



Experimental study of flow resistance in the presence of rigid vegetation and its prediction with intelligent models

Yaser Mehri¹ | Mohammad Hosein Omid² | Salah Kouchakzadeh³ | Mohsen Nasrabadi⁴

1. Corresponding Author, Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail: yaser.mehri@ut.ac.ir
2. Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail: momid@ut.ac.ir
3. Department of Irrigation and Reclamation Engineering, College of Agriculture and Natural Resources, University of Tehran, Karaj, Iran. E-mail: skzadeh@ut.ac.ir
4. Department of Water Science and Engineering, Arak University, Arak, Iran. E-mail: m-nasrabadi@araku.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Feb. 12, 2024

Revised: March. 9, 2024

Accepted: March. 14, 2024

Published online: Sep. 2024

Keywords:

Machine Learning,
Laboratory Investigation,
Modeling,
Gradually Varied Flow,
Roughness.

ABSTRACT

Determining the resistance coefficients and reducing the uncertainty in selecting this parameter is one of the most essential factors in achieving the flow characteristics in rivers and open channels. Therefore, the appropriate selection of roughness coefficient in different conditions, such as vegetation, has been one of the important research topics. This research first determined the Manning's roughness coefficient in a laboratory flume with different vegetation arrangements. Then, the ability of five intelligent models, including GMDH, ANN-RBF, RT, ANFIS, and ANFIS-PSO, to predict the Manning's roughness coefficient was evaluated. The models were coded in the MATLAB software. Due to the creation of a gradually varied flow in the laboratory flume, the water level profile obtained through Euler's method was compared with the experimental values. The results showed an acceptable agreement between the experimental water level profiles and the estimates made by Euler's method. The evaluation of the results based on the statistics showed that the ANFIS-PSO model performs better than other models in predicting the Manning's coefficient. Hence, the results of this model are RMSE=0.0096, $R^2=0.9984$ and KGE=0.9922 in the training phase and RMSE=0.0099, $R^2=0.9982$ and KGE=0.9873 in the test phase. The ANN-RBF, GMDH, ANFIS, and RT models are in the next ranks. By evaluating the results of different combinations in modeling, it was found that three parameters of vegetation density (D), vegetation arrangement (N) and Reynolds number (Re) had, respectively, significant effect in estimating the correct results.

Cite this article: Mehri, Y., Omid, M. H., Kouchakzadeh, S., & Nasrabadi, M. (2024). Experimental study of flow resistance in the presence of rigid vegetation and its prediction with intelligent models, *Iranian Journal of Soil and Water Research*, 55 (7), 1167-1183.

© The Author(s).

Publisher: The University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2024.372519.669665>



مطالعه آزمایشگاهی مقاومت جریان در حضور پوشش گیاهی صلب و پیش‌بینی آن با مدل‌های هوشمند

ياسر مهري^۱ | محمدحسين اميد^۲ | صلاح كوچكزاده^۳ | محسن نصرآبادي^۴۱. نویسنده مسئول، گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: yaser.mehri@ut.ac.ir۲. گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: momid@ut.ac.ir۳. گروه مهندسی آبیاری و آبادانی، دانشکده‌گان کشاورزی و منابع طبیعی، دانشگاه تهران، کرج، ایران. رایانامه: skzadeh@ut.ac.ir۴. گروه علوم و مهندسی آب، دانشگاه اراک، اراک، ایران. رایانامه: m-nasrabadi@araku.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	تعیین ضرایب مقاومت و کاهش عدم قطعیت در انتخاب این پارامتر یکی از مهم‌ترین عوامل دستیابی به مشخصات جریان در رودخانه‌ها و مجاری روباز است. از این رو، انتخاب مطلوب ضریب زبری در شرایط مختلف مانند وجود پوشش گیاهی از جمله موضوعات مورد توجه پژوهشگران بوده است. در این پژوهش، ابتدا ضریب زبری مانینگ در یک فلوام آزمایشگاهی با حضور آرایش‌های مختلف پوشش گیاهی تعیین شد. سپس توانایی پنج مدل هوشمند شامل GMDH، ANN-RBF، ANFIS، RT، ANFIS-PSO و ANFIS در پیش‌بینی ضریب زبری مانینگ ارزیابی شد. مدل‌ها در محیط نرم‌افزار MATLAB کدنویسی شد. با توجه به ایجاد جریان متغیر تدریجی در کانال آزمایشگاهی، نیم‌رخ سطح آب به‌دست آمده از طریق حل به روش اویلر، با مقادیر اندازه‌گیری شده در آزمایشگاه مقایسه شد. نتایج نشان داد که تطابق قابل قبول بین پروفیل سطح آب آزمایشگاهی و برآوردهای انجام شده با روش اویلر وجود دارد. ارزیابی نتایج مدل‌ها بر اساس تحلیل آماری به کاررفته نشان داد که مدل ANFIS-PSO عملکرد بهتری نسبت به سایر مدل‌ها در پیش‌بینی ضریب مانینگ دارد، به طوری که نتایج این مدل $RMSE=0.0096$ ، $R^2=0.9984$ و $KGE=0.9922$ در مرحله آموزش و $RMSE=0.0099$ ، $R^2=0.9982$ و $KGE=0.9873$ در مرحله آزمون است. در مراتب بعد، از لحاظ دقت به ترتیب مدل‌های ANN-RBF، GMDH، ANFIS و RT قرار می‌گیرند. با ارزیابی نتایج ترکیب‌های مختلف در مدل‌سازی مشخص شد، سه پارامتر تراکم پوشش گیاهی (D)، آرایش پوشش گیاهی (N) و عدد رینولدز (Re) به ترتیب تاثیر بیشتری در ارائه نتایج درست داشتند.
واژه‌های کلیدی: یادگیری ماشین، بررسی آزمایشگاهی، مدل‌سازی، جریان متغیر تدریجی، زبری.	

استناد: مهري، ياسر؛ اميد، محمد حسين؛ كوچكزاده، صلاح؛ نصرآبادي، محسن (۱۴۰۳). مطالعه آزمایشگاهی مقاومت جریان در حضور پوشش گیاهی صلب و پیش‌بینی

آن با مدل‌های هوشمند، مجله تحقیقات آب و خاک ایران، ۵۵ (۷)، ۱۱۶۷-۱۱۸۳.

ناشر: مؤسسه انتشارات دانشگاه تهران.

© نویسندگان.

DOI: <https://doi.org/10.22059/ijswr.2024.372519.669665>

مقدمه

یکی از مسائل مهم در مهندسی رودخانه تخمین ضریب مقاومت جریان است. پیش‌بینی دقیق شرایط جریان وابسته به ضریب مانینگ در کانال‌ها و رودخانه‌ها است. از این رو، محاسبه دقیق ضریب مانینگ کاربرد فراوانی در طراحی، نگهداری، بهره‌برداری کانال‌های باز و همچنین پیش‌بینی مشخصات سیل دارد (Pradhan and Khatua, 2018). با توجه به ملاحظات اقتصادی اگر زبری تخمین زده شده کم باشد منجر به محاسبه بیش از حد دبی، برآورد سطح سیلاب و طراحی نادرست سازه‌ها با هزینه‌های بیش از حد در طرح‌های کنترل فرسایش می‌شود (Ladson et al., 2002).

از عوامل افزایش ضریب زبری وجود پوشش گیاهی است، از این رو، حضور پوشش گیاهی در بستر رودخانه‌ها باید در طراحی‌ها لحاظ شود. رشد گیاهان در بستر رودخانه‌ها یا کانال‌ها سبب افزایش سطح جریان و کاهش سرعت و ظرفیت انتقال از این مجاری می‌شود. در ساماندهی رودخانه‌ها در گذشته، پوشش گیاهی به دلیل انسداد رودخانه و ایجاد طغیان، عاملی نامطلوب محسوب می‌شد و به‌طور معمول با روش‌های مختلف حذف می‌شد. اما با توجه به نگاه جدید محیط‌زیستی به سامانه‌های آبی، حفظ پوشش گیاهی و احیای محیط‌زیست رودخانه‌ها مورد توجه قرار گرفته است. پوشش گیاهی را می‌توان در شکل‌های مختلف در کانال‌ها و رودخانه‌ها مشاهده کرد (Cheng and Nguyen, 2011; Cornacchia et al., 2019; Coscarella et al., 2021).

