

بررسی عملکرد شبکه‌های عصبی مصنوعی

در برآورد بیشترین ژرفای آبستگي پيرامون آبشكن‌ها

پيام خسروي نيا^۱، حبيب صيادي^۱، علي حسين زاده دلير^۲، داود فرسادي زاده^۲، رسول ميرعباسي نجف‌آبادي^۱
تاریخ دریافت: ۹۰/۰۲/۲۵ تاریخ پذیرش: ۹۰/۱۱/۱۹

چکیده

یکی از عوامل اصلی ویرانی آبشکن‌ها آبستگي می‌باشد که فرآیندی بسیار پیچیده است. پیچیدگی الگوی جریان پیرامون آبشکنها و گوناگونی عوامل مؤثر بر آبستگي، موجب پرشماری روابط تجربی و کاهش دامنه‌ی هر یک از آنها، به دلیل محدودیت شرایط آزمایشگاهی می‌شود. در این تحقیق امکان استفاده از شبکه‌های پرسپترون چندلایه (MLP) برای برآورد بیشترین ژرفای آبستگي پیرامون سه نوع آبشکن شامل آبشکنهایی با دیواره‌ی عمودی، بالدار و نیم‌دایره‌ای مورد مطالعه قرار گرفتند. دستاوردهای شبیه شبکه عصبی مصنوعی با نتایج به دست آمده از رابطه‌ی تجربی پیشنهادی به وسیله‌ی باربھیوا و دی (۲۰۰۴) مقایسه گردیدند. هشت نمایشنامه بر اساس فراسنجهای مؤثر و شبکه‌های با ورودیهای مختلف برای پیش‌بینی ژرفای آبستگي تعریف شدند. مقایسه‌ی نتایج نمایشنامه‌های مختلف نشان دادند که نمایشنامه‌ی که تنها از دو فراسنج y/l و F_e برای برآورد ژرفای آبستگي در پیرامون آبشکن استفاده می‌کند، از عملکرد بهتری برخوردار است. همچنین، نتایج تحلیل حساسیت نشان دادند که فراسنجهای y/l و l/d_{50} بیشترین تأثیر را در پیش‌بینی ژرفای آبستگي آبشکن دارند. مقایسه نتایج شبیه شبکه‌های عصبی و مقادیر محاسبه شده از رابطه‌ی تجربی با داده‌های آزمایشگاهی نشان دادند که مقادیر بیشترین ژرفای آبستگي به دست آمده از روش شبکه‌های عصبی مصنوعی از دقت بیشتری نسبت به رابطه‌ی تجربی برخوردارند. همچنین، دقت شبکه‌های عصبی مصنوعی در برآورد ژرفای آبستگي پیرامون آبشکنهای با دیواره‌ی عمودی در مقایسه با دو نوع آبشکن دیگر بیشتر است.

واژه‌های کلیدی: آب‌شستگی، آب‌شکن، شبکه‌های عصبی، شبکه‌های پرسپترون چند لایه.

۱- دانشجوی دکتری گروه مهندسی آب، دانشگاه تبریز.

۲- دانشیار گروه مهندسی آب، دانشگاه تبریز.

* نویسنده‌ی مسئول: payamsh1998@yahoo.com

مقدمه

نمونه‌ها، حتی در مواردی که داده‌های ورودی دارای خطا و یا ناقص باشند، و سازگار نمودن راه حلها با شرایط متغیر و پردازش سریعتر اطلاعات می‌باشند (بشیر و حاجمیر، ۲۰۰۰؛ آزمادولا و همکاران ۲۰۰۶، ۲۰۰۵). یک سامانه ممکن است غیرخطی و چندمتغیره بوده و متغیرهای دخیل نیز دارای روابط داخلی پیچیده‌ای باشند. شبکه‌های عصبی مصنوعی توانایی مطابقت با این پیچیدگیها را داشته و دقت آنها با افزایش هر چه بیشتر داده‌های ورودی افزایش می‌یابد. همچنین شبکه‌های عصبی مصنوعی توانایی استخراج رابطه‌ی بین داده‌های ورودی و خروجی یک فرآیند را بدون هیچ گونه اطلاع از اصول آن دارند. به دلیل تواناییهای تعمیم یافته تابع استخراجی، نیازی به هیچ گونه فرضی در مورد رابطه‌ی (خطی یا غیر خطی) بین داده‌های ورودی و خروجی نیست (جین و همکاران، ۲۰۰۴).

استفاده از شبکه‌های عصبی مصنوعی در علوم آب در چند دهه‌ی اخیر گسترش فراوانی یافته است. در زمینه برآورد آبخستگی در سازه‌های مختلف، با استفاده از شبکه‌های عصبی، نیز تاکنون مطالعاتی صورت گرفته اند. کامبکر و دئو (۲۰۰۳) کاربرد شبکه‌های عصبی را برای پیش‌بینی ژرفای آبخستگی پیرامون گروه شمعه‌ها بررسی کرده و نشان دادند که شبکه‌های عصبی توانایی ارائه‌ی روشهای مناسبتری را برای بالا بردن دقت منحنیهای آماری دارند.

