



بررسی کارائی شبکه های عصبی مصنوعی در پیش بینی عمق آبشستگی پایه های پل و مقایسه نتایج با مدل های ریاضی معتبر

سیمین شهزادفر¹، نعیمه ابوالواسط²، یوسف حسن زاده³
1، 2 و 3-دانشگاه تبریز-دانشکده فنی مهندسی عمران-گروه آب

Simin_shahradfar3000@yahoo.com

چکیده

پل ها از جمله مهمترین و حیاتی ترین سازه های ارتباطی هستند که از دیرباز مورد استفاده قرار می گیرند. آبشستگی پایه های پل یکی از مهم ترین عوامل تهدید کننده پایداری پل های احداث شده بر روی رودخانه ها می باشد. منشا آبشستگی موضعی در واقع نوعی فرسایش در اطراف پایه پل ها است که در نتیجه جریان های گردابی برخاستگی و جریان نعل اسبی می باشد. به دلیل پیچیدگی فرایند آبشستگی و نامعلوم بودن جزئیات و عملکرد گردابه های تشکیل یافته در اطراف پایه های پل، روابط گوناگونی برای برآورد حداکثر عمق حفزه آبشستگی ارائه شده است که عمدتاً آزمایشگاهی و بعضاً نیمه تئوری و یا صحرایی هستند. در عصر حاضر، استفاده از شبکه های عصبی مصنوعی (Artificial Neural Networks) به دلیل ساختار ریاضی کاملاً غیر خطی می تواند جایگزین مناسبی برای مدل های دیگر باشد. در این مقاله با استفاده از آمار واقعی نتایج بدست آمده از 3 رابطه معتبر برای محاسبه عمق آبشستگی (CSU)، ملویل و سادرلند، لارسن و توچ) با نتایج یک مدل شبکه عصبی مصنوعی بهینه و مقادیر مشاهداتی مقایسه شده است. برای مقایسه از توابع هدف MAE، RMSE و R² استفاده شد. نتایج تحقیق حاکی از آن است که ANN از سرعت عمل و دقت قابل قبولی برخوردار بوده و نتایج بهتری نسبت به سایر مدل ها ارائه می دهد.

واژه های کلیدی: پایه پل، عمق آبشستگی، شبکه عصبی مصنوعی، معادلات آبشستگی، داده های صحرایی

مقدمه

علت تخریب اکثر پل ها در جهان آبشستگی بیش از حد پایه ها و دیوارهای حائل می باشد. بعنوان مثال، در سیلاب بهاری سال 1987، 17 پل در نیویورک بعلت آبشستگی آسیب دید یا تخریب شد. در سال 1985، سیلاب در پنسیلوانیا، ویرجینیا 73 پل را منهدم کرد. بر طبق گزارش سازمان راه آمریکا [1]، 383 پل در آمریکا در سال 1973 تخریب شده است [2]. تعیین دقیق عمق آبشستگی پایه ها، در طراحی مطمئن پل ضروری است زیرا تخمین کم عمق آبشستگی ممکن است منجر به تخریب پل و تخمین زیاد منجر به هزینه های اضافی گردد. در چند دهه اخیر تحقیقات زیادی برای یافتن روابط معتبر جهت تخمین حداکثر عمق آبشستگی در اطراف پایه های پل صورت گرفته است. در نتیجه این تحقیقات تا کنون روابط مختلفی توسط محققین برای پیش بینی حداکثر عمق آبشستگی موضعی اطراف پایه های پل ارائه گردیده است. مشکل اصلی این روابط این است که معادلات موجود بر اساس داده های آزمایشگاهی بوده و نمونه واقعی را با دقت کافی تخمین نمی زنند. از این رو معمولاً نتایج محافظه کارانه و بیش از مقدار واقعی ارائه می دهند. از جمله این روابط می توان به لارسن و توچ (Laursen and Toch) (1956)، شن (Shen) (1971)، هانس (Hancu) (1971)، بروزرز (Breusers) (1977)، ملویل و سادرلند (Melville and Sutherland) (1988)، جانسن (Janssen) (1992)، US DOT (1993)، ملویل و چاو (Melville and Chiew) (1999) اشاره کرد. گرچه تحقیقات زیادی در این زمینه صورت گرفته است ولی بررسی مقالات موجود نشان دهنده کمبود روابط معتبر برای پیش بینی میزان عمق آبشستگی که جوابگوی محدوده های مختلف باشد، است. نتایج بدست آمده از روابط موجود با هم اختلافات زیادی دارند. بنابراین در طراحی بیشترین مقدار در نظر گرفته می شود.

