

ارزیابی عملکرد سیستم‌های هوش مصنوعی برای شبیه‌سازی آبشستگی پایه‌های پل در خاک‌های چسبنده

کیومرث روشنگر*¹ و بهزاد روح‌پرور²

تاریخ دریافت: 90/12/03 تاریخ پذیرش: 91/08/30

¹ - استادیار دانشکده عمران، دانشگاه تبریز

² - دانش آموخته کارشناسی ارشد، سازه‌های هیدرولیکی، دانشگاه آزاد اسلامی، واحد اهر، باشگاه پژوهشگران جوان، اهر، ایران

* مسئول مکاتبات، پست الکترونیکی: roshangari@tabrizu.ac.ir

چکیده

آبشستگی اطراف پایه‌های پل به عنوان یکی از مهمترین و مؤثرترین عوامل تخریب پل‌ها، در واقع نوعی فرسایش در اطراف پایه‌ها می‌باشد که در اثر جریان‌های پیچیده گردابی رخ داده و به صورت کلی باعث ایجاد یک گودال در اطراف پایه‌های پل می‌شود. تاکنون تحقیقات آزمایشگاهی و صحرایی که در این خصوص انجام شده منجر به ارائه روابط متعدد برای تخمین عمق آبشستگی شده است ولی روابط موجود به نتایج جامع و قابل قبولی منجر نشده است. در این تحقیق به کمک داده‌های آزمایشگاهی انجام شده در مورد پایه استوانه‌ای و بستر با خاک چسبنده از قابلیت سیستم‌های هوش مصنوعی در شبیه‌سازی میزان عمق آبشستگی پایه‌های پل استفاده شده است. بدین منظور با استفاده از شبکه‌های عصبی FFNN، RBF، GRNN و شبکه فازی-عصبی ANFIS برای هر دو حالت داده‌های بابت و بی‌بعد، عمق آبشستگی محاسبه شده و با انجام آنالیز حساسیت به بررسی تأثیر پارامترها در عمق آبشستگی پرداخته شده است. نتیجه حاصله حاکی از این است که مدل ANFIS با وجود کارایی بهتر نسبت به شبکه‌های GRNN و RBF دارای عملکرد ضعیف‌تری در مقایسه با شبکه FFNN است.

واژه‌های کلیدی: آبشستگی، خاک‌های چسبنده، ANFIS، FFNN، GRNN، RBF

Evaluation of Artificial Intelligence Systems for Simulation of Bridge Piers Scouring in Cohesive Soils

K Roushangar^{1*} and B Rouhparvar²

Received: 22 February 2012 Accepted: 20 November 2012

¹Assist. Prof., Dept. of Civil Eng., Univ., of Tabriz, Iran

²Former M.Sc. Student, Young Researchers Club, Ahar Branch, Islamic Azad Univ., Ahar, Iran

*Corresponding Author Email: roshangari@tabrizu.ac.ir

Abstract

Scouring around bridge piers as one of important and effective factors in bridge damage is a kind of erosion around the pier that occurs due to the effect of complex vortex flows and generally, result is a trench around the pier of bridge. Many field and laboratory investigations of scour around bridge pier and foundations cause to give different equations for prediction of scour depth. But, results of these equations are not satisfactory. In this research, capability of artificial intelligence is evaluated for simulation of cylindrical bridge pier scouring using laboratory data of cohesive soil bed. Using FFNN (Feed Forward Neural Network), RBF (Radial Basis Function), GRNN (Generalized Regression Neural Network) neural networks and ANFIS, scouring depth is calculated for both of dimensional and non-dimensional data and then using sensitivity analysis, effect of all parameters on pier scouring is determined. The results indicate that the ANFIS model leads to better results than the RBF and GRNN models but it is not as robust as FFNN.

Keywords: ANFIS, Cohesive soils, FFNN, GRNN, RBF, Scour.

مقدمه

مهمی را ایفا می‌کند. با توجه به اینکه عمق آبشستگی به پارامترهای متعددی از قبیل ویژگی‌های هیدرولیکی سیال، مشخصات هندسی پایه و مواد رسوبی بستگی دارد، مطالعه تأثیر کلیه این عوامل عملاً مشکل و غیرممکن است، لذا روابط ارائه شده تعداد محدودی از پارامترهای موثر در عمق آبشستگی را در نظر گرفته و نتایج قابل قبولی را ارائه نمی‌دهند (شفاعی بجستان 1387).

امروزه پدیده آبشستگی یکی از مسائل مهم در علم مهندسی رودخانه و مهندسی سواحل است. قرارگیری سازه‌های مختلف در مسیر جریان رودخانه‌ها مستلزم تعبیه پایه‌هایی در این مناطق است که عملاً این پایه‌ها در معرض پدیده آبشستگی قرار خواهند داشت. تعیین عمق آبشستگی از این جهت دارای اهمیت می‌باشد که اولاً بیانگر میزان پتانسیل تخریب جریان در اطراف سازه بوده و ثانیاً در طراحی ابعاد فونداسیون سازه‌هایی که در مسیر جریان آب قرار دارند نقش بسیار

استنتاج فازی- عصبی ANFIS² که ترکیب شبکه‌های عصبی و سیستم فازی بر مبنای ریاضیات فازی هستند، می‌توانند جایگزین مناسبی برای مدل‌های دیگر باشند. سیستم استنتاجی فازی- عصبی قابلیت خوبی در آموزش، ساخت و طبقه بندی دارد.