آزمادولا و همکاران (۲۰۰۵، ۲۰۰۶) برای برآورد آبخستگی پایین دست پرش جام اسکی از شبکه‌های عصبی مصنوعی استفاده کرده و نشان دادند که نتایج حاصل از شبکه‌های عصبی رضایت بخشتر از نتایج معادلات وایزی می‌باشند. لیریانو و دی (۲۰۰۱) از شبکه‌های عصبی برای پیش‌بینی ژرفای آبخستگی در دهانه‌ی خروجی آبگذر استفاده کرده و نتایج حاصل از شبکه را با معادلات پیش‌بینی متداول مقایسه نمودند. این محققین نتیجه گرفتند که شبکه‌های عصبی مصنوعی (ANN) ژرفای آبخستگی را با دقت و صحت بیشتری نسبت به روابط تجربی موجود پیش‌بینی می‌کنند.


جنگ و همکاران (۲۰۰۵) ارزیابی ژرفای آبخستگی را پیرامون پایه‌های پل به کمک شبکه‌های عصبی انجام

زمانی که در بستر رودی سازه‌های تنگ کننده جریان نظیر تکیه‌گاه پل، آبشکن و پایه پل قرار می‌گیرند، الگوی جریان سه بعدی به دلیل توسعه‌ی جریان گردابی در مجاورت تنگ شدگی، تغییر می‌کند. در مورد آبشکن‌ها، جریان در وجه بالادست سازه جدا شده، به سمت کناره‌ها رفته و گردابه‌های ایجاد شده به سمت پایین دست حرکت می‌کند، که در نهایت منجر به آبخستگی موضعی ته نشستهای بستر در مجاورت سازه می‌گردند. این آبخستگی موضعی، پی و خود سازه را در معرض خطر ویرانی قرار می‌دهد (شکل ۱). ویرانی پل بر اثر آبخستگی در شالوده‌ی این سازه، که شامل تکیه‌گاه‌ها و پایه‌های آن می‌باشد، رخدادی معمولی به شمار می‌آید. از جمله مسائل مهم در طراحی تکیه‌گاه‌ها، پدیده‌ی آبخستگی موضعی در پیشانی تکیه‌گاه است و یکی از شاخص‌های مهم در تعیین ویژگی‌های حفره آبخستگی، بیشترین ژرفای آبخستگی می‌باشد. پیچیدگی الگوی جریان پیرامون تکیه‌گاههای پل و گوناگونی عوامل مؤثر بر آبخستگی، موجب پرشماری روابط تجربی و کاهش دامنه‌ی هریک از آنها، به دلیل محدودیت شرایط آزمایشگاهی، شده است. از جمله پژوهشگرانی که در این زمینه بررسی‌هایی انجام داده‌اند می‌توان به زاغلول (۱۹۸۳)، ملویل (۱۹۹۲)، کوهنل و همکاران (۱۹۹۹)، بارهویا و دی (۲۰۰۴) و اتما و موسته (۲۰۰۴) اشاره کرد. با این وجود، مسائل زیادی در رابطه با این موضوع هنوز ناشناخته اند. در سالهای اخیر، روشهای پیشرفته‌ای بر مبنای استفاده از روشهای محاسباتی از قبیل منطق‌فازی، شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک و الگوریتمهای موازی ژنتیک مطرح شده‌اند که بطور گسترده در مسائل پیچیده‌ی مهندسی به کار گرفته می‌شوند (لی و همکاران، ۲۰۰۷؛ لین و همکاران ۲۰۰۶).


شبکه‌های عصبی مصنوعی (ANN^۱) ابزار مناسبی برای شبیه‌سازی سامانه‌های غیرخطی می‌باشند. شبکه‌های عصبی مصنوعی شبیه‌های ریاضی ساده شده‌ی شبکه‌های عصبی زیستی را ارائه می‌کنند. این شبکه‌ها در برگیرنده‌ی قابلیت درک و تعمیم راه حل‌های معنی‌دار برای مسائلی از

۱ - Artificial Neural Network

و آبشکنهای نیم‌دایره‌ای تحت شرایط آب زلال برای توسعه‌ی شبیه‌سازی شبکه‌ی عصبی در جدول ۱ آورده شده‌اند. تمامی آزمایشات در منابع مذکور تحت شرایط یکسان آزمایشگاهی انجام گشته و در این تحقیق جمع‌آوری شده‌اند. همان‌طور که از جدول مشخص است ژرفای جریان در آزمایشات بین ۰/۵۸ تا ۰/۲۵ متر، قطر مبه وسیله‌ی ذرات بین ۰/۲۶ تا ۱/۳ متر، سرعت نزدیک شونده بین ۰/۲۱۹ تا ۰/۶۷ متر بر ثانیه و ژرفای آبشستگی بین ۰/۰۵۳ تا ۰/۲۹۳ متر متغیر بوده‌اند. همچنین، طولهای مختلف آبشکن از ۰/۰۴، ۰/۰۶، ۰/۰۸، ۱/۰ و ۱۲/۰ متر برای همه آبشکنها و ۱۳/۰ در یک مورد برای آبشکن نیم‌دایره‌ای متغیر بود. چگالی نسبی ذرات در تمام آزمایشات ۶۵/۲ بود.



شکل ۱- الگوی آبشستگی در پیرامون آبشکن



شکل ۲- شکل‌های مختلف آبشکن

دادند. در این تحقیق مشخص شد که نتایج به دست آمده از ANN از دقت بالاتری در مقایسه با نتایج نظری و آزمایشگاهی برخوردار می‌باشند.

آذر درخش و همکاران (۱۳۸۵) با استفاده از شبکه‌های عصبی پرسپترون چند لایه (MLP^۱) بیشترین ژرفای آبشستگی آبشکن تیغه‌ای را برآورد زدند و بدین نتیجه رسیدند که شبکه‌های عصبی مصنوعی نسبت به سایر روش‌های تجربی از کارایی بیشتری برخوردار است.