¹ دانشجوی کارشناسی ارشد عمران-سازه های هیدرولیکی

² دانشجوی کارشناسی ارشد عمران-آب

³ استاد گروه عمران آب دانشگاه تبریز



در واقع هر رابطه برای داده های بخصوص بهتر عمل می کند. به همین دلیل تحقیقات زیادی برای کشف روشهای جدید و اصلاح روابط موجود صورت می گیرد. با توجه به تواناییهای شبکه های عصبی مصنوعی (Artificial Neural Networks) در شناسایی ارتباط بین متغیرهای ورودی و خروجی یک مساله و کارکرد خوب آن حتی در مواقعی که داده های یادگیری همراه با نویز یا خطا در اندازه گیری باشند، شبکه عصبی مصنوعی می تواند به عنوان یک راهکار مناسب در محاسبه عمق آبشستگی بکاررود و مشکل تنوع و اختلاف در روابط مختلف را که بر اساس مدل‌های فیزیکی ایجاد شده اند، حل کند. این شبکه ها برای اولین بار از فرموله کردن توانایی های مغز انسان توسط مک کالچ و پیتس در سال 1943 ایجاد شدند. این مدلها نه تنها برای مطالعه پدیده های موجود، بلکه برای پیش بینی آنها در زمانهای متفاوت نیز بکار می روند [3]. ANN بطور گسترده در زمینه های مختلف هیدرولیکی و مهندسی منابع آب بکار رفته است. (سولداتی (Soldati) و همکاران در سال 2000، جین (Jain) در سال 2001، لیریانو و دی (Liriano and Day) در سال 2001، لی و گو (Li and Gu) در سال 2003، ییتیان و گو (Yitian and Gu) در سال 2003 و اگروال (Agarwal) در سال 2005). در این مقاله هدف، بررسی عملکرد مدل شبکه عصبی مصنوعی در پیش بینی عمق آبشستگی پایه های پل می باشد که با نتایج بدست آمده از 3 رابطه معتبر و آمار واقعی مقایسه گردیده است.

مواد و روش ها

معادلات آبشستگی پایه پل

تقریباً تمام فرمولهای آبشستگی موضعی بر اساس داده های آزمایشگاهی بدست آمده اند. با این وجود، این روابط معمولاً بوسیله مهندسی عمران برای محاسبه عمق آبشستگی موضعی در طراحی پل های جدید یا پل های موجود که تحت آبشستگی قرار گرفته اند، بکار می رود. از آن رو بررسی دقت این روابط بر اساس داده های واقعی ضروری است. در این مقاله 3 رابطه که در مقالات دیگر کارائی آنها به اثبات رسیده است [2] با استفاده از آمار واقعی که از سایت اینترنتی سازمان نقشه برداری آمریکا (<http://water.usgs.gov>) جمع آوری شده است، مورد بررسی قرار گرفته اند.

1. رابطه CSU

این رابطه یکی از روابط گروه مهندسی ارتش آمریکا است که در نرم افزار Hec-18 به کار گرفته شده و توسط دانشگاه کلرادو توصیه شده است (Colorado state university).

$$ds/y=2.0K_1K_2(b/y)^{0.65}Fr_1^{0.43} \quad (1)$$

در این رابطه ds عمق آبشستگی و y عمق جریان در بالادست پایه می باشد. K_1 ضریبی که به شکل نوک پایه بستگی دارد و K_2 ضریبی است که به نسبت طول پایه به عرض آن و زاویه نزدیک شدن جریان به پایه پل بستگی دارد. ضرایب K_1 و K_2 از جدول (1) بدست می آیند.