پژوهش‌های مرتبط با حضور پوشش گیاهی در آبراهه‌ها اغلب با فرض جریان یکنواخت انجام شده است. به عبارت دیگر، با ایجاد جریان شبه‌یکنواخت در مجرا نسبت به تعیین ضریب زبری اقدام شده است (Zhang et al., 2019). افزون بر این، پژوهش‌های محدودی بر روی آرایش‌های مختلف پوشش گیاهی انجام شده است. Díaz (2005) با بررسی آزمایشگاهی با استفاده از پوشش گیاهی مصنوعی و نیز مطالعات میدانی، ضریب زبری مانینگ را در جریان‌های کم‌عمق در آبراهه‌ها مورد بررسی قرار داد. او همچنین نشان داد که ضریب زبری علاوه بر عمق، به شیب کانال و عدد فرود نیز بستگی دارد. (Gu et al., 2007) با بررسی آزمایشگاهی، ضریب مانینگ را در حضور گیاه نی در شرایط مستغرق و آزاد مورد بررسی قرار دادند. آن‌ها نتیجه گرفتند که توزیع سرعت در میان پوشش گیاهی به‌تقریب ثابت است. همچنین یک رابطه تجربی بین ضریب مانینگ و عمق جریان در شرایط آزاد ارائه دادند. افزون بر این، تاثیر تراکم پوشش گیاهی در شرایط مستغرق را مورد بررسی قرار دادند. Wu (2008) با بررسی آزمایشگاهی و تحلیلی، رابطه‌ای برای محاسبه ضریب زبری مانینگ در حضور پوشش گیاهی بدست آورد. او نتیجه گرفت ضریب زبری مانینگ با افزایش عمق و تراکم، افزایش پیدا می‌کند. افزون بر این، وی نتیجه گرفت که توزیع سرعت با وجود پوشش گیاهی با توزیع لگاریتمی سرعت مطابقت ندارد. (Noarayanan et al., 2012) مطالعه آزمایشگاهی جامعی برای ارزیابی مقاومت هیدرولیکی پوشش گیاهی مصنوعی انعطاف‌پذیر انجام دادند. آزمایش‌ها بر روی اندازه‌های مختلف قطر و چگالی انجام شد. نتایج نشان داد که مقاومت جریان با چگالی پوشش گیاهی، قطر و خواص کشسانی آن‌ها و سرعت جریان تغییر می‌کند. در تحقیق یادشده بر اساس داده‌های آزمایشگاهی، ضریب مانینگ برای شرایط مختلف جریان تعیین شد و یک معادله تجربی جدید برای ارزیابی ضریب زبری مانینگ، n ، برای جریان نیمه مستغرق، زمانی که عمق جریان بیشتر از 0.8 برابر ارتفاع گیاه است، پیشنهاد شد. Li et al., (2014) اثر پوشش گیاهی انعطاف‌پذیر مستغرق را بر ساختار جریان (سرعت جریان، تنش برشی رینولدز، شدت آشفتگی و ضریب مانینگ) به‌طور تجربی با یک سرعت‌سنج آکوستیک داپلر سه‌بعدی (ADV) در یک فلوم مورد مطالعه قرار دادند. نتایج حاصل از مشاهدات جریان بر روی پوشش گیاهی نشان داد که ساختار جریان به‌طور قابل‌توجهی با حضور پوشش گیاهی انعطاف‌پذیر مستغرق تحت تاثیر قرار می‌گیرد. همچنین، معادلات ریاضی جدیدی برای بیان تغییرات در پروفیل سرعت، ضریب مانینگ و نسبت دبی جریان با تراکم پوشش گیاهی مختلف ارائه شد. Zhang et al., (2019) یک رابطه‌ی تحلیلی برای محاسبه ضریب زبری مانینگ در کانال با پوشش گیاهی در حالت آزاد در جریان متغیر تدریجی ارائه کردند. این رابطه وابسته به ضریب درگ، عمق جریان، قطر پوشش گیاهی و درصد تراکم پوشش گیاهی بود.

به‌تازگی از روش‌های داده‌کاوی برای مدل‌سازی بسیاری از پدیده‌های مهندسی استفاده می‌شود. یکی از این روش‌ها، استفاده از هوش مصنوعی است که مزایایی مانند هزینه کم، سرعت پردازش بالا و دقت مناسب در شبیه‌سازی پدیده‌های هیدرولیکی دارد. در بررسی پدیده‌های هیدرولیکی به‌طور معمول نیاز به کار آزمایشگاهی است که هزینه و زمان زیادی نیاز دارد. بنابراین در کنار انجام تعداد محدودی آزمایش، می‌توان با استفاده از هوش مصنوعی پدیده موردنظر را با دقت مناسبی شبیه‌سازی کرد. از مدل‌های هوشمند می‌توان برای محاسبه ضریب مانینگ نیز استفاده کرد.

گرچه پژوهش‌های متنوعی در ارتباط با مدل‌سازی هوشمند در پیش‌بینی مشخصات جریان انجام شده است، ولی این‌گونه تحقیقات

در زمینه ضریب زبری مانینگ در حضور پوشش گیاهی محدود است. (Bahramifar et al., (2013 از مدل ANFIS و رگرسیون غیرخطی برای پیش‌بینی ضریب مانینگ استفاده کردند. در این تحقیق از پارامترهای اندازه متوسط ذرات بستر، شیب کف کانال و عمق جریان به‌عنوان پارامترهای ورودی استفاده شد. با مقایسه بین مدل ANFIS و مدل‌های رگرسیونی مشخص شد که مدل ANFIS دقت بالاتری دارد. این مدل با ضریب تعیین $R^2=0.74$ و $MSE=0.54$ توانست ضریب مانینگ را پیش‌بینی کند. (Roushangar et al., (2017 از حداقل مربعات ماشین بردار پشتیبان (LSSVM) که با استفاده از بهینه‌سازی ازدحام ذرات (PSO) بهینه شده بود برای پیش‌بینی ضریب زبری مانینگ استفاده کردند. نتایج نشان داد که برای تخمین ضریب زبری در کانال‌های باز با شکل‌های تلماسه، مدل‌های توسعه‌یافته بر اساس ویژگی‌های جریان و رسوب با موفقیت بیشتری عمل کردند به‌طوری که دقت مدل با ضریب تعیین برابر با $R^2=0.8609$ و $RMSE=0.0034$ بود. (Muhammad et al., (2018 کاربردهای شبکه عصبی مصنوعی (ANN) و برنامه‌ریزی بیان ژن (GEP) را برای پیش‌بینی ضریب مقاومت جریان (n) پوشش گیاهی ارزیابی کردند. با تحلیل ابعادی پارامترهای موثر شناسایی شد. معادله رگرسیون به دست آمده با مدل‌های ایجاد شده ANN و GEP مقایسه شد. نتایج نشان داد که مدل‌های ANN و GEP بر اساس شاخص‌های عملکرد، مقادیر n را بهتر پیش‌بینی می‌کنند. (Pradhan and Khatua (2018 از مدل GEP برای مدل‌سازی ضریب مانینگ در کانال پيچانرود مرکب استفاده کردند. در پژوهش ایشان از داده‌های آزمایشگاهی متعددی برای بررسی این مدل استفاده شد. در نهایت با توجه به دقت مدل نشان داده شد که این مدل، مدلی مناسب برای پیش‌بینی ضریب مانینگ در این شرایط است. (Yarahmadi et al., (2023 از چهار مدل MLPNN، GMDH، SVM و GP برای پیش‌بینی ضریب مانینگ در کانال آبرفتی با فرم بستر استفاده کردند. آن‌ها با استفاده از داده آزمایشگاهی و تعیین پارامترهای بی‌بعد موثر بر ضریب مانینگ مدل‌سازی را انجام دادند. نتایج نشان داد که همه مدل‌های هوشمند یادشده دقت مناسبی دارند و در بین این مدل‌ها، مدل SVM به‌عنوان برترین مدل شناخته شد.


هدف از تحقیق حاضر ارائه مدلی با دقت بالا برای تعیین ضریب مانینگ کانال با آرایش‌های مختلف پوشش گیاهی سخت (صلب) در شرایط جریان متغیر تدریجی است. روش‌های مختلفی برای محاسبه ضریب مانینگ وجود دارد که شامل مدل‌های آزمایشگاهی و هوشمند می‌شود. اگرچه مدل‌های هوشمند دارای دقت بالا، کم‌هزینه و سریع‌تر از کارهای آزمایشگاهی است ولی برای آموزش این مدل‌ها نیاز به داده‌های آزمایشگاهی است. با توجه به لزوم برآورد دقیق ضریب مانینگ در کانال‌ها برای طراحی مناسب، استفاده از روش‌های هوشمند در تعیین ضریب مانینگ می‌تواند مفید باشد. بر اساس تحقیقات قبلی، در این پژوهش از پنج مدل ANN-RBF، GMDH، RT، ANFIS و ANFIS-PSO برای پیش‌بینی ضریب مانینگ استفاده شد.

مواد و روش‌ها

در این پژوهش ۸۶ آزمایش در کانالی با پوشش گیاهی با آرایش‌های مختلف در شرایط جریان متغیر تدریجی انجام شد تا از این داده‌ها برای واسنجی و صحت‌سنجی مدل‌ها استفاده شود. سپس از ۵ مدل ANN-RBF، GMDH، RT، ANFIS و ANFIS-PSO برای پیش‌بینی ضریب مانینگ، استفاده شد. تمامی مدل‌ها در محیط نرم‌افزار MATLAB کدنویسی شدند. تمامی پارامترهای موثر بر ضریب مانینگ استخراج و به‌عنوان پارامترهای ورودی و خروجی در مدل‌سازی استفاده شد.

تجهیزات آزمایشگاهی


آزمایش‌های این تحقیق در آزمایشگاه مرکزی تحقیقات آب گروه مهندسی آبیاری و آبادانی دانشگاه تهران انجام شد. کانال موردبررسی دارای مقطع مستطیلی با عرض و ارتفاع ۰/۵ متر و طول ۱۲ متر است. کف کانال از جنس پلکسی گلاس و دیواره آن از جنس شیشه می‌باشد. شیب این فلوم ثابت و برابر با ۰/۰۰۲ است. برای تأمین جریان آب در این کانال از سامانه توزیع آب گردشی آزمایشگاه استفاده شد. در بالادست کانال به منظور کاهش تلاطم جریان ورودی از آرام‌کننده‌های مختلف استفاده شد. در انتهای کانال نیز دریچه تنظیم سطح آب در فاصله ۳ متری از انتهای بازه آزمایش قرار داشت. برای اطمینان از توسعه‌یافتگی جریان، کف کانال به طول حدود ۷ متر در ابتدا، قبل از محدوده آزمایش پوشش گیاهی، با ذرات درشت‌دانه زبر شد (شکل ۱). برای اندازه‌گیری دبی، از یک سرریز مثلثی، نصب‌شده در مخزن ورودی استفاده شد. عمق جریان نیز با عمق‌سنج ساخت شرکت نیرپیک با دقت ۰/۱ میلی‌متر اندازه‌گیری می‌شد. نمایی از کانال مورد استفاده در شکل (۲) و (۳) نشان داده شده است. آزمایش‌ها برای تراکم‌ها و آرایش‌های مختلف انجام شد و برای هر تراکم حداقل ۷ دبی مورد بررسی قرار گرفت. انواع آرایش‌ها و تراکم در حالت زیگزاگی و موازی به ترتیب در شکل‌های (۴) و (۵) نشان داده شده است. همچنین مشخصات کانال، جریان و پوشش گیاهی در جدول (۱) ارائه شده است.



