

برآورد بیشترین ژرفای آبستگي در پيرامون پايه‌هاي پل با بهره‌وري از شبكه‌هاي وايازي كلي و پرسپترون چند لايه‌اي

جواد ظهيري^{۱*}، مناحي ظهيري^۲، ميثم سالاري جزي^۳

تاريخ دريافت: ۱۳۹۰/۱۱/۲۳ تاريخ پذيرش: ۱۳۹۱/۶/۲۰

چکیده

در اين مطالعه، شبكه‌هاي وايازي كلي (GRNN) و پرسپترون چند لايه‌اي (MLP) براي برآورد بیشترین ژرفای آبستگي مورد بهره‌وري قرار گرفتند. الگوريتم‌هاي Levenberg-Marquardt و Momentum به عنوان الگوريتم‌هاي آموزشي، و دو تابع Tanh و Sigmoid نيز به عنوان توابع فعال‌ساز در اين پژوهش جهت ساختن شبیه‌هاي عصبی به کار رفتند. تاکنون مطالعات گسترده‌اي در زمينه‌ي استفاده از شبیه‌هاي مختلف شبكه‌ي عصبی جهت برآورد بیشترین ژرفای آبستگي اطراف پايه‌هاي پل صورت گرفته است که بیشتر اين پژوهش‌ها دارای دو مشکل عمده بوده‌اند: در نظر گرفتن شکل استوانه‌اي به عنوان پايه‌هاي پل، و استفاده از اطلاعات آزمایشگاهی براي ساختن شبیه‌ها از مهمترين کاستي‌هاي مطالعات صورت گرفته در زمينه‌ي برآورد بیشترین ژرفای آبستگي اطراف پايه‌هاي پل به حساب می‌آیند. بر همین اساس، در اين پژوهش علاوه بر شکل استوانه‌اي از اشکال مستطیلی، گرد گوشه و نوک تيز نيز استفاده شده است. همچنین براي ساختن صحت‌سنجی شبیه‌ها از اطلاعات واقعی، که مشتمل بر ۴۷۵ داده‌ي مربوط به آبستگي اطراف پايه‌هاي پل بوده بهره‌وري شده است. در اين پژوهش، بر خلاف پژوهش‌هاي گذشته که از روش آزمون و لغزش براي تعيين شمار نرون‌هاي لايه‌ي مخفی استفاده می‌شد، از الگوريتم ژنتیک جهت اين منظور بهره‌وري گردیده است. نتایج مقایسه‌ي شبیه‌هاي مختلف عصبی نشان‌دهنده‌ي دقت بیشتر شبیه GRNN بوده است. براي بررسی کارآيي اين شبیه از معادلات تجربی موجود نيز استفاده شد، که از جمله می‌توان به روابط بروسرز و همکاران، فروهلیچ، ملویل و ملویل، و چيو اشاره کرد. نتایج شبیه‌هاي مختلف نشان دادند که شبیه عصبی ارائه شده از کارآيي بهتری نسبت به روابط موجود برخوردار است. جهت تعيين تاثیر فراسنج‌هاي مختلف بر آبستگي از تحليل حساسيت استفاده شد. نتایج اين تحليل نشان‌دادند که فراسنج سرعت نسبت به ديگر فراسنج‌هاي مستقل بیشترین تأثير را بر آبستگي اطراف پايه‌هاي پل دارد.

واژه‌هاي کلیدی: شبكه‌هاي وايازي كلي، ژرفای آبستگي، پايه‌هاي پل، الگوريتم ژنتیک، تحليل حساسيت

^۱ - مدرس دانشگاه آزاد اسلامی واحد امیدیه و دانشجوی دکتری سازه‌هاي آبی دانشگاه شهید چمران اهواز

