



Prediction of the scour depth of bridge pier using artificial neural network model and comparison with empirical equations

Samad Emamgholizadeh^{1✉} , Mohammad Ali Rahimi² 

¹ Corresponding Author, Department of Water and Environmental Engineering, Faculty of Civil Engineering, Shahrood University of Technology, Shahrood, Iran. Email : s_gholizadeh517@shahroodut.ac.ir.

² M. Sc student of Water structures, Department of Water and Soil, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran. Email: mohammadalii906@gmail.com.

ABSTRACT

Introduction

The impact of flow on the bridge piers creates turbulent flows that cause scour around it, and as result collapse of the bridges. Failure and destruction of bridges, in addition to causing financial and sometimes loss of life, may cut off communication routes to flooded areas. Despite to most research which done in this field, but due to the complexity characterizes the behavior of a system and the many parameters involved in this phenomenon, there is still no exact relationship or fundamental solution to predict scour depth. Therefore, using new methods such as artificial intelligence models can be very useful.

Methods

In recent years, artificial intelligence models such as artificial neural networks (ANNs) in various fields such as water engineering have been used to predict the studied parameters. ANN biologically inspired computational networks. Among the various types of ANNs, multilayer perceptron (MLPs) with back propagation learning algorithms are famous and was used by many researchers. This model relates the inputs and outputs of a system and it has been successfully used to map non-linear input and output relationships in a wide range of areas. It consists of a layer of input nodes and layer of output nodes, connected by one or more layers of hidden nodes.

In the present study, the scour depth was estimated with ANN model. Also the ability of this model compared with linear and nonlinear regression models, and also empirical relationships. To train and test of these models, the measured data which collected from literature were used.

To estimate the scour depth, several parameters such as flow characteristics, bridge geometric characteristics, etc. are involved. In selecting the next parameters in this research, two reasons were considered: first, the parameters that have a more impact on scour depth and second, that it has been used in the research of other researchers. Effective parameters can be arranged in Eq.1 as follows.

$$D_s = f(v, y, L_p, W_p, \theta, D_{s1}, D_{s2}) \quad (1)$$

In which, D_s is scour depth, P_1 is the pier length, θ is pier angle in degrees, W_p is the pier width, V is flow velocity, y is depth of flow, D_{s0} is average particle diameter in millimeters, D_{s1} is diameter of sediment which 84% of the particles have passed through sieve.

By Buckingham's dimensional analysis, the final forms of the dimensionless parameters that define the scour depth was derived as follows:

$$\frac{D_s}{y} = f\left(\frac{L_p}{W_p}, \frac{D_{s1}}{D_{s2}}, \frac{V}{\sqrt{gy}}\right) \quad (2)$$

Results

The results of this study showed that the artificial neural network model able to predict scour depth with determination coefficient (R^2) equal to 0.99 and 0.81, as well as RMSE error equal to 0.01 m and 0.32, respectively, when data was used with dimension and non-dimension forms. Linear regression model predicted scour depth with R^2 and RMSE error of 0.58, 0.60, 0.20, 0.31, and also nonlinear regression model predicted scour depth with R^2 and RMSE, respectively, equal to 0.60, 0.91 and 0.42 m, 0.20. Also, the empirical equations. Also, the empirical equations of the Colorado State University between the empirical relationships predicted scour depth with R^2 and RMSE error equal to 0.84 and 0.52. Comparison of the results of different models shows that the best results are related to the artificial neural network model and it decreased error of prediction 70, 85.5 and 87.7% compared to linear regression model, nonlinear regression model and the empirical equation of the Colorado State University, respectively.

Conclusion

In this study, different methods such as artificial neural network model, linear and non-linear regression model were used to predict scour depth around bridge pier. Also, the performance of these models compared with previous studies. Based on dimensional analysis, dataset were used in two forms of dimension and non-dimension.

Results showed that:

- The artificial neural network (ANN) predicts the scour depth with higher accuracy, when dimensional dataset were used.
- The accuracy of the linear regression model (LR) was better when non-dimensional dataset were used.
- Comparison of different equations from previous studies showed that the Colorado State University relationship estimated the scour depth more accurately.
- Nonlinear regression model (NLR) has better performance compared to linear regression model (LR).
- Comparing ANN, and LR and NLR models with previous studies indicated that the artificial neural network model has a higher ability to predict scour depth.

Keywords: Scouring, Bridges, Empirical Relations, Artificial Neural Network

Article Type: Research Article

Article history: Received: 29 August 2021 Revised: 02 October 2021 Accepted: 19 October 2021 ePublished: 20 February 2022

Cite this article: Emamgholizadeh, S., & Rahimi, M.A. (2022). Prediction of the scour depth of bridge pier using artificial neural network model and comparison with empirical equations., *Advanced Technologies in Water Efficiency*, 1(1), 70-90. DOI: 10.22126/ATWE.2021.6873.1005





پیش بینی عمق آبستگی پایه پل با استفاده از مدل شبکه عصبی مصنوعی و مقایسه آن با روابط تجربی

صمد امامقلی زاده^۱ ✉، محمدعلی رحیمی^۲ ID

^۱ نویسنده مسئول، دانشیار گروه آب و محیط زیست، دانشکده مهندسی عمران، دانشگاه صنعتی شاهرود، شاهرود، ایران. رایانامه: s_gholizadeh517@shahroodut.ac.ir
^۲ دانشجوی کارشناسی ارشد سازه های آبی، گروه آب و خاک دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران. رایانامه: mohammadalii906@gmail.com

چکیده

برخورد جریان به پایه های پل و تکیه گاه ها جریان های آشفته ای را ایجاد می کند که سبب فرسایش در کنار پایه ها و تکیه گاه های پل شده و در نتیجه تخریب پل ها را در پی دارد. با توجه به پیچیدگی موضوع و پارامترهای زیادی که دخالت دارند هنوز یک رابطه ی دقیق یا راه حل اساسی برای پیش بینی عمق آب شستگی ارائه نشده است. در تحقیق حاضر عمق آب شستگی با استفاده از داده های اندازه گیری شده و با به کارگیری روش شبکه عصبی مصنوعی، رگرسیون خطی و غیرخطی و روابط تجربی برآورد شد. داده ها به دو صورت، با بعد و بدون بعد که با استفاده از آنالیز ابعادی به دست آمد مورد استفاده قرار گرفتند. نتایج نشان داد مدل شبکه عصبی مصنوعی توانسته است با به کارگیری پارامترهای تأثیرگذار عمق آب شستگی را با ضریب تبیین برابر با ۰/۹۷ و ۰/۸۱ و همچنین خطای RMSE برابر با ۰/۱۱m و ۰/۳۲ به ترتیب زمانی که داده ها با بعد و بدون بعد استفاده شده اند، پیش بینی کند. همچنین رابطه تجربی دانشگاه ایالتی کلرادو توانسته است عمق آب شستگی را با ضریب تبیین و خطای RMSE برابر با ۰/۵۳ و ۰/۵۲ متر پیش بینی کند. مقایسه نتایج مدل های مختلف نشان می دهد که مدل شبکه عصبی مصنوعی مقدار خطای پیش بینی عمق آب شستگی را به ترتیب ۰/۷، ۸۵/۷ و ۸۷/۷ درصد در مقایسه با مدل رگرسیون خطی، مدل رگرسیون غیرخطی و رابطه تجربی دانشگاه ایالتی کلرادو کاهش داد.

واژه های کلیدی: آب شستگی، پایه پل ها، روابط تجربی، شبکه عصبی مصنوعی

نوع مقاله: مقاله پژوهشی

سابقه مقاله: دریافت: ۰۷ شهریور ۱۴۰۰ اصلاح: ۱۰ مهر ۱۴۰۰ پذیرش: ۲۷ مهر ۱۴۰۰ چاپ الکترونیکی: ۰۱ اسفند ۱۴۰۰

استناد: امامقلی زاده، ص. و رحیمی، م.ع. (۱۴۰۰). پیش بینی عمق آب شستگی پایه پل با استفاده از مدل شبکه عصبی مصنوعی و مقایسه آن با روابط تجربی.، *فناوری های پیشرفته در بهره وری آب*، (۱)، ۹۰-۷۰. شناسه دیجیتال: 10.22126/ATWE.2021.6873.1005



© نویسندگان.