دهقانی و همکاران (۱۳۸۸) ژرفای آبشستگی پیرامون آبشکن L- شکل را با استفاده از شبکه‌های عصبی مصنوعی، سامانه‌ی استنتاج فازی عصبی و رابطه‌ی تجربی برآورد کردند. مقایسه‌ی نتایج این سه روش با داده‌های آزمایشگاهی نشان دادند که گرچه شبکه‌ی عصبی مصنوعی عملکرد خوبی در برآورد ژرفای آبشستگی پیرامون آبشکن L- شکل داشت، ولی سامانه‌ی استنتاج فازی عصبی از دقت بیشتری نسبت به دو روش دیگر برخوردار بود.

در تحقیق حاضر با استفاده از شبکه‌های عصبی پرسپترون چند لایه (MLP)، مقادیر بیشترین ژرفای آبشستگی با استفاده از داده‌های آزمایشگاهی مربوط به آبشکنهای با دیواره عمودی، بالدار و نیم‌دایره‌ای شبیه‌سازی شده‌اند. بدین منظور نمایشنامه‌های مختلف مورد بررسی قرار گرفتند. نتایج شبیه‌سازی شبکه‌های عصبی و مقادیر محاسبه شده از رابطه‌ی تجربی پیشنهادی به وسیله‌ی باربیهوا و دی (۲۰۰۴) با داده‌های آزمایشگاهی مقایسه گردیده و مناسبترین نمایشنامه انتخاب شد.

مواد و روش‌ها

محاسبه‌ی (ژرفای تعادل آبشستگی) d_{se}

در تحقیق حاضر، برای توسعه‌ی شبیه‌سازی شبکه‌های عصبی از داده‌های آزمایشگاهی ژرفای تعادل آبشستگی پیرامون آبشکنهای با دیواره عمودی، آبشکنهای بالدار و آبشکنهای نیم‌دایره‌ای که به وسیله‌ی لیم، ۱۹۹۷؛ کولمن و همکاران، ۲۰۰۳؛ باربیهوا و دی، ۲۰۰۴ گزارش شده، استفاده گردیده است (شکل ۲). محدوده تغییرات داده‌های آزمایشگاهی آبشکنهای با دیواره عمودی، آبشکنهای بالدار

۱- Multilayer Perceptron

جدول ۱- محدوده ی تغییرات داده‌های آزمایشگاهی

محدوده	فراسنج
۰۴/۰-۱۳/۰	طول آبشکن $l(m)$
۰۵۸/۰-۲۵/۰	ژرفای جریان $h(m)$
۲۱۹/۰-۶۷/۰	سرعت نزدیک شونده $U(m/s)$
۲۶/۰-۱/۳	اندازه به وسیله ی ذرات $d_{50}(mm)$
۰۵۳/۰-۲۹۳/۰	ژرفای آبستنگی $d_{se}(m)$

تحلیل ابعادی

فراسنجهای مشخصه تأثیرگذار در ژرفای تعادل آبستنگی d_{se} در یک آبشکن با ته نشسته‌های یکنواخت را می‌توان به صورت رابطه ی زیر نوشت (باربهبوا و دی، ۲۰۰۵):

$$d_{se} = f_1(U, \rho_s, \rho, g, l, \nu, h, d_{50}, U_c) \quad (1)$$

در این رابطه، U سرعت جریان، ρ_s جرم مخصوص ذرات رسوبی، l طول آبشکن، ν گرانیوی پویایی، h ژرفای جریان، d_{50} اندازه ی مبه وسیله ی ذرات رسوبی و U_c سرعت بحرانی جریان می‌باشند. برای نشان دادن اثر متقابل بین مایع و رسوب، g ، ρ و ρ_s باید به صورت فراسنجهای وابسته بیان شوند. به هر حال، عبارت Δg یا $(s-1)g$ نماینده ی بهتری از ۳ فراسنج بالا می‌باشد (دبناث و دی، ۲۰۰۱). همچنین، آبستنگی پیرامون یک آبشکن زمانی اتفاق می‌افتد که سرعت جریان نزدیک شونده اضافی $(U_e = U - \varepsilon U_c)$ بزرگتر از صفر باشد. مقدار ε برای آبشکن با دیواره های عمودی، بالدار و نیم دایره‌ای به ترتیب ۵/۰، ۵۵/۰ و ۶/۰ می‌باشد. بنابراین، رابطه (۱) را می‌توان به صورت زیر نوشت:

$$d_{se} = f_2(U_e, \Delta g, l, \nu, h, d_{50}, U_c) \quad (2)$$

با استفاده از نظریه π باکینگهام و انتخاب فراسنجهای U_e و l به عنوان متغیرهای تکراری، رابطه (۲) به صورت فراسنجهای بی بعد زیر ارائه می‌شود:

$$\frac{d_{se}}{l} = f_3\left(\frac{U_e}{(\Delta g l)^{0.5}}, \frac{U_e l}{\nu}, \frac{l}{d_{50}}, \frac{h}{l}, \frac{U}{U_c}\right) \quad (3)$$

که عبارت بی بعد اول را با F_e^1 ، و عبارت بی بعد دوم را با R_e^2 نشان می‌دهند. از تأثیر عدد رینولدز (R_e)، تحت شرایط جریان کاملاً آشفته در یک بستر زبر، می‌توان چشم‌پوشی کرد (ملویل، ۱۹۹۲). بنابراین رابطه ی (۳) را می‌توان به صورت زیر خلاصه کرد (باربهبوا و دی، ۲۰۰۵):

$$\frac{d_{se}}{l} = f_3\left(F_e, \frac{h}{l}, \frac{l}{d_{50}}, \frac{U}{U_c}\right) \quad (4)$$