شکل ۱. شماتیک کانال مورد بررسی



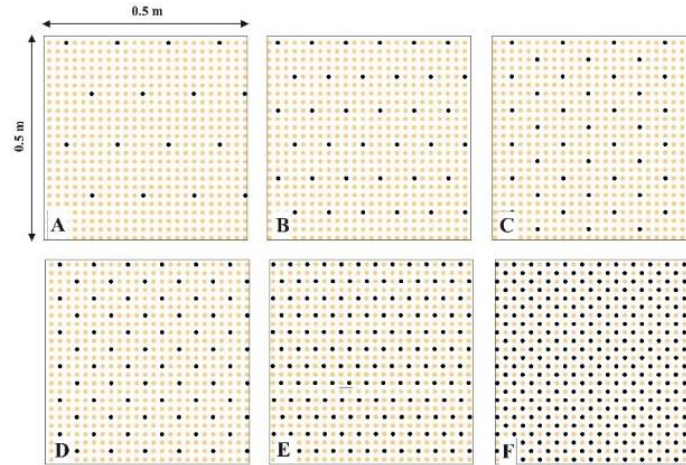
شکل ۲. فلوم مورد بررسی همراه با پوشش گیاهی صلب (جهت جریان از راست به چپ)



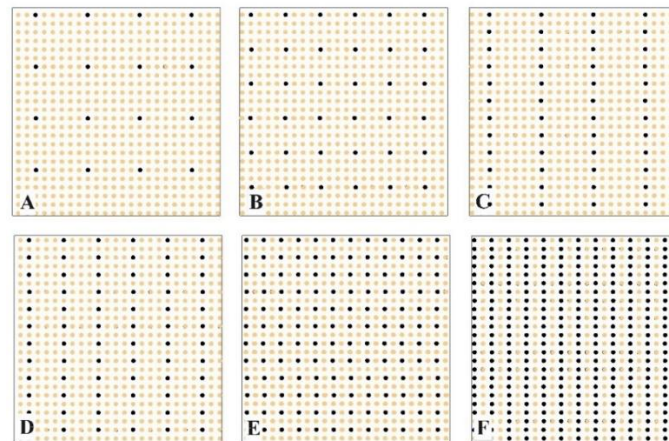
شکل ۳. نمایی از پوشش گیاهی مورد استفاده

جدول ۱. مشخصات کانال، جریان و پوشش گیاهی

محدوده	واحد	علامت	متغیر
۰/۵	M	B	عرض کانال
۰/۵	M	P	عمق کانال
۰/۰۰۲	-	S_0	شیب کانال
۳۰-۴	L/s	Q	دبی
۰/۰-۱۸/۳۹	-	Fr	عدد فروود
۰/۰۹۲ - ۰/۰۴۶ - ۰/۰۲۳ - ۰/۰۱۵ - ۰/۰۱۱ - ۰/۰۰۵	-	D	تراکم گیاه
۰/۰۱	M	d	قطر گیاه
۰/۳۰	M	L	ارتفاع گیاه
۲ و ۱	-	N	آرایش گیاه
۰/۳۱ الی ۰/۰۴	M	y	عمق جریان



شکل ۴. چیدمان آرایش زیگزاگی (N=1) پوشش گیاهی در آزمایش
 $(D_A = 0.005, D_B = 0.011, D_C = 0.015, D_D = 0.023, D_E = 0.046, D_F = 0.092)$



شکل ۵. چیدمان آرایش موازی (N=2) پوشش گیاهی در آزمایش
 $(D_A = 0.005, D_B = 0.011, D_C = 0.015, D_D = 0.023, D_E = 0.046, D_F = 0.092)$

مبانی جریان متغیر تدریجی

در این تحقیق از معادله‌ی حاکم بر جریان متغیر تدریجی (معادله ۱) استفاده شد (Henderson., 1996). با استفاده از روش عددی اویلر با استفاده از مشتق عمق جریان نسبت به طول، نرخ تغییرات عمق جریان محاسبه می‌شود که در آن i مقدار متغیرها در نقطه معلوم X_i و همچنین y' مشتق عمق نسبت به طول بوده و با استفاده از تابع f محاسبه می‌شود (معادلات ۱ و ۲). در این روابط نرخ تغییر عمق در نقطه X_i و y_i و با فرض تغییرات خطی عمق در حد فاصل X_i و X_{i+1} مقدار y_{i+1} بدست می‌آید که در رابطه (۳) نشان داده شده است.

$$\frac{dy}{dx} = \frac{S_o - S_f}{1 - Fr^2} \quad \text{رابطه (۱)}$$

$$\frac{dy}{dx} = y' = f(x_i, y_i) \quad \text{رابطه (۲)}$$

$$y_{i+1} = y_i + y'_i \Delta x = y_i + f(x_i, y_i) \Delta x \quad \text{رابطه (۳)}$$

که در آن S_0 شیب طولی کف مجرا، S_f شیب خط انرژی و Fr عدد فرود است. شیب خط انرژی با استفاده از فرمول مانینگ به صورت زیر:

$$S_f = \frac{Q^2 n^2}{R^{4/3} A^2} \quad \text{رابطه (۴)}$$

تعیین می‌شود و عدد فرود نیز با استفاده از رابطه (۵) قابل تعیین است.

$$\frac{Q^2 T}{g A^3} = Fr^2$$

رابطه ۵)

که در آن R شعاع هیدرولیکی، T عرض سطح آزاد، A اندازه سطح مقطع و g شتاب ثقل است.

معرفی مدل‌ها

مدل GMDH

الگوریتم هوشمند GMDH یک ساختار خود سازمانده است. یکی از ویژگی‌های این مدل قابلیت تشخیص پارامترهای غیرضروری در پیش بینی است. ارتباط بین پارامترهای ورودی و خروجی را می‌توان با سری توابع ولترا که مشابه با چند جمله‌ای کولموگروف گابور است، بیان نمود (Mehri et al, 2019).

$$y = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k$$

رابطه ۶)

که در آن بردار متغیرهای ورودی و بردار وزن است. $A=(a_1, a_2, \dots, a_m)$ ایواخنکو با الهام از این چند جمله‌ای الگوریتم GMDH را توسعه داد. ساختار این روش یک شبکه چند لایه پیشرونده است که متشکل از یک سری نورون‌های پشتیبان است. این نورون‌های پشتیبان حداقل دو ورودی دارند. عملکرد محرک یا انتقال این نورون‌ها را می‌توان به صورت یک چندجمله‌ای خطی یا غیرخطی بیان کرد که به صورت زیر تعریف می‌شود:

$$y = w_0 + w_1 x_1 + w_2 x_2 + w_3 x_1^2 + w_4 x_2^2 + w_5 x_1 x_2$$

رابطه ۷)

که در آن w_0 تا w_5 ضرایب چندجمله‌ای هستند. ضرایب شش گانه هر نورون در شبکه از طریق رویکرد حداقل مربعات محاسبه می‌شوند که مراحل انجام کار به صورت زیر است.

فرض کنید N بردار ورودی $X_n=(x_{n1}, x_{n2}, \dots, x_{np})$ که در آن $n=1, 2, \dots, N$ که هر کدام از یک مقدار عدد صحیح تشکیل شده است.

مقدار مطلوب خروجی n ام با ϕ_n نشان داده می‌شود. با استفاده از معادلات نرمال گوسین ضرایب به صورت زیر بدست می‌آیند:

$$\phi_1 = w_0 + w_1 x_{1i} + w_2 x_{1j} + w_3 x_{1i}^2 + w_4 x_{1j}^2 + w_5 x_{1i} x_{1j}$$

رابطه ۸)

$$\phi_2 = w_0 + w_1 x_{2i} + w_2 x_{2j} + w_3 x_{2i}^2 + w_4 x_{2j}^2 + w_5 x_{2i} x_{2j}$$

.

.

.

$$\phi_1 = w_0 + w_1 x_{Ni} + w_2 x_{Nj} + w_3 x_{Ni}^2 + w_4 x_{Nj}^2 + w_5 x_{Ni} x_{Nj}$$

که به صورت ماتریس کلی زیر نوشته می‌شود:

$$\phi = XW$$

رابطه ۹)

معادلات نرمال با استفاده از ضرب طرفین رابطه بالا در ترانهاده ماتریس X بدست می‌آید.

مدل ANN-RBF

این مدل دارای ۳ لایه ورودی، پنهان و خروجی است. لایه پنهان برای نگاشت خطی و لایه خروجی به عنوان لایه طبقه‌بندی یا رگرسیون مورد استفاده قرار می‌گیرد (Ghorbani et al., 2016). در این مدل داده‌های ورودی به صورت غیرخطی طبقه‌بندی می‌شوند. خروجی y_k با رابطه زیر نشان داده می‌شود:

$$y_k = \sum_{j=1}^M \omega_{kj} \phi_j(x) + \omega_{k0}$$

رابطه ۱۰)

که در این رابطه M تعداد توابع پایه و x بردار داده‌های ورودی و ω_{kj} ارتباط وزنی بین لایه خروجی و تابع پایه را نشان می‌دهد که به صورت گوسی است و در رابطه زیر نشان داده شده است:

$$\phi_j(x) = \exp\left(-\frac{|x - \mu_j|}{2\sigma_j^2}\right)$$

رابطه (۱۱)

که در آن x داده ورودی و μ میانگین نقاط هستند و σ انحراف از معیار داده‌ها است. پارامترهای داخلی مدل برتر RBF دارای عدد گسترش ۰/۵ و تعداد نرون آن برابر با ۹ است.

مدل RT

مدل رگرسیون درختی یک درخت تصمیم است که در هر گره انتهایی دارای روابط رگرسیون خطی است که می‌تواند مقادیر هدف را پیش‌بینی کند. در این روش ورودی‌ها توسط متغیرهای پیش‌بینی به بخش‌های مختلفی تقسیم می‌شوند به شکلی که متغیرهای هدف در هر منطقه ثابت هستند. هر درخت رگرسیون شامل سوالات اگر - آنگاه است که برای پیش‌بینی مقادیر هدف برای جمعی از ورودی‌های منتخب است. مبانی ریاضی درخت رگرسیون در تحقیق بریمن و همکاران (۱۹۸۴) آورده شده است (Breiman et al., 1984).

