

Research Paper

Intelligent Modeling of Salty Density Current in the Presence of Permeable Obstacles

Mehdi Derakhshannia¹, Mehdi Ghomeshi², Seyed Saeid Eslamian^{3*}, Seyed Mahmood Kashefipour²

1.Ph.D. Candidate, Department of Civil Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran

2.Professor, Department of Water Structures, Faculty of Water and Environmental Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran

3.Professor, Department of Civil Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran. and Department of Water Engineering, College of Agriculture, Isfahan University of Technology, Isfahan, Iran

Received: 2020/10/01

Revised: 2020/12/23

Accepted: 2021/07/14

Use your device to scan and read the article online



DOI:

10.30495/wej.2021.26178.2270

Keywords:

Density current, Sedimentation, Head reduction percentage, Feed Forward neural network, Multivariate regression

Abstract

Introduction: Density current is one of the most important factors in the sedimentation process of dams. Increased sediment will reduce dam storage capacity and makes significant challenges for relevant engineers. Therefore, understanding the dynamics of density fluids and related sediment patterns is very efficient for dam reservoir management.

Methods: The purpose of this study was to create an intelligent model with appropriate adaptation to laboratory data so that, it can be used in future designs with different variables. Therefore, in this study, the percentage of reduction of density salt current head under the influence of trapezoidal permeable obstacles (aggregates with a diameter of 1 cm), taking into account variables such as discharge, slope, concentration and height of obstacles in laboratory.

Findings: Based on the results, the density salt current head was modeled using the artificial neural network feed-forward method and the classical multivariate regression method, and the performance of these two methods was compared. The results showed that the intelligent feed neural network intelligent method in modeling the percentage reduction of density salt current head is significantly superior to the multivariate regression method so that the training, calibration and test regression values are 0.99, 0.98 and 0.98 were obtained for neural network and 0.92, 0.91 and 0.91 for multivariate regression, respectively.

Conclusion: The performance of the artificial neural network is much better than the multivariate regression method.

Citation: Derakhshannia M, Ghomeshi M, Slamian S, Kashefipour M. Intelligent modeling of salty density current in the presence of permeable obstacles. Water Resources Engineering Journal. 2022; 15(53): 53-70.

***Corresponding author:** Seyed Saeid Eslamian

Address: Department of Civil Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran. and Department of Water Engineering, College of Agriculture, Isfahan University of Technology, Isfahan, Iran

Tell: +989131157554

Email: saeid@iut.ac.ir

Extended Abstract

Introduction

The number of dams built for flood control, water supply, and electricity generation has increased in the past decades. Sedimentation behind the walls of dams is the biggest problem that causes the reduction of water storage space in the reservoirs, which will reduce the lifespan of the dam compared to the expected time. Considering the huge cost of building a dam, engineers are always looking for solutions to solve this problem. Through the investigations, the researchers realized that density currents are often the cause of sediment transfer in reservoirs, and since the main driving forces of these currents are gravity and the density difference between the sediment flow and the surrounding liquid, the currents are classified as dense currents. Many researchers studied the characteristics of density currents using laboratory, numerical and field studies. Some studies were on the influence of effective parameters on density currents such as bottom roughness and slope. Garcia (18) studied the behavior of density currents in the vicinity of variable slope in the form of sedimentary and saline currents, in this research, velocity, concentration and profile of velocity and concentration were measured. Peters and Wenart (25) used a fluorescence laser device to better understand the behavior of density currents, and the results showed that the roughness of the substrate decreases the velocity and average concentration of the current head. Bass et al. (5) conducted some experiments to study the characteristics of flow and deposition in density currents with high concentration. Nogira et al. (23) investigated the effect of bed roughness and inlet concentration on concentrated saline flow in a laboratory.

Data were used to model turbidity current using feed forward artificial neural network and classical multivariate regression method, and intelligent genetic through the comparison, it was found that the modeling

method with feed-forward artificial neural network for training and test data had a much better performance than the multivariate regression method, so that the RMSE criterion related to the neural network is much lower than the value. This criterion is for the multivariate regression method, and the regression values of training, calibration, and test were 0.99, 0.98, and 0.98, respectively for the neural network and 0.92, 0.91, and 0.91 for the multivariate regression.

Materials and Methods

All the experiments of this study were done in the hydraulic laboratory of Shahid Chamran University of Ahvaz. A rectangular flume with a length of 7.8 meters, a width of 0.35 meters and a depth of 0.7 meters was used to perform the experiments, which was able to change the slope up to four percent. At the entrance of the channel, a vertical Plexiglas plate with 10 cm opening capability, which remains fixed until the end of the experiment, was used as an inlet valve, the upstream and downstream parts of the valve were filled with density currents and clear water, respectively. A cylindrical tank with a capacity of 3 cubic meters equipped with a mixer was used to prepare density fluid. The density fluid was pumped from the cylindrical tank to the head tank which was fixed at a height of 3 meters from the ground and was transferred to the back of the valve with a fluid pipe. An electromagnetic flow meter with an accuracy of one thousand liters per second was used to determine the concentrated flow. The trapezoidal obstacles were made using a metal net with a wall slope of 1:1 and filled with sand grains with a diameter of 1 cm, in such a way that the obstacle completely filled the width of the channel. The length of the obstacle was 25 cm with a variable height, algorithm method was used to determine the desired

parameters in multivariate regression method. Through the comparison, it was found that the modeling method with feedforward artificial neural network for training and test data had a much better performance than the multivariate regression method, so that the RMSE criterion related to the neural network is much lower than the value. This criterion is for the multivariate regression method, and the regression values of training, calibration, and test were 0.99, 0.98, and 0.98, respectively for the neural network and 0.92, 0.91, and 0.91 for the multivariate regression.

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: Mehdi Derakhshannia, Mehdi Ghomeshi, Seyed Saeid Eslamian, Seyed Mahmood Kashefipour.

Methodology and data analysis: Mehdi Derakhshannia, Mehdi Ghomeshi, Seyed Saeid Eslamian, Seyed Mahmood Kashefipour.

Supervision and final writing: Mehdi Derakhshannia, Mehdi Ghomeshi.

Conflicts of interest

The authors declared no conflict of interest.

Findings

In this section, data modeling has been done using feedforward neural network, the inputs of this network include the height of the barrier, floor slope, concentration, and the input flow rate, and the output of the network is the percentage of the reduction in flow rate. The structure of the neural network used in this section is (1-n-4), the first number from the left indicates the number of network inputs, the second which was installed at a distance of 2 meters from the valve.

Discussion

As shown, the results of data modeling with polynomial regression show relatively poor performance compared to other researches, and other intelligent methods have performed better in modeling, however, the performance of the feedforward neural network with a prediction error of 0.0028 is very favorable. It has been in such a way that it shows good performance compared to other very powerful intelligent modeling methods.

Conclusion

In this research, the effect of permeable obstacles on the percentage of density current head was modeled using MATLAB software. For this purpose, feedforward artificial neural network method and classical multivariate regression method were used. The performance process was such that the density current was created by considering different variables of flow rate, concentration and slope, and by placing a trapezoidal permeable obstacle at a distance of 2 meters from the obstacle, the flux values before and after the obstacle were determined. And then, the percentage of head reduction was also obtained.

مقاله پژوهشی

مدل سازی هوشمند جریان غلیظ نمکی در حضور موانع نفوذپذیر

مهدی درخشان نیا^۱، مهدی قمشی^۲، سید سعید اسلامیان^{۳*}، سید محمود کاشفی پور^۲
 ۱. دانشجوی دکتری، گروه مهندسی عمران، واحد نجف آباد، دانشگاه آزاد اسلامی نجف آباد، نجف آباد، ایران .
 ۲. استاد، گروه سازه های آبی، دانشکده مهندسی آب و محیط زیست، دانشگاه شهید چمران اهواز، اهواز، ایران.
 ۳. استاد، گروه مهندسی عمران، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران. و گروه مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، اصفهان، ایران

چکیده

مقدمه: جریان غلیظ یکی از مهمترین عوامل در فرآیند رسوب گذاری سدها می باشد. افزایش رسوب در نزدیک دیواره سد، ظرفیت ذخیره سازی آن را کاهش داده و چالش های قابل توجهی را برای مهندسیین مربوطه ایجاد می کند. بنابراین درک پویایی سیالات غلیظ و الگوهای رسوبی مرتبط جهت مدیریت مخزن سدها بسیار کارآمد است.

روش: هدف از این تحقیق ایجاد یک مدل هوشمند با تطابق مناسب با داده های آزمایشگاهی بوده تا بتوان از آن در طرح های آتی با متغیرهای متفاوت نیز استفاده نمود. براین اساس در این تحقیق درصد کاهش هد جریان غلیظ نمکی تحت تاثیر موانع نفوذپذیر دوزنقه ای شکل (سنگ دانه ها با قطر ۱ سانتیمتر)، با در نظر گرفتن متغیرهایی همچون دبی، شیب، غلظت و ارتفاع موانع به صورت آزمایشگاهی مورد بررسی قرار گرفت، سپس براساس نتایج حاصله اقدام به مدل سازی هد جریان غلیظ نمکی با روش شبکه عصبی مصنوعی پیش خور و روش کلاسیک رگرسیون چند متغیره شد و کارکرد این دو روش مورد مقایسه قرار گرفت.