ناشر: دانشگاه رازی

آب شستگی در حقیقت جابه‌جایی ذرات رسوب توسط جریان آب از محل استقرار اولیه آن‌ها به مکان دیگری است. به‌طور کلی آب شستگی در اثر اندرکنش دینامیک، یکی نیروی محرک ناشی از جریان که در راستای جدا کردن ذره از بستر عمل می‌کند و دوم نیروی مقاوم ناشی از اصطکاک ذرات و وزن ذره که در برابر حرکت ذره مقاومت کرده و مانع جدایی ذره از بستر می‌شود حاصل می‌گردد. با حضور پایه‌های پل در مسیر جریان؛ سرعت موضعی و آشفتگی جریان افزایش می‌یابد و بسته به شکل سازه گردابه‌هایی ایجاد می‌گردند (بی‌نام، ۱۳۹۰). الگوی جریان و آب شستگی در اطراف پایه‌ها به دلیل وجود میدان جریان آشفتنه، در اطراف آن‌ها پدیده پیچیده‌ای ایجاد می‌کند. از برخورد جریان به جلوی پایه و منحرف شدن آن به سمت بستر رودخانه باعث می‌شود که یکسری گرداب‌های چرخشی در اطراف پایه به وجود آید؛ که این گرداب‌ها در پلان مانند نعل اسب می‌باشد. از این رو به آن‌ها گرداب نعل اسبی می‌گویند (ملویل، ۱۹۹۷). الگوی جریان در اطراف پایه به دو صورت، یکی برخورد جریان به پایه و دیگری جدایی جریان از پایه می‌باشد؛ که با جدایی جریان از پایه باعث تشکیل گرداب برخاستگی می‌شود و این گرداب‌ها مانند گرداب عمل کرده و ته‌نشست‌ها را از کنار پایه‌ها جدا کرده و سپس آن‌ها را به سمت پایین دست به حرکت درمی‌آورد (چیو، ۱۹۹۲). گرداب‌های برخاستگی که در پشت پایه فعال‌اند، در صورت نبودن گرداب‌های نعل اسبی حفره‌ای را در پشت پایه به وجود می‌آورند. همچنین گرداب‌های دیگری با جهت چرخش مخالف در جلوی پایه‌ها تشکیل می‌شود که به آن‌ها موج کمانی یا سطحی گفته می‌شود، که در جریان‌های کم عمق دارای اهمیت می‌باشد (رادکیوی و همکاران، ۱۹۹۸). با برخورد جریان به پایه‌ها و تکیه‌گاه‌ها جریان به سمت پایین منحرف می‌شود و با چرخش گرداب اولیه را ایجاد می‌کند؛ یک گرداب ثانویه نیز در اثر چرخش معکوس با گرداب اولیه ایجاد می‌شود. که گرداب ثانویه همراه با گرداب برخاستگی باعث یکسری فعالیت‌های پیچیده‌ای بین آب و بستر می‌شود که دلیل اصلی آب شستگی در تکیه‌گاه‌ها است (دی و همکاران، ۲۰۰۴).

با توجه به نقش بسیار مهمی که پل‌ها از لحاظ عبور از موانع فیزیکی از جمله رودخانه‌ها دارند، امروزه مساله آب شستگی آن یکی از مسائل مهم در علم مهندسی رودخانه و هیدرولیک رسوب می‌باشد، چراکه تخریب آن‌ها می‌تواند خسارت جبران‌ناپذیری ایجاد کند. بررسی پارامترهای مؤثر در ایجاد عمق آب شستگی می‌تواند نقش مهمی در پیش‌بینی آن به‌منظور طراحی ایمن و اقتصادی آن داشته باشد. از سویی دیگر، با توجه به پیچیدگی موضوع و پارامترهای زیادی که در این پدیده دخالت دارند، هنوز یک رابطه‌ی دقیق یا راه‌حل اساسی برای پیش‌بینی عمق آب شستگی ارائه نشده است.

روابط زیادی برای تخمین عمق آب شستگی پای‌های پل بر مبنای داده‌های صحرایی و یا آزمایشگاهی ارائه گردید، که دقت آن‌ها در پیش‌بینی عمق آب شستگی بخصوص روابطی که بر مبنای داده‌های آزمایشگاهی می‌باشند، کم می‌باشد. علاوه بر آن، یکی از دلایل دیگر می‌تواند مربوط به ارتباط غیرخطی بودن پارامترهای هیدرولیکی و یا مشخصات بستر رودخانه با عمق آب شستگی باشد. در سالهای اخیر استفاده از هوش مصنوعی به‌عنوان یک ابزار توانمند برای مدل‌سازی سیستم‌های غیرخطی پیچیده بخصوص در علم مهندسی هیدرولیک برای پیش‌بینی پارامترهای مختلفی مورد استفاده قرار گرفته است و استفاده از آن می‌تواند کمک مؤثری در این زمینه نماید. با توجه به اهمیت موضوع، در این تحقیق با استفاده از داده‌های صحرایی اندازه‌گیری شده سعی شد، با به‌کارگیری مدل شبکه عصبی مصنوعی و مقایسه آن با روش‌های مرسوم مانند روابط مبتنی بر رگرسیون خطی و غیرخطی و همچنین روابط تجربی، عملکرد آن در پیش‌بینی عمق آب شستگی با استفاده از ضرایب آماری مورد بررسی و مقایسه قرار گرفت. همچنین بر اساس آنالیز حساسیت بر روی پارامترهای مؤثر در ایجاد آب شستگی، عوامل مهمی که می‌تواند در پیش‌بینی عمق آب شستگی مؤثر واقع شوند، معرفی گردید.

¹ Melville

² Chiew

³ Raudkivi et al

⁴ Dey

مبانی نظری و پیشینه پژوهش

ملویل (۱۹۹۷) عواملی چون عمق جریان، اندازه‌ی پایه، شدت جریان، ویژگی‌های رسوب، نوع پایه، شکل و تراز پایه و شکل آبراهه را برای تعیین عمق آب شستگی بررسی کرد. رادکیوی و همکاران (۱۹۸۳) برای به دست آوردن عمق آب شستگی بر روی مشخصات جریان از جمله سرعت و عمق جریان مطالعه‌هایی انجام دادند. نتایج نشان داد که تأثیر عمق جریان بر حداکثر عمق آب شستگی به درجه‌بندی رسوب‌های بستر بستگی دارد. ملویل و همکاران (۱۹۸۸) با استفاده داده‌های آزمایشگاهی برای تعیین حداکثر عمق آب شستگی از پارامترهای چون سرعت، عمق جریان، اندازه‌ی و درجه‌بندی رسوب، اندازه و شکل و تراز پایه مورد مطالعه قراردادند. رئیس و همکاران (۱۳۹۴) با انجام آزمایش‌هایی بر روی انواع قطر پایه و سرعت‌های مختلف به این نتیجه رسیدند که هر چه سرعت جریان بیشتر باشد عمق آب شستگی بیشتر است. همچنین عدد فرود در بالادست پایه‌ها از اهمیت خاصی برخوردار است. کامبکار و همکاران (۲۰۰۳) برای تعیین عمق آب شستگی ناشی از موج در پایه‌های مواردی چون ارتفاع موج، دوره موج، عمق آب، قطر پایه، حداکثر سرعت ذرات موج و حداکثر سرعت برش را با استفاده از شبکه عصبی مصنوعی مورد بررسی قراردادند. نتایج نشان داد که شبکه عصبی مصنوعی نسبت به روابط تجربی عملکرد بهتری دارد. باطنی و همکاران (۲۰۰۷) با مطالعه بر روی داده‌های میدانی مقایسه‌ای را بین شبکه عصبی مصنوعی و استنباط فازی انجام دادند. بررسی‌ها نشان داد که شبکه عصبی مصنوعی نتایج بهتری نسبت به استنباط فازی دارد. بگام و همکاران (۲۰۱۳) دو مدل شبکه مصنوعی RBF و MLP برای پیش‌بینی حداکثر عمق آب شستگی در اطراف پایه‌ها استفاده کردند. هر دو مدل نتایج خوبی را نشان داد؛ اما عملکرد مدل MLP بهتر از مدل RBF بود. عبدالله محمد و همکاران (۲۰۱۶) با به‌کارگیری مدل عددی و شبیه‌سازی آزمایشگاهی برای تعیین حداکثر عمق آب شستگی عرض‌های مختلف کانال و زاویه‌های ورود آب در آستانه پل مورد بررسی قراردادند و نشان دادند که عمق آب شستگی با افزایش انقباض در آستانه پل افزایش پیدا می‌کند. چاو و همکاران (۲۰۱۴) با استفاده از یک مدل ترکیبی (GA-SVR) برای پیش‌بینی عمق آب شستگی آبراهه‌ها مورد مطالعه قراردادند و نتایج نشان داد این مدل نسبت به روش‌های تجربی، رگرسیون درختی، مدل‌های طبقه‌بندی و آشکارساز تعامل اتوماتیک تراشه مربع عملکرد بهتری دارد. غضنفری و همکاران (۱۳۹۱) با استفاده از ماشین‌های بردار پشتیبان نشان داد که این روش نسبت به روابط تجربی عمق آب شستگی را با دقت بالاتری تخمین می‌زند.