مدل ANFIS

سیستم استنتاج فازی عصبی از دو مدل شبکه عصبی و سیستم استنتاج فازی تشکیل شده است. در این مدل در ابتدا مقدار عضویت پارامترهای ورودی با استفاده از توابع عضویت در بازه‌های مختلف که به صورت فازی است، مشخص می‌شود. داده‌های ورودی از ۵ لایه در مدل ANFIS عبور می‌کند و طی فرآیند یادگیری، پارامترهای ورودی در توابع عضویت تغییر می‌کنند (Kisi et al., 2009). توابع عضویت موجود در لایه ۱ به صورت زیر نشان داده شده است.

$$Q_{1,i} = \mu A_i(x), \quad \text{for } i = 1, 2 \quad \text{رابطه (۱۲)}$$

$$Q_{1,i} = \mu B_i(x), \quad \text{for } i = 3, 4 \quad \text{رابطه (۱۳)}$$

که در این جا: x ورودی گره A_i و B_i متغیر توصیفی است که در این گره مشارکت دارد. همچنین $Q_{1,i}$ تابع عضویت A_i و B_i بوده و این درجه‌ای است که کفایت x را برای A_i و B_i تعیین می‌کند. در لایه دوم وزن قانون‌ها بدست می‌آید:

$$Q_{2,i} = W_i = \mu B_i(x) \times \mu B_i(y) \quad i = 1, 2 \quad \text{رابطه (۱۴)}$$

وزن قانون‌ها در گره‌های لایه سوم نرمال‌سازی می‌شوند:

$$Q_{3,i} = \frac{w_i}{w_1 + w_2} \quad i = 1, 2 \quad \text{رابطه (۱۵)}$$

سپس قوانین موردنیاز در لایه چهارم بدست می‌آید:

$$Q_{4,i} = \frac{w_i}{w_1 + w_2} (p_i(x) + q_i(y) + r_i) = \frac{w_i}{w_1 + w_2} f_i \quad \text{رابطه (۱۶)}$$

که در آن p_i ، q_i و r_i ضرایب این ترکیب خطی است. در لایه آخر با استفاده از غیرفازی سازی، مقادیر قوانین فازی تغییر شکل می‌دهند. در این مدل نماینده ماتریس پارتیشن برابر با ۲، حداکثر تعداد تکرار برابر با ۱۰۰۰، حداقل نرخ رشد برابر با 10^{-6} و تابع داخلی مدل برابر با ۰ در نظر گرفته شد.

مدل ANFIS-PSO

برای افزایش دقت مدل ANFIS می‌توان از روش‌های بهینه‌سازی استفاده کرد. یکی از روش‌هایی که می‌تواند باعث بهبود عملکرد مدل ANFIS شود، روش بهینه‌سازی ازدحام ذرات (PSO) است. این روش با استفاده از مجموعه‌ای از ذرات تصادفی کار می‌کند. سپس وضعیت بهینه را با استفاده از به‌روزرسانی مکرر این ذرات جستجو می‌کند (Roushangar and Shahnazi, 2019). موقعیت هر ذره با استفاده از بردار آن تعیین می‌شود که به صورت زیر نشان داده می‌شود:

$$\vec{X}_i = [X_{i1} X_{i2} X_{i3} \dots X_{iN}] \quad \text{رابطه (۱۷)}$$

که در آن با i شاخص یک ذره در ازدحام نشان داده می‌شود و N بعد فضای جستجو است. سرعت ذرات را به شکل زیر می‌توان نشان داد:

$$\vec{v}_i = [v_{i1} v_{i2} v_{i3} \dots v_{iN}] \quad \text{رابطه ۱۸}$$

هر ذره بهترین موقعیت را به حافظه می‌سپارد که به شکل زیر نشان داده می‌شود:

$$\vec{X}_{Pbest} = [X_{Pbest1} X_{Pbest2} X_{Pbest3} \dots X_{PbestN}] \quad \text{رابطه ۱۹}$$

بهترین موقعیت که توسط تمامی ذرات کشف شود به عنوان بهترین ذرات جهانی نامیده می‌شود:

$$\vec{X}_{Gbest} = [X_{Gbest1} X_{Gbest2} X_{Gbest3} \dots X_{GbestN}] \quad \text{رابطه ۲۰}$$

در هر تکرار از PSO، سرعت ذره بدست می‌آید:

$$v_i(t) = \omega v_i(t-1) + \rho_1 (X_{Pbest_i} - X_i(t)) + \rho_2 (X_{Gbest_i} - X_i(t)) \quad \text{رابطه ۲۱}$$

$$X_i(t) = X_i(t-1) + v_i(t) \quad \text{رابطه ۲۲}$$

که در آن $\rho_1 = C_1 R_1$ و $\rho_2 = C_2 R_2$ و در آن C_1 و C_2 ضرایب ثابت هستند و R_1 و R_2 دو عدد تصادفی با توزیع یکنواخت بین ۰ و ۱ است. با ثابت نگه‌داشتن پارامترهای ANFIS، پارامترهای تنظیمی مدل برتر ANFIS-PSO شامل حداکثر تعداد تکرار ۱۰۰۰، میزان جمعیت ۲۰، وزن اینرسی برابر با ۱، ضریب کاهش برابر با ۰/۹۹ و ضریب یادگیری شخصی برابر با ۱ و ضریب یادگیری جمعی ۲ در نظر گرفته شد.

پارامترهای مؤثر بر روی ضریب مانینگ

در این تحقیق پارامترهای مؤثر بر روی ضریب مانینگ را می‌توان به شکل زیر نشان داد (Xu et al., 2012; Wu, 2008; Meng et al., 2021):

$$n = f(N, \frac{d}{y}, D, Re, Fr, S_0) \quad \text{رابطه ۲۳}$$

که در آن n ضریب مانینگ، y عمق متوسط جریان، S_0 شیب کانال، D تراکم پوشش گیاهی، d قطر تنه پوشش گیاهی و N ضریب آرایش پوشش گیاهی و Re عدد رینولدز و Fr عدد فرود است. با توجه به اینکه شیب کانال ثابت در نظر گرفته شده است، رابطه بالا به شکل زیر تبدیل می‌شود:

$$n = f(N, \frac{d}{y}, D, Re, Fr) \quad \text{رابطه ۲۴}$$

که n به عنوان خروجی و ۵ عامل دیگر عوامل ورودی به مدل خواهند بود.

نرمال‌سازی داده‌ها

در این تحقیق از پنج عامل ورودی شامل $N, \frac{d}{y}, D, Re, Fr$ و یک خروجی (n ضریب مانینگ) برای مدل‌سازی استفاده شد. به منظور استانداردسازی داده‌ها، تمامی داده‌ها بین ۰ و ۱ نرمال‌سازی شدند. برای نرمال‌سازی داده‌ها از رابطه (۲۵) استفاده شد (Mehri et al., 2021). سپس داده‌ها به صورت تصادفی به دو بخش آموزش و آزمون تقسیم شدند. ۶۵ داده برای آموزش و ۲۱ داده برای آزمون استفاده شده است.

$$X = \frac{X_0 - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه ۲۵}$$

که در آن X داده نرمال، X_0 داده آزمایشگاهی، X_{\max} حداکثر مقدار داده آزمایشگاهی و X_{\min} حداقل مقدار داده آزمایشگاهی است.

شاخص‌های ارزیابی عملکرد

برای ارزیابی عملکرد مدل‌ها از جذر میانگین مربعات خط (RMSE)، جذر میانگین مربعات خطای نرمال شده (NRMSE)، ضریب همبستگی (R^2) و ضریب کلینگ گوپتا (KGE) استفاده شد. این شاخص‌ها مطابق روابط (۲۶)، (۲۷)، (۲۸) و (۲۹) می‌باشند (Mehri et al., 2019; Marashi et al., 2023; Hassanzadeh and Abbaszadeh., 2023; Abbaszadeh et al., 2024).



$$R^2 = \left(\frac{\sum XY}{\sqrt{\sum X^2 \sum Y^2}} \right)^2 \quad \text{رابطه ۲۶}$$

$$RMSE = \left[\frac{\sum (X - Y)^2}{N} \right]^{0.5} \quad \text{رابطه ۲۷}$$

$$NRMSE = \frac{\left[\frac{\sum (X - Y)^2}{N} \right]^{0.5}}{X_{\max} - X_{\min}} \quad \text{رابطه ۲۸}$$

$$KGE = 1 - \sqrt{(R-1)^2 + (\beta-1)^2 + (\gamma-1)^2} \quad \text{رابطه ۲۹}$$

که در آن، X مقدار واقعی، Y مقدار پیش‌بینی شده، N تعداد نمونه، β نسبت میانگین مقدار پیش‌بینی شده به مقدار واقعی و γ انحراف معیار مقدار پیش‌بینی شده به مقدار واقعی است. با ارزیابی این شاخص‌ها برای هر یک از مدل‌های مورد بررسی، عملکرد و کارایی آنها مورد مقایسه قرار خواهد گرفت.

