

## بررسی عملکرد شبکه‌های عصبی مصنوعی در برآورده بیشترین ژرفای آبشنکن‌ها

پیام خسروی‌نیا<sup>۱</sup>، حبیب صیادی<sup>۱</sup>، علی حسین‌زاده دلیر<sup>۲</sup>، داود فرسادی‌زاده<sup>۲</sup>، رسول میرعباسی‌نجف‌آبادی<sup>۱</sup>

تاریخ دریافت: ۹۰/۰۲/۲۵ تاریخ پذیرش: ۹۰/۱۱/۱۹

### چکیده

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

**واژه‌های کلیدی:** آبشنستگی، آبشنکن، شبکه‌های عصبی، شبکه‌های پرسپترون چندلایه.

۱- دانشجوی دکتری گروه مهندسی آب، دانشگاه تبریز.

۲- دانشیار گروه مهندسی آب، دانشگاه تبریز.

\*- نویسنده‌ی مسؤول:

نمونه‌ها، حتی در مواردی که داده‌های ورودی دارای خطای ناقص باشند، و سازگار نمودن راه حلها با شرایط متغیر و پردازش سریعتر اطلاعات می‌باشند ( بشیر و حاجمیر، ۲۰۰۵؛ آزمادولا و همکاران ۲۰۰۶). 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 غیرخطی) 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 آبشنستگی در سازه‌های مختلف، با استفاده از شبکه‌های عصبی، نیز تاکنون مطالعاتی صورت گرفته‌اند. کامبکر و دئو (۲۰۰۳) کاربرد شبکه‌های عصبی را برای پیش‌بینی ژرفای آبشنستگی پیرامون گروه شمعها بررسی کرده و نشان دادند که شبکه‌های عصبی توانایی ارائه‌ی روش‌های مناسبتری را برای بالابردن دقت منحنیهای آماری دارند.

آزمادولا و همکاران (۲۰۰۶، ۲۰۰۵) برای برآورد آبشنستگی پایین دست پرش جام اسکی از شبکه‌های عصبی مصنوعی استفاده کرده و نشان دادند که نتایج حاصل از شبکه‌های عصبی رضایت‌بخشتر از نتایج معادلات وایازی می‌باشند. لیریانو و دی (۲۰۰۱) از شبکه‌های عصبی برای پیش‌بینی ژرفای آبشنستگی 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 آبشنستگی را با دقت و صحت بیشتری نسبت به روابط تجربی موجود پیش‌بینی می‌کنند.

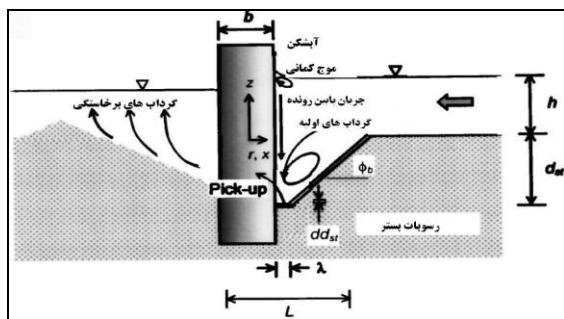
جنگ و همکاران (۲۰۰۵) ارزیابی ژرفای آبشنستگی را پیرامون پایه‌های پل به کمک شبکه‌های عصبی انجام