^۲ - عضو هیأت علمی دانشگاه آزاد اسلامی واحد امیدیه

^۳ - دانشجوی دکتری هیدرولوژی دانشگاه شهید چمران اهواز

* - نویسنده مسؤل: J-Zahiri@scu.ac.ir

مقدمه

فرایند آبخستگی اطراف پایه‌های پل پدیده‌ای بسیار پیچیده بوده که این امر به دلیل غامض بودن شرایط هیدرولیکی جریان و ته‌نشست در مکان مزبور می‌باشد. تا کنون پژوهش‌های پرشماری در زمینه‌ی برآورد ژرفای آبخستگی در اطراف پایه‌های پل صورت گرفته‌اند که از مهمترین آنها می‌توان به ملویل و ساترلند (۱۹۸۸)، ملویل و رادکیوی (۱۹۹۶)، پارولا و همکاران (۱۹۹۶)، لیم و چنگ (۱۹۹۸)، میا و ناگو (۲۰۰۳) و شپرد و همکاران (۲۰۰۴) اشاره کرد. هر چند تا کنون مطالعات گسترده‌ای در این زمینه‌ی صورت گرفته، و روابط پرشماری نیز ارائه شده‌اند، ولی به علت پیچیدگی بیش از حد این پدیده‌ی این مطالعات هنوز هم ادامه دارند. روابط ارائه شده، که بیشتر آنها بر پایه‌ی داده‌های آزمایشگاهی به‌دست آمده‌اند، تنها در بعضی شرایط از دقت قابل قبولی برخوردارند. پیچیدگی پدیده‌ی آبخستگی در اطراف پایه‌های پل باعث شده است که پژوهشگران از روشهای دیگری برای شبیه‌سازی آن استفاده کنند، که یکی از آنها بهره‌وری از شبکه‌های عصبی مصنوعی است. دخالت داشتن فراسنجهای پرشمار در پدیده‌ی آبخستگی باعث گردیده است که شبیه‌های شبکه‌ی عصبی جوابهای دقیقتری نسبت به شبیه‌های تجربی ارائه نمایند. این امر در پژوهش‌های صورت گرفته به‌وسیله‌ی بعضی از پژوهشگران، از جمله باتنی و همکاران (۲۰۰۶) و فیرات و گنگور (۲۰۰۹) کاملاً به چشم می‌خورد. باتنی و همکاران (۲۰۰۶) کوشش کردند با استفاده از شبیه‌های عصبی به برآورد بیشترین ژرفای آبخستگی در اطراف پایه‌های استوانه‌ای بیرازند. این پژوهشگران نتایج شبیه خود را با روابط تجربی متداول مقایسه نموده، و دریافتند که کارایی شبیه عصبی بیش از دیگر شبیه‌های متداول می‌باشد. فیرات و گنگور (۲۰۰۹)، با استفاده از شبیه‌های وایازی کلی و شبیه‌های پس‌خور اقدام به همانند سازی ژرفای چاله‌ی آبخستگی نمودند.

متأسفانه، کلیه‌ی تحقیقات صورت گرفته در زمینه‌ی استفاده از شبیه‌های عصبی در تخمین ژرفای آبخستگی اطراف پایه‌های پل دارای دو کاستی عمده می‌باشند: دشواری نخست مربوط به داده‌های مورد

بهره‌وری در این تحقیقات می‌باشد، چه، اکثراً از اطلاعات آزمایشگاهی جهت ساختن شبیه‌های عصبی استفاده شده است و با توجه به این که شرایط طبیعی تفاوت‌های عمده‌ای با شرایط آزمایشگاهی دارند، نمی‌توان به دقت این شبیه‌ها در موارد عملی اطمینان کامل داشت. مشکل دوم آن که شکل پایه همواره به صورت استوانه‌ای فرض شده است و با توجه به این که شکل پایه از جمله عوامل مؤثر بر بیشترین ژرفای آبخستگی در اطراف پایه‌های پل به حساب می‌آید، نمی‌توان از شبیه‌های عصبی ارائه شده برای پایه‌هایی با شکلهای مختلف استفاده کرد. بر همین اساس، در این پژوهش به جای اطلاعات آزمایشگاهی از اطلاعات میدانی جهت آموزش و صحت‌سنجی شبیه‌ها استفاده شد. از طرف دیگر، شکل پایه در این پژوهش به عنوان یک متغیر در نظر گرفته شده است. شکلهایی که در این پژوهش مورد استفاده قرار گرفته‌اند طیف وسیعی را از پایه‌های پل موجود، از قبیل استوانه‌ای، مستطیلی، گرد گوشه و لبه تیز شامل می‌شوند.

شبکه‌ی های عصبی مصنوعی

شبکه‌ی عصبی از تعداد زیادی اجزاء ساده محاسباتی، که به آنها نرون گفته می‌شود، تشکیل می‌گردد. در حالت کلی، شبکه‌ی عصبی را می‌توان به عنوان یک سامانه یا شبیه ریاضی دانست که از تعداد زیادی اجزاء عصبی غیر خطی در یک یا چند لایه تشکیل شده باشد (فیرات و گنگور، ۲۰۰۹). بیشتر شبکه‌های عصبی از سه لایه تشکیل می‌شوند: لایه‌های ورودی، خروجی و پنهان. داده‌ها به شکل فراسنجهای ورودی و خروجی به شبکه‌ی معرفی شده، و بهترین رابطه‌ی غیر خطی با حداقل کردن خطا به‌دست می‌آید. در حقیقت، شبکه‌ی عصبی به مانند تحلیل‌های وایازی انواع مختلفی از روابط را جهت پیدا کردن بهترین انطباق مورد آزمایش قرار می‌دهد. تجربه نشان داده است که شبکه‌ی هرگز به آن دقتی که درمورد مجموعه‌ی آموزش عمل می‌کند، درمورد بقیه مجموعه عمل نمی‌کند. این پدیده‌ی به عنوان آموزش زیادی^۱ شناخته، و بیان می‌شود که شبکه‌ی برای داده آموزشی برازش زیادی^۲ دارد (پیکتن،

