

Prediction of Bed Load Transport Rate into Lateral Intakes in Bend Channels Using Hybrid Machine Learning and Discrete Phase Numerical Model

Hossein Montaseri^{1*} ; Hamid Nejati²

*1. Associate Professor, Faculty of Engineering, University of Yasouj, Yasouj, Iran

2. MSc., Faculty of Engineering, University of Yasouj, Yasouj, Iran

*Email Address: hmontaseri@yu.ac.ir

Article Info

Article Type:
Research Paper

Article History:

Received Date:

2025/05/13

Revised Date:

2025/07/31

Accepted Date:

2025/08/25

Published Date:

2025/09/28

Keywords:

Sediment transport,
machine learning,
lateral intakes,
bend channel,
computational fluid dynamics (CFD).

ABSTRACT

This study develops a meta-model combining Fluent numerical simulations and machine learning (ML) to predict sediment diversion into lateral intakes along a U-shaped channel. The model considers key input parameters, including the intake's position along the outer bend, diversion angle, and inflow percentage. Initially, sediment transport was simulated using discrete phase model in a U-shaped channel with a lateral intake positioned at 115° on the outer bank and a 45° diversion angle. The results were validated against experimental data. Following calibration, the numerical model was applied to 31 intake positions along the outer bend (from 10° to 140° at 5° intervals) with diversion angles of 10°, 30°, 50°, 70°, and 90°, and inflow ratios of 20%, 30%, and 40%. For each configuration, the percentage of sediment entering the lateral intake was computed. The resulting dataset was used to train and validate multiple neural network models, including Multi-Layer Perceptron (MLP), Radial Basis Function (RBF), Generalized Regression Neural Network (GRNN), and Support Vector Regression (SVR). Using 70% of the data for training, the meta-model's performance was assessed on the remaining 30%. Error analysis demonstrated that the SVR model outperformed others in predicting bed load sediment rates

Cite this article:

Hossein Montaseri, Hamid Nejati(2025). Prediction of Bed Load Transport Rate into Lateral Intakes in Bend Channels Using Hybrid Machine Learning and Discrete Phase Numerical Model, Journal of Environmental Sciences Studies, 10(3) , Pages 10534-10548.

EXTENDED ABSTRACT

Introduction

This study presents an innovative hybrid approach combining discrete phase numerical modeling with machine learning techniques to predict bedload sediment transport rates into lateral intakes located in curved channel bends. The research addresses a critical gap in sediment management for water diversion systems by developing a predictive model that considers three key parameters: intake position along the outer bend (10° - 140°), diversion angle (10° - 90°), and inflow ratio (20%-40%). The numerical model employed a two-phase discrete phase approach to simulate sediment transport in a U-shaped channel (bend radius: 2.6 m, width: 0.6 m), calibrated against experimental data from Montaseri (2008) for a lateral intake at 115° (45° diversion angle). The validated model was extended to 31 intake positions (10° - 140° at 5° intervals), five diversion angles, and three inflow ratios, generating a dataset for ANN training.

Materials and methods

Numerical Modelling

- Geometry & Setup: U-shaped channel with lateral intake; simulations conducted in *Fluent* using a discrete phase model (DPM) for sediment transport.
- Validation: Results matched against laboratory data (Montaseri, 2008).

Machine Learning Framework

Four ANN architectures were trained on 465 simulated cases (70% training, 30% validation):

1. Multilayer Perceptron (MLP): Optimized with two hidden layers (5 neurons each).
2. Radial Basis Function (RBF): Best performance at $Spread = 0.25$.
3. Generalized Regression Neural Network (GRNN): Optimal $Spread = 5$.
4. Support Vector Regression (SVR): Kernel-based regression for nonlinear prediction.

Results and discussion

The SVR model achieved superior accuracy ($R^2 = 0.982$), followed by RBF ($R^2 = 0.98$), MLP ($R^2 = 0.976$), and GRNN ($R^2 = 0.949$). Error analysis confirmed SVR's robustness in predicting bed load sediment rates under varying hydraulic and geometric conditions.

Conclusion

The meta-model demonstrates that **SVR** outperforms MLP, RBF, and GRNN in predicting sediment diversion to lateral intakes. Recommendations:

- Use SVR for sediment transport predictions in bend channels.
- Optimized ANN architectures (e.g., MLP layers, RBF/GRNN spread values) are critical for model accuracy.

The hybrid model provides water engineers with:

- Reliable sediment intake predictions for diversion structure design
- Framework applicable to various bend geometries
- Decision-support tool for irrigation and flood control systems



پیش بینی نرخ انتقال بار بستر ورودی به آبگیرهای جانبی واقع در آبراهه های قوسی با استفاده از ترکیب مدل های یادگیری ماشین و مدل عددی فاز گسسته

حسین منتصری^{۱*}، حمید نجاتی^۲

^{۱*} - دانشیار، دانشکده مهندسی، دانشگاه یاسوج

^۲ - دانش آموخته کارشناسی ارشد، دانشکده مهندسی، دانشگاه یاسوج

* ایمیل نویسنده مسئول: hmontaseri@yu.ac.ir

چکیده	اطلاعات مقاله
این پژوهش به توسعه یک فرامدل ترکیبی می‌پردازد که مدل عددی دوفازی را با الگوریتم‌های یادگیری ماشین تلفیق می‌کند تا نرخ رسوب انحرافی به آبگیرهای جانبی در قوس رودخانه‌ها را با دقت بالا پیش‌بینی نماید. مطالعه حاضر با در نظر گرفتن سه پارامتر کلیدی موقعیت آبگیر در طول قوس خارجی (۱۰-۱۴۰ درجه)، زاویه انحراف آبگیر (۱۰-۹۰ درجه) و درصد دبی آبگیری (۲۰-۴۰٪)، یک چارچوب تحلیلی جامع را ارائه می‌دهد. ابتدا، با استفاده از مدل دوفازی فاز گسسته در نرم افزار Fluent، شبیه سازی پدیده انتقال رسوب در یک کانال قوسی ۱۸۰ درجه با آبگیر جانبی که در موقعیت ۱۱۵ درجه از قوس خارجی و با زاویه انحراف ۴۵ درجه قرار دارد، صورت پذیرفته و نتایج حاصل با داده های آزمایشگاهی کالیبره گردیده است. در ادامه، در ۳۱ موقعیت از قوس خارجی از مقطع ۱۰ تا ۱۴۰ درجه از قوس با فواصل ۵ درجه و با ۵ زاویه آبگیری ۱۰، ۳۰، ۵۰، ۷۰ و ۹۰ درجه و سه دبی آبگیری ۲۰٪، ۳۰٪ و ۴۰٪ مدل عددی کالیبره شده، اجرا گردیده است و درصد رسوب انحرافی به آبگیر جانبی برای هر مدل تعیین گردید. نتایج حاصل به عنوان داده های لازم برای آموزش و صحت سنجی مدل های مختلف شبکه عصبی به کار برده شد. در ادامه با استفاده از ۷۰ درصد داده های حاصل، یک فرامدل با استفاده از مدل های شبکه عصبی مصنوعی چند لایه (MLP)، شبکه عصبی شعاعی (RBF)، شبکه عصبی رگرسیون عمومی (GRNN) و رگرسیون بردار پشتیبان (SVR) آموزش داده شده و صحت آن توسط بخشی از داده‌هایی که در مرحله آموزش از آنها استفاده نشده، مورد ارزیابی قرار گرفت. دقت نتایج حاصل از مدل های مذکور بر اساس معیار ضریب همبستگی، نشان‌دهنده توانایی بهتر مدل شبکه عصبی SVR در پیش بینی مقادیر رسوب ورودی به آبگیر جانبی نسبت به سایر مدل ها می باشد.	<p>نوع مقاله: مقاله علمی پژوهشی</p> <p>تاریخ دریافت: ۱۴۰۴/۰۲/۲۳</p> <p>تاریخ بازنگری: ۱۴۰۴/۰۵/۰۹</p> <p>تاریخ پذیرش: ۱۴۰۴/۰۶/۰۳</p> <p>تاریخ انتشار: ۱۴۰۴/۰۷/۰۶</p> <p>کلید واژه ها: انتقال رسوب، آبگیر جانبی، آبراهه های قوسی، یادگیری ماشین، دینامیک سیالات محاسباتی.</p>

