پیش بینی درصد تراکم خاک‌های ریزدانه در ساختمان سد مخزنی سرابی با استفاده از شبکهٔ عصبی مصنوعی

*علی حسن شریفی: دانشگاه آزاداسلامی واحد علوم وتحقیقات،
سیدمحمود فاطمی عقدا: دانشگاه تربیت معلم
علی ارومیه‌ای: دانشگاه تربیت مدرس

تاریخ: دریافت ۸۹/۱۲/۱۹ **پذیرش** ۹۰/٦/۱۲

چکیده

تحلیل تراکم حاصل شده از عملیات تراکم در خاک‌های ریزدانه در تحلیل برگشتی اهمیت به‌سزایی دارد. روش متداول در محاسبهٔ درصد تراکم خاک؛ شیوه‌های معمول مانند روش مخروط ماسه، روش بالون لاستیکی و روش چگالی‌سنج هسته‌ای است. که به‌عنوان روشی مناسب جای‌گزین، شبکهٔ عصبی آموزش دیده شده بر مبنای الگوهای تحلیل شده است. با روش‌های مذکور محاسبهٔ تراکم، علاوه بر این که به دقت مورد نیاز در روش‌های مرسوم می‌رسد، سادگی و سهولت استفاده از آن از سایر روش‌ها بیش‌تر بوده و سرعت محاسبهٔ آن نیز بیش‌تر است. در این تحقیق مدلی مبتنی بر شبکهٔ عصبی چندلایه پرسپترون برای پیش‌بینی رفتار تراکمی خاک‌های ریزدانه در سد مخزنی سرابی در حین اجرا، و متراکم کردن لایه‌های خاک ارائه شد. متغیرهای ورودی شامل٤ پارامتر ژئوتکنیکی رطوبت بهینه، درصد عبوری از الک۲۰۰، حد روانی و حد خمیری و ٤ پارامتر اجرایی تعداد دفعات عبور غلتک، ضخامت لایه، رطوبت خاک در محل و دانسیتهٔ حاصل شده در محل، در نظر گرفته شد. ایـن مدل که مبتنی بر شبـکهٔ عصبی چنـد لایه با روی‌کرد پس‌انتشار خطا ارائه شده، قادر است بدون داشتن حداکثر دانسیتهٔ آزمایشگاه که از ملزومات حتمی محاسبهٔ درصد تراکم در حالت معمولی است؛ با استفاده از دیگر پارامترهای ژئوتکنیکی و اجرایی (۸ مورد اشاره شده) درصد تراکم و بالطبع حداکثر وزن مخصوص آزمایشگاه را با تقریب نزدیک به ۱۰۰ درصد محاسبه کند.

واژه‌های کلیدی: درصد تراکم خاک، شبکهٔ عصبی، پارامتر ژئوتکنیکی، پارامتر اجرایی، حداکثر وزن مخصوص آزمایشگاه

*نویسنده مسئول

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

مقدمه

مباحث مرتبط با عملیات خاکی در بدنهٔ سدها و در احداث جاده‌ها و هر پروژه‌ای که به نوعی با عملیات خاکی در ارتباط هستند همواره مورد توجه محققان مختلف بوده است.

خاک و سنگ به‌دلیل رفتار نامعین خود که ناشی از پیچیدگی ساختارهای تشکیل دهندهٔ آن‌ها است، ویژگی‌های مهندسی متفاوتی دارند. در بسیاری از شرایط دانش ما به اندازه‌ای نیست که بتوانیم رفتار خاک را به‌طور کامل پیش‌بینی کنیم. در این موارد، قضاوت مهندسی نقش مهمی را ایفا می‌کند و شیوه‌های تجربی طراحی بیش‌تر استفاده می‌شود. بنا بر این مهندسانی که با مسائل مربوط به رفتار خاک سروکار دارند، ناگزیر از تجربه‌گرایی هستند. پیشرفت علم رایانه به آن‌ها امکان می‌دهد که پدیده‌های فیزیکی را با دقت و نزدیک به واقعیت حل کنند. هرچند مقایسهٔ بین نتایج مدل‌ها و رفتار واقعی، مجدداً آن‌ها را به تجربه‌گرایی می‌کشاند و این دلیلی است که شبکه‌های عصبی مصنوعی بتوانند راه جدیدی را بگشایند.

مکانیک خاک هوشمند با بهره‌گیری از آخرین پیشرفت‌های هوش مصنوعی (سیستم خبره، ریاضیات فازی، شبکهٔ عصبی، الگوریتم ژنتیک و علم سیستم‌ها) راه حلی برای مسائل پیچیدهٔ مکانیک خاک است. اساس مکانیک خاک هوشمند ایده‌های جدید بهینه‌سازی سیستم، پردازش اطلاعات نامعین، بازخور اطلاعات و بررسی کلی اطلاعات است.

در بسیاری از شرایط مهندسی ژئومکانیک، مسائلی وجود دارند که بسیار پیچیده و نامشخص هستند. در بسیاری از مدل‌های ریاضی که سعی در حل چنین مسائلی دارند، نبود درک فیزیکی منجر به ساده‌سازی‌ها یا اتخاذ فرضیات متعدد در مدل می‌شود.

به‌دلیل پیچیدگی ساختار تودهٔ خاک و شرایط اجرایی، ساخت یک مدل دقیق فیزیکی یا عددی کاری دشوار است. شبکه‌های عصبی از توانایی بالایی برای خودآموزی و ارائه روابط غیرخطی حاکم بر داده‌های جمع‌آوری شده، برخوردارند. این قابلیت منحصر به فرد باعث افزایش روز افزون به‌کارگیری شبکه‌های عصبی در مسائل ژئومکانیک شده است. شبکه‌های عصبی شیوهٔ مناسبی برای مسائل مهندسی خاک هستند که مکانیسم پیچیده‌ای دارند و عامل‌های زیادی بر روند و نتیجهٔ کار تأثیر دارند.

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

در روش شبکه‌های عصبی، تودهٔ خاک به‌طور غیرمستقیم با یک سیستم نرون‌های متصل به‌هم ارائه می‌شود و نیازی به تفسیر ژئومتریکی و مکانیکی نرون‌های داخلی شبکه نیست. روش‌های هوشمند فقط براساس داده‌های واقعی آموزش داده می‌شوند و ساختار و پارامترهای مدل را تعیین می‌کنند. در این حالت، نیازی به ساده‌سازی مسئله و در نظر گرفتن فرضیات، نیست.

پرکاربردترین الگوریتم آموزش شبکهٔ عصبی، الگوریتم پس‌انتشار خطاست. این الگوریتم، تابع مربع خطا را برای قضاوت میزان یادگیری سیستم استفاده می‌شود.

کاربرد شبکهٔ عصبی در مکانیک خاک

سیستم شبکهٔ عصبی مصنوعی در زمینه‌های مختلف شامل پزشکی و مسائل علوم مهندسی کاربرد دارد. معادلات موجود حاکم بر مدل را می‌توان با شبکهٔ مصنوعی که برای آنالیز مسائل چندمتغیره به‌کار می‌رود، تعویض کرد. کاربرد شبکهٔ عصبی در مهندسی ژئوتکنیک نسبتاً جدید است و احتیاج به تحقیقات بیش‌تری دارد [۱].