## مقدمه

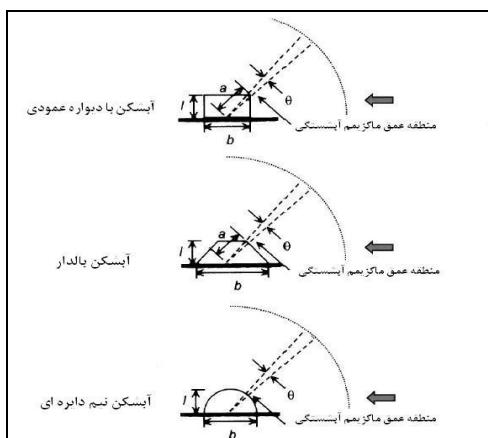
زمانی که در بستر رودی سازه‌های تنگ کننده جریان نظری تکیه‌گاه پل، آبشکن و پایه‌پل قرار می‌گیرند، الگوی جریان سه بعدی به دلیل توسعه‌ی جریان گردابی در مجاورت تنگ شدگی، تغییر می‌کند. در مورد آبشکن‌ها، جریان در وجه بالادست سازه جدا شده، به سمت کناره‌ها رفته و گردابه‌های ایجاد شده به سمت پایین دست حرکت می‌کند، که در نهایت منجر به آبشنستگی موضعی ته نشستهای بستر در مجاورت سازه می‌گردد. این آبشنستگی موضعی، پی و خود سازه را در معرض خطر ویرانی قرار می‌دهد (شکل ۱). ویرانی پل بر اثر آبشنستگی در شالوده‌ی این سازه، که شامل تکیه‌گاهها و پایه‌های آن می‌باشد، رخدادی معمولی به شمار می‌آید. از جمله مسائل مهم در طراحی تکیه‌گاهها، پدیده‌ی آبشنستگی موضعی در پیشانی تکیه‌گاه است و یکی از شاخص‌های مهم در تعیین ویژگی‌های حفره‌ی آبشنستگی، بیشترین ژرفای آبشنستگی می‌باشد. پیچیدگی الگوی جریان پیرامون تکیه‌گاههای پل و گوناگونی عوامل مؤثر بر آبشنستگی، 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)، باربهیوا و دی (۲۰۰۴) و اتما و موسته (۲۰۰۴) اشاره کرد. با این وجود، مسائل زیادی در رابطه با این موضوع هنوز ناشناخته‌اند. در سالهای اخیر، روش‌های پیشرفت‌هایی 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) 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

و آبشکن‌های نیم‌دایره‌ای تحت شرایط آب زلال برای توسعه‌ی شبیه‌شبکه‌ی 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  $0.058/0.25$  متر، قطر مبه وسیله‌ی ذرات بین  $0.026/0.026$  تا  $0.0219/0.067$  متر بر ثانیه و ژرفای آبشستگی بین  $0.053/0.293$  تا  $0.06/0.04$  متر متغیر بوده‌اند. همچنین، طولهای مختلف آبشکن از  $0.01/0.06$ ،  $0.01/0.08$  و  $0.01/0.12$  متر برای همه آبشکنها و  $0.13/0.01$  در یک مورد برای آبشکن نیم‌دایره‌ای متغیر بود. چگالی نسبی ذرات در تمام آزمایشات  $2/65$  بود.



شکل ۱- الگوی آبشستگی در پیرامون آپشنکن



شکل ۲- شکل‌های مختلف آپشنکن

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

آذردرخش و همکاران (۱۳۸۵) با استفاده از شبکه‌های عصبی پرسپترون چند لایه (MLP) بیشترین ژرفای آپشنکنی آپشنکن تیغه‌ای را برآورد زندند و بدین نتیجه رسیدند که شبکه‌های عصبی مصنوعی نسبت به سایر روش‌های تجربی از کارایی بیشتری برخوردار است.

دهقانی و همکاران (۱۳۸۸) ژرفای آپشنکنی پیرامون آپشنکن 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 آپشنکنی پیرامون آپشنکن 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 آپشنکنی با استفاده از داده‌های آزمایشگاهی مربوط به آپشنکن‌های با دیواره عمودی، بالدار و نیم‌دایره‌ای شبیه‌سازی شده‌اند. بدین منظور نمایشنامه‌های مختلف مورد بررسی قرار گرفتند. نتایج شبیه‌شبکه عصبی و مقادیر محاسبه شده از رابطه‌ی تجربی پیشنهادی به وسیله‌ی باربیووا و دی (۲۰۰۴) با داده‌های آزمایشگاهی مقایسه گردیده و مناسبترین نمایشنامه انتخاب شد.

## مواد و روش‌ها

### محاسبه‌ی (ژرفای تعادل آپشنکنی) $d_{se}$

در تحقیق حاضر، برای توسعه‌ی شبیه‌شبکه عصبی از داده‌های آزمایشگاهی ژرفای تعادل آپشنکنی پیرامون آپشنکن‌های با دیواره‌ی عمودی، آپشنکن‌های بالدار و آپشنکن‌های نیم‌دایره‌ای که به وسیله‌ی لیم، ۱۹۹۷؛ کولمن و همکاران، ۲۰۰۳؛ باربیووا و دی، ۲۰۰۴ گزارش شده، استفاده گردیده است(شکل ۲). محدوده تغییرات داده‌های آزمایشگاهی آپشنکن‌های با دیواره‌ی عمودی، آپشنکن‌های بالدار

