

## تخمین خوردند سیمان پرده آب‌بند با استفاده از شبکه‌ی عصبی مصنوعی

مهرداد پسندی

عضو هیات علمی گروه زمین شناسی، دانشگاه اصفهان

رسول اجل لوئیان

عضو هیات علمی گروه زمین شناسی، دانشگاه اصفهان

رضا فروغی ابری

کارشناس ارشد ژئوتکنیک

تاریخ پذیرش: ۹۲/۳/۲۶

تاریخ دریافت: ۹۱/۱/۲۱

*m.pasandi@sci.ui.ac.ir*

### چکیده

در پروژه‌های سد سازی عملیات احداث پرده آب‌بند یکی از پر هزینه ترین مراحل می‌باشد. بنابراین تخمین هزینه مورد نیاز در این بخش از اهمیت ویژه‌ای برخوردار است. عمدتاً هزینه عملیات تزریق بر اساس هزینه مواد که خود بر اساس میزان خوردند سیمان است، محاسبه می‌شود. از آنجایی که ارتباط بین فاکتورهای تاثیرگذار بر عملیات تزریق پیچیده و بعضاً مبهم می‌باشد و باید به طریقی رابطه منطقی بین این فاکتورها را شبیه‌سازی کرد. بدین منظور در این پژوهش از شبکه عصبی مصنوعی برای تعیین میزان خوردند سیمان بخشی از پرده آب‌بند سد بختیاری بر اساس پارامترهایی چون لوژان، شرایط زمین‌شناسی، ناپیوستگی‌ها، عمق، حالت لوژان و فشار تزریق استفاده گردیده است. خوردند سیمان به توسط روش‌های رگرسیون دو متغیره و چند متغیره نیز تخمین زده شده که مقایسه تخمین خوردند سیمان بوسیله روش‌های مذکور دلالت بر برتری روش شبکه عصبی دارد.

**کلمات کلیدی:** تزریق پرده آب‌بند، شبکه‌ی عصبی مصنوعی، رگرسیون چند متغیره، سد بختیاری

### مقدمه

در رابطه فوق Lu عدد لوژان، V حجم خوردند آب بر حسب لیتر،  $P_s$  فشار تزریق استاندارد (۹۸۱ کیلوپاسکال)، T زمان تزریق (دقیقه)،  $P_i$  فشار استفاده شده (کیلوپاسکال) و L طول مقطع تزریق (متر) می‌باشند. عدد لوژان بهترین پارامتر برای بیان حالت ناپیوستگی‌های درون فونداسیون سد است و از لحاظ تئوری تعریف رابطه‌ی میان عدد لوژان و خوردند سیمان دشوار می‌باشد (Yamaguchi and Matsumoto, 1989; Hirota et al, 1990). افزون بر این هنگامی که محققان از تجارب قبلی در تخمین خوردند سیمان جهت ساختگاه سد بهره می‌گیرند، با مشکل خصوصیات زمین شناسی متفاوت مواجه می‌گردند. به دلیل فرآیندهای فیزیکی نامشخص مرتبط با تشکیل خاک و سنگ، خصوصیات مهندسی این مواد رفتار متفاوت و غیر قطعی بروز می‌دهند. جهت سازگاری با پیچیدگی رفتار ژئوتکنیکی و تغییرات مکانی این مواد، اشکال مرسوم مدل‌های طراحی مهندسی بطور قابل توجیهی ساده می‌شوند. یک راهبرد جایگزین تحت عنوان شبکه‌ی عصبی مصنوعی ANNs تنها بر اساس داده‌ها، ساختار و پارامترهای مدل را تعیین می‌نماید و جهت شبیه سازی مسائل پیچیده که ارتباط میان متغیرهای مدل نامعلوم است، بسیار مناسب می‌باشد (Hubick, 1992).

سنگ بستر عمدتاً دارای ناپیوستگی‌هایی از قبیل گسل‌ها، چین‌ها، صفحات لایه بندی، درزه‌ها و شکاف‌هایی می‌باشد که بر روی نفوذ پذیری، مقاومت برشی و تغییر شکل سنگ اثر مستقیم دارند. از این رو قبل از ساخت سد لازم است جهت ایجاد یک محیط آب‌بند، شالوده سد مورد بهسازی قرار گیرد. استفاده از تزریق سیمان جهت بهسازی سنگ بستر امری متداول می‌باشد (Baker, 1982; Verfel, 1989; Hously, 1990; Jsidre, 1994) و در پروژه‌های مختلفی خواص مهندسی سنگ با استفاده از سیمان بهبود یافته است (Ewert, 1985; Weaver, 1991). به هر حال بدلیل عدم شناخت شرایط زیر زمین، تخمین خوردند سیمان امری دشوار می‌باشد.

عموماً وضعیت بازشدگی‌های درون زمین بطور غیرمستقیم بوسیله‌ی عدد لوژان که توسط آزمایش فشار آب تعیین می‌شود، بیان می‌گردد. همچنین از اطلاعات بدست آمده از آزمایش فشار آب می‌توان جهت تعیین نسبت آب به سیمان و میزان فشار در فرآیند تزریق استفاده نمود. عدد بالای لوژان نشانگر بازشدگی سنگ و در نتیجه خوردند بالای سیمان در حین بهسازی می‌باشد. عدد لوژان توسط رابطه‌ی ذیل محاسبه می‌گردد (Foyo and Sanchez, 2005):

$$Lu = \frac{VP_s}{TP_iL} \quad (1)$$

خاکستری) با میان لایه‌های مارنی و شیلی (به رنگ تازه خاکستری تیره مایل به سیاه و رنگ هوازگی ملایم خاکستری نسبتاً تیره) دارای ساختمان نواری تشکیل شده است. ضخامت لایه‌های آهک مارنی بین ۰/۱۵ تا ۰/۴ متر و ضخامت لایه‌های مارنی-شیلی بین ۳ تا ۱۵ سانتیمتر است. میان لایه‌های مارنی-شیلی در قسمتهای سطحی در امتداد لایه بندی بصورت ورقه‌های نازک درمی‌آیند. بخش SV3 از تناوب لایه‌های آهک مارنی به رنگ تازه خاکستری تیره مایل به سیاه و رنگ هوازگی ملایم خاکستری و آهک سیلیسی به رنگ تازه خاکستری تیره و رنگ‌های هوازگی ملایم قهوه‌ای روشن مایل به قرمز و قهوه‌ای تیره مایل به سیاه تشکیل شده است. ضخامت لایه‌های آهکی بین ۱۰ تا ۳۰ سانتی متر و ضخامت لایه‌های آهک سیلیسی بین ۵ تا ۲۰ سانتیمتر است. بخش SV4 از آهک متوسط تا ضخیم لایه به رنگ تازه خاکستری تیره و رنگ هوازگی ملایم خاکستری دارای گرهک‌هایی (Nodules) از آهک سیلیسی و به ندرت چرت با میان لایه‌هایی از مارن تشکیل شده است. بخش SV5 از آهک ضخیم تا خیلی ضخیم لایه گرهکدار (Nodular) تشکیل شده است. رنگ آهک در مقطع تازه خاکستری تیره و در سطوح با هوازگی ملایم، خاکستری است (مه‌آب قدس، ۱۳۸۰).