محققان زیادی خواص مکانیکی خاک را بررسی کرده‌اند و علیرغم این بررسی‌ها نمی‌توان ادعا کرد سازوکار رفتاری خاک کاملاً شناخته شده است. به‌همین سبب روش‌های متداول کنونی همانند روش‌های تجربی و ریاضی، از فرضیه‌های ساده‌کننده‌ای برای حل مسائل چند متغیره ژئوتکنیک استفاده می‌کنند. با مروری بر این روش‌ها می‌توان استدلال کرد که رفتار پیچیدهٔ خاک را نمی‌توان توصیف کرد. بنا بر این ضرورت روشی جای‌گزین، که توانایی درنظر گرفتن تمام پارامترهای مؤثر را به‌طور هم‌زمان، و قدرت تعمیم و یادگیری مستقیم را از داده‌های تجربی داشته باشد، احساس می‌شود. استفاده از شبکهٔ عصبی به‌عنوان راه حلی جای‌گزین، در حل بسیاری از مسائل مهندسی ژئوتکنیک در سال‌های اخیر با موفقیت استفاده شده است. زهو[۱] و ویو[۲] (۱۹۹٤) استفاده از شبکهٔ عصبی چندلایه پرسپترون را برای تحلیل نتایج آزمایش‌های صحرایی تشریح کرده‌اند [۲]. آگراول[۳] در همین سال مقاومت برشی مؤثر

۱. Zhu ۲. Wu ۳. Agraval

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

رس‌های سیلتی و مدل رفتاری تنش- کرنش ماسه را با استفاده از شبکهٔ عصبی پیش‌بینی کرده است [۳] .

گوه[۱] در سال ۱۹۹۵ و ۱۹۹٦ کاربرد شبکهٔ عصبی را در پیش‌بینی روان‌گرایی بررسی کرده است [٤]، [٥]. محققانی مانند هیدج[۲] و ویلیام[۳] (۱۹۷۹) کرنش ماسه تحت تنش‌های سیکلی [٦] و در سال ۱۳۷۷ مهین روستا تنش- کرنش خاک‌های رسی را با استفاده از شبکه‌های عصبی بررسی کرده‌اند [۷] .

روش استفاده از شبکهٔ عصبی برای پیش‌بینی رفتار تنش-کرنش شن را پنومادو[٤] و زهائو[٥] در سال ۲۰۰۰ [۸]، و ارزیابی رفتار تنش- کرنش ماسه‌ها را الیس[٦] و همکاران در سال ۱۹۹٥ [۹]، و همچنین پیش بینی رفتار تنش- کرنش رس‌ها را پنومادو همکاران در سال۱۹۹٤استفاده کرده‌اند [۱۰]. هم‌چنین روش مذکور را در مورد ظرفیت باربری شمع‌ها ابوکیفا[۷] در سال ۱۹۹۸ [۱۱] استفاده کرده است.

بنی‌مهد و یثربی در سال ۱۳۸۲ از شبکهٔ عصبی در مدل سازی، تحلیل و طراحی در مباحث مهندسی ژئوتکنیک استفاده کرده‌اند [۱۲] و در سال ۱۳۸۸ بابایی به کاربرد شبکهٔ عصبی مصنوعی در پیش‌بینی و تفسیر نتایج آزمایش بارگذاری صفحه در خاک‌های ریزدانه پرداختند [۱۳].

حبیب آگاهی، کاتبی و جوهری در سال ۲۰۰۰، رفتار مکانیکی خاک‌های ریزدانه (تنش و کرنش) را با استفاده از شبکه‌های عصبی مصنوعی بررسی کرده‌اند [۱٤].

محققان مختلف دیگری همچون جوآنگ[۸]، کوئن[۹]، شیباتا[۱۰]، شاهین[۱۱]، نجار[۱۲] و همکارانشان (۱۹۹٦ تا ۲۰۰۲) در زمینه‌های مختلفی مانند ضریب نفوذپذیری خاک‌های ریزدانه، آزمایش نفوذ استاندارد و آزمایش نفوذ مخروط، تورم خاک، تنش و کرنش در خاک‌های ریزدانه، پیش‌بینی رفتار ماسه و رس‌ها، نشست پی‌های کم عمق و تعیین پارامترهای تراکم خاک از شبکه‌های عصبی مصنوعی استفاده کرده‌اند [۱٥]، [۱٦]، [۱۷]، [۱۸]، [۱۹]، [۲۰]، [۲۱]، [۲۲]، [۲۳]، [۲٤]، [۲٥].

---

۱. Goh ۲. Hadge ۳. William ٤. Penumadu ٥. Zhao
٦. Ellis ۷. Abo kiefa ۸. Juang ۹. Coen ۱۰. Shibata
۱۱ . Shahin ۱۲. Najjar

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

در مجموع می‌توان گفت شبکه‌های عصبی مصنوعی، ابزاری توانمند برای تحلیل برگشتی در علوم زمین‌شناسی‌مهندسی، ژئوتکنیک و مکانیک‌خاک هستند. به‌همین سبب و به‌منظور تحلیل برگشتی هوشمند سد مخزنی سرابی بر اساس نتایج رفتارسنجی، اطلاعات مورد نیاز از اوراق آزمایشگاهی در قالب ۱۲٤٥ دسته داده، جمع‌آوری شد و سپس این اطلاعات برای یافتن ارتباط غیرخطی و پیچیده موجود در بین ورودی‌های شبکه (که همان اطلاعات قابل اندازه‌گیری در حین اجرای پروژه‌اند) و خروجی‌های شبکه (که شامل درصد تراکم حاصل است)، با شبکه‌های عصبی چندلایه به‌وسیلهٔ قانون آموزشی پس‌انتشار خطا بررسی شدند.

در تحقیق حاضر نیز سعی شد با استفاده از داده‌های آزمایشگاهی و اجرایی در محل سد مخزنی سرابی و بر اساس شبکه‌های عصبی مصنوعی، مدلی از این شبکه‌ها با روی‌کرد پس‌انتشار خطا برای پیش‌بینی درصد تراکم خاک‌های ریزدانه استفاده شده در این پروژه، به‌کار گرفت.

شبکه‌های عصبی مصنوعی

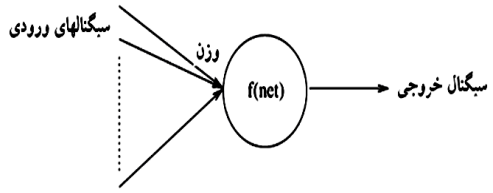
نرون‌ها، سلول‌های تشکیل دهندهٔ دستگاه عصبی بدن هستند. هر نرون با استفاده از تعدادی دندریت (گیرنده) تحریک‌های عصبی را دریافت می‌کند و پس از پردازش این پیام‌ها، آن‌ها را از طریق یک آکسون (فرستنده) به نرون بعدی ارسال می‌کند. مغز، کامپیوتری با ساختار پیچیده پیچیده، غیرخطی و موازی است و توانایی انجام وظایفی مانند بازشناسی الگو، ادراک و کنترل موتور را- بسیار سریع‌تر از هـر کامپیـوتری- داراست. علاوه بر ایـن خصوصیات، ویژگی‌های دیگری مانند توانایی فراگیری، حفظ‌کردن و حتی تعمیم، تحقیقات را در جهت مدل‌سازی الگوریتمی سیستم‌های زیستی به‌صورت شبکه‌های عصبی مصنوعی، به حرکت درآورده است. تخمین زده می‌شود که در قشر مخ انسان، ۱۰ تا ۵۰۰ بیلیون نرون با ٦۰ تریلیون سیناپس وجود دارند. این نرون‌ها در حدود۱۰۰۰ حوزه، که هرکدام حدود ۵۰۰ شبکهٔ عصبی دارند، قرار گرفته‌اند [۲٦]، [۲۷].

نرون مصنوعی (AN)، مدلی از نرون زیستی (BN) است. هر نرون مصنوعی، سیگنال‌ها را از محیط اطراف و یا نرون‌های مصنوعی دیگر دریافت می‌دارد و سپس این سیگنال‌ها را با

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

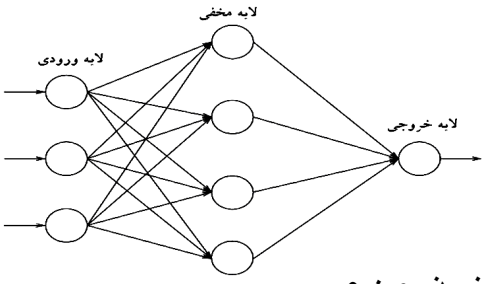
[DOR: 20.1001.1.22286837.1389.4.2.5.5]

یک‌دیگر جمع کرده و در نهایت زمانی که آتش می‌کند، سیگنالی را به تمام نرون‌های مصنوعی متصل انتقال می‌دهد. شکل۱، نرونی مصنوعی و شکل ٤ نیز نمونهٔ ساختار شبکهٔ عصبی را نشان می‌دهد.



