی و لایه مخفی کالبره شده با الگوریتم انتشار برگشتی برای مدل‌سازی زمانی غیرخطی آب و محیط‌زیست مناسب می‌باشد (۱۹، ۲۰).

۲-۲-۲- مدل شبکه عصبی-فازی تطبیقی

مشخصه هدف، کرنل توابع پایه شعاع (RBF) با یک مشخصه هدف و کرنل خط (Linear) است. در این تحقیق، آنالیز حساسیت نسبت به کلیه پارامترهای موثر در شبیه‌سازی تخمین عمق آبستتگی در هر سه مدل پیشنهادی با ترکیب ورودی‌های یکسان و متفاوت تحلیل می‌گردد.

۳-۲- معیار ارزیابی مدل‌ها

کارایی مدل‌های هوش مصنوعی مبتنی بر برخی معیارهای ارزیابی در هر دو مرحله آموزش و صحت سنجی است. برخی از معیارهای ارزیابی متداول در مسائل آب و محیط‌زیست شامل ضریب نش-ساتکلیف (NS)، میانگین مربع خطاها (MSE)، جذر میانگین مربع خطاها (RMSE)، میانگین مطلق خطاها (MAE) و درصد خطاهای استاندارد (SEP) است. در این تحقیق دو نوع معیار ارزیابی RMSE و NS به کار گرفته شده‌اند. این معیارها برای مقایسه مقادیر واقعی و تخمینی از رابطه γ, δ بدست می‌آیند.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs} - X_{pre})^2}{n}} \quad (7)$$

$$NS = 1 - \frac{\sum_{i=1}^n (X_{obs} - X_{pre})^2}{\sum_{i=1}^n (X_{obs} - \bar{X}_{obs})^2} \quad (8)$$

که X_{obs} ، \bar{X}_{obs} و X_{pre} به ترتیب نشان دهنده مقدار واقعی، تخمینی و متوسط داده‌هاست و n تعداد داده‌ها می‌باشد. لگاتس و مکیب نشان دادند که RMSE و DC برای ارزیابی مدل‌های آب و محیط زیست کافی می‌باشند (۲۶).

- نتایج و بحث

با توجه به نتایج مطالعات صورت گرفته توسط محققین قبلی اشاره شده در بخش مقدمه مقاله حاضر و خطاهای زیاد مدل‌های رایج در این خصوص، عدم قطعیت ارتباط پارامترهای آبستتگی در سازه‌های کنترل شیب باعث شده‌اند تا مدل‌سازی میزان آبستتگی در سازه‌های کنترل شیب، غیرخطی و پیچیده باشد. به دلیل همین پیچیدگی‌ها، در این تحقیق از روش‌های هوش مصنوعی (ANN، ANFIS، SVM) به‌عنوان مدل‌های جعبه سیاه که به اطلاعات فیزیکی پدیده نیاز چندانی ندارند استفاده شده است. آنالیز حساسیت نسبت به داده‌های ورودی (پارامترهای مدل) در روش‌های هوش مصنوعی به عنوان لایه ورودی تحلیل شده‌اند. در این تحقیق، کلیه ابزارهای مورد استفاده در محیط Matlab کدنویسی و توسعه داده شدند.

برای تعیین لایه ورودی هر سه مدل ANN، ANFIS، SVM از پارامترهای عرض سرریز (b)، ارتفاع ریزش آب (Z)، ارتفاع آب روی تاج (h₀)، اختلاف ارتفاع آب در بالادست و پایین دست (H)، قطر متوسط ذرات (d_m)، عمق آب در پایین دست (h)، دبی جریان در واحد عرض (q)، عدد فرود جریان در بالادست (Fr1) و عدد فرود جریان در پایین دست (Fr2) به عنوان ورودی‌های مدل‌ها امتحان شدند تا

برای محاسبه W و b لازم است تابع خطا (معادله ۳) در مدل ε-SVM با در نظر گرفتن شرایط مندرج (قیود) در معادله ۴ بهینه شود.


$$\frac{1}{2}W^T W + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^* \quad (3)$$

$$\begin{aligned} W^T \cdot \phi(x_i) + b - y_i &\leq \varepsilon + \xi_i^* \\ y_i - W^T \cdot \phi(x_i) - b &\leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* &\geq 0, \quad i = 1, 2, \dots, N \end{aligned} \quad (4)$$

که C عددی صحیح و مثبت است و عامل تعیین جرمه در هنگام رخ دادن خطای آموزش مدل است. N تعداد نمونه‌ها و دو مشخصه ξ و ξ^* متغیرهای

کمکی هستند که حد بالا و پایین خطای آموزش مرتبط با مقدار خطای مجاز ε را مشخص می‌کنند.