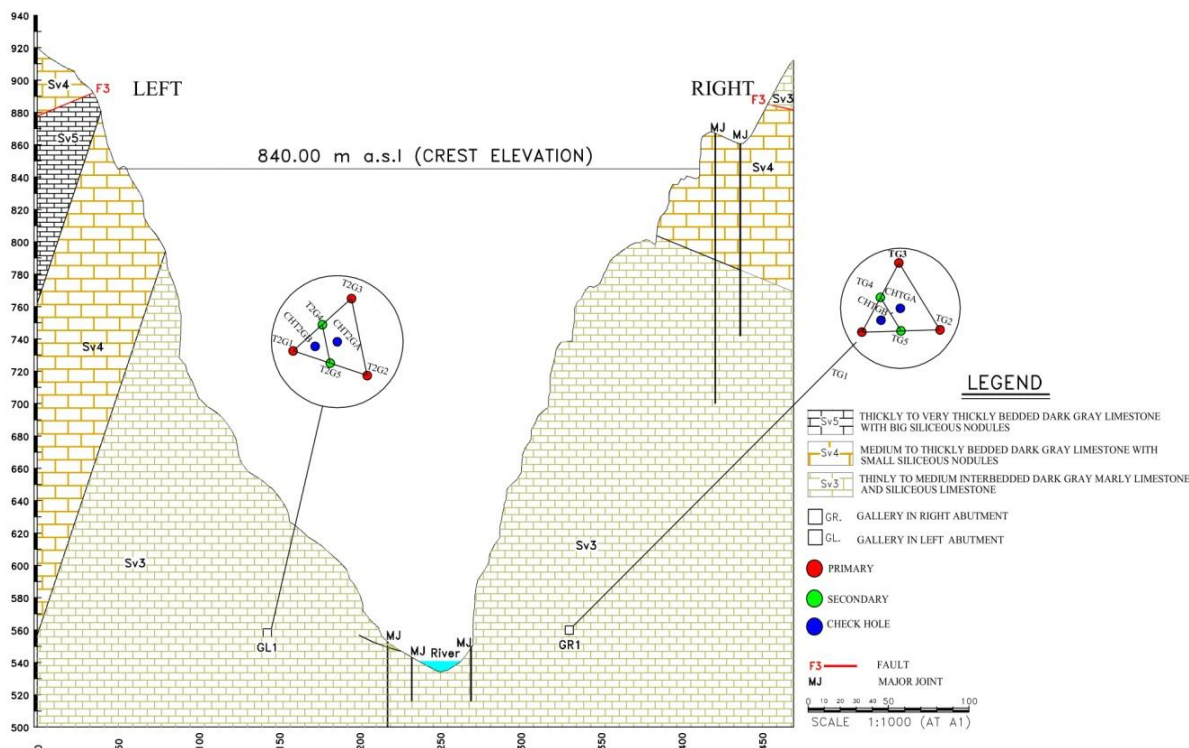
شکل ۱. موقعیت سد بختیاری در نقشه‌ی ایران

در سالهای اخیر استفاده فزاینده از شبکه‌های عصبی مصنوعی (ANNs) در بسیاری از زمینه‌های تحقیقی مهندسی و از جمله مهندسی ژئوتکنیک موفقیت قابل توجهی داشته و کاربرد گسترده‌ای در مکانیک سنگ، ژئوتکنیک و زمین شناسی مهندسی یافته است و برای حل مسائلی که ارتباط بین متغیرهای مدل بخوبی مشخص نیست، بکار رفته است (Hubick, 1992; Millar and Clarici, 1994). از جمله مطالعات صورت گرفته در ژئوتکنیک می‌توان تحقیق Goh (1994) را برشمرد که از روش شبکه عصبی برای بررسی پتانسیل روانگرایی خاک استفاده کرده است. Goh (1995) همچنین شبکه عصبی را جهت تخمین ظرفیت اصطکاکی شمعها در رس بکار برده است. Yang and Zhang (1997) آزمون بار نقطه‌ای را به توسط شبکه عصبی مصنوعی تجزیه و تحلیل نموده اند. (Chang and Chao (2006) از شبکه عصبی پس انتشار جهت تخمین جریان واریزه بهره گرفته اند. (Moosavi et al. (2006) از شبکه عصبی جهت شبیه سازی فشار تورم دوره ای سنگ رسی استفاده نموده‌اند. (Zorlu et al. (2008) دو مدل مختلف رگرسیون چند متغیره و ANN را جهت تخمین مقاومت فشاری تک محوری ماسه سنگها بکار برده اند. (Gomez and Kavzoglu (2008); Lee et al. (2004) و Nefeslioglu et al. (2008) در مطالعه‌های موردی متفاوت از روش شبکه عصبی مصنوعی جهت ارزیابی و تهیه نقشه آسیب پذیری زمین لغزش استفاده نموده اند.

(Maji and Sitharan (2008) از شبکه عصبی مصنوعی جهت تخمین مدول الاستیکی توده سنگهای درزه و شکافدار استفاده کرده‌اند. این کاربردها نشان می‌دهند که مدل شبکه عصبی در حل مسائلی که در آنها پارامترهای بسیاری در فرآیند و نتایج ممکن است تاثیرگذار باشند و نتایج بخوبی درک نمی‌شوند و همچنین در حالتیکه داده‌های تاریخی یا تجربی در دسترس هستند، حائز اولویت است. Yang (2004) بوسیله روش‌های متوسط گیری، رگرسیون خطی و شبکه پس انتشار داده‌های پرده آب‌بند سد Li-Yu-Tan واقع در شمال تایوان را جهت تخمین میزان خوردن سیمان تجزیه و تحلیل نموده است. در این پژوهش تخمین خوردن سیمان جهت ساخت پرده آب‌بند سد بختیاری از طریق روشهای رگرسیون دو متغیره و چند متغیره و همچنین شبکه عصبی مصنوعی پس انتشار (BPN)، مورد ارزیابی و مقایسه قرار گرفته تا بتوان مدلی ساده و درعین حال کارآمد برای پیشبینی خوردن سیمان ارائه نمود.

### موقعیت جغرافیایی و زمین شناسی منطقه

ساختمان سد بختیاری در قسمت جنوب غربی ایران، در حدود ۷۰ کیلومتری شمال شرقی شهر اندیمشک و حدود ۶۵ کیلومتری جنوب غربی شهر دورود لرستان قرار دارد (شکل ۱). نقطه مرکزی محور سد دارای مختصات ۲۹۰۷۲۵ متر طول شرقی و ۳۶۴۸۷۲۹ متر عرض شمالی است. هدف از احداث این سد بتنی تولید انرژی از طریق احداث نیروگاه برقابی می‌باشد (مه‌آب قدس، ۱۳۸۰). گستره ساختمان و مخزن سد بختیاری در استان ساختاری - چینه شناختی زاگرس چین خورده قرار گرفته است. محور سد را کلاً سازند سروک پوشش می‌دهد که خود به پنج بخش SV1، SV2، SV3، SV4، SV5 و تقسیم می‌شود (شکل ۲). بخش SV1 در گستره ساختمان سد و سازه‌های جانبی و نیروگاه رخنمون ندارد. بخش SV2 از آهک مارنی (به رنگ تازه خاکستری تیره و رنگ هوازگی ملایم



شکل ۲. مقطع عرضی زمین شناسی ساختگاه سد بختیاری به همراه موقعیت گالری‌ها و گمانه‌های تزریق

پرکردن حفرات افزایش داده شود، این فشار می‌تواند باعث وقوع پدیده شکست هیدرولیکی و هدر رفتن مقدار زیادی سیمان شود. طبق تجربه، فشار تزریق بایستی در محدوده بین ۵۰۰ تا ۱۰۰۰ کیلوپاسکال بر طبق اصل افزایش ۳۰ کیلوپاسکال به ازای هر متر عمق اعمال گردد (Yang, 2004)

### عدد لوژان

مهمترین عاملی که براساس آن می‌توان تزریق پذیری منطقه را مورد ارزیابی قرار داد، عدد لوژان است. معمولاً منطقه‌ای که لوژان بالایی دارد خوردن سیمان بالایی نیز دارا است، مگر در صورت وجود درزه‌های مویین متعدد که با وجود لوژان بالا، خوردن به علت لزجت سیمان زیاد نمی‌باشد.