یافته ها: نتایج نشان داد که روش هوشمند شبکه عصبی مصنوعی پیش خور در مدل سازی درصد کاهش هد جریان غلیظ نمکی نسبت به روش رگرسیون چند متغیره برتری قابل توجهی دارد به گونه ای که مقادیر رگرسیون آموزش، واسنجی و تست به ترتیب ۰/۹۹، ۰/۹۸ و ۰/۹۸ برای شبکه عصبی و ۰/۹۲، ۰/۹۱ و ۰/۹۱ برای رگرسیون چند متغیره بدست آمد.

نتیجه گیری: عملکرد شبکه عصبی مصنوعی نسبت به روش رگرسیون چند متغیره کارایی بسیار بهتری دارد.

تاریخ دریافت: ۱۳۹۹/۰۷/۱۰

تاریخ داوری: ۱۳۹۹/۱۰/۰۳

تاریخ پذیرش: ۱۴۰۰/۰۴/۲۳

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



DOI:

10.30495/wej.2021.26178.2270

واژه های کلیدی:

جریان غلیظ، رسوب گذاری، درصد کاهش هد، شبکه عصبی پیش خور، رگرسیون چند متغیره

* نویسنده مسئول: سید سعید اسلامیان

نشانی: گروه مهندسی عمران، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران. و گروه مهندسی آب، دانشکده کشاورزی، دانشگاه صنعتی اصفهان، اصفهان، ایران.

تلفن: +989131157554

پست الکترونیکی: saeid@iut.ac.ir

مقدمه

ارتفاع مانع باعث کاهش شار رسوب عبوری و در نتیجه رسوب‌گذاری بیشتر در بالادست موانع می‌شود.

در تحقیق‌های آزمایشگاهی به دلیل هزینه‌بر بودن و زمان بالا انجام این طرح‌ها، محققین تمایل به استفاده از روش‌های عددی پیدا کرده‌اند. براین اساس در دو دهه گذشته استفاده از روش‌های عددی در مهندسی هیدرولیک، منابع آب و هیدرولوژی افزایش یافته است، در این راستا یوهانگ و ونسینگ (28) از یک شبکه عصبی مصنوعی سه لایه (ANN) که براساس الگوریتم یادگیری مبتنی بر لونیگ-مارکارت ایجاد شده بود، برای برآورد ضریب اصطکاک جریان در کانال‌های باز استفاده نمودند. مروتیونجایا و همکاران (22) از الگوریتم شبکه عصبی انتشار مجدد (BP) برای پیش بینی سرعت در یک جریان کانال باز مرکب استفاده نمودند. بقالیان و همکاران (6) تغییرات سرعت را در یک کانال خمیده با قوس ۹۰ درجه انجام دادند. در این تحقیق روش‌های هوش مصنوعی، تحلیلی و آزمایشگاهی را مورد بررسی قرار دادند. با تحلیل‌های انجام شده متوجه شدند که روش آزمایشگاهی و عددی تطابق بهتری نسبت به روش تحلیلی در پیش‌بینی داده‌ها نشان می‌دهد. هوویچی و همکاران (19) با استفاده از روش شبکه عصبی (ANN) طول پرش هیدرولیکی را در کانال U-شکل تخمین زدند. عباس‌پور و همکاران (1) برای پیش‌بینی ویژگی‌های پرش هیدرولیکی مانند مکان ایجاد و انرژی آزاد شده را مورد بررسی قرار دادند، برای این منظور از روش شبکه عصبی (ANN) و برنامه‌نویسی ژنتیکی (GP) استفاده نمودند که نتایج نشان داد که روش شبکه عصبی (ANN) بسیار دقیق‌تر از روش برنامه‌نویسی ژنتیکی (GP) می‌باشد.

کای و ناروسی (11) روش جدیدی برای تجزیه و تحلیل جریان‌های کدر ارایه نمودند. آنها برای تحلیل داده‌ها از شبکه عصبی یادگیری عمیق (DNN) استفاده نمودند. با بررسی‌های انجام شده مشخص شد که تطابق مناسبی بین داده‌های واقعی و مدل‌سازی وجود دارد و براین اساس می‌توان از این شبکه جهت پیش‌بینی داده‌های واقعی در آینده استفاده نمود. ناروسی و ناكاو (23) با استفاده از شبکه عصبی یادگیری عمیق به بررسی جریان کدر ایجاد شده در طول ۱۰ کیلومتر پرداخته و برداشت داده‌ها نیز در مقاطع ۱ کیلومتر انجام شد. با بررسی نتایج مشخص شد که این شبکه به طور بسیار مطلوبی توانسته داده‌ها را مدل‌سازی کند و براین اساس می‌توان از آن در تحلیل‌های میدانی نیز استفاده نمود. سانگ و جانگ (27) در این مطالعه از شبکه عصبی حافظه کوتاه مدت (LSTM) جهت شناسایی، واسنجی و محاسبه کدورت در مخزن Qingcaosha استفاده نمودند. این مدل از داده‌های پیشین کدورت، سطح آب، جهت و سرعت باد در طی یک دوره ۲ ساله در نقاط مختلف به عنوان ورودی استفاده نمود. در ۴۰٪ تکرار از مدل، میانگین خطای مربع به طور پیوسته به کمتر از ۰.۰۵ همگرا شد و ضریب کارایی نش از پیش‌بینی ۲۴ ساعته بالای ۰.۵

تعداد سدهای ساخته شده برای کنترل سیلاب، آبرسانی، تولید برق در دهه‌های گذشته افزایش یافته است (10). ته‌نشینی رسوبات در پشت دیواره سدها بزرگ‌ترین معضلی است که سبب کاهش فضای ذخیره آب در مخازن می‌شود، که همین امر سبب کاهش طول عمر سد نسبت به زمان پیش‌بینی شده خواهد شد (14). با توجه به هزینه هنگفت ساخت سد، مهندسین همواره به دنبال راهکارهایی جهت حل این معضل می‌باشند. محققین با بررسی‌های انجام داده متوجه شدند که جریان‌های کدر اغلب عامل انتقال رسوب در مخازن می‌باشند و چون نیروهای اصلی محرک این جریان‌ها، نیروی جاذبه و اختلاف چگالی بین جریان رسوبی و مایع محیط می‌باشند، این جریان‌ها زیرمجموعه جریان‌های چگال یا غلیظ قرار گرفته‌اند (3).

بسیاری از محققین ویژگی‌های جریان کدر را با استفاده از روش‌های آزمایشگاهی، عددی و همچنین مطالعات میدانی مورد مطالعه قرار دادند (2). برخی مطالعه‌ها بر تأثیر پارامترهای موثر بر جریان‌های کدر مانند زبری و شیب کف بود (20). گارسیا (18) رفتار جریان‌های غلیظ را در مجاورت شیب متغیر به صورت جریان‌های رسوبی و نمکی مورد مطالعه قرار داد، در این تحقیق سرعت، غلظت و پروفیل سرعت و غلظت اندازه‌گیری شد. پیترز و ونارت (25) برای درک بهتر رفتار جریان‌های کدر از دستگاه لیزر فلورانس استفاده نمودند که نتایج نشان داد که زبری بستر باعث کاهش سرعت و میانگین غلظت هد جریان می‌شود. یاس و همکاران (5) برخی از آزمایش‌ها را برای مطالعه خصوصیات جریان و رسوب‌گذاری در جریان‌های کدر با غلظت بالا انجام دادند. نوگیرا و همکاران (24) اثر زبری بستر و غلظت ورودی را بر جریان غلیظ نمکی بصورت آزمایشگاهی مورد بررسی قرار دادند. فلیکس و همکاران (16) سه سری آزمایش با غلظت‌های مختلف انجام دادند، جریان غلیظ ایجاد شده در سری اول با استفاده از ۱۶ درصد کائولینات و دو سری دیگر نیز با استفاده از ۴ و ۲۸ درصد پودر سیلیس انجام شد. در انجام این آزمایش‌ها از سرعت‌سنج اولتراسونیک داپلر استفاده شد و پروفیل سرعت و غلظت در ارتفاع‌های مختلف اندازه‌گیری و ارایه شد. فیروزآبادی و همکاران (17) برخی از آزمایش‌ها را در مورد جریان غلیظ نمکی و رسوبی انجام دادند و پارامترهایی همچون غلظت‌های مختلف ورودی، دبی و شیب کف را مورد بررسی قرار دادند.