باربهبوا و دی (۲۰۰۴) رابطه ی زیر را برای به دست آوردن ژرفای آبستنگی آبشکنهای کوتاه در شرایط آب زلال ارائه نموده‌اند:

$$\frac{d_{se}}{l} = 5.16 k_s \left(\frac{h}{l}\right)^{0.18} \left(\frac{U_c}{\sqrt{(s-1)gl}}\right)^{0.26} \quad (5)$$

که در آن d_{se} ژرفای تعادل آبستنگی (m)، l طول آبشکن (m)، h ژرفای جریان (m)، s چگالی مواد رسوبی، U_c سرعت بحرانی جریان (m/s) و k_s فاکتور شکل آبشکن می‌باشند. مقدار فاکتور شکل در آبشکنهای عمودی، بالدار و نیم دایره‌ای به ترتیب ۱، ۷۵/۰ و ۷۵/۰ است (ملویل، ۱۹۹۲). از این رابطه برای مقایسه ی داده های آزمایشگاهی و نتایج شبکه عصبی استفاده شده است.

شبکه‌های پرسپترون چند لایه (MLP)

شبکه‌های چند لایه ای پیشخور یکی از مهمترین ساختارهای شبکه‌های عصبی مصنوعی می‌باشند. بطور معمول، این شبکه‌ها شامل مجموعه‌ای از واحدهای حسی (نرونهای پایه) می‌باشند که متشکل از لایه ورودی، یک یا چند لایه ی پنهان و یک لایه ی خروجی می‌باشند. علامت ورودی در خلال شبکه و در مسیری رو به جلو به صورت لایه به لایه منتشر می‌شود. این نوع شبکه معمولاً با عنوان پرسپترون چند لایه (MLP) نامیده می‌شود (هایکین، ۱۹۹۹). شکل ۳ تصویر شماتیک این نوع شبکه عصبی را نشان می‌دهد.

در تحقیق حاضر، برای شبیه‌سازی با استفاده از شبکه‌های MLP، از یک شبکه ی سه لایه ای پیشخور استفاده شده است، که در آن یک تابع محرک سیگموئید (تانژانت

1- Excess Abutment Froude Number
2- Excess Abutment Reynolds Number

پردازش مقدماتی داده‌ها

برای افزایش بازدهی آموزش، ورودیها و داده‌های هدف شبکه برای قرارگیری در بازه ی [۱، -۱] بهنجار شده است. پس از اتمام آموزش، داده‌های شبیه‌سازی شده با روش معکوس از مقادیر بهنجار شده حاصل می‌گردند.

بهبود قدرت تعمیم‌دهی شبکه

برای تعمیم‌دهی مناسب شبکه، باید به نحوی از آموزش بیش از اندازه جلوگیری کرد. در مطالعه ی حاضر، برای جلوگیری از آموزش بیش از اندازه در شبکه‌های MLP از روش متوقف سازی زود هنگام آموزش استفاده شده است (بی‌نام، ۲۰۰۷). برای تصمیم‌گیری در مورد زمان متوقف ساختن آموزش، داده‌ها به صورت تصادفی به سه مجموعه تقسیم شدند: ۶۰ درصد داده‌ها برای آموزش، ۲۰ درصد برای صحت سنجی و ۲۰ درصد برای آزمون به کار رفتند.

برای متوقف‌سازی زود هنگام، خطا، یعنی تفاوت بین داده‌های هدف اندازه‌گیری شده و مقادیر شبیه‌سازی شده، برای مجموعه ی آموزش، مجموعه ی صحت سنجی و آزمون بطور جداگانه و در هر تکرار آموزش محاسبه می‌گردند. خطا در مجموعه ی صحت‌سنجی بطور عادی در اوایل آموزش کاهش می‌یابد، اما هنگامی که شبکه شروع به آموزش بیش از اندازه داده‌ها می‌کند، خطای مجموعه صحت‌سنجی شروع به افزایش می‌نماید. وقتی این افزایش برای تعداد معینی از تکرارها ادامه می‌یابد، آموزش شبکه متوقف شده و مقادیر وزنها حفظ می‌گردد. مجموعه ی آزمون برای اطمینان از صحت تقسیم داده‌ها به کار می‌رود، به گونه‌ای که تفاوت معنی‌دار خطا در دو مجموعه ی صحت‌سنجی و آزمون نشانگر تقسیم نادرست داده‌ها می‌باشد (صیادی و همکاران، ۱۳۸۸).


نواع عملکرد

عملکرد شبکه ی MLP در برآورد مقادیر d_{se} با استفاده از جذر میانگین مربعات خطا (RMSE) سنجیده شده است. این مقدار از رابطه ی (۸) به دست می‌آید:

$$RMSE = \sqrt{\frac{1}{p} \sum_{i=1}^p [(d_{sm})_i - (d_{ss})_i]^2} \quad (8)$$

که در آن p تعداد داده ها، d_{sm} مقدار به دست آمده از آزمایشها و d_{ss} مقدار برآوردی از شبکه‌های عصبی

هیپربولیک) بین لایه‌ی ورودی و لایه‌ی پنهان و یک تابع محرک خطی بین لایه‌ی پنهان و لایه‌ی خروجی به کار رفته است.