در حل مسائل، داده‌ها درون بازه مرزی ε قرارگیرند، در صورتی که داده‌ها خارج از بازه ε قرار بگیرد آنگاه یک خطا معادل ξ و ξ^* وجود خواهد داشت (شکل ۲).



شکل 2 مدل SVM رگرسیونی (۲۵).

یک الگوریتم استاندارد برای حل معادله ۳ در مدل SVM، معرفی یک مجموعه دوتایی ضریب لاگرانژ α_i و α_i^* برای حل ساده مسائل با بهینه‌سازی عددی تابع درجه دوم می‌باشد. پس از تعیین ضرایب لاگرانژ، پارامترهای W و b را می‌توان با استفاده از شرایط تئوری کاروش - کوهن - تاکر تخمین زد (۲۶). در نتیجه، تابع تقریبی را می‌توان به صورت ۵ نوشت:

$$f(x) = \sum_{i,j=1}^N (\alpha_i - \alpha_i^*) \phi(x_i^T) \phi(x_j) + b \quad (5)$$

در معادله ۵، α_i میانگین ضرایب لاگرانژ است. محاسبه $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد. برای حل این مشکل روند معمول در مدل SVM، انتخاب یک تابع کرنل به صورت $K(x_i, x_j) = \phi(x_i^T) \cdot \phi(x_j)$ به کار برده می‌شود.

از توابع مختلف کرنل می‌توان برای ساخت انواع مختلف ε-SVM استفاده کرد. انواع توابع کرنل مورد استفاده در این تحقیق در مدل SVM رگرسیونی شامل کرنل چندجمله‌ای (Polynomial) با سه

شامل تعداد لایه مخفی، تعداد تکرار، حداقل جذر میانگین مربعات خطاها و ضریب تبیین می‌باشد، در جدول ۲ آورده شده است.

جدول ۲ نتایج مدل‌سازی محاسبات عمق آبشستگی پایین‌دست سازه‌های کنترل شیب با سرریز لبه تیز در مقابل مشاهدات با استفاده از مدل ANN

TRAIN	
RMSE	NS
0.092156	0.608
VERIFY	
RMSE	NS
0.122159	0.452
TRAIN	
RMSE	NS
0.081129	0.803
VERIFY	
RMSE	NS
0.091259	0.631
TRAIN	
RMSE	NS
0.041044	0.927
VERIFY	
RMSE	NS
0.064917	0.740
TRAIN	
RMSE	NS
0.089236	0.782
VERIFY	
RMSE	NS
0.096254	0.596

۲-۳- نتایج مدل ANFIS

نمودار پراکنش مقادیر مشاهداتی و محاسباتی برای عمق آبشستگی پایین‌دست سازه‌های کنترل شیب با سرریز لبه تیز، با انتخاب حالت‌های مختلف مدل ANFIS که مهمترین آنها تنظیم تعداد تکرار، تابع عضویت و تعداد تابع عضویت می‌باشد، در شکل ۴ نشان داده شده است.

