

کاربرد شبکه عصبی مصنوعی در تخمین عمق آبستگی اطراف پایه پل در بستر با رسوبات چسبنده

رحیم رضازاده¹، غلامعباس بارانی² و امینه ناصری^{3*}

1- دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران، دانشگاه صنعتی سیرجان، سیرجان

2- استاد، دانشکده مهندسی عمران، دانشگاه شهید باهنر کرمان، کرمان

3- مربی، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی سیرجان، سیرجان

* naseri.amine@sirjantech.ac.ir

(دریافت مقاله: 97/4/16؛ پذیرش مقاله: 97/10/24)

چکیده - بیشتر آسیب پل‌ها به دلیل آبستگی اطراف پی‌های آن در شرایط سیلابی جریان است. بنابراین برای حداقل‌سازی احتمال خرابی، یک مدل بهبود یافته برای تخمین عمق آبستگی اطراف آنها لازم است. به دلیل اینکه آبستگی در پایه‌های پل یک تابع پیچیده از مشخصات مصالح کف، ویژگی‌های سیال، مشخصات جریان و هندسه پایه است، معادلات تجربی توانایی تخمین دقیق عمق آبستگی را ندارند. در این تحقیق، روشی سودمند برای تخمین عمق آبستگی در خاک‌های چسبنده مبتنی بر راهکارهای هوش مصنوعی ارائه شده است. به منظور ارزیابی عملکرد روش ذکر شده از داده‌های آزمایشگاهی در دو حالت با بعد و بی بعد استفاده شده است. در اینجا ابتدا مدل مناسبی مبتنی بر شبکه عصبی مصنوعی ارائه شده و سپس با استفاده از الگوریتم ژنتیک بهینه شده است. متوسط ضریب همبستگی بدست آمده برای داده‌های بی‌بعد با استفاده از روش پیشنهادی 0/97 بوده است. در این مدل شبکه عصبی بهینه شده با الگوریتم ژنتیک، مقدار ریشه میانگین مربعات خطا، 0/094 می‌باشد. نتایج حاصل نشان می‌دهد که روش پیشنهادی در تخمین عمق آبستگی پایه‌های پل در بسترهای با رسوبات چسبنده در مقایسه با معادلات تجربی عملکرد بسیار بهتری دارد.

کلیدواژگان: آبستگی پایه پل، رسوبات چسبنده، شبکه عصبی مصنوعی، الگوریتم ژنتیک.

1- مقدمه


است. آبستگی پل به عنوان دلیل اصلی خرابی پل بزرگراه‌ها در آمریکا شناخته شده است (Kattell and Eriksson, 1998). تاکنون محققان فرمول‌های زیادی را برای پیش‌بینی عمق آبستگی توسعه داده‌اند. آزمایش‌هایی برای مطالعه بر روی آبستگی پایه پل در خاک‌های چسبنده توسط Hosny (1995) انجام شد، در این مقاله به این نتیجه رسیدند که عمق آبستگی در خاک چسبنده به مقدار زیادی به ویژگی‌های خاک بستگی دارد و فرایند آبستگی پایه در خاک چسبنده، آهسته

ساخت پایه‌های پل یک کار پرهزینه است، از آنجا که یک پل به طور معمول پایه‌های متعددی دارد تخمین دقیق عمق آبستگی تعادلی اطراف پایه‌های پل، برای طراحی ایمن و اقتصادی پایه‌های پل و مدیریت پایداری پل‌های حاضر بسیار مهم است. شکل‌گیری چاله‌های آبستگی اطراف پایه‌های پل در بستر رودخانه‌ها، یک مسئله غیر قابل اجتناب است از این رو طراحی و ساخت پل‌ها نیازمند داشتن دقت لازم در تخمین حداکثر عمق آبستگی

دقت پایینی برخوردار بودند. از این رو مدل‌های مبتنی بر هوش مصنوعی به طور روز افزون به صورت یک راه حل ثانوی برای حل این مسئله دیده می‌شود. در این تحقیق نیز، با استفاده از داده‌های آزمایشگاهی، الگوریتمی مبتنی بر روش شبکه عصبی مصنوعی³ و سپس ترکیب و بهینه سازی آن با الگوریتم ژنتیک در تخمین عمق آبشستگی پایه‌های پل ارائه شده است.