^۱ -over-training

^۲ -over-fit

چگالی احتمال توأم، یعنی احتمال این‌که خروجی y و ورودی x باشد، است. به همان طریقی که توابع چگالی احتمال در PNN با مجموع توابع گوسی برآورد شد، می‌توان تابع احتمال شرطی را نیز تقریب زد. این امر با قرار دادن مرکز تابع گوسی بر روی داده ورودی در یک مجموعه آموزشی، و ضرب آن در مقدار خروجی متناظر انجام می‌شود. پس از عملیات مختصری، معادله فوق را می‌توان با معادله زیر تقریب زد:

$$y = \frac{\sum_{p=1}^P y_p \exp(-d_p^2 / 2\sigma^2)}{\sum_{p=1}^P \exp(-d_p^2 / 2\sigma^2)} \quad (2)$$

در این معادله فرض شده است که P داده در مجموعه آموزشی وجود دارد. هر یک از داده‌ها از یک زوج آموزشی شامل بردار ورودی، X_{1p} ، X_{2p} تا X_{np} و مقدار خروجی متناظر، y_p ، تشکیل شده است. مقدار d_p فاصله‌ی بین بردار ورودی کنونی و بردار ورودی P ام در داده‌های آموزشی است. برای یک بردار ورودی معین، فاصله‌ی آن بردار با تمام بردارهای ورودی در مجموعه آموزشی محاسبه شده و به یک تابع گوسی با مرکزیت بردارهای ورودی مجموعه آموزشی داده می‌شود. در مخرج کسر، خروجیهای این توابع گوسی برای به‌دست آوردن مجموع، جمع زده می‌شوند. در صورت کسر، خروجیهای توابع گوسی با مقدار مربوطه y از مجموعه آموزشی وزن دار شده و جمع زده می‌شود. در این‌جا نیز مانند شبکه‌های عصبی احتمالی، توابع گوسی با استفاده از معادله‌ی زیر، که در آن b مقداری بین ۰ و ۱ است، به‌دست می‌آید:

$$\sigma = \alpha P^{-b/n} \quad (3)$$

از نظر معماری نیز شبکه‌ی عصبی GRNN شباهت زیادی به شبکه‌ی عصبی احتمالی دارد، به استثناء این‌که وزنها در لایه‌ی خروجی برابر با ۱ قرار داده نمی‌شوند. در عوض، این وزنها برابر با مقادیر متناظر خروجی y در مجموعه‌ی آموزشی قرار داده می‌شوند. علاوه بر آن، مجموع خروجی‌های لایه‌ی گوسی باید محاسبه شود تا بتوان خروجی نهایی را بر آن تقسیم کرد.

۱۳۸۸). جهت جلوگیری از این مشکل درصدی از داده‌های مورد استفاده به عنوان مجموعه‌ی آزمون^۱ در نظر گرفته شد. بر این اساس، مجموعه‌ی داده به سه مجموعه‌ی آموزش، مجموعه‌ی آزمون و مجموعه‌ی تأیید تقسیم شدند. آموزش با استفاده از مجموعه‌ی آموزشی انجام گرفته، و خطا برای تنظیم وزنها به‌کار گرفته می‌شود. با این وجود، در حین آموزش، داده‌ی آزمون نیز به شبکه‌ی نشان داده شده و خطا ثبت می‌گردد. فرق داده‌های آزمون با آموزش در این است که هنگامی که داده‌های آزمون به شبکه‌ی نشان داده می‌شوند، وزنها تنظیم نمی‌گردند، بلکه فقط پس از نشان دادن داده‌ی آموزشی به شبکه‌ی، و با استفاده از پس انتشار، وزنها تنظیم می‌گردند. بر این اساس، در حین فرایند آموزش، علاوه بر این خطای داده آموزش کاهش می‌یابد، می‌بایستی خطای داده‌ی آزمون نیز کاهش یابد. در مرحله‌ای که کاهش خطای داده‌ی آزمون متوقف شود، و یا افزایش یابد، می‌بایستی فرایند آموزش متوقف گردد.

شبیه‌های شبکه‌ی عصبی

شبکه‌ی عصبی وایازی کلی (GRNN)^۲

شبکه‌ی عصبی وایازی کلی، به‌وسیله‌ی دونالد اسپکت (۱۹۹۱) برای شبیه‌سازی و تشخیص سامانه ابداع شد، و می‌توان آن را به عنوان تعمیمی از شبکه‌ی عصبی احتمالی تلقی کرد. شبکه‌ی عصبی احتمالی خصوصاً برای طبقه‌بندی الگو به‌کار گرفته می‌شود، در حالی که، GRNN کاربردهای وسیعتری دارد. مقصود از GRNN این است که بتوان هر تابع معلومی را به‌وسیله‌ی مجموعه‌ای از زوجهای داده ورودی و خروجی تقریب زد. با فرض این‌که یک تابع η ورودی، X_1 تا X_n ، و یک خروجی، y ، دارد، مقدار میانگین خروجی با یک ورودی معین را می‌توان با استفاده از نظریه‌ی احتمال از معادله‌ی زیر به‌دست آورد:

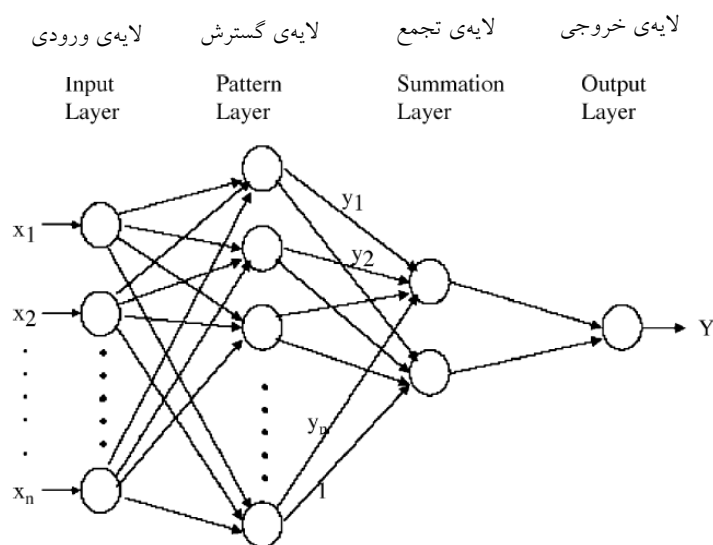
$$y(x) = \frac{\int_{-\infty}^{+\infty} y \text{ pdf}(x, y) dy}{\text{pdf}(x)} \quad (1)$$

که در آن، معادله‌ی تابع $\text{pdf}(x, y)$ یک تابع


¹ Validation

² General Regression Neural Network


این معماری برای یک تابع تک خروجی و n متغیر ورودی در شکل (۱) نشان داده شده است.



شکل ۱- ساختار شبکه‌ی عصبی وایزی کلی.



شکل ۲- مقایسه‌ی همبستگی بین نتایج شبیه GRNN و مقادیر واقعی ژرفای آبستنگی در مرحله‌ی آموزش.



شکل ۳- مقایسه‌ی همبستگی بین نتایج شبکه GRNN و مقادیر واقعی ژرفای آبستنگی در مرحله‌ی صحت‌سنجی.

الگوریتم‌های آموزشی

در این پژوهش از دو الگوریتم مشهور، که کاربرد گسترده‌ای در زمینه‌های مختلف دارند، استفاده شده است. این دو الگوریتم شامل Levenberg-Marquardt و اندازه حرکت (Momentum) می‌باشند. از آنجا که الگوریتم Levenberg-Marquardt دقت و سرعت فرایند آموزش را افزایش می‌دهد، محبوبیت بیشتری پیدا کرده است. در این الگوریتم وزن اجزاء شبکه‌ی را می‌توان از طریق رابطه‌ی زیر به دست آورد:

$$w(k+1) = w(k) - H^{-1}(k)g(k) \quad (4)$$

که در آن $w(k)$ وزن اجزاء شبکه‌ی در تکرار k ام بوده و ماتریس $H^{-1}(k)$ نشان‌دهنده‌ی معکوس ماتریس Hessian می‌باشد. بردار $g(k)$ نماینده‌ی شیب تابع فعال‌ساز می‌باشد. ماتریس Hessian را می‌توان از طریق رابطه‌ی زیر تخمین زد:

$$H \approx J^T J \quad (5)$$

که در آن J ماتریس ژاکوبی بوده و شیب تابع فعال‌ساز را می‌توان از طریق رابطه‌ی زیر برآورد نمود:

$$g = \frac{\partial E}{\partial w} = J^T e. \quad (6)$$

که در آن e بردار خطا بوده و از رابطه‌ی زیر قابل محاسبه است:

$$e = y - o \quad (7)$$

براین اساس، تابع تنظیم‌کننده‌ی وزنها را می‌توان به صورت زیر بازنویسی کرد (هاگان و منهاج، ۱۹۹۴):

$$w(k+1) = w(k) - [J^T(k)J(k)]^{-1} \times J^T(k)e(k) \quad (8)$$

روش آموزش Momentum در حقیقت اصلاح شده‌ی روش کاهش شیب^۱ بوده که در آن فراسنج حافظه به گونه‌ای تغییر یافته است تا رسیدن به همگرایی پایدار را سرعت بخشد. در روش آموزش Momentum، معادله‌ای که جهت به هنگام کردن وزنها به کار می‌رود به صورت زیر است:

$$w_{ij}(k+1) = w_{ij}(k) + \eta \delta_i(k)x_j(k) + \alpha(w_{ij}(k) - w_{ij}(k-1)) \quad (9)$$

که در آن α ضریب اندازه‌ی حرکت می‌باشد. معمولاً مقدار α بین ۰/۱ تا ۰/۹ تغییر می‌کند. η نرخ یادگیری و δ به عنوان میزان مسؤولیت نرون در به وجود آوردن خطا می‌باشد.