توابع عضویت مورد استفاده در این تحقیق تابع گوسی (gussmf)، تابع ترکیبی گوسی (gauss2mf)، تابع دوزنقه‌ای (trapmf)، تابع مثلثی شکل (trimf)، تابع زنگوله‌ای (gbellmf)، تابع π شکل (pimf)، تفاضل دو تابع حلقوی (dsigmf) و حاصل ضرب دو تابع حلقوی (psigmf) بوده‌اند. مقادیر بهینه تعداد تابع عضویت، نوع تابع عضویت، حداقل جذر میانگین مربعات خطاها و ضریب تبیین در جدول ۳ نشان داده شده است. بر اساس جدول مذکور مدل ANFIS از

بهترین ورودی برای مدل‌سازی تعیین گردد. چهار ترکیب به شرح زیر به عنوان لایه ورودی مطرح شدند:

Comb. (1): $b/z, h_0/H$

Comb. (2): $b/z, h_0/H, Fr_1, Fr_2$

Comb. (3): $b/z, h_0/H, d_m/h$


Comb. (4): $b/z, h_0/H, d_m/h, Fr_1, Fr_2$

به منظور افزایش دقت پیش‌بینی مدل‌های هوش مصنوعی، داده‌های ورودی نرمال‌سازی و به کار گرفته شد. در کلیه مدل‌ها ۷۰ درصد داده‌های هر ترکیب به عنوان واسنجی و ۳۰ درصد داده‌ها نیز برای تست به کار گرفته شده‌اند و بهترین ترکیب ورودی برای هر مدل هوش مصنوعی به صورت مجزا تعیین می‌گردد. به منظور آنالیز حساسیت به پارامترهای موثر در عمق آبشستگی، کلیه پارامترها در هر سه مدل پیشنهادی بررسی شد.

۳-۱- نتایج مدل ANN

در این تحقیق از الگوریتم لونیگ - مارکارت برای آموزش ANN استفاده شد (۲۷). به منظور تعیین بهترین ورودی مدل شبکه عصبی کلیه ترکیب‌های ورودی آزمون و بهترین ورودی برای مدل، ترکیب شماره ۳ تعیین گردید. با وجود تأثیرات عدد فرود به دلیل اینکه در شبکه عصبی تعداد پارامترهای ورودی بیشتر می‌تواند منجر به خطای بیشتر در ارزیابی مدل گردد و همچنین تأثیرات مستقیم پارامترهای دیگر در ترکیب ۳ به‌نوعی می‌تواند بیانگر عدد فرود گردد.

در شکل ۳، نمودار پراکنش مشاهدات و محاسبات میزان عمق آبشستگی در پایین‌دست سازه‌های کنترل شیب با سرریز لبه تیز با استفاده از مدل ANN نشان داده شده است.



شکل ۳ نمودار پراکنش محاسبات عمق آبشستگی

پایین‌دست سازه‌های کنترل شیب با سرریز لبه تیز در

مقابل مشاهدات با استفاده از مدل ANN

مقادیر بهینه پارامترهای مدل ANN برای تعیین میزان عمق آبشستگی در پایین‌دست سرریزهای منتهی به پرتاب‌کننده جامی که

VERIFY				
M	F		RMSE	NS
		Trimf	0.0417	0.893
	2		27	
TRAIN				
M	F		RMSE	NS
		Gauss2	0.0399	0.916
	2	mf	8	
VERIFY				
M	F		RMSE	NS
		Gauss2	0.0512	0.786
	2	mf	35	

Comb. (4)

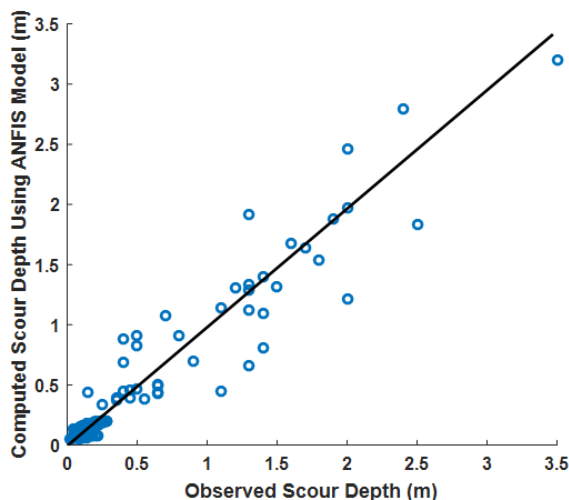
۳-۳- نتایج مدل SVM

به منظور مدل‌سازی عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز، از کرنل‌های رایج مدل SVM که شامل کرنل خطی، کرنل چند جمله‌ای و کرنل تابع پایه شعاعی است، استفاده شد. مقادیر بهینه کرنل‌ها که با سعی و خطا مشخص شدند در جدول ۴ نشان داده شده‌است. بر اساس جدول ۴، کرنل تابع پایه شعاعی نسبت به کرنل خطی و چند جمله‌ای از دقت بیشتری برخوردار است. نمودار پراکنش مقادیر مشاهداتی و محاسباتی برای عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز، با استفاده از مدل SVM و انتخاب کرنل RBF، در شکل ۵ نشان داده شده است.