جدول 1: مقادیر K_1 و K_2 برای انواع مختلف پایه ها

K_2			زاویه برخورد جریان (درجه)	K_1	نوع پایه
$L/b=12$	$L/b=8$	$L/b=4$			
1.0	1.0	1.0	0	1.1	با نوک مربعی
2.5	2.0	1.5	15	1.0	با نوک گرد
3.0	2.5	2.0	30	1.0	ره ای استوانه ای-دا
4.3	3.3	2.3	45	0.9	با نوک تیز
5.0	3.9	2.5	90	1.0	گروه استوانه ای

2. رابطه لارسن و توچ (Laursen and Toch) [4]

$$ds=1.35 b^{0.7} y^{0.3} \quad (2)$$

که در آن ds حداکثر عمق آبشستگی موضعی، b عرض پایه پل و y عمق جریان است.

3. رابطه ملویل و سادرلند (Melville and Sutherland) [5]


$$ds=K_1 K_d K_y K_a K_s b \quad (3)$$

که در آن K_1 ضریب شدت جریان، K_d ضریب اندازه ذرات رسوب، K_y ضریب عمق جریان، K_a ضریب قرار گیری پایه ها و K_s ضریب شکل پایه ها می باشد. ds و b قبلاً تعریف شده اند.

شبکه عصبی مصنوعی

تئوری ریاضی شبکه عصبی مصنوعی

شبکه عصبی مصنوعی در واقع مدل ساده شده ای از مغز انسان می باشد. این شبکه یک ساختار ریاضی است که توانایی نشان دادن فرایندها و ترکیبات دلخواه غیر خطی جهت ارتباط بین ورودیها و خروجیهای هر سیستمی را داراست. شبکه عصبی از سلول های عصبی به نام نرون (Neuron) تشکیل یافته است. نرون های شبکه عصبی مصنوعی در حقیقت شکل بسیار ساده ای از نرون های بیولوژیکی هستند. شکل (1) شمای ساده ای از مدل یک شبکه عصبی را نشان می دهد.



شکل شماره 1. ساختار یک شبکه عصبی مصنوعی

یک شبکه تیپیک معمولاً از لایه ورودی، لایه میانی (مخفی) و لایه خروجی تشکیل شده است (شکل 1). لایه ورودی که یک لایه انتقال دهنده و وسیله ای برای تهیه کردن داده ها می باشد. آخرین لایه یا لایه خروجی شامل مقادیر پیش بینی شده بوسیله شبکه می باشد و بنابراین خروجی مدل را معرفی می کند و لایه های میانی یا مخفی که از نودهای پردازشگر تشکیل شده اند، محل پردازش داده هاست. شمار لایه های مخفی و شمار گره ها در هر لایه مخفی به طور معمول بوسیله روش آزمون و خطا مشخص می شود. گره های لایه های مجاور در شبکه به طور کامل در ارتباط هستند. هر گره از لحاظ ساختاری خود دارای ورودیها، آستانه (Threshold) و خروجی می باشد که خروجی هر نرون به تمامی نرون های لایه بعد منتقل می شود. عملیاتی که در هر نرون صورت می گیرد بدین ترتیب است که 1- نرون تمامی ورودیهای را که به سلول رسیده است جمع می کند. 2- مقدار آستانه ای نرون را از آن کم می کند. 3- آنرا از یک تابع محرک یا تابع فعالیت عبور می دهد. 4- در نهایت خروجی نرون بدست می آید. طی فرآیند آموزشی این وزنها و مقادیر ثابتی که با آنها جمع می شود که اصطلاحاً بایاس (Bias) نامیده می شود، بطور پی در پی تغییر می کنند تا اینکه خطا به کمترین مقدار خود برسد. برای انتقال خروجیهای هر لایه به لایه های بعدی از توابع محرک استفاده می شود. از توابع محرک می توان توابع سیگموئیدی، خطی و آستانه ای را نام برد [6]. بطور کلی شبکه های عصبی مصنوعی به دو گروه تقسیم بندی می شوند که عبارتند از شبکه های پیش خور (Feed Forward) و شبکه های پس خور (Feed Backward). شبکه های پیش رو به جز در مواردی که الگوریتم انتشار خطا به عقب (Back Propagation) جوابگوی مدل مورد نظر نباشد، به طور موفقیت آمیزی در بسیاری از مسائل مختلف به کار برده می شوند. یکی از انواع مهم شبکه های پیش رو شبکه های پرسپترون چند لایه (Multi-Layer Perception Network) هستند که شامل یک لایه ورودی و یک یا چند لایه مخفی از گره های محاسباتی و یک لایه خروجی می باشند. سیگنال ورودی در این شبکه ها تنها به سمت جلو گسترش می یابد.