رسوبات انتقالی توسط رودخانه‌ها مشکلات زیادی جهت بهره‌برداری از سازه‌های آبی به وجود می‌آورند. آنگیر جانبی و تا سیسات انحراف جریان که به طور گسترده‌ای در زمینه آبیاری، زهکشی زمین و سیستم فاضلاب شهری به کار برده می‌شود، با پدیده انتقال رسوب سروکار دارند (Tien و همکاران، ۲۰۲۰). الگوی خاص جریان اطراف آنگیرهای جانبی باعث می‌شود تا جریان در حین ورود به آنگیر، باعث ایجاد یک ناحیه جدایی جریان گردد و راندمان آنگیری در اثر وقوع این پدیده کاهش می‌یابد (Xiao و همکاران، ۲۰۲۰). به منظور مطالعه رفتار سازه‌های هیدرولیکی، اغلب مدل فیزیکی آن ساخته می‌شود که این روش هزینه‌بر و وقت‌گیر می‌باشد. امروزه با پیشرفت قابل توجه رایانه‌ها، مدل‌های عددی جایگاه خاصی برای حل مسائل پیچیده پیدا کرده‌اند. از مزایای اصلی مدل‌های عددی نسبت به مدل‌های فیزیکی این است که به کمک مدل‌های عددی می‌توان به سادگی تغییرات و شرایط فیزیکی را در شرایط مسأله اعمال و نتایج را مشاهده نمود. از طرف دیگر در صورت استفاده از یک مدل پیش‌بینی در تعامل با مدل‌های عددی، می‌توان تعداد مدل سازی‌ها را کاهش داد و در زمان محاسبات صرفه جویی نمود. امروزه مدل‌های هوش مصنوعی، به دلیل تخمین و پیش‌بینی نتایج با ضریب همبستگی بالا و خطای کمتر در مقایسه با مدل‌های پیش‌بینی معمولی، می‌توانند در تعامل با مدل‌های عددی جهت پیش‌بینی رفتار سازه‌های هیدرولیکی به‌عنوان گزینه‌ای کارا مورد استفاده قرار گرفته‌اند (Tassi و همکاران، ۲۰۲۳). تخمین میزان رسوب ورودی به تاسیسات انحراف جریان رودخانه‌ها، جهت انتخاب راه کارهای پیشگیرانه یا علاج‌بخش جهت کنترل رسوب ورودی به سازه‌های انحراف جریان حائز اهمیت است. پیش‌بینی نرخ انتقال رسوب بار بستر در رودخانه‌ها به دلیل تنوع ذاتی در هیدرولیک رودخانه و مورفولوژی کانال، یک مسئله بسیار دشوار است. یادگیری ماشین (ML) رویکردی جذاب برای بهره‌برداری از مشاهدات رو به رشد انتقال بار بستر به سمت توسعه یک مدل پیش‌بینی مبتنی بر داده ارائه می‌دهد. اخیراً مدل‌های مبتنی بر هوش مصنوعی و الگوریتم‌های یادگیری ماشین در شاخه‌های متعدد علمی به کار می‌رود. اخیراً این تکنیک یک رشد ساختاری در کاربرد در مهندسی رودخانه و منابع آب داشته است (Sisinggih و همکاران، ۲۰۲۱). از جمله این کاربردها می‌توان به پیش‌بینی راندمان حذف سرب (سعیدی نیا و دیوبند، ۱۴۰۴)، پیش‌بینی غلظت آلاینده PM2.5 (طایفه طاهرلو و سدی وایقان، ۱۴۰۳)، مدل سازی فرآیند بارش-رواناب (Hsu و همکاران، ۱۹۹۵)، پیش‌بینی و بهره‌برداری جریان ورودی به مخزن سد (Jain و همکاران، ۱۹۹۹)، پیش‌بینی جریان رودخانه (Imrie و همکاران، ۲۰۰۰)، تخمین ظرفیت تخلیه سرریز کنگره-ای مثلثی در کانال مستقیم (Emiroglu و همکاران، ۲۰۱۱)، پیش‌بینی ضریب تخلیه سرریز کنگره-ای مثلثی در کانال قوسی (Bilhan و همکاران، ۲۰۱۱)، مدل پیش‌بینی غوطه‌وری بحرانی آنگیرهای افقی در جریان‌های سطح آزاد (Ayoubloo و همکاران، ۲۰۱۱)، پیش‌بینی رواناب (Ghumman و همکاران، ۲۰۱۱)، پیش‌بینی تغییرات زمانی عمق آبستگي اطراف آبشکن‌ها (Karami و همکاران، ۲۰۱۲)، مدل‌سازی هندسه مخروط آبستگي اطراف خروجی در رسوبشویی تحت فشار (Emamgholizadeh, 2012)، پیش‌بینی سیل در رودخانه (Elsafi 2014)، تغییرات مورفولوژی بستر رودخانه نزدیک آنگیرهای تامین مستقیم آب (Khalaf و همکاران، ۲۰۱۳)، پیش‌بینی آبستگي در سرریز جانبی (Onen 2014)، پیش‌بینی آبستگي پایین دست جام پرتابی (Noori and Hooshyaripor 2014)، تحلیل و پیش‌بینی رواناب (Mishra و همکاران، ۲۰۱۵)، مدل بارش رواناب با در نظر گرفتن رطوبت پیشین خاک (Kang و همکاران، ۲۰۱۵)، تعیین ظرفیت آنگیری سرریز کنگره ای مثلثی (Karimi و همکاران، ۲۰۱۵)، پیش‌بینی جریان رودخانه (Veintimilla-Reyes و همکاران، ۲۰۱۶) و تخمین طول غلطابی پرش هیدرولیکی (Azimi و همکاران، ۲۰۱۸) اشاره نمود. در خصوص کاربرد مدل‌های یادگیری ماشین جهت پیش‌بینی بار رسوبی در آبراهه‌ها می‌توان به مطالعات زیر اشاره کرد: در مطالعه Khosravi و همکاران (۲۰۱۸) ارزیابی مدل‌های داده‌کاوی مستقل یعنی درخت هرس خطای کاهش‌یافته (REPT)، M5P و یادگیری مبتنی بر نمونه (IBK) و مدل‌های ترکیبی (یعنی bagging-M5P، RC-REPT و RS-REPT) برای پیش‌بینی بار رسوب معلق ناشی از ذوب یخچال‌های طبیعی در حوضه آبریز آند در شیلی انجام شده است. نتایج نشان داد مدل‌های ترکیبی عملکرد بهتری نسبت به مدل‌های منفرد داشتند. مدل bagging-M5P بهترین قابلیت پیش‌بینی و مدل REPT ضعیف‌ترین قابلیت پیش‌بینی را داشت. در تحقیق Khosravi و همکاران (۲۰۲۰) با استفاده از داده‌های انتقال بار بستر جمع‌آوری شده در آزمایش‌های فلوم آزمایشگاهی، عملکرد چهار نوع از تکنیک‌های داده‌کاوی مستقل اخیراً توسعه‌یافته شامل M5P، درخت تصادفی (RT)، جنگل تصادفی (RF) و درخت هرس خطای کاهش‌یافته (REPT) به همراه چهار نوع الگوریتم ترکیبی آموزش‌دیده با الگوریتم داده‌کاوی جهت پیش‌بینی نرخ انتقال بار بستر ارزیابی شده‌اند و همه مدل‌ها عملکرد «بسیار خوبی» را نشان دادند. در مطالعه Hosseini و همکاران (۲۰۲۲) یک ساختار شبکه عصبی ترکیبی بلوکی (BCNN) که با الگوریتم ژنتیک (GA) ترکیب شده جهت پیش‌بینی نرخ انتقال بار بستر بر روی ۸۷۹ مجموعه داده بار بستر، با در نظر گرفتن سرعت، دبی، میانگین اندازه دانه، شیب و عمق به عنوان ورودی‌های مدل اعمال شد. نرخ طبقه‌بندی صحیح بار بستر پیش‌بینی شده با استفاده از این مدل (دقت عملکرد برتر این مدل را در مقایسه با سایر ANN‌ها و مدل‌های تجربی نشان داد. 89.77٪)

در مطالعه Shakya و همکاران (۲۰۲۳) با استفاده از روش‌های مختلف مانند رگرسیون خطی (LR)، رگرسیون بردار پشتیبان (SVR)، ماشین یادگیری شدید (ELM) و شبکه عصبی عمیق (DNN) به پیش‌بینی بار رسوب کل در رودخانه پرداخته شده است. نتایج نشان می‌دهد که روش DNN، بار رسوب کل را با دقت قابل توجهی پیش‌بینی کرده و بالاترین دقت پیش‌بینی را داشته است با این حال، عملکرد سایر روش‌های پیشنهادی در مقایسه با تکنیک‌های موجود رضایت‌بخش بوده است. در مطالعه Latif و همکاران (۲۰۲۳) چندین مدل مبتنی بر هوش مصنوعی مانند حافظه کوتاه‌مدت بلند (LSTM)، شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) را در پیش‌بینی انتقال رسوب در رودخانه جوهور بررسی کرد. نتایج آماری نشان داد که علیرغم توانایی مدل‌های یادگیری عمیق و یادگیری ماشین در ارائه پیش‌بینی‌های رسوب بر اساس مجموعه داده‌های ورودی تاریخی، یادگیری ماشین، مانند ANN، ممکن است بیشتر از یادگیری عمیق مستعد بیش‌برازش یا گیر افتادن در بهینه‌ی محلی باشد. LSTM در این مقایسه از سایر مدل‌ها پیشی گرفت. در تحقیق Hosseiny و همکاران (۲۰۲۳) یک مدل شبکه عصبی مصنوعی (ANN) برای پیش‌بینی نرخ انتقال بار بستر ارائه شده است که از ۸۱۱۷ اندازه‌گیری از ۱۳۴ رودخانه به دست آمده است. ورودی‌های این مدل، دبی رودخانه، عرض جریان، شیب بستر و چهار اندازه رسوب سطح بستر بودند. تجزیه و تحلیل حساسیت نشان داد که همه ورودی‌های مدل ANN به تخمین معقولی از نرخ بار بستر کمک می‌کنند. خلاصه پیشینه تحقیقات انجام شده در زمینه پیش‌بینی بار رسوبی در آبراهه‌ها در جدول (۱) ارائه شده است.