جدول ۴ نتایج مدل‌سازی محاسبات عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز در مقابل مشاهدات با استفاده از مدل SVM

TRAIN				
			RMSE	NS
		Linear	0.033785	0.951
		Polynomial	0.036815	
		RBF	0.042529	
VERIFY				
			RMSE	NS
		Linear	0.081281	0.593
		Polynomial	0.061510	0.767
		RBF	0.05373	0.822
		5		
TRAIN				
			RMSE	NS
Comb. (2)		Linear	0.035862	0.892

توانایی مناسبی برای پیش بینی میزان عمق آبشستگی در پایین دست سازه‌های کنترل شیب با سرریز لبه تیز برخوردار است.




شکل ۴ نمودار پراکنش محاسبات عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز در مقابل مشاهدات با استفاده از مدل ANFIS

جدول ۳ نتایج مدل‌سازی محاسبات عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز در مقابل مشاهدات با استفاده از مدل ANFIS

TRAIN				
M	F		RMSE	NS
		Psigmf	0.0398	0.852
	2		52	
VERIFY				
M	F		RMSE	NS
		Psigmf	0.0596	0.701
	2		23	
TRAIN				
M	F		RMSE	NS
		Trimf	0.0342	0.946
	2		8	
				6
VERIFY				
M	F		RMSE	NS
		Trimf	0.0441	0.813
	2		24	
TRAIN				
M	F		RMSE	NS
Comb. (3)		Trimf	0.0331	0.952
	2		8	

فرض استفاده از پارامترهای کمتر مثل ترکیب شماره ۱ و استفاده از پارامترهای بیشتر مثل ترکیب ۴ که خطاهای بیشتری به مدل وارد می‌کند، مطابقت دارد. از بین سه مدل مذکور، روش ANFIS نسبت به مدل‌های ANN و SVM از دقت بیشتری برخوردار است که می‌تواند از ناشی از غلبه بر عدم قطعیت‌ها در سیستم فازی در نظر گرفته شود و این موضوع با پژوهش‌های محققین در زمینه‌های هیدرولوژی و هیدروژئولوژی مطابقت کامل دارد (۲۸، ۲۹). در کلیه مدل‌ها مشاهده می‌گردد استفاده از تعداد پارامترهای خیلی زیاد کارایی مدل‌ها را کاهش می‌دهد که ناشی از ورود تعداد خطاهای جزئی بیشتر به وردی مدل‌ها می‌باشد. در این تحقیق، با در نظر گرفتن ۶ پارامتر برای مدل‌های جعبه سیاه بهترین نتیجه حاصل شد.




شکل ۵ نمودار پراکنش محاسبات عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز در مقابل مشاهدات با استفاده از مدل SVM

به‌منظور مقایسه بیشتر روش‌های مورد بررسی در این تحقیق با سایر روش‌های رایج و انجام شده، از نتایج تحقیق انجام شده در منبع (۱۰) استفاده شد. در شکل ۶ کارایی مدل‌های هوش مصنوعی نسبت به سایر روش‌ها نشان داده شده است. همانند روش الگوریتم بیان ژن، روش‌های ANN، ANFIS و SVM در تخمین میزان عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز نسبت به روش‌های تجربی از دقت بیشتری برخوردار هستند. همچنین، در مقایسه با روش الگوریتم بیان ژن، روش ANFIS نسبت به دو روش دیگر بررسی شده در این تحقیق (ANN، ANFIS) از کارایی نسبتاً بیشتری برخوردار است. علت افزایش دقت مدل سیستم عصبی فازی تطبیقی نسبت به سایر مدل‌ها می‌تواند مربوط به استفاده این مدل از توانایی هر دو روش شبکه عصبی و منطق فازی باشد که در آن عدم قطعیت-هایی که در مدل‌سازی سازه‌های کنترل شیب با سرریز لبه تیز وجود دارد، پوشش داده می‌شود.