الگوریتم های مختلف آموزشی

برای آموزش شبکه الگوریتم های مختلفی می تواند به کار رود. در این تحقیق دو الگوریتم مختلف به منظور شناسایی بهترین روش با بالاترین بازده برای آموزش شبکه به کار می رود:

گرادیان نزولی انتشار خطا به عقب با ممنتوم (GDx)

Gradient Descent back propagation with momentum

در این روش از الگوریتم انتشارخطا به سمت عقب برای محاسبه خطای شبکه و تعیین بردار وزنی و بایاس (حد بحرانی) شبکه به طوری که شبکه دارای کمترین خطا باشد، استفاده می شود. پارامتر ممنتوم نوعی اینرسی حرکتی برای تغییر وزن ها ایجاد می کند که سبب می شود با تعداد نمونه های کمتر و در زمان کمتری سیستم به مرحله همگرایی برسد. اگر داده های مورد استفاده خطای عددی کمی داشته باشند، می توان از ممنتوم بالا استفاده کرد. اما در سیستم های غیر دقیق باید این میزان را کم انتخاب کرد.

الگوریتم لوبنبرگ - مارکواردت (LM) Levenberg-Marquardt

این روش تغییر یافته الگوریتم کلاسیک نیوتن است که برای پیدا کردن راه حلی مناسب برای مسائلی که نیاز به کمینه سازی دارند به کار می رود. این روش یک تقریب برای ماتریس هیزن (Hessian) در تغییر وزن ها مثل روش نیوتن در نظر می گیرد.



$$X_{k+1} = X_k - [J^T J + \mu I]^{-1} J^T + e \quad (4)$$

در رابطه فوق، X وزنهای شبکه عصبی، J ژاکوبین ماتریس معیار اجرای شبکه که باید حداقل شود، μ عددیست که فرایند آموزش را کنترل می کند و e بردار خطای باقیمانده است. وقتی μ صفر باشد، معادله فوق همان روش نیوتن است که از روش هیزن استفاده می کند ولی وقتی μ مقداری بزرگ باشد معادله تبدیل به یک رابطه کاهش گرادیان با فاصله زمانی کم می شود. روش نیوتن از سرعت بالایی برخوردار است و نتایج آن بسیار نزدیک به مینیمم خطا خواهد بود.

طراحی شبکه

ساختار شبکه با آزمون و خطا مشخص می شود و اندازه ورودی و لایه مخفی شبکه متغیر است و تنها به افق پیش بینی بستگی دارد. نکته مهم در مورد تعداد لایه های مخفی و تعداد نرون ها این است که تعداد نرون های لایه ورودی و خروجی باید برابر با تعداد پارامترهای ورودی و خروجی باشند ولی تعداد لایه های مخفی و تعداد نرون های آن ها بصورت تجربی تعیین می شوند. اگر تعداد لایه های مخفی و یا تعداد نرون های آنها کمتر از مقدار مشخصی باشد ممکن است مراحل آموزش شبکه بصورت کامل انجام نگیرد. به این حالت برازش ناقص می گویند. در مقابل اگر تعداد نرون ها و لایه های پنهان بیش از حد لازم باشد، حالت بیش برازش (over training) رخ می دهد. در هر حال میتوان تعداد مناسب نرون ها و لایه های مخفی را با استفاده از عملکرد شبکه از طریق سری های آموزش و آزمایش بدست آورد.