در دو دهه اخیر محققین متوجه شدند که ساخت موانع یکی از کاربردی‌ترین روش‌ها در راستای کنترل جریان‌های غلیظ می‌باشد و براین اساس بیشتر تحقیق‌ها در مورد تأثیر موانع بر جریان‌های غلیظ انجام شد و طرح‌های آزمایشگاهی بسیار در این زمینه انجام شد. فرزین و همکاران (15) به بررسی تأثیر غلظت رسوب و ارتفاع مانع بر ویژگی‌های جریان‌های غلیظ پرداختند. نتایج نشان داد که افزایش

موردشان کم توجهی شده و یا به دلیل دخیل شدن افراد زیاد در طرح، افرادی با ضعف‌های علمی یا عملی بخش‌هایی از کار را انجام داده که سبب ایجاد خطا در نتیجه نهایی می‌شود. در کنار این موضوع می‌توان به ایجاد وقفه زمانی در آزمایشات اشاره کرد که سبب تغییر کاربری ابزارآلات مربوطه شده و نیاز به دوباره آماده‌سازی آزمایشگاه برای موضوع مورد بررسی می‌باشد که به طور معمول این روند سبب تغییرات مختلفی در بخش‌های مختلف ابزارآلات آزمایشگاه شده و به کاهش ارزش نتایج نهایی طرح می‌انجامد. براساس مشکلات ارایه شده، روش‌های عددی راهکاری بسیار مثرتر در این شاخه تحقیقی بوده که می‌تواند با تعداد داده‌های محدود، پارامترهای مختلف را با تغییرات در بازه‌های مختلف و با تعیین میزان خطا مشخص مورد ارزیابی قرار دهد و حتی بسیاری از پارامترها را با کارایی کم شناسایی کرده و با استدلال درست در طرح‌های آزمایشگاهی آتی توسط کاربر حذف شوند. در ضمن با روش‌های هوشمند می‌توان قبل از توسعه بخش‌های مختلف طرح تحقیقی، دورنمایی جامع از روند و خطاهای محتمل به دست آورد که این دید جدید و جامع کمکی ارزنده به بسیار از مشاورین طرح‌های تحقیقی در سطح کشوری داشته و کمک می‌کند که بسیار از آزمایشات به طور کل یا بخش‌هایی از آنها حذف شود، در صورتی که در روش معمول نیاز به هزینه و زمان بسیار برای رسیدن به این دیدگاه می‌باشد.

براساس مطالب ارایه شده در زمینه کارایی مطلوب روش‌های هوشمند، اصلی‌ترین هدفی که در این تحقیق توسط نویسندگان دنبال می‌شود عبارت است از بررسی عملکرد روش‌ها هوشمند مدل‌سازی و مقایسه آن با روش‌های کلاسیک در شبیه‌سازی جریان‌های غلیظ می‌باشد. با توجه به مطالعات وسیع نویسندگان این مقاله مشخص شد که تحقیقات بسیار اندکی بر کارایی روش‌های هوشمند در مدل‌سازی جریان‌های غلیظ انجام شده است.

براین‌اساس در بخش اول این تحقیق به بررسی موانع دوزنقه‌ای ساخته شده از مش فلزی که با شن به قطر ۱ سانتی‌متر کاملاً پر شده پرداخته شده و تأثیر پارامترهای مهم از جمله غلظت، دبی ورودی، شیب و ارتفاع موانع بر رفتار جریان غلیظ مورد بررسی قرار گرفت. میزان شار هد جریان براساس پارامترهای دبی، غلظت و ارتفاع هد جریان غلیظ قبل و بعد از موانع محاسبه و براساس نتایج حاصله اقدام به آموزش سیستم استنتاج عصبی- فازی تطبیقی شد و مقادیر درصد شار هد جریان غلیظ حاصله با روش رگسیون چند متغیره مقایسه و روش بهینه ارایه گردید. در صورت عملکرد مناسب این روش‌ها امکان بررسی این پارامترها در بازه‌های مختلف در طرح‌های آتی میسر می‌شود.

آزمایش‌ها

کلیه آزمایش‌های این مطالعه در آزمایشگاه هیدرولیک دانشگاه شهید چمران اهواز انجام شده است. برای انجام آزمایش‌ها از یک فلوم مستطیل شکل با طول ۷.۸، عرض ۰.۳۵ و عمق ۰.۷ متر که قادر به تغییر شیب تا چهار درصد بود، استفاده شد (شکل ۱). در ورودی کانال

بدست آمد. این نتایج نشان داد که مدل دارای ویژگی‌های همگرایی سریع، پایداری بالا و پیش بینی دقیق می‌باشد، به این معنی که این مدل می‌تواند به خوبی برای پیش بینی مقادیر کدورت مخزن استفاده شود. بلودرسی و همکاران (۸) به بررسی و پیش‌بینی جریان رودخانه‌ها با استفاده از سیستم استنتاج عصبی فازی تطبیقی متوالی پرداختند که این روش به خوبی توانست داده‌ها را مدل‌سازی کند. چانگ و همکاران (۱۳) در این مطالعه از یک سیستم پشتیبانی تصمیم هوشمند استفاده نمودند. ماژول‌های ایجاد شده توسط آنها عبارتند از: پرس و جو از پایگاه داده عملیات مخزن، پیش بینی الگوی طوفان، استراتژی عملیاتی پیش از رهاسازی آب برای تولید برق، پیش بینی بارش رواناب برای رواناب مخزن، زمان‌بندی رسوب مخزن و تجزیه و تحلیل خطر تأمین آب. تجزیه و تحلیل رسوب و ماژول تجزیه و تحلیل خطر تأمین آب براساس دوازده طوفان با جریان غلیظ به سد ساخته شده است. سرعت جریان غلیظ و زمان حرکت آن برای رسیدن به سد با توجه به آمار دوازده توفان برآورد شد که نتایج نشان داد که آستانه جریان غلیظ برای رسیدن به سد می‌تواند ۱۵۰۰ سانتی‌متر تنظیم شود.


مطالب ارایه شده نشان می‌دهد که مطالعات اندکی بر تأثیر موانع بر کنترل جریان غلیظ انجام شده است که نیاز به انجام این مطالعه احساس می‌شود، در ضمن این مطالعه جزو محدود تحقیقاتی می‌باشد که به مدل‌سازی داده‌های آزمایشگاهی در زمینه درصد کاهش شار هد به وسیله روش‌های یادگیری هوشمند پرداخته است. براین‌اساس ابتدا اثر موانع دوزنقه‌ای ساخته شده از مش فلزی که با شن به قطر یک سانتی‌متر کاملاً پر شده استفاده و تأثیر برخی پارامترهای مهم از جمله غلظت، دبی ورودی، شیب و ارتفاع موانع بر رفتار جریان غلیظ مورد بررسی قرار گرفت. برای ارزیابی تمام متغیرها، میزان شار هد جریان غلیظ قبل و بعد از موانع محاسبه و میزان درصد کاهش هد جریان تعیین شد، سپس براساس نتایج آزمایشگاهی درصد کاهش شار هد با استفاده از روش شبکه عصبی پیش‌خور و روش کلاسیک رگسیون چند متغیره بهینه شده با الگوریتم ژنتیک مدل‌سازی شد. با استفاده از این مدل‌ها می‌توان عملکرد موانع را به ازای پارامترهای مختلف مورد ارزیابی قرار داد.

ضرورت و کاربرد تحقیق

در مبحث هیدرولیک کانال‌های باز، پارامترهای بسیار زیادی بر جریان موثر می‌باشند و به همین دلیل محققین در طرح‌های آزمایشگاهی به هیچ عنوان نمی‌توانند تمامی این پارامترها را به صورت کامل مورد بررسی قرار دهند که همین امر سبب تعریف چندین طرح تحقیقی جداگانه برای تحلیل دقیق یک موضوع می‌شود که در کنار زمان‌بری و هزینه بالا، احتمال خطا را نیز بسیار افزایش می‌دهد، به این صورت که از چند تیم تحقیقی و سرپرست برای تحلیل هر طرح باید استفاده شود که به طور طبیعی بعضی از پیش فرض‌ها تغییر پیدا کرده و یا در

منتقل می‌شود. برای تعیین جریان غلیظ عبوری از یک دی‌سنج الکترومغناطیس با دقت یک هزارم لیتر در ثانیه استفاده می‌شود. موانع دوزنقه‌ای شکل با استفاده از توری فلزی با شیب جداره ۱:۱ ساخته و با دانه‌های شن با قطر ۱ سانتی‌متر پر شده، به گونه‌ای که مانع عرض کانال را کاملاً پر می‌کند. طول مانع ۲۵ سانتی‌متر با ارتفاع متغیر بود که در فاصله ۲ متری از دریچه نصب شده بود.


یک صفحه پلاکسی عمودی با قابلیت بازشدگی ۱۰ سانتی‌متر که تا انتها آزمایش ثابت باقی می‌ماند به‌عنوان دریچه ورودی استفاده شد، قسمت‌های بالادست و پایین‌دست دریچه به ترتیب با جریان غلیظ و آب شفاف پر می‌شد. برای تهیه سیال غلیظ از یک مخزن استوانه‌ای با ظرفیت ۳ مترمکعب که مجهز به میکسر بود، استفاده شد. سیال غلیظ از مخزن استوانه‌ای به هد تانک که در ارتفاع ۳ متری از سطح زمین ثابت شده بود پمپ شده و با یک لوله سیال به پشت دریچه



شکل ۱- نمایشی از فلوم و ابزارآلات آزمایشگاهی (۴).

آزمایش با مانع (با ارتفاع یک، یک‌ونیم و دو برابر ارتفاع بدنه جریان غلیظ) انجام شد. حالت جریان در کلیه آزمایشات به صورت زیر بحرانی بود. غلظت جریان غلیظ هد با استفاده از سیفون‌های نصب شده در قبل و بعد مانع و ارتفاع و سرعت هد از فیلم‌های گرفته شده با استفاده از دوربین دیجیتال تعیین می‌شود. در شکل (۲) به ارایه نحوه برخورد هد جریان غلیظ به مانع در زمان‌های مختلف پرداخته شده است.