شکل۱. نرون مصنوعی [۲۸]

سلول‌های ورودی مستقیماً سیگنال‌های نرمالیزه شده را دریافت می‌کنند و هدف سیستم به‌دست آوردن سیگنال نرمالیزه شده در خروجی شبکه است. چنان‌که در شکل ۲ مشاهده می‌شود خروجی نرمالیزه شده لحظه‌ای بعد به لایهٔ ورودی اعمال شده است، بنا بر این هنوز هم خاصیت پیش‌بینی‌کنندگی قانون کنترل، حفظ شده است [۲۷]، [۲۸].



شکل۲. شبکهٔ عصبی مصنوعی [۲۸]

یادگیری نرون مصنوعی

به‌طور کلی سه‌گونه یادگیری وجود دارد:

یادگیری با نظارت[۱]: شبکهٔ عصبی با مجموعه‌ای از داده‌ها که شامل بردارهای ورودی و هدف (خروجی دل‌خواه) است، آماده می‌شود. این مجموعه داده‌ها همان مجموعهٔ آموزش است. هدف از آموزش با نظارت آنست که پس از تنظیم مقادیر وزن‌ها، مقدار خطای موجود بین خروجی واقعی نرون و خروجی هدف به حداقل ممکن برسد.

یادگیری بدون نظارت[۲]: هدف یافتن الگوها یا خصوصیات از داده‌های ورودی، بدون کمک گرفتن از منبعی خارجی است. اکثر الگوریتم‌های یادگیری بدون نظارت، اساساً در مورد الگوهای آموزشی بی‌قاعده به‌کار می‌روند.

۱. Supervised Learning ۲. Unsupervised Learning

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

تقویت یادگیری[۱]: هدف در این نوع یادگیری، تشویق کردن نرون یا بخشی از شبکهٔ عصبی به‌ازای عمل‌کرد خوب و جریمه کردن نرون به‌ازای عمل‌کرد بد است [۲۸].

آموزش شبکهٔ با روش پس‌انتشار خطا

در این بخش از الگوریتم LMS برای طبقهٔ مهمی از شبکه‌های عصبی موسوم به شبکه‌های چندلایه پیش‌خور ارائه می‌شود. این تعمیم موسوم است به یادگیری پس‌انتشار خطا که مبتنی بر قانون یادگیری اصلاح خطا است. از قانون یادگیری پس‌انتشار خطا (BP) برای آموزش شبکه‌های عصبی چندلایه پیش‌خور که عموماً شبکه‌های چندلایه پرسپترون (MLP) هم نامیده می‌شود، استفاده می‌کنند. به‌عبارتی توپولوژی شبکه‌های پس‌انتشار خطا تکمیل می‌شود. این قانون–مثل قانون LMS– تقریبی است از الگوریتم S.D و در چارچوب یادگیری عمل‌کردی قرار می‌گیرد.

شبکهٔ عصبی پس‌انتشار خطا از تعداد زیادی نرون که در لایه‌های مختلف (ورودی، میانی و خروجی) قرار گرفته، تشکیل شده است. این شبکه، یک شبکهٔ قدرتمند تعیین نگاشت است که مـی‌تواند بـرای یادگیری رابطهٔ بین پارامترهای ورودی و خروجی استفاده شود. بیش از ۵۰ مدل شبکهٔ عصبی تاکنون ساخته شده است و ثابت شده که الگوریتم یادگیری پس‌انتشار خطا پرطرفدارترین و بهترین الگوریتم یادگیری در شبکه‌های عصبی چندلایه است. این الگوریتم برای آموزش شبکه‌های عصبی چندلایه پیش‌خور استفاده می‌شود [۲۸].

قانون پس‌انتشار خطا از دو مسیر اصلی تشکیل می‌شود: مسیر اول به مسیر رفت موسوم است که در این مسیر، بردار ورودی به شبکهٔ پرسپترون چندلایه اعمال می‌شود و تأثیر آن از طریق لایه‌های میانی به لایه‌های خروجی انتشار می‌یابد. بردار خروجی تشکیل یافته در لایه خروجی، پاسخ واقعی شبکهٔ پرسپترون چندلایه را تشکیل می‌دهد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می‌شوند.

مسیر دوم به مسیر بازگشت موسوم است. در این مسیر، برعکس مسیر رفت، پارامترهای شبکهٔ پرسپترون چندلایه تغییر یافته و تنظیم می‌گردند. این تنظیم مطابق با قانون اصلاح خطا

۱. Reinforcement Learning

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

صورت می‌گیرد. سیگنال خطا، در لایهٔ خروجی شبکه تشکیل می‌شود. مقدار خطا پس از محاسبه در مسیر برگشت از لایهٔ خروجی و از طریق لایه‌های شبکه، در همهٔ شبکه توزیع می‌گردد. چون توزیع اخیر در مسیر خلاف مسیر ارتباطات وزنی سیناپس‌ها صورت می‌پذیرد، کلمهٔ پس‌انتشار خطا[1] برای توضیح اصلاح رفتاری شبکه انتخاب شده است. پارامترهای شبکه طوری تنظیم می‌شوند که پاسخ واقعی آن هرچه بیش‌تر، به پاسخ مطلوب نزدیک‌تر شود. به این روش اصلاح خطا اصطلاحاً روش بهینه‌سازی شیب نزولی[2] نیز اطلاق می‌شود.

توسعهٔ الگوریتم‌های پس‌انتشار خطا با فراهم آوردن روش محاسباتی کارا، رنسانسی در شبکه‌های عصبی ایجاد کرد؛ زیرا شبکه‌های پرسپترون چندلایه با قاعدهٔ آموزش پس‌انتشار خطا هم‌چنان بیش‌ترین کاربرد را در حل مسائل فنی و مهندسی دارند [۲۷]، [۲۸].

جمع‌آوری و آماده‌سازی داده‌ها در منطقهٔ بررسی شده

سد مخزنی سرابی در فاصله ۲/۲ کیلومتری بالادست ایستگاه هیدرومتری پل علی‌آباد و حدود ۱۰ کیلومتری شرق شهر تویسرکان در مختصات جغرافیایی ٤٨ درجه و ۳۲ دقیقه طول شرقی و ۳٤ درجه و ۳۳ دقیقهٔ عرض شمالی بر روی رودخانه گزندر واقع شده است. مساحت حوضهٔ آبریز تا محور سد سرابی ۳۳ کیلومتر مربع است (شکل ۳).

دسترسی به محل سد سرابی از شهر تویسرکان و از طریق جادهٔ اصلی آسفالته موجود در مسیر تویسرکان- ملایر امکان‌پذیر است.

بدنهٔ سد سرابی از نوع سنگ‌ریزه‌ای با هستهٔ رسی قائم به ارتفاع ساختمانی ٦۹ متر تا تراز ۲۲۱٤ متر از سطح دریا و طول تاج ۲۸۷ متر است.