آموزش شبکه

هر شبکه برای بوجود آمدن و قابل قبول بودن به سه سری داده نیازمند است: سری آموزشی، صحت سنجی و آزمون. برای اینکه شبکه عصبی مصنوعی بتواند خروجی را تا حد امکان نزدیک به بردار هدف کند به فرایند آموزش نیاز دارد. آموزش عبارت است از پیدا کردن مناسبترین بردار وزنی w و بردار $bias$ و مینیمایز کردن تابع خطای از پیش تعیین شده. بعد از اینکه آموزش پایان یافت، شبکه برای دادن جوابهای منطقی به داده های جدید توانا می شود. در صورت تعیین توابع تبدیلگر مناسب، تهیه داده هایی با دقت بالا و شبکه ای کارآمد، معمولاً آموزش این مدلها به مناسبترین نحو صورت می گیرد.

صحت سنجی

پس از آموزش شبکه مرحله صحت سنجی صورت می گیرد. در این مرحله مدل بوسیله داده هایی که در مرحله آموزش شرکت نداشته اند اجرا می شود. خروجی های مدل در این مرحله با مقادیر مشاهداتی مقایسه شده و دقت مدل به دست می آید. در صورتی که دقت مدل پایین باشد ممکن است تا سه بار مراحل آموزش و صحت سنجی تکرار شود تا مدل به نتیجه مطلوب برسد. بهترین شکل مدل، حالتی است که سیستم در مقابل داده های این مرحله رفتاری شبیه مرحله آموزش داشته باشد که این مرحله را تعمیم (Generalization) گویند. مرحله آزمون برای کنترل نهایی مدل انجام می شود.

توابع هدف

به منظور ارزیابی کارایی هر شبکه و توانایی آن برای پیشگویی دقیق و همچنین کارایی روابط بررسی شده معیارهای مختلفی می تواند مورد استفاده قرار می گیرد. در این تحقیق از 3 تابع هدف میانگین مطلق خطا (MAE)، ریشه مربع متوسط خطا (RMSE) و ضریب تبیین R^2 استفاده شده است.

نتایج و بحث

پارامترهای زیادی در میزان عمق ابستگی پایه های پل موثر است. در این تحقیق پارامترهای عمق جریان (Y)، سرعت نزدیک شدن جریان به پایه (V)، عرض پایه (b)، قطر متوسط ذرات بستر (D_{50}) و میزان بار رسوبات کف به عنوان ورودی و عمق آبستگی پایه پل (ds) به عنوان خروجی مدل در نظر گرفته شد. با توجه به اینکه اکثر پایه های پل در جهان به شکل دایره ای (circular) هستند، در این تحقیق این نوع پایه ها مورد بررسی قرار گرفته اند. به علت عدم وجود داده های کافی در زمینه عمق آبستگی پایه های پل در کشور به ناچار آمار مورد نیاز از سایت اینترنتی سازمان نقشه برداری آمریکا (<http://water.usgs.gov>) که مربوط به یک ایالت در آمریکا است، تهیه شده است.

تعیین تعداد نرون ها و لایه های مخفی مهمترین مرحله در طراحی می باشد. باهر (Baheer) [7] و هک نیلسون (Hect-Neilsen) [8] نشان دادند که یک لایه پنهان برای بیشتر مسائل کافی است. لیپمن (lippmann) [9] و راملهارت (Rumelhart) [10] نیز نشان دادند که استفاده بیش از یک لایه پنهان بندرت می تواند موثر واقع گردد. به همین علت یک لایه پنهان در این مقاله مورد استفاده قرار گرفت. انتخاب تعداد نرون های لایه پنهان می تواند از طریق سعی و خطا صورت گیرد به نحوی که شبکه دارای کمترین خطا گردد. در بیشتر موارد افزایش تعداد نودهای میانی تا مقدار بهینه خود، باعث کاهش خطای مدل در مرحله آموزش می شود، اما در صورتی که از این میزان افزایش یابد باعث ایجاد overtraining در مرحله آموزش می شود. بنابراین تاثیر افزایش نودهای میانی برای صحت سنجی کاملاً محسوس خواهد بود [11]. در این مدلها صحت سنجی باعث تشخیص آموزش