۲۲ آزمایش جریان غلیظ نمکی با بررسی پارامترهای مختلفی از جمله تغییرات شیب (نیم، یک و یک‌ونیم درصد)، غلظت ورودی (۱۰ و ۱۵ گرم‌درلیتر) و دی‌سنج (یک، یک‌ونیم و دو لیتر در ثانیه) انجام شد. همان‌گونه که در بخش پیشینه مقاله بیان شد این سه پارامتر بیشترین تاثیر را بر جریان غلیظ داشته و براین‌اساس به ارایه و بررسی آنها پرداخته شده است. (نحوه انجام آزمایش‌ها در جدول (۱) ارایه شده است). ۱۸ آزمایش بدون مانع (برای تعیین ارتفاع بدنه جریان) و ۵۴



شکل ۲- نمای برخورد جریان غلیظ به مانع در زمان‌های مختلف.

جدول ۱-ارایه روند انجام آزمایش‌ها.

ارتفاع مانع	شیب (درصد)	غلظت (گرم بر لیتر)	دبی (لیتر بر ثانیه)
			Q ₁
		C ₁	Q ₂
	S ₁		Q ₃
		C ₂	Q ₁
			Q ₂
			Q ₃
		C ₁	Q ₁
			Q ₂
	S ₂		Q ₃
H ₁		C ₂	Q ₁
			Q ₂
			Q ₃
		C ₁	Q ₁
			Q ₂
	S ₃		Q ₃
		C ₂	Q ₁
			Q ₂
			Q ₃
		C ₁	Q ₁
			Q ₂
	S ₁		Q ₃
		C ₂	Q ₁
			Q ₂
			Q ₃
		C ₁	Q ₁
			Q ₂
	S ₂		Q ₃
H _{1.5}		C ₂	Q ₁
			Q ₂
			Q ₃
		C ₁	Q ₁
			Q ₂
	S ₃		Q ₃
		C ₂	Q ₁
			Q ₂
			Q ₃
		C ₁	Q ₁
			Q ₂
	S ₁		Q ₃
		C ₂	Q ₁
			Q ₂
			Q ₃
		C ₁	Q ₁
			Q ₂
	S ₂		Q ₃
H ₂		C ₂	Q ₁
			Q ₂
			Q ₃
		C ₁	Q ₁
			Q ₂
	S ₃		Q ₃
		C ₂	Q ₁
			Q ₂
			Q ₃


فرض (۲): نگاشت پارامترهای ورودی به خروجی تقریباً در همه جا

هموار است (۹).

فرضیه تحقیق

فرض (۱): تمامی پارامترهای ورودی از جمله (شیب، دبی ورودی و غلظت) و پارامتر خروجی به طور کامل قابل اندازه گیری می‌باشند.

(ANN) می‌تواند جایگزین بسیاری از تحقیقات آزمایشگاهی، نظری و عددی باشد. در واقع این روش شکلی از یک سیستم کامپیوتری چندپرزنده متشکل از عناصر پردازش ساده، پیام‌های مقیاس‌پذیر ساده و درجه بالایی از ارتباط‌های داخلی می‌باشد. محبوب‌ترین نوع این شبکه، شبکه عصبی چند لایه پیش‌خور می‌باشد (MLFF) شکل (3) یک نمودار شماتیک معمولی معماری شبکه عصبی را نشان می‌دهد.



شکل ۳- نمایشی از شبکه عصبی مصنوعی چندلایه پیش‌خور (۲۶).

و از روش BEP برای تعیین وزن‌ها استفاده می‌شود (۲۶).

مزیت و کاربرد شبکه عصبی برای پیش‌بینی هد جریان غلیظ

انجام آزمایش‌های آزمایشگاهی معمولاً محدود بوده و دستیابی به نتایج آزمایشگاهی براساس شرایط مختلف یک مشکل بزرگ می‌باشد. همچنین انجام تست‌های آزمایشگاهی معمولاً پرهزینه و وقت‌گیر بوده و علاوه بر این بسیاری اوقات طرح‌های آزمایشگاهی به صورت خاص برای شرایط یک مشکل طرح‌ریزی شده و هنگامی که طراحان نتایج آزمایشگاهی را دریافت می‌کنند، متوجه می‌شوند که در برخی شرایط به داده‌های اضافی نیاز می‌باشد که دستیابی به آزمایشگاه و ابزارآلات مربوطه برای آزمایش‌های بیشتر گاهی امکان‌پذیر نیست بنابراین ارائه یک ابزار هوشمند برای تجهیز کردن طراح جهت پیش‌بینی دقیق شرایط لازم است علاوه بر این بسیاری از مواقع داده‌های ثبت شده از ابزارآلات آزمایشگاهی خام بوده و نیاز به تخصص برای آنالیز و درون‌یابی آنها به گونه‌ای که مورد استفاده طراح قرار گیرند می‌باشد، اگر ابزاری وجود داشته باشد که بتواند مقادیر پارامترهای طراحی مستقل و خروجی‌های مورد نظر را ارائه دهد، می‌تواند سبب ساده شدن بسیاری از طرح‌ها گردد. رویکرد ارائه شده از این مطالعه براساس هوش مصنوعی تمام مشکلات ذکر شده را حل می‌کند و نشان می‌دهد که دقت پیش‌بینی برای این آزمایش‌ها بسیار مناسب است. در این روش شبکه عصبی مصنوعی آموزش داده می‌شود تا بتوان از آن به جای آزمون آزمایشی استفاده کرد. برای آموزش شبکه عصبی مصنوعی لازم است ابتدا ساختار مناسب برای این شبکه ایجاد شود، همان‌طور که در بخش قبل توضیح داده شد، یکی از

فرض (۳): پارامترهای ورودی مستقل می‌باشند به صورتی که هر کدام تاثیر مشخص و قابل توجهی بر خروجی دارند (۷).

روش شبکه عصبی پیش‌خور

شبکه‌های عصبی مصنوعی مبتنی بر معماری موزی مغز حیوانات می‌باشند، این شبکه در واقع یک روش جایگزین برای حل چالش‌ها و مسائل آرایه می‌دهد و در واقع قادر به محاسبه رفتار بسیاری از سیستم‌های دشوار می‌باشد، بنابراین بسیاری از اوقات شبکه عصبی

معماری معمول شبکه عصبی حاوی یک لایه ورودی، تعدادی لایه پنهان و لایه خروجی می‌باشد و اطلاعات در وزن‌دهی ارتباطات ذخیره می‌شوند. خود لایه‌های پنهان نیز از تعداد متفاوتی نورون تشکیل می‌شوند که هر نورون وزن مخصوصی را دارد.

خطای تناسب بازگشتی (BEP) یک روش رایج برای آموزش شبکه‌های عصبی می‌باشد، الگوریتم آموزش (BEP) چرخه دو مرحله‌ای از انتشار خطا را تکرار و وزن‌دهی را به روز رسانی می‌کند و در حین اجرای الگوریتم (BEP)، بردار ورودی در ابتدای شبکه عصبی وارد می‌شود و سپس به سمت جلو پخش شده تا اینکه به لایه خروجی برسد سپس با استفاده از یک تابع کاهش، تفاوت خروجی و هدف شبکه عصبی محاسبه می‌شود و بعد از بدست آوردن مقدار خطا با شروع از خروجی، مقادیر خطای بدست آمده به عقب پخش می‌شوند، این مقادیر خطا برای محاسبه شیب تابع کاهش استفاده می‌شوند و برای تنظیم وزن‌های شبکه عصبی استفاده می‌شوند، برای به روزرسانی وزن‌دهی، این گرادینان به روش بهینه‌سازی برای به حداقل رساندن تابع کاهش به کار می‌رود. روش بهینه‌سازی معمول برای بدست آوردن وزن‌های بهینه شبکه عصبی معمولاً از روش شیب کاهنده استفاده می‌کنند و وقتی شبکه عصبی پیش‌خور به سطح دقت مطلوب آموزش داده شد، ورودی‌های دلخواه را می‌توان به شبکه عصبی مصنوعی پیش‌خور آرایه داد و خروجی مربوطه را محاسبه کرد. در شبکه عصبی استفاده شده در این مقاله از تابع *تانسیگ* استفاده شده که به صورت رابطه (۱) تعریف می‌شود:

$$y = \frac{2}{1 + \exp(-2x)} - 1 \quad (1)$$

مختلف بیان شده است و مرتبه مناسب برای مدل سازی این داده ها استفاده شده است. معادله چند جمله ای مورد نظر در این تحقیق در حالت کلی براساس رابطه (۲) ارایه می شود.

$$y = P(m, n, k, p) = \beta_0 + \beta_{11}x_1 + \beta_{12}x_1^2 + \dots + \beta_{1m}x_1^m + \beta_{21}x_2 + \beta_{22}x_2^2 + \dots + \beta_{2n}x_2^n + \beta_{31}x_3 + \beta_{32}x_3^2 + \dots + \beta_{3k}x_3^k + \beta_{41}x_4 + \beta_{42}x_4^2 + \dots + \beta_{4p}x_4^p \quad (2)$$