مواد و روش‌ها

داده‌های مورد استفاده

دپناث و چادری (2010) آزمایشاتی در خصوص آبشستگی موضعی اطراف پایه استوانه‌ای برای بستر رسی و ترکیب رس- ماسه در کانالی بطول 18/3 متر، عرض 0/9 متر، عمق 0/9 متر و با شیب ثابت 0/001 انجام دادند. این آزمایش‌ها شامل 56 داده برای بستر زنده می‌باشد. با پیش فرض اولیه تأثیر تمام پارامترها بر نرخ آبشستگی پارامترهای اندازه‌گیری شده به صورت تابع زیر می‌باشد:

$$Y_s = f(\rho, \mu, g, V, D, Y, \tau, D_{50}, C_p, W_c, S_0) \quad [1]$$

که در آن Y_s : عمق آبشستگی، ρ : جرم مخصوص آب، μ : لزجت دینامیکی آب، g : شتاب ثقل زمین، V : سرعت جریان در بالادست پایه، D : عرض پایه، Y : عمق جریان در بالادست پایه، τ : تنش برشی بستر، D_{50} : اندازه متوسط ذرات، S_0 : شیب بستر، C_p : مقدار رس در ترکیب رس- ماسه و W_c : درصد آب ترکیب رس- ماسه می‌باشد. با استفاده از آنالیز ابعادی و انتخاب D ، ρ و μ به عنوان متغیرهای تکراری پارامترهای بی‌بعد به شرح زیر بدست می‌آید:

$$\frac{Y_s}{D} = f(Fr_p, Re_p, \frac{Y}{D}, \frac{D}{D_{50}}, \tau, C_p, W_c, S_0) \quad [2]$$

$$\tau = \frac{t}{rV^2} \quad [3]$$

$$Fr_p = \frac{V}{\sqrt{gD}} \quad [4]$$

$$Re_p = \frac{rVD}{m} \quad [5]$$


طی دهه‌های اخیر مطالعات متنوعی در زمینه تخمین عمق آبشستگی پایه‌های پل انجام پذیرفته است. انصاری و همکاران (2002) نشان دادند که ماکزیم عمق آبشستگی متعادل در خاک‌های چسبنده می‌تواند کوچکتر یا حتی بیشتر از خاک‌های غیرچسبنده باشد، به علاوه مقدار رطوبت، مهم‌ترین فاکتور حاکم در خاک‌های چسبنده است. لی و همکاران (2007) در بررسی مدل شبکه عصبی تخمین عمق آبشستگی در خاک‌های غیرچسبنده به این نتیجه رسیدند که مدل شبکه عصبی در مقایسه با روابط تجربی توانایی خوبی در پیش‌بینی عمق آبشستگی دارد. فیرات و گانگور (2009) ضمن بررسی مدل شبکه عصبی برای پیش‌بینی عمق آبشستگی نشان دادند که قطر پایه و اندازه متوسط ذرات دارای بیشترین تأثیر روی آبشستگی در خاک‌های غیرچسبنده می‌باشند. دپناث و چادری (2010) با بررسی جامع آزمایشگاهی بر روی آبشستگی موضعی اطراف پایه‌های استوانه‌ای در بستر رسی و ترکیب رس- ماسه نشان دادند که برای تنش برشی متوسط، ماکزیم عمق آبشستگی در بالادست و پایین دست پایه یکسان است.

امروزه با پیشرفت علم و تکنولوژی و گسترش استفاده از سیستم‌های کامپیوتری در محاسبات پیچیده، سیستم‌های هوشمند کامپیوتری و به طور کلی هوش مصنوعی از اهمیت روز افزونی برخوردار شده‌اند. هوش مصنوعی سعی در مدل‌سازی پدیده‌ها و حل مسائل دشواری دارد که تحلیل آنها به شیوه‌های ریاضی معمول یا برنامه نویسی تابعی غیرممکن و یا بسیار پیچیده است. شبکه‌های عصبی مصنوعی ANN¹ به عنوان یکی از شاخه‌های اصلی هوش مصنوعی از سیستم‌های عصبی زیستی الهام گرفته شده‌اند. این شبکه‌ها از انواع مدل‌های محاسباتی هستند که قادرند رابطه میان ورودی‌ها و خروجی‌های یک سیستم فیزیکی (هر چند پیچیده و غیرخطی) را توسط شبکه‌ای از گره‌ها که همگی به هم متصل هستند، تعیین نمایند. سیستم‌های

² Adaptive Neuro-Fuzzy Inference System

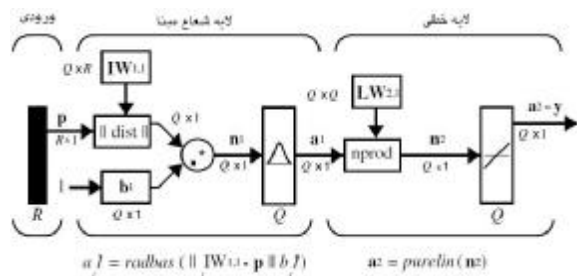
¹ Artificial Neural Networks

هوش مصنوعی - شبکه عصبی شعاع مبنا³ RBF
 شبکه‌های عصبی شعاع مبنا بر اساس یادگیری با سرپرست می‌باشند. تابع عملکرد در شبکه عصبی شعاع مبنا که بر مبنای توزیع گوسین می‌باشد، فاصله اقلیدسی بین بردار ورودی و مرکز نرون متناظر را مورد پردازش قرار می‌دهد و در ضمن به طور توانی با استفاده از کاهش پارامترهای غیرخطی محلی، نگاشت ورودی-خروجی غیرخطی را به طور محلی تخمین می‌زند (منهاج، 1381). در شکل شماره 2 یک شبکه شعاع مبنا نمایش داده شده است.