نتایج و بحث

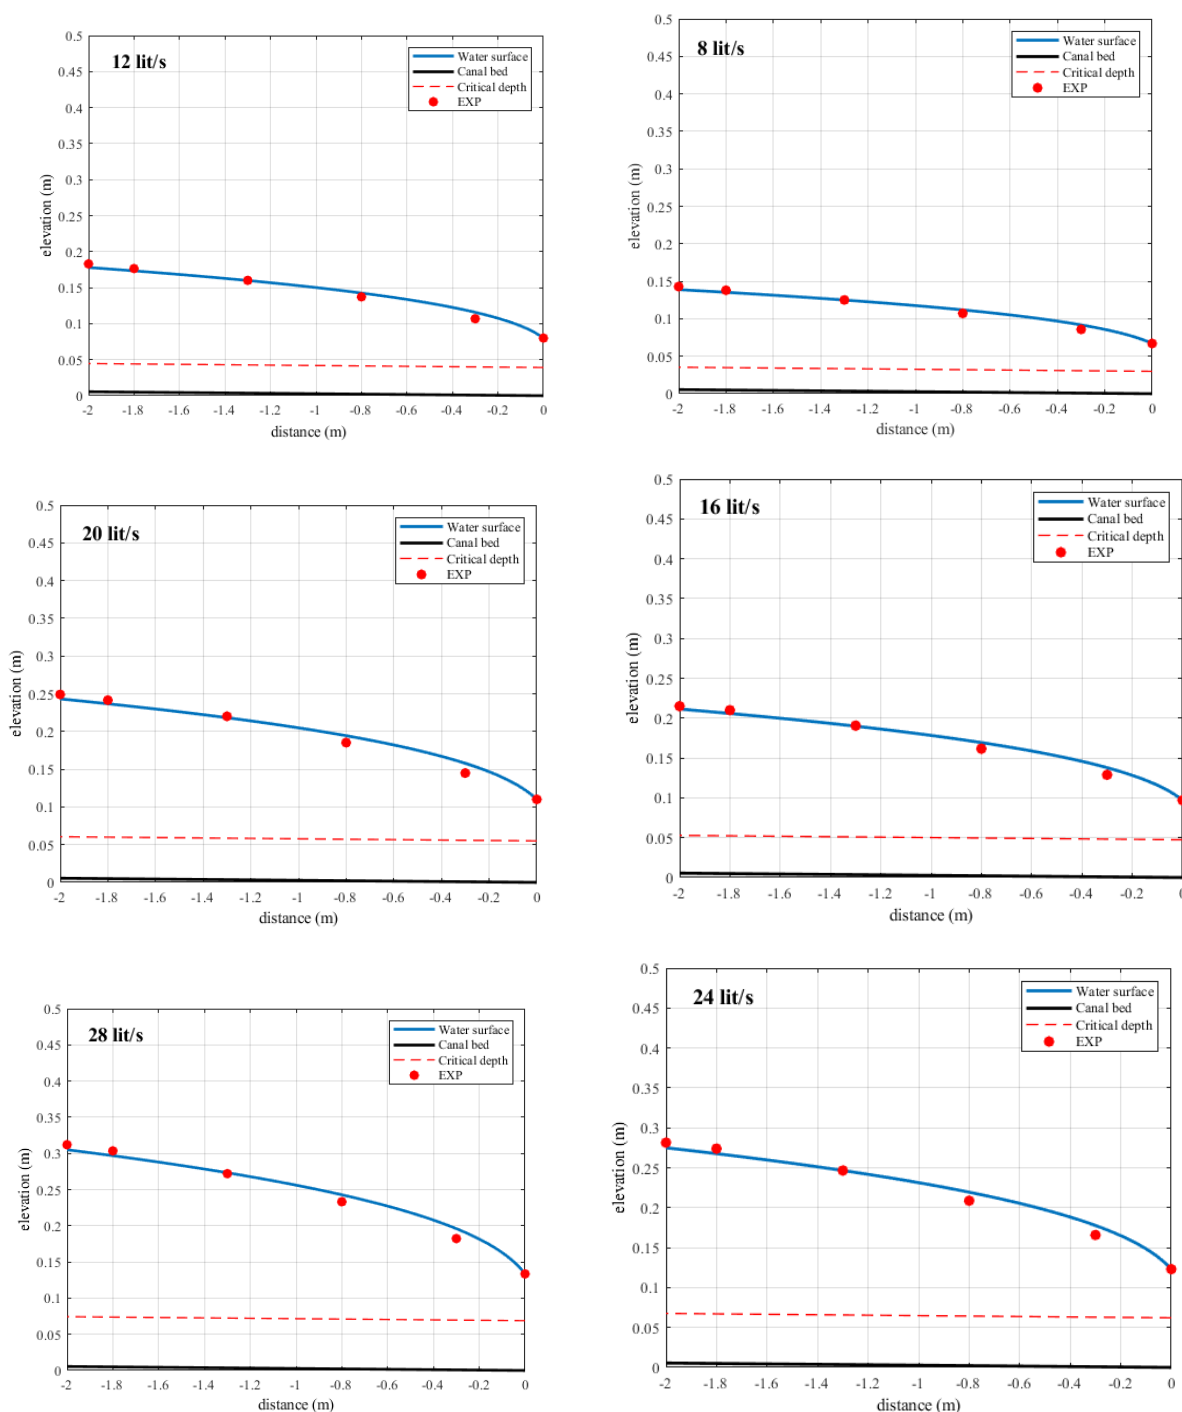
در این تحقیق ابتدا ۸۶ آزمایش برای اندازه‌گیری ضریب مانینگ در کانال با پوشش گیاهی سخت انجام شد. برای این منظور با حل معادلات متغیر تدریجی به روش عددی اویلر پروفیل سطح آب بدست آمد و سپس با مقادیر آزمایشگاهی مقایسه شد. ضریب مانینگ به گونه‌ای تعیین شد که بین نیمرخ سطح آب داده‌های آزمایشگاهی و داده‌های محاسباتی تطابق ایجاد شود. سپس داده‌های به دست آمده نرمال شده، بین صفر و ۱ قرار داده و به صورت تصادفی به دو قسمت آموزش و آزمون تقسیم‌بندی شد که سهم داده آموزش ۷۵ درصد و داده‌های آزمون ۲۵ درصد است. مشخصات آماری داده‌های نرمال شده در مرحله آموزش و آزمون در جدول (۲) نشان داده شده است.

جدول ۲. مشخصات آماری داده‌های مورد استفاده (نرمال شده)

n	Fr	Re	D	$\frac{d}{y}$	N	پارامتر آماری
۰	۰/۰۲۴۳	۰	۰	۰	۰	Min
۱	۱	۱	۱	۱	۱	Max
۰/۲۷۱۹	۰/۵۱۰۳	۰/۴۷۴۹	۰/۳۰۷۹	۰/۳۴۰۶	۰/۵۰۷۷	Average
۰/۲۴۸۳	۰/۲۴۱۴	۰/۳۱۰۰	۰/۳۲۲۴	۰/۲۶۹۸	۰/۵۰۳۸	Stdev
۰/۰۱۲۰	۰	۰/۰۰۶۷	۰	۰/۰۶۱۱	۰	Min
۰/۸۲۰۷	۰/۹۶۷۰	۰/۹۷۶۴	۱	۰/۶۶۶	۱	Max
۰/۲۴۶۴	۰/۵۶۴۴	۰/۵۸۸۴	۰/۳۳۷۸	۰/۲۶۰۲	۰/۴۲۸۶	Average
۰/۲۳۲۸	۰/۲۹۰۲	۰/۳۱۹۳	۰/۴۰۰۹	۰/۱۸۴۳	۰/۵۰۷۱	Stdev

نیمرخ سطح آب

در این بخش نیمرخ طولی سطح آب مورد بررسی قرار گرفت. با حل معادله به روش اویلر و ترسیم نیمرخ سطح آب، تطابق قابل قبولی بین داده‌های آزمایشگاهی و نتایج ناشی از حل معادلات جریان متغیر تدریجی مشاهده شد. در شکل (۶) نیمرخ سطح آب را برای یک نمونه از پوشش‌های گیاهی می‌توان ملاحظه نمود. در این شکل نیمرخ سطح آب برای دبی‌های ۸، ۱۲، ۱۶، ۲۰، ۲۴ و ۲۸ لیتر بر ثانیه برای تراکم ۰/۰۹۲ رسم شده است. با توجه به شکل می‌توان مشاهده نمود که تطابق مناسبی بین حل به روش اویلر و مقادیر آزمایشگاهی وجود دارد. همچنین مشاهده می‌شود در این قسمت نیمرخ M2 تشکیل می‌شود (نقطه (۰,۰) انتهای بازه پوشش گیاهی در پایین دست است).



شکل ۶. تعدادی از نیمرخ‌های سطح آب محاسباتی در مقابل داده‌های آزمایشگاهی (تراکم ۰/۰۹۲)

مدل‌های هوشمند

در این بخش عملکرد مدل‌های هوشمند GMDH، ANN-RBF، ANFIS، RT، ANFIS-PSO و ANFIS در پیش‌بینی ضریب مانینگ در کانال با پوشش گیاهی مورد بررسی قرار می‌گیرد. برای این منظور ترکیب‌های مختلفی از ورودی‌ها برای مدل‌سازی مورد استفاده قرار گرفت که پارامترهای ورودی در جدول (۳) بر اساس رابطه ۲۴ قابل مشاهده است. از داده‌های ورودی در مرحله آموزش و آزمون ارائه شده در جدول (۲) استفاده شد. جدول (۳) ارزیابی مدل‌های هوشمند یادشده را با متغیرهای ورودی مختلف از گروه‌بندی I_1 تا I_6 نشان می‌دهد. با توجه به این جدول، مدل ANFIS-PSO نسبت به سایر مدل‌ها دقت بیشتری دارد. در این مدل با توجه به اینکه سیستم استنتاج فازی با نرون‌ها ترکیب شده است، زمانی که توابع عضویت به بهینه‌ترین حالت ممکن می‌رسند، دقت مدل افزایش یافته و عملکرد بالایی از خود نشان می‌دهد. در این مدل پارامترهای داخلی مرتبط با روش بهینه‌سازی، با سعی و خطا تعیین شد. در این مدل با توجه به اینکه تابع هدف وابسته