کالورت تخلیه کنندهٔ تحتانی و آب‌گیر کشاورزی در تکیه‌گاه چپ قرار دارند سرریز سد از نوع شوت آزاد با مقطع کنترل اوجی در تکیه‌گاه راست سد جانمایی شده‌اند. حوضهٔ آبریز سد در محدودهٔ آبریز رودخانه قلقل‌رود قراردارد و ارتفاع ساخت‌گاه سد حدود ۲۱٤٥ متر از سطح تراز دریا است. از اهداف مهم احداث این سد می‌توان علاوه بر کنترل سیلاب حوضه، برای تأمین

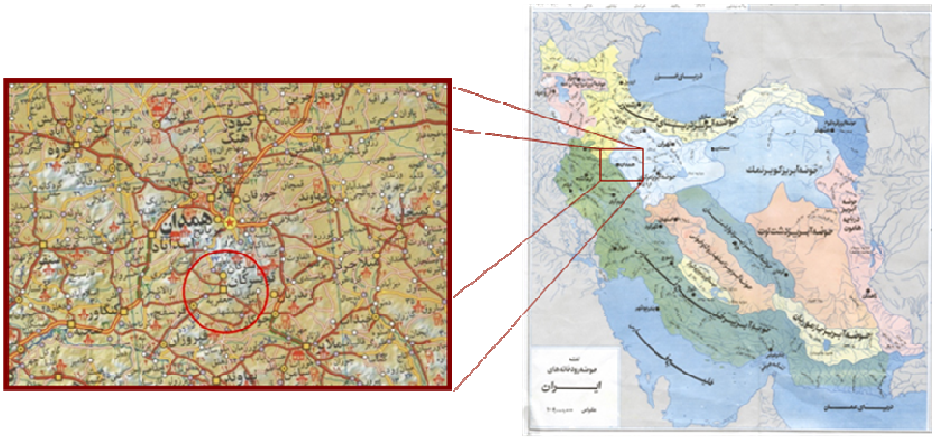
۱. Back Propagation ۲. Gradient Descent Optimization

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

آب مورد نیاز باغداری، شرب، پرورش ماهی و گسترش زراعت و باغبانی و مکان‌های تفریحی و سیاحتی اشاره گردد.

مصالح استفاده شده در هستهٔ رسی سد مخزنی سرابی از نوع رس‌های لاغر (CL) است [۲۹].



شکل ۳. موقعیت جغرافیایی سد سرابی در استان همدان و در فاصلهٔ ده کیلومتری شرق شهر تویسرکان [۳۰]

در این تحقیق در ابتدا اطلاعات مورد نیاز برای تحلیل برگشتی، جمع‌آوری گردید. این داده‌ها شامل مشخصات زمین‌شناسی مهندسی و فعالیت اجرایی سدسازی‌اند و با نگاهی گذرا به اطلاعات جمع‌آوری شده از آن‌ها می‌توان دریافت که دامنه متنوعی از شرایط محتمل را دارا هستند. بنا بر این می‌توان بیان کرد که شبکهٔ آموزش دیده با این اطلاعات، دارای تعمیم زیادی است و می‌توان از آن برای تحلیل برگشتی لایه‌های اجرایی در ماه‌های آینده و در پروژه‌های با شرایط مشابه با اطمینان زیاد، استفاده کرد.

پس از جمع‌آوری این اطلاعات، داده‌های حاصل دسته‌بندی شدند که حاصل آن ۱۲٤٥ دسته داده با ۹ پارامتر است (۱۱۲۰۵ پارامتر اندازه‌گیری شده). در جدول ۱ داده‌ها، در سه ردیف با عناوین حداکثر، حداقل و میانگین آورده شده است که در ردیف مربوط به میانگین، میانگین عددی حاصل از ۱۲٤٥ عدد چال دانسیته قید شده است و در دو ردیف دیگر نیز

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

حداقل و حداکثر ممکن در بین ۱۲٤٥ عدد چال دانسیته آورده شده است. در این جدول رابطهٔ عددی شاخص خمیری با نشانهٔ خمیری و حد روانی برقرار نیست زیرا هر کدام از داده‌های حداکثر و حداقل، الزاماً مربوط به یک چال دانسیته نیست.

پارامترهای ورودی و خروجی شبکهٔ عصبی

پارامترهای ورودی شبکهٔ عصبی مورد نظر، با توجه به میزان تأثیر گذاری‌شان بر روی خروجی هدف شبکه، شامل ۸ پارامتر است که این ۸ پارامتر در زمان عملیات اجرایی سد سازی، به‌سهولت قابل برداشت و محاسبه هستند. پارامترهای ورودی شبکهٔ عصبی در ادامه آمده است.

الف) پارامترهای زمین‌شناسی مهندسی که شامل ٤ پارامتر بدین شرح است:

۱. حد روانی، ۲. نشانه خمیری، ۳. درصد عبوری از الک ۲۰۰، ٤. رطوبت بهینهٔ آزمایشگاهی

ب) پارامترهای اجرایی سدسازی که شامل ٤ پارامتر بدین شرح است:

۱. تعداد دفعات عبور غلتک، ۲. دانسیتهٔ حاصل شده در محل، ۳. ضخامت لایه‌های اجرا شده، ٤. رطوبت لایه‌های اجرا شده.

پارامتر خروجی شبکهٔ عصبی، پارامتر عمدهٔ زمین‌شناسی مهندسی در ارزیابی قابلیت حصول اطمینان از خصوصیات تراکمی خاک است.

این پارامتر عبارت است از درصد تراکم حاصل شده در محیط اجرای هستهٔ رسی سد مخزنی سرابی، خلاصه این پارامترها در جدول‌های ۱ و ۲ آمده است.

جدول ۱. اطلاعات آزمایشگاهی استفاده شده [۳۱]

	تعداد کل چال های مورد تجزیه و تحلیل	دانسیته نسبی خشک در محل (gr/cm^3)	ضخامت لایه (cm)	رطوبت در محل (٪)	دفعات عبور غلتک	رطوبت بهینه (٪)	LL (٪)	PL (٪)	عبوری الک ۲۰۰ (٪)	تفاضل رطوبت اجرا شده از رطوبت بهینه	تراکم نسبی (٪)	حداکثر دانسیته آزمایشگاه (gr/cm^3)	PI (٪)
میزان حداکثر	۱۲۴۵	۱.۹۳	۲۳	۲۳.۱	۱۲	۲۱	۴۲	۲۱.۲	۸۷.۶	۴.۷	۱۰۸	۱.۸۸	۲۱.۲
میزان حداقل	-	۱.۵۰	۸.۵	۸.۸	۴	۱۴	۲۷	۱۶.۷	۵۰.۱	-۹.۲	۸۵	۱.۶۹	۹.۹
میانگین	-	۱.۷۵	۱۵.۸	۱۶.۷	۸.۲	۱۷.۱	۳۴	۱۸.۸	۶۵.۲	-۰.۵	۹۹	۱.۷۸	۱۵.۲

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

جدول۲. پارامترهای ورودی و خروجی شبکهٔ عصبی- تحلیل پس‌انتشار خطا در سد مخزنی سرابی [۳۱]

ورودی های شبکه					
ردیف	شرح آیتم	واحد	شناسه	مقادیراندازه گیری شده	
				حداقل	حداکثر
۱	حد روانی	درصد	LL	۴۲	۲۷
۲	حد خمیری	درصد	PL	۲۱.۲	۱۶.۷
۳	عبوری الک ۲۰۰	درصد	-	۸۷.۶	۵۰.۱
۴	رطوبت بهینه آزمایشگاهی	درصد	mopt	۲۱	۱۴
۵	رطوبت اجرا شده در محل	درصد	m	۲۳.۱	۸.۸
۶	ضخامت لایه	cm	T	۲۳	۸.۵
۷	دفعات عبور غلتک	دفعه(بار)	p	۱۲	۴
۸	دانسیته در محل	gr/cm3	$d\gamma$	۱.۹۳	۱.۵
خروجی شبکه					
۱	میزان تراکم لایه ها	درصد	Dr	۱۰۸	۸۵

تعیین نوع شبکهٔ عصبی استفاده شده

پس از مرحلهٔ جمع‌آوری داده‌ها و آماده‌سازی آن‌ها، باید نوع شبکهٔ عصبی استفاده شده تعیین شود. در مرحلهٔ تعیین نوع شبکهٔ عصبی، چنان‌که در بخش‌های قبلی بیان شد، شبکه‌های عصبی متعددی وجود دارند که باید پس از بررسی آن‌ها، بهترین شبکه را انتخاب کرد.