### بازشدگی درزه‌ها

بدیهی است هر اندازه میزان بازشدگی‌ها بیشتر باشد خوردن سیمان نیز بیشتر خواهد بود. این عامل با محاسبه‌ی متوسط وزنی بازشدگی‌ها درمقاطع ۵ متری بدست آمده است.

### روش کار

در این قسمت روشهای بکار برده شده جهت تخمین خوردن سیمان شامل شبکه عصبی مصنوعی، رگرسیون دو متغیره و رگرسیون چند متغیره تشریح می‌گردند و صحت تخمین به توسط محاسبه ضریب تعیین  $R^2$  برازش بین خوردن اندازه گیری شده و محاسباتی و همچنین محاسبه میانگین نسبی مربع خطاها (RMSE) ارزیابی می‌گردد.

### فاکتورهای موثر بر خوردن سیمان

عوامل متعددی بر روی خوردن سیمان اثر می‌گذارند که بطور کامل نمی‌توان به تمامی آنها پرداخت. برخی از این فاکتورها که می‌توانند بصورت کمی دسته بندی شوند عبارتند از:

#### لایه بندی

این فاکتور ویژگی‌هایی از قبیل جنس لایه‌ها، مقاومت سنگ و میزان سیمانه شدن را تحت پوشش قرار می‌دهد. اگر ساختگاه سد از لایه‌های متفاوتی تشکیل شده باشد، احتمالاً دارای درزه‌های پنهان فراوانی نیز می‌باشد.

#### ناحیه ی پی سد

تجربه نشان می‌دهد که تکیه گاه‌های چپ و راست سد بختیاری بعلت شرایط متفاوت زمین شناسی دارای درزه‌های متفاوت و در نتیجه خوردن متفاوت هستند. بنابراین از لحاظ زمین شناسی سد بختیاری به دو قسمت چپ و راست تقسیم شد (شکل ۲).

#### عمق مقطع تزریق

در نواحی عمیق ترک‌ها معمولاً ریز و غالباً تزریق ناپذیرند. بنابراین عمق یک فاکتور مهم در خوردن سیمان می‌باشد. در سد بختیاری عملیات تزریق در مقاطع ۵ متری انجام گردیده است (Kutzner, 1985; Shibata, 1989).

#### فشار تزریق

بصورت تئوری فشار تزریق بایستی کمتر از تنش تکتونیکی در عمق قطعه تزریق بوده و همچنین کمتر از مقاومت کششی سنگ باشد (Kutzner, 1985; Shibata, 1989). اگر در حین عمل تزریق بدون دقت کافی فشار تزریق برای

## شبکه عصبی مصنوعی

روش شبکه عصبی مبتنی بر یافتن روابط ذاتی میان داده‌های مختلف، یادگیری این روابط و سپس تعمیم به نمونه‌های مشابه است و شبکه عصبی مصنوعی پردازنده‌ای است که دانشی را که از راه تجربه کسب نموده، برای استفاده‌های دیگر ذخیره می‌کند. این پردازنده از دو جهت شبیه مغز انسان است (Haykin, 1994):

- دانش شبکه از طریق فرایند آموزش حاصل می‌شود.

- وزن اتصالات بین نرون‌ها مشابه سیستم ذخیره اطلاعات شبکه عصبی مغز انسان تعیین می‌شود.

شبکه‌های عصبی از نظر ساختاری به شبکه‌های تک لایه و چند لایه تقسیم می‌شوند. شبکه‌های عصبی چند لایه از سه نوع لایه تشکیل شده‌اند و وجود این سه لایه برای تشکیل یک شبکه عصبی مصنوعی ضروری است. نرون‌ها عناصر تشکیل دهنده لایه‌ها در شبکه‌های عصبی می‌باشند. عناصر هر لایه با تمام عناصر لایه‌های دیگر در ارتباط است ولی با سایر عناصر در همان لایه ارتباطی ندارد. سه لایه شبکه چند لایه‌ای شامل لایه ورودی، لایه‌های میانی یا پنهان و لایه خروجی است (شکل ۳). در این شبکه اولین لایه که اطلاعات ورودی به آن وارد می‌شود اصطلاحاً لایه ورودی (Input Layer) نامیده می‌شود. آخرین لایه که جوابهای خروجی از مدل را فراهم می‌نماید لایه خروجی (Output Layer) گفته می‌شود. در بین لایه‌های ورودی و خروجی یک یا چند لایه دیگر بنام لایه‌های مخفی یا میانی (Hidden Layer) قرار می‌گیرند که مستقیماً به داده‌های ورودی و نتایج خروجی متصل نیستند (شکل ۳). شبکه عصبی در واقع یک ساختار منطقی تشکیل شده از یک سری المان‌هایی است که از طریق مجموعه‌ای از وزن‌های داخلی با یکدیگر ارتباط دارند. این روش مبتنی بر یافتن روابط ذاتی میان داده‌های مختلف، یادگیری آن و سپس تعمیم به نمونه‌های مشابه است. وزن‌های یاد شده در حین پروسه‌ی آموزش دائماً اصلاح می‌شوند. در شبکه‌های عصبی کاربر تعداد ورودی‌ها، خروجی‌ها، لایه‌های مخفی و نودهای لایه‌ی مخفی را تعیین می‌کند. این نوع شبکه‌ها از یک سری توابع انتقال تشکیل شده‌اند که وظیفه‌ی ضرب مقادیر ورودی به هر نرون در وزن مربوطه را برعهده دارند (شکل ۴). توابع زیادی هستند که در انتقال اعداد از لایه قبل به لایه بعد ممکن است مورد استفاده قرارگیرند که از آن جمله می‌توان توابع سیگموئید (Sigmoid)، گوسی (Gaussian)، تانژانت هیپربولیک (Hyperbolic Tangent) سکانت هیپربولیک (Hyperbolic Secant) را نام برد ولی تابع سیگموئید بیشترین کاربرد را در مسائل مهندسی دارد که یکی از دلائل عمده استفاده از این تابع سادگی مشتق آن است که استفاده از روش پس انتشار خطا را بسیار ساده می‌کند. شبکه‌های پس انتشار (BPN) یکی از پرکاربردترین شاخه‌های شبکه‌های عصبی هستند (Rumelhart et al., 1986). این نوع شبکه پروسه‌ی آموزش را با وزن‌های انتخابی شروع می‌کند و با مقایسه‌ی خروجی‌های شبکه عصبی با خروجی‌های مورد انتظار خطاهای حاصله را محاسبه می‌کند و کلیه‌ی وزن‌ها از طریق انتشار برگشتی خطاها اصلاح می‌شوند. این پروسه در هر سیکل آموزش ادامه یافته و تا زمانی که خطای خروجی‌های شبکه به کمترین میزان ممکن نرسد متوقف نمی‌شود. یادگیری و مومنتم انتخاب شده توسط کاربر به ترتیب سرعت و پایداری شبکه را کنترل می‌کنند. با اضافه شدن تعداد لایه‌های مخفی ممکن