که y نشان دهنده پیش بینی درصد کاهش هد جریان غلیظ و x_1, \dots, x_n پارامترهای ورودی هستند. در حالت کلی برای بدست آوردن پارامترهای β روش تحلیلی حداقل میانگین مربعات خطا با استفاده از مفاهیم جبر خطی به صورت زیر وجود دارد.

$$A = \begin{bmatrix} 1 & x_{12} & \dots & x_{11}^m & x_{21} & \dots & x_{21}^n \\ 1 & x_{12} & \dots & x_{12}^m & x_{22} & \dots & x_{22}^n \\ \vdots & \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{1t} & \dots & x_{1t}^m & x_{2t} & \dots & x_{2t}^n \\ x_{31} & \dots & x_{31}^k & x_{41} & \dots & x_{41}^p \\ x_{32} & \dots & x_{32}^k & x_{42} & \dots & x_{42}^p \\ \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ x_{3t} & \dots & x_{3t}^k & x_{4t} & \dots & x_{4t}^p \end{bmatrix} \quad (3)$$

اگر رابطه (۳) شامل داده های ورودی باشد (t تعداد داده ها می باشد).

$$y^T = [y_1, y_2, \dots, y_t] \quad (4)$$

و y برداری شامل داده های خروجی باشد و پارامترهای چند جمله ای به صورت زیر بدست می آید.

$$\beta = (A^T A)^{-1} A^T y \quad (5)$$

این روش بسیار دقیق بوده و می تواند به صورت تحلیلی پارامترهای مدل چند جمله ای را ایجاد کند و هر چند این روش با مشکلات مهمی نیز روبرو شده و از جمله این که ابعاد ماتریس $A^T A$ می تواند بسیار زیاد باشد و این باعث می شود که گرفتن معکوس این ماتریس بسیار مشکل و وقت گیر باشد، مشکل دیگر اینکه ماتریس فوق از مرتبه کامل نباشد و در نتیجه باعث می شود که دترمینان آن صفر شود و در نتیجه ماتریس فوق معکوس پذیر نبوده و دیگر این روش پاسخگو نمی باشد. به دلیل مشکلات ذکر شده لازم است برای تعیین این پارامترها از روش های بهینه سازی استفاده شود که در این مقاله از الگوریتم بهینه سازی ژنتیک استفاده شده است (۱۹).

محبوب ترین شبکه های عصبی، شبکه عصبی مصنوعی چند لایه پیش خور است که در این مطالعه استفاده شده و تعداد سلول های عصبی موجود در لایه های خروجی و ورودی به طور خاص براساس تعداد اهداف پارامترهای طراحی مستقل می باشند. در طول مهمترین مرحله آموزش، شبکه عصبی سعی می کند رابطه ای بین ورودی ها و خروجی های مسئله براساس داده های آموزش شبیه سازی کند. شبکه عصبی مصنوعی این کار را فقط با وزن دهی نورون ها انجام داده تا زمانی که واسنجی و نتایج آزمون نشان دهد که دقت پیش بینی در سطح قابل قبولی است، در این صورت می توان گفت که ANN با موفقیت آموزش داده شده و شرایط لازم برای جایگزینی به جای طرح خاص آزمایشگاهی را دارد. یکی از جذاب ترین خصوصیات این روش این است که شبکه عصبی مصنوعی آموزش دیده کمتر از ۱ ثانیه طول می کشد تا پیش بینی های خروجی از مشکل را با بیش از ۱۰۰۰ مجموعه پارامترهای طراحی مختلف به طور همزمان ارائه دهد. بنابراین می توان گفت که رویکرد این مطالعه در حل مسایل آبی بسیار کاربردی می باشد (۱). اصلی ترین مزیت این نوع شبکه عصبی نسبت به دیگر انواع شبکه عصبی، سادگی نسبی ساختار آن می باشد به صورتی که استفاده از روش های پیچیده شبکه عصبی به فرابرازش می انجامد که باعث افزایش قابل توجه خطای پیش بینی داده های تست می شود ولی در این روش به دلیل سادگی ساختار آن، مدلسازی به درستی انجام می شود.

روش کار شبکه عصبی مصنوعی در این مطالعه شامل سه مرحله می باشد. در مرحله اول یک شبکه عصبی چند لایه پیش خور با لایه های ورودی پنهان و خروجی و تعداد متفاوت نورون ایجاد می شود. ورودی های شبکه عصبی مصنوعی پیش خور شامل دبی، شیب، غلظت ورودی و ارتفاع موانع بوده و خروجی هدف شبکه عصبی مصنوعی درصد کاهش شار هد می باشد. آموزش شبکه عصبی مصنوعی پیش خور بر اساس داده های آزمایشگاهی و استفاده از روش BEP انجام شده است، در مرحله آموزش شبکه عصبی مصنوعی پیش خور، تکرارهای BEP، ۱۰۰۰ بار فرض شده و سپس با یافتن تعداد نورون های بهینه و براساس شاخص MAE و مقدار رگرسیون، نتایج مدل سازی شبکه عصبی برای داده های آموزشی و تست بررسی می شوند.

مدل سازی با استفاده از رگرسیون چند جمله ای

رگرسیون چند جمله ای، تابعی چند جمله ای است که رابطه بین هر مجموعه ورودی و خروجی مربوطه را بیان می کند. مدل رگرسیون چند جمله ای که شامل بیش از دو متغیر پیش بینی کننده باشد MPR نامیده می شود. رگرسیون چند جمله ای می تواند از نظر عددی ناپایدار شود، خصوصاً اگر درجه بالایی داشته و یا دامنه عملکرد صفر نباشد. اگر درجه چند جمله ای خیلی کم باشد، نمی تواند پیچیدگی تابعی را که فرا گرفته بخوبی نمایش دهد اما با این حال این روش هنوز از بهترین روش های مدل سازی می باشد. در اینجا رابطه آماری بین درصد کاهش هد جریان غلیظ بر اساس سایر پارامترها (ارتفاع موانع، شیب، دبی و غلظت) را با استفاده از معادله MPR مرتبه های

الگوریتم بهینه‌سازی ژنتیک

سپس با انتخاب کروموزوم‌های بهتر، این کروموزوم‌ها با هم ترکیب شده و نسل بعدی کروموزوم‌ها ایجاد می‌شوند، پس از اجرای این فرآیند مشاهده می‌شود که در هر نسل، کروموزوم‌های (جواب‌ها) بهتری حاصل می‌شوند. پس از انجام فرآیند تکامل، مناسب‌ترین کروموزوم به عنوان یک پاسخ بهینه برای مسئله داده شده ارائه می‌شود. در جدول (۲) مراحل الگوریتم ژنتیک نشان داده شده است (۱۹)

الگوریتم ژنتیک یکی از موثرترین روش‌های بهینه‌سازی ابتکاری می‌باشد، در این الگوریتم معمولاً یک جمعیت تصادفی ایجاد شده سپس برای دستیابی به راه‌حل‌های بهتر، مجموعه اولیه تکامل می‌یابد. این فرآیند تکامل ادامه پیدا کرده تا شرایط توقف تکامل ارضا شود. در ابتدا جواب‌های اولیه به عنوان کروموزوم‌های اولیه در نظر گرفته شده و بر اساس تابع هزینه، هزینه اولیه محاسبه می‌گردد و

جدول ۲- مراحل الگوریتم ژنتیک (۲۱).

الگوریتم ژنتیک

۱. ایجاد مجموعه اولیه جمعیت
۲. اگر معیارهای توقف حاصل نشده است، الگوریتم ادامه پیا کند
۳. برای هر کروموزوم در جمعیت انجام دهید
۴. تابع هزینه برای کروموزوم‌ها محاسبه شود
۵. کروموزوم‌ها با هم ترکیب شوند
۶. نسل جدید جایگزین نسل قدیم شوند
۹. بازگشت به ۲

نتایج و بحث

در این بخش با ذکر جزئیات به ارائه نتایج حاصل از مدل‌سازی داده‌های درصد کاهش هد جریان بر اساس پارامترهای ورودی (ارتفاع مانع، شیب کف، غلظت و دبی ورودی) پرداخته شده است. ساختار بهینه‌ای از دو روش مدل‌سازی انتخاب شده و به مقایسه کارایی دو روش پرداخته شده است.

نتایج مدل‌سازی با شبکه عصبی پیش‌خور

در این بخش به مدل‌سازی داده‌ها با استفاده از شبکه عصبی پیش‌خور پرداخته شده است، ورودی‌های این شبکه شامل ارتفاع مانع، شیب کف، غلظت و دبی ورودی بوده و خروجی شبکه درصد کاهش شار جریان می‌باشد. ساختار شبکه عصبی استفاده شده در این بخش (۱- $4-\pi$) می‌باشد که اولین عدد از سمت چپ، نشانگر تعداد ورودی‌های شبکه، دومین عدد نشانگر تعداد نورون‌ها در لایه پنهان و سومین عدد نشانگر تعداد خروجی می‌باشد. در این بخش توجه به دو نکته ضروریست:

۱- به منظور آموزش صحیح شبکه عصبی و تاثیر مناسب هر یک از ورودی‌ها بر خروجی مورد نظر، داده‌ها ابتدا نرمالیزه شده سپس به شبکه اعمال می‌شوند، به این صورت که داده‌های مربوط به هر پارامتر ورودی بر مقدار ماکزیمم آن پارامتر تقسیم شده تا داده‌های مربوطه بین ۰ و ۱ قرار گیرند.