در این تحقیق، به‌منظور پیش‌بینی و تخمین پارامتر تراکم حاصل شده در سد مخزنی سرابی با استفاده از شبکه‌های عصبی آموزش دیده بر اساس نتایج تراکمی حاصل شده از ۱۲٤٥ عدد چال دانسیتهٔ نسبی بررسی شده، شبکهٔ عصبی چندلایه پیش‌خور با روش آموزشی با نظارت پس‌انتشار خطا بهترین گزینه است. دلایل استفاده از شبکهٔ عصبی پس‌انتشار خطا، بدین شرح است:

هدف از این تحقیق، تخمین و پیش‌بینی پارامترها است که شبکهٔ عصبی پس‌انتشار خطا در این زمینه بسیار خوب عمل می‌کند. یادگیری این نوع شبکهٔ عصبی با ناظر است. یعنی با توجه به ورودی‌ها و خروجی‌های معین، می‌توان ارتباط بین پارامترهای بردار ورودی و خروجی را به‌دست آورد. بنا بر این با توجه به این‌که هدف از این تحقیق نیز تعیین رابطهٔ غیرخطی پیچیده بین پارامترهای ورودی و خروجی است، این نوع شبکهٔ عصبی بسیار مناسب است. ساختمان این شبکه و کار با آن نسبت به بسیاری از شبکه‌های دیگر ساده‌تر است.

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

پس از انتخاب نوع شبکه، مرحلهٔ بعدی معماری شبکه و طراحی پارامترهای مؤثر برآن است. این پارامترها عبارتند از:

الف) تعداد نرون‌ها در لایه‌های ورودی و خروجی، ب) تعداد لایه‌های پنهان، ج) تعداد نرون‌ها در لایه پنهان، د) توابع فعالیت لایه‌های مختلف شبکه، ه)انتخاب خطای مناسب برای شبکه، و) پیش‌پردازش داده‌ها، ز)تقسیم‌بندی درست داده‌ها به سری‌های آموزشی، ارزیابی و آزمایشی،ح) پیش پردازش داده‌ها، ط) تعیین نوع روش، آموزش و یادگیری.

آموزش شبکهٔ و بررسی عمل‌کرد شبکهٔ عصبی مصنوعی

برای تعیین تعداد نرون‌ها در لایه‌های ورودی و خروجی شبکهٔ عصبی با توجه به این‌که ۸ پارامتر ورودی برای شبکه در نظر گرفته شده است، تعداد نرون‌ها در لایهٔ ورودی شبکه ۸ عدد است، تعداد نرون‌ها در لایهٔ خروجی شبکه نیز با توجه به پارامتر خروجی مورد نظر، ۱ عدد است.

در این تحقیق، با توجه به تعداد زیاد داده‌ها و پراکنده بودن مقادیر آن‌ها، برای یافتن تعداد بهینه لایه‌های پنهان شبکه و نیز تعداد بهینه نرون‌ها در این لایه‌ها، چندین شبکه متفاوت از نظر تعداد لایه‌های پنهان و تعداد نرون‌های موجود در لایه‌های پنهان ساخته و اجرا شد. در هر مرحله، مقادیر میانگین مربع خطا (MSE) و ضریب هم‌بستگی بین خروجی‌های هدف و واقعی شبکه مربوطه (R) به‌دست آمد. در نهایت مشخص شد که شبکه‌ای با دو لایهٔ پنهان و تعداد نرون‌های ٤٥ (لایه اول) و یک (لایه دوم) دارای کم‌ترین مقدار میانگین مربع خطا و بیش‌ترین مقدار ضریب هم‌بستگی است که نتایج این بررسی‌ها در جدول ۳ آمده است.

تعیین توابع فعالیت لایه‌های شبکهٔ عصبی مصنوعی

هر نرون به یک تابع فعالیت نیاز دارد. اما به‌دلیل آن‌که نرون‌های هر لایه نقش مشابهی دارد، بنا بر این به توابع فعالیت یک‌سانی نیاز دارند. در این تحقیق توابع فعالیت شبکهٔ عصبی،

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

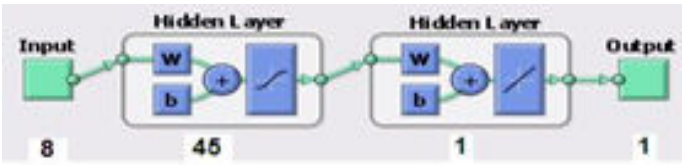
برای تحلیل پس‌انتشار خطا در سد مخزنی سرابی، در دو لایه پنهان (تانژانت سیگموئید و خطی) و لایه خروجی (خطی) است (شکل٤).

جدول۳. بررسی ساختار بهینهٔ شبکهٔ عصبی پس‌انتشار خطا در سد مخزنی سرابی [۳۲]

ردیف	شبکه	تعداد لایه ها			مشخصات لایه ها						MSE	R
		خروجی	پنهان	ورودی	مخفی ۱			مخفی ۲		خروجی		
		تعداد نرون	ورودی	پنهان	تابع فعالیت	تعداد نرون	تعداد ورودی	تابع فعالیت	تعداد نرون	تابع فعالیت		
۱	Net۱	۱	۲	۸	TANSIG	۱۰	۱	PURLIN	۱	PURLIN	1.78E-03	۰.۹۸۵۶
۲	Net۲	۱	۲	۸	TANSIG	۲۰	۱	PURLIN	۱	PURLIN	1.25E-03	۰.۹۹۶۵
۳	Net۳	۱	۲	۸	TANSIG	۲۵	۱	PURLIN	۱	PURLIN	1.05E-03	۰.۹۹۳۱۷۲
۴	Net۴	۱	۲	۸	TANSIG	۳۰	۱	PURLIN	۱	PURLIN	9.03E-04	۰.۹۹۴۰۹
۵	Net۵	۱	۲	۸	TANSIG	۴۵	۱	PURLIN	۱	PURLIN	6.42E-12	۰.۹۹۹۹۹

تعیین خطای مناسب

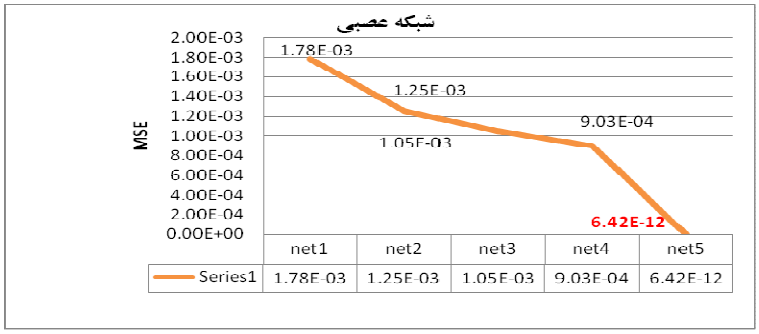
در این تحقیق، با توجه به تعداد پارامترها و دسته داده‌ها و ارتباط غیرخطی بین پارامترهای شبکه، کم‌ترین خطای ممکن تا رسیدن به بالاترین ضریب هم‌بستگی مدنظر قرار گرفته است. در شکل ۵، سیر نزولی گرادیان خطای آموزش، در ۵ شبکه بررسی شده براسی تحلیل پس‌انتشار خطا در سد مخزنی سرابی، آمده است.