است خطای شبکه کاهش یابد اما در عین حال ساختار شبکه عصبی پیچیده‌تر می‌گردد که خود منجر به افزایش زمان آموزش شبکه برای یافتن وزن‌های مناسب می‌شود. به طور کلی برای ساخت مدلی به روش شبکه عصبی مصنوعی لازم است طبق مراحل زیر اقدام شود (Trippi and Turban, 1996):

- ۱) تهیه زوج‌های آموزشی: این زوج داده‌ها شامل اطلاعات آماری از پدیده مورد نظر است و در واقع ورودی‌های شبکه عصبی را تشکیل می‌دهند.
  - ۲) نرمال کردن زوج‌های آموزشی: نرمال کردن داده‌ها به معنی تغییرمقیاس آنها جهت قرار گرفتن در یک محدوده خاص می‌باشد.
  - ۳) پیدا کردن بهترین ساختار شبکه: بهترین ساختار شبکه عصبی عبارت است از ایجاد ترکیب مناسبی از تعداد لایه‌های پنهان و تعداد نرون‌های آنها جهت رسیدن به حداقل خطای شبکه عصبی. این کار به روش آزمون و خطا صورت می‌گیرد.
  - ۴) یادگیری شبکه عصبی: جهت یادگیری شبکه‌های عصبی الگوریتم‌های آموزشی مختلفی ارائه گردیده است که معروفترین آنها الگوریتم آموزشی انتشار به عقب (BP) می‌باشد. در این روش ابتدا اطلاعات از لایه ورودی به لایه خروجی انتقال می‌یابد، سپس میزان خطا محاسبه و در نهایت با بازگشت از لایه خروجی به لایه ورودی وزن‌های شبکه اصلاح می‌گردند. این عمل تا رسیدن به مقدار حداقل خطای شبکه ادامه می‌یابد.
  - ۵) تست شبکه عصبی: جهت بررسی دقت شبکه آموزش یافته لازم است که عمل تست یا امتحان شبکه عصبی انجام شود. این کار با ارائه زوج داده‌های مجموعه تست به شبکه و محاسبه میزان خطای شبکه انجام خواهد شد. بدیهی است که در این مرحله انتخاب بهترین ساختار شبکه عصبی و الگوی ورودی و با مقایسه مقادیر خطاهای تست شبکه‌های مختلف انجام پذیر خواهد بود.
  - ۶) تکرار مراحل (۱) تا (۵) تا تعیین مدل بهینه
  - ۷) کاربرد مدل ANN بهینه
- در شبکه عصبی هر نرون تمامی ورودی‌ها را از لایه‌ی قبل خود مطابق رابطه‌ی زیر دریافت می‌کند:

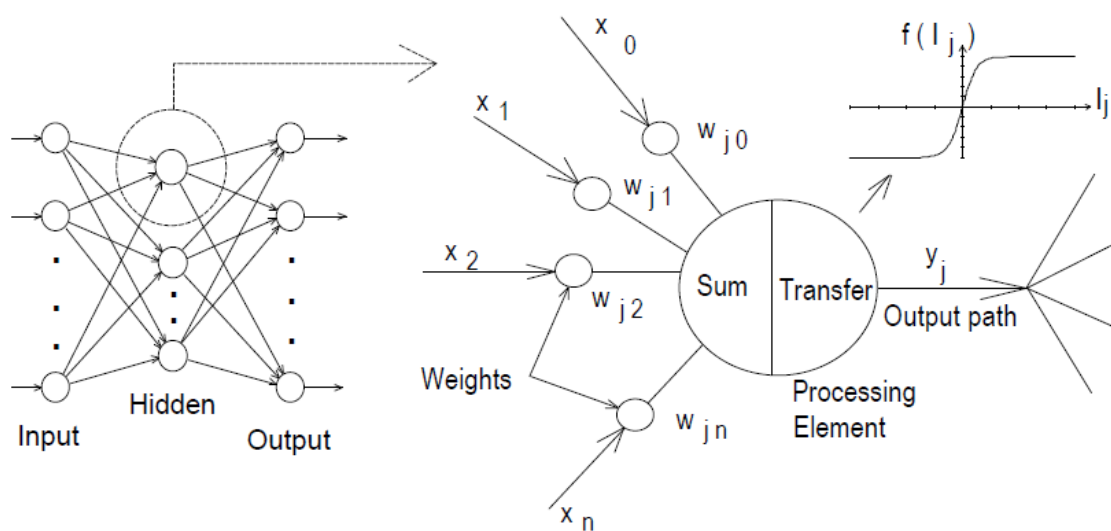
$$\text{net}_j = \sum_{i=0}^n W_{ij} X_i \quad (2)$$

در این رابطه  $\text{net}_j$  سیگنال ورودی به لایه بعدی و  $n$  تعداد ورودی‌ها به  $j$  امین نرون در لایه مخفی است.  $W_{ij}$  وزن اتصال میان  $i$  امین نرون در لایه بعدی به  $j$  امین نرون در لایه مخفی است.  $X_i$  ورودی از  $i$  امین نرون در لایه قبلی است. یک نرون به کمک یک تابع انتقال  $f$  مثل تانژانت سیگموئید (که در این پژوهش مورد استفاده قرار گرفته است) خروجی  $\text{out}_j$  را تولید می‌کند (رابطه‌ی ۳ و شکل ۴).

$$\text{out}_j = f(\text{net}_j) = \frac{1 - 2 \exp(-2\text{net}_j)}{1 + 2 \exp(-2\text{net}_j)} \quad (3)$$



شکل ۳. نمای کلی شبکه چند لایه ای



شکل ۴. طرح ساده ای از اجزای تشکیل دهنده یک نورون

ورودی برابر با تعداد عناصر بردار ورودی و تعداد نرونهای لایه خروجی برابر با تعداد عناصر بردار خروجی می باشد. هر نرون توسط خروجی اش به نرونهای لایه بعد متصل است ولی با نرونهای لایه خودش ارتباط ندارد. آنالیز دقیق و واقعی برای پیدا کردن تعداد نرونهای لایه میانی در کل بسیار پیچیده است اما می توان گفت که تعداد نرونهای لایه مخفی تابعی از تعداد عناصر برداری ورودی و همچنین حداکثر تعداد نواحی از فضای ورودی که بطور خطی از هم جداپذیرند می باشد از این رو تعداد نرونهای لایه مخفی عموماً بطور تجربی بدست می آید. در این تحقیق با استفاده از کد نوشته شده در نرم افزار MATLAB بهترین ترکیب شبکه عصبی بدست آمد و برای مدل سازی مجموعه شبکه عصبی پس انتشار از یک لایه پنهان استفاده شد. همانگونه که در (شکل ۵) نشان داده شده است، این شبکه شامل یک لایه مخفی با هفت ورودی و یک خروجی است. ورودیها شامل لوژان، حالت‌های لوژان، عمق گمانه تزریق، جنس سنگ، فشار تزریق، متوسط میزان بازشدگی‌ها در هر مقطع و شرایط زمین شناسی (ناحیه) بوده و خروجی نیز خوردن سیمان می‌باشد. حالت بهینه ورودی‌های شبکه عصبی متفاوت از Yang (2004) است که تنها لوژان، عمق گمانه تزریق، فشار تزریق و شرایط زمین شناسی را برای تخمین خوردن سیمان به توسط شبکه عصبی مورد استفاده قرار داده است. برای جلوگیری از تاثیر مقادیر بسیار بزرگ یا کوچک ورودی‌ها بر روی وزن‌های شبکه، توسط رابطه‌ی زیرکلیه داده‌ها بین (۱-۱) نرمالیزه شده‌اند.