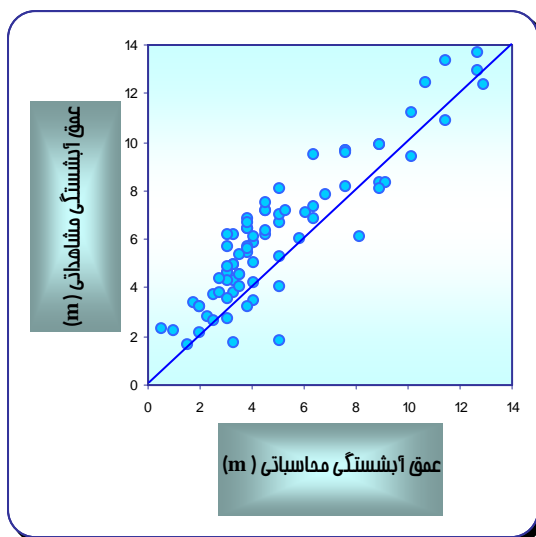
زیاد می شود و می توان به سه روش زیر از آن جلوگیری کرد: الف) افزایش تعداد و محدوده داده های آموزشی ب) تقسیم بندی صحیح داده های آموزشی ج) تعیین تعداد بهینه نودهای پردازشگر. در بیشتر موارد داده های ورودی شبکه باید نورمالیزه شوند [12]. تعداد چرخه های آموزش (Epoch) نیز عاملی است که می تواند در انتخاب مدل بهینه تاثیر گذار باشد. عامل مهم دیگر نحوه دسته بندی داده ها برای مراحل آموزش، صحت سنجی و آزمون می باشد. به همین منظور مسر و کیتلر (Messer and Kittler) [13] پیشنهاد کردند که برای بدست آوردن نتیجه بهتر، تعداد داده های مرحله آموزش باید حداقل 5-10 بار تست شود. نلسن و ایلینگورس (Nelson and Illingworth) [14] 20 تا 30 درصد از داده ها را برای مرحله آزمون توصیه کردند. در این مقاله برای تعیین این دسته بندی، آموزش چندین بار با 40، 50، 60 و 70 درصد داده ها صورت گرفت که بهترین آموزش به وسیله 60 درصد از داده ها انجام شد. 20 درصد داده ها نیز برای صحت سنجی و 20 درصد باقیمانده برای مرحله آزمون در نظر گرفته شد. برای تهیه مدل ANN از نرم افزار MATLAB (version 7) استفاده شده است.

در این مقاله با استفاده از آمار واقعی نتایج پیش بینی عمق آبشستگی 3 رابطه csu، لارسن و توج، ملویل و سادرلند محاسبه شد. سپس برای بدست آوردن یک مدل شبکه عصبی مصنوعی (ANN) بهینه، شبکه چندین بار با تغییر مدل، Epoch، الگوریتم آموزشی، نرون های لایه میانی و نحوه دسته بندی داده ها و پارامترهای ورودی مورد بررسی قرار گرفت. از بین الگوریتم های مختلف، الگوریتم LM به علت اینکه یک روش کاهش گرادینان با فاصله زمانی کم بوده و از سرعت همگرایی بالایی برخوردار می باشد و همچنین نتایجی نزدیک به مینیمم خطا را نسبت به الگوریتم GDX ارائه می دهد، از مقبولیت بالایی برخوردار است.

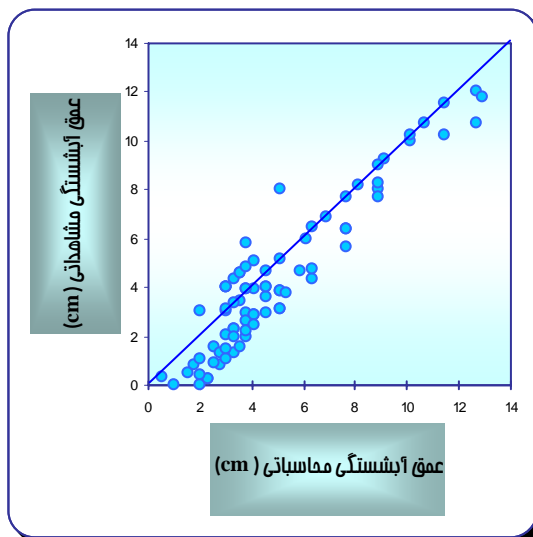
نتایج مدل های مختلف شبکه با توابع هدف MAE، RMSE و R^2 مورد بررسی قرار گرفت و در نهایت از بین مدل های مختلف، شبکه پیشرو (FNN) با الگوریتم LM (levenberg-marquardt) و تابع محرک تانژانت سیگموئیدی با یک لایه میانی شامل 11 نرون بعنوان بهترین و منطقی ترین مدل با کمترین خطا برای داده های موجود انتخاب شد. نتایج بدست آمده توابع هدف برای مدل های ریاضی بکار رفته و مدل شبکه عصبی مصنوعی بهینه، در جدول (2) ارائه شده است. همچنین در نمودارهای 2، 3، 4 و 6 مقدار مقادیر محاسباتی و مشاهداتی برای روابط مختلف و مدل شبکه عصبی مصنوعی مقایسه شده است.