بحث تخمین عمق آب شستگی بحث بسیار مهمی در طراحی سازه‌های پل می‌باشد. بدین منظور محققین روابط تجربی زیادی برای تخمین عمق آبشستگی پایه‌های پل ارائه کرده‌اند (جدول ۱). برخی از این روابط در محیط آزمایشگاهی توسعه داده شدند و دقت آن‌ها در پیش‌بینی‌های واقعی کم می‌باشد (باطنی و همکاران، ۲۰۰۷). علت آن است که در مطالعه‌های تجربی انجام شده تأثیر همه پارامترها مؤثر بر مسئله به‌خوبی در نظر گرفته نشده است (اتما و همکاران^۱، ۱۹۹۸).

¹ Kambekar et al

² Begum

³ Multi layer perceptron

⁴ Raial basis function

⁵ Abdallah Mohamed

⁶ Chou

⁷ Genetic algorithm-support vector regression

⁸ Ettema et al

جدول ۱. روابط تجربی ارائه شده برای پیش بینی عمق آب شستگی در اطراف پایه پل

معادله تخمین آب شستگی	نام محقق
$D_s = 1/\sqrt{3} b^{0.72} V^{0.78} - y$	اینگیس (۱۹۴۹)
$\frac{D_s}{b} = 1/\delta (\frac{y}{b})^{0.72}$	لارسن و تاج (۱۹۵۶)
$D_s = 1/\delta \sqrt{3} b^{0.72} v^{0.5} y^{0.5} D_{s0}^{-0.725} - y$	بلنج (۱۹۶۲)
$D_s = 1/0.5 b^{0.75}$	لاراس (۱۹۶۳)
$D_s = 1/5 b^{0.72} y^{0.72}$	نیل (۱۹۶۴)
$\frac{D_s}{y} = 1/95 (\frac{b}{y})^2 - 1$	آرونچلام (۱۹۶۵)
$D_s = 1/11 b^{0.5} y^{0.5}$	ملویل (۱۹۷۵)
$\frac{D_s}{y} = \sqrt{K_1, K_2, K_3} (\frac{b}{y})^{0.725} Fr^{0.72}$	دانشگاه ایالتی کلرادو (۱۹۷۵)
$D_s = 1/4 b$	بروزرس (۱۹۷۷)
$D_s = 0/2 b$	رادکیوی (۱۹۸۶)
$D_s = \sqrt{0.2} (\frac{b}{y})^{0.72} Fr^{0.72} (\frac{D_{s0}}{D_s})^{0.72}$	جانسون (۱۹۹۲)
$\frac{D_s}{b} = \delta \log(\frac{b}{D_{s0}}) - 4; \quad \delta \leq \frac{b}{D_{s0}} \leq 25$	لی و استروم (۲۰۰۹)
$\frac{D_s}{b} = \frac{1/\delta}{(1/0.2 \times \frac{b}{D_{s0}} - 0.72)^2 + 1} + 1/3; \quad 25 < \frac{b}{D_{s0}}$	لی و استروم (۲۰۰۹)
$\frac{D_s}{b^{0.72} y^{0.72}} = 1/\sqrt{2} K_1, K_2, K_3 \left[\tanh\left(\frac{\sqrt{g(G_s - 1) D_{s0}}}{1/97 (\frac{D_{s0}}{D_s})^{0.72}}\right) \right]$	HN/GC اصلاح شده (۲۰۱۶)

پارامترهای به کاررفته در این جدول عبارتند از: D_s : عمق آب شستگی [L]، b : عرض پایه [L]، y : عمق جریان در بالادست پایه [L]، V : سرعت جریان نزدیک شونده به پایه $[L.T^{-1}]$ ، Fr : عدد فرود در بالادست پایه، D_{s0} : قطر متوسط ذرات رسوب [L]، D_{s4} : قطر ذرات رسوبی که ۸۴ درصد ذرات رسوب از الک عبور کرده اند [L]، G_s : چگالی نسبی ذرات رسوب، K_1 ضریب تصحیح شکل پایه است که برای پایه های مستطیلی و گرد مقدار آن یک می باشد و K_2 ضریب تصحیح زاویه برخورد جریان با پایه است و از رابطه $K_2 = (\cos\theta + \frac{L}{b} \sin\theta)^{0.65}$ محاسبه می گردد که در آن L طول پایه، b عرض پایه و θ زاویه برخورد جریان با پایه است، K_3 ضریب تصحیح شرایط بستر که برای آب زلال مقدار آن $1/1$ و برای شرایط آب گل آلود مقدار آن بین $1/1$ تا $1/3$ است.

روش پژوهش

پارامترها و نحوه انتخاب داده ها


برای تخمین عمق آب شستگی پارامترهای متعددی مانند مشخصات جریان، مشخصات هندسی پل و مشخصات رسوب دخالت دارند. در انتخاب پارامترهای با بعد در این تحقیق مدنظر بود دو دلیل اول اینکه پارامترهایی که تأثیر بیشتری بر عمق آب شستگی دارند و دوم اینکه در تحقیقات سایر محققین مورد استفاده قرار گرفته باشد؛ پارامترهای در نظر گرفته شده شامل موارد زیر است:

$$D_s = f(V, y, L_p, W_p, \theta, D_{50}, D_{84}, \emptyset) \quad (1)$$

که در رابطه ی (۱)، D_s عمق آب شستگی [L]، L_p طول پایه در جهت جریان [L]، θ زاویه برخورد جریان با پایه [L]، W_p عرض پایه [L]، V سرعت جریان $[L.T^{-1}]$ ، y عمق جریان [L]، D_{s0} قطر متوسط ذرات [L]، D_{s4} قطری که ۸۴ درصد ذرات از آن عبور کرده اند [L]، \emptyset فاکتور تأثیر شکل پایه می باشد. با استفاده از آنالیز ابعادی روش باکینگهام می توان رابطه ی (۲) را برای عمق آب شستگی به دست آورد.

$$\frac{D_s}{y} = f\left(\frac{P_1}{W_p}, \frac{D_{50}}{D_{84}}, \theta, \frac{V}{\sqrt{gy}}, \emptyset\right) \quad (2)$$

با توجه به اینکه در این تحقیق از یک نوع پایه، به شکل مستطیلی دماغه گرد استفاده گردید، لذا پارامتر \emptyset ثابت می‌باشد و در نتیجه این پارامتر از روابط ۱ و ۲ حذف گردید.



شکل ۱. آب شستگی در اطراف پایه (ملویل، ۱۹۹۷)

مشخصات داده‌ها

برای بررسی قابلیت مدل شبکه عصبی مصنوعی و رگرسیون خطی و غیرخطی در پیش‌بینی عمق آب شستگی از داده‌های ارائه شده در منبع ریچاردسون و همکاران^۱ (۱۹۹۹) استفاده گردید. آب شستگی می‌تواند در دو شرایط آب زلال^۲ و آب گل‌آلود^۳ اتفاق بیفتد. حالت اول وقتی به وجود می‌آید که سرعت جریان بیشتر سرعت آستانه حرکت است ($V > V_c$), در غیر این صورت شرایط آب گل‌آلود ایجاد می‌شود. در این پژوهش برخی از داده‌ها در شرایط آب زلال و برخی دیگر در شرایط آب گل‌آلود بودند. محدوده‌ی تغییرات داده‌ها به دو صورت با بعد و بدون بعد به ترتیب در جداول ۲ و ۳ آورده شده است. همان‌طوری که در جدول ۱ آمده است روابط تجربی ارائه شده برای پیش‌بینی عمق آب شستگی در اطراف پایه پل به دو صورت با بعد و بدون بعد ارائه شده‌اند، لذا در این پژوهش داده‌ها به دو صورت با بعد و بدون بعد مورد استفاده قرار گرفتند. در حالت استفاده از داده‌های با بعد در مقایسه با داده‌های با بدون بعد، چون تعدادی از پارامترهای مورد استفاده به صورت ترکیبی مورد استفاده قرار می‌گیرند، لذا تعداد آن‌ها کاهش می‌یابد. مطالعات سایر محققین مانند امامقلی زاده و همکاران (۲۰۱۳) و باطنی و همکاران (۲۰۰۷) در استفاده از مدل‌های هوش مصنوعی مانند شبکه عصبی نشان داد، که ترکیب داده‌های ورودی به مدل و همچنین تعداد آن‌ها می‌تواند بر روی عملکرد آن‌ها تأثیر داشته باشد. لذا بدین منظور برای در نظر گرفتن تأثیر آن، داده‌های ورودی به مدل به دو صورت با بعد و بدون بعد مورد استفاده قرار گرفتند. همچنین از کل داده‌های انتخاب شده ۱۰۷ داده (معادل ۸۰ درصد کل داده) برای آموزش مدل و از ۲۵ داده (معادل ۲۰ درصد داده‌ها) برای تست مدل استفاده گردید.