جدول (۱) مقایسه پیشینه تحقیقات انجام شده در زمینه پیش‌بینی بار رسوبی با تحقیق حاضر

نام محقق	سال	هدف	مدل‌های مورد استفاده	بهترین مدل
Hosseiny و همکاران	۲۰۲۳	پیش‌بینی نرخ انتقال بار بستر	ANN	ANN
Latif و همکاران	۲۰۲۳	پیش‌بینی انتقال رسوب	LSTM, ANN, SVM	LSTM
Shakya و همکاران	۲۰۲۳	پیش‌بینی بار رسوب کل	LR, SVR, ELM, DNN	DNN
Hosseini و همکاران	۲۰۲۲	پیش‌بینی نرخ انتقال بار بستر	ANN, BCNN	BCNN
Khosravi و همکاران	۲۰۲۰	پیش‌بینی انتقال بار بستر	M5P, RT, RF, REPT	M5P
Khosravi و همکاران	۲۰۱۸	پیش‌بینی بار رسوب معلق	M5P, REPT, IBK, bagging-M5P, RC-REPT, RS-REPT	bagging-M5P
تحقیق حاضر	۲۰۲۵	پیش‌بینی بار رسوب بستر به آبگیر جانبی در کانال قوسی	ANN, RBF, GRNN, SVR	SVR


۲- روش انجام تحقیق

در تحقیق حاضر براساس نتایج به دست آمده از مدل عددی فاز گسسته با مدل‌های مختلف شبکه عصبی، یک مدل هوشمند به منظور پیش‌بینی رفتار هیدرولیکی آبگیر جانبی در میزان انحراف رسوبات بار بستر تدوین شده است. مراحل تحقیق به شرح زیر است:

- تهیه داده‌ها از اجرای مدل عددی کالیبره شده به ازای تغییر موقعیت و زاویه انحراف آبگیر جانبی و دبی آبگیری.
- تدوین یک فرامدل بر مبنای مدل‌های هوش مصنوعی و نتایج مدل عددی جهت پیش‌بینی مقدار رسوب ورودی به آبگیر جانبی در کانال U شکل.
- آموزش و آزمایش مدل‌های شبکه عصبی مصنوعی چند لایه (MLP)، شبکه عصبی شعاعی (RBF)، رگرسیون بردار پشتیبان (SVR) و مدل شبکه عصبی عمومی (GRNN).
- تعیین بهترین ساختار از مدل‌های شبکه عصبی مصنوعی با استفاده از معیارهای R^2 , SSE, MARE.

• مدل آزمایشگاهی


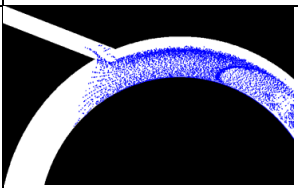

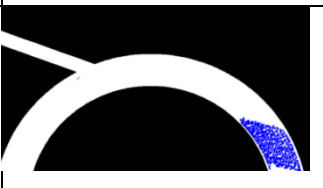

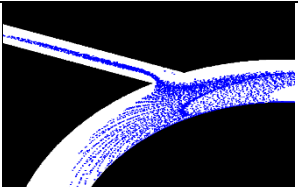

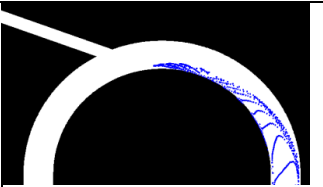
مدل آزمایشگاهی مورد استفاده در این تحقیق شامل یک کانال U شکل با شعاع متوسط ۲/۶ متر و عرض ۰/۶ متر می‌باشد. شکل (۱) کانال آزمایشگاهی مذکور را نشان می‌دهد. آبگیر جانبی به عرض ۲۵ سانتی‌متر در موقعیت ۱۱۵ درجه قوس و با زاویه آبگیری ۴۵ درجه قرار دارد، تشکیل شده است. آزمایش‌ها با دبی ثابت ۴۰ لیتر بر ثانیه و عمق ورودی ثابت ۱۴/۵ سانتی‌متر انجام شده است. دبی آبگیری برابر با ۳۰ درصد جریان ورودی تعیین شده است. رسوبات مورد استفاده با دانه بندی یکنواخت و قطر متوسط ۱ میلی‌متر که از بالادست قوس با نرخی برابر با قدرت حمل جریان به درون کانال تزریق می‌شوند و شرایط حرکت رسوبات به صورت بار بستر می‌باشد (منتصری و همکاران، ۱۳۹۷).



شکل ۱- مدل آزمایشگاهی، ابعاد به متر است (منتصری، ۲۰۰۸)

• مدل عددی فاز گسسته

نرم افزار FLUENT، توانایی مدل سازی انتقال رسوب را با روش دوفازی و بر اساس دو رویکرد اویلری و فاز گسسته لاگرانژی را دارد. به منظور تهیه داده های لازم جهت برپایی مدل های یادگیری ماشین، اقدام به مدلسازی انتقال رسوب در کانال U شکل با آبگیر جانبی گردید. بدین منظور از مدل کالیبره شده در تحقیق توکلی و منتصری (۱۳۹۶) استفاده شد. توکلی و منتصری در سال ۱۳۹۶، شبیه سازی پدیده انتقال رسوب در یک U شکل با آبگیر جانبی را با استفاده از مدل های اویلری و لاگرانژی در نرم افزار فلوئنت انجام دادند و مکانیسم انتقال رسوب و میزان رسوب ورودی به آبگیر در شرایط هیدرولیکی مختلف مورد بررسی قرار گرفت (شکل ۲). برای صحت سنجی مدل عددی از داده های مدل آزمایشگاهی استفاده کردند. لذا با استفاده از مدل عددی کالیبره شده، در ۳۱ موقعیت از قوس خارجی از مقطع ۱۰ تا ۱۴۰ درجه از قوس با فواصل ۵ درجه و با ۵ زاویه انحراف آبگیر ۱۰، ۳۰، ۵۰، ۷۰ و ۹۰ درجه و سه دبی آبگیری ۲۰٪، ۳۰٪ و ۴۰٪ مدل عددی برپا شد و پس از اجرای مدل، درصد رسوب انحرافی برای هر مدل تعیین گردید و به عنوان داده های لازم برای ایجاد مدل های یادگیری ماشین به کار برده شد. تعداد کل داده های بدست آمده از مدل عددی فلوئنت ۴۶۵ داده برای میزان رسوب ورودی به آبگیر جانبی در کانال U شکل به ازای موقعیت های مختلف آبگیر جانبی، زوایای انحراف مختلف و دبی های متفاوت آبگیری می باشد که جهت آموزش و آزمایش شبکه های عصبی مختلف مورد استفاده قرار گرفت.