2- نمایی کلی از الگوریتم پیشنهادی

در این پژوهش ابتدا بعد از جمع آوری داده‌ها، عملیات آنالیز ابعادی و بعد نرمال‌سازی بر روی داده‌ها انجام شده است. سپس جهت ارائه روش پیشنهادی، داده‌ها به دو دسته‌ی آموزش و صحت سنجی تقسیم می‌شوند. برای یادگیری از شبکه عصبی مصنوعی استفاده شده است. نتایج به دست آمده در مرحله‌ی اول نشان داد که به منظور افزایش دقت در خروجی و داده‌های تست نیاز به بهینه‌سازی مدل می‌باشد. از این رو از ترکیب شبکه عصبی پیشنهادی با الگوریتم ژنتیک استفاده شده است. در شکل 1، خلاصه‌ای از جریان کلی الگوریتم پیشنهادی آورده شده است.



شکل 1 عملکرد کلی الگوریتم پیشنهادی

است. در تحقیقی Mohammad (1995) تعدادی آزمایش فلوم برای مطالعه بر روی اثر تراکم، درصد رطوبت اولیه و میزان رس بر عمق آبشستگی انجام داد، او مشاهده کرد که برای خاک چسبنده اشباع، زمان رسیدن به حداکثر عمق آبشستگی خیلی بیشتر از خاک غیر اشباع است.

پژوهش‌های دیگری توسط Briaud (1999) و Ting (2001) انجام شد؛ آنها با استفاده از معادله‌ای که توسط وی و همکاران (1997) توسعه داده شده بود، حداکثر تنش برشی اطراف پایه را بر روی بستر صاف قبل از این که آبشستگی آغاز شود، محاسبه کرده و در نهایت نتیجه Hosny (1995) را تأیید کردند که نرخ آبشستگی در خاک‌های غیر چسبنده بزرگتر از خاک‌های چسبنده است. درباره اثر چسبندگی بر آبشستگی پایه به صورت آزمایشگاهی Ansari et al. (2002) نیز مطالعه کرده اند. آنها عمق آبشستگی تعادلی در خاک چسبنده را از طریق معادلات رگرسیونی بر حسب درصد آب، درصد رس و شاخص پلاستیسیته بدست آوردند.

برای تشخیص عمق آبشستگی پایه‌های پل در خاک‌های غیر چسبنده نیز، تحقیقی مبتنی بر هوش مصنوعی و شبکه عصبی انجام شده که در بهترین حالت به ضریب همبستگی 0/91 و میانگین مربعات خطای 0/18 در تشخیص رسیده است (Najafzadeh et al. 2013). تحقیقی دیگر Akib et al. (2014) از سیستم تطبیقی استنتاج فازی-عصبی¹ و رگرسیون خطی² برای پیش‌بینی عمق آبشستگی پل‌ها استفاده کرده‌اند. در جدیدترین تحقیقات انجام شده در این زمینه توسط Hoang et al. (2018) روش رگرسیون بردار پشتیبان را برای تخمین عمق آبشستگی اطراف پایه‌های مرکب بکار گرفته‌اند. نتایج به دست آمده از این روش شامل $R^2=0.85$ و $MAPE=0.216$ می‌باشد. همچنین Pandey et al. (2018) در پژوهش خود از روش الگوریتم ژنتیک و رگرسیون خطی چندگانه برای پیش‌بینی عمق آبشستگی زمانی، نزدیک پایه‌های دایره‌ای شکل استفاده کردند.

محققان در گذشته معادلاتی را برای تعیین عمق آبشستگی پایه پل در خاک‌های چسبنده ارائه دادند اما این معادلات از

¹ Adaptive neuro-fuzzy inference system (ANFIS)

² Liner regression

³ Artificial neural network (ANN)

برخی از توابع محرک مانند تابع محرک زیگموئید با این که در بازه $(-\infty, +\infty)$ قرار دارند، اما برد آن‌ها محدود به بازه $(0, 1)$ می‌شود. بنابراین باید بازه‌ی مقادیر ورودی و خروجی شبکه محدود به این بازه شود. این مهم، تنها به کمک عمل نرمال‌سازی داده‌ها میسر می‌گردد.