جهت آغاز فرایند یادگیری، لازم است مقادیر اولیه جهت هر کدام از وزنها در نظر گرفته شده و فرایند تا زمانی که شرایط توقف آموزش ارضاء گردد، ادامه یابد. سه معیاری که اغلب جهت توقف فرایند آموزش به کار می‌روند، عبارتند از: شمار تکرارها، میانگین مربعات خطای

^۱ -straight gradient descent

فراسنجهای بعد دار در برآورد میزان ژرفای آبشستگی اطراف پایه‌های پل از دقت بهتری نسبت به متغیرهای بی بعد برخوردار می‌باشند. بر همین اساس در این پژوهش از متغیرهای بعد دار به عنوان متغیرهای ورودی جهت ارائه به شبیه‌های عصبی استفاده شد.

روش پژوهش

در این پژوهش از دو شبیه‌سازی شبکه‌ی عصبی وایزی کلی و شبکه‌ی پرسپترون چند لایه استفاده شده است. تعیین تعداد نرونها در لایه‌های ورودی و خروجی بوده، همچنان که به وسیله‌ی متغیرهای ورودی و خروجی به شبیه‌های القاء می‌شود. اما تعیین تعداد لایه‌های پنهان و نرونهای آنها به سادگی امکان‌پذیر نیست. در بیشتر مطالعات گذشته از روش آزمون و لغزش برای تعیین تعداد نرونها و لایه‌های پنهان استفاده شده است. در این پژوهش از آن جا که دو شبیه GRNN و MLP، و دو تابع فعال-ساز Sigmoid و Tanh به کار رفته‌اند، و نیز از دو روش آموزش Momentum و Levenberg-Marquardt استفاده شده است، شمار اجرای شبیه‌های مختلف زیاد بود. بر این اساس، و با توجه به مطالعات صورت گرفته در گذشته، تعداد لایه‌های مخفی برابر با ۱ در نظر گرفته شد، هر چند تعدادی از شبیه‌ها با ۲ لایه‌ی پنهان اجرا شدند، دقت آنها تغییر محسوسی نداشته و تنها مدت زمان اجرای شبیه را افزایش دادند. در این پژوهش از الگوریتم ژنتیک جهت تعیین شمار نرونهای لایه‌ی پنهان بهره‌وری شده است. جهت تعیین کارایی شبیه‌های شبکه‌ی عصبی از معیارهای متفاوتی استفاده می‌گردد که سه معیار از آنها بیشترین کاربرد را دارند. این سه معیار عبارتند از: خطای میه‌وسیله‌ی مطلق (MAE)^۱، جذر میانگین مربعات خطا (RMSE)^۲ و ضریب همبستگی (R^۲)^۳.

$$MAE = \frac{1}{N} \sum_{i=1}^N |O_i - t_i| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - t_i)^2} \quad (14)$$

داده‌های آموزش، و میانگین مربعات خطای داده‌های آزمون. در بین سه معیار فوق، خطای مربوط به داده‌های آزمون کاربرد بیشتری دارد، زیرا فرایند آموزش را در نقطه‌ی بهینه (نقطه‌ای که در آن خطای داده‌های آزمون به کمترین مقدار خود می‌رسد) متوقف می‌سازد.

انتخاب فراسنجهای

ژرفای نهایی آبشستگی اطراف پایه‌های پل تابعی از مشخصات جریان، ته‌نشستهای بستر و مشخصات پایه می‌باشد (ملویل و کلمن، ۲۰۰۰).
(۱۰)

$$d_s = f \left(\rho, v, V, y, g, d_{50}, \sigma, \rho_s, V_c, B, Sh, \alpha \right)$$

در رابطه‌ی فوق d_s = ژرفای آبشستگی نهایی، ρ و v = چگالی و گرانیوی جنبشی جریان، V = سرعت متوسط جریان نزدیک شونده، y = ژرفای جریان، g = شتاب ثقل، d_{50} و σ = به ترتیب اندازه‌ی متوسط و انحراف هندسی معیار ذرات رسوبی بستر، ρ_s = چگالی ته‌نشستها، V_c = سرعت بحرانی متوسط جهت آستانه‌ی حرکت ته‌نشستهای بستر، B = عرض یا قطر پایه، Sh و α = فراسنجهایی جهت معرفی شکل و نحوه‌ی قرارگیری پایه نسبت به جریان می‌باشند. در این پژوهش از آن جا که ρ ، v ، g و ρ_s در تمامی داده‌های مورد استفاده اعداد ثابتی بوده‌اند، حذف گردیدند. متغیر V_c نیز یک متغیر مستقل نبوده، بلکه می‌توان آن را به صورت زیر نوشت (مولر و واگنر، ۲۰۰۵):

$$V_c = 31.08 \theta^{1/2} y^{1/6} D_{50}^{1/3} \quad (11)$$

که θ = فراسنج شیلدز بوده و خود نیز تابعی است از اندازه‌ی ذرات. بر این اساس V_c تابعی است از مشخصات جریان و رسوب که خود جزء متغیرهای ورودی به حساب می‌آیند. بر این اساس در شبیه‌های مورد استفاده ژرفای آبشستگی به صورت تابعی از متغیرهای زیر معرفی شد:

$$d_s = f \left(V, y, d_{50}, \sigma, B, Sh, \alpha \right) \quad (12)$$

بدین ترتیب، کل متغیرهای ورودی به هفت فراسنج کاهش یافتند. متغیر خروجی نیز ژرفای آبشستگی در نظر گرفته شد. گرچه می‌توان از متغیرهای بی بعد و یا متغیرهای بعد دار جهت معرفی فراسنجهای ورودی بهره برد، ولی براساس نتایج پژوهشات گذشته (باتنی و همکاران، ۲۰۰۷) و (فیرات و گنگور، ۲۰۰۹)، استفاده از