۲- در آموزش شبکه عصبی ۷۰ درصد داده‌ها بصورت تصادفی انتخاب شده و برای آموزش سیستم استفاده می‌شوند و از ۳۰ درصد باقیمانده، ۱۵ درصد برای تست و ۱۵ درصد جهت واسنجی مورد استفاده قرار

وا سنجی متقابل

روش‌های واسنجی متقابل از سه نوع تشکیل شده‌اند که عبارتند از نمونه‌گیری تصادفی، واسنجی متقاطع K فولد و واسنجی یکجا، که واسنجی متقابل K فولد به دلیل دارا بودن ویژگی‌هایی همچون سادگی، آسانی و استفاده از همه داده‌ها برای آموزش و واسنجی بسیار پر کاربرد می‌باشد، با توجه خصوصیات مناسب، در این تحقیق نیز از این روش برای تحلیل داده‌ها استفاده شده است.

عملکرد این روش به این گونه است که ابتدا به تعداد $K-1$ قسمت از داده‌ها برای بخش آموزش استفاده شده و سپس برای بخش واسنجی از باقی داده‌ها استفاده می‌شود، این فرآیند به طور مکرر تکرار می‌شود تا همه K بخش داده به عنوان داده‌های واسنجی استفاده شوند و در مرحله نهایی میانگین خطاهای K بار واسنجی تعیین می‌شود. یکی از ضعف‌های این روش نیاز به تعداد تکرار زیاد آن می‌باشد به این صورت که اگر K خیلی بزرگ انتخاب شود، خطا تخمین زده شده بسیار کم بوده اما مدت زمان محاسبه بسیار زیاد می‌شود، حال اگر مجموعه K خیلی کوچک انتخاب شود، مدت زمان محاسبه کاهش یافته اما مقادیر خطا با دقت بسیار کم محاسبه می‌شود. براین اساس تعیین تعداد بهینه بین میزان خطا و مدت محاسبات به عنوان یک چالش در این روش مطرح می‌گردد و کاربران تلاش می‌کنند که به طور هم‌زمان به انتخاب مدل و برآورد مقدار خطا بپردازند، انجام این هم‌زمانی نیازمند تقسیم مجموعه داده‌ها به سه مجموعه جدا از هم می‌باشد، به عبارت دیگر از زیرمجموعه واسنجی برای تنظیم پارامترهای مدل شبکه عصبی استفاده شود اما نکته حایز اهمیت این است که برای ارزیابی عملکرد شبکه عصبی آموزش دیده نیاز به زیر مجموعه آزمایشی دیگر (مجموعه داده های تست) می‌باشد.



ساختارهای دیگر مشاهده می‌شود که خطای آموزش کمتر نیز حاصل شده اما ساختار (۱-۱۲-۴) مقدار خطای تست کمتری داشته مخصوصاً که خطای واسنجی در مدل‌سازی داده‌ها بسیار مهم می‌باشد و خطای پایین واسنجی نشان می‌دهد که فرابرازش اتفاق نیفتاده و مدل تعمیم‌پذیری مناسبی برای آزمایشات دیگر دارد که در پیش‌بینی داده‌های جدید بسیار کارآمد می‌باشد. در ادامه به بررسی دقیق‌تر نمودارهای رگسیون این شبکه برای داده‌های آموزشی و تست در شکل (۴) پرداخته شده است.

گرفت، مشخصاً سیستمی عملکرد مناسب‌تری دارد که خطای تخمین خروجی آن برای هر سه داده آموزشی، تست و واسنجی کمینه باشد. در این بخش به شبیه‌سازی و آموزش شبکه به ازای تعداد نورون‌های لایه پنهان مختلف پرداخته شده تا بدین طریق تعداد نورون‌هایی که در آنها خطای نورون‌سازی کمینه می‌باشد، بدست آید. با توجه به جدول (۳) واضح است که شبکه با ساختار (۱-۱۲-۴) یعنی ساختاری با ۴ پارامتر ورودی، ۱۲ نورون لایه پنهان و ۱ خروجی مناسب‌ترین شبکه برای مدل‌سازی داده‌های مربوطه بوده و مقادیر ۰.۰۳۳، ۰.۰۷۴، ۰.۰۰۰۰۷۴ و ۰.۰۱۶ کمترین خطا را برای داده‌های آموزشی، واسنجی و تست نشان داده است. البته با بررسی نتایج این شبکه با

جدول ۳- عملکرد شبکه عصبی مصنوعی پیش‌خور به ازای ساختارهای مختلف شبکه

تست		واسنجی		آموزش		ساختار	ردیف
RMSE	R	RMSE	R	RMSE	R		
۰.۰۳	۰.۹۹	۰.۰۳۳	۰.۹۹	۰.۰۱۳۲	۰.۹۹	۱-۴-۴	۱
۰.۱۵	۰.۸۴	۰.۰۰۲۶	۰.۹۳	۰.۰۰۷۴	۰.۹۷	۱-۵-۴	۲
۰.۰۶	۰.۹۶	۰.۰۰۶۵	۰.۹۷	۰.۰۰۲۱	۰.۹۹	۱-۶-۴	۳
۰.۰۵	۰.۹۸	۰.۰۰۳۳	۰.۹۸	۰.۰۰۰۳	۰.۹۹	۱-۷-۴	۴
۰.۱۱	۰.۹۶	۰.۰۰۲۱	۰.۹۹	۰.۰۰۱	۰.۹۹	۱-۸-۴	۵
۰.۰۶	۰.۹۵	۰.۰۱۱	۰.۹۶	۰.۰۰۰۲	۰.۹۷	۱-۹-۴	۶
۰.۰۹	۰.۹۴	۰.۰۰۳۳	۰.۹۹	۰.۰۰۰۰۰۳	۰.۹۹	۱-۱۰-۴	۷
۰.۰۷۶	۰.۹۹	۰.۰۰۲۹	۰.۹۹	۰.۰۰۰۰۷۶	۰.۹۹	۱-۱۱-۴	۸
۰.۰۱۶	۰.۹۸	۰.۰۰۲۳	۰.۹۸	۰.۰۰۰۰۷۴	۰.۹۹	۱-۱۲-۴	۹
۰.۱	۰.۹	۰.۰۰۱۵	۰.۸۹	۰.۰۰۰۲۴	۰.۸۹	۱-۱۳-۴	۱۰
۰.۱۷	۰.۴۵	۰.۰۳۱	۰.۷۶	۰.۰۰۳۱	۰.۹۹	۱-۱۴-۴	۱۱

درصد کاهش
شار هد جریان
غلیظ



شکل ۴- نمودار رگسیون برای داده‌های آموزشی و تست شبکه عصبی پیش‌خور

داده‌های آموزشی، واسنجی و تست ۰.۹۹، ۰.۹۸ و ۰.۹۸ بوده که به صورت مطلوبی نزدیک به ۱ است و نشان از قدرت پیش‌بینی بالای شبکه دارد.

شکل (۴) نمودار رگسیون را برای داده‌های آموزشی و تست شبکه عصبی پیش‌خور با ساختار (۱-۱۲-۴) نشان می‌دهد، همان‌طور که مشخص است هر چه مقدار رگسیون به ۱ نزدیک‌تر باشد، آن شبکه عملکرد بهتری در پیش‌بینی داده‌های جدید دارد. مقدار رگسیون

در ادامه به مدل‌سازی داده‌ها با رگرسیون چند جمله‌ای پرداخته شده است.

نتایج مدل‌سازی با روش رگرسیون چند متغیره

در این بخش به ارایه نتایج مدل‌سازی داده‌های درصد کاهش هد جریان بر اساس پارامترهای ورودی پرداخته شده و برای بدست آوردن ضرایب رگرسیون چند جمله‌ای از الگوریتم ژنتیک استفاده شده است. به این صورت که ابتدا به مدل‌سازی داده‌ها برای چند جمله‌ای‌های مختلف پرداخته و سپس توان پارامترها را تا حدی که

فرابرازش اتفاق بیافتد ادامه داده، و براساس معیار RMSE و R بهترین مدل انتخاب شده است.

در جدول (۴) نتایج مدل‌سازی داده‌ها به وسیله رگرسیون چند جمله‌ای با درجه‌های مختلف ارایه شده است. با توجه به اینکه امکان مدل‌سازی داده‌ها با چند جمله‌ای‌های مرتبه بالاتر میسر نمی‌باشد، در مدل‌سازی این داده‌ها فرابرازش اتفاق می‌افتاد به این صورت که عملاً چند جمله‌ای، داده‌های آموزشی را حفظ کرده و در نتیجه خطای داده‌های تست به صورت زیادی افزایش یافته و پاسخ‌های حاصل قابل استناد و مناسب نمی‌باشند.