¹ Richardson et al

² Clear water scour

³ Live bed scour

جدول ۳. محدوده‌ی تغییرات پارامترهای بی‌بعد		جدول ۲. محدوده‌ی تغییرات پارامترهای با بعد		
محدوده	پارامترها	محدوده	واحد	پارامترها
۰-۲/۳۳	$\frac{D_s}{y}$	۶/۴۰-۲۴/۹۳	(m)	L_p
۰/۰۵-۰/۸۵	$\frac{D_{s_1}}{D_{s_2}}$	۰/۲۸-۳/۰۵	(m)	W_p
		۰-۴۳	(deg)	Θ
		۰/۲۴-۴/۴۸	(m/s)	V
۳/۶۷-۲۵/۲۶	$\frac{L_p}{W_p}$	۰/۱۲-۹/۴۵	(m)	y
۰/۰۴-۸۳	$Fr = \frac{V}{\sqrt{gy}}$	۰/۱۷-۹۵	(mm)	D_{s_1}
		۰/۲۵-۲۳	(mm)	D_{s_2}
		۰-۱/۶۸	(m)	D_s

انتخاب پارامترهای ورودی به مدل

به منظور دست‌یابی به ارتباط بین داده‌های ورودی (طول پایه، عرض پایه، سرعت، عمق جریان، زاویه استقرار، D_{s_1} ، D_{s_2}) و خروجی مدل (عمق آب شستگی) ابتدا آزمون همبستگی بین داده‌های مذکور در دو حالت با بعد و بدون بعد با استفاده از نرم‌افزار SPSS انجام شد. نتایج به دست آمده در جدول ۴ آورده شده است؛ همبستگی داده‌ها در دو سطح ۹۵ و ۹۹ درصد مورد بررسی قرار گرفت که علامت * نشان‌دهنده‌ی سطح ۹۹ و ** نشان‌دهنده‌ی سطح ۹۵ می‌باشد. با توجه به جدول ۴ بیش‌ترین همبستگی بین عمق آب شستگی و سرعت جریان $R = ۰/۵۳$ بوده و کمترین همبستگی بین Θ و عمق آب شستگی $R = ۰/۰۸$ بوده است. با توجه به اینکه همبستگی بین Θ و عمق آب شستگی در سطح ۹۵ درصد معنی‌دار نبود، این پارامتر از داده‌های ورودی به مدل حذف گردید.

همچنین ارتباط بین پارامترها در حالت بدون بعد نیز بررسی شد که نتایج آن در جدول ۵ آورده شده است. با توجه به جدول ۵ بیشترین ضریب همبستگی عمق آب شستگی با عدد فرود ($F_r = \frac{V}{\sqrt{gy}}$) $R = ۰/۶۹$ بوده است.

مدل شبکه عصبی مصنوعی

داده‌کاوی فرآیند تحلیلی است که برای کاوش داده‌ها صورت می‌گیرد و یافته‌ها با به‌کارگیری الگوهایی احراز اعتبار می‌کنند. هدف اصلی داده‌کاوی پیش‌بینی است. در واقع این سیستم‌ها فرآیندی هستند که با استفاده از تکنیک‌های هوش مصنوعی، دانش را از مجموعه‌ای از داده‌ها استخراج می‌کنند. شبکه عصبی مصنوعی (ANN) به‌عنوان یکی از عناصر عملیاتی ساده‌ای ساخته شده که به‌صورت موازی در کنار هم عمل می‌کنند. این شبکه از سه لایه ورودی، خروجی و پردازش تشکیل شده است؛ که هر لایه شامل گروهی از سلول‌های عصبی (نرون) می‌باشد. لایه‌های ورودی به تعداد داده‌های ورودی، لایه‌های خروجی به تعداد داده‌های خروجی و لایه‌های پردازش (پنهان) با صحیح و خطا به دست می‌آید (هانراهان، ۲۰۱۱). در این پژوهش، بر اساس آنالیز همبستگی انجام شده در بخش قبلی، تعداد داده‌های ورودی به مدل در حالت با بعد ۷ پارامتر و در حالت بی‌بعد ۳ پارامتر، برای پیش‌بینی عمق آب شستگی در نظر گرفته شد. همچنین تعداد لایه‌های پنهان با آزمون و خطا به دست آمده

¹ Artificial neural network

² Hanrahan

است. تعداد لایه‌های پنهان طوری انتخاب شد که بیشترین ضریب همبستگی R^2 ، کمترین (RMSE) میانگین مربعات خطا و کمترین (MAE) میانگین خطای مطلق را داشته است.

با توجه به اینکه در این تحقیق از یک نوع پایه، به شکل مستطیلی دماغه گرد استفاده گردید، لذا پارامتر θ ثابت می‌باشد و در نتیجه این پارامتر از روابط ۱ و ۲ حذف گردید. همچنین بر اساس آنالیز همبستگی که در بخش قبلی آمده است، بنابراین روابط ۱ و ۲ را می‌توان به صورت زیر نوشت:

$$D_s = f(V, y, W_p, L_p, \theta, D_{50}, D_{84}) \quad (3)$$

$$\frac{D_s}{y} = f\left(\frac{L_p}{W_p}, \frac{D_{50}}{D_{84}}, \frac{V}{\sqrt{gy}}\right) \quad (4)$$

رگرسیون خطی

درواقع به رگرسیونی که شامل بیش از یک متغیر مستقل باشد؛ رگرسیون خطی چندگانه گفته می‌شود. در رگرسیون خطی چندگانه تأثیر همزمان خطی دو یا چند متغیر را روی متغیر وابسته‌ای اندازه می‌گیریم و به صورت زیر نوشته می‌شود:

$$Y = a + bx_1 + cx_2 + \dots + \varepsilon \quad (5)$$

که به Y متغیر وابسته و به X_1 و X_2 و... متغیرهای مستقل و نهایتاً به ε خطای مطلق گفته می‌شود.

رگرسیون غیرخطی

رگرسیون غیرخطی نیز مانند رگرسیون خطی دارای یک متغیر وابسته و چندین متغیر مستقل است؛ که به صورت زیر نوشته می‌شود.

$$Y = A \cdot x_1^a \cdot x_2^b \cdot \dots \quad (6)$$

یافته‌ها

جدول ۴. ضریب همبستگی بین پارامترهای با بعد

D_s	D_{84}	D_{50}	y	V	W_p	θ	L_p	
۰/۲*	۰/۳۷**	۰/۳۶**	۰/۴۷**	۰/۴۷**	۰/۶۸**	-۰/۵۲**	۱	L_p
-۰/۰۸	-۰/۳۶**	-۰/۳۷**	-۰/۳۲**	-۰/۳۱**	-۰/۶۲**	۱		θ
۰/۲۴**	۰/۳۶**	۰/۳۸**	۰/۵۷**	۰/۶۰**	۱			W_p
۰/۵۳**	۰/۴۵**	۰/۴۷**	۰/۶۴**	۱				V
۰/۳۷**	۰/۰۵	۰/۱۰	۱					y
۰/۲۲*	۰/۹۹**	۱						D_{50}
۰/۲۴**	۱							D_{84}
۱								D_s

**معنی‌داری در سطح ۹۵ درصد **معنی‌داری در سطح ۹۵ درصد

² Root mean square error

³ Mean absolute error

نتایج حاصل از شبکه عصبی مصنوعی

به منظور تخمین عمق آب شستگی با استفاده از مدل شبکه عصبی مصنوعی داده‌ها به دو صورت در حالت با بعد با چهار تابع محرک شامل گوس، سکانت هیپربولیک، تانژانت هیپربولیک و سیگموئید آموزش داده شد. همچنین تعداد لایه‌های میانی از ۸ تا ۱ تغییر داده شد. بهترین نتایج هر تابع محرک در جدول ۶ آورده شده است.


تابع محرک سکانت هیپربولیک با ۶ لایه میانی توانسته که عمق آب شستگی را در مرحله‌ی آموزش با ضریب تبیین ۰/۸۵، RMSE برابر ۰/۱۴، MAE برابر ۰/۱۱ و در مرحله تست ضریب تبیین ۰/۹۹، RMSE برابر ۰/۰۱، MAE برابر ۰/۰۱ پیش‌بینی کند.