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 زیر، می‌توان چشم پوشی کرد (ملویل، ۱۹۹۲). بنابراین رابطه‌ی (۳) را می‌توان به صورت زیر خلاصه کرد (باربیو و دی، ۲۰۰۵):

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

باربیو و دی (۲۰۰۴) رابطه‌ی زیر را برای به دست آوردن ژرفای آشستگی 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 آشستگی ( $m$ )،  $l$  طول آبشکن ( $m$ )،  $h$  ژرفای جریان ( $m$ )،  $s$  چگالی مواد رسوبی،  $U_c$  سرعت بحرانی جریان ( $m/s$ ) و  $k_s$  فاکتور شکل آبشکن‌های عمودی، بالدار و نیم دایره‌ای به ترتیب ۱، ۰/۷۵ و ۰/۷۵ است (ملویل، ۱۹۹۲). از این رابطه برای مقایسه‌ی داده‌های 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 متتشکل از لایه ورودی، یک یا چند لایه‌ی پنهان و یک لایه‌ی خروجی می‌باشد. 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 شبکه‌ی سه لایه ای پیشخور استفاده شده است، که در آن یک تابع محرک سیگموئید (تائزانت

جدول ۱- محدوده‌ی تغییرات داده‌های آزمایشگاهی

فراسنج	محدوده
۱ طول آبشکن ( $l(m)$ )	۰/۰۴۰-۰/۱۳
۲ ژرفای جریان ( $h(m)$ )	۰/۰۵۸-۰/۲۵
۳ سرعت نزدیک شونده ( $U(m/s)$ )	۰/۲۱۹-۰/۶۷
۴ اندازه‌ی وسیله‌ی ذرات ( $d_{50}(mm)$ )	۰/۲۶-۳/۱
۵ ژرفای آشستگی ( $d_{se}(m)$ )	۰/۰۵۳-۰/۲۹۳

### تحلیل ابعادی

فراسنجهای مشخصه تأثیرگذار در ژرفای تعادل آشستگی  $d_{se}$  در یک آبشکن با ته نشستهای یکنواخت را می‌توان به صورت رابطه‌ی زیر نوشت (باربیو و دی، ۲۰۰۵):

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

در این رابطه،  $U$  سرعت جریان،  $\rho_s$  جرم مخصوص ذرات رسوبی،  $l$  طول آبشکن،  $v$  گرانش پویایی،  $h$  ژرفای جریان،  $d_{50}$  اندازه‌ی مبه وسیله‌ی ذرات رسوبی و  $U_c$  سرعت بحرانی جریان می‌باشد. برای نشان دادن اثر متقابل بین مایع و رسوب،  $g$ ،  $\rho$  و  $\rho_s$  باید به صورت فراسنجهای وابسته بیان شوند. به هر حال، عبارت  $\Delta g$  یا  $(s-1)g$  نماینده‌ی بهتری از ۳ فراسنج بالا می‌باشد (دبناش و دی، ۲۰۰۱). همچنین، آشستگی پیرامون یک آبشکن زمانی اتفاق می‌افتد که سرعت جریان نزدیک شونده اضافی ( $U_e = U - \varepsilon U_c$ ) بزرگتر از صفر باشد. مقدار  $\varepsilon$  برای آبشکن با دیواره‌های عمودی، بالدار و نیم دایره‌ای به ترتیب ۰/۰۵۵، ۰/۰۵۵ و ۰/۰۶ می‌باشد. بنابراین، رابطه (۱) را می‌توان به صورت زیر نوشت:

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

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

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

## پردازش مقدماتی داده‌ها

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

### بهبود قدرت تعمیم‌دهی شبکه

برای تعمیم‌دهی مناسب شبکه، باید به نحوی از آموزش بیش از اندازه جلوگیری کرد. در مطالعه‌ی 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، خطأ، یعنی تفاوت بین داده‌های هدف اندازه‌گیری شده و مقادیر شبیه‌سازی شده، برای مجموعه‌ی آموزش، مجموعه‌ی صحت سنجی و آزمون بطور جداگانه و در هر تکرار آموزش محاسبه می‌گردد. خطأ در مجموعه‌ی صحت سنجی بطور عادی در اوایل آموزش کاهش می‌یابد، اما هنگامی که شبکه شروع به آموزش بیش از اندازه داده‌ها می‌کند، خطای مجموعه‌ی صحت سنجی شروع به افزایش می‌نماید. وقتی این افزایش برای تعداد معینی از تکرارها ادامه می‌یابد، آموزش شبکه متوقف شده و مقادیر وزنها حفظ می‌گردد. مجموعه‌ی آزمون برای اطمینان از صحت تقسیم داده‌ها به کار می‌رود، به گونه‌ای که تفاوت معنی‌دار خطأ در دو مجموعه‌ی صحت سنجی و آزمون نشانگر تقسیم نادرست داده‌ها می‌باشد (صیادی و همکاران، ۱۳۸۸).