شکل٤. ساختار شبکهٔ عصبی پس‌انتشار خطا در سد مخزنی سرابی [۳۲]

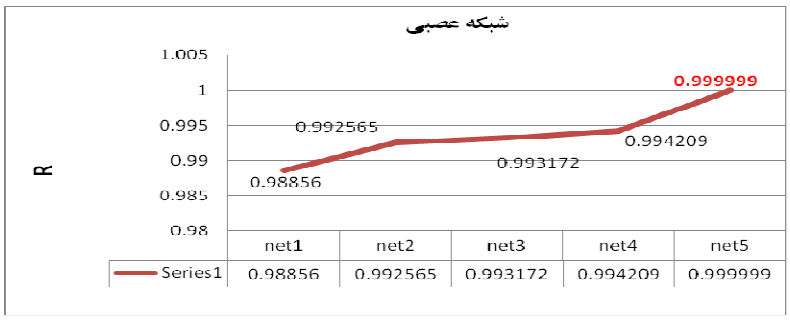
[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]



شکل۵. سیر نزولی گرادیان خطا در مرحلهٔ آموزش شبکهٔ عصبی [۳۲]

در شکل٦، سیر صعودی گرادیان ضریب هم‌بستگی بین خروجی‌های هدف و خروجی‌های واقعی شبکه، در طول دورهٔ آموزش شبکه، در ۵ شبکه بررسی شده برای تحلیل پس‌انتشار خطا در سد مخزنی سرابی، آمده است.



شکل٦. سیر صعودی گرادیان ضریب هم‌بستگی در مرحلهٔ آموزش شبکهٔ عصبی [۳۲]

تقسیم‌بندی داده‌ها

در شبکه‌های عصبی، عموماً داده‌ها به سه قسمت آموزشی، ارزیابی و آزمایشی تقسیم‌بندی می‌شوند:

داده‌های آموزشی داده‌هایی هستند که در فرآیند آموزش شبکه استفاده شده، قرار می‌گیرند. همچنین از این داده‌ها برای محاسبهٔ گرادیان و بهینه ساختن وزن‌ها و بایاس‌ها نیز استفاده می‌شود.

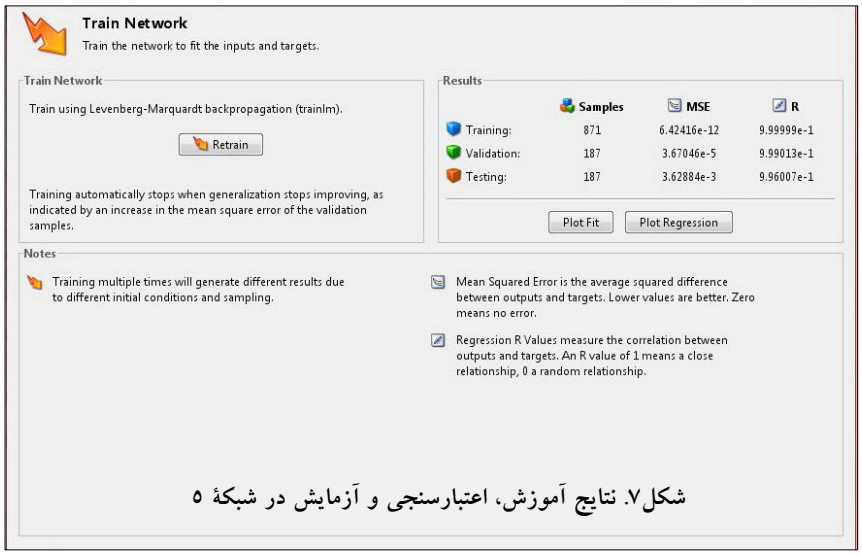
[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

داده‌های ارزیابی در واقع بخشی از داده‌های آموزشی هستند. این داده‌ها عموماً به‌دلیل جلوگیری کردن از بروز پدیده بیش‌یادگیری و حفظ کردن داده‌ها، به‌وسیلهٔ شبکه در طی فرایند آموزشی، به‌کار می‌روند.

داده‌های آزمایشی، برای آزمایش کردن درستی شبکه استفاده می‌شوند. این داده‌ها در طی آموزش شبکه استفاده نمی‌شوند ولی برای مقایسهٔ میزان خطا استفاده می‌شوند. این داده‌ها هم‌چنین برای رسم خطای داده‌های آزمایشی در طی فرایند آموزش، استفاده می‌شوند.

در این تحقیق، ۷۰ درصد از داده‌ها برای آموزش، ۱۵ درصد برای ارزیابی و ۱۵ درصد نیز برای آزمون در نظر گرفته شده‌اند (شکل ۷).



شکل۷. نتایج آموزش، اعتبارسنجی و آزمایش در شبکهٔ ۵

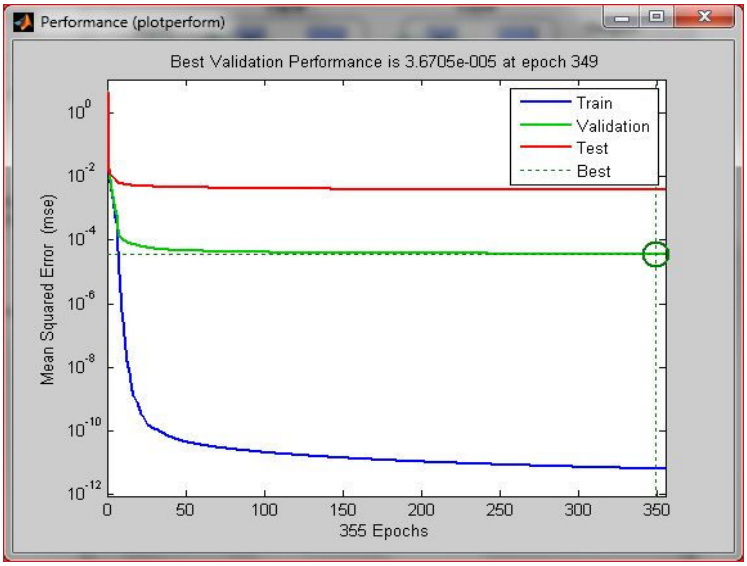
برای دسته‌بندی داده‌ها، دو راه وجود دارد:

به دل‌خواه قسمتی از داده‌ها به‌عنوان داده‌های آموزشی و باقی به‌عنوان داده‌های ارزیابی و آزمایشی انتخاب شوند. در این حالت، امکان درست انتخاب نکردن داده‌ها بیش‌تر است. زیرا مثلاً، با انتخاب یک‌سری از داده‌های شبیه به هم و تکرار داده‌های آن‌ها، در بین داده‌های آموزشی، شبکه می‌تواند با خصوصیات آن داده‌ها آموزش یابد و دارای همان خصوصیات

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]
[DOR: 20.1001.1.22286837.1389.4.2.5.5]

شود، درحالی که کل داده‌ها دارای این خصوصیت نیستند. یکی از نتایج کار این است که داده‌های آزمون جواب ضعیفی می‌دهند و جواب هم‌خوان با داده‌های آموزشی نست.

برنامه به نحوی نوشته شود که داده‌ها به‌طور تصادفی انتخاب شوند. در این حالت، چون داده‌ها از قسمت‌های مختلف مجموعه داده‌ها انتخاب می‌شوند، تمام خصوصیات را در بر می‌گیرند و خصوصیات داده‌ها به سمت مجموعهٔ خاصی از داده‌ها میل پیدا نمی‌کند. در این تحقیق از روش دوم استفاده شده است. در این راستا، با استفاده از تابع دستوری (Dividevec) در نرم‌افزار (MATLAB 7.9.0)، داده‌ها به‌صورت تصادفی در سه مجموعهٔ آموزشی، ارزیابی و آزمایشی، با درصد تعیین شده قرارگرفتند که در شکل ۸ (الف و ب) نشان داده شده است که بهترین نتایج حاصل از اعتبارسنجی در ۳۴۹ دور به‌دست آمده شده است.