شکل 2- شبکه عصبی شعاع مبنا.

هوش مصنوعی- شبکه عصبی رگرسیونی تعمیمی GRNN⁴
 این شبکه‌ها دارای یک لایه مبنا شعاعی و یک لایه خطی خاص می‌باشند. معماری شبکه GRNN در شکل 3 نشان داده شده است. این معماری بسیار شبیه به شبکه‌های شعاع مبنا می‌باشد. البته تفاوت‌های اندکی در لایه دوم وجود دارد. لایه دوم این شبکه‌ها نیز به تعداد اعضای بردار ورودی P و T دارای نرون می‌باشد اما این بار وزن‌های $LW^{2,1}$ برابر T قرار می‌گیرند (کیا 1389).



شکل 3- شبکه عصبی رگرسیونی تعمیمی.


که در آن ℓ : تنش برشی بی‌بعد، Fr_p : عدد فرود پایه و Re_p : عدد رینولدز پایه را توصیف می‌کنند. دسته دوم داده‌ها برای بستر زنده از گزارش آزمایشی که در خصوص آبشستگی موضعی پایه استوانه‌ای در خاک‌های چسبیده برای بستر رسی در مرکز تحقیقات مهندسی در CSU¹ انجام یافته بود، تهیه شده است (بی‌نام 1999). پارامترهای اندازه‌گیری شده در اینجا نیز به صورت تابع زیر می‌باشد:

$$Y_s = f(\rho, \mu, g, V, D, Y, \tau, D_{50}, C, W_c, S_0) \quad [6]$$

که در آن C : درصد تراکم رس بوده و با استفاده از آنالیز ابعادی و انتخاب ρ و μ به عنوان متغیرهای تکراری تابع کلی آبشستگی به صورت زیر تعریف شده است:

$$\frac{Y_s}{D} = f(Fr_p, Re_p, \frac{Y}{D}, \frac{D}{D_{50}}, \ell, C, W_c, S_0) \quad [7]$$

هوش مصنوعی - شبکه عصبی پیش‌خور² FFNN
 شبکه‌های پیش‌خور مطابق شکل 1 اغلب دارای یک یا چند لایه مخفی از نرون‌های Sigmoid بوده و از یک لایه پایانی خطی استفاده می‌کنند. وجود چند لایه از نرون‌ها با یک تابع انتقال غیرخطی به شبکه اجازه می‌دهد که توانایی یادگیری رابطه خطی و غیرخطی را بین ورودی‌ها و خروجی‌ها داشته باشد. لایه خروجی خطی به شبکه این امکان را می‌دهد که خروجی خارج از محدوده +1 و -1 داشته باشد (کیا 1389).



شکل 1- شبکه عصبی پیش‌خور.

³ Radial Basis Networks

⁴ Generalized Regression Neural Networks

¹ Colorado State University

² Feed Forward Neural Network

پیش پردازش داده‌ها

آموزش شبکه‌های عصبی در صورت اعمال یکسری پیش‌پردازش‌ها بر روی ورودی‌ها و هدف می‌تواند کارایی بالاتری داشته باشد. در این تحقیق از سه روش برای پیش پردازش داده‌ها استفاده شده است. در روش اول (mapstd) بردارهای ورودی و هدف طوری تنظیم شد که میانگین آنها صفر و انحراف معیار آنها یک باشد. در روش دوم (mapminmax) بردارهای ورودی و هدف در بازه ی $[-1,1]$ مقیاس‌بندی شده و در روش سوم از بردارهای ورودی و هدف در مبنای ده لگاریتم گرفته شده است (کیا 1389).

روابط تجربی

تاکنون روابط تجربی و نیمه تجربی متعددی برای برآورد آبخستگی پایه پل ارائه شده است. در این تحقیق از روابط شن و همکاران (1969)، هانسو (1971)، اتما (1980)، (ریچاردسون و دیویس 2001) و فروهلیچ (1988) استفاده شده است. جدول 1 روابط تجربی مورد استفاده در این تحقیق را نشان می‌دهد. در این جدول، d_s : عمق آبخستگی، b : عرض پایه، Fr : عدد فرود جریان، Fr_p : عدد فرود پایه، L : طول پایه، θ_p : زاویه برخورد جریان با پایه، K_1 : ضریب شکل پایه، K_2 : ضریب زاویه برخورد جریان با پایه، K_3 : ضریب تصحیح برای شرط بستر، K_4 : ضریب تصحیح برای اندازه مصالح بستر و φ : ضریب شکل پایه، b_c : تأثیر طول پایه و هجوم آب به پایه را در نظر می‌گیرد.