شکل ۳- تصویر ساده طرح شبکه‌ی پرسپترون چند لایه (MLP)

از میان روشهای مختلف آموزش به روش پس انتشار خطا، الگوریتم لونیبرگ - مارکواریت^۱، به دلیل همگرایی سریعتر در آموزش شبکه‌های با اندازه ی مبه و وسیله ی، در تحقیق حاضر استفاده شده است. الگوریتم پس انتشار خطا، وزنها ی شبکه و مقادیر اریبی^۲ را در جهتی تغییر می‌دهد که تابع عملکرد با سرعت بیشتری کاهش یابد. الگوریتم پس انتشار خطا را می‌توان به شکل زیر نشان داد:

$$x_{k+1} = x_k - \alpha_k g_k \quad (6)$$

که در آن x_k بردار وزنها و اریبی در تکرار k ام، α_k نرخ آموزش در تکرار k ام و g_k گرادیان در تکرار k ام می‌باشد. الگوریتم لونیبرگ - مارکواریت که برای دستیابی به آموزش سریعتر شبکه بسط داده شده از رابطه ی (۷) استفاده می‌کند (هایکین، ۱۹۹۹):

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (7)$$


که در آن x_k بردار وزنها و اریبی در تکرار k ام، J ماتریس ژاکوبین شامل اولین مشتقات خطای شبکه با توجه به وزنها و اریبی، e بردار خطاهای شبکه، I ماتریس واحد و μ یک کمیت عددی است. μ پس از هر گام موفق، کاهش می‌یابد و در صورتی که یک گام منفرد، تابع عملکرد را افزایش دهد، μ نیز افزایش می‌یابد. به این ترتیب، تابع عملکرد در هر تکرار الگوریتم کاهش خواهد یافت. در این تحقیق از مقدار اولیه ی ۰.۰۱/۰ برای μ استفاده شده است.

۱. Levenberg-Marquardt

۲. Bias

جدولهای ۳ تا ۵ نتایج کلی محاسبات صورت گرفته برای شبکه‌های MLP را برای سه شبیه آبشکن نشان می‌دهند. چنانچه در جداول مزبور مشخص است، تمام نمایشنامه‌های پیشنهادی دقت قابل قبولی را در برآورد ژرفای آبخستگی آبشکنها دارند. با مقایسه‌ی نتایج مشخص شد که نمایشنامه‌ی ۴ که تنها از دو فراسنج y/l و F_e برای برآورد ژرفای آبخستگی پیرامون آبشکن‌ها استفاده می‌کند می‌تواند به عنوان بهینه‌ترین نمایشنامه انتخاب گردد، زیرا با وجود این که این نمایشنامه از تعداد فراسنجهای کمتری به عنوان ورودی شبکه استفاده می‌نماید ولی دقت آن بیش از نمایشنامه‌های دارای تعداد فراسنج ورودی بیشتر می‌باشد. نکته‌ی دیگری که با توجه به جداول ۳ تا ۵ مشخص می‌گردد این است که شبکه‌های عصبی MLP در برآورد ژرفای آبخستگی آبشکن با دیواره‌ی عمودی، در مقایسه با دیگر آبشکنها از دقت بیشتری برخوردار می‌باشند، بطوری که برای نمایشنامه‌ی بهینه انتخابی، خطای برآورد ژرفای آبخستگی در آبشکن بالدار حدود ۳ برابر و در تکیه‌گاه نیم‌دایره‌ای حدود ۲ برابر بیشتر از آبشکن با دیواره‌ی عمودی است.

در شکل‌های ۴ تا ۶ نتایج به دست آمده از شبکه‌های MLP در مقایسه با داده‌های آزمایشگاهی موجود نمایش داده شده‌اند. ضریب تبیین (R^2) در هر سه مورد بالاتر از ۹۵/۰ است، که نشان‌دهنده‌ی دقت بالای شبکه عصبی MLP در برآورد ژرفای آبخستگی می‌باشد.



شکل ۴- مقایسه‌ی d_s/l محاسبه‌شده با کاربرد روش MLP و داده‌های آزمایشگاهی برای آبشکن بالدار.

می‌باشند. همچنین، برای بی‌بعد سازی مقادیر خطا از $RMSE$ بهنجار (بر حسب درصد) استفاده گردیده است که از رابطه‌ی (۹) بدست می‌آید:

$$NRMSE = \left(\frac{RMSE}{d_{S \max} - d_{S \min}} \right) \times 100 \quad (9)$$

از ضریب نکویی برازش (R^2) نیز برای مقایسه‌ی بین مقادیر برآوردی و مقادیر واقعی استفاده شده است.

نتایج و بحث


انتخاب شبکه‌ی عصبی بهینه

با استفاده از جعبه ابزار شبکه‌های عصبی در MATLAB® و تعریف ۸ نمایشنامه برای فراسنجهای مؤثر، شبکه‌های میپرشماری با ساختارها و فراسنجهای ورودی متفاوت برای برآورد ژرفای بیشترین آبخستگی در سه آبشکن عمودی، بالدار و نیم‌دایره‌ای تعریف شدند. تعداد نرونهای لایه پنهان و نرخ آموزش در شبکه‌های MLP با استفاده از آزمون و خطا تعیین گردید. پس از بررسی ساختارهای متفاوت برای شبکه‌های MLP، با توجه به مقادیر توابع عملکرد، در هر نمایشنامه یک ساختار به عنوان ساختار بهینه انتخاب گردید. جدول ۲ فراسنجهای دخیل در هر نمایشنامه را نمایش می‌دهد.