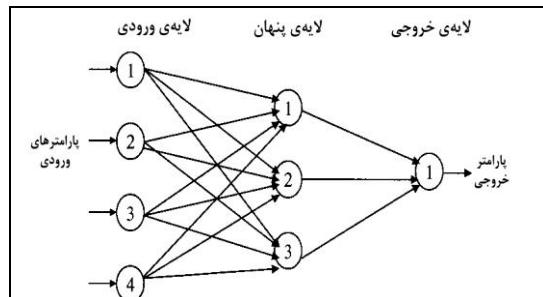
### تابع عملکرد

عملکرد شبکه‌ی MLP در برآورد مقادیر  $d_{se}$  با استفاده از جذر میانگین مربعات خطأ (RMSE) سنجیده شده است. این مقدار از رابطه‌ی (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 داده‌ها،  $d_{sm}$  مقدار به دست آمده از آزمایشها و  $d_{ss}$  مقدار برآورده از شبکه‌های عصبی

هیپربولیک) بین لایه‌ی ورودی و لایه‌ی پنهان و یک تابع حرک خطي 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 خطأ، الگوریتم لونبرگ - مارکوارت<sup>۱</sup>، به دلیل همگرایی سریعتر در آموزش شبکه‌های با اندازه‌ی میله وسیله‌ی، در تحقیق حاضر استفاده شده است. الگوریتم پس انتشار خطأ، وزن‌های شبکه و مقادیر اریبی<sup>۲</sup> را در جهت تغییر می‌دهد که تابع عملکرد با سرعت بیشتری کاهش یابد. الگوریتم پس انتشار خطأ 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،  $\alpha_k$  نرخ آموزش در تکرار  $k$  ام و  $g_k$  گرادیان در تکرار  $k$  ام می‌باشد. الگوریتم لونبرگ - مارکوارت که برای دستیابی به آموزش سریعتر شبکه بسط داده شده از رابطه‌ی (۷) استفاده می‌کند (هایکین، ۱۹۹۹):

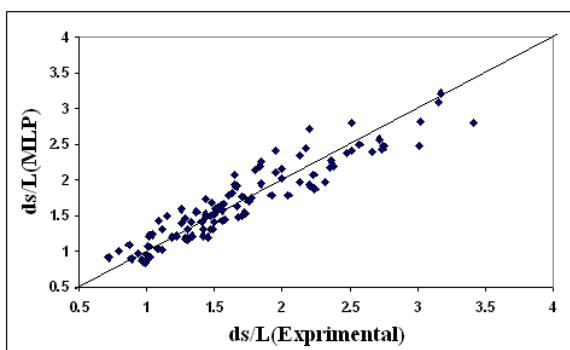
$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (7)$$

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  $\mu$  یک کمیت عددی است.  $\mu$  پس از هر گام موفق، کاهش می‌یابد و در صورتی که یک گام منفرد، تابع عملکرد را افزایش دهد،  $\mu$  نیز افزایش می‌یابد. به این ترتیب، تابع عملکرد در هر تکرار الگوریتم کاهش خواهد یافت. در این تحقیق از مقدار اولیه‌ی  $1 \times 10^{-4}$  برای  $\mu$  استفاده شده است.

1 . Levenberg-Marquardt  
2 . Bias

جدولهای ۳ تا ۵ نتایج کلی محاسبات صورت گرفته برای شبکه‌های MLP را برای سه شبیه آبشکن نشان می‌دهند. چنانچه در جداول مذبور مشخص است، تمام نمایشنامه‌های پیشنهادی دقت قابل قبولی را در برآورد ژرفای آبستگی آبشکنها دارند. با مقایسه‌ی نتایج مشخص شد که نمایشنامه‌ی ۴ که تنها از دو فراسنج  $l/y$  و  $F_e$  برای برآورد ژرفای آبستگی 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 آبستگی آبشکن با دیواره‌ی عمودی، در مقایسه با دیگر آبشکنها از دقت بیشتری برخوردار می‌باشند، بطوری که برای نمایشنامه‌ی بهینه انتخابی، خطای برآورد ژرفای آبستگی 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 ۰/۹۵ است، که نشان‌دهنده‌ی دقت بالای شبکه عصبی MLP در برآورد ژرفای آبستگی می‌باشد.