$$X_i = 2 \left( \frac{X - X_{\min}}{X_{\max} - X_{\min}} \right) - 1 \quad (9)$$

وزن‌های اولیه بصورت اتفاقی بین ۰/۱ و ۰/۹ انتخاب شده‌اند. داده‌های استفاده شده مربوط به بخش تزریق گالری‌های GR2 و GL1 می باشند که تنها در این گالری‌ها تزریق انجام شده است. داده‌های هر چال با توجه به گام‌های تزریق ۵ متری و عمق چال به مجموعه‌های جداگانه تقسیم بندی گردیده است. به عنوان مثال چال با عمق ۶۰ متر در بردارنده ۱۲ مجموعه داده می باشد. البته از مقاطع اول هر گمانه بدلیل عدم اطمینان کافی نسبت به اطلاعات چشم پوشی گردید. جهت دخالت دادن فاکتورهای موثر بر خوردن سیمان در پروسه تخمین به توسط شبکه عصبی، تغییرات ذیل لازم بوده است (جدول ۱):

شبکه‌ی عصبی در واقع یک رگرسیون چند متغیره است که فرم استاندارد آن بصورت زیر است:

$$y' = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (4)$$

در این معادله  $y'$  متغیر وابسته (مانند خوردن سیمان که تقریبی از  $y$  است)،  $X_i$  ها متغیرهای مستقل (در این تحقیق فشار، میزان متوسط بازشدگی درزه‌ها، لوژان، نوع سازند و ناحیه‌ی فونداسیون سد) هستند.  $\beta_i$  ها ضرایب رگرسیون و  $\varepsilon$  خطای معادله می‌باشند. پس اگر میانگین  $y$  ها  $y_{avg}$  باشد،  $(y' - y_{avg})$  بیانگر اختلاف میان  $y$  امین  $y$  و میانگین  $y$  هاست. حال پارامترهای SSE و SST بصورت زیر تعریف می شوند:

$$SSE = \sum_{j=1}^n (y - y'_j)^2 \quad (5)$$

$$SSR = \sum_{j=1}^n (y' - y_{avg})^2 \quad (6)$$

$$SST = SSR + SSE \quad (7)$$

ضریب رگرسیون یا ضریب تعیین که در واقع توزیع متغیرها را نشان می‌دهد، بصورت زیر تعریف می شود:


$$R^2 = SSR/SSE \quad (8)$$

### طراحی و آموزش شبکه

طراحی یک شبکه عصبی مصنوعی شامل انتخاب تعداد لایه‌های پنهان و عناصر پردازنده نرون (برای لایه‌های پنهان) است که یک فرایند سعی و خطا جهت کسب بهترین نتیجه ممکن برای تولید خروجی میباشد. تعداد نرونهای لایه

جدول ۱. کد بندی ورودی‌های شبکه عصبی

کد	ناحیه‌ی فونداسیون	کد	نوع سازند	کد	فشار تزریق (kpa)	کد	عمق مقطع تزریق (m)	کد	حالت لوژان	کد	میزان متوسط باز شدگی درزه‌ها (m m)
۰	چپ	۰	SV2	۰	۰-۵۰۰	۰	۰-۲۰	۰	خطی	۰	۱-۱/۵
۱	راست	۱		۱	۵۰۰-۱۰۰۰	۱	۲۰-۴۰	۱	آشفته	۱	۱/۵-۲
۲		۱	SV3	۲	۱۰۰۰-۱۵۰۰	۲	۴۰-۶۰	۲	آبشستگی	۲	۲-۲/۵
۳		۳		۳	۱۵۰۰-۲۰۰۰	۳	۶۰-۸۰	۳	پرشدگی	۳	۲/۵-۳
۴		۴		۴	۲۰۰۰-۲۵۰۰	۴	۸۰-۱۰۰	۴	بازشدگی	۴	> ۳
		۵		۵	۲۵۰۰-۳۰۰۰						
		۶		۶	> ۳۰۰۰						



شکل ۵. شمایی از الگوریتم بکار رفته در شبکه عصبی

با توجه به موارد فوق برای هر سری از گمانه‌های تزریق با توجه به تفاوت منطقی مقادیر لوژان و خورد در دو گالری لازم بود که حداقل از دو شبکه استفاده شود، لیکن بدلیل کمبود اطلاعات این امر میسر نبوده و از ۷۰٪ داده های هر بخش برای آموزش شبکه و از مابقی برای آزمون استفاده گردیده است. نتایج تکرارهای مختلف و حالت بهینه در جدول ۲ و ۳ ارائه گردیده است. صحت تخمین خورد سیمان به توسط حالت بهینه شبکه عصبی با محاسبه ضریب تعیین (رابطه ۸) و ضریب ارزیابی گردیده است. ضریب RMSE به توسط رابطه ذیل محاسبه می گردد:

$$RMSE = \frac{1}{s^2 n} \sum_{i=1}^n (y - y')^2 \quad (10)$$

در این رابطه  $y$  مقدار خورد سیمان واقعی،  $y'$  خورد تخمین زده شده توسط مدل،  $n$  تعداد کل داده ها و  $s^2$  واریانس نمونه می باشد. جدول (۳) و شکل (۶) نتایج آموزش و آزمون در شبکه عصبی را در حالت بهینه نشان می دهند. مدل بر اساس بیشترین مقادیر ضریب تعیین و کمترین مقدار RMSE ارزیابی می گردد.

با توجه به اطلاعات موجود، ناحیه‌ی سد به دو تکیه گاه چپ و راست تقسیم شد. در خصوص عمق مقطع تزریق با سعی و خطا مشخص گردید که بهتر است بصورت مقاطع ۲۰ متری کد گذاری شوند. فشار تزریق در بازه‌های ۵۰۰ کیلوپاسکال به کدهای ۱ تا ۶ تبدیل گردیده است. لوژان تنها فاکتوری است که بصورت کد وارد شبکه عصبی نشده، زیرا تغییر یک واحد لوژان باعث چندین واحد تغییر خورد می‌شود.

تابع انتقال نرون های لایه میانی Sigmoid و لایه خروجی Purelin تعیین گردید. هر شبکه با تعداد نرون‌های مختلف در لایه میانی آموزش یافته و تعداد بهینه انتخاب شد. برای آموزش شبکه از الگوریتم Levenberg-Marquardt و برای جلوگیری از حفظ داده‌های آموزشی در شبکه (overfitting) از الگوریتم Bayesian-regularization استفاده گردید. از ویژگی های این الگوریتم این است که با کنترل تابع برای داده های آموزش و آزمون، عملیات آموزش را با تعدیل تابع عملکرد به گونه ای متوقف می نماید که تابع خطا برای هر دو مجموعه داده‌ها کمترین مقدار ممکن باشد.