جدول ۲- فراسنجهای دخیل در نمایشنامه‌های مختلف

شماره نمایشنامه	فراسنجهای ورودی شبکه
۱	$l/d50 - F_e - U/U_C - h/l$
۲	$l/d50 - F_e - h/l$
۳	$l/d50 - F_e$
۴	$F_e - h/l$
۵	$h/l - l/d50$
۶	$l/d50$
۷	F_e
۸	h/l

در آموزش شبکه‌های MLP از ۲ تا ۶ نرون در لایه‌ی پنهان برای تمام نمایشنامه‌های آموزش استفاده شد. در نهایت، پس از انتخاب ساختار بهینه MLP برای هر نمایشنامه و محاسبه‌ی مقادیر توابع عملکرد، این نمایشنامه‌ها با در نظر گرفتن میزان خطای بهنجار ($NRMSE$) رتبه‌بندی شدند.




شکل ۸- مقایسه‌ی ds/L محاسبه‌شده با کاربرد رابطه‌ی تجربی و داده‌های آزمایشگاهی برای آبشکن عمودی.




شکل ۹- مقایسه‌ی ds/L محاسبه‌شده از رابطه‌ی تجربی و داده‌های آزمایشگاهی برای آبشکن نیم دایره‌ای.

مقایسه‌ی شبکه‌های عصبی با رابطه‌ی تجربی

نمودارهای بی‌بعد ژرفای آبشستگی با استفاده از شبکه‌های عصبی، رابطه‌ی تجربی و داده‌های آزمایشگاهی نسبت به نیمساز ربع اول رسم شد. با توجه به شکل‌های ۴ تا ۹ و مقایسه‌ی نتایج حاصل، مشخص می‌گردد که شبکه‌های عصبی MLP در مقایسه با رابطه‌ی تجربی ارائه شده به‌وسیله‌ی باربهیوا و دی (۲۰۰۴) از دقت بسیار بیشتری برای برآورد ژرفای تعادل آبشستگی برخوردارند. شبکه‌های عصبی MLP در برآورد ژرفای آبشستگی آبشکن با دیواره‌ی عمودی در مقایسه با دو نوع آبشکن دیگر از دقت بیشتری برخوردار می‌باشند. همچنین، با تغییر شکل آبشکن از دیواره عمودی به نیم دایره‌ای و از نیم دایره‌ای به بالدار، از دقت شبیه MLP در برآورد ژرفای آبشستگی کاسته می‌شود. شکل‌های ۷ تا ۹ نشان می‌دهد که رابطه‌ی تجربی ارائه شده به‌وسیله‌ی باربهیوا و دی (۲۰۰۴) دقت بالایی برای برآورد ژرفای آبشستگی ندارد، ولی در این حالت نیز در آبشکن با دیواره‌ی عمودی، مقادیر




شکل ۵- مقایسه‌ی ds/L محاسبه‌شده با کاربرد روش MLP و داده‌های آزمایشگاهی برای آبشکن عمودی.



شکل ۶- مقایسه‌ی ds/L محاسبه‌شده با کاربرد روش MLP و داده‌های آزمایشگاهی برای آبشکن نیم دایره‌ای

در شکل‌های ۷ تا ۹ مقایسه بین نتایج حاصل از رابطه‌ی تجربی ارائه شده به وسیله‌ی باربهیوا و دی (۲۰۰۴) و مقادیر آزمایشگاهی موجود نمایش داده شده اند. همان طور که در شکلها مشخص است، ضریب R^2 در سه نوع آبشکن بین ۷۰/۰ تا ۸۲/۰ می باشد. نتایج حاصل از برآورد آبشستگی برای آبشکن با دیواره‌ی عمودی با استفاده از رابطه‌ی تجربی، در مقایسه با دو آبشکن دیگر، همانند نتایج به دست آمده از شبکه‌ی MLP، از دقت بیشتری برخوردارند.



شکل ۷- مقایسه‌ی ds/L محاسبه‌شده با کاربرد رابطه‌ی تجربی و داده‌های آزمایشگاهی برای آبشکن بالدار.

محاسبه شده با کاربرد رابطه مذکور بیشترین تطابق را با داده‌های آزمایشگاهی نشان داد.

جدول ۳- نتایج کلی آموزش و صحت‌سنجی شبکه‌های MLP برای شبیه آبشکن بالدار

رتبه	شماره نمایشنامه	RMSE	R^2 (آموزش)	R^2 (صحت سنجی)	NRMSE (%)
۱	۴	۱۲۷۲/۰	۹۲۵/۰	۹۵۸/۰	۳۶/۶
۲	۵	۱۴۵۵/۰	۹۳۱/۰	۹۴۶/۰	۱۳۵/۷
۳	۶	۱۹۲۶/۰	۹۳۶/۰	۹۴۶/۰	۶۷۳/۸
۴	۱	۲۶۴۳/۰	۹۴۱/۰	۹۳۱/۰	۰۶/۱۰
۵	۲	۲۵۲۴/۰	۹۳۰/۰	۹۱۷/۰	۲۹/۱۱
۶	۳	۲۳۵/۰	۹۱۹/۰	۹۲۳/۰	۶۱/۱۳
۷	۸	۳۲۸۸/۰	۹۰۴/۰	۹۱۲/۰	۲۴/۱۴
۸	۷	۴۹۹۰/۰	۸۹۲/۰	۸۷۶/۰	۴۳/۲۰