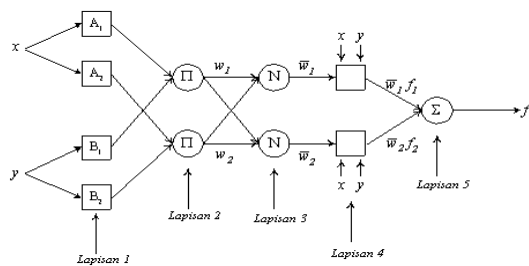
هوش مصنوعی - شبکه استنتاج فازی - عصبی ANFIS

یادگیری فازی - عصبی دارای عملکردی مشابه با شبکه‌های عصبی می‌باشد. شبکه‌های عصبی پیش‌خور مقادیر وزن خود را به صورت تصادفی در نظر می‌گیرد، ممکن است در طی فرایند آموزش در حداقل محلی گرفتار شود، که در نهایت باعث می‌شود شبکه خوب آموزش ندیده و کارایی لازم را نداشته باشد. تکنیک‌های یادگیری فازی - عصبی روشی را برای ایجاد یک رویه مدل‌سازی فازی در راستای یادگیری اطلاعات از یک مجموعه داده فراهم می‌آورند. مطابق شکل 4 اگر سیستم منطق فازی دارای دو ورودی x و y و یک خروجی z باشد برای مدل فازی sugeno درجه اول، مجموعه قوانین معمولی سیستم فازی به صورت 2 قانون اگر - آنگاه به شکل زیر در می‌آید.

$$\text{If } (x \text{ is } A_1) \text{ and } (y \text{ is } B_1) \text{ then } (f_1 = p_1x + q_1y + r_1)$$

$$\text{If } (x \text{ is } A_2) \text{ and } (y \text{ is } B_2) \text{ then } (f_2 = p_2x + q_2y + r_2)$$

f_i خروجی هر یک از قواعد، p_i ، q_i و r_i پارامترهای طراحی هستند که در طی روند آموزش تعیین می‌شوند (جنگ و همکاران 1997).



شکل 4- مدل ANFIS برای دو ورودی.

جدول 1- روابط تجربی عمق آبشستگی مورد استفاده در این تحقیق.

معادله	محقق
$Fr_p < 0.2$	$ds = 11 Fr_p^2$ Shen(I)
$Fr_p > 0.2$	$ds = 3.4 Fr_p^{0.67}$ Shen(II)
	$\frac{ds}{b} = 3.3 \left(\frac{D_{50}}{b}\right)^{0.2} \left(\frac{y}{b}\right)^{0.13}$ Hancu
$K_2 = (\sin qp + \frac{l}{a} \cos qp)^{0.65}$	$\frac{ds}{y} = 2K_1 K_2 K_3 K_4 \left(\frac{b}{y}\right)^{0.65} Fr^{0.43}$ CSU
$b' = b \cos qp + L \sin qp$	$\frac{ds}{b} = 0.32j \left(\frac{b'}{b}\right)^{0.65} \left(\frac{y}{b}\right)^{0.46} Fr^{0.2} \left(\frac{b}{D_{50}}\right)^{0.08} + 1$ Froehlich
	$\frac{ds}{b} = \left(\frac{y}{b}\right)^{0.62} Fr^{0.2} \left(\frac{b}{D_{50}}\right)^{0.08}$ Ettema

ارزیابی اعتبار مدل‌ها

به منظور ارزیابی و بررسی کارایی روش‌های مورد استفاده برای تخمین عمق آبشستگی، از توابع جذر میانگین مربعات خطاها، ضریب همبستگی، میانگین قدرمطلق خطاها و میانگین قدرمطلق نسبت خطاها استفاده گردید. با توجه به اینکه معیار میانگین قدرمطلق نسبت خطاها بی‌بعد است به همین دلیل این معیار و ضریب همبستگی برای بررسی کارایی مدل‌ها، برای داده‌های با بعد و بی‌بعد استفاده شده است.

$$RMSE = \sqrt{\left[\frac{\sum_{i=1}^N (Y_M - \bar{Y}_P)^2}{N} \right]} \quad [8]$$

$$R = \frac{\sum_{i=1}^N (Y_M - \bar{Y}_M) \cdot (Y_P - \bar{Y}_P)}{\sqrt{\sum_{i=1}^N (Y_M - \bar{Y}_M)^2 \cdot (Y_P - \bar{Y}_P)^2}} \quad [9]$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_M - Y_P| \quad [10]$$

$$MARE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_M - Y_P}{Y_M} \right| \times 100 \quad [11]$$

در روابط یاد شده Y_M : عمق آبشستگی اندازه‌گیری شده، \bar{Y}_M : متوسط عمق آبشستگی اندازه‌گیری شده، Y_P :

عمق آبشستگی پیش‌بینی شده، \bar{Y}_P : متوسط عمق

آبشستگی پیش‌بینی شده را توصیف می‌کنند.

در این تحقیق مدل‌سازی آبشستگی پایه‌های پل در خاک‌های چسبنده با استفاده از شبکه‌های عصبی و فازی- عصبی انجام شد. برای این منظور کلیه پارامترهای آموزشی، تعداد نرون‌ها و لایه‌ها با استفاده از سعی و خطا انتخاب شدند. بردارهای ورودی برای شبکه پیش‌خور به صورت تصادفی توسط نرم افزار به سه مجموعه به شرح زیر تقسیم می‌شوند. 60% داده‌ها در مجموعه آموزشی، 20% داده‌ها در مجموعه ارزیابی در راستای جلوگیری از بیش‌برازش شبکه، 20% داده‌ها در مجموعه تست برای بررسی کارایی شبکه نهایی در نظر گرفته شد. با توجه به اینکه مجموعه بالا تصادفی انتخاب می‌شود برای رسیدن به نتایج بهتر و دقیق، روند آموزش چند بار تکرار شد تا خروجی هر سه مجموعه نزدیک به هم باشد. برای شبکه‌های شعاع مبنا، رگرسیون تعمیمی و ANFIS، 30% داده‌ها جهت تست و 70% داده‌ها جهت آموزش شبکه به صورت تصادفی انتخاب شدند. در مدل ANFIS برای آموزش پارامترهای تابع عضویت، روش بهینه‌سازی hybrid که در آن از پس انتشار در مورد پارامترهای مربوط به توابع عضویت ورودی و تخمین حداقل مربعات برای

نخست مطابق جدول 2، هفت مدل به عنوان مدل‌های اولیه با ورودی‌های مختلف به شبکه‌های مختلف معرفی شدند.