4- روش‌های استفاده شده


1-4- شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی، الگویی برای پردازش اطلاعات می‌باشند که با تقلید از شبکه‌های عصبی بیولوژیکی مثل مغز انسان ساخته شده‌اند. (حسینی آهنگر، 1388). نورون به عنوان یک پردازشگر، اساس عملکرد شبکه عصبی می‌باشد. ورودی p به نورون اعمال شده از طریق ضرب در وزن w ، وزن‌دار می‌شود با مقدار بایاس جمع شده و حاصل به تابع انتقال f به عنوان ورودی اعمال شده و خروجی نهایی حاصل می‌گردد. آرگومان n و خروجی نورون به صورت روابط (1) و (2) محاسبه می‌شود:

$$n = w * p + b \quad (1)$$

$$a = f(w * p + b) \quad (2)$$

بایاس یک پارامتر قابل تنظیم نورون‌ها می‌باشد و با توجه به مثبت یا منفی بودن می‌تواند اثر کاهشی یا افزایشی بر روی ورودی خالص داشته باشد (کیا، 1388). یک شبکه خاص، خود می‌تواند از چند لایه تشکیل شود، هر لایه در شبکه دارای ماتریس وزن‌ها، بردار بایاس و خروجی مختص به خود می‌باشد. شکل 2 نمایی از شبکه عصبی استفاده شده در این تحقیق می‌باشد.



شکل 2 نمایی از شبکه عصبی طراحی شده

3- مجموعه داده‌های مورد استفاده

مجموع داده‌های مورد نیاز برای پژوهش حاضر 95 داده می‌باشد که 12 داده از آزمایش‌های نجف زاده (1388)، 71 داده از پژوهش (Debnath et al. (2010) و 12 داده نیز از کار (Rambabu et al. (2003) بدست آمده است. مدل آزمایشگاهی نجف‌زاده (1388) شامل یک کانال بتنی به طول 22 متر و عرض 0/77 متر و ارتفاع 0/6 متر بود. سرعت متوسط جریان در فاصله 2 متری از بالادست پایه و از میانگین سرعت در اعماق 0/8 و 0/2 برابری عمق جریان بدست آمد. بستر رسی به طول 1/5 متر و ضخامت 15 سانتی‌متر در نظر گرفته شد.

Debnath, K. and Chaudhuri, S. (2010) آزمایش‌های خود را در فلومی به طول 18/3 متر و عرض 0/9 متر و عمق 0/9 متر انجام دادند. رسوبات در 10 متری ابتدای فلوم به عمق 0/25 متر و به طول 2/5 متر قرار داشت. سرعت متوسط جریان از میانگین سرعت در اعماق $0/2y$ و $0/8y$ بدست آمد. پایه از جنس پرسپکس و به قطر 12 سانتی‌متر بود. مصالح کف از ترکیب رسوبات چسبنده و ماسه نرم بدست آمد که قطر متوسط آن 0/182 میلی‌متر بود.

همچنین (Rambabu et al. (2003) از فلومی به طول 30 متر و عرض 2 متر و عمق 1/7 متر برای انجام آزمایش‌های خود استفاده کردند. خاک بستر از رس (44%)، سیلت (47%) و ماسه (9%) تشکیل شد. ضخامت بستر رسی 30 سانتی‌متر در نظر گرفته شد. قطر پایه استفاده شده در آزمایش‌ها 50، 90 و 110 میلی‌متر بود. به طور کلی مجموعه داده‌های مورد استفاده به دو دسته آموزش و صحت سنجی تقسیم می‌شود، که به ترتیب مقادیر 70% و 30% از کل مجموعه به صورت تصادفی انتخاب شده‌اند. لازم به ذکر است که پیش از استفاده از داده‌ها جهت معرفی به سیستم‌های هوشمند ذکر شده می‌بایست اعمالی چون کنترل، نرمال‌سازی، دسته بندی و بی‌بعدسازی روی داده‌ها انجام گیرد. این اعمال تحت عنوان پیش پردازش شناخته می‌شوند. در این تحقیق داده‌های نرمال شده از تقسیم داده مورد نظر بر اختلاف حداکثر و حداقل داده بدست می‌آید. لازم به ذکر است

ریشه میانگین مربعات خطا، شاخصی پرکاربرد جهت اندازه‌گیری اختلافات بین مقادیر پیش‌بینی شده یک متغیر توسط یک مدل و مقادیر واقعی مشاهده شده آن متغیر می‌باشد. میانگین قدر مطلق درصدی خطا، تفاوت نسبی بین مدل‌ها را به طور مؤثری منعکس می‌کند زیرا اندازه یا واحد مقادیر واقعی و پیش‌بینی شده، آن را تحت تأثیر قرار نمی‌دهد. ضریب همبستگی مطابق با رابطه (3) محاسبه می‌شود.

$$R = \frac{\sum_{i=1}^n (x_i^o - \bar{x}^o)(x_i^p - \bar{x}^p)}{\sqrt{\sum_{i=1}^n (x_i^o - \bar{x}^o)^2 \sum_{i=1}^n (x_i^p - \bar{x}^p)^2}} \quad (3)$$

ریشه میانگین مربعات خطا نیز مطابق با رابطه (4) و میانگین قدر مطلق درصدی خطا مطابق با رابطه (5) به دست می‌آید.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i^o - x_i^p)^2}{n}} \quad (4)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i^p - x_i^o}{x_i^o} \right| \quad (5)$$

در روابط فوق، x_i^o پارامتر مشاهده شده، x_i^p پارامتر پیش‌بینی شده و n تعداد داده‌ها است.