در حالت بدون بعد نیز مدل با چهار تابع انتقال (گوس، سکانت هیپربولیک، تانژانت هیپربولیک و سیگموئید) بررسی شد. بهترین نتایج آن در جدول ۶ آورده شده است. تابع محرک تانژانت هیپربولیک با ۲ لایه میانی توانسته است عمق آب شستگی را در مرحله‌ی آموزش با ضریب تبیین ۰/۸۱، RMSE برابر ۰/۲۴، MAE برابر ۰/۱۷ و در مرحله‌ی تست ضریب تبیین ۰/۸۱، RMSE برابر ۰/۳۲، MAE برابر ۰/۲۲ پیش‌بینی کند.


شکل‌های ۲ و ۳ نمودار پراکندگی بهترین نتایج مدل شبکه عصبی مصنوعی را در دو حالت با بعد و بدون بعد در مرحله‌ی آموزش و تست نشان می‌دهند. با توجه به شکل‌های ۲-الف و ۳-الف در مرحله‌ی آموزش ضریب تبیین حالت با بعد ۴/۹ درصد نسبت به حالت بی‌بعد افزایش پیدا کرده است و خطای RMSE نیز ۴۱/۶۷ درصد نسبت به بی‌بعد کاهش یافته است. همچنین در مرحله‌ی تست که در شکل‌های ۲-ب و ۳-ب نشان داده شده ضریب تبیین حالت با بعد ۲۲/۲۲ درصد نسبت به حالت بی‌بعد افزایش یافته است و خطای RMSE نیز ۹۶/۸۷ درصد نسبت به حالت بی‌بعد کاهش یافته است. از این رو مدل شبکه عصبی مصنوعی در حالت با بعد عمق آب شستگی را با دقت بالاتری نسبت به حالت بی‌بعد پیش‌بینی کرده است.

جدول ۶. بهترین نتایج حاصل از اجرای مدل شبکه عصبی مصنوعی

تست			آموزش			حالت
R ^۲	RMSE	MAE	R ^۲	RMSE	MAE	
	(m)	(m)		(m)	(m)	
۰/۰۱	۰/۴۹	۰/۳۳	۰/۸۷	۰/۱۴	۰/۱	گوسین
۰/۹۹	۰/۰۱	۰/۰۱	۰/۸۵	۰/۱۴	۰/۱۱	شبکه عصبی مصنوعی - داده با
۰/۱۹	۰/۴۱	۰/۲۸	۰/۸۵	۰/۱۴	۰/۱۱	هیپربولیک سکانت
۰/۱۵	۰/۴۵	۰/۲۹	۰/۸۴	۰/۱۵	۰/۱۲	هیپربولیک تانژانت
۰/۱۵	۰/۴۵	۰/۲۹	۰/۸۴	۰/۱۵	۰/۱۲	سیگموئید
۰/۷۲	۰/۳۹	۰/۲۳	۰/۷۴	۰/۲۶	۰/۱۷	شبکه عصبی مصنوعی - داده
۰/۷۴	۰/۳۸	۰/۲۳	۰/۷۸	۰/۲۲	۰/۱۴	گوسین
۰/۸۱	۰/۳۲	۰/۲۲	۰/۸۱	۰/۲۴	۰/۱۷	هیپربولیک سکانت
۰/۸۱	۰/۳۲	۰/۲۲	۰/۸۱	۰/۲۴	۰/۱۷	هیپربولیک تانژانت
۰/۷۷	۰/۳۷	۰/۲۲	۰/۷۴	۰/۲۶	۰/۱۷	هیپربولیک سکانت
۰/۷۷	۰/۳۷	۰/۲۲	۰/۷۴	۰/۲۶	۰/۱۷	سیگموئید



شکل ۲. پیش‌بینی عمق آب شستگی با استفاده از مدل شبکه عصبی مصنوعی حالت با بعد برای الف) آموزش مدل ب) تست مدل

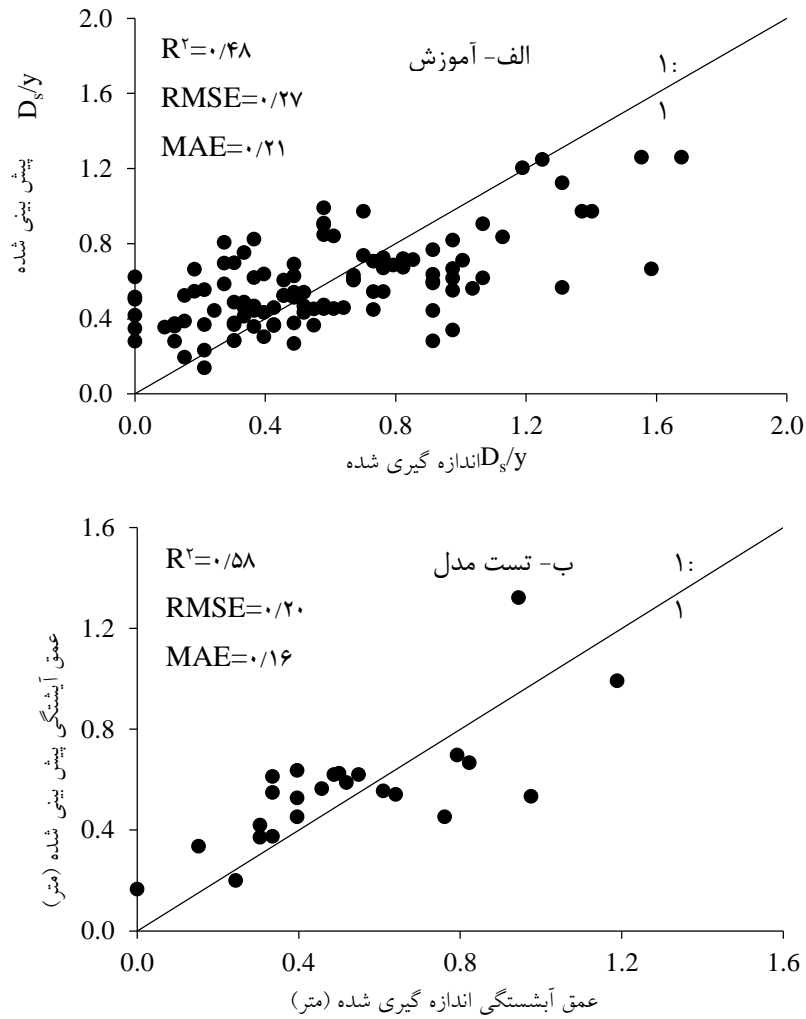


شکل ۳. پیش بینی عمق آب شستگی با استفاده از مدل شبکه عصبی مصنوعی حالت بدون بعد الف) آموزش مدل ب) تست مدل