پارامترهای مربوط به توابع عضویت خروجی استفاده شد. تعداد دوره‌ها و خطای مطلوب به ترتیب 200 و صفر انتخاب شدند. با توجه به اینکه عمق آبخستگی به پارامترهای متعددی وابسته است، در گام


جدول 2- ساخت مدل‌های مختلف برای ورودی‌های با بعد و بی‌بعد.

مدل	ورودی‌های بی‌بعد	ورودی‌های با بعد
Model(I)	$FrP, Re P, \frac{Y}{D}, \frac{D}{D_{50}}, \hat{f}, CP, WC, S_0$	$V, D, Y, \tau, D_{50}, C_P, W_C, S_0$
Model (II)	$FrP, \frac{Y}{D}, \frac{D}{D_{50}}, \hat{f}, CP, WC, S_0$	$Y, \tau, D_{50}, C_P, W_C, S_0$
Model (III)	$FrP, Re P, \frac{Y}{D}, \frac{D}{D_{50}}$	Y, C_P, W_C, S_0
Model (IV)	CP, WC, S_0	V, D_{50}, C_P, W_C
Model (V)	\hat{f}, CP, WC, S_0	V, D, Y, τ, D_{50}
Model (VI)	$FrP, Re P, CP, WC, S_0$	V, D, Y, S_0
Model (VII)	$FrP, \frac{Y}{D}, \frac{D}{D_{50}}, S_0$	V, C_P, W_C, S_0


نتایج و بحث

شعاع مبنا میزان گستردگی گوسی برای هر دو مدل 1، و در شبکه رگرسیونی تعمیمی میزان گستردگی گوسی برای مدل با بعد 6 و برای مدل بی‌بعد 1 انتخاب شد. در مدل فازی- عصبی بدلیل کثرت پارامترهای ورودی از خوشه‌بندی فازی که در حقیقت فرآیندی برای شناخت الگوی واقعی مربوط به عامل‌های مختلف است استفاده گردید که 9 تابع گوسی به عنوان تابع عضویت بهینه برای هر دو مدل انتخاب شد.

اجرای اولیه مدل‌های ارائه شده نشان داد برای داده‌های بی‌بعد Model(II) در کلیه شبکه‌های ANN و ANFIS با 7 ورودی شامل $FrP, \frac{Y}{D}, \frac{D}{D_{50}}, \hat{f}, CP, WC, S_0$ (شکل 5- الف) برای داده‌های با بعد Model(I) با 8 ورودی شامل $Y, \tau, D_{50}, C_P, W_C, S_0, V, D$ (شکل 5- ب) به عنوان بهترین مدل با کمترین قدرمطلق نسبت خطاها و بیشترین ضریب همبستگی عمل می‌نماید. در شبکه FFNN برای مدل با بعد شبکه با 1 لایه میانی و 6 نرون در این لایه و برای مدل بی‌بعد شبکه با 2 لایه میانی و 10 نرون عملکرد مناسبی را از خود نشان داد. در شبکه



	Model (I)	Model (II)	Model (III)	Model (IV)	Model (V)	Model (VI)	Model (VII)
MARE%	21.125	52.21	58.79	28.29	29.8	61.31	38.32
R%	94.07	63.3	67.3	88.9	89.3	59.2	85.3



	Model (I)	Model (II)	Model (III)	Model (IV)	Model (V)	Model (VI)	Model (VII)
MARE%	15.2	12.64	26.04	62.16	25.2	20.18	24.41
R%	94	96.1	87.5	67.3	90.9	93.2	86

(الف)

(ب)

شکل 5- نتایج عملکرد شبکه FFNN به ازای مدل‌های مختلف: الف) با بعد 3 بی‌بعد.

مرحله آموزش با داشتن $MARE$ ، $RMSE$ و MAE پایین و ضریب همبستگی بالا در مقایسه با مدل‌های GRNN و ANFIS، ولی عملکرد مناسب این مدل‌ها در مرحله تست در هر چهار معیار نسبت به RBF را نشان می‌دهد.

نتایج ارزیابی عملکرد بهترین ترکیب با استفاده از مدل شبکه عصبی و فازی - عصبی در جدول 3 و 4 برای بستر ترکیب رس - ماسه و رس خالص نشان داده شده است. مقایسه نتایج از عملکرد مناسب شبکه RBF در

جدول 3- مقایسه نتایج مدل‌های ANN و ANFIS برای بستر چسبیده (داده‌های با بعد).