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

می‌باشد. همچنین، برای بی‌بعد سازی مقادیر خطای RMSE بهنجر (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 برآورده و مقادیر واقعی استفاده شده است.

## نتایج و بحث

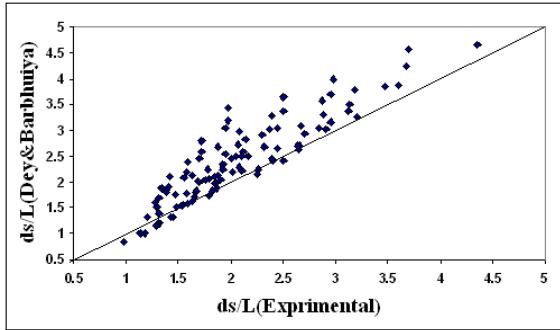
### انتخاب شبکه‌ی عصبی بهینه

با استفاده از جعبه ابزار شبکه‌های عصبی در MATLAB® و تعریف ۸ نمایشنامه برای فراسنجهای مؤثر، شبکه‌های مپرشاریی با ساختارها و فراسنجهای ورودی متفاوت برای برآورد ژرفای بیشترین آبستگی در سه آبشکن عمودی، بالدار و نیم‌دایره‌ای تعریف شدند. تعداد نمونه‌ای لایه پنهان و نرخ آموزش در شبکه‌های MLP با استفاده از آزمون و خطای 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.

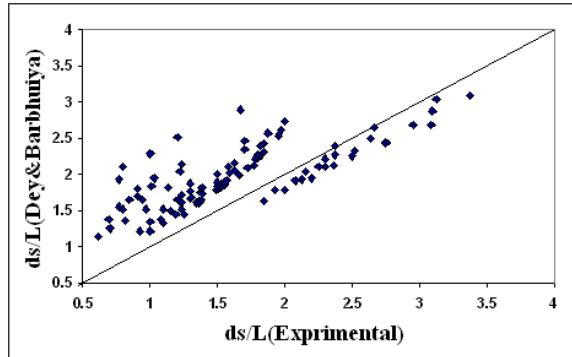
### جدول ۲- فراسنجهای دخیل در نمایشنامه‌های مختلف

شماره نمایشنامه	فراسنجهای ورودی شبکه
۱	$l/d_{50} - F_e - U/U_C - h/l$
۲	$l/d_{50} - F_e - h/l$
۳	$l/d_{50} - F_e$
۴	$F_e - h/l$
۵	$h/l - l/d_{50}$
۶	$l/d_{50}$
۷	$F_e$
۸	$h/l$

در آموزش شبکه‌های MLP از ۲ تا ۶ نمون 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 بهنجر (NRMSE) رتبه‌بندی شدند.



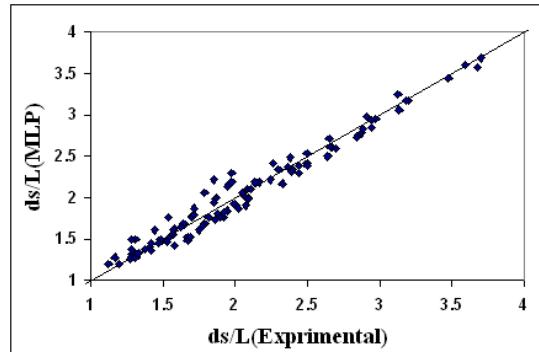
شکل ۸- مقایسه‌ی  $dS/I$  محاسبه شده با ارباب رابطه‌ی تجربی و داده‌های آزمایشگاهی برای آبشکن عمودی.