^۱- mean-absolute error

^۲- root mean square error

^۳- determination coefficient

مرحله‌ی صحت‌سنجی متغیر بوده است. نتایج تحلیل‌های آماری صورت گرفته برای شبیه‌های مختلف در جدول (۱) ارائه شده‌اند. بر این اساس شبیه GRNN به عنوان شبیه مناسب جهت برآورد بیشترین ژرفای آبشستگی در اطراف پایه‌های پل انتخاب شد. شکل‌های (۲) و (۳) نیز نشان‌دهنده‌ی نتایج حاصل از آموزش و صحت‌سنجی مربوط به شبیه GRNN می‌باشند.

مقایسه نتایج شبیه عصبی با معادلات موجود در زمینه‌ی برآورد ژرفای آبشستگی

برای برآورد دقت شبیه‌های عصبی به کار رفته در این پژوهش، در تخمین ژرفای آبشستگی از شماری معادله‌ی موجود جهت برآورد ژرفای آبشستگی در اطراف پایه‌های پل استفاده شده است. معادلات مورد استفاده در این پژوهش عبارت بودند از: معادله‌ی لارسن و تاچ (۱۹۵۶)، شن (۱۹۷۱)، بروزرس و همکاران (۱۹۷۷)، فروهلیچ (۱۹۹۵)، ملویل (۱۹۹۷) و ملویل و چپو (۱۹۹۹). نتایج روابط معرفی شده با توجه به همان داده‌های به کار رفته در شبیه‌های عصبی در جدول (۲) ارائه شده‌اند. با توجه به تحلیل‌های صورت گرفته، معادله فروهلیچ (۱۹۹۵) از دقت بهتری نسبت به بقیه‌ی روابط برخوردار بود. شکل (۴) نشان‌دهنده‌ی نتایج حاصل از این معادله در مقابل مقادیر مشاهداتی می‌باشد.

در مقایسه‌ای که بین نتایج حاصل از شبیه GRNN و معادله‌ی فروهلیچ (۱۹۹۵) صورت گرفت (جدول ۱ و ۲)، مشخص شد که شبیه GRNN می‌تواند با دقت بهتری نسبت به معادله، فروهلیچ (۱۹۹۵) اندازه‌ی ژرفای آبشستگی را در اطراف پایه‌های پل شبیه‌سازی کند، به طوری که مقدار MAE و RMSE برای شبیه GRNN به ترتیب برابر با ۰/۲۴۶ و ۰/۳۲۲ بود، در حالی که این مقادیر جهت معادله فروهلیچ ۰/۴۳۲ و ۰/۶۴۹ می‌باشند. ضریب R^2 نیز در شبیه عصبی بهتر از معادله‌ی فروهلیچ بود.

$$R^2 = 1 - \frac{\sum_{i=1}^N (O_i - t_i)^2}{\sum_{i=1}^N (O_i - \bar{O}_i)^2} \quad (15)$$

در روابط فوق O_i و t_i به ترتیب مقادیر واقعی و خروجی شبکه و \bar{O}_i به وسیله‌ی مقادیر واقعی، و N تعداد کل داده‌ها می‌باشند. آموزش شبیه‌های شبکه‌ی عصبی زمانی که خطای قابل قبولی به دست می‌آید، و یا این که تعداد تکرارها از مقدار بیشترین (=۱۰۰۰) تجاوز می‌کند، خاتمه می‌یافت. بهترین شبیه، شبیهی است که مقادیر MAE و RMSE کمتری داشته و مقدار R^2 به یک نزدیکتر باشد.

اطلاعات مورد استفاده به وسیله‌ی سازمان FHWA^۱ ارائه شده و مربوط به پلهای موجود در ایالات متحده می‌باشند. از آن جا که کلیه‌ی اطلاعات مورد استفاده، داده‌های واقعی بوده، و بازه‌ی وسیعی از شرایط هیدرولیکی و رسوبی را شامل می‌شوند، می‌توان از شبیه‌های ارائه شده جهت موارد کاربردی نیز بهره جست. این اطلاعات جمعاً شامل ۴۷۵ داده بوده که ۳۰۹ داده‌ی آن جهت آموزش شبیه‌های عصبی، ۷۲ داده به عنوان مجموعه‌ی آزمون و ۹۴ داده باقیمانده برای صحت‌سنجی شبیه‌های مختلف به کار رفتند.