تست				آموزش				مدل
$MARE$ (%)	$RMSE$ (cm)	MAE (cm)	R	$MARE$ (%)	$RMSE$ (cm)	MAE (cm)	R	
بستر ترکیب رس - ماسه								
21/13	1/3855	1/182	0/941	21/13	1/3855	1/182	0/941	FFNN
33/35	2/8775	2/1812	0/761	28/90	1/6991	1/356	0/903	GRNN
57/65	4/8016	4/3722	0/70	1/04e-13	1/86e-15	4/7e-15	0/999	RBF
33/35	2/0726	1/7705	0/816	4/36e-4	3/57e-5	2/63e-5	0/999	ANFIS
بستر رسی								
11	1/2709	0/765	0/972	11	1/2709	0/765	0/972	FFNN
26/60	3/5647	2/3414	0/71	10/58	1/1077	0/728	0/977	GRNN
46/60	4/9817	3/4168	0/70	2/28e-14	5/52e-15	3/5e-15	0/999	RBF
22/6	3/088	2/1344	0/831	4/15	0/3919	0/265	0/997	ANFIS

هر چهار معیار برای مدل‌های با بعد 3 بی‌بعد برای هر دو بستر، برخوردار است. مقایسه نتایج مدل با بعد 3 بی‌بعد حاکی از این است که شبکه‌های عصبی و فازی - عصبی برای مدل بی‌بعد عملکرد مناسب‌تری داشته‌اند.

مدل FFNN با داشتن R بالا و $MARE$ ، MAE و $RMSE$ پایین از قابلیت بالایی در پیش‌بینی عمق آبشستگی دارا می‌باشد. شبکه عصبی FFNN در مقایسه با مدل ANFIS و شبکه‌های RBF، GRNN که قبل از ایجاد نگاشت به تقسیم‌بندی الگوها می‌پردازند و برای هر طبقه نگاشتی غیرخطی ایجاد می‌کنند، از عملکرد مناسبی در

جدول 4- مقایسه نتایج مدل‌های ANN و ANFIS برای بستر چسبیده (داده‌های بی‌بعد).

تست				آموزش				مدل
MARE (%)	RMSE	MAE	R	MARE (%)	RMSE	MAE	R	
بستر ترکیب رس - ماسه								
12/64	0/0994	0/0666	0/961	12/64	0/0994	0/0666	0/961	FFNN
17/65	0/2869	0/128	0/75	8/21	0/05	0/0388	0/989	GRNN
39	0/2435	0/093	0/766	2/38e-13	2/38e-15	6/9e-16	0/999	RBF
9/35	0/1153	0/054	0/948	1/03	0/0297	0/0056	0/996	ANFIS
بستر رسی								
9/15	0/097	0/0487	0/972	9/15	0/097	0/0487	0/972	FFNN
18/20	0/15	0/1073	0/881	10/46	0/1044	0/0649	0/957	GRNN
19	0/1533	0/1293	0/790	0/092	9/25e-4	2/56e-4	0/999	RBF
18/70	0/1221	0/0968	0/936	0/20	1/21e-3	7/1e-4	0/998	ANFIS

داده ورودی، X_{max} : ماکزیمم داده‌ها و X_{min} : مینیمم داده‌ها می‌باشد. برای هر سه تابع پیش پردازش مورد استفاده قرار گرفته کارایی شبکه در هر چهار معیار کاهش یافت (جدول 5).

برای تعیین تأثیر پیش پردازش داده‌ها بر روی عملکرد شبکه FFNN پارامترهای بی‌بعد برای مدل برتر بستر ترکیب رس - ماسه نرمالیزه شدند. در جدول 5، $Y_{max}=1$ ، $Y_{min}=-1$ ، X_{mean} : میانگین داده‌ها، X_{std} : انحراف معیار داده‌ها، $Y_{mean}=0$ ، $Y_{std}=1$ ، X_n : داده نرمالیزه شده، X :

جدول 5- تأثیر پیش پردازش داده‌ها بر روی شبکه FFNN.

MARE (%)	RMSE	MAE	R	تابع پیش پردازش
34/52	0/187	0/144	0/86	$X_n = \frac{(Y_{max} - Y_{min}) * (X - X_{min})}{(X_{max} - X_{min})} + Y_{min}$
23/21	0/201	0/127	0/84	$X_n = (X - X_{mean}) * \left(\frac{Y_{std}}{X_{std}}\right) + Y_{mean}$
32/59	0/639	0/237	0/54	Log_{10}

مذکور با مدل برتر FFNN و ANFIS حاکی از این است که این مدل‌ها با داشتن MARE، RMSE و MAE پایین و R بالا از قابلیت بالایی در تخمین عمق آبشستگی برخوردارند.

مقایسه مدل ANN، ANFIS و روابط تجربی

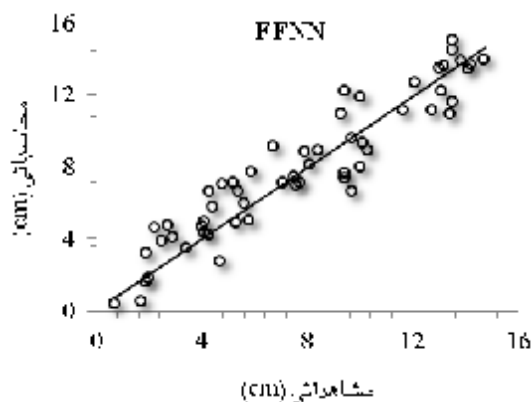

جدول 6 نتایج روابط تجربی به کار رفته در این تحقیق را نشان می‌دهد. با مقایسه نتایج حاصل از این تحقیق و شهردافر و همکاران (1387) نیز نتیجه می‌شود که معادله CSU و HANCU نسبت به سایر معادلات از نتایج قابل قبول‌تری برخوردار هستند. مقایسه معادلات

جدول 6- مقایسه نتایج روابط تجربی در تخمین عمق آبشستگی.