نتایج آزمایشگاهی	نتایج مدل عددی	نتایج آزمایشگاهی	نتایج مدل عددی
			
ج) ۴۵ دقیقه از شروع تزریق		الف) ۱۰ دقیقه از شروع تزریق	
			
الف) ۶۰ دقیقه از شروع تزریق		ب) ۳۵ دقیقه از شروع تزریق	

شکل ۲- نحوی حرکت ذرات رسوب برای دبی آبگیری ۳۰٪ (توکلی و منتصری، ۱۳۹۶)

• مدل های یادگیری ماشین

یادگیری ماشین شاخه‌ای از هوش مصنوعی است که به سیستم‌ها توانایی یادگیری خودکار از داده‌ها بدون برنامه‌نویسی صریح را می‌دهد. این فناوری با شناسایی الگوها در داده‌ها، مدل‌هایی برای پیش‌بینی یا تصمیم‌گیری می‌سازد. یادگیری ماشین با خودکارسازی تحلیل داده‌های پیچیده، انقلابی در علوم مهندسی از جمله مدیریت منابع آب ایجاد کرده است. انتخاب روش به نوع مسئله، حجم داده و دقت موردنیاز بستگی دارد. اعتبارسنجی این مدل‌ها با معیارهایی مانند RMSE ضروری است. یادگیری ماشین (ML) بر اساس نوع داده، روش یادگیری و کاربرد، به سه دسته اصلی تقسیم می‌شود:

۱. یادگیری نظارت‌شده (Supervised Learning): در این حالت، مدل با استفاده از داده‌های برچسب‌دار آموزش می‌بیند. روش‌های رگرسیون خطی/لوجستیک، درخت تصمیم (Decision Trees)، ماشین بردار پشتیبان (SVM) و شبکه‌های عصبی مصنوعی (ANN) در این دسته قرار می‌گیرند.

۲. یادگیری بدون نظارت (Unsupervised Learning): این روش جهت کشف الگوها در داده‌های بدون برچسب کاربرد دارد و شامل روش‌های خوشه‌بندی K-Means، تحلیل مؤلفه‌های اصلی (PCA) و شبکه‌های عصبی رقابتی (SOM) می‌باشند.

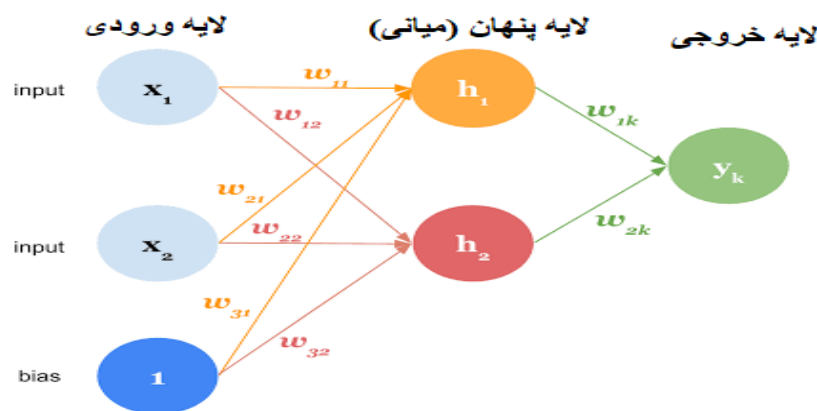
۳. یادگیری تقویتی (Reinforcement Learning): یادگیری تقویتی از طریق تعامل با محیط و دریافت پاداش/تنبیه انجام می‌شود. از نمونه‌های این روش می‌توان به Q-Learning و شبکه‌های عمیق تقویتی (Deep Q-Networks) اشاره نمود.

شبکه‌های عصبی مصنوعی (ANNs) به عنوان یکی از روش‌های پیشرفته یادگیری ماشین، با الهام از ساختار عصبی زیستی طراحی شده‌اند. این سیستم‌ها از واحدهای پردازشی به نام نورون تشکیل شده‌اند که در لایه‌های مختلف سازماندهی می‌شوند. مزایای استفاده از ANN شامل توانایی مدل‌سازی روابط غیرخطی پیچیده، قابلیت تعمیم‌پذیری به شرایط مختلف جریان و کاهش هزینه‌های محاسباتی نسبت به روش‌های عددی می‌باشد. از انواع شبکه‌های عصبی مصنوعی می‌توان به شبکه‌های عصبی MLP, RBF, GRNN, SVR اشاره نمود. هر یک از این مدل‌ها مزایا و محدودیت‌های خاص خود را در مدل‌سازی انتقال رسوب دارند. همچنین اعتبارسنجی نتایج با داده‌های آزمایشگاهی و شبیه‌سازی عددی CFD ضروری است.

– مدل شبکه عصبی مصنوعی چند لایه (MLP)^۲

در شبکه پرسپترون چند لایه سلول‌های عصبی در لایه‌های موازی قرار دارند و هر سلول واقع در یک لایه با همه سلول‌های لایه بعد ارتباط دارد. پرسپترون چند لایه به ترتیب شامل یک لایه ورودی، یک یا چند لایه میانی (پنهان) و یک لایه خروجی می‌باشد (حسینی و همکاران، ۱۳۸۱). نوع تابع فعالیت برای لایه دوم تابع تانژانت سیگموئید و برای لایه سوم از نوع خطی انتخاب شده است. در حالت کلی برای تعیین تعداد لایه‌های پنهان، تعداد سلول‌های عصبی قرار گرفته در هر لایه پنهان و نیز نوع تابع فعالیت، قاعده خاصی وجود ندارد و با استفاده از سعی و خطا و بررسی کارایی شبکه این پارامترها تعیین می‌گردد. ویژگی‌های کلیدی این شبکه‌ها به قرار زیر است:

- ساختار پیش‌خور (Feed-Forward) با حداقل سه لایه (ورودی، پنهان، خروجی)
- استفاده از توابع فعال‌ساز غیرخطی (مانند سیگموئید)
- قابلیت یادگیری روابط پیچیده غیرخطی بین پارامترهای هیدرولیکی و انتقال رسوب




شکل ۳- شبکه عصبی مصنوعی چند لایه

¹ Machine Learning

² Multi Layer Perceptron

- شبکه‌های توابع پایه شعاعی (RBF)^۱


نوع دیگر شبکه‌های عصبی مصنوعی، شبکه عصبی با تابع شعاعی می باشد که یک شبکه پیش خور با ساختاری شبیه شبکه پرسپترون چند لایه ای می باشد. همانطور که از نام این شبکه مشخص است. تابع مورد استفاده در آن، نوعی از توابع به نام توابع شعاعی می باشند. این نوع توابع اولین بار توسط پاول به عنوان راه‌حلی برای مسائل درون یابی چند متغیری معرفی شدند. بروم هد و لویو در سال ۱۹۸۸ و همچنین مودی و داکن در سال ۱۹۸۹ اولین کسانی بودند که از تابع پایه شعاعی در طراحی شبکه‌های عصبی استفاده کردند. امروزه از این شبکه بطور گسترده‌ای در تخمین ارتباطات ناشناخته استفاده می شود. در شبکه عصبی RBF نیز گره‌های لایه ورودی اطلاعات را دریافت و به لایه مخفی انتقال می دهند. انتقال از فضای ورودی به فضای میانی غیرخطی و انتقال از فضای میانی به خروجی خطی می باشد. انتقال غیرخطی توسط تابع انتقال شعاعی و انتقال خطی بوسیله یک دسته وزن w_1 بوجود می آید. تعداد گره‌های لایه مخفی، یکی از پارامترهای کلیدی شبکه RBF می باشد و بایستی بهینه شود ولی متأسفانه روش راحتی برای بدست آوردن تعداد گره بهینه لایه مخفی در شبکه RBF وجود ندارد و تنها از طریق آزمایش می توان این تعداد را بدست آورد. بدین صورت که شبکه را با تعداد مختلفی از گره‌ها محاسبه کرده و بهترین جواب به عنوان تعداد گره بهینه در نظر گرفته می شود. هر گره لایه مخفی شامل یک تابع پایه شعاعی، به عنوان تابع انتقال می باشد. توابع شعاعی دارای پارامترهایی همچون مرکز و پهنا می باشند که به ترتیب با نمادهای C و σ نشان داده می شوند. این پارامترها در مرحله آموزش شبکه تعیین می شوند. مزایا در مدلسازی رسوب شامل دقت بالا در برون‌یابی داده‌های محدود، کارایی مناسب در مدلسازی فضای پارامتری پیوسته و مقاومت در برابر داده‌های پرت (Outliers) می باشد. ساختار شماتیک یک شبکه عصبی RBF در شکل زیر نشان داده شده است.



شکل ۴- ساختار کلی یک شبکه عصبی مصنوعی RBF

- شبکه عصبی رگرسیون تعمیم یافته (GRNN)^۲

شبکه عصبی رگرسیون تعمیم یافته (GRNN) یک شبکه برای حل مسائل رگرسیونی بر پایه آمار است. این شبکه نوع دیگری از شبکه‌های RBF است. GRNN در سال ۱۹۹۱ توسط اسپکت معرفی گردید. این شبکه دارای آموزش سریع بوده و می تواند توابع غیرخطی را به خوبی مدل نماید. GRNN یک شبکه سه لایه است. که تعداد نرون‌های آن در مقایسه با MLP بسیار آسان تر انتخاب می‌شود، زیرا برابر تعداد مشاهدات در نظر گرفته می شوند. شکل ۴ یک شبکه GRNN را نشان میدهد. این شبکه همانند RBF، در لایه میانی از تابع گوسی استفاده میکند؛ اما در لایه خروجی یک بخش اضافه‌تر از RBF وارد محاسبات می شود.