جدول ۴- نتایج مدل‌سازی داده‌ها توسط رگرسیون چند جمله‌ای و الگوریتم ژنتیک


تست		واسنجی		آموزش		ساختار	ردیف
RMSE	R	RMSE	R	RMSE	R		۱
۰.۷۳	۰.۹۵	۰.۷۱۱	۰.۹۵	۰.۶۹۱	۰.۹۳	$p(1,1,1,1)$	۲
۱.۳۲	۰.۸۸	۱.۸۸	۰.۶۳	۱.۸	۰.۵۸	$p(1,1,1,2)$	۳
۰.۰۷۶	۰.۷۱	۰.۰۷۷	۰.۶۹	۰.۰۷۴	۰.۸۲	$p(1,1,2,1)$	۴
۰.۰۷۸	۰.۵۲	۰.۸۱	۰.۸۵	۰.۰۷۱	۰.۸۷	$p(1,1,2,1)$	۵
۰.۰۵۳	۰.۹۱	۰.۰۴۳	۰.۹۱	۰.۰۳۶	۰.۹۲	$p(2,2,1,1)$	۶
۰.۰۵۱	۰.۷۸	۰.۴۱۵	۰.۸	۰.۰۳۸	۰.۸۷	$p(2,1,2,1)$	۷
۰.۰۴۷	۰.۸	۰.۴۵۵	۰.۸۱	۰.۰۴۱	۰.۸۱	$p(2,2,2,1)$	۸
۱.۷۵	۰.۷۸	۱.۲۱	۰.۸۶	۱.۶۶	۰.۸۵	$p(3,1,1,1)$	۹
۰.۹۱	۰.۷۵	۰.۸۸۵	۰.۷۱	۰.۶۵	۰.۶۳	$p(1,3,1,1)$	۱۰
۰.۸۵۴	۰.۷۴	۰.۷۳۱	۰.۵۹	۰.۷۱	۰.۵۹	$p(1,1,3,1)$	۱۱

درصد کاهش شار
هد جریان غلیظ

همچنین از جدول (۴) مشخص است که خطای واسنجی نیز مقدار ۰.۰۴۳ می‌باشد که مقدار پایین آن مدلسازی صحیح و عدم فرابرازش را نشان می‌دهد و این مهم نشان از تعمیم‌پذیری بالای مدل معرفی شده دارد.

با توجه به شکل (۵) که نمودار رگرسیون چند جمله‌ای با درجه $p(2,2,1,1)$ را نشان می‌دهد مشخص است که خطاهای برازش شده بر روی داده‌ها به خط مرجع با شیب ۱ بسیار نزدیک می‌باشد همچنین ضریب رگرسیون برای داده‌های آموزشی، واسنجی و تست به ترتیب ۰.۹۲، ۰.۹۱ و ۰.۹۱ می‌باشد، که نشان از قدرت پیش‌بینی این روش مدل‌سازی دارد.

با توجه به جدول (۴) مشخص است که رگرسیون چند جمله‌ای بصورت نسبتاً مناسبی قادر بوده داده‌ها را مدل کند و رفتار آنها را پیش‌بینی نماید. در این بین با مقایسه توابع چند جمله‌ای با درجه‌های مختلف مشخص شد که چند جمله‌ای $p(2,2,1,1)$ (هر عدد نشانه درجه آن پارامتر در مدل می‌باشد) به بهترین حالت توانسته رفتار داده‌ها را مدل کند بصورتی که خطای پیش‌بینی برای داده‌های آموزشی، تست به ترتیب ۰.۰۳۶ و ۰.۰۵۳ بوده است که مقادیر کمی می‌باشند در ادامه به بررسی نمودارهای رگرسیون در شکل (۴) پرداخته شده است.

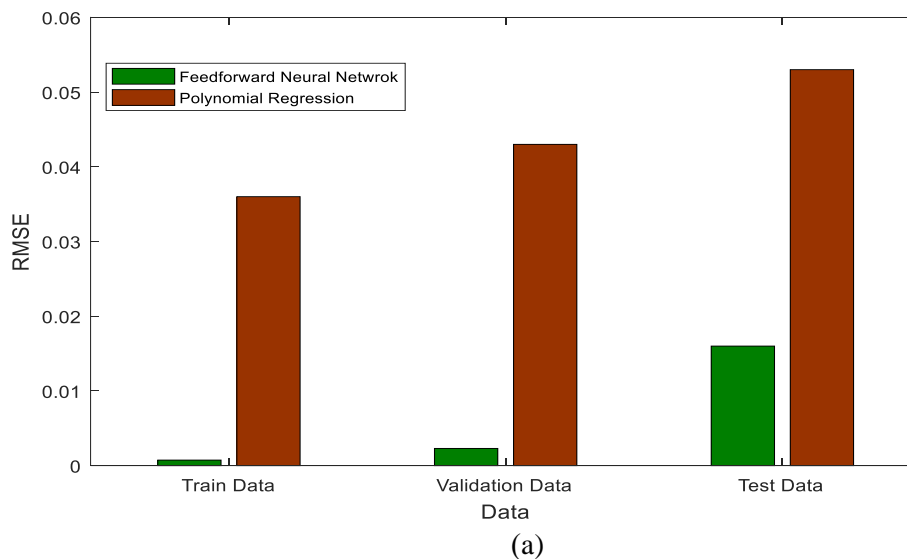


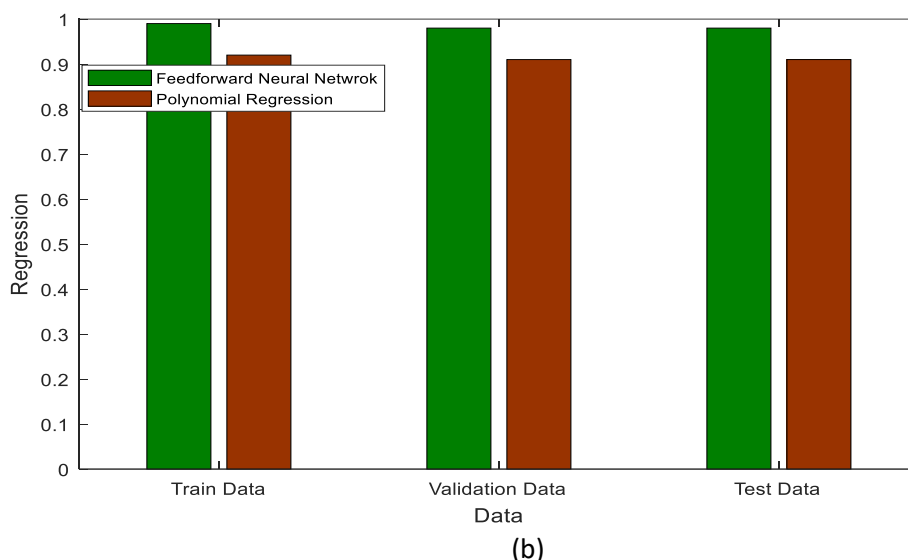
شکل ۵- نمودار رگسیون چند جمله‌ای

کمتر و قدرت پیش‌بینی بیشتری دارد. به دست آوردن روش بهینه مدل‌سازی در این تحقیق بسیار حایز اهمیت بوده، چون انجام آزمایش و محاسبه درصد کاهش هد بصورت آزمایشگاهی به ازای طیف وسیعی از متغیرها بسیار پرهزینه و زمان‌بر می‌باشد. براین اساس شبکه عصبی با نورون مخفی بهینه و رگسیون چند جمله‌ای با مناسب‌ترین درجه با هم مقایسه شده‌اند. نتایج مقایسه در شکل (۶) ارایه شده است.

مقایسه شبکه عصبی مصنوعی پیش‌خور و رگسیون چند جمله‌ای در مدل‌سازی درصد کاهش شار هد جریان

در این بخش عملکرد روش هوشمند شبکه عصبی مصنوعی پیش‌خور با روش رگسیون چند جمله‌ای (بهینه شده با الگوریتم هوشمند ژنتیک) بر مقادیر درصد کاهش هد جریان مورد مقایسه قرار گرفته است تا بتوان تعیین نمود کدام روش مدل‌سازی کارایی بهتر، خطای پیش‌بینی





شکل ۶- مقایسه شبکه عصبی مصنوعی پیش‌خور و رگسیون چند متغیره

رگسیون نزدیک به یک بدست آمده، با این حال تفاوت‌هایی در مقدار رگسیون آنها مشاهده می‌شود و در داده‌های آموزشی مقدار رگسیون شبکه عصبی پیش‌خور تقریباً برابر یک بوده که بسیار مطلوب است با این حال همین مقدار برای مدل‌سازی با رگسیون چند متغیره مقدار کمتری بوده است که حکایت از عملکرد بهتر شبکه عصبی مصنوعی پیش‌خور دارد. مقایسه این مقادیر در داده‌های تست نیز از عملکرد بهتر شبکه عصبی مصنوعی پیش‌خور حکایت دارد همان‌طور که مشخص است مقدار رگسیون شبکه عصبی بصورت مطلوبی بیشتر از این مقدار برای رگسیون چند متغیره است که از عملکرد بهتر این شبکه و قدرت پیش‌بینی بالاتر آن برای داده‌های جدید حکایت دارد.

مقایسه با دیگر تحقیقات

در این بخش به منظور بررسی نتایج به دست آمده به مقایسه نتایج این تحقیق با تحقیقات دیگر پرداخته شده است. نتایج مقایسه در جدول (۵) آورده شده است.