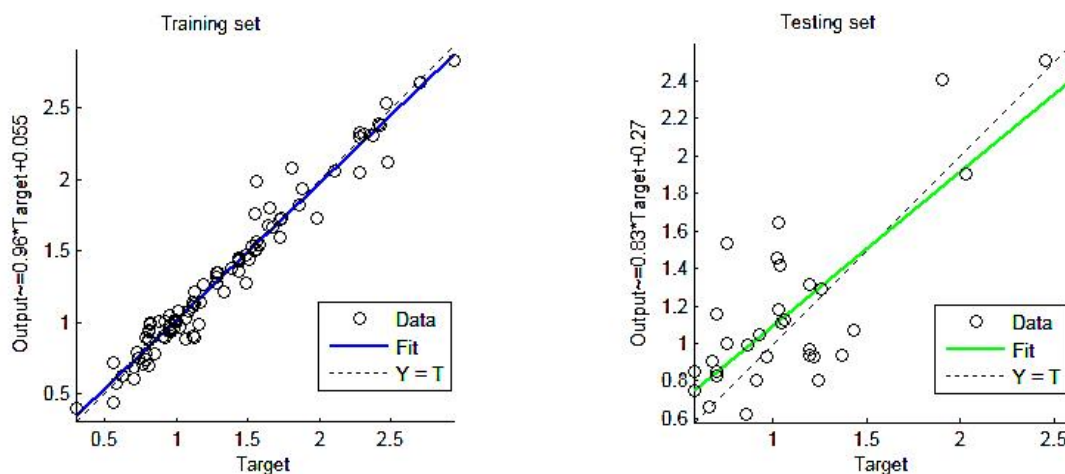
مجموعه داده هایی که به شبکه داده می شوند به دو دسته کلی تقسیم می شوند: مجموعه آموزشی و مجموعه آزمایشی. مجموعه آموزشی برای بالا بردن توان یادگیری وارد شبکه می‌شوند و شبکه باید وزنه‌های ارتباطی را از الگوهای آموزشی موجود فراگیری نماید. هنگامی که مرحله یادگیری مدل با موفقیت به اتمام رسید، عملکرد مدل آموزش داده شده باید با استفاده از یک مجموعه مستقل داده آزمایشی صحت سنجی شود (Moselhi et al., 1992; Flood and Kartam, 1994; Maier and Dandy, 2000).

جدول ۲. نتایج آموزش و تست شبکه عصبی در تکرارهای مختلف

1st hidden layer nodes	epoch	iteration	R <sup>2</sup>		
			Train	Test	Total
3	100	77	0.852203	0.642831	0.808304
3	100	74	0.852076	0.67804	0.818442
3	100	81	0.832039	0.748339	0.816987
3	100	29	0.821524	0.644826	0.786821
3	100	97	0.814109	0.664138	0.786884
3	100	72	0.812391	0.644052	0.779856
4	100	52	0.877531	0.715551	0.833975
4	100	80	0.877236	0.670062	0.833728
4	100	43	0.857614	0.657108	0.817812
6	100	46	0.932871	0.667156	0.843851
6	100	90	0.810672	0.669614	0.785237

جدول ۳. نتایج شبکه عصبی BPN با ترکیب مختلف داده‌های ورودی

تعداد نودهای اولین لایه مخفی	تعداد تکرار	RMSE	
		آموزش	آزمون
۴	۱۰۰	۰/۸۷۸	۰/۷۱۶



شکل ۶. ارتباط خوردن پیش بینی شده و خوردن واقعی در دو حالت آموزش و آزمون (شبکه عصبی)



## روش رگرسیون دو متغیره

تحلیل رگرسیون یکی از تکنیکهای مورد استفاده برای تخمین با استفاده از پارامترهای ورودی مسائل مهندسی و علوم است. دو روش اصلی رگرسیون یعنی رگرسیون ساده و چند متغیره کاربرد فراوانی دارند. رگرسیون ساده ارتباطی بین دو متغیر برقرار می سازد. توابع خطی  $(y = ax + b)$ ، توانی  $(y = ax^b)$ ، لگاریتمی  $(y = a \ln x + b)$  و نمایی  $(y = ae^{bx})$  جهت ساخت مدل پیش بینی ساده بکار می روند. رایج ترین روش برای ارزیابی خوردن سیمان پرده آببند با رگرسیون ساده استفاده از معیار لوژان است. با اعمال رگرسیون دو متغیره بر روی داده های لوژان و خوردن سیمان سد بختیاری و پس از بررسی کیفیت برازش توابع مختلف بر اساس میزان ضریب تعیین مشخص گردید که یک رابطه ی توانی میان اطلاعات لوژان و خوردن وجود دارد (رابطه ی ۱۱ و شکل ۷ الف):

$$Lg = -0.002(Lu^2) + 3.299 \quad (11)$$

که در این رابطه  $Lg$  خوردن سیمان بر حسب کیلوگرم در واحد طول و  $Lu$  عدد لوژان می باشد. در شکل (۷ ب) ارتباط میان خوردن واقعی و خوردن پیش بینی شده بکمک رگرسیون دو متغیره دیده می شود.

### رگرسیون چند متغیره

در کاربردهای مهندسی مدل های ساده نمی توانند تغییرات کل به توسط متغیرهای مستقل را توضیح دهند و مدل های قابل اعتمادی نیستند. بنابراین استفاده از مدل رگرسیونی چند متغیره بخصوص در مواقعی که روابط پیچیده ای بین متغیرها وجود دارند و بیش از یک متغیر بر پدیده مورد بررسی اثرگذار هستند، ضروری می باشد. این روش بر اساس ارتباط میان یک متغیر وابسته و مجموعه ای از متغیرهای مستقل استوار است. در این مطالعه به منظور اعمال این روش از نرم افزار آماری MINITAB بهره گرفته شده است. مجموعاً ۱۰ مدل رگرسیونی جهت تخمین خوردن سیمان با استفاده از ۵ پارامتر ورودی تولید گردیده و نتایج مدل های تولید شده مقایسه گردید تا بهترین پارامترهای ورودی و همچنین بهترین مدل انتخاب گردد. پس از بررسی ترکیبهای متفاوت پارامترهای اثرگذار بر خوردن سیمان بهترین ترکیب ورودی ها شامل لوژان، فشار، ناحیه و شرایط زمین شناسی تعیین شده و در این حالت کمترین خطا در برآورد خوردن سیمان حاصل گردیده است:

پس از بارها سعی و خطا ترکیب خطی ورودی ها شامل لوژان، فشار، ناحیه و شرایط زمین شناسی بصورت رابطه زیر بهترین حالت انتخاب گردید:

$$Lg = -42.7 - 201(r) + 2.63(Lu) - 4.9(ap) + 0.0452(p) + 146(g) \quad (12)$$

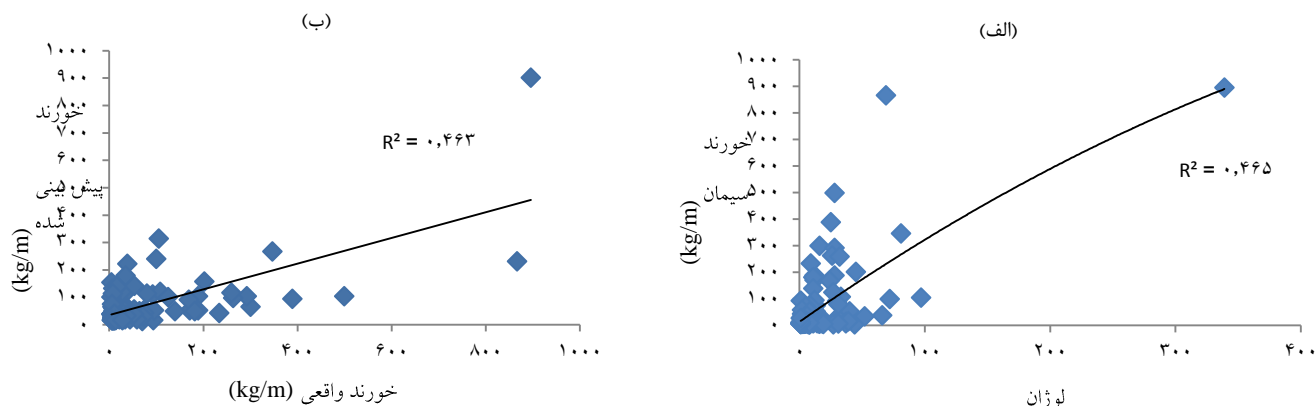
که در رابطه ی بالا  $Lg$ ،  $r$ ،  $Lu$ ،  $ap$ ،  $P$  و  $g$  به ترتیب معرف خوردن سیمان، ناحیه ی فونداسیون، عدد لوژان در مقطع مورد نظر، متوسط میزان بازشدگی درزه ها، فشار و شرایط زمین شناسی می باشند. در شکل (۸) میزان تطابق

میان خوردن واقعی و خوردن پیش بینی شده توسط رگرسیون چند متغیره مشاهده می گردد.


### بحث و نتیجه گیری

در این پژوهش از روش شبکه عصبی پس انتشار برای ارزیابی میزان خوردن سیمان در ساخت پرده آببند سد بختیاری استفاده گردیده است. مدل ANN با الگوریتم پس انتشار خطا با قوانین آموزشی و توابع تبدیل مختلف برای رسیدن به کمترین RMSE و بیشترین ضریب تعیین مورد آزمون قرار گرفت. طراحی یک شبکه عصبی مصنوعی شامل انتخاب تعداد لایه های پنهان و عناصر پردازنده نرون (برای لایه های پنهان) است که یک فرایند سعی و خطا جهت کسب بهترین نتیجه ممکن برای تولید خروجی میباشد. تعداد لایه های مخفی و تعداد عناصر فرایند در آنها و نوع تابع فعالیت بصورت سعی و خطا بدست آمد. بدین ترتیب که در ابتدا به ازای یک لایه مخفی با یک عنصر فرایند محاسبات شروع شد و با افزایش تعداد عناصر فرایند در یک لایه مخفی و تعداد لایه های مخفی حداقل خطا بدست آمد و این عمل برای سه نوع تابع فعالیت خطی، تانژانت هیپربولیک و سیگموئید تکرار شد. با مقایسه ی نتایج شبکه عصبی و رگرسیون های دو متغیره و چند متغیره، مشخص می شود که شبکه عصبی مدل بهتری جهت برآورد خوردن سیمان می باشد و اهمیت استفاده از این روش بیش از پیش نمایان می شود. جهت توجیه صحت مدل های ارائه شده، اندیسهای پیش بینی شامل ضریب تعیین ( $R^2$ ) و میانگین نسبی مربع خطا (RMSE) برای هر مدل محاسبه گردیده اند. هراندازه مقدار  $R^2$  بیشتر بوده و مقدار RMSE کمتر باشد، مدل ساخته شده دقیق تر خواهد بود.

ضریب تعیین  $R^2$  مدل ساخته شده به کمک شبکه عصبی ۷۱/۶٪ است که این عدد در رگرسیون چند متغیره و دو متغیره به ترتیب برابر ۶۵/۵٪ و ۴۶/۳٪ می باشد. همچنین ضریب RMSE برای روشهای رگرسیون دو متغیره، چند متغیره و شبکه عصبی به ترتیب برابر 0.532، 0.344، و 0.088 محاسبه گردیده است. با توجه به مقادیر ضرایب تعیین و RMSE مشخص می شود که شبکه عصبی بهتر از رگرسیون چند متغیره و روش رگرسیون دو متغیره جهت مدلسازی خوردن سیمان عمل می کند و مسئله مورد بررسی دارای ابعاد و غیر خطی بودن بالایی می باشد. در واقع هر چه ابعاد و غیر خطی بودن مسئله افزوده گردد، اهمیت شبکه عصبی بیشتر نمود پیدا می کند و در این حالت تکنیکهای مرسوم رگرسیونی در جهت تخمین صحیح ناکارآمد می باشند.



شکل ۷ الف. ارتباط میان لوژان و خوردن سیمان با استفاده از رگرسیون دو متغیره (ب) ارتباط خوردن پیش بینی شده و خوردن واقعی در رگرسیون دو متغیره



شکل ۸. ارتباط خوردن پیش بینی شده و خوردن واقعی در رگرسیون چند متغیره

عوامل موثر بر خوردن سیمان (ورودی‌های شبکه عصبی) شامل لوژان، حالت‌های لوژان، عمق گمانه تزریق، جنس سنگ، فشار تزریق، متوسط میزان بازشدگی‌ها در هر مقطع و شرایط زمین شناسی (ناحیه) در نظر گرفته شده اند که متفاوت از Yang (2004) است که تنها لوژان، عمق گمانه تزریق، فشار تزریق و شرایط زمین شناسی را برای تخمین خوردن سیمان به توسط شبکه عصبی مورد استفاده قرار داده است. البته باید توجه شود که ترکیب داده‌های ورودی در هر سه روش و حتی کد بندی آنها تنها برای ساختگاه سد بختیاری مناسب بوده و بایستی برای هر ساختگاه از ترکیب مناسب به خود استفاده شود.

با استفاده از سیستم پس انتشار وزنه‌ای ارتباطی در مراحل مختلف تصحیح می‌شوند که این امر دقت مدل ساخته شده را نسبت به دو روش دیگر افزایش می‌دهد. پس از آموزش ساختارهای مختلف ساخته شده جهت هر الگوی ورودی، کلیه شبکه‌ها مورد ارزیابی قرار گرفته و مقادیر خطاها محاسبه شده است و در نهایت الگوی ساختاری که دارای مقادیر حداقل خطا می باشد انتخاب گردیده است. مجموع خوردن سیمان محاسبه شده به توسط روش شبکه عصبی برابر 29215.15 کیلوگرم می باشد که در مقایسه با خوردن سیمان واقعی (30409.91 کیلوگرم)، خطایی برابر 3.9% را نشان می دهد شبکه‌ی عصبی طراحی شده علاوه بر عوامل موثر بر خوردن سیمان، حالت لوژان و باز شدگی متوسط درزه‌ها را نیز جهت شبیه سازی واقعی‌تر در نظر می‌گیرد. در حالت بهینه

عصبی در انطباق دادن خود با داده های ورودی دارند، می توان در صورت عدم دسترسی به تعداد پارامترهای فراوان، با انتخاب پارامترهای مناسب موجود، به نتایج خوبی دست پیدا کرد. نکته قابل توجه دیگر این است که با اعمال داده های مشابه و یکسان که پردازش چندان زیادی در مورد آنها نشده است، به شبکه عصبی و روش رگرسیون، نتایج حاصل از شبکه عصبی از دقت بالاتری برخوردار بودند که این امر می تواند در هنگام انجام مطالعات مختلف، مورد توجه قرار گیرد.