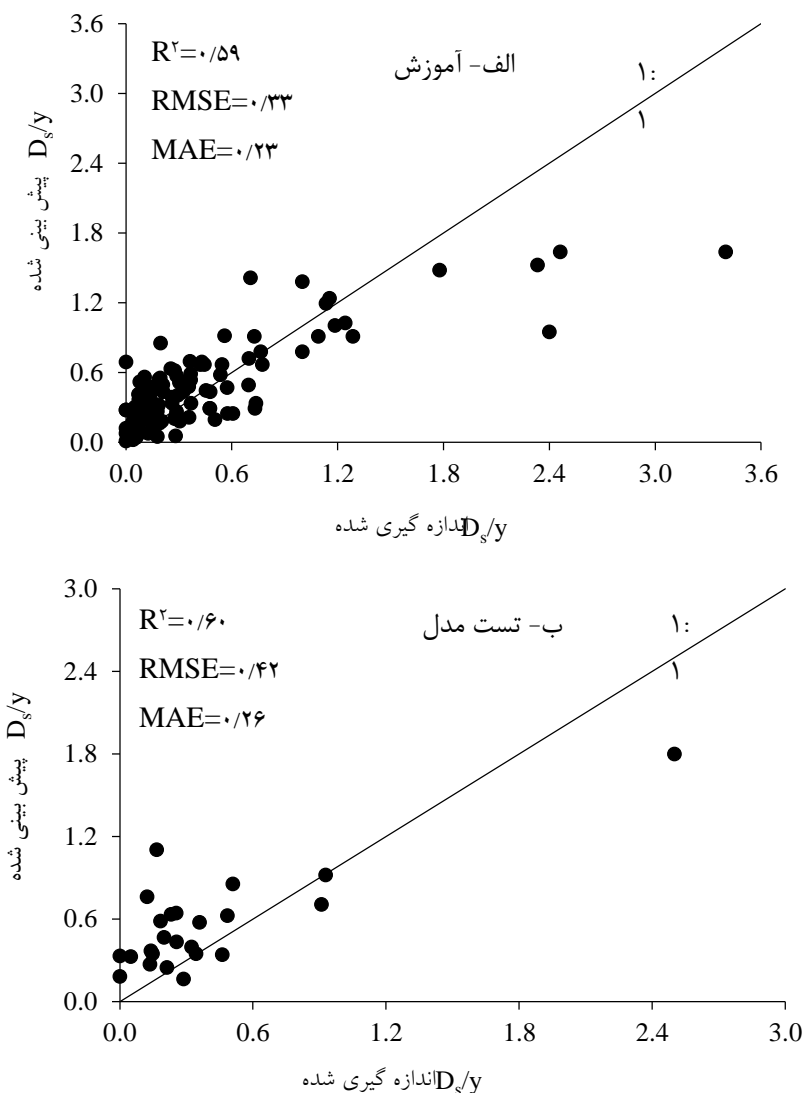
نتایج رگرسیون خطی و غیرخطی

به منظور تخمین عمق آب شستگی نرم افزار SPSS با دو مدل رگرسیون خطی و غیرخطی در دو حالت با بعد و بدون بعد که به ترتیب با ۷ و ۳ ورودی به مدل بررسی شد. نتایج به دست آمده در شکل های ۴ تا ۷ آورده شده است که رگرسیون خطی با بعد عمق آب شستگی را توانسته در مرحله ی آموزش با ضریب تبیین برابر ۰/۴۸، $RMSE$ برابر ۰/۲۷، MAE برابر ۰/۲۱ و در مرحله ی تست ضریب تبیین برابر ۰/۵۸، $RMSE$ برابر ۰/۲۰، MAE برابر ۰/۱۶ پیش بینی کند. در حالت بدون بعد عمق آب شستگی را در مرحله ی آموزش با ضریب تبیین برابر ۰/۵۹، $RMSE$ برابر ۰/۳۳، MAE برابر ۰/۲۳ و در مرحله ی تست ضریب تبیین ۰/۶۰، $RMSE$ برابر ۰/۴۲، MAE برابر ۰/۲۶ توانسته پیش بینی کند. دو حالت گفته شده در شکل های ۴ و ۵ نشان داده شده است که حالت بی بعد در مرحله ی آموزش، ضریب تبیین ۲۲/۹۲ درصد افزایش یافته و خطای $RMSE$ به مقدار ۱۸/۱۸ افزایش یافته است. در مرحله ی تست نیز ضریب تبیین، حالت بی بعد ۳/۴۵ درصد نسبت به حالت با بعد افزایش داشته و خطای

RMSE آن ۰/۵۵ درصد افزایش یافته است از این رو رگرسیون خطی بی‌بعد عمق آب شستگی را با دقت بالاتری نسبت به حالت با بعد پیش‌بینی کرده است.




شکل ۴. پیش‌بینی عمق آب شستگی با استفاده از مدل رگرسیون خطی حالت با بعد برای (الف) آموزش مدل (ب) تست مدل

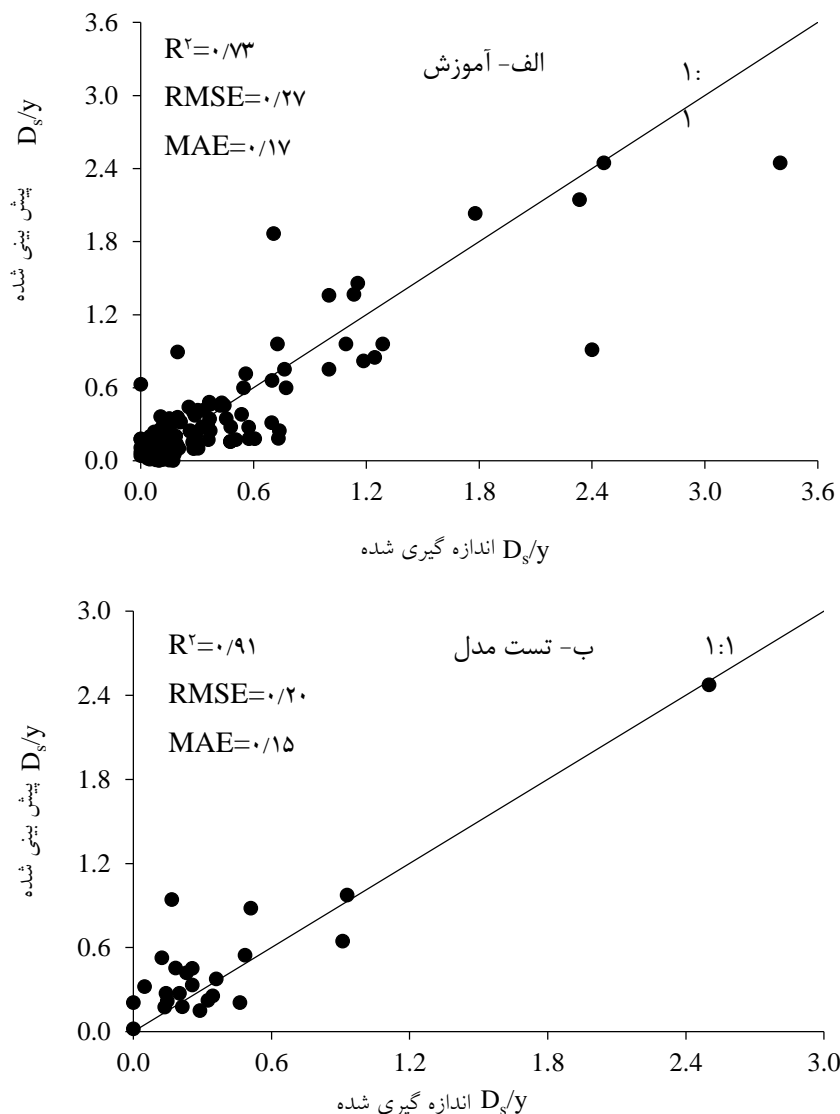


شکل ۵. پیش بینی عمق آب شستگی با استفاده از مدل رگرسیون خطی حالت بدون بعد الف) آموزش مدل ب) تست مدل

رگرسیون غیرخطی در حالت با بعد عمق آب شستگی را در مرحله ی آموزش با ضریب تبیین برابر 0.44 ، $RMSE$ برابر 0.28 ، MAE برابر 0.22 و در مرحله ی تست ضریب تبیین 0.60 ، $RMSE$ برابر 0.42 ، MAE برابر 0.26 پیش بینی کند. در حالت بدون بعد نیز عمق آب شستگی را در مرحله ی آموزش با ضریب تبیین 0.73 ، $RMSE$ برابر 0.27 ، MAE برابر 0.17 و در مرحله ی تست ضریب تبیین 0.91 ، $RMSE$ برابر 0.2 ، MAE برابر 0.15 توانسته پیش بینی کند. این نتایج در شکل های ۶ و ۷ نشان داده شده است که در مرحله ی آموزش ضریب تبیین $0.65/0.91$ درصد نسبت به حالت با بعد افزایش یافته و خطای $RMSE$ $3/6$ درصد کاهش یافته است و در مرحله ی تست ضریب تبیین در حالت بی بعد $51/66$ درصد نسبت به حالت با بعد افزایش یافته است و خطای $RMSE$ آن $52/38$ درصد کاهش یافته از این رو رگرسیون غیرخطی توانسته است در حالت بی بعد عمق آب شستگی را با دقت بالاتری نسبت به حالت با بعد پیش بینی کند.




شکل ۶. پیش‌بینی عمق آب شستگی با استفاده از مدل رگرسیون غیرخطی حالت با بعد الف)آموزش مدل ب)تست مدل



شکل ۷. پیش بینی عمق آب شستگی با استفاده از مدل رگرسیون غیرخطی حالت بدون بعد الف) آموزش مدل ب) تست مدل

نتایج روابط تجربی

برای مقایسه روش های مورد استفاده در این پژوهش با روابط تجربی موجود در منابع (جدول ۷)، در این بخش با استفاده از داده های مورد استفاده به تخمین عمق آب شستگی پرداخته شد از میان ۱۲ رابطه مورد استفاده رابطه دانشگاه ایالتی کلرادو توانسته است عمق آب شستگی را با بالاترین دقت در مرحله ی تست با ضریب تبیین ۰/۵۳، $RMSE$ برابر ۰/۲۱m، MAE برابر ۰/۱۶ m پیش بینی کند. نمودار پراکنندگی حاصل از به کار بردن این رابطه در شکل ۸ در مرحله تست نشان داده شده است.