3-4- آنالیز ابعادی

همان‌طور که اشاره شد، عوامل مؤثر در پدیده آبشستگی شامل عوامل هیدرولیکی، ویژگی‌های سیال، عوامل هندسی و خصوصیات رسوب بستر در محل قرارگیری پایه پل می‌باشد. با توجه به نوع پارامترهای موجود از داده‌های آزمایشگاهی، رابطه 5 که در آن پارامترهایی چون d_{50} قطری که 50% ذرات از آن ریزتر هستند، D قطر پایه پل، U سرعت جریان آب در بالادست پایه پل، Y عمق جریان آب در بالادست، ρ چگالی جریان، μ ویسکوزیته دینامیکی سیال، g شتاب ثقل، IWC درصد رطوبت اولیه، C_p درصد رس، S مقاومت برشی خاک‌های چسبیده و d_s عمق آبشستگی پایه پل وجود دارند، به منظور برقرار نمودن مدل مورد استفاده قرار گرفته‌اند.

$$d_s = f(\rho, \mu, U, d_{50}, Y, g, D, IWC, C_p, S) \quad (6)$$

تئوری باکینگهام از جمله رایج‌ترین روش‌های آنالیز ابعادی جهت بی‌بعدسازی است. به منظور بی‌بعدسازی داده‌های موجود در رابطه‌ی 6 با استفاده از آنالیز ابعادی و انتخاب پارامترهای تکرار شونده ρ ، D و U رابطه (7) ارائه گردیده است.

محققان تاکنون الگوریتم‌های متنوعی برای آموزش شبکه‌های پرسپترون‌های چند لایه ارائه کرده‌اند، که ثابت شده است در مسائل تخمین تابع، دو الگوریتم لورنبرگ-مارکواردت و گرادیان توأم مقیاس شده¹ بهترین عملکرد را از خود نشان می‌دهند. در این تحقیق نظر به این که تعداد بردارهای ورودی نزدیک به صد بردار است روش لورنبرگ-مارکواردت به کار رفته است.

معادله‌های تجربی مختلف مقایسه شده در این تحقیق در جدول 1 ارائه شده است. در این معادلات پارامتر ρ_s همان ρ چگالی جریان و Fr عدد فرود جریان می‌باشد.

الگوریتم ژنتیک نیز روشی برای حل مسائل بهینه‌سازی می‌باشد که از طبیعت الهام گرفته شده و فرایندهای آن بر اساس تکامل زیستی انجام می‌شود. الگوریتم بهینه‌سازی ژنتیک به عنوان یکی از روش‌های الگوریتم تکاملی که بر مبنای روش‌های عددی تصادفی هستند در این جا برای بهینه‌سازی استفاده شده است.

2-4- شاخص‌های ارزیابی مدل‌ها

به منظور ارزیابی عملکرد مدل‌ها در این تحقیق، از سه شاخص آماری ضریب همبستگی² (R)، ریشه میانگین مربع خطا³ و میانگین قدر مطلق درصد خطا⁴ استفاده شده است. ضریب همبستگی، رابطه بین دو متغیر را تعیین می‌کند. هر چه مقدار این شاخص به 1+ نزدیک‌تر باشد، نشان‌دهنده قوی‌تر بودن رابطه مستقیم همبستگی بین متغیرهای مورد بررسی می‌باشد.

جدول 1 معادله‌های تجربی به کار برده شده در تخمین

آبشستگی	
معادله تجربی	محقق
$d_s/D = 0.0288 IWC^{1.14} (350/IWC^2 - Fr)^{0.6}$	(Hosny, 1995)
$d_s/D = 5565.05 (S/\rho_s g y)^{0.83} C_p Fr^{2.306}$	(نجف‌زاده, 1388)
$d_s/D = Fr^{0.641} R_{ep}^{0.64} (S/\rho_s g y)^{-0.976}$	Rambabu et al, 2003)

¹ Scaled Conjugate Gradient

² Correlation coefficient

³ Root Mean Square Error (RMSE)

⁴ Mean Absolute Percentage Error (MAPE)

ارزیابی شبکه عصبی برای تعیین تعداد بهینه نرون‌ها برای داده‌های خام آزمایشگاهی آورده شده است.