Comb. (3)	Polynomialia 1	0.036895	0.863
	RBF	0.046259	0.854
	VERIFY		
	RMSE		NS
	Linear	0.086958	0.522
	Polynomialia 1	0.072563	0.598
	RBF	0.05982	0.792
	5		
	TRAIN		
	RMSE		NS
Comb. (4)	Linear		0.951
	Linear	0.033785	
	Polynomialia 1	0.036815	0.941
	RBF	0.042529	0.922
	VERIFY		
	RMSE		NS
	Linear	0.081281	0.593
	Polynomialia 1	0.061510	0.767
	RBF	0.05373	0.822
	5		
TRAIN			
RMSE		NS	
Comb. (4)	Linear		0.822
	Linear	0.036298	
	Polynomialia 1	0.039532	0.811
	RBF	0.049985	0.803
	VERIFY		
	RMSE		NS
	Linear	0.094526	0.506
	Polynomialia 1	0.084625	0.520
	RBF	0.06325	0.700
	9		

نتایج مدل‌های ANN، ANFIS و SVM نشان می‌دهند که روش‌های هوش مصنوعی در برآورد میزان عمق آبشستگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز از قابلیت مناسبی برخوردار هستند. آنالیز حساسیت نسبت به پارامترهای ورودی در هر سه مدل پیشنهادی نشان می‌دهد که اعمال پارامترهای عرض سرریز، ارتفاع ریزش آب، ارتفاع آب روی تاج، اختلاف ارتفاع آب در بالادست و پایین دست، قطر متوسط ذرات و عمق آب در پایین دست، کارایی مدل‌ها را بهبود می‌دهد. این موضوع به دلیل اعمال خطاهای ورودی مدل‌ها با



شکل ۶ مقایسه کارایی روشهای تجربی، الگوریتم بیان ژن و روشهای هوش مصنوعی در تخمین عمق آبستنگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز

b	ثابت مشخصه‌های تابع رگرسیونی
ϕ	تابع کرنل
C	عدد صحیح و مثبت
ξ	حد بالای خطای آموزش
ξ^*	حد پایین خطای آموزش
ε	خطای مجاز
α_i, α_i^*	ضرایب لاگرانژ
K	تابع کرنل
DC	ضریب تبیین
MSE	میانگین مربع خطاها
RMSE	جذر میانگین مربع خطاها
MAE	میانگین مطلق خطاها
SEP	درصد خطاهای استاندارد
X_{obs}	مقدار واقعی
X_{pre}	مقدار تخمینی
\bar{X}_{obs}	مقدار متوسط
b	عرض سرریز
z	ارتفاع ریزش آب
h0	ارتفاع آب روی تاج
H	اختلاف ارتفاع آب
dm	قطر متوسط ذرات
Fr1	عدد فرود جریان در بالادست
Fr2	عدد فرود جریان در پایین دست

ملاحظات اخلاقی پیروی از اصول اخلاق پژوهش

همکاری مشارکت‌کنندگان در تحقیق حاضر به صورت داوطلبانه و با رضایت آنان بوده است.