شکل ۸. پیش‌بینی عمق آب شستگی با استفاده از بهترین رابطه تجربی (دانشگاه ایالتی کلرادو) در مرحله تست مدل

جدول ۷. نتایج حاصل از روابط تجربی در پیش‌بینی عمق آب شستگی در مرحله تست

مرحله تست مدل			رابطه تجربی
R^2	RMSE (m)	MAE (m)	مقدار پارامتر آماری
۰/۰۶	۲/۴۶	۱/۸۱	اینگلیس (۱۹۴۹)
۰/۲۷	۱/۳	۱/۱۹	لارسن و تاج (۱۹۵۶)
۰/۱۸	۰/۶۶	۰/۵۹	بلنچ (۱۹۶۲)
۰/۰۶	۱/۵۱	۱/۱۲	لاراس (۱۹۶۳)
۰/۱	۵/۷۶	۴/۳۱	نیل (۱۹۶۴)
۰/۴۷	۰/۶۱	۰/۴۶	آرونچلام (۱۹۶۵)
۰/۱۲	۵	۳/۷۲	ملویل (۱۹۷۵)
۰/۵۳	۰/۲۱	۰/۱۶	دانشگاه ایالتی کلرادو - CSU (۱۹۷۵)
۰/۰۷	۳/۹	۲/۸۴	بروزرس (۱۹۷۷)
۰/۰۷	۱/۴۸	۱/۲۶	رادکیوی (۱۹۸۶)
۰/۱۱	۱/۵۵	۱/۰۳	جانسون (۱۹۹۲)
۰/۰۶	۰/۷۱	۰/۸۲	لی و استروم (۲۰۰۹)
۰/۳۱	۱/۱۱	۰/۸۵	HN/GC اصلاح شده (۲۰۱۶)

مقایسه مدل های مختلف برای پیش بینی عمق آب شستگی

برای بررسی توانایی مدل های مختلف در پیش بینی عمق آب شستگی، مقایسه بین نتایج به دست آمده از آن ها صورت گرفت. در جدول ۸ بهترین نتایج حاصل از مدل شبکه عصبی مصنوعی، رگرسیون خطی، رگرسیون غیرخطی و روابط تجربی نشان داده شده است. نتایج به دست آمده در مدل ها نشان داده که مدل شبکه عصبی مصنوعی در حالت با بعد، رگرسیون خطی و رگرسیون غیرخطی در حالت بدون بعد عمق آب شستگی را با دقت بالاتری تخمین زدند. با مقایسه بین این سه مدل که نتایج آن ها در جدول ۸ نشان داده شده است، ضریب تبیین در مدل شبکه عصبی مصنوعی ۶۵ درصد نسبت به رگرسیون خطی و ۸/۷۹ درصد نسبت به رگرسیون غیرخطی افزایش یافته و خطای RMSE آن ۹۶/۷۷ درصد نسبت به رگرسیون خطی و ۹۵ درصد نسبت به رگرسیون غیرخطی کاهش پیدا کرده است. از این رو مدل شبکه عصبی مصنوعی در حالت با بعد توانسته با عملکرد بهتری نسبت به سایر مدل های ذکر شده عمق آب شستگی را پیش بینی کند.

مدل شبکه عصبی مصنوعی با بعد به عنوان برترین مدل انتخاب شد و با مقایسه ای که بین این مدل و بهترین رابطه تجربی مربوطه (دانشگاه ایالتی کلرادو) انجام شد، مقایسه آن ها نشان می دهد که ضریب تبیین ۱۷/۸۵ درصد نسبت به رابطه ای تجربی افزایش و خطای RMSE آن ۹۸/۰۷ درصد کاهش داشته است. از این رو مدل شبکه عصبی مصنوعی با توانایی بیشتری عمق آب شستگی را نسبت به رابطه تجربی تخمین زده است.

جدول ۸. بهترین نتایج مدل ها و روابط تجربی

تست			حالت
R^2	RMSE	MAE	
۰/۹۷	۰/۰۶	۰/۰۵	شبکه عصبی مصنوعی با بعد تابع هیپربولیک سکانت
۰/۸۱	۰/۳۲	۰/۲۲	شبکه عصبی مصنوعی بدون بعد تابع هیپربولیک تانژانت
۰/۵۸	۰/۲۰	۰/۱۶	رگرسیون خطی با بعد
۰/۶۰	۰/۴۲	۰/۲۶	رگرسیون خطی بدون بعد
۰/۶۰	۰/۴۲	۰/۲۶	رگرسیون غیرخطی با بعد
۰/۹۱	۰/۲۰	۰/۱۵	رگرسیون غیرخطی بدون بعد
۰/۱۶	۰/۲۱	۰/۵۳	رابطه تجربی دانشگاه ایالتی کلرادو

تحلیل حساسیت

به منظور مشخص کردن این که کدام یکی از پارامترهای ورودی بر عمق آب شستگی بیشترین و کمترین تأثیر را دارد، در این بخش به آنالیز حساسیت پارامترهای ورودی پرداخته شد. بدین منظور پارامترهای ورودی به دو صورت با بعد و بدون بعد وارد مدل شبکه عصبی مصنوعی گردید. در حالت با بعد که تابع هیپربولیک سکانت با ۶ لایه میانی عمق آب شستگی را با بیشترین دقت پیش بینی کرده بود برای تحلیل حساسیت پارامترهای با بعد نیز از این تابع استفاده شد که نتایج آن در جدول ۷ نشان داده شده است. با توجه به نتایج جدول ۷ با حذف پارامترهای سرعت جریان (V) و (θ) از پارامترهای ورودی می توان گفت بیشترین و کمترین تأثیر را روی عمق آب شستگی دارند و در حالت بدون بعد تابع محرک

هیپربولیک تانژانت توانسته بود با ۲ لایه میانی عمق آب شستگی را با دقت بالاتری پیش‌بینی کند، حساسیت پارامترها نیز با این تابع انجام شد که نتایج آن در جدول ۸ آورده شده است. با توجه به نتایج جدول ۸ با حذف پارامترهای ورودی Fr و $\frac{L_p}{W_p}$ بیشترین و کمترین تأثیر را روی عمق آب شستگی نشان داده است.

جدول ۹. تحلیل حساسیت پارامترهای با بعد

مشخصات آماری	R^2	RMSE (m)
L_p	۰/۸۳	۰/۰۸۶
θ	۰/۸۵	۰/۰۸۳
W_p	۰/۸۲	۰/۰۸۶
v	۰/۸۰	۰/۰۹۲
γ	۰/۸۱	۰/۰۸۸
D_{Δ}	۰/۸۴	۰/۰۸۳
$D_{\Delta f}$	۰/۸۴	۰/۰۸۲

جدول ۱۰. تحلیل حساسیت پارامترهای بدون بعد

مشخصات آماری	R^2	RMSE
$\frac{L_p}{W_p}$	۰/۸۶	۰/۰۵۸
$\frac{D_{\Delta}}{D_{\Delta f}}$	۰/۸۱	۰/۰۶۶
Fr	۰/۴۸	۰/۰۹۸

بحث

برآورد عمق آب شستگی یکی از پارامترهای مهم در علم هیدرولیک و مسائل مرتبط با مهندسی رودخانه است. در صورت عدم وجود داده‌های واقعی، استفاده از روابط تجربی و یا مدل‌های هوشمند برای تخمین عمق آب شستگی می‌تواند کمک مؤثری به محققین نماید. لذا در این تحقیق استفاده از مدل شبکه عصبی مصنوعی در مقایسه با روابط تجربی و روابط رگرسیون خطی برای برآورد عمق آب شستگی مورد استفاده قرار گرفت و عملکرد آن‌ها باهم مورد مقایسه قرار گرفت. بدین منظور بر اساس آنالیز همبستگی بر روی پارامترهای مؤثر در ایجاد عمق آب شستگی، ۷ پارامتر شامل پارامترهای طول پایه در جهت جریان (L_p)، زاویه برخورد جریان با پایه (θ)، عرض پایه (W_p)، سرعت جریان (v)، عمق جریان (γ)، قطر متوسط ذرات رسوب (D_{Δ})، و قطری که ۸۴ درصد ذرات از آن عبور کرده‌اند ($D_{\Delta f}$)، برای پیش‌بینی عمق آب شستگی (D_s)

مورد استفاده قرار گرفت. همچنین بر اساس آنالیز ابعادی به روش باکینگهام، سه پارامتر L_p / W_p ، $D_{\Delta} / D_{\Delta f}$ و F_r به صورت بدون بعد نیز مورد استفاده قرار گرفتند.