جدول 2 دستیابی به تعداد بهینه نرون‌ها در شبکه عصبی مصنوعی با استفاده از داده‌های خام آزمایشگاهی

تعداد نرون	مرحله	R	RMSE	MAPE
3	آموزش	0/94	1/5	0/14
	تست	0/91	2/7	0/19
5	آموزش	0/95	1/5	0/13
	تست	0/93	2/5	0/19
8	آموزش	0/95	1/5	0/13
	تست	0/93	2/5	0/18
9	آموزش	0/95	1/5	0/13
	تست	0/93	2/5	0/18

جدول 3 ارزیابی شبکه عصبی مصنوعی بازگشتی برای تعیین تعداد بهینه نرون‌ها بر روی داده‌های بی بعد آزمایشگاهی را نشان می‌دهد.

با توجه به جدول‌های 2 و 3 می‌توان به خوبی مشاهده کرد که افزایش تعداد نرون تا حدی می‌تواند مناسب باشد و از یک مقدار به بعد نه تنها تاثیری نداشته بلکه حتی در مواردی می‌تواند دقت را کاهش دهد.

بنابراین، در اینجا شبکه‌ای دو لایه با تعداد پنج نرون در لایه مخفی و یک نرون در لایه خروجی و تعداد چرخه-های آموزشی 1000 به عنوان بهترین شبکه انتخاب گردید چرا که ضریب همبستگی برای داده‌های خام به ترتیب برای مراحل آموزش و تست 95% و 93% و برای داده‌های بی‌بعد شده به ترتیب برای مراحل آموزش و تست 93% و 91% و معیارهای سنجش خطا نیز کمترین میزان در مجموعه مورد بررسی بودند. همچنین نمودار مقادیر پیش‌بینی شده و اندازه‌گیری شده این مدل‌ها برای داده‌های خام و بی‌بعد در مراحل آموزش و تست در شکل‌های 2 و 3 آورده شده است.

در این تحقیق نتایج پیش‌بینی شده توسط شبکه عصبی مصنوعی، با معادله‌های تجربی که تاکنون به کار برده شده نیز مقایسه شده است، این معادله‌های تجربی در جدول 1 برای ارزیابی عمق آبشستگی در خاک‌های چسبنده ارائه شده‌اند. مقایسه‌ای میان نتایج این تحقیق و نتایج Hosny

$$\frac{d_s}{D} = f\left(Re_p, \frac{d_{50}}{D}, Fr_p, \frac{Y}{D}, IWC, C_p, \frac{S}{\rho U^2}\right) \quad (7)$$

رابطه (7) در برگزیده پارامترهای بی‌بعد Rep عدد رینولدز پایه، $\frac{d_{50}}{D}$ اندازه بی بعد ذره، Fr_p عدد فرود پایه، $\frac{Y}{D}$ عمق نسبی جریان، IWC درصد رطوبت اولیه، C_p درصد رس، $\frac{S}{\rho U^2}$ مقاومت برشی بی‌بعد بستر می‌باشد. در انتها متغیر $\frac{d_s}{D}$ عمق بی‌بعد آبشستگی به عنوان خروجی شبکه محاسبه شد (Najafzadeh et al., 2013). اگر جریان اطراف پایه کاملاً آشفته باشد عدد رینولدز پایه، پارامتر مهمی نیست و معمولاً در مطالعه ی آبشستگی پایه مورد توجه قرار نمی‌گیرد (Najafzadeh et al., 2013). همچنین مجموعه داده‌های حاضر در $\frac{d_{50}}{D} < 50$ انجام شده‌اند و بر اساس بررسی‌های اتما (1980) و چو (1984)، عمق آبشستگی مستقل از اندازه رسوب است (Najafzadeh et al., 2013) که در رابطه (8) نشان داده شده است.

$$\frac{d_s}{D} = f\left(Fr_p, \frac{Y}{D}, IWC, C_p, \frac{S}{\rho U^2}\right) \quad (8)$$

انتخاب هر یک از پارامترهای ذکر شده به دلیل اهمیت و تأثیرشان بر عمق آبشستگی صورت پذیرفته است. عمق جریان در بالادست پایه‌ی پل به دلیل دخیل بودن آن در میزان فشار، شکل و نیروهای اینرسی حائز اهمیت است. عدد فرود، منعکس کننده تأثیرات نیروی اینرسی و نیروی ناشی از جرم می‌باشد. قطر پایه پل نیز از عوامل مهم در نیروهای فعال بالا برنده و جلو برنده وارده بر پایه پل است و همچنین از عوامل تأثیرگذار در معادله ممنتوم در مجاورت پایه پل می‌باشد (Oliveto et al., 2002).