جدول ۴- نتایج کلی آموزش و صحت‌سنجی شبکه‌های MLP برای شبیه آبشکن با دیواره عمودی

رتبه	شماره نمایشنامه	RMSE	R^2 (آموزش)	R^2 (صحت سنجی)	NRMSE (%)
۱	۴	۱۲۷۲/۰	۹۸۴/۰	۹۹۲/۰	۲۶۱/۲
۲	۵	۱۴۵۵/۰	۹۸۱/۰	۹۸۱/۰	۹۶۹۴/۲
۳	۱	۱۹۲۶/۰	۹۹/۰	۹۸۸/۰	۲۷۶/۴
۴	۷	۲۶۴۳/۰	۹۵۲/۰	۹۸/۰	۷۴۸/۴
۵	۲	۲۵۲۴/۰	۹۷۲/۰	۹۶۸/۰	۲۱۴/۶
۶	۳	۲۳۵/۰	۹۶۸/۰	۹۷۴/۰	۹۶۹۶/۶
۷	۸	۳۲۸۸/۰	۸۹۶/۰	۹۲۱/۰	۰۸۷۷/۸
۸	۷	۴۹۹۰/۰	۸۵۳/۰	۸۲۳/۰	۲۴۵/۱۴

جدول ۵- نتایج کلی آموزش و صحت‌سنجی شبکه‌های MLP برای شبیه آبشکن نیم دایره ای.

رتبه	شماره نمایشنامه	RMSE	R^2 (آموزش)	R^2 (صحت سنجی)	NRMSE (%)
۱	۴	۱۲۷۲/۰	۹۷۸/۰	۹۷۱/۰	۱۰۶/۵
۲	۵	۱۴۵۵/۰	۹۷۲/۰	۹۶۴/۰	۸۰۵/۵
۳	۱	۱۹۲۶/۰	۹۴۶/۰	۹۵۸/۰	۵۸۴/۶
۴	۳	۲۶۴۳/۰	۰/۹۵۱	۹۵۲/۰	۹۰۲/۷
۵	۲	۲۵۲۴/۰	۹۵۶/۰	۹۴۸/۰	۴۶/۸
۶	۷	۲۳۵/۰	۹۶/۰	۹۱۲/۰	۱۰۳/۹
۷	۶	۳۲۸۸/۰	۹۴۲/۰	۹۱۶/۰	۳۵۷/۱۰
۸	۸	۴۹۹۰/۰	۸۹۵/۰	۸۸/۰	۹۴/۱۸

تحلیل حساسیت

تحلیل حساسیت معمولاً برای معین کردن اهمیت نسبی هر کدام از فرانسجهای مستقل بر فرانسجهای وابسته انجام می‌شود. همه‌ی فرانسجهای مستقل در تحلیل حساسیت مورد بررسی قرار گرفتند. این تحلیل در مورد داده‌های آموزش داده شده برای شبکه انجام گردیده است. نتایج تحلیل حساسیت برای فرانسجهای آبشستگی به

صورت گروهی برای آبشکنهای عمودی و بالدار در جدول

۶ (الف) و (ب) آورده شده‌اند.

این جدولها اثر نسبی هر یک از فرانسجهای مستقل بر کارایی شبکه عصبی را در هر مورد نشان می‌دهند. جدول ۶ (الف) نشان می‌دهد که فرانسج بی بعد h/l بیشترین و کمترین تأثیر را در پیش بینی ژرفای آبشستگی نسبی (d_{se}/l) دارند. همچنین، جدول ۶ (ب) نشان

نتیجه‌گیری

در این تحقیق با استفاده از شبکه‌های عصبی پرسپترون چندلایه (MLP)، اندازه‌های بیشترین ژرفای آبستگی با استفاده از داده‌های آزمایشگاهی مربوط به آبشکن‌های با دیواره عمودی، بالدار و نیم‌دایره‌ای شبیه‌سازی شدند. ۸ نمایشنامه‌ی مختلف براساس فراسنج‌های مؤثر و شبکه‌های پرشماری با ساختارها و فراسنج‌های ورودی متفاوت، برای برآورد ژرفای بیشترین آبستگی در این سه نوع آبشکن تعریف شده و نمایشنامه‌ها با در نظر گرفتن اندازه‌ی خطای بهنجار (NRMSE) رتبه‌بندی شدند. مقایسه‌ی نتایج نمایشنامه‌های مختلف نشان داد نمایشنامه‌های که تنها از دو فراسنج y/l و F_e برای برآورد ژرفای آبستگی در پیرامون آبشکنها استفاده می‌کند از عملکرد بهتری برخوردار است. همچنین نتایج تحلیل حساسیت نشان داد که فراسنج‌های y/l و l/d_{50} بیشترین تأثیر را در پیش‌بینی ژرفای آبستگی آبشکنها دارند. مقایسه‌ی نتایج شبیه‌سازی شبکه‌های عصبی و مقادیر محاسبه شده از رابطه‌ی تجربی پیشنهادی به‌وسیله‌ی باربهبوا و دی (۲۰۰۴) با داده‌های آزمایشگاهی نشان دادند که اندازه‌های بیشترین ژرفای آبستگی به دست آمده با کاربرد روش MLP از دقت بیشتری نسبت به رابطه‌ی تجربی برخوردارند. همچنین، شبکه‌های عصبی MLP در برآورد ژرفای آبستگی آبشکن با دیواره‌ی عمودی، در مقایسه با دو نوع آبشکن دیگر، از دقت بیشتری برخوردار می‌باشند.