نتایج شبیه‌های عصبی

شبیه‌های پرسپترون طی آموزش دارای RMSE متغیر از ۰/۴۸۳ تا ۰/۳۳۹ بوده‌اند، در حالی که این مقدار طی مرحله صحت‌سنجی کمی افزایش یافتند (۰/۴۰۳ تا ۰/۷۰۴). شبیه GRNN نسبت به شبیه‌های پرسپترون از RMSE کمتری برخوردار بود (۰/۲۷۱) در مرحله‌ی آموزش و ۰/۳۲۲ در مرحله‌ی صحت‌سنجی). از نظر همبستگی بین نتایج شبیه‌های مختلف و مقادیر مشاهداتی، در بین توابع فعال‌ساز تفاوت معنی‌داری مشاهده نشد، ولی الگوریتم آموزشی Levenberg-Marquardt دقت بهتری نسبت به الگوریتم Momentum را از خود نشان داد. شبیه GRNN دارای R^2 بهتری نسبت به شبیه‌های پرسپترون بوده، که مقدار R^2 آن برابر با ۰/۹۱۲ در مرحله‌ی آموزش و ۰/۸۶۶


^۱ -Federal Highway Administration

جدول ۱- محاسبه مقادير خطا و همبستگي شبیه‌هاي مختلف عصبي

مدل	نوع شبکه	تابع فعالساز	روش یادگیری	نورونهای پنهان	MAE		RMSE		R ²	
					Test	Train	Test	Train	Test	Train
TL1	MLP	L.M	Tanh	۱۵	۰/۲۶۰	۰/۲۸۳	۰/۳۳۹	۰/۴۰۳	۰/۹۲۶	۰/۸۶۵
TM1	MLP	Momentum	Tanh	۲۵	۰/۳۰۷	۰/۲۸۴	۰/۴۲۶	۰/۴۱۸	۰/۸۷۸	۰/۸۳۹
SL1	MLP	L.M	Sigmoid	۶	۰/۲۵۵	۰/۲۸۲	۰/۳۴۶	۰/۴۲۸	۰/۹۲۰	۰/۸۳۴
SM1	MLP	Momentum	Sigmoid	۲۵	۰/۴۷۷	۰/۳۶۶	۰/۴۸۳	۰/۷۰۴	۰/۷۱۷	۰/۷۰۱
GRN	GRNN	-	-	-	۰/۲۰۲	۰/۲۴۶	۰/۲۷۱	۰/۳۲۲	۰/۹۱۲	۰/۸۶۶

جدول ۲- محاسبه‌ي مقادير خطا و همبستگي معادلات مختلف

ضریب همبستگی (R ²)	خطا		معادلات موجود
	RMSE	MAE	
۰/۶۲۱	۱/۹۱۲	۱/۵۰۹	لارسن و تاچ (۱۹۵۶)
۰/۵۲۱	۱/۰۶۸	۰/۷۸۵	شن (۱۹۷۱)
۰/۶۲۲	۱۴/۶۱۱	۶/۹۷۸	بروزرس و همکاران (۱۹۷۷)
۰/۷۰۸	۰/۶۴۹	۰/۴۳۲	فروهلیچ (۱۹۹۵)
۰/۵۳۲	۲/۹۴۷	۲/۲۴۲	ملویل (۱۹۹۷)
۰/۵۴۳	۲/۸۰۱	۲/۱۲۷	ملویل و چپو (۱۹۹۹)



شکل ۴- مقایسه‌ی همبستگی بین نتایج شبیه فروهلیچ (۱۹۹۵) و مقادیر واقعی ژرفای آبستگي در مرحله‌ی صحت‌سنجی.

تحلیل حساسیت

متغیرهای ورودی حذف شد و شبیه‌ی عصبي با در نظر گرفتن بقیه فراسنجهای ورودی اجرا گردید. پس از آن، تحلیل‌های آماری برای نتایج به‌دست آمده انجام شد. نتایج این تحلیل در جدول (۳) ارائه شده‌اند. با توجه به این

تحلیل حساسیت جهت تعیین اثر نسبی هر کدام از متغیرهای ورودی بر ژرفای آبستگي اطراف پایه‌های پل صورت گرفت، بدین ترتیب که در هر مرحله یکی از

آبشستگی برخوردار بودند. زاویه قرارگیری پایه نیز نسبت به دیگر فراسنجه‌ها اثر کمتری بر ژرفای آبشستگی اطراف پایه‌های پل دارد.

جدول، فراسنج سرعت بیشترین تأثیر را بر اندازه‌ی ژرفای آبشستگی دارا می‌باشد. پس از سرعت، مشخصات ته‌نشست‌ها از قبیل D_{50} و σ از تأثیر بیشتری بر ژرفای

جدول ۳- تحلیل حساسیت شبیه GRNN.