جدول 2: نتایج تست های آماری انجام شده بر روی مدل های بکار رفته

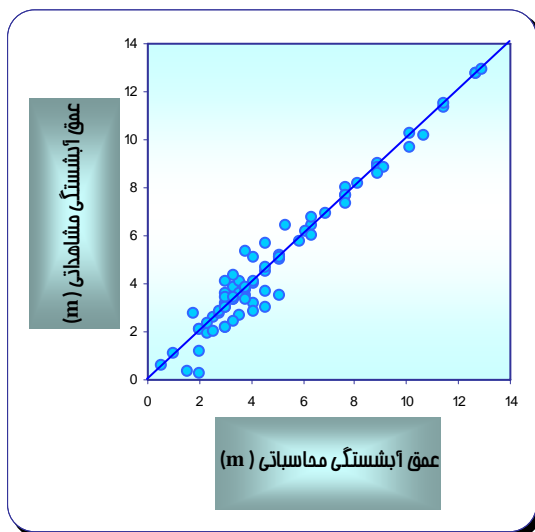
ضریب تبیین R^2	خطا		مدلهای بکار رفته
	MAE	RMSE	
0.67	0.039	0.042	CSU
0.611	0.042	0.058	لارسن و توج
0.54	0.078	0.13	ملویل و سادرلند
0.81	0.022	0.031	ANN مرحله آزمون (الگوریتم GDX)
0.89	0.015	0.023	ANN مرحله آزمون (الگوریتم LM)



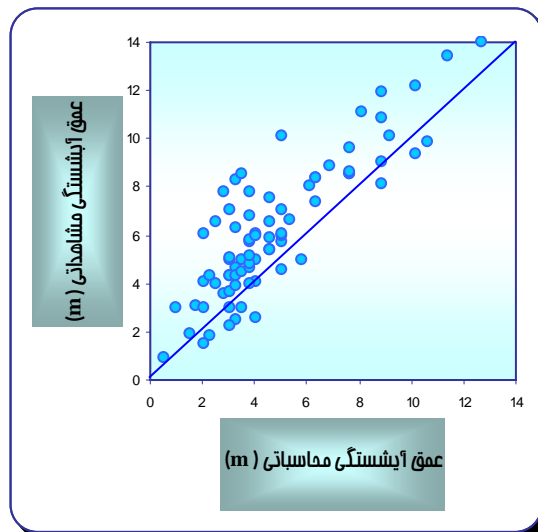
شکل 3. مقایسه مقدار عمق آبشستگی بدست آمده از رابطه لارسن و توج با مقادیر اندازه گیری شده



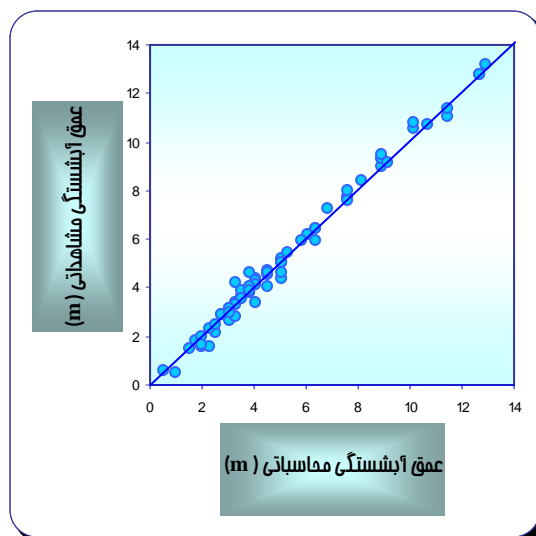
شکل 2. مقایسه مقدار عمق آبشستگی بدست آمده از رابطه CSU با مقادیر اندازه گیری شده