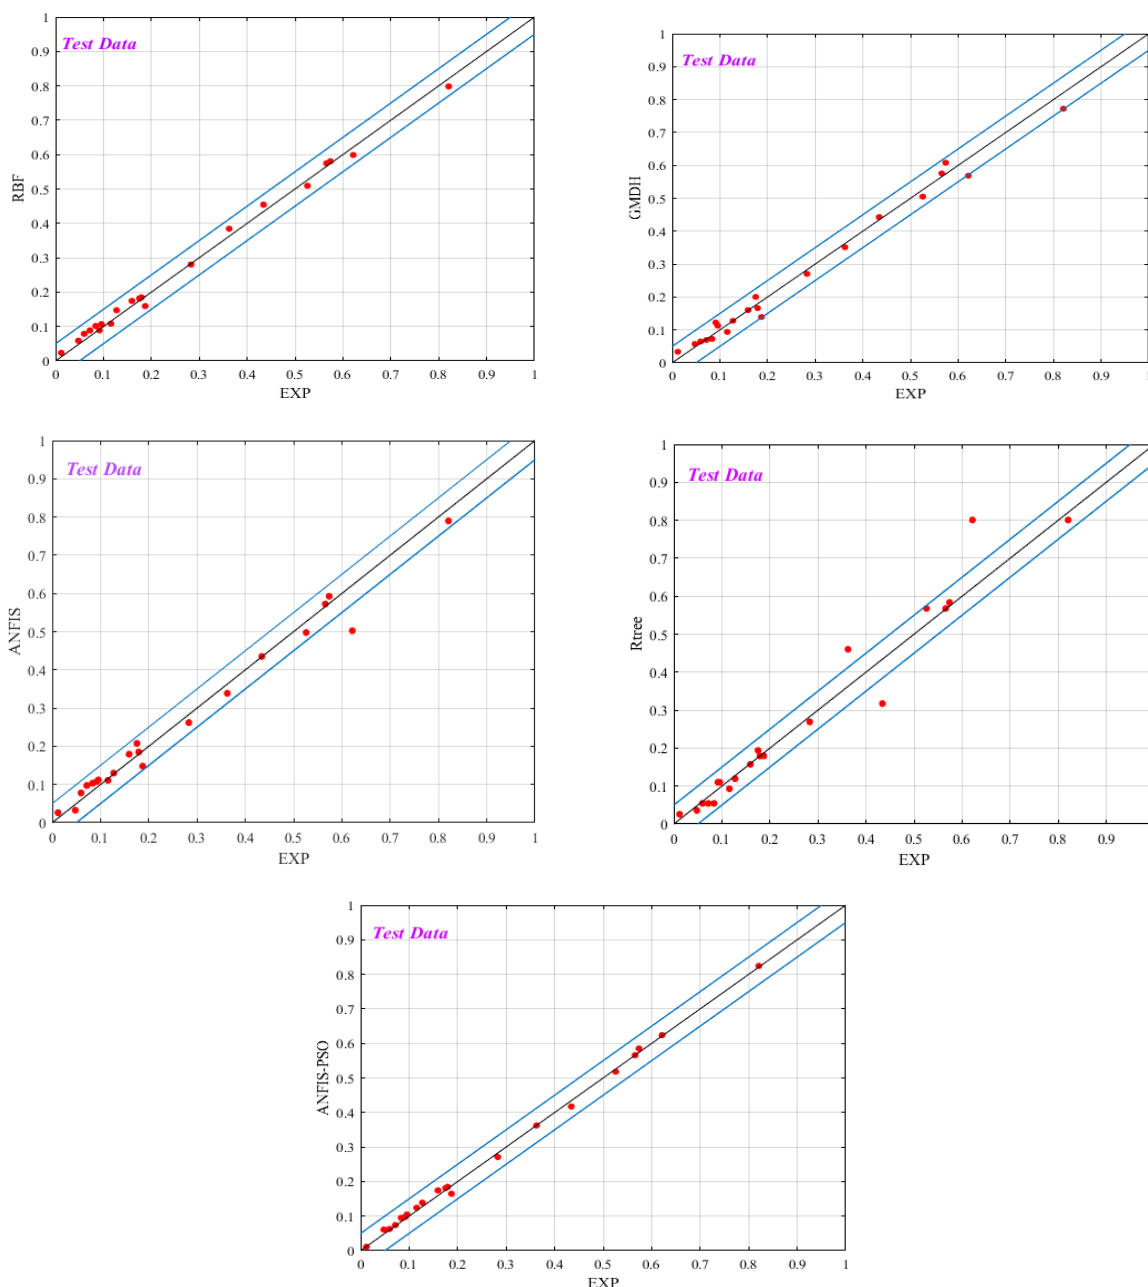
به مقدار خطای مدل تخمینی است، با استفاده از پارامترهایی که در FIS پایه هستند مقادیر خطا تعیین شد و زمانی که خطای مدل از مقدار خطایی که تعیین شده، کمتر می‌شود مدل سازی متوقف می‌شود، و گرنه مراحل مدل سازی ادامه می‌یابد تا زمانی که شرط توقف را ارضا کند. در نهایت مقادیر خطا ثبت گردید. همان طور که در جدول (۳) مشاهده می‌شود، بهینه سازی بر روی مدل ANFIS تأثیرگذار بوده است. دقت مدل برتر ANFIS-PSO برابر با $RMSE=0.0096$ ، $R^2=0.9984$ و $KGE=0.9922$ در مرحله آموزش و $RMSE=0.0099$ ، $R^2=0.9982$ و $KGE=0.9873$ در مرحله آزمون است.

جدول ۳. نتایج مدل سازی با مدل های مختلف

Test				Train				پارامترهای ورودی	نام گروه	مدل
R^2	NRMSE	RMSE	KGE	R^2	NRMSE	RMSE	KGE			
۰/۹۸۸۶	۰/۰۳۱۵	۰/۰۲۵۴	۰/۹۵۸۸	۰/۹۹۳۷	۰/۰۱۹۴	۰/۰۱۹۴	۰/۹۸۹۰	$N, d/y, D, Re$	I_1	GMDH
۰/۹۷۰۴	۰/۰۴۸۸	۰/۰۳۹۵	۰/۹۷۷۵	۰/۹۹۱۰	۰/۰۲۳۸	۰/۰۲۳۸	۰/۹۸۰۱	$N, d/y, D, Fr$	I_2	
۰/۹۴۸۰	۰/۰۶۸۳	۰/۰۵۵۳	۰/۸۸۹۵	۰/۹۸۱۸	۰/۰۳۳۲	۰/۰۳۳۲	۰/۹۸۷۲	$N, d/y, Re, Fr$	I_3	
۰/۹۸۳۶	۰/۰۳۵۹	۰/۰۲۹۰	۰/۹۸۳۱	۰/۹۹۳۴	۰/۰۲۰۰	۰/۰۲۰۰	۰/۹۹۴۹	N, D, Re, Fr	I_4	
۰/۹۴۸۶	۰/۰۶۵۸	۰/۰۵۳۲	۰/۹۲۶۵	۰/۹۸۰۴	۰/۰۳۴۶	۰/۰۳۴۶	۰/۹۸۴۳	$d/y, D, Re, Fr$	I_5	
۰/۹۸۹۴	۰/۰۳۰۴	۰/۰۲۴۶	۰/۹۵۹۵	۰/۹۹۵۰	۰/۰۱۷۲	۰/۰۱۷۲	۰/۹۹۵۲	$N, d/y, D, Re, Fr$	I_6	
۰/۹۹۷۶	۰/۰۲۰۰	۰/۰۱۶۲	۰/۹۵۰۶	۰/۹۹۸۴	۰/۰۰۹۵	۰/۰۰۹۵	۰/۹۹۸۷	$N, d/y, D, Re$	I_1	ANN-RBF
۰/۹۸۷۶	۰/۰۳۱۶	۰/۰۲۵۶	۰/۹۷۳۷	۰/۹۹۸۲	۰/۰۱۰۱	۰/۰۱۰۱	۰/۹۹۷۴	$N, d/y, D, Fr$	I_2	
۰/۹۶۴۷	۰/۰۶۲۰	۰/۰۵۰۱	۰/۸۷۳۳	۰/۹۹۲۸	۰/۰۲۰۷	۰/۰۲۰۷	۰/۹۹۴۹	$N, d/y, Re, Fr$	I_3	
۰/۹۹۳۴	۰/۰۲۳۲	۰/۰۱۷۰	۰/۹۸۸۱	۰/۹۹۸۸	۰/۰۰۸۴	۰/۰۰۸۴	۰/۹۹۹۲	N, D, Re, Fr	I_4	
۰/۹۷۸۷	۰/۰۴۶۰	۰/۰۳۷۲	۰/۹۱۴۰	۰/۹۹۳۰	۰/۰۲۰۵	۰/۰۲۰۵	۰/۹۹۵۰	$d/y, D, Re, Fr$	I_5	
۰/۹۹۶۲	۰/۰۱۹۴	۰/۰۱۵۷	۰/۹۶۶۳	۰/۹۹۸۸	۰/۰۰۸۱	۰/۰۰۸۱	۰/۹۹۹۲	$N, d/y, D, Re, Fr$	I_6	
۰/۹۵۵۸	۰/۰۶۶۵	۰/۰۵۳۸	۰/۹۱۰۶	۰/۹۹۳۵	۰/۰۱۹۷	۰/۰۱۹۷	۰/۹۹۵۴	$N, d/y, D, Re$	I_1	RT
۰/۹۴۹۲	۰/۰۷۰۶	۰/۰۵۷۱	۰/۹۱۰۱	۰/۹۹۳۵	۰/۰۱۹۷	۰/۰۱۹۷	۰/۹۹۵۴	$N, d/y, D, Fr$	I_2	
۰/۷۴۱۵	۰/۱۴۴۷	۰/۱۱۷۰	۰/۸۵۰۲	۰/۹۸۹۸	۰/۰۲۴۷	۰/۰۲۴۷	۰/۹۹۲۸	$N, d/y, Re, Fr$	I_3	
۰/۹۵۵۱	۰/۰۶۶۷	۰/۰۵۴۰	۰/۹۰۷۳	۰/۹۹۳۲	۰/۰۲۰۳	۰/۰۲۰۳	۰/۹۹۵۱	N, D, Re, Fr	I_4	
۰/۸۳۹۱	۰/۱۳۷۰	۰/۱۱۰۸	۰/۷۸۸۰	۰/۹۹۳۲	۰/۰۲۰۲	۰/۰۲۰۲	۰/۹۹۵۲	$d/y, D, Re, Fr$	I_5	
۰/۹۵۵۸	۰/۰۶۶۵	۰/۰۵۳۸	۰/۹۱۰۶	۰/۹۹۳۵	۰/۰۱۹۷	۰/۰۱۹۷	۰/۹۹۵۴	$N, d/y, D, Re, Fr$	I_6	
۰/۹۷۷۹	۰/۰۵۰۶	۰/۰۴۰۹	۰/۹۱۳۰	۰/۹۹۷۸	۰/۰۱۱۵	۰/۰۱۱۵	۰/۹۹۸۴	$N, d/y, D, Re$	I_1	ANFIS
۰/۹۷۶۷	۰/۰۵۱۳	۰/۰۴۱۵	۰/۹۱۴۰	۰/۹۹۸۰	۰/۰۱۰۹	۰/۰۱۰۹	۰/۹۹۷۳	$N, d/y, D, Fr$	I_2	
۰/۹۵۴۹	۰/۰۶۴۶	۰/۰۵۲۲	۰/۸۸۷۶	۰/۹۸۶۴	۰/۰۲۸۵	۰/۰۲۸۵	۰/۹۹۰۲	$N, d/y, Re, Fr$	I_3	
۰/۹۸۱۶	۰/۰۵۴۳	۰/۰۴۳۹	۰/۹۵۱۵	۰/۹۹۸۴	۰/۰۰۹۱	۰/۰۰۸۲	۰/۹۹۸۳	N, D, Re, Fr	I_4	
۰/۹۶۲۱	۰/۰۵۹۲	۰/۰۴۷۹	۰/۸۹۹۴	۰/۹۹۵۶	۰/۰۱۶۲	۰/۰۱۶۲	۰/۹۹۶۴	$d/y, D, Re, Fr$	I_5	
۰/۹۸۲۶	۰/۰۴۰۶	۰/۰۳۲۸	۰/۹۳۰۲	۰/۹۹۷۸	۰/۰۱۱۳	۰/۰۱۱۳	۰/۹۹۸۴	$N, d/y, D, Re, Fr$	I_6	
۰/۹۹۷۸	۰/۰۱۴۸	۰/۰۱۱۹	۰/۹۷۷۱	۰/۹۹۸۰	۰/۰۱۰۷	۰/۰۱۰۷	۰/۹۹۲۷	$N, d/y, D, Re$	I_1	ANFIS-PSO
۰/۹۹۶۸	۰/۰۱۶۲	۰/۰۱۳۱	۰/۹۸۱۴	۰/۹۹۶۸	۰/۰۱۳۹	۰/۰۱۳۹	۰/۹۸۵۶	$N, d/y, D, Fr$	I_2	
۰/۹۸۳۴	۰/۰۴۴۴	۰/۰۳۵۹	۰/۹۰۲۶	۰/۹۸۱۸	۰/۰۳۳۵	۰/۰۳۳۵	۰/۹۷۱۳	$N, d/y, Re, Fr$	I_3	
۰/۹۹۷۰	۰/۰۱۶۳	۰/۰۱۳۲	۰/۹۸۱۲	۰/۹۹۷۶	۰/۰۱۱۷	۰/۰۱۱۷	۰/۹۹۵۱	N, D, Re, Fr	I_4	
۰/۹۹۲۶	۰/۰۲۵۹	۰/۰۲۱۰	۰/۹۶۱۱	۰/۹۸۷۲	۰/۰۲۸۱	۰/۰۲۸۱	۰/۹۷۴۵	$d/y, D, Re, Fr$	I_5	
۰/۹۹۸۲	۰/۰۱۲۳	۰/۰۰۹۹	۰/۹۸۷۳	۰/۹۹۸۴	۰/۰۰۹۶	۰/۰۰۹۶	۰/۹۹۲۲	$N, d/y, D, Re, Fr$	I_6	