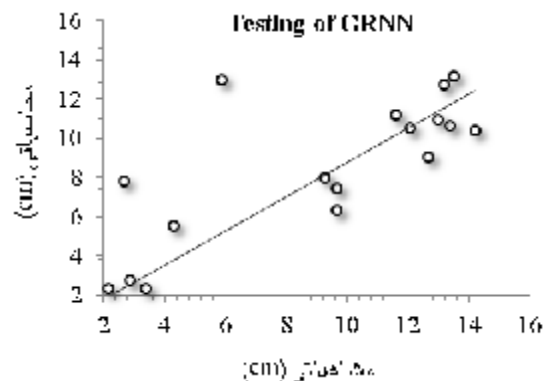
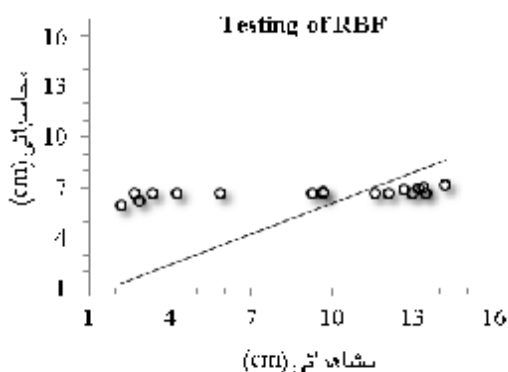
بستر رسی				بستر ترکیب رس - ماسه				روش
MARE %	RMSE	MAE	R	MARE %	RMSE	MAE	R	
106/42	0/28	0/2405	0/415	132/35	0/4596	0/4264	0/732	CSU
120/15	0/41	0/3485	0/537	49/12	0/3582	0/2912	0/616	HANCU
482/185	1/8263	1/7961	0/418	169/12	0/8998	0/8775	0/814	SHEN
613/125	2/3189	2/291	0/275	263/32	1/3594	1/3778	0/776	ETTEMA
338/91	1/191	1/1455	0/275	205/47	1/057	1/0108	0/789	FROEHLICH

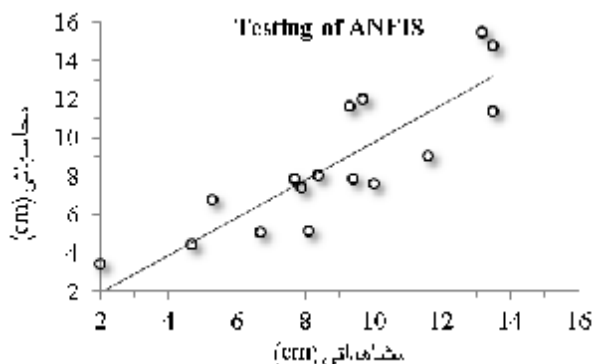
مشاهده شده و برآورد دقیقتر مدل است. بنابراین با توجه به نمودار مقادیر برآورد شده توسط مدل FFNN نسبت به مدل‌های RBF، GRNN و ANFIS از انحراف کمتری برخوردار است.

نمودارهای بهترین مدل شبکه‌های عصبی و فازی - عصبی در شکل‌های 6 و 7 آورده شده است. در نمودارها هرچه نقاط به خط 1:1 نزدیکتر باشد نشان دهنده انحراف کمتر مقادیر محاسبه شده از مقادیر



شکل 6- عمق آبشستگی مشاهداتی و پیش‌بینی شده توسط FFNN برای مدل برتر.





شکل 7- عمق آبخستگی مشاهداتی و پیش‌بینی شده توسط GRNN, RBF و ANFIS برای مدل برتر (تست).

آنالیز حساسیت

برای تعیین میزان تأثیر پارامترها در آبخستگی پایه‌های پل آنالیز حساسیت انجام گرفت. برای بستر ترکیب رس- ماسه در مدل بابعدها حذف سرعت $MARE$ حدود 29% افزایش و پارامتر R حدود 26% کاهش یافت. در مدل بی‌بعد تنش برشی بی‌بعد و مقدار رس در ترکیب رس- ماسه بیشترین تأثیر را داشتند به طوری که با حذف این پارامترها $MARE$ به ترتیب در حدود 35% و 34% افزایش

و R در حدود 16% و 15% کاهش یافت. برای بستر رس خالص در مدل بابعدها حذف سرعت $MARE$ حدود 9% افزایش و R حدود 10% کاهش یافت. در مدل بی‌بعد درصد تراکم رس بیشترین تأثیر را داشت به طوری که با حذف درصد تراکم رس $MARE$ حدود 23% افزایش و R حدود 18% کاهش یافت. جدول 7 میزان حساسیت شبکه FFNN نسبت به حذف پارامترها را نشان می‌دهد.

جدول 7- نتایج آنالیز حساسیت برای بستر چسبنده (داده‌های بابعدها و بی‌بعد).

بابعدها			بی‌بعد				
$MARE$ (%)	$RMSE$ (cm)	R	پارامتر حذف شده	$MARE$ (%)	$RMSE$	R	پارامتر حذف شده
بستر ترکیب رس- ماسه							
49/66	3/070	0/686	V	47/73	0/204	0/802	$\hat{\tau}$
36/08	2/618	0/775	τ	46/56	0/203	0/814	C_p
34/2	2/471	0/793	D_{50}	40/71	0/200	0/814	W
33/52	2/279	0/837	Y	36/75	0/189	0/853	Y/D
28/41	1/7916	0/90	D	29/14	0/182	0/860	Fr_p
				29	0/174	0/862	D/D_{50}
				24/79	0/153	0/894	S_0
بستر رسی							
20/47	2/673	0/859	V	32/15	0/215	0/794	C
17/32	2/326	0/893	τ	28/02	0/201	0/854	$\hat{\tau}$
14/44	2/223	0/940	Y	27/29	0/191	0/848	W
13/35	1/772	0/968	D_{50}	26/02	0/182	0/859	Fr_p
12/59	1/481	0/961	D	22/71	0/180	0/883	Y/D
				22/68	0/166	0/878	S_0
				18/53	0/142	0/922	D/D_{50}

نتیجه گیری کلی

- شبکه‌های عصبی و فازی - عصبی نسبت به روابط تجربی از قابلیت خوبی برای تخمین عمق آبشستگی اطراف پایه‌های پل برخوردار بوده و معادله CSU و HANCU نسبت به سایر معادلات نتایج قابل قبول‌تری دارد.