شکل ۵- شماتیک کلی شبکه GRNN

¹ Radial Basis Function Networks² Generalized Regression Neural Network

- مدل رگرسیون بردار پشتیبان (SVR)¹

روش رگرسیون بردار پشتیبان مستقیماً از نظریه یادگیری آماری وینیک به نام ماشین‌های بردار پشتیبان استخراج شده است. ماشین‌های بردار پشتیبان برای مسائل طبقه بندی به کار می‌روند. بعدها الگوریتم آن‌ها برای کار با مسائل رگرسیون یا تخمین داده‌ها توسعه یافت. این الگوریتم جدید رگرسیون بردار پشتیبان نامیده شد. الگوریتم SVR یکی از الگوریتم‌های یادگیری ماشین است که بر اساس تئوری آموزش آماری استوار است. این روش که جزو روش‌های آموزش نظارت‌شده (Supervised) است، بین داده‌های ورودی و مقدار پارامتر وابسته، بر اساس کمینه‌سازی ریسک ساختاری ارتباط برقرار می‌کند. کمینه‌سازی ریسک ساختاری، نسبت به روش متداول کمینه‌سازی ریسک تجربی مورد استفاده در الگوریتم‌هایی مانند شبکه‌های عصبی و روش‌های کلاسیک آماری، دارای برتری است و برخلاف روش‌هایی همانند شبکه‌های عصبی، به جواب‌های موضعی همگرا نمی‌شود. SVR روشی برای تخمین یک تابع است که بر اساس داده‌های آموزشی از یک شیء ورودی به یک عدد واقعی نگاشت می‌شود. در مسائل رگرسیون، بردارهای ورودی به یک فضای چندبعدی، نگاشت می‌شوند، سپس یک ابرصفحه ساخته می‌شود که بردارهای ورودی را با بیشترین فاصله ممکن، از یکدیگر جدا می‌کند. برای رفع مشکل انجام عملیات در فضای با ابعاد زیاد، از یک تابع کرنل استفاده می‌شود. در این صورت عملیات می‌تواند با همان سرعت فضای داده‌های ورودی انجام شود. در واقع با استفاده از تابع کرنل، مشکل چندبعدی و غیرخطی بودن نگاشت، مرتفع می‌شود. فرآیند بهینه‌سازی باید با یک تابع تلفات اصلاح شده همراه شود، تا سنجش فاصله را دربر گیرد. در حقیقت هدف SVR، تخمین پارامترهای وزن‌ها و ارباب تابعی است که بهترین انطباق را بر داده‌ها داشته باشد. تابع SVR می‌تواند خطی یا غیرخطی باشد (شکل ۶) و در حالت غیرخطی، محاسبه تابع رگرسیون در یک فضای ویژگی با ابعاد بالا صورت می‌گیرد که داده‌های ورودی از طریق یک تابع غیرخطی، نگاشت می‌شوند.



شکل ۶- نمایش یک تابع SVR خطی (تابع تلفات و متغیرهای آن)

به طور کلی روش رگرسیون بردار پشتیبان در مسائل رگرسیون مورد استفاده قرار می‌گیرد. مانند بسیاری از روش‌های یادگیری ماشین، در این روش نیز فرآیند ساخت مدل شامل دو مرحله آموزش Training و آزمایش Testing می‌باشد. در انتهای فاز آموزش قابلیت تعمیم یابی مدل آموزش‌داده شده با استفاده از داده‌های آزمایش مورد ارزیابی قرار می‌گیرد. در واقع رگرسیون بردار پشتیبان، تابع رگرسیون را با به کارگیری یک دسته تابع خطی تخمین می‌زند. در این تابع، انحراف مقادیر پیش‌بینی شده از مقدار واقعی به میزان ϵ مجاز است (تابع تلفات Loss Function). در نهایت بهترین جواب به کمک اصول کمینه‌سازی ریسک توسط تابع تلفات مورد استفاده، ارائه می‌شود. برای ساخت مدل رگرسیون بردار پشتیبان، پارامترهای C و ϵ توسط کاربر تعریف می‌شوند. پارامتر C یک پارامتر تنظیمی است و می‌تواند مقادیر صفر تا بی‌نهایت را بپذیرد. وقتی به این پارامتر مقادیر بزرگی اختصاص داده شود، SVR اجازه وقوع خطا در داده‌های آموزش را نمی‌دهد و نتیجه حاصل یک مدل پیچیده خواهد بود، لذا قابلیت تعمیم مدل کاهش می‌یابد. از طرف دیگر وقتی که C به سمت صفر میل می‌کند، مدل می‌تواند خطای زیادی را بپذیرد، در نتیجه پیچیدگی مدل کمتر خواهد بود. پارامتر ϵ نیز می‌تواند مقادیر صفر تا بی‌نهایت را بپذیرد. مقدار این پارامتر در وضعیت بردارهای پشتیبان و در نتیجه کارایی مدل بسیار موثر است. هر چند که انتخاب مقادیر بسیار بزرگ ϵ سبب کاهش تعداد بردارهای پشتیبان می‌شود و مطلوب نیز چنین است اما رسیدن به این هدف با عریض کردن بازه‌ی ϵ نادرست است. از طرف دیگر مقادیر بسیار کوچک این پارامتر، موجب می‌شود تا تعداد زیادی بردار پشتیبان انتخاب شود و احتمال خطر بیش آموزش Over fitting شدن افزایش یابد. مسئله رگرسیون خطی در SVR به راحتی قابل گسترش به رگرسیون غیر خطی است. بدین منظور از توابع کرنل استفاده می‌شود. توابع کرنل، داده‌ها را به یک فضای ویژگی Feature Space نگاشت می‌کنند که در آن فضا ممکن است امکان استفاده از رگرسیون خطی وجود داشته باشد. تاکنون توابع کرنل گوناگونی معرفی شده‌اند که در این میان می‌توان به کرنل‌های چندجمله‌ای Polynomial و کرنل گاوسی یا پایه شعاعی Radial Basis و ... اشاره کرد.

¹ Support Vector Regression

• معیارهای ارزیابی و اعتبارسنجی

در این تحقیق، به منظور ارزیابی کارایی مدل‌ها، از معیارهای معتبر به شرح زیر استفاده شده است.

- ضریب تعیین (Determination Coefficient)

ضریب تعیین (تیین) بیان‌کننده بخشی از کل واریانس مقادیر مشاهده‌ای است که توسط مقادیر شبیه‌سازی شده توجیه می‌شود. ضریب تعیین بین صفر تا یک تغییر می‌کند و مقدار بهینه آن یک است و این حالت مربوط به زمانی است که در آن مقادیر شبیه‌سازی شده دقیقاً مشابه مقادیر مشاهداتی باشد. در این رابطه \bar{x} ، x_{ipred} ، x_{imeas} به ترتیب برابر با مقدار میانگین متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_{imeas} - x_{ipred})^2}{\sum_{i=1}^n (x_{imeas} - \bar{x})^2} \quad (1)$$

- میانگین مربعات خطا (Mean Squared Error)

روشی برای برآورد میزان خطاست که در واقع تفاوت بین مقادیر تخمینی و آنچه تخمین زده شده، است. MSE به دو دلیل تقریباً همه جا مثبت است (صفر نیست) یک اینکه تصادفی است و دوم به این دلیل که تخمین‌گر اطلاعاتی که قابلیت تولید تخمین دقیق تری دارد را حساب نمی‌کند. پس این شاخص که مقداری همواره نامنفی دارد، هرچقدر مقدار آن به صفر نزدیکتر باشد، نشان‌دهنده میزان کمتر خطاست. مقدار این شاخص به صورت زیر بیان می‌شود که n ، x_{ipred} ، x_{imeas} به ترتیب برابر با تعداد متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

$$MSE = \frac{1}{n} \times \sum_{i=1}^n [(x_{imeas} - x_{ipred})^2] \quad (2)$$

- میانگین خطای نسبی مطلق (Mean Absolute Relative Error)

روشی برای برآورد خطا است که به صورت رابطه زیر تعریف می‌شود. مقدار بهینه برای این خطا برابر با صفر می‌باشد.

$$MARE = \frac{\sum_{i=1}^n \frac{|(x_{imeas} - x_{ipred})|}{x_{imeas}}}{n} \quad (3)$$

n ، x_{ipred} ، x_{imeas} به ترتیب برابر با تعداد متغیر اندازه‌گیری شده، مقدار متغیر پیش‌بینی شده و مقدار متغیر اندازه‌گیری شده می‌باشد.