با توجه نتایج مدل ها در جدول (۳) می‌توان مشاهده کرد که گروه I_3 پایین ترین دقت را در بین گروه‌ها در تمامی مدل‌ها دارد. در این گروه بندی پارامتر D یا تراکم وجود ندارد. با توجه به کاهش دقت همه مدل‌ها می‌توان نشان داد که پارامتر D ، پارامتری مهم در پیش بینی ضریب زبری مانینگ با استفاده از مدل‌ها است. در مرحله دوم با نبود پارامتر N یا آرایش پوشش گیاهی، با توجه به نتایج تمام مدل‌ها کمترین دقت بعد از گروه I_3 به گروه I_5 تعلق دارد. بنابراین بعد از پارامتر تراکم پوشش گیاهی، پارامتر آرایش گیاهی یعنی N اهمیت پیدا می‌کند. به همین ترتیب، به ترتیب پارامترهای d/y ، Re و Fr قرار می‌گیرد. بعد از مدل ANFIS-PSO از لحاظ دقت مدل ANN-RBF قرار


می‌گیرد. در مدل ANN-RBF دقت گروه‌بندی I_6 که بالاترین دقت را داشت در مرحله آموزش برابر با $RMSE=0.0081$ ، $R^2=0.9988$ و $KGE=0.9992$ و در مرحله آزمون برابر با $RMSE=0.0157$ ، $R^2=0.9962$ و $KGE=0.9963$ است. بعد از دو مدل یادشده، مدل GMDH رتبه سوم قرار می‌گیرد. دقت مدل برتر در این مدل در مرحله آموزش برابر با $RMSE=0.0172$ ، $R^2=0.9950$ و $KGE=0.9952$ و در مرحله آزمون برابر با $RMSE=0.0246$ ، $R^2=0.9894$ و $KGE=0.9595$ است. مشخصات مدل برتر GMDH شامل حداکثر مقدار نرون، حداکثر تعداد لایه‌ها و فشار انتخابی به ترتیب برابر با ۱۰، ۴ و ۰/۷۵ می‌باشد. مدل ANFIS در رتبه چهارم از لحاظ دقت قرار می‌گیرد. مدل برتر ANFIS برابر با $RMSE=0.0113$ ، $R^2=0.9978$ و $KGE=0.9984$ در مرحله آموزش و $RMSE=0.0328$ ، $R^2=0.9826$ و $KGE=0.9302$ در مرحله آزمون می‌باشد. گفتنی است با ثابت نگه‌داشتن پارامترهای داخلی که در ANFIS استفاده شد، اقدام به بهینه‌سازی توابع عضویت با استفاده از ANFIS-PSO، برای تعیین کمترین مقدار خطا شد. آخرین مدل از لحاظ دقت مدل RT است. دقت در مدل RT برابر با $RMSE=0.0197$ ، $R^2=0.9935$ و $KGE=0.9954$ در مرحله آموزش و $RMSE=0.0538$ ، $R^2=0.9558$ و $KGE=0.9106$ در مرحله آزمون است. شکل (۷) به ترتیب عملکرد مدل‌ها را در مرحله آزمون نشان می‌دهد.



شکل ۷. عملکرد مدل‌ها در مرحله آزمون (داده نرمال شده آزمایشگاهی در مقابل داده پیش‌بینی شده مدل)

مقایسه بین نتایج مدل‌ها و نتایج تحقیقات گذشته

شکل (۸) دقت مدل‌های ANN-RBF، GMDH، RT، ANFIS و ANFIS-PSO را در مقایسه با رابطه‌ی ارائه‌شده توسط ژانگ و همکاران (۲۰۱۹) نشان می‌دهد. نتایج نشان می‌دهد که مدل‌های هوشمند دقت مناسب‌تری در پیش‌بینی ضریب مانینگ در حضور پوشش گیاهی دارند. مدل‌های هوشمند، مزایای زیادی نسبت به راه‌حل‌های تحلیلی دارند. همان‌طور که در تحقیق Kelleher et al., (2018) نشان داده شده است، یکی از اصلی‌ترین مزیت‌ها توانایی آن‌ها در مدیریت حجم زیادی از داده‌های پیچیده است که با روش‌های تحلیلی می‌تواند دشوار یا غیرممکن باشد. مدل‌های هوشمند همچنین می‌توانند با داده‌های جدید سازگار شوند و از آنها یاد بگیرند و آنها را نسبت به راه‌حل‌های تحلیلی، انعطاف‌پذیرتر و دقیق‌تر می‌کند. افزون بر این، مدل‌های هوشمند می‌توانند الگوها و روابطی را شناسایی کنند که ممکن است برای انسان‌ها آشکار نباشد. به‌طور کلی، مدل‌های هوشمند پتانسیل ارائه راه‌حل‌های دقیق‌تر و کارآمدتر برای مسائل پیچیده را نسبت به روش‌های تحلیلی دارند. از سوی دیگر، یکی از علت‌هایی که سبب کاهش دقت رابطه‌ی ارائه‌شده می‌شود عدم تمایز بین آرایش‌های مختلف در پوشش گیاهی است. این در حالی است که در این تحقیق نشان داده شد که یکی از عوامل مؤثر بر ضریب مانینگ نحوه آرایش پوشش گیاهی است. علت دیگر پایین‌تر بودن دقت رابطه ارائه‌شده عدم وجود تابع گوسی در معادله این رابطه است، در حالی که تحقیق حاضر نشان می‌دهد استفاده از تابع گوسی در مدل‌سازی سبب افزایش دقت می‌شود.



شکل ۸. مقایسه عملکرد مدل‌ها و تحقیقات گذشته

نتیجه‌گیری

در این تحقیق برآورد ضریب مانینگ در کانال همراه با پوشش گیاهی در شرایط جریان متغیر تدریجی با استفاده از بررسی آزمایشگاهی و همچنین مدل‌های ANN-RBF، GMDH، RT، ANFIS و ANFIS-PSO مورد بررسی قرار گرفت. برای این منظور ابتدا ضریب مانینگ جریان عبوری از یک بازه دارای پوشش گیاهی سخت (صلب)، در یک کانال مستطیلی در آزمایشگاه با ۸۶ آزمایش اندازه‌گیری شد. برای بدست آوردن ضریب مانینگ از ترسیم نیمرخ سطح آب استفاده شد. با استفاده از حل به روش عددی اویلر نشان داده شد که داده‌های آزمایشگاهی تطابق خوبی با نیمرخ سطح آب محاسبه‌شده با این روش دارد. سپس پنج مدل یادشده در محیط نرم‌افزار MATLAB کدنویسی شد. با بررسی نتایج مشخص شد که مدل ANFIS-PSO بیشترین دقت را نسبت به سایر مدل‌ها دارد. پایین‌ترین عملکرد نیز به RT اختصاص یافت. پارامترهای تراکم پوشش گیاهی (D)، آرایش پوشش گیاهی (N) و عدد رینولدز (Re) در توسعه مدل‌ها بیشترین نقش را داشتند. بنابراین برای برآورد ضریب مانینگ در شرایط یادشده پیشنهاد می‌شود از مدل ANFIS-PSO استفاده شود.