نتیجه گیری

نتایج تحقیق نشان داد مدل شبکه عصبی مصنوعی در حالتی که از داده‌های با بعد استفاده گردید، عمق آب شستگی را با دقت بالاتری نسبت به حالت بدون بعد پیش‌بینی کرد. همچنین همانند مدل شبکه عصبی مصنوعی، استفاده از داده‌های ورودی به مدل رگرسیون خطی و غیرخطی، به دو صورت با بعد و بدون بعد نیز بر روی دقت آن‌ها تأثیر داشت که علت اصلی آن می‌تواند مربوط به بیشتر بودن تعداد داده ورودی به مدل در حالت با بعد (۷ ورودی) در برابر حالت بی‌بعد (۳ ورودی) و در نتیجه ایجاد درجه آزادی بیشتر و انعطاف‌پذیری مدل برای ایجاد رابطه بین پارامترهای ورودی به مدل و خروجی از آن باشد. همچنین نتایج تحلیل حساسیت انجام شده بر روی پارامترهای مؤثر بر عمق آب شستگی نشان داد، وقتی پارامترها به دو صورت بدون بعد و با بعد مورد استفاده قرار گیرند، سرعت جریان (V) و عدد فرود جریان F_r بیشترین تأثیر را روی عمق آب شستگی دارند. استفاده از ۱۳ رابطه تجربی برای پیش‌بینی عمق آب شستگی نشان داد، رابطه دانشگاه ایالتی کلرادو در مقایسه با سایر روابط تجربی توانسته است عمق آب شستگی را با دقت بهتری تخمین بزند و در مقایسه با رگرسیون غیرخطی، نتایج آن‌ها نزدیک به هم بوده است. در مجموع مدل شبکه عصبی توانسته است در مقایسه با روابط تجربی و مدل‌های رگرسیون خطی و غیرخطی عملکرد بهتری از خود نشان دهد، لذا استفاده از آن در پیش‌بینی عمق آب شستگی به‌عنوان یک ابزار مناسب پیشنهاد می‌گردد.

منابع

- حسونی زاده، هوشنگ. (۱۳۷۰). بررسی روش‌های پیش‌بینی آبشستگی موضعی اطراف پایه پل. پایان‌نامه کارشناسی ارشد دانشگاه شهید چمران اهواز.
- راهنمای محاسبه‌ی آبشستگی موضعی (نشریه ۵۴۹). معاونت برنامه‌ریزی و نظارت راهبردی رئیس جمهور، تهران.
- رئیس‌ی، نرگس، و قمشی، مهدی. (۱۳۹۴). اثر مقیاس مدل و آزمایش‌های آبشستگی پایه‌های پل. نشریه دانش آب و خاک، (۳) ۲۴۰-۲۲۷. https://water-soil.tabrizu.ac.ir/article_4032.html
- غضنفری هاشمی، سمانه، و اعتماد شهیدی، امیر. (۱۳۹۱). پیش‌بینی عمق آبشستگی اطراف پایه پل با استفاده از ماشین‌های بردار پشتیبان. مجله علمی پژوهشی عمران مدرس، (۲) ۱۲-۳۶، ۲۳-۳۶. <http://mcej.modares.ac.ir/article-16-5542-fa.html>

References

- Abdallah Mohamed, Y., Mohamed Abdel-Aal, G., Hemdan Nasr-Allah, T., & shawky, A. (2016). Experimental and theoretical in vestigation of scour at bridge abutment Abdallah. Journal of king saud university Engineering sciences, 28, 32-40. <http://dx.doi.org/10.1016/j.jksues.2013.09.005>
- Batani, S.M., Borghei, S. M., & Jeng, D.S. (2007). Neural network and neuro-fuzzy assessments for scour depth around bridge piers. Engineering application of artificial intelligence, 20(3), 401-414. <http://dx.doi.org/10.1016/j.engappai.2006.06.012>
- Begum, S.A., Fujail, A.K., & Barbhuiya, M.D. (2012). Artificial neural network to predict equilibrium local scour depth around semicircular bridge abutments. 6th International symposium on advances in science and technology. Kuala Lumpur. Malaysia. <https://civilica.com/doc/158958>
- Blench, T. (1962). Discussion, of scour at bridge crossings. By Laursen EM. Transactions of American society of civil Engineers, 127, 180-183.
- Breusers, H.N.C. (1965). Scour around drilling platforms. Bulletin of hydraulic research, 19, 276-286.
- Breusers, H.N.C., Nicollet, G., & shen, H.W. (1997). Local scour around cylindrical piers. Journal of hydraulic research, 15(3), 211-252. <https://doi.org/10.1080/00221687709499645>

- Chiew, Y.M. (1992). Scour protection at bridge piers. *Journal of Hydraulic Engineering*, 118(9), 1260-1269. [https://doi.org/10.1061/\(ASCE\)0733-9429\(1992\)118:9\(1260\)](https://doi.org/10.1061/(ASCE)0733-9429(1992)118:9(1260))
- Chou, J.S., Pham, A.D. (2014). Hybrid computational model for predicting bridge scour depth near APA pier and abutments. *Automation in construction*, 48, 88-96. <http://dx.doi.org/10.1016/j.autcon.2014.08.006>
- Dey, S., & Barbhuiya, A.K. (2004). Clear-water scour at abutment in thinly armored beds. *Journal of Hydraulic Engineering*, 130(2), 622-634. [https://doi.org/10.1016/S1001-6279\(10\)60041-8](https://doi.org/10.1016/S1001-6279(10)60041-8)
- Emamgholizadeh, S., Bateni, M.F.M., & Jeng, D.S. (2013). Artificial intelligence-based estimation of flushing half-cone geometry. *Engineering Applications of Artificial Intelligence*, 26 (10), 2551-2558. <https://doi.org/10.1016/j.engappai.2013.05.014>
- Ettema, R., Melville B.W., & Borkdoll, B. (1998). Scale effect of pier-scour experiments. *Journal of Hydraulic Engineering*, 124(6), 639-642.
- Ghazanfari Hashemi, S.G.H., & Etemad-Shahidi, A. (2012) Prediction of Scour Depth Around Bridge Pier by Support Vector Machines. *MCEJ*. 12(2) ,23-36. <http://mcej.modares.ac.ir/article-16-5542-fa.html> [In Persian]
- Guide to calculating local scour (Journal 549). Vice President for Strategic Planning and Oversight, Tehran. [In Persian]
- Hanrahan, G. (2011). *Artificial neural networks in biological and environmental analysis*. CRC Press. Boca raton. <https://doi.org/10.1201/b10515>
- Hassoni Zadeh, H. (1991). Investigation of local scour prediction methods around the bridge pier. Master Thesis of Shahid Chamran University of Ahvaz. [In Persian]
- Inglis, S.C. (1949). Maximum depth of scour at heads of guide banks and groynes, pier noses, and downstream of bridges. *The behavior and control of rivers and canals*. Poona. India.
- Kambekar, A.R., & Deo, M.C. (2003). Estimation of pier group using neural network. *Applied ocean Research* (25), 225-234. <https://dx.doi.org/10.22115/sce.2019.173862.1098>
- Laursen, E. M., & Toch, A. (1956). Scour around bridge piers and abutments. *Bulletin no 4 Iowa highway research board, Ames Iowa us publications*.
- Lee, S.O., & Sturm, T.W. (2009). Effect of sediment size scaling on physical modeling of bridge pier scour. *Journal of Hydraulic Engineering*, 135(10), 793-802. [https://doi.org/10.1061/\(ASCE\)HY.1943-7900.0000091](https://doi.org/10.1061/(ASCE)HY.1943-7900.0000091)
- Melville, B.W. (1997). Pier and abutment scour –an integrated approach. *Journal of Hydraulic Engineering*, 123(2), 125-136. [https://doi.org/10.1061/\(ASCE\)0733-9429\(1997\)123:2\(125\)](https://doi.org/10.1061/(ASCE)0733-9429(1997)123:2(125))
- Melville, B.W., & Stherland, A.J. (1988). Design method for local scour at bridge piers. *Journal of Hydraulic Engineering*, 114(10). [https://doi.org/10.1061/\(ASCE\)0733-9429\(1988\)114:10\(1210\)](https://doi.org/10.1061/(ASCE)0733-9429(1988)114:10(1210))
- Melville, M.W. (1975). Local scour at bridge sites. University of Auckland. School of Engineering. New Zealand. Project Report No. 117.
- Neill, C. R. (1964). Riverbed scour-A review for engineers. Canadian Good Roads Association Technical Publication. Ottawa, Canada, 23.
- Raeisi, N., & Ghomeshi, M. (2015). Effect of Model Scale in Bridge Piers Scour Experiments. *Water and Soil Science*, 25(3), 227-240. https://water-soil.tabrizu.ac.ir/article_4032.html [In Persian]
- Raudkivi, A. J. (1998). *Loose Boundary Hydraulics*. <https://doi.org/10.1201/9781003077800>
- Raudkivi, A.J., & Ettema, R. (1983). Clear-water scour at cylindrical piers. *Journal of Hydraulic Engineering*, 109(3), 338-350. [https://doi.org/10.1061/\(ASCE\)0733-9429\(1983\)109:3\(338\)](https://doi.org/10.1061/(ASCE)0733-9429(1983)109:3(338))

Richardson, E.V., & lagasse, P.F. (1999). Stream stability and scour at highway bridges. ASCE Publications.