- مجموع مربعات خطا (Sum of Squared Error)

SSE مجموع مربعات خطاهای بین هر متغیر مشاهده شده x_i و میانگین گروه آن است. \bar{x} ، n ، x_i به ترتیب برابر با تعداد متغیرهای مشاهده شده، میانگین متغیرها و متغیرهای مشاهده شده است.

$$SSE = \sum_{i=1}^n (x_i - \bar{x})^2 \quad (4)$$

۳- نتایج

جهت مدل‌سازی مدل‌های شبکه عصبی مصنوعی چند لایه (MLP)، شبکه عصبی شعاعی (RBF)، شبکه عصبی رگرسیون عمومی (GRNN) و رگرسیون بردار پشتیبان (SVR)، تقسیم‌بندی داده‌ها برای مراحل آموزش (Train) و آزمایش (Test) در حالات مختلفی انجام گرفت و در نهایت از ۷۵ درصد داده‌ها برای آموزش و ۲۵ درصد مابقی برای آزمایش مدل‌ها به صورت تصادفی استفاده گردید. ورودی‌های مدل‌های مذکور عبارتند از موقعیت آبگیر، زاویه انحراف آبگیر و دبی آبگیری. خروجی مدل‌ها مقدار رسوب انحرافی به درون آبگیر می‌باشد که در ادامه نتایج حاصل از هر یک از این مدل‌ها بررسی می‌گردد.

• نتایج مدل سازی شبکه عصبی مصنوعی چند لایه (MLP)

انتخاب تعداد نورون‌های لایه‌های پنهان قانون و قاعده خاص و مشخصی ندارد. معمولاً از یک لایه با تعداد زیاد نورون استفاده نمی‌شود و بهتر است از لایه‌های بیشتر با تعداد نورون‌های کمتر استفاده کرد. قانون کلی برای ساخت مدل وجود ندارد و توصیه می‌شود که مدل‌های مختلف، با معماری‌های متفاوت آزمایش شود و با توجه به نتایج به دست آمده، بهترین آن‌ها انتخاب گردد. می‌توان با یک لایه ورودی و ۲ یا ۳ نورون در آن شروع کرد. شبکه باید با روش بهینه آموزش داده شود. در انتها با استفاده از داده‌هایی که هنگام آموزش استفاده نشده است، مدل‌ها آزمایش شود و با توجه به میزان خطا، مدل‌ها ارزیابی گردد و بهترین ساختار شبکه عصبی گزارش شود. برای مشخص کردن بهترین ساختار و معماری شبکه عصبی، از مدل‌های سه لایه (دارای یک لایه پنهان) و چهار لایه (دارای دو لایه پنهان) استفاده گردید. در هر دو حالت، تعداد نورون لایه پنهان از ۲ تا ۵ عدد انتخاب شد. نتایج در هر حالت بدست آمد و مقایسه شدند که طبق جدول زیر بهترین معماری شبکه عصبی چندلایه به صورت $1 \times 2 \times 5 \times 3$ بدست آمد. به عبارت دیگر ۵ نورون در لایه پنهان اول و ۵ نورون در لایه پنهان دوم. لازم به ذکر است که تمام شبکه‌های عصبی در جدول (۲) ۳ نورون در لایه ورودی و ۱ نورون در لایه خروجی دارند.

جدول (۲) میزان خطا در مراحل آموزش و آزمایش معماری‌های مختلف مدل شبکه عصبی MLP

معماری شبکه عصبی	MARE_train	MARE_test	R ² _train	R ² _test
3×2×1	0.17419	0.1521	0.89516	0.92902
3×3×1	0.076105	0.079411	0.97361	0.97205
3×4×1	0.071942	0.090586	0.97615	0.96615
3×5×1	0.072749	0.0869	0.97761	0.97101
3×2×2×1	0.17221	0.15095	0.89485	0.92876
3×2×3×1	0.12814	0.11638	0.93835	0.94278
3×2×4×1	0.16904	0.1472	0.8944	0.93089
3×2×5×1	0.13157	0.11868	0.93771	0.94267
3×3×2×1	0.12568	0.12884	0.94292	0.93449
3×3×3×1	0.072633	0.074534	0.97519	0.97328
3×3×4×1	0.073222	0.076054	0.97444	0.97221
3×3×5×1	0.073177	0.075667	0.097478	0.97174
3×4×2×1	0.072034	0.077776	0.97662	0.97598
3×4×3×1	0.06761	0.084524	0.97827	0.97352
3×4×4×1	0.071729	0.086739	0.97623	0.9691
3×4×5×1	0.070772	0.087029	0.97659	0.96927
3×5×2×1	0.068605	0.075308	0.97889	0.97678
3×5×3×1	0.062789	0.071299	0.098005	0.97548
3×5×4×1	0.066716	0.07409	0.97835	0.97625
3×5×5×1	0.067606	0.088232	0.97912	0.97172

• نتایج مدل سازی شبکه عصبی - شعاعی (RBF)

برای طراحی شبکه RBF، علاوه بر متغیرهای ورودی و خروجی به پارامترهای Goal یا میزان مطلوب خطای پیش‌بینی و Spread یا همان پارامتر سیگما نیز نیاز است. پارامتر Goal را برابر با صفر در نظر گرفته شد تا حداقل خطای پیش‌بینی ممکن بدست آید. انتخاب تعداد Spread قانون و قاعده خاص و مشخصی ندارد. معمولاً با انجام آزمون و خطا بر روی یک سری از مقادیر Spread مدل‌های مختلف با معماری‌های متفاوت آزمایش شود و با توجه به نتایج به دست آمده، بهترین آن‌ها انتخاب گردد. شبکه باید با روش بهینه آموزش داده شود. در انتها با استفاده از داده‌هایی که هنگام آموزش استفاده نشده است، مدل‌ها آزمایش شود و با توجه به میزان خطا، مدل‌ها ارزیابی گردد و بهترین ساختار شبکه عصبی گزارش شود. برای مشخص کردن بهترین ساختار و معماری شبکه عصبی، از مقدار Spread به میزان ۰/۱ شروع و با قدر نسبت ۰/۰۵ تا میزان ۰/۹ این مقادیر آزمایش شده و نتایج شبکه‌های عصبی مختلف با این مقادیر Spread در جدول (۳) نمایش داده شده است. که طبق جدول زیر بهترین معماری شبکه عصبی RBF با مقدار Spread برابر با 0.25 بدست آمد.

جدول (۳) میزان خطا در مراحل آموزش و آزمایش شبکه عصبی RBF

مقدار Spread	MARE_train	MARE_test	SSE_train	SSE_test	R ² _train	R ² _test
0.1	1.384e-15	0.44	8.62e-29	0.87	1	0.39
0.15	4.11e-15	0.38	8.69e-28	0.70	1	0.51
0.2	6.74e-15	0.14	5.31e-27	0.27	1	0.8
0.25	2.9e-14	0.11	1.07e-25	0.12	1	0.91
0.3	1.93e-14	0.11	7.82e-26	0.12	1	0.91
0.35	9.01e-15	0.12	1.04e-26	0.15	1	0.89
0.4	5.97e-14	0.15	2.46e-25	0.24	1	0.82
0.45	1.02e-13	0.19	9.38e-25	0.56	1	0.6
0.5	1.4e-13	0.16	1.87e-24	0.49	1	0.65
0.55	2.53e-13	0.28	3.52e-24	2.04	1	0.41
0.6	3.18e-13	0.23	7.56e-24	1.40	1	0.023
0.65	3.27e-13	0.14	1.16e-23	0.41	1	0.71
0.7	5.71e-13	0.27	2.31e-23	2.70	1	0.87
0.75	1.02e-12	0.37	9.82e-23	6.46	1	0.48
0.8	5.93e-13	0.18	3.37e-23	0.71	1	0.50
0.85	6.05e-13	0.19	2.77e-23	0.92	1	0.36
0.9	1.33e-12	0.40	2.15e-22	10.07	1	0.98

• نتایج مدل سازی با شبکه عصبی رگرسیون عمومی (GRNN)


در شبکه‌های عصبی GRNN برای طراحی شبکه علاوه بر متغیرهای ورودی و خروجی به پارامتر Spread یا همان پارامتر سیگما نیز نیاز داریم. انتخاب تعداد Spread قانون و قاعده خاص و مشخصی ندارد. معمولاً با انجام آزمون و خطا بر روی یک سری از مقادیر Spread مدل‌های مختلف با معماری‌های متفاوت آزمایش شود و با توجه به نتایج به دست آمده، بهترین آن‌ها انتخاب گردد. شبکه باید با روش بهینه آموزش داده شود. در انتها با استفاده از داده‌هایی که هنگام آموزش استفاده نشده است، مدل‌ها آزمایش شود و با توجه به میزان خطا، مدل‌ها ارزیابی گردد و بهترین ساختار شبکه عصبی گزارش شود. در این تحقیق، برای مشخص کردن بهترین ساختار و معماری شبکه عصبی، از مقدار Spread به میزان ۰/۵ شروع و با قدر نسبت ۰/۵ تا میزان ۱۰ این مقادیر آزمایش شده و نتایج شبکه‌های عصبی مختلف با این مقادیر Spread در جدول زیر نمایش داده شده است. که طبق جدول (۴) بهترین معماری شبکه عصبی GRNN با مقدار Spread برابر با 5 بدست آمد.