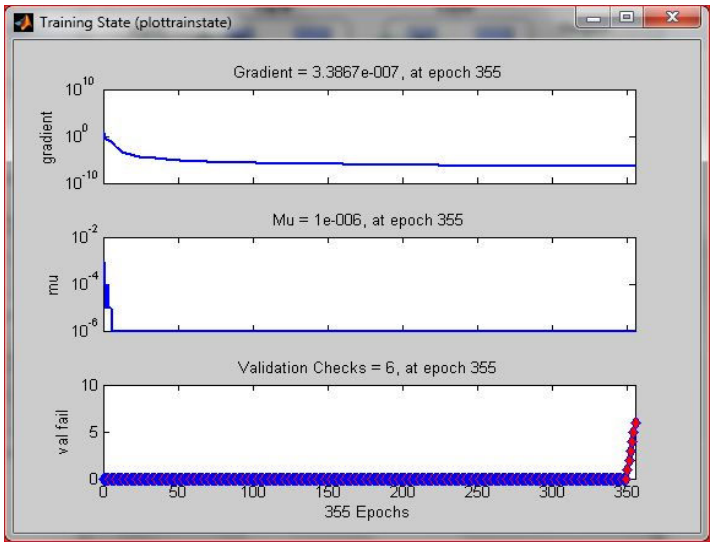
شکل۸ الف. عمل‌کرد شبکهٔ عصبی تحلیل پس‌انتشار خطا در سد مخزنی سرابی در هنگام آموزش

پیش‌پردازش و پس‌پردازش داده‌ها

از تکنیک‌هایی که استفاده از آن‌ها می‌تواند باعث آموزش بهتر شبکه شود، پیش‌پردازش داده‌ها است. در این تحقیق با توجه به دامنهٔ گسترده مقادیر پارامترها، با ارائه مقادیر واقعی

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]
[DOR: 20.1001.1.22286837.1389.4.2.5.5]

آن‌ها به شبکه، امکان دارد که خطاهایی در آموزش شبکه ایجاد شود. این خطا عمدتاً ناشی از اهمیت یافتن تصادفی پارامتری کم اهمیت و یا بالعکس، به خاطر مقادیر بسیار زیاد یا بسیار کم آن‌ها است.



شکل۸ ب. عمل‌کرد شبکهٔ عصبی تحلیل پس‌انتشار خطا در سد مخزنی سرابی در هنگام آموزش

برای جلوگیری از بروز این خطا، در این تحقیق تمامی داده‌های ورودی و خروجی، با استفاده از تابع دستوری (mapminmax) در نرم‌افزار (MATLAB 7.9.0)، در محدودهٔ [۱،۱-] نگاشت خطی شدند.

برای پس‌پردازش داده‌های آتی، کدهای نگاشت خطی داده‌ها در این نرم‌افزار در فایلی ذخیره شدند تا در زمان نیاز، داده‌ها با توجه به این کدها، با تابع دستوری (mapminmax 'reverse') در همین نرم‌افزار نگاشت معکوس، خطی شوند.

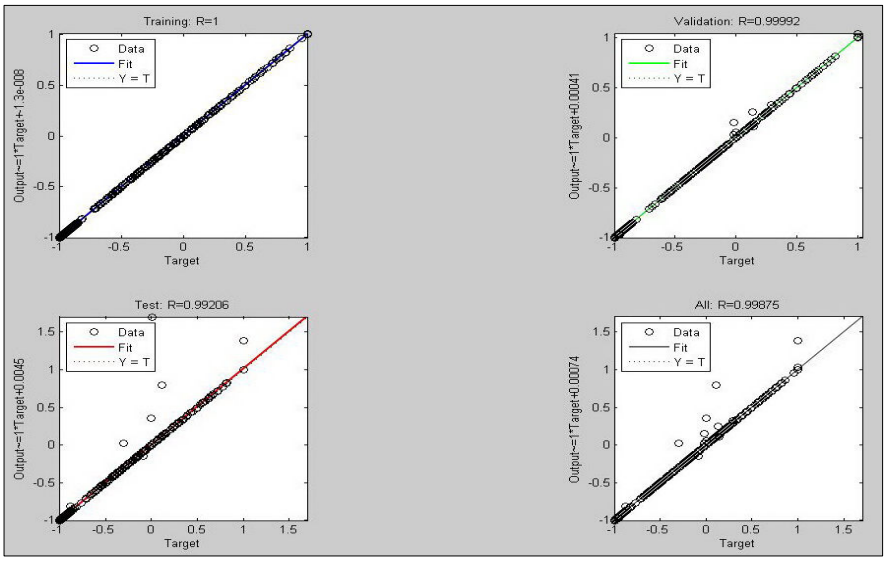
تعیین نوع روش آموزش و یادگیری

برای آموزش شبکهٔ عصبی، در نرم افزار (MATLAB 7.9.0)، ۱٤ روش کلی وجود دارد.

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

با توجه به شبکهٔ عصبی طراحی شده، اهداف شبکه، زمان، میزان حافظهٔ مورد نیاز کامپیوتر و راهنمایی‌های ارائه شده در این نرم‌افزار، روش آموزشی LM (Levenberg-Marquardt) برای آموزش شبکهٔ عصبی در تحلیل پس‌انتشار خطا در سد مخزنی سرابی استفاده شده است. برای تعیین درستی شبکه، ضریب هم‌بستگی خروجی‌های واقعی و هدف شبکه بررسی شده‌اند. نتایج نشان می‌دهند که شبکهٔ طراحی شده برای تحلیل پس‌انتشار خطا در سد مخزنی سرابی، NET 5، به‌خوبی آموزش دیده است و ضریب هم‌بستگی در آن ۰.۹۹۹۹۹۹ و صحت شبکه تقریبا ۱۰۰ درصد است (شکل ۹).



شکل ۹. نمودار ضریب هم‌بستگی خروجی هدف و خروجی واقعی شبکه NET 5 [۳۱]

تعیین صحت عمل‌کرد شبکه با داده‌های آزمایشی جدید

برای صحت عمل‌کرد شبکه و اطمینان از نحوهٔ عمل‌کرد آن، تعداد ۸۹ داده جدید که دارای ۸ پارامتر هستند (متناسب با جدول ۲)، به شبکه داده شد. نتایجی که شبکه پیش‌بینی کرد، با نتایج واقعی در جدول٤ با هم مقایسه شده‌اند و نتایج نهایی در جدول ۵ آمده است.

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

شیوهٔ عمل‌کرد شبکه در تحلیل داده‌ها

پس از انجام آزمایش، دانسیتهٔ نسبی برجا در محل، و پس از تعیین رطوبت مصالح در آزمایشگاه، از تقسیم دانسیتهٔ خشک محل به دانسیتهٔ حداکثر آزمایشگاه و ضرب آن در عدد ۱۰۰ میزان تراکم برحسب درصد به‌دست می‌آید. اما در شیوهٔ آموزش داده شده به‌شبکه، این شبکه است که تصمیم می‌گیرد با توجه به ۸ پارامتر ورودی بیان شده؛ چه تراکم آزمایشگاهی برای خاک مورد نظر لحاظ کند و در نتیجهٔ آن، علاوه بر درصد تراکم حداکثر، دانسیتهٔ آزمایشگاه نیز محاسبه شود، که از تقسیم دانسیتهٔ خشک در محل بر درصد تراکم، ضرب در صد این عدد به‌دست می‌آید.