"هیچ‌گونه تعارض منافع بین نویسندگان وجود ندارد"

REFERENCES

Abbaszadeh, H., Daneshfaraz, R., Sume, V. & Abraham, J. (2024). Experimental investigation and application of soft computing models for predicting flow energy loss in arc-shaped constrictions. *AQUA—Water*

Infrastructure, Ecosystems and Society, p.jws2024010.

- Bahramifar, A., Shirkhani, R. & Mohammadi, M. (2013). An anfis-based approach for predicting the manning roughness coefficient in alluvial channels at the bank-full stage. *International Journal of Engineering*, 26(2), 177-186.
- Breiman L. Friedman J. H. Olshen R. A. Stone C. J. (1984). Classification and Regression Trees. Cole Statistics/Probability Series. *Wadsworth & Brooks*, New York, NY.
- Cheng, N.S. & Nguyen, H.T. (2011). Hydraulic radius for evaluating resistance induced by simulated emergent vegetation in open-channel flows. *Journal of hydraulic engineering*, 137(9), 995-1004.
- Cornacchia, L., Folkard, A., Davies, G., Grabowski, R.C., van de Koppel, J., van der Wal, D., Wharton, G., Puijalon, S. & Bouma, T.J. (2019). Plants face the flow in V formation: A study of plant patch alignment in streams. *Limnology and oceanography*, 64(3), 1087-1102.
- Coscarella, F., Penna, N., Ferrante, A.P., Gualtieri, P. & Gaudio, R. (2021). Turbulent flow through random vegetation on a rough bed. *Water*, 13(18), 2564.
- García Díaz, R. (2005). Analysis of Manning coefficient for small-depth flows on vegetated beds. *Hydrological Processes: An International Journal*, 19(16), 3221-3233.
- Ghorbani, M.A., Zadeh, H.A., Isazadeh, M. & Terzi, O. (2016). A comparative study of artificial neural network (MLP, RBF) and support vector machine models for river flow prediction. *Environmental Earth Sciences*, 75, 1-14.
- Gu, F.F., Ni, H.G. & Qi, D.M. (2007). Roughness coefficient for unsubmerged and submerged reed. *Journal of Hydrodynamics*, 19(4), 421-428.
- Hassanzadeh, Y. & Abbaszadeh, H. (2023). Investigating Discharge Coefficient of Slide Gate-Sill Combination Using Expert Soft Computing Models. *Journal of Hydraulic Structures*, 9(1), pp.63-80. (In Persian).
- Henderson, F.M. (1996). Open channel flow.
- Kelleher, J.D., Tierney, B. & Tierney, B. (2018). Data science: an introduction.
- Kisi, O., Haktanir, T., Ardiclioglu, M., Ozturk, O., Yalcin, E. & Uludag, S. (2009). Adaptive neuro-fuzzy computing technique for suspended sediment estimation. *Advances in Engineering Software*, 40(6), pp.438-444.
- Ladson, A., Anderson, B., & Rutherford, I. (2002). Towards an Australian Handbook of Stream Roughness Coefficients. In *Hydrology and Water Resources Symposium*. 348-355. Barton, ACT: Institution of Engineers, Australia.
- Li, Y., Wang, Y., Anim, D.O., Tang, C., Du, W., Ni, L., Yu, Z. & Acharya, K. (2014). Flow characteristics in different densities of submerged flexible vegetation from an open-channel flume study of artificial plants. *Geomorphology*, 204, 314-324.
- Marashi, A., Kouchakzadeh, S. & Yonesi, H.A. (2023). Rotary gate discharge determination for inclusive data from free to submerged flow conditions using ENN, ENN-GA, and SVM-SA. *Journal of Hydroinformatics*. 25(4), 1312-1328.
- Mehri, Y., Nasrabadi, M. & Omid, M.H. (2021). Prediction of suspended sediment distributions using data mining algorithms. *Ain Shams Engineering Journal*, 12(4), 3439-3450.
- Mehri, Y., Soltani, J. & Khashehchi, M. (2019). Predicting the coefficient of discharge for piano key side weirs using GMDH and DGMDH techniques. *Flow Measurement and Instrumentation*, 65, 1-6.
- Meng, X., Zhou, Y., Sun, Z., Ding, K. & Chong, L. (2021). Hydraulic characteristics of emerged rigid and submerged flexible vegetations in the riparian zone. *Water*, 13(8), 1057.
- Muhammad, M.M., Yusof, K.W., Mustafa, M.R.U., Zakaria, N.A. & Ab Ghani, A. (2018). Prediction models for flow resistance in flexible vegetated channels. *International journal of river basin management*, 16(4), 427-437.
- Noarayanan, L., Murali, K. & Sundar, V. (2012). Manning's 'n' co-efficient for flexible emergent vegetation in tandem configuration. *Journal of hydro-environment research*, 6(1), 51-62.
- Pradhan, A. and Khatua, K.K. (2018). Gene expression programming to predict Manning's n in meandering flows. *Canadian Journal of Civil Engineering*, 45(4), 304-313.
- Roushangar, K., Sagheblian, S.M. & Mouaze, D. (2017). Predicting characteristics of dune bedforms using PSO-LSSVM. *International Journal of Sediment Research*, 32(4), 515-526.
- Roushangar, K. & Shahnazi, S. (2019). Bed load prediction in gravel-bed rivers using wavelet kernel extreme learning machine and meta-heuristic methods. *International Journal of Environmental Science and Technology*, 16, pp.8197-8208.
- Wu, F. S. (2008). Characteristics of flow resistance in open channels with non-submerged rigid



vegetation. *Journal of Hydrodynamics*, 20(2), 239-245.

Xu, W.G., Zhang, H.Y., Wang, Z.Y. and Huang, W.P. (2012). A study of manning coefficient related with vegetation density along the vegetated channel. *Applied Mechanics and Materials*, 212, 744-747.

Yarahmadi, M.B., Parsaie, A., Shafai-Bejestan, M., Heydari, M. & Badzanchin, M. (2023). Estimation of Manning roughness coefficient in alluvial rivers with bed forms using soft computing models. *Water Resources Management*, 1-22.

Zhang, H., Wang, Z., Xu, W. & Wang, H. (2019). Determination of emergent vegetation effects on Manning's coefficient of gradually varied flow. *IEEE Access*, 7, 146778-146790.

Experimental study of flow resistance in the presence of rigid vegetation and its prediction with intelligent models

EXTENDED ABSTRACT

Introduction

The presence of vegetation in rivers and waterways is one of the main factors that increases the roughness coefficient, therefore, it should be considered in the designs. Research related to vegetation in waterways has often been conducted with the assumption of uniform flow conditions (Zhang et al., 2019). In addition, limited research has been done on different types of vegetation. Therefore, it is necessary to investigate Manning's coefficient in the presence of vegetation under gradually varied flow conditions.

This research aims to provide a high-accuracy model for determining the Manning's coefficient of the bed with different arrangements of rigid vegetation in the gradually varied flow conditions. There are various methods for calculating Manning's coefficient, including laboratory and intelligent models. Although intelligent models have high accuracy and low-cost, which are faster than laboratory works, experimental data is needed to train these models. Considering the need to accurately calculate the Manning's coefficient in river beds for proper design, using intelligent methods to determine the Manning's coefficient can be helpful. Based on the results of previous research, five models of GMDH, ANN-RBF, RT, ANFIS, and ANFIS-PSO were used to predict the Manning's coefficient.

Methodology

In this research, 86 experiments were conducted in a flume with vegetation with different arrangements under the gradually varied flow conditions, so that these data can be used for calibration and validation of the models. Then, five models of GMDH, ANN-RBF, RT, ANFIS, and ANFIS-PSO were used to evaluate the Manning's coefficient. All models were coded in the MATLAB software. All parameters affecting Manning's coefficient were extracted and used as input and output parameters in modeling. Also, the experiments of this research were carried out in the central water research laboratory of the Department of Irrigation and Reclamation Engineering, University of Tehran. The examined flume has a rectangular cross-section with a width and height of 0.5 m and a length of 12 m, respectively. The bottom of the flume is made of plexiglass, and its wall is made of glass. The slope of this flume is constant and equal to 0.002. The laboratory's circulating water distribution system was used to supply the stream water used in this channel.

Results and Discussion

The results showed that there is an acceptable agreement between the laboratory water surface profile and the predicted results by Euler's method. The evaluation of the results based on some important statistics showed that the ANFIS-PSO model has a better performance than other models in predicting the Manning's coefficient. Hence, the results of this model are $RMSE=0.0096$, $R^2=0.9984$ and $KGE=0.9922$ in the training phase, and $RMSE=0.0099$, $R^2=0.9982$ and $KGE=0.9873$ in the test phase. In the following order, the ANN-RBF model with the accuracy of $RMSE=0.0157$, $R^2=0.9962$ and $KGE=0.9663$, the GMDH model with the accuracy of $RMSE=0.0246$, $R^2=0.9894$ and $KGE=0.9595$, the ANFIS model with the accuracy of $RMSE=0.0328$, $R^2=0.9826$ and $KGE=0.9302$ and the RT model with the accuracy of $RMSE=0.0538$, $R^2=0.9558$ and $KGE=0.9106$ are in the test phase. Considering that different combinations were used in the modeling, it was determined by evaluating the results that three parameters, respectively, vegetation density (D), vegetation arrangement (N), and Reynolds number (Re), had a greater effect in providing correct results.

Conclusions

Using the Euler's numerical method, it was shown that the laboratory data matched the water surface profile calculated by this method. By examining the results, it was found that the ANFIS-PSO model has the most accuracy compared to other models. The lowest performance was assigned to RT. The parameters of vegetation density (D), vegetation arrangement (N), and Reynolds number (Re) played the most crucial role in the development of models. Therefore, the ANFIS-PSO model should be used to predict the Manning's coefficient in the mentioned conditions.

Keywords: Machine Learning, Laboratory Investigation, Modeling, Gradually Varied Flow, Roughness.