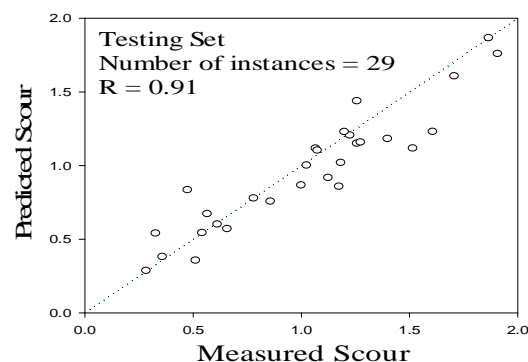

5- الگوریتم پیشنهادی

5-1- طراحی معماری شبکه عصبی مصنوعی

شبکه‌ی عصبی پرسپترون از جمله پرکاربردترین انواع شبکه‌های عصبی می‌باشند. در این تحقیق نیز از این نوع شبکه استفاده شد، به طوری که در لایه پنهان از تابع log-sig و در لایه خروجی از تابع خطی استفاده شد. الگوریتم آموزشی مورد استفاده لونیگ -مارکوات¹ می‌باشد که با استفاده از روش بیزین² از بیش برآزش آن در فرایند آموزش شبکه، جلوگیری می‌کند. در جدول 2

¹ Levenberg-Marquardt

² Bayesian



شکل 3 نتایج مدل شبکه عصبی برای داده‌های بی بعد

از عملکرد این روش‌ها می‌توان دریافت که Rambabu (2003) عمق آبشستگی را با خطای بالایی پیش‌بینی کرده است. این معادله فقط دو پارامتر مهم مقاومت برشی و عدد فرود در خاک‌های چسبنده را شامل می‌شود. به عبارت دیگر عدد رینولدز، نقش کمی را در شرایط کاملاً آشفته دارد. همچنین می‌توان دریافت که مدل ارائه شده در مقایسه با معادلات تجربی، پیش‌بینی‌های بهتری داشته است و مقادیر خطای آن به صورت قابل توجهی از دیگر روش‌ها کمتر است.

5-2- بهبود نتایج با استفاده از الگوریتم ژنتیک

برای بهبود نتایج شبکه عصبی مصنوعی، بهینه‌سازی مقادیر وزن و بایاس با استفاده از الگوریتم ژنتیک انجام شد. برای این منظور در مرحله اول نرخ ترکیب، نرخ جهش و تعداد جمعیت را در هر نسل برای الگوریتم ژنتیک به ترتیب 0/8، 0/2 و 30 در نظر گرفته شده است. در الگوریتم ژنتیک پارامترهای نرخ ترکیب و نرخ جهش نقش مهمی در نتایج دارد. برای این منظور مقدار بهینه این پارامترها با روش آزمون و خطا بدست می‌آید. در



(1995)، (2003) Rambabu et al. و نجف‌زاده (1388)، در جدول 4 آورده شده است. مقایسه بر اساس دو معیار RMSE و R انجام می‌باشد.

جدول 3 دستیابی به تعداد بهینه نورون‌ها در شبکه عصبی مصنوعی با استفاده از داده‌های بی بعد آزمایشگاهی

تعداد نورون	مرحله	R	RMSE	MAPE
3	آموزش	0/89	0/17	0/19
	تست	0/92	0/21	0/17
5	آموزش	0/93	0/14	0/15
	تست	0/91	0/22	0/19
8	آموزش	0/93	0/14	0/15
	تست	0/91	0/22	0/19
9	آموزش	0/93	0/14	0/15
	تست	0/91	0/22	0/19

جدول 4 مقایسه عملکرد روش‌های هوشمند و معادلات تجربی در تعیین آبشستگی خاک‌های چسبنده

روش	منبع	R	RMSE
شبکه عصبی	تحقیق حاضر	0/91	0/17
معادله تجربی	(Hosny, 1995)	0/6	0/67
معادله تجربی	(نجف‌زاده، 1388)	0/68	0/8
معادله تجربی	(Rambabu et al, 2003)	0/86	67/3