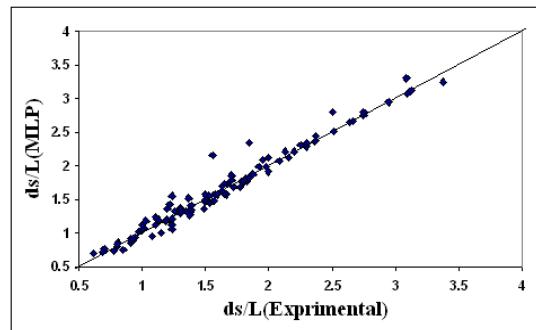
شکل ۹- مقایسه‌ی  $dS/I$  محاسبه شده از رابطه‌ی تجربی و داده‌های آزمایشگاهی برای آبشکن نیم دایره‌ای.

#### مقایسه‌ی شبکه‌های عصبی با رابطه‌ی تجربی

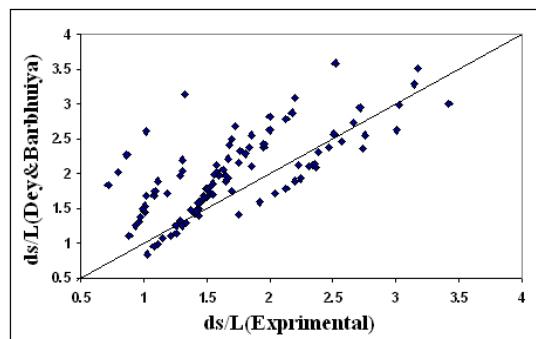
نمودارهای بی بعد ژرفای آبشستگی با استفاده از شبکه‌های عصبی، رابطه‌ی تجربی و داده‌های آزمایشگاهی نسبت به نیمساز ربع اول رسم شد. با توجه به شکل‌های ۴ تا ۹ و مقایسه‌ی نتایج حاصل، مشخص می‌گردد که شبکه‌های عصبی MLP در مقایسه با رابطه‌ی تجربی ارائه شده به وسیله‌ی باربهیوا و دی (۲۰۰۴) از دقت بسیار بیشتری برای 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 به وسیله‌ی 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  $dS/I$  محاسبه شده با کاربرد روش MLP و داده‌های آزمایشگاهی برای آبشکن عمودی.



شکل ۶- مقایسه‌ی  $dS/I$  محاسبه شده 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. همان‌طور که در شکل‌ها مشخص است، ضریب  $R^2$  در سه نوع آبشکن بین ۰/۷۰ تا ۰/۸۲ می‌باشد. 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  $dS/I$  محاسبه شده 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

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

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

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

جدول ۵- نتایج کلی آموزش و صحتسنجی شبکه‌های MLP برای شبیه آبشکن نیم دایره‌ای

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

صورت گروهی برای آبشکن‌های عمودی و بالدار در جدول

۶ (الف) و (ب) آورده شده است.

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

### تحلیل حساسیت

تحلیل حساسیت معمولاً برای معین کردن اهمیت نسبی هر کدام از فراسنجهای مستقل بر فراسنجهای وابسته انجام می‌شود. همه‌ی فراسنجهای 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 فراسنجهای آبشستگی به

## نتیجه‌گیری

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

## References:

- Anonymous. 2007. Neural network toolbox 5, User's guide, 9th printing version 5. The Mathworks Inc. Massachusetts, USA.
- Azaraderakhsh, M., Ghodsiyan, M., Norouzi, H. R.(1385). Estimation Maximum Depth of Scour around Abutments Using Artificial Neural Network", 7th International

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

جدول ۶- تحلیل حساسیت فراسنج‌جهای مستقل بدون بعد:

(الف) آبشنکن عمودی-ب) آبشنکن بالدار.

ANN	شبیه	R	RMSE
ALL	.۹۹۵	.۰۶۴	
No $U/U_c$	.۹۸۸	.۱۰۸	
No $h/l$	.۹۸۴	.۱۱۶	
No Fe	.۹۸۵	.۱۱۵	
No $l/d_{50}$	.۹۸۷	.۱۱۲	

ANN	شبیه	R	RMSE
ALL	.۹۸۷	.۰۸۳	
No $U/U_c$	.۹۷۱	.۱۶۲	
No $h/l$	.۹۵۹	.۱۷۵	
No Fe	.۹۶۲	.۱۷۳	
No $l/d_{50}$	.۹۶۸	.۱۶۸	

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

Congress of civil engineering, University of Tarbiat Modares, Tehran.(In Persian)

- 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., Sadradiani, 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. Zaghloul, N.A. 1983. Local scour around spur-dikes. J. Hydrology., 60. 123-140.