جدول ۵- مقایسه نتایج این تحقیق با سایر تحقیقات

مطالعات	مدلسازی	روش هوشمند مورد استفاده	خطا پیش‌بینی همه داده‌ها (RMSE)
مطالعه حاضر	درصد کاهش هد جریان غلیظ	شبکه عصبی پیش‌خور رگسیون چند متغیره	۰.۰۰۲۸ ۰.۰۰۴
سانگ و زانگ (۲۷)	درصد کاهش هد جریان کدر (آزمایشگاهی و مخزن سد)	شبکه عصبی LSTM	۰.۰۰۲۲
کای و ناروسی (۱۱)	مقادیر رسوبات ته‌نشین شده	شبکه عصبی عمیق	۰.۰۰۴۲
چانگ و همکاران (۱۲)	زمان ورود جریان کدر	ماشین بردار پشتیبان	۰.۰۰۶۱

تحقیقات دیگر نشان می‌دهد و روش‌های هوشمند دیگر در مدلسازی بهتر عمل کرده‌اند با این حال عملکرد شبکه عصبی پیش‌خور با خطای

همان‌طور که از جدول (۵) مشخص است، نتایج حاصل از مدلسازی داده‌ها با رگسیون چند جمله‌ای عملکرد نسبتاً ضعیفی را نسبت به

مقادیر رگسیون آموزش، واسنجی و تست به ترتیب ۰/۹۸، ۰/۹۹ و ۰/۹۸ برای شبکه عصبی و ۰/۹۲، ۰/۹۱ و ۰/۹۱ برای رگسیون چند متغیره بدست آمد.

ملاحظات اخلاقی پیروی از اصول اخلاق پژوهش

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

حامی مالی

هزینه تحقیق حاضر توسط نویسندگان مقاله تامین شده است.

مشارکت نویسندگان

طراحی و ایده‌پردازی: مهدی درخشان نیا ، مهدی قمشی ، سید سعید اسلامیان ، سید محمود کاشفی پور
روش‌شناسی و تحلیل داده‌ها: مهدی درخشان نیا ، مهدی قمشی ، سید سعید اسلامیان ، سید محمود کاشفی پور
نظارت و نگارش نهایی: مهدی درخشان نیا ، مهدی قمشی

تعارض منافع

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

References

1. Abbaspour A, Farsadzadeh D, Ghorbani MA (2013) Estimation of hydraulic jump on corrugated bed using artificial neural networks and genetic programming. *Water Sci Eng* 6:189-198.
2. Abd El-Gawad SM, Pirmez C, Cantelli A, Minisini D, Sylvester Z, Imran J (2012) 3-D numerical simulation of turbidity currents in submarine canyons off the Niger Delta. *Mar Geol* 326-328:55-66.
3. Alexander J, Mulder T (2002) Experimental quasi-steady density currents. *Mar Geol* 186:195-210.
4. Asghari Pari, S. A., Kashefipour, S. M., Ghomeshi, M., & Bajestan, M. S. (2010). Effects of obstacle heights on controlling turbidity currents with different concentrations and discharges. *Journal of Food, Agriculture and Environmen.*, 8(2), 930-935.
5. Baas JH, Kesteren WV, Postma P (2004) Deposits of depletive high-density

پیشبینی ۰.۰۰۲۸ بسیار مطلوب بوده است به صورتی که در مقایسه با روش های مدل‌سازی هوشمند بسیار قدرتمند دیگر نیز عملکرد مطلوبی را نشان می‌دهد.

نتیجه‌گیری

در این تحقیق اثر موانع نفوذپذیر بر میزان درصد شار هد جریان غلیظ با استفاده از نرم‌افزار متلب مدل‌سازی شد. به همین منظور از روش شبکه عصبی مصنوعی پیش‌خور و روش کلاسیک رگسیون چند متغیره استفاده شد. روند عملکرد به این‌گونه بود که جریان غلیظ با در نظر گرفتن متغیرهای مختلف دبی، غلظت و شیب ایجاد شد و با جایگذاری مانعی نفوذپذیر دوزنقه‌ای شکل در فاصله ۲ متری از مانع، مقادیر شار قبل و بعد از مانع تعیین شده و سپس درصد کاهش هد نیز به‌دست آمد. در بخش دوم از داده‌های آزمایشگاهی جهت مدل‌سازی جریان غلیظ با استفاده از شبکه عصبی مصنوعی پیش‌خور و روش کلاسیک رگسیون چند متغیره استفاده شده و برای تعیین پارامترهای مورد نظر در روش رگسیون چند متغیره، از روش الگوریتم هوشمند ژنتیک استفاده شده است. با مقایسه انجام شده مشخص شد که روش مدل‌سازی با شبکه عصبی مصنوعی پیش‌خور برای داده‌های آموزشی و تست عملکرد بسیار بهتری نسبت به روش رگسیون چند متغیره داشته، به طوری که معیار RMSE مربوط به شبکه عصبی بسیار کمتر از مقدار این معیار برای روش رگسیون چند متغیره بوده و همچنین

turbidity currents: a flume analogue of bed geometry, structure and texture. *Sedimentology* 51:1053-1088.

6. Baghalian S, Bonakdari H, Nazari F, Fazli M (2012) Closed-form solution for flow field in curved channels in comparison with experimental and numerical analyses and artificial neural network. *Eng Appl Comput Fluid* 6:514-526.
7. Baghalian, S., & Ghodsian, M. (2017). Experimental analysis and prediction of velocity profiles of turbidity current in a channel with abrupt slope using artificial neural network. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 39(11), 4503-4517.
8. Belvederesi, C., Dominic, J. A., Hassan, Q. K., Gupta, A., and Achari, G. (2020). Predicting river flow using an AI-based sequential adaptive neuro-fuzzy inference system. *Water*, 12(6), 1622.
9. Bishop, C.M., 2006. Pattern recognition and machine learning. *springer*.

10. Brandt SA (1999) Reservoir distillation by means of hydraulic flushing. Ph.D. thesis, Inst. of Geog. Faculty of Sci. University of Copenhagen, pp 204.
11. Cai, Z., & Naruse, H. (2019). Application of Deep Learning Neural Network to the Inverse Analysis of Experimental Scale Turbidity Currents. In AGU Fall Meeting Abstracts (Vol. 2019, pp. EP53E-2290).
12. Chang, L. C., Chang, F. J., Kao, I. F., Chien, C. L., Lin, Y. C., Chang, C. J., ... & Yang, S. N. (2019). Building an Intelligent Reservoir Operation Decision Support System for Flood and Sedimentation Control. In 3rd International workshop on Sediment Bypass Tunnels.
13. Chang, M. J., Lin, G. F., Chen, P. A., Lee, F. Z., & Lai, J. S. (2020). Development of a real-time forecasting model for turbidity current arrival time to improve reservoir desilting operation. *Hydrological Sciences Journal*, 65(6), 1022-1035.
14. Fan J, Morris G (1992) Reservoir sedimentation. I: delta and density current. *J Hydraul Eng* 118:354-369.
15. Farizan, A., Yaghoubi, S., Firoozabadi, B., & Afshin, H. (2019). Effect of an obstacle on the depositional behaviour of turbidity currents. *Journal of Hydraulic Research*, 57(1), 75-89.
16. Felix M, Sturton S, Peakall J (2005) Combined measurements of velocity and concentration in experimental turbidity currents. *Sediment Geol* 179:31-47.
17. Firoozabadi B, Afshin H, Aram E (2009) Three-dimensional modeling of density current in a straight channel. *J Hydraul Eng* 135:393-402.
18. Garcia M (1993) Hydraulic jumps in sediment-driven bottom current. *J Hydraul Eng* 119:1094-1117.
19. Houichi L, Dechemi N, Heddami S, Achour B (2013) An evaluation of ANN methods for estimating the length of hydraulic jumps in U-shaped channel. *J Hydroinform* 15:147-154.
20. Kneller B (2003) "The influence of flow parameters on turbidite slope channel architecture. *Mar Pet Geol* 20(2003):901-910.
21. Kochenderfer, M.J. and Wheeler, T.A., 2019. Algorithms for optimization. Mit Press.
22. Mrutyunjaya S, Khatua KK, Mahapatra SS (2011) A neural network approach for prediction of discharge in straight compound open channel flow. *Flow Meas Instrum* 22:438-446.
23. Naruse, H., & Nakao, K. (2020). Inverse modeling of turbidity currents using artificial neural network: verification for field application. *Earth Surface Dynamics Discussions*, 1-27.
24. Nogueira HIS, Adduce C, Alves E, Franca MJ (2013) Analysis of lock-exchange gravity currents over smooth and rough beds. *J Hydraul Res* 51:417-431.
25. Peters WD, Venart JES (2000) Visualization of rough-surface gravity current flows using laser-induced fluorescence. In: 9th international symposium on flow visualization
26. Rojas, R., 2013. Neural networks: a systematic introduction. Springer Science & Business Media.
27. Song, C., & Zhang, H. (2020). Study on turbidity prediction method of reservoirs based on long short term memory neural network. *Ecological Modelling*, 432, 109210.
28. Yuhong Z, Wenxin H (2009) Application of artificial neural network to predict the friction factor of open channel flow. *Commun Nonlinear Sci Numer Simul* 14:2373-2378.