شکل 2 نتایج مدل شبکه عصبی برای داده‌های خام

جدول 5 پارامترها نشان داده شده است. که با توجه به نتایج بدست آمده مقادیر بهینه برای پارامترهای نرخ ترکیب و نرخ جهش به ترتیب برابر 0/8 و 0/5 خواهد بود که دارای کمترین میزان خطا می باشد. همان طور که مشاهده می شود با زیاد کردن احتمال جهش، تنوع نیز زیاد شده یعنی احتمال تغییرات تصادفی در کروموزومها افزایش پیدا کرده و جمعیت می تواند نماینده بخشی از فضا باشد. این کار باعث می شود که افراد جمعیت کمتر در نقاط محلی گرفتار شده و امکان پرش به نقاط دیگر نیز افزایش یابد. در جدول 6 مقادیر خطا و ضریب همبستگی برای بهترین مدل، آمده است.

جدول 5 تعیین پارامترهای الگوریتم ژنتیک

تعداد کل نسل ها	RMSE (test)	نرخ جهش	نرخ ترکیب
33	0/121	0/3	0/9
50	0/112	0/4	0/8
50	0/107	0/5	0/8

جدول 6 مقادیر خطا و ضریب همبستگی برای بهترین مدل

مرحله	R	RMSE	MAPE
آموزش	0/978	0/088	0/085
تست	0/972	0/107	0/086
کل	0/976	0/094	0/085

جدول 6 مقادیر خطا و ضریب همبستگی برای بهترین مدل

مرحله	R	RMSE	MAPE
آموزش	0/978	0/088	0/085
تست	0/972	0/107	0/086
کل	0/976	0/094	0/085

7- فهرست علائم

C_p	درصد رس
D	قطر پایه پل
d_s	عمق آبستنگی پایه پل
Fr_p	عدد فرود پایه
g	شتاب ثقل
IWC	درصد رطوبت اولیه
MAPE	میانگین قدر مطلق درصد خطا
n	تعداد داده ها
Re_p	عدد رینولدز پایه
RMSE	ریشه میانگین مربع خطا
S	مقاومت برشی خاک های چسبنده
U	سرعت جریان آب در بالادست پایه پل
Y	عمق جریان آب در بالادست،
x_i^o	پارامتر مشاهده شده
x_i^p	پارامتر پیش بینی شده
μ	ویسکوزیته دینامیکی سیال
ρ	چگالی جریان

6- نتیجه گیری

در این تحقیق، قابلیت پیش بینی روش شبکه عصبی مصنوعی در تخمین حداکثر عمق آبستنگی پایه پل در خاک های چسبنده مورد ارزیابی قرار گرفت. بدین منظور از مجموعه ای از داده های آزمایشگاهی که از آزمایش های نجف زاده (1388)، (2010) Deb Nath و Rambabu et al. (2003) بدست آمده بود، استفاده شد. شبکه عصبی مورد استفاده در این تحقیق از نوع شبکه های پرسپترون بود که وزن های آن به کمک قاعده پس انتشار خطا بدست آمد. الگوریتم آموزشی مورد استفاده لونیبرگ-مارکوارت می باشد. برای داده های بی بعد، ضریب همبستگی 0/92 و ریشه میانگین مربعات خطا، 0/16 بدست آمد. همچنین برای داده های با بعد، ضریب همبستگی 0/94 و ریشه

scour around circular bridge piers in cohesive soils. Ph.D. Thesis, Civil engineering department, Colorado state university, Colorado, USA.

Kattel, J., and Eriksson, M. (1998). "Bridge scour evaluation screening, analysis, and countermeasures". Pub. Rep. No 9877, USDA forest service, Washington, DC.

Lagasse, P. F. and Richardson, E. V. (2001). "ASCE compendium of stream stability and bridge scour papers". Journal of hydraulic engineering, ASCE, 127 (7):531-533.

Mohamed, M. H. (1995). *Experimental study of local scour around circular bridge piers in cohesive soils*. Ph.D. Dissertation, Civil engineering department, Colorado state university, Colorado, USA.

Najafzadeh, M., Barani, Gh. A., Azamathulla, H. M. (2013). "GMDH to predict scour depth around a pier in cohesive soils". Ocean research, 40:35-41.

Oliveto, G. and Hager, W. H. (2002). "Temporal evolution of clear water pier and abutment scour. Journal of hydraulic engineering", ASCE, 128 (9):811-820.