#### قدردانی

از تحصیلات تکمیلی دانشگاه اصفهان که با حمایت های مالی زمینه انجام این تحقیق را فراهم نمودند، تشکر و قدردانی می شود.

در فرآیند مدل سازی بکمک شبکه عصبی این نتیجه حاصل شد که عمق و فشار تاثیر یکسان بر روی خوردن سیمان داشتند، هنگامی که گزارشات تزریق مورد بررسی قرار گرفت دیده شده که اپراتور با افزایش عمق گمانه فشار تزریق را افزایش داده است یعنی افزایش عمق، افزایش فشار تزریق را در پی خواهد داشت. استفاده از روش سیستم شبکه عصبی برای مطالعات خوردن سیمان نیاز به اطلاعات دقیق دارد و دادن داده های ناقص و نادرست، افزایش مدت پردازش و یادگیری اشتباه سیستم را در پی خواهد داشت. اگرچه با داشتن تعداد پارامترهای ورودی بیشتر مرتبط با مقدار پارامتر مورد پیش بینی این امکان وجود دارد که بتوان به پاسخ های با دقت بیشتر دست یافت ولی به دلیل خاصیتی که شبکه های

#### منابع

شرکت مهندسی مشاور مهتاب قدس، ۱۳۸۰، گزارش اصلی سد مخزنی و نیروگاه برقابی بختیاری - مطالعات مرحله اول.

- Baker W.H., 1982, Grouting in geotechnical engineering, American Society of Civil Engineers.
- Chang T.C., Chao R.J., 2006, Application of back-propagation networks in debris flow prediction, Eng. Geol., 85: 270-280.
- Ewert F.K., 1985, Rock grouting with emphasis on dam sites, Springer-Verlag Ltd., Berlin, Heidelberg, Germany.
- Flood I., Kartam N., 1994, Neural networks in civil engineering. I: Principles and understanding, J. Computing in Civil Engineering, ASCE, 8(2), 131-148.
- Foyo A., Sanchez M.A., 2005, Permeability Tests for Rock Masses. A Proposal for a New Expression for the Equivalent Lugeon Unit (ELU), Dam Engineering, 13(3), 199-218.
- Goh A.T.C., 1994, Seismic liquefaction potential assessed by neural network, J. Geotech. & Geoenv. Engrg., ASCE, 120(9), 1467-1480.
- Goh A.T.C., 1995, Back-propagation neural networks for modeling complex systems, Journal of Artificial Intelligence in Engineering, Elsevier Ltd., 9: 143-151.
- Gomez H., Kavzoglu T., 2008, Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela Eng. Geol., 78: 11-27.
- Haykin S., 1994, Neural Network: A comprehensive foundation, NY: Macmillan
- Hirota Y., Takebayasi S., Shibata I., 1990, Prediction of grout take in dam foundation grouting - a case of Granite, Journal of Japan Society of Civil Engineering, 13(421): 195-202.
- Houlsby A.C., 1990, Construction and design of cement grouting - a guide to grouting in rock foundations, John Wiley & Sons, New York.
- Huang Y., Wanstedt S., 1998, The introduction of neural network system and its application in rock engineering, Engineering Geology, Elsevier Ltd., 49: 253-260.
- Haykin S., 1994, Neural Networks: A Comprehensive Foundation, New York: MacMillan Publishing Company. 696 pp.
- Hubick K., 1992, ANNs thinking for industry, Process Control Eng 15(11):36-38
- JSIDRE, 1994, The Fundamental Knowledge on Grouting, Japanese Society of Irrigation, Drainage and Reclamation Engineering, Tokyo.
- Kutzner C., 1985, Consideration on rock permeability and grouting criteria, 15th International Congress on Large Dams, Lausanne, Q.58, R.17.
- Lee S., Ryu J.H., Won J.S., Park H.J., 2004, Determination and application of the weights for landslide susceptibility mapping using an artificial neural network, Eng. Geol., 71: 289-302.
- Maier H.R., Dandy G.C., 2000, Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications, Environmental Modelling & Software, 15(1), 101-124.
- Maji V.B., Sitharam T.G., 2008, Prediction of elastic modulus of jointed rock mass using artificial neural networks, Geotech Geol. Eng., 26: 443-452.
- Millar D., Clarici E., 1994, Investigation of back-propagation artificial neural networks in modelling the stress-strain behaviour of sandstone rock, IEEE Int Conf Neural Netw 5:3326-3331
- Moosavi M., Yazdanpanah M.J., Doostmohammadi R., 2006, Modeling the cyclic swelling pressure of mudrock using artificial neural networks, Eng. Geol., 87: 178-194.
- Moselhi O., Hegazy T., Fazio P., 1992, Potential applications of neural networks in construction, Canadian Journal of Civil Engineering, 19, 521-529.
- Nefeslioglu H.A., Gokceoglu C., Sonmez H., 2008, An assessment on the use of logistic regression and artificial neural networks with different sampling strategies for the preparation of landslide susceptibility maps, Eng. Geol., 97: 171-191.

- Rumelhart D. E., Hinton G. E., Williams R. J., 1986, Learning internal representations by error propagation, In Rumelhart, D. E., McClelland, J. L., and the PDP Research Group, editors, *Paralled Distributed Processing. Explorations in the Microstructure of Cognition. Volume 1: Foundations*, pages 318-362. The MIT Press, Cambridge, MA.
- Shibata I., 1989, The determination of a rational injection pressure related to in-situ stress in dam foundation grouting, *Journal of Japan Society of Civil Engineering*, 16(436): 121-130.
- Trippi R.R., Turban E., 1996, *Neural Networks in Finance and Investing*, Irwin Professional Publishing.
- Verfel J., 1989, *Rock grouting and diaphragm wall construction*, Elsevier Science Pub., 532 pp.
- Weaver K., 1991, *Dam foundation grouting*, Library of Congress Catalog, Card No. 91-34635, American Society of Civil Engineers.
- Yamaguchi Y., Matsumoto N., 1989, Permeability and Lugeon values of dam foundation, *Journal of Japan Society of Civil Engineering*, 12(412): 51-60.
- Yang, Y., Zhang Q., 1997, A hierarchical analysis for rock engineering using artificial neural networks, *Rock Mechanics and Rock Engineering* 30 (4), 207-222.
- Yang C. P., 2004, Estimating cement take and grout efficiency on foundation improvement for Li – Yu – Tan dam, *Engineering Geology*, 75:1-14.
- Zorlu, K., Gokceoglu C., Ocakoglu F., Nefeslioglu H.A., Acikalin S., 2008, Prediction of uniaxial compressive strength of sandstones using petrography-based models, *Eng. Geol.*, 96: 141-158.