- با بی‌بعد کردن پارامترهای ورودی کارایی مدل افزایش پیدا کرد.

- مقایسه نتایج تحقیق فیرات و گانگور (2009) و این تحقیق نشان می‌دهد که در خاک‌های چسبنده درصد رس در ترکیب رس- ماسه و درصد تراکم رس برای بستر رسی بیشترین تأثیر و اندازه متوسط ذرات بر خلاف خاک‌های غیرچسبنده کمترین تأثیر را بر روی بستر رسی در تخمین عمق آبشستگی دارند. نتایج تحقیق فیرات و گانگور (2009)، کایا (2010) و این تحقیق نشان می‌دهد که سیستم‌های هوشمند با دقت قابل قبولی عمق آبشستگی را مدل‌سازی می‌کنند.

در این تحقیق قابلیت و کارایی شبکه‌های پیش‌خور، شعاع مبنا، رگرسیون تعمیمی و سیستم استنتاج فازی - عصبی برای شبیه‌سازی عمق آبشستگی اطراف پایه پل در خاک‌های چسبنده مورد بررسی و تجزیه و تحلیل قرار گرفت. نتایج بدست آمده حاکی از آن است که:

- شبکه شعاع مبنا در آموزش عملکرد مناسبی نسبت به بقیه شبکه‌ها داشته، ولی نتایج نهایی این مدل نسبت به مدل‌های دیگر از دقت کافی برخوردار نیست.

- مدل فازی - عصبی کارایی بهتری نسبت به شبکه‌های رگرسیونی تعمیمی و شعاع مبنا در هر چهار معیار مورد ارزیابی قرار گرفته داشته ولی در مقایسه با شبکه‌های پیش‌خور کارایی ضعیف‌تری دارد.

- کارایی نهایی مدل با پیش‌پردازش داده‌ها کاهش یافت.

منابع مورد استفاده

- شفاعی بجمستان م، 1387. مبانی نظری و عملی هیدرولیک انتقال رسوب. انتشارات دانشگاه شهید چمران اهواز، چاپ اول. شهزادفر س، ابوالواسط ن و حسن زاده ی، 1387. بررسی کارایی شبکه‌های عصبی مصنوعی در پیش‌بینی عمق آبشستگی پایه‌های پل و مقایسه نتایج با مدل‌های ریاضی معتبر. چهارمین کنگره ملی مهندسی عمران، 17-20 اردیبهشت، دانشگاه تهران.
- کیا س م، 1389. محاسبات نرم در Matlab. انتشارات کیان رایانه سبز، تهران.
- منهاج م ب، 1381. مبانی شبکه‌های عصبی. مرکز نشر دانشگاه صنعتی امیر کبیر.
- Ansari SA, Kothiyari UC and Ranga Raju KG, 2002. Influence of cohesion on scour around bridge piers. J Hydraulic Research 40 (6): 717-729.
- Anonymous, 1999. Experimental study of scour around circular pier in cohesive soils. Federal Highway Administration -RD-99-186 4: 99-186.
- Depnath K and Chaudhuri S, 2010. Laboratory experimental on local scour around cylinder for clay – sand mixed beds. J Engineering geology 111: 51 – 61.
- Ettema RE, 1980. Scour at Bridge Piers. Department of Civil Engineering, University of Auckland, Auckland, New Zealand, 216.
- Firat M and Gungor M, 2009. Generalized regression neural networks and feed forward neural networks for prediction of scour depth around bridge piers. J Advances in Engineering Software 40: 731-737.
- Froehlich DC, 1988. Analysis of onsite measurements of scour at piers. In: Proceedings of the ASCE National Hydraulic Engineering Conference, Colorado Springs, Colorado, pp. 534-539. American Society of Civil Engineers, New York, NY.
- Hancu S, 1971. Sur le calcul des affouillements locaux dans la zone des piles des ponts. Pp. 299-313. In: Proceedings of the 14th International Association of Hydraulic Research Congress, Paris, France.
- Jang JSR, Sun CT and Mizutani E, 1997. Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence. Prentice-Hall International, New Jersey.

- Kaya A, 2010. Artificial neural network study of observed pattern of scour depth around bridge piers. *J Computers and Geotechnics* 37: 413–418.
- Lee TL, Jeng DS, Zhang GH and Hong JH, 2007. Neural network modeling for estimation of scour depth around bridge piers. *J Hydrodynamics Ser B* 19(3): 378–386.
- Richardson EV and Davis SR, 2001. Evaluating Scour at Bridges. 4th edn. Hydraulic Engineering Circular No. 18, Rep. No. FHWA NHI 01-001, Federal Highway Administration, Washington, DC.
- Shen HW, Schneider VR and Karaki SS, 1969. Local scour around bridge piers. *Hydraulic Division ASCE* 95 (6): 1919-1940.