جدول (۴) میزان خطا در مراحل آموزش و آزمایش شبکه عصبی GRNN

مقدار Spread	MARE_train	MARE_test	SSE_train	SSE_test	R ² _train	R ² _test
0.5	0.073	0.146	0.129	0.143	0.970	0.903
1	0.074	0.146	0.137	0.144	0.969	0.902
1.5	0.075	0.146	0.138	0.144	0.968	0.902
2	0.075	0.143	0.139	0.138	0.968	0.907
2.5	0.077	0.134	0.141	0.120	0.968	0.919
3	0.079	0.127	0.145	0.103	0.967	0.930
3.5	0.081	0.122	0.151	0.093	0.965	0.937
4	0.083	0.119	0.157	0.086	0.964	0.941
4.5	0.085	0.116	0.162	0.083	0.963	0.944
5	0.086	0.115	0.166	0.080	0.962	0.945
5.5	0.087	0.114	0.170	0.079	0.961	0.946
6	0.088	0.113	0.173	0.078	0.960	0.947
6.5	0.089	0.113	0.177	0.077	0.960	0.947
7	0.090	0.113	0.180	0.077	0.959	0.948
7.5	0.092	0.112	0.183	0.076	0.958	0.948
8	0.093	0.112	0.187	0.076	0.957	0.948
8.5	0.094	0.112	0.191	0.076	0.956	0.948
9	0.095	0.111	0.195	0.075	0.956	0.949
9.5	0.097	0.111	0.199	0.075	0.955	0.949
10	0.098	0.110	0.204	0.075	0.953	0.949

• نتایج مدل شبکه عصبی رگرسیون بردار پشتیبان (SVR)

در این تحقیق جهت مدل سازی با SVR از تابع کرنل (هسته) گاوسی استفاده شده است. پارامترهای کالیبراسیون مدل شامل ϵ (میزان خطای مجاز در تابع تلفات) و C (ضریب جریمه) و پارامتر γ (به عنوان پارامتر تابع گوسی) می باشد که با مدلسازی برای بازه‌های از مقادیر متفاوت C ، ϵ و γ و با در نظر گرفتن مقدار تابع خطا، بهترین مقادیر برای پارامترهای مذکور برابر با مقادیر $C=610$ ، $\epsilon=0/93$ و $\gamma=02$ به دست آمد. نتایج مدل سازی پیش بینی رسوب با استفاده از متغیرهای ورودی موقعیت آبیگر، زاویه انحراف آبیگر و دبی آبیگری در دو مرحله آموزش (Train) و آزمایش (Test) به ترتیب در شکل‌های زیر نمایش داده شده است. مقادیر معیارهای خطا در دو حالت آموزش و آزمایش روی شکل ۷ نشان داده شده است.



شکل ۷- مقادیر معیارهای خطا در دو حالت آموزش و آزمایش مدل شبکه عصبی رگرسیون بردار پشتیبان

جدول (۵) مقادیر ضریب همبستگی R^2 را برای مدل های مختلف شبکه عصبی مصنوعی در پیش بینی میزان رسوب ورودی به آبیگر جانبی در کانال قوسی U شکل را نشان می دهد. همانگونه که مشاهده می شود مدل رگرسیون بردار پشتیبان بیشترین ضریب همبستگی بین داده های مشاهداتی و پیش بینی شده را دارد.

جدول (۵) مقادیر ضریب همبستگی R^2 برای مدل های مختلف شبکه عصبی مصنوعی	
Model	R^2
MLP	0.976
RBF	0.98
GRNN	0.949
SVR	0.982

۴- نتیجه گیری

در این تحقیق به منظور پیش بینی میزان بار بستر رسوبی ورودی به آبیگر جانبی در یک کانال قوسی U شکل، از مدل های مختلف یادگیری ماشین MLP, RBF, GRNN, SVR استفاده شد. داده های مورد استفاده در این تحقیق شامل ۴۶۵ مورد نرخ بار بستر رسوب ورودی به آبیگر جانبی در ۳۱ موقعیت از قوس خارجی یک کانال آزمایشگاهی U شکل، با ۵ زاویه انحراف آبیگر و ۳ دبی آبیگری بود که از مدل عددی فاز گسسته که با داده های مدل آزمایشگاهی کالیبره شده بود، بدست آمد. نتایج نشان داد مدل های مختلف یادگیری ماشین، توانایی بسیار بالایی در پیش بینی نرخ بار بستر ورودی به آبیگر جانبی را دارند. بهترین معماری شبکه عصبی MLP، با دو لایه پنهان که ۵ نورون در لایه پنهان اول و ۵ نورون در لایه پنهان دوم قرار دارد، با ضریب همبستگی 0.976 بدست آمد. بهترین معماری شبکه عصبی RBF، با مقدار Spread برابر با 0.25 و ضریب همبستگی 0.98 بدست آمد. بهترین معماری شبکه عصبی GRNN، با مقدار Spread برابر با 5 و ضریب همبستگی 0.949 بدست آمد. نتایج نشان می دهد مدل SVR دارای بیشترین ضریب همبستگی (R^2) با داده های مشاهده ای برابر با 0.982 است. لذا جهت پیش بینی رسوب ورودی به آبیگرهای جانبی پیشنهاد می شود از مدل رگرسیون بردار پشتیبان استفاده شود. به منظور مقایسه تحقیق حاضر با تحقیقات انجام شده در زمینه پیش بینی بار رسوبی در آبراهه ها، فهرستی از این تحقیقات در جدول (۱) ارائه شده است. همانگونه که ملاحظه گردید در تحقیق Khosravi وهمکاران (۲۰۱۸) جهت پیش بینی بار رسوب معلق در رودخانه ها،

از میان مدل‌های داده‌کاوی مستقل (REPT, M5P, IBK) و مدل‌های ترکیبی (یعنی bagging-M5P, RC-REPT و RS-) REPT مدل bagging-M5P بهترین قابلیت پیش‌بینی و مدل REPT ضعیف‌ترین قابلیت پیش‌بینی را داشته است. در مطالعه Khosravi و همکاران (۲۰۲۰) جهت پیش‌بینی انتقال بار بستر از بین مدل‌های M5P، درخت تصادفی (RT)، جنگل تصادفی (RF) و درخت هرس خطای کاهش‌یافته (REPT)، مدل M5P بهترین عملکرد را نشان داد. در مطالعه Hosseini و همکاران (۲۰۲۲) دقت عملکرد مدل شبکه عصبی ترکیبی بلوکی (BCNN) با الگوریتم ژنتیک (GA) در پیش‌بینی نرخ انتقال بار بستر، برابر با ۸۹.۷۷٪ تخمین زده شد. در مطالعه Shakya و همکاران (۲۰۲۳) روی پیش‌بینی بار رسوب کل در رودخانه با استفاده از روش‌های مختلف رگرسیون خطی (LR)، رگرسیون بردار پشتیبان (SVR)، ماشین یادگیری شدید (ELM) و شبکه عصبی عمیق (DNN)، روش DNN، بار رسوب کل را با دقت قابل توجهی پیش‌بینی کرده و بالاترین دقت پیش‌بینی را داشته است. مطالعه Latif و همکاران (۲۰۲۳) در پیش‌بینی انتقال رسوب با استفاده از چندین مدل مبتنی بر هوش مصنوعی مانند حافظه کوتاه‌مدت بلند (LSTM)، شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) نشان داد که علیرغم توانایی مدل‌های یادگیری عمیق و یادگیری ماشین در ارائه پیش‌بینی‌های رسوب، مدل‌های یادگیری ماشین، مانند ANN، ممکن است بیشتر از مدل یادگیری عمیق مستعد بیش‌برازش یا گیر افتادن در بهینه‌ی محلی باشد. LSTM در این مقایسه از سایر مدل‌ها دقت بیشتری را نشان داد. تحقیق Hosseini و همکاران (۲۰۲۳) جهت پیش‌بینی نرخ انتقال بار بستر با استفاده از مدل شبکه عصبی مصنوعی (ANN) تخمین معقولی از نرخ بار بستر را ارائه داد.