شکل 5: مقایسه مقادیر عمق آبشستگی پیش بینی شده در مرحله آزمون با استفاده از ANN (الگوریتم GDX) و مقادیر اندازه گیری شده



شکل 4: مقایسه مقدار عمق آبشستگی بدست آمده از رابطه ملویل با مقادیر اندازه گیری شده



شکل 6: مقایسه مقادیر عمق آبشستگی پیش بینی شده در مرحله آزمون با استفاده از ANN (الگوریتم LM) و مقادیر اندازه گیری شده

نتیجه گیری

نتایج بدست آمده حاکی از آن است که از بین 3 رابطه بررسی شده، رابطه CSU نتایج نزدیکتری به واقعیت ارائه می دهد. همچنین نتایج بدست آمده از مدل شبکه عصبی مصنوعی، نسبت به روابط یاد شده قابل قبول تر بوده و خطای کمتری نسبت به مقادیر مشاهداتی دارد بنابراین می تواند در پیش بینی میزان آبشستگی پایه های پل به عنوان یک ابزار مفید و دقیق تر مورد استفاده قرار گیرد. لازم به ذکر است چنانچه تعداد داده های بیشتری در دسترس بود، مدل شبکه عصبی نتایج بهتری ارائه می داد.



منابع

- [1] U.S. Department of Transportation, (1993). "Evaluating Scour at Bridges". Hydr. Engrg. Circular No. 18, Rep No. FHWA-IP-90-017, Federal Hwy. Administration (FHWA), Washington, D.C., USA.
- [2] Thamer.A.M, Megat Johari.M, Ghazali.A.H, Huat .B.K,(2005). "Validation of some bridge pier scour formulae using field data and labratoty data", American Journal of Environmental.
- [3] Daliakopoulos, N.I., Couliblay, P., Tsanis, H. K., (2005). "Ground Water level forecasting using artificial neyral networks". J. Hydrol., 309, 229-240.
- [4] Johnson, P.A., (1995). "Comparison of pier scour equations using field data". J. Hydraulic Eng., ASCE, 121:626-629.
- [5] Melville, B.V. and A.J. Sutherland, (1998). Design method for local scour at bridge piers. J. Hydraulic Eng., ASCE, 114, 1210-1226.
- [6] اکبر پور، م. و بارانی، غ. ع. و راهنما، م.ب.(1382). "مقایسه شبکه عصبی مصنوعی و مدل HEC-HMS در فرایند بارندگی-رواناب"، مجموعه مقالات چهارمین کنفرانس هیدرولیک ایران، دانشگاه شیراز، صفحات 1025 تا 1032.
- [7] I. Baheer, "Selection of methodology for modeling hysteresis behavior of soils using neural networks", J Comput Aided Civil Infrastruct Eng 5 (2000) (6), pp. 445-463.
- [8] Hecht-Nielsen R, "Kolmogorov's mapping neural network existence theorem". Proceedings of the first IEEE international conference on neural networks, San Diego CA, USA 1987. p. 11-4.
- [9] R.P. Lippmann, "An introduction to computing with neural nets", IEEE ASSP Mag 4 (1987), pp. 4-22.
- [10] Rumelhart DE, Hinton GE, Williams RJ. "Learning internal representation by error propogation". In: Rumelhart DE, McClelland JL, editors. Parallel distributed processing. vol. 1, (1986). p. 318-62.
- [11] Anderson, D., McNeill, G., (1992). "Artificial neural networks technology". Kaman Sciences Corp., New York, 87
- [12] ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). "Artificial neural network in hydrology", part I and II. J. Hydrol. Eng. ASCE, 5(2), 115-137.
- [13] Messer K, Kittler J. "Choosing an optimal neural network size to aid search through a large image database". Proceedings of the ninth British machine vision conference (BMVC98), University of Southamton, UK, (1998); p. 235-44.
- [14] M. Nelson and W.T. Illingworth, A practical guide to neural nets, Addisin-Wesley, Reading MA (1990).