نتیجه‌گیری

عدم قطعیت پارامترهای فیزیکی فرایند عمق آبستنگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز، نتایج مدل‌سازی را تحت تأثیر قرار می‌دهند. در این تحقیق از توانایی‌های مدل‌های هوش مصنوعی (ANN, ANFIS, SVM) به عنوان یک مدل جعبه سیاه استفاده شده است. نتایج مدل‌سازی میزان عمق آبستنگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز با استفاده از مدل‌های هوش مصنوعی نشان می‌دهد که کارایی مدل‌های شبکه عصبی، سیستم عصبی-فازی تطبیقی و بردار ماشین پشتیبان در پیش بینی مقادیر آبستنگی مناسب می‌باشند که این امر می‌تواند به علت غیرخطی و پیچیده بودن طبیعت مسئله باشد. نتایج تحقیق نشان داد که روش‌های هوش مصنوعی از کارایی مناسبتری نسبت به روش‌های تجربی رایج در زمینه برآورد میزان عمق آبستنگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز دارند. استفاده از تعداد پارامترهای بیشتر در ورودی مدل‌های هوش مصنوعی دقت این مدل‌ها را افزایش نمی‌دهد که این مسئله می‌تواند به دلیل ورود خطای بیشتر به این مدل‌ها باشد و بایستی به صورت محتاطانه پارامترهای ورودی انتخاب شوند. در این تحقیق، با در نظر گرفتن ۶ پارامتر برای مدل‌های جعبه سیاه بهترین نتیجه حاصل شد. در تخمین میزان عمق آبستنگی پایین دست سازه‌های کنترل شیب با سرریز لبه تیز در هر دو مرحله واسنجی و صحت سنجی، مدل ANFIS نسبت به مدل ANN تا ۲۰ درصد و نسبت به مدل SVM تا ۸/۵ درصد قابلیت اطمینان بیشتری دارد که این امر می‌تواند به دلیل توانایی تئوری فازی در غلبه بر نامعینی فرایند باشد.

۵- فهرست علائم

x, y	پارامترهای ورودی
A	تابع عضویت X
B	تابع عضویت Y
p, q, r	پارامترهای تابع خروجی
W	بردار ضرایب

هزینه تحقیق حاضر توسط نویسندگان مقاله تامین شده است.

هزینه تحقیق حاضر توسط نویسندگان مقاله تامین شده است.

مشارکت نویسندگان

طراحی و ایده‌پردازی: شهرام موسوی؛ روش‌شناسی و تحلیل داده‌ها: شهرام موسوی؛ نظارت و نگارش نهایی: شهرام موسوی.

مشارکت نویسندگان

طراحی و ایده‌پردازی: شهرام موسوی؛ روش‌شناسی و تحلیل داده‌ها: شهرام موسوی؛

تعارض منافع

بنابر اظهار نویسندگان، مقاله حاضر فاقد هرگونه تعارض منافع بوده است.

تعارض منافع

بنابر اظهار نویسندگان، مقاله حاضر فاقد هرگونه تعارض منافع بوده است.