می‌دهد که فراسنج بی بعد h/l بیشترین و U/U_c کمترین تأثیر را در برآورد ژرفای آبستگی در آبشکن بالدار دارند. از نتایج این جداول می‌توان نتیجه گرفت که فراسنج‌های h/l و F_e تأثیر بسزایی در پیش‌بینی ژرفای آبستگی آبشکنها دارند. با توجه به تأثیر زیاد ژرفای آب و طول آبشکن در آبستگی پیرامون آبشکنها، تأثیر این دو فاکتور به صورت عدد بی بعد h/l در نتایج کاملاً مشهود است.

جدول ۶- تحلیل حساسیت فراسنج‌های مستقل بدون بعد: الف) آبشکن عمودی-ب) آبشکن بالدار.

الف)		
شبیه ANN	R	RMSE
ALL	۹۹۵/۰	۰۶۴/۰
No U/U_c	۹۸۸/۰	۱۰۸/۰
No h/l	۹۸۴/۰	۱۱۶/۰
No Fe	۹۸۵/۰	۱۱۵/۰
No l/d_{50}	۹۸۷/۰	۱۱۲/۰
ب)		
شبیه ANN	R	RMSE
ALL	۹۸۷/۰	۰۸۳/۰
No U/U_c	۹۷۱/۰	۱۶۲/۰
No h/l	۹۵۹/۰	۱۷۵/۰
No Fe	۹۶۲/۰	۱۷۳/۰
No l/d_{50}	۹۶۸/۰	۱۶۸/۰

سرعت جریان نیز از فراسنج‌های مهم دیگر در آبستگی می‌باشد، که در این تحقیق به صورت عدد بی بعد F_e نمایش داده شده و تأثیر خود را نشان داده است.

References:

1. Anonymous. 2007. Neural network toolbox 5, User's guide, 9th printing version 5. The Mathworks Inc. Massachusetts, USA.
2. Azaraderakhsh, M., Ghodsiyan, M., Norouzi, H. R. (1385). Estimation Maximum Depth of Scour around Abutments Using Artificial Neural Network", 7th International Congress of civil engineering, University of Tarbiat Modares, Tehran. (In Persian)
3. Azmathullah, HM., Deo, MC., Deolalikar, PB. 2005. Neural network for estimation of scour downstream of a skew-jump bucket. , J. Hydraul. Eng, 131(10):898-908.
4. Azmathullah, HM., Deo, MC., Deolalikar, PB. 2006. Estimation of scour below spillways using

- neural network scour downstream of a skew-jump bucket. , J. Hydraul. Eng, 44(1):61-69.
5. Basheer, IA., and Hajmeer, M. 2000. Artificial neural networks: fundamentals, computing, design, and application. J Microbiologic Meth 43: 3-31.
 6. Barbhuya, AK., Dey, S. 2004. Local scour at abutment: a review. Sadhana. 29(5):449-476.
 7. Dehghani, A. A., Hashemi Najafi, S. F., Ayoubzadeh, S. A., Meshkati, M. E. (1388). Intelligent Estimation of Maximum Scour Depth around L-shaped Abutments Using Artificial Neural Network and Interference Nero-Fuzzy System. Journal of Soil and Water Conservation, 16(1), 143-161. (In Persian)
 8. Ettema, R., and Muste., M. 2003. An Overview of Scour Types and Scour-Estimation Difficulties Faced at Bridge Abutments. IIHR, Hydroscience and Engineering. Department of Civil and Environmental Engineering. The Univ. of Iowa, Iowa City, IA 52242.
 9. Haykin, S. 1999. Neural networks: A comprehensive foundation. NJ. Prentice-Hall Inc. Englewood Cliffs. pp. 842.
 10. Jain, SK., Singh, VP., F. ASCE and van Genuchten, MTh. 2004. Analysis of soil water retention data using artificial neural networks. J. Hydrol. Engin. ASCE. 9 (5): 415-420.
 11. Jeng, DS., Bateni, SM., Locket, E. 2005. Neural network Assessment for Scour Depth around Bridge Piers. Research Report NO R855, Department Of Civil Engineering, University Of Sydney, Australia. pp.89.
 12. Kambekar, AR., Deo, MC. 2003. Estimation of Group Pile Scour Using Neural Networks. Applied Ocean Res. 25:225-234.
 13. Kuhnle, R. A., Alonso, C. V., and Shields, F. D. 1999. Geometry of scour holes associated with 90° spur dikes. J. Hydraul. Engin., 125(9):972-978.
 14. Li, WX., Dai, LF., Hou, XB., Lei, W. 2007. Fuzzy Genetic Programming Method for Analysis of Ground Movements Due to Underground Mining. International Journal of Rock Mechanics and Mining Sciences. 44(6):954-961.
 15. Lin, JY., Cheng, CT., Chau, KW. 2006. Using support vector machines for long-term discharge prediction. J. Hydrolog. Engin. 51(4):599-612.
 16. Liriano, SL., Day, RA. 2001. Prediction of scour depth at culvert outlets using neural networks. J. Hydraul Engin, 3(4):231-238.
 17. Melville, BW. 1992. Local scour at bridge abutments. J. Hydraul. Engin, 118(4):615-631
 18. Sayyadi, H., Sadradini, A. A., Farsadizadeh, D., Ghorbani, M. A. (1388). Intelligent Simulation of Sprinkler water Distribution Pattern of Individual Variation in Wind. Journal of Irrigation and Drainage of Iran.1 (3):25-35. (In Persian).
 19. Zaghoul, N.A. 1983. Local scour around spur-dikes. J. Hydrology., 60. 123-140.