منابع

- توکلی کیوان، منتصری حسین. ارزیابی مدل‌های دوفازی اویلری و لاگرانژی در شبیه‌سازی مکانیسم انتقال رسوب در کانال قوسی ۱۸۰ درجه با آبیگر جانبی. مهندسی عمران مدرس. ۱۳۹۶؛ ۱۷ (۲): ۸۱-۹۲
- سعیدی نیامهری، دیوبند هفشجانی، لاله. (۱۴۰۴). 'پیش‌بینی حذف سرب توسط بیوجار و هیدروچار بقایای کلزا با استفاده از رویکرد کاهش ابعاد و برنامه‌ریزی بیان ژن، 'مطالعات علوم محیط زیست، 10(2), pp. 10027-10037.
- طایفه طاهرلو، محمد، اسدی وایقان، امیر. (۱۴۰۳). 'پیش‌بین غلظت آلاینده PM2.5 با استفاده از شبکه ترکیبی (ANN-GA) مطالعه موردی: شهر ارومیه، 'مطالعات علوم محیط زیست، 9(3), pp. 8912-8898.
- منتصری حسین، قدسیان مسعود، صالحی نیشابوری سید علی اکبر. مطالعه آزمایشگاهی پدیده انتقال رسوب و مکانیسم ورود رسوبات به آبیگر در قوس ۱۸۰ درجه با استفاده از روش تزریق رسوب روی بستر صلب. مهندسی عمران مدرس. ۱۳۹۷؛ ۱۸ (۵): ۲۰۳-۲۱۵.
- Latif, S.D., Chong, K.L., Ahmed, A.N., Huang, Y.F., Sherif, M. and El-Shafie, A., 2023. Sediment load prediction in Johor river: deep learning versus machine learning models. *Applied Water Science*, 13(3), p.79.
- Khosravi, K., Mao, L., Kisi, O., Yaseen, Z.M. and Shahid, S., 2018. Quantifying hourly suspended sediment load using data mining models: case study of a glacierized Andean catchment in Chile. *Journal of Hydrology*, 567, pp.165-179.
- Khosravi, K., Cooper, J.R., Daggupati, P., Pham, B.T. and Bui, D.T., 2020. Bedload transport rate prediction: Application of novel hybrid data mining techniques. *Journal of Hydrology*, 585, p.124774.
- Hosseini, S.A., Abbaszadeh Shahri, A. and Asheghi, R., 2022. Prediction of bedload transport rate using a block combined network structure. *Hydrological Sciences Journal*, 67(1), pp.117-128.
- Shakya, D., Deshpande, V., Kumar, B. and Agarwal, M., 2023. Predicting total sediment load transport in rivers using regression techniques, extreme learning and deep learning models. *Artificial intelligence review*, 56(9), pp.10067-10098.
- Hosseini, H., Masteller, C.C., Dale, J.E. and Phillips, C.B., 2023. Development of a machine learning model for river bed load. *Earth Surface Dynamics*, 11(4), pp.681-693.
- Ayoubloo, Mohammad Karim, H Md Azamathulla, Ebrahim Jabbari, and Morteza Zanganeh. 2011. "Predictive Model-Based for the Critical Submergence of Horizontal Intakes in Open Channel Flows with Different Clearance Bottoms Using CART, ANN and Linear Regression Approaches." *Expert Systems with Applications* 38 (8): 10114-23.
- Azimi, Hamed, Hossein Bonakdari, Isa Ebtehaj, Bahram Gharabaghi, and Fatemeh Khoshbin. 2018. "Evolutionary Design of Generalized Group Method of Data Handling-Type Neural Network for Estimating the Hydraulic Jump Roller Length." *Acta Mechanica* 229: 1197-1214.
- Bilhan, Omer, M Emin Emiroglu, and Ozgur Kisi. 2011. "Use of Artificial Neural Networks for Prediction of Discharge Coefficient of Triangular Labyrinth Side Weir in Curved Channels." *Advances in Engineering Software* 42 (4): 208-14.

- Elsafi, Sulafa Hag. 2014. "Artificial Neural Networks (ANNs) for Flood Forecasting at Dongola Station in the River Nile, Sudan." *Alexandria Engineering Journal* 53 (3): 655–62.
- Emamgholizadeh, S. 2012. "Neural Network Modeling of Scour Cone Geometry around Outlet in the Pressure Flushing." *Global NEST Journal* 14 (4): 540–49.
- Emiroglu, M Emin, Omer Bilhan, and Ozgur Kisi. 2011. "Neural Networks for Estimation of Discharge Capacity of Triangular Labyrinth Side-Weir Located on a Straight Channel." *Expert Systems with Applications* 38 (1): 867–74.
- Ghumman, A R, Yousry M Ghazaw, A R Sohail, and K Watanabe. 2011. "Runoff Forecasting by Artificial Neural Network and Conventional Model." *Alexandria Engineering Journal* 50 (4): 345–50.
- Hsu, Kuo-lin, Hoshin Vijai Gupta, and Soroosh Sorooshian. 1995. "Artificial Neural Network Modeling of the Rainfall-runoff Process." *Water Resources Research* 31 (10): 2517–30.
- Imrie, C E, S Durucan, and A Korre. 2000. "River Flow Prediction Using Artificial Neural Networks: Generalisation beyond the Calibration Range." *Journal of Hydrology* 233 (1–4): 138–53.
- Jain, Sharad Kumar, A Das, and D K Srivastava. 1999. "Application of ANN for Reservoir Inflow Prediction and Operation." *Journal of Water Resources Planning and Management* 125 (5): 263–71.
- Kang, Boosik, Young Hun Ku, and Young Do Kim. 2015. "A Case Study for ANN-Based Rainfall–Runoff Model Considering Antecedent Soil Moisture Conditions in Imha Dam Watershed, Korea." *Environmental Earth Sciences* 74: 1261–72.
- Karami, Hojat, Abdollah Ardeshtir, Mojtaba Saneie, and S Amin Salamatian. 2012. "Prediction of Time Variation of Scour Depth around Spur Dikes Using Neural Networks." *Journal of Hydroinformatics* 14 (1): 180–91.
- Karimi, Sohrab, Hossein Bonakdari, and Azadeh Gholami. 2015. "Determination Discharge Capacity of Triangular Labyrinth Side Weir Using Multi-Layer Neural Network (ANN-MLP)." *Current World Environment, Special Volume*.
- Khalaf, Rasul M, Rafa H Al Suhaili, and Sanaa A T Al-Osmy. 2013. "Experimental and Artificial Neural Networks Modeling for Rivers Bed Morphology Changes near Direct Water Supply Intakes." *Int. Journal of Engineering Research and Applications* 3 (6): 2111–23.
- Mishra, S Sangita, K Phadtare, and M Solapure. 2015. "Rainfall Analysis and Forecasting in Mumbai Metropolitan Region Using Artificial Neural Networks (ANN)." *International Journal of Civil & Structural Engineering* 6 (2): 129–39.
- Noori, R, and F Hooshyaripor. 2014. "Effective Prediction of Scour Downstream of Ski-Jump Buckets Using Artificial Neural Networks." *Water Resources* 41: 8–18.
- Onen, Fevzi. 2014. "Prediction of Scour at a Side-Weir with GEP, ANN and Regression Models." *Arabian Journal for Science and Engineering* 39: 6031–41.
- Sisingsih, D, S Wahyuni, and A Rasyid. 2021. "Flow and Sediment Transport in a Sharp River Bend Using a 3D-RANS Model." In *IOP Conference Series: Earth and Environmental Science*, 930:12033. IOP Publishing.
- Tien, Chien-Jung, Zi-Xuan Wang, and Colin S Chen. 2020. "Microplastics in Water, Sediment and Fish from the Fengshan River System: Relationship to Aquatic Factors and Accumulation of Polycyclic Aromatic Hydrocarbons by Fish." *Environmental Pollution*, 114962.
- Veintimilla-Reyes, Jaime, Felipe Cisneros, and Pablo Vanegas. 2016. "Artificial Neural Networks Applied to Flow Prediction: A Use Case for the Tomebamba River." *Procedia Engineering* 162: 153–61.
- Xiao, He, Asfandyar Shahab, Beidou Xi, Qixin Chang, Shaohong You, Jieyue Li, Xiaojie Sun, Hongwei Huang, Xiangkui Li, and Jamil Saddique. 2020. "Heavy Metal Pollution, Ecological Risk, Spatial Distribution, and Source Identification in Sediments of the Lijiang River, China." *Environmental Pollution*, 116189.