Pandey, M., Zakwan, M., Sharma, P. K., and Ahmad, Z. (2018). "Multiple linear regression and genetic algorithm approaches to predict temporal scour depth near circular pier in non-cohesive sediment". ISH Journal of Hydraulic Engineering, 1-8.

Rambabu, M., Narasimha Rao, S. and Sunder, V. (2003). "Current-induced scour around a vertical pile in cohesive soil. Ocean Engineering", 30(4):893-920.

Ting, F. C. K., Briaud, J. L., Chen, H. C., Gudavalli, R. and Perugu, S. (2001). "Flume test for scour in Clay at circular pier". Journal of Hydraulic engineering, ASCE, 127(11):969-978.

Wardhana, K. and Hadipriono, F. C. (2003). "Analysis of recent bridge failures in the United States". Journal of performance of constructed facilities, ASCE, 17 (3):144-150.

8- منابع

حسنی آهنگر، م. ر. و کنگاوری، م. ر. (1388)، *اصول و مبانی هوش مصنوعی*، انتشارات دانشگاه امام حسین (ع)، تهران، ایران.

کیا، م. (1394)، *شبکه‌های عصبی در MATLAB*، انتشارات کیان رایان سبز، تهران، ایران.

منهاج، م. ب. (1392)، *مبانی شبکه‌های عصبی هوش محاسباتی*، جلد اول، انتشارات دانشگاه صنعتی امیرکبیر، تهران، ایران.

نجف‌زاده، م. (1388)، *مطالعه آزمایشگاهی و شبیه‌سازی آبشستگی موضعی پایه پل در بستر خاک‌های چسبنده*، پایان‌نامه کارشناسی ارشد، دانشگاه شهید باهنر کرمان، ص. 110.

Ansari, S. A., Kothyari, U.C., and RangaRaju, K.G. (2002). "Influence of cohesion on scour around bridge piers". Journal of hydraulic research, 40(6): 717-729.

Akib, S., Mohammadhassani, M. and Jahangirzadeh, A. (2014). "Application of ANFIS and LR in prediction of scour depth in bridges". Computers & Fluids, 91(2): 77-86.

Briaud, J. L., Ting, F. C. K., Chen, H. C., Gudavalli, R., Perigu, S., and Wei, G. (1999). "SRICOS: Prediction of scour rate in cohesive soils at bridge piers". Journal of Geotechnical engineering, ASCE, 125(4):237-246.

Debnath, K. and Chaudhuri, S. (2010). "Bridge pier scour in Clay -sand mixed sediments at near-threshold velocity for sand". Journal of hydraulic engineering, ASCE, 136 (9):597-609.

Hoang, N. D., Liao, K. W., Tran, X. L (2018). "Estimation of scour depth at bridges with complex pier foundations using support vector regression integrated with feature selection". Journal of Civil Structural Health Monitoring, 8(3), 431-442.

Hosny, M. (1995). *Experimental study of local*

« Research Note »

Application of artificial neural networks in estimation of scour depth around the bridge pier with sticky sediments**Rahim Rezazadeh¹, Gholamabbas Barani² and Amineh Naseri^{3*}**

1- MSc. Student, Faculty of Civil Engineering, Sirjan University of Technology, Sirjan, Iran

2- Professor, Faculty of Civil Engineering, Shahid Bahonar University, Kerman, Iran

3- Instructor, Faculty of Computer Engineering and Information Technology, Sirjan University of Technology, Sirjan, Iran

* naseri.amine@sirjantech.ac.ir**Abstract**

Most of the bridges breakdown is due to scour around the foundation of bridge during the floodwater. Accordingly, an improved model is needed to estimate the depth of scour around the bridge pier, for minimizing the possibility of failure. Since the scour in the bridge pier is a complex function of floor materials specification, fluid characteristics, flow specification and basic geometry, thus experimental equations cannot estimate the scour depth accurately. In this paper, artificial intelligence approaches have been used to estimate scour depth. In order to evaluate the performance of the mentioned method, laboratory data has been used in two cases with dimension and dimensionless data. First, an appropriate artificial neural network model is proposed and then optimized using the genetic algorithm. The mean correlation coefficient for dimensionless data were 0.97 at the testing stage. In this model, the neural network optimized by genetic algorithm, the root mean square error value, is 0.094. The results show that the recursive artificial neural network and genetic algorithm has a much better performance in estimation of scour depth around the bridge pier in substrate with sticky sediments in comparison to experimental equations.

Keywords: Pier bridge scour, Sticky sediment, Artificial neural network, Genetic Algorithm.