حامی مالی

References

1. D'Agostino, V., and Ferro, V. (2004). Scour on alluvial bed downstream of grade-control structures. *Journal of Hydraulic Engineering*, 130(1), 24-37.
2. Doddiah, D., Albertson, M. L., and Thomas, R. ~1953!. "Scour from jets." *Proc., 5th Congr. Int. Assoc. for Hydraulic Res., Minneapolis, September*, 161-169.
3. Rouse, H. ~1940!. "Criteria for similarity in the transportation of sediment." *Studies in engineering bull., Univ. of Iowa*, 20, 33-49.
4. Mason, P. J., and Arumugam, K. ~1985!. "Free jet scour below dams and flip buckets." *J. Hydraul. Eng.*, 111~2!, 220-235.
5. Hoffmans, G.J.C.M. 1998. Jet scour in equilibrium phase. *Journal of Hydraulic Engineering.*, 124(4): 430-437.
6. Rajaratnam, N., and Mazurek, K. 2003. Erosion of sand by circular impinging water jets with small tailwater. *Journal of Hydraulic Engineering.*, 129(3):225-229.
7. Salehzadeh, M., Hemmati, M., Yasi, M., & Lanzoni, S. (2021). The Effect of Height and Crest Slope of the Submerged Weirs on Erosion and Sedimentation Pattern in a [90]^o Sharp Bend. *Iranian Journal of Soil and Water Research*, 52(3), 621-633.
8. Solbi, M., Dehghani, A. A., Meftah Halaghi, M., & Zahiri, A. Z. (2021). Estimation of maximum scour depth downstream of stilling basin (Case study: Masonary check dam of Ziarat basin). *Journal of Hydraulics*, 16(1), 81-92.
9. Ahadiyan, J. (2020). Experimental investigation of the effective parameters in design of non-phase hydraulic jet in reduction of 90 degrees bend scour. *Modares Civil Engineering journal*, 20(4), 179-190.
10. Roushangar, K., Akhgar, S., Erfan, A., and Shiri, J. (2016). Modeling scour depth downstream of grade-control structures using data driven and empirical approaches. *Journal of Hydroinformatics*, 18(6), 946-960.
11. Nourani, V., Mousavi, S., Sadikoglu, F., and Singh, V. P. (2017). Experimental and AI-based numerical modeling of contaminant transport in porous media. *Journal of contaminant hydrology*, 205, 78-95.
12. Singh, R. M. and Datta, B. (2007), Artificial Neural Network Modeling for Identification of Unknown Pollution Sources in Groundwater with Partially Missing Concentration Observation Data, *Water Resources Management*, 21, 557-572.
13. Nourani, V., Mogaddam, A. A. and Nadiri, A. O. (2008), An Ann-Based Model for Spatiotemporal Groundwater Level Forecasting, *Hydrological Processes*, 22, 5054-5066.
14. Li, X. and Tsai, F. T.-C. (2009), Bayesian Model Averaging for Groundwater Head Prediction and Uncertainty Analysis Using Multimodel and Multimethod, *Water resources research*, 45(9).
15. Taormina, R. and Chau, K.-W. (2014), Neural Network River Forecasting with Multi-Objective Fully Informed Particle Swarm Optimization, *Journal of Hydroinformatics*, 17(1), 99-113.
16. Foddis, M. L., Ackerer, P., Montisci, A. and Uras, G. (2015), Ann-Based Approach for

- the Estimation Aquifer Pollutant Source Behaviour, Water Science and Technology: Water Supply, 15(6), 1285-1294.
17. Nourani, V., Alami, M. T. and Vousoughi, F. D. (2015), Wavelet-Entropy Data Pre-Processing Approach for Ann-Based Groundwater Level Modeling, 524, 255-269
 18. Nourani, V. and Andalib, G. (2015), Daily and Monthly Suspended Sediment Load Predictions Using Wavelet Based Artificial Intelligence Approaches, Journal of Mountain Science, 12(1), 85-100.
 19. Govindaraju, R. S. (2000), Artificial Neural Networks in Hydrology. Ii: Hydrologic Applications, Journal of Hydrologic Engineering, 5, 124-137.
 20. Hornik, K., Stinchcombe, M. and White, H. (1989), Multilayer Feedforward Networks Are Universal Approximators, Neural Networks, 2, 359-366.
 21. Jang, J.-S. R., Sun, C.-T. and Mizutani, E. (1997), Neuro-Fuzzy and Soft Computing; a Computational Approach to Learning and Machine Intelligence, Prentice-Hall.
 22. Kacprzyk, J. and Pedrycz, W. (2015), Springer Handbook of Computational Intelligence, Springer.
 23. Jang, J.-S. R. and Sun, C.-T. (1995), Neuro-Fuzzy Modeling and Control, Proceedings of the IEEE, 83, 378-406.
 24. Cortes, C., and Vapnik, V. (1995). Support-vector networks. Machine learning, 20(3), 273-297.
 25. Chen, S. T., and Yu, P. S. (2007). Real-time probabilistic forecasting of flood stages. Journal of Hydrology, 340(1-2), 63-77.
 26. Legates, D. R. and McCabe, G. J. (1999), Evaluating the Use of 'Goodness-of-Fit' Measures in Hydrologic and Hydroclimatic Model Validation, Water Resources Research, 35, 233-241.
 27. Haykin, S. and Lippmann, R. (1994), Neural Networks, a Comprehensive Foundation, International Journal of Neural Systems, 5, 363-364.
 28. Nourani, V., & Mousavi, S. (2016). Spatiotemporal groundwater level modeling using hybrid artificial intelligence-meshless method. Journal of Hydrology, 536, 10-25.
 29. Nourani, V., & Komasi, M. (2013). A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. Journal of Hydrology, 490, 41-55.