ضریب همبستگی (R2)	خطاها		مدل
	RMSE	MAE	
۰/۸۰۰	۰/۴۵۷	۰/۳۰۶	GRNN no Shape
۰/۷۷۴	۰/۴۸۱	۰/۳۲۹	GRNN no Width
۰/۸۱۵	۰/۴۳۹	۰/۲۹۷	GRNN no Skew
۰/۶۷۶	۰/۶۴۶	۰/۳۶۴	GRNN no Velocity
۰/۷۶۰	۰/۵۰۰	۰/۳۳۵	GRNN no Depth
۰/۶۷۱	۰/۶۱۷	۰/۳۴۱	GRNN no D_{50} & σ

نتایج

در این پژوهش جهت برآورد ژرفای آبشستگی در اطراف پایه‌های پل از شبکه‌های وایازی کلی، پرسپترون چند لایه، و الگوریتم‌های فراگیری Levenberg-Marquardt و Momentum استفاده شد. در این پژوهش، علاوه بر متغیرهای متداول در پژوهش‌های گذشته، شکل پایه نیز به عنوان متغیر ورودی به شبیه‌های مورد استفاده معرفی گردید. جهت تعیین تعداد نرونهای لایه‌ی پنهان نیز از الگوریتم ژنتیک استفاده شد. با توجه به معیارهای آماری مورد استفاده مشخص گردید که شبکه‌ی وایازی کلی از دقت بیشتری نسبت به شبکه‌های پرسپترون چند لایه برخوردار است. از دیگر مزایای این شبکه، سرعت در اجرای شبیه بود. جهت ارزیابی عملکرد شبیه‌های عصبی از شماری معادله‌ی موجود جهت برآورد ژرفای آبشستگی اطراف پایه‌های پل استفاده شد. مقایسه‌ی نتایج این روابط و شبیه‌های عصبی نشان‌دهنده‌ی دقت بیشتر شبیه‌های عصبی بوده است. در تحلیل حساسیت انجام شده نیز مشخص شد که فراسنج سرعت نزدیک شونده بیشترین تأثیر، و زاویه قرارگیری پایه کمترین تأثیر را بر ژرفای آبشستگی دارا می‌باشند.

منابع

۱. پیکتن، فیلیپ. شبکه‌های عصبی. ترجمه تقی زاده کاخکی ح، و میرصالحی م، انتشارات دانشگاه فردوسی، مشهد، ۱۳۸۸.
2. Bateni, S.M., Jeng, D.S and Melville, B.W. 2007. Bayesian neural networks for prediction of equilibrium and time-dependent scour depth around bridge piers. Adv Eng Software 38:102-111.
3. Breusers, H. N. C., Nicollet, G, and Shen, H. W. 1977. Local scour around cylindrical piers. J. Hydro. Res., (Delft), 15:211-252.
4. Firat, M. and Gungor, M. 2009 Generalized regression neural networks and feed forward neural networks for prediction of scour depth around bridge piers. Adv in Eng Software 40:731-737.
5. Froehlich, D.C. 1995. Contraction scours at bridges clear water conditions with armoring, in Water Resources Research: San Antonio, TX, Am Soc of Civ Eng. 981-985.
6. Laursen, E.M. and Toch, A. 1956 Scour around bridge piers and abutm-

18. Sheppard, D.M., Odeh, M. and Glasser, T. 2004. Large scale clear-water local pier scour experiments. *J. Hydraul. Eng.* 130 10: 957–963.
19. Specht, D.F. 1991. A generalized regression neural network. *IEEE, Trans Neural Networks* 2: 568-576.
- ents. *Bulletin No.4, Iowa Highways Research Board, Ames, Iowa, U.S.A.*
7. Lim, SY. and Cheng, NS. 1998. Prediction of live-bed scour at bridge abutments. *J. Hydraul. Eng.* 124:635–642.
8. Hagan, M. T., and Menhaj, M. B. 1994. Training feed-forward networks with the Marquardt algorithm. *IEEE Trans. Neural Networks.* 5 6: 989-993.
9. Melville, BW. and Sutherland, AJ. . 1988. Design method for local scour at bridge piers. *J. Hydraul. Eng.* 114 10:1210–1226.
10. Melville, BW. and Raudkivi, A.J. 1996. Effects of foundation geometry on bridge pier scour. *J. Hydraul. Eng.* 122:203–209.
11. Melville, B. W. 1997. Pier and abutment scour: Integrated approach. *J. Hydraul. Eng.* 123 2:125–136.
12. Melville, B. W., and Chiew, Y. M. 1999. Time scale for local scour at bridge piers. *J. Hydraul. Eng.* 125 1: 59–65.
13. Melville, B.W., and Coleman, S.E. .2000. *Bridge scour. Water Resources Publications, Littleton, Co.*
14. Mia, F, and Nago, H. 2003. Design method of time-dependent local scour at circular bridge pier. *J. Hydraul. Eng.* 129 6:420–427.
15. Mueller, D. S., and Wagner, C. R. 2005. Field observations and evaluations of streambed scour at bridges. Report No. FHWA-RD-03-052, U.S. Department of Transportation, Federal Highway Admin., McLean, Va.
16. Parola, A.C., Mahavadi, S.K., Brown, B.M. and ElKhoury, A.. 1996. Effect of rectangular foundation geometry on local pier scour. *J. Hydraul. Eng.* 122: 35–40.
17. Shen, H. W. 1971. *River Mechanics. Vol. 2, Ft. Collins, Colorado, USA.*