جدول ٤. مقایسهٔ نتایج تراکم واقعی موجود در داده‌های آزمایشگاه و شبیه‌سازی شبکهٔ عصبی مصنوعی [۳۲]

ردیف	درصد تراکم با لحاظ حداکثر دانسیته آزمایشگاه	تراکم شبیه سازی شده توسط شبکه (٪)	اختلاف پیش بینی (٪)	ردیف	درصد تراکم با لحاظ حداکثر دانسیته آزمایشگاه	تراکم شبیه سازی شده توسط شبکه ٪	اختلاف پیش بینی (٪)	ردیف	درصد تراکم با لحاظ حداکثر دانسیته آزمایشگاه	تراکم شبیه سازی شده توسط شبکه (٪)	اختلاف پیش بینی (٪)
1	97.77	98.19	0.42	31	96.11	96.54	0.43	53	100.00	99.38	0.62
2	94.41	95.20	0.79	32	100.56	100.50	0.06	54	104.14	101.92	2.22
3	98.32	99.06	0.74	33	95.56	95.94	0.38	**55**	**98.82**	**95.91**	**2.91**
4	101.11	101.82	0.71	34	100.00	101.35	1.35	87	101.12	101.45	0.33
5	97.22	98.08	0.86	35	100.56	100.90	0.34	88	101.69	102.05	0.36
6	101.67	102.38	0.71	36	100.56	101.07	0.51	89	99.40	100.70	1.30
7	100.60	100.77	0.17	37	99.44	99.73	0.29	78	100.56	101.31	0.75
8	93.30	94.20	0.90	38	98.33	98.88	0.55	56	98.90	97.76	1.14
9	94.41	95.05	0.64	39	94.01	95.25	1.24	57	100.55	99.60	0.95
10	95.81	97.06	1.25	40	100.56	102.03	1.47	58	97.79	96.56	1.23
11	103.35	104.15	0.80	41	102.22	103.24	1.02	59	100.55	99.52	1.03
12	97.77	99.37	1.60	42	91.72	90.31	1.41	60	95.03	93.84	1.19
13	100.56	101.68	1.12	43	99.44	98.81	0.63	61	99.41	97.12	2.29
14	97.77	99.24	1.47	44	101.69	100.93	0.76	62	97.62	98.55	0.93
15	98.80	98.85	0.05	45	99.44	98.86	0.58	63	100.00	101.11	1.11
16	98.88	98.92	0.04	46	100.56	99.90	0.66	64	98.88	100.02	1.14
17	98.88	98.91	0.03	47	101.69	100.93	0.76	65	95.53	96.69	1.16
18	96.63	96.89	0.26	48	99.41	98.17	1.24	66	96.06	97.25	1.19
19	96.63	96.81	0.18	49	100.59	99.71	0.88	67	98.32	99.46	1.14
20	101.69	101.56	0.13	50	97.75	96.96	0.79	68	97.02	97.69	1.67
21	97.60	98.15	0.55	51	100.00	98.92	1.08	69	95.24	93.00	2.24
22	**97.60**	**97.62**	**0.02**	52	100.00	98.99	1.01	70	99.45	98.33	1.12
23	97.75	98.12	0.37	53	101.12	99.92	1.20	71	101.66	100.62	1.04
24	98.31	98.89	0.58	54	96.07	95.44	0.63	72	100.00	98.94	1.06
25	100.00	100.40	0.40	55	95.27	95.88	0.61	73	97.79	96.75	1.04
26	100.00	100.39	0.39	56	102.96	100.91	2.05	74	101.66	100.60	1.06
27	100.56	100.98	0.42	57	103.35	102.61	0.74	75	94.05	91.53	2.52
28	95.81	96.03	0.22	58	102.23	101.47	0.76	76	94.64	94.66	0.02
29	94.01	95.21	1.20	59	93.85	93.40	0.45	77	100.00	100.84	0.84
30	94.44	95.33	0.89	60	101.12	100.43	0.69				

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

جدول ۵ . نتایج حاصل از مقایسهٔ داده‌های واقعی با نتایج پیش‌بینی شده به‌وسیلهٔ شبکهٔ عصبی مصنوعی [۳۲]

0.88	میانگین اختلاف پیش بینی توسط شبکه	2.91	حداکثر اختلاف پیش بینی شده توسط شبکه	91.7	حداقل تراکم واقعی	104.1	حداکثر تراکم واقعی	98.7	تراکم میانگین داده های واقعی
		0.02	حداقل اختلاف پیش بینی شده توسط شبکه	90.3	حداقل تراکم پیش بینی شده توسط شبکه	104.2	حداکثر تراکم پیش بینی شده توسط شبکه	98.7	تراکم میانگین داده های پیش بینی شده توسط شبکه

نتایج حاصل از شبکهٔ عصبی مصنوعی

۱. با در دست داشتن مقادیر دقیق پارامترهای فیزیکی و مکانیکی خاک و اطلاعات اجرایی سدسازی و تراکم، با دقت بسیار زیاد می‌توان تراکم حاصل و به‌تبع آن حداکثر دانسیتهٔ خشک آزمایشگاه را پیش‌بینی کرد.

۲. از جمله نکات این تحقیق، محاسبهٔ تراکم آزمایشگاه با لحاظ کردن پارامترهای مکانیک خاک چون حدود اتربرگ، عبوری الک ۲۰۰ و ... پارامترهای اجرایی است، به‌عبارت دیگر در روش‌های معمول (که هم‌اکنون در حال اجرا است) به پارامترهای اجرایی مانند انرژی غلتک و ... توجه نمی‌شود و همین امر یکی از مشکلات روش‌های تراکم آزمایشگاهی است. و به‌همین دلیل روش‌های مختلف A، B، C و D و به‌دنبال آن روش‌های اصلاح شده پدیدار گشته است. اما در این شیوه علاوه بر لحاظ نمودن اکثر خصوصیات ژئوتکنیکی خاک، انرژی غلتک، ضخامت لایه، رطوبت و دانسیتهٔ در محل، که از پارامترهای اجرایی هستند؛ نیز در محاسبه حداکثر دانسیتهٔ آزمایشگاه لحاظ می‌گردند و دانسیته محاسبه شده با شبکهٔ عصبی، حداکثر دانسیتهٔ قابل دست‌یابی تحت شرایط محیط اجرا است و این نقطهٔ قوت مهم این تحقیق است.

۳. نتایج به‌دست آمده از شبکهٔ عصبی، حاکی از وجود رابطهٔ پیچیده میان داده‌های ژئوتکنیکی و داده‌های اجرایی با حداکثر دانسیتهٔ محاسبه شده و درصد تراکم حاصل شده دارد، به‌طوری‌که این روابط در تحلیل‌های آماری قابل محاسبه نبود.

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

٤. چنان‌چه بتوان به‌روشی دیگر رطوبت بهینه را به‌دست آورد (مثلاً با به‌دست آوردن یک رابطه بین پارامترهای دیگر مکانیک خاک با رطوبت بهینه)، عملاً شیوه تراکم آزمایشگاه را (که به‌عنوان یک عامل کند کننده پروژه‌های عمرانی است) می‌توان حذف کرد.

منابع

۱. زمردیان، ع.، طهماسبی، ع.، *برآورد پتانسیل روان‌گرایی خاک‌ها با استفاده از شبکهٔ عصبی مصنوعی*، اولین کنگره مهندسی عمران، دانشگاه صنعتی شریف (۱۳۸۲).

2. Zhou, Y. X., Whu, X. P., "Use of Neural Networks in the Analysis and Interpretation of Site Investigation Data", Computer & Geotechnics, Vol. 16 (1994) 105-122.

3. Agrawal, G., Frost. J. D., Chameau, J. L., "Data analysis and Modeling Using an Artificial Neural Network", Proc. 13th Conference of Int. Soc. Soil Mechanics and Foundation Engrg; Vol. 4 (1994) 1441-1444.

4. Goh, A. T. C., "Seismic Liquefaction Potential Assessed by Neural Networks", Journal of Geo technical Engineering, ASCE, 120 (9) (1995) 1467-1480.

5. Goh, A. T. C., "Neural Network Modeling of CPT Seismic Liquefaction Data", Journal of Geo technical Engineering", ASCE, 122 (1) (1996) 70-73.

6. Hadge, Willim E., "Cyclic stress-strain behavior of sand in offshore environment-M.Sc. thesis", Massachusetts Institute of Technology (1979).

۷. مهین‌روستا، ر.، *پیش‌بینی رفتار تنش-کرنش خاک‌های رسی با استفاده از شبکهٔ عصبی مصنوعی*، پایان‌نامهٔ کارشناسی ارشد ژئوتکنیک، دانشگاه صنعتی شریف (۱۳۷۷).

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

8. Penumadu, D., Zhao, R., Modeling "Drained Compression Behavior of Sand Using ANN Numerical Method in Geotechnical Engineering", Geotechnical Special Publication, ASCE, No. 96 (2000) 71-87.

9. Ellis, G. W., Yao, C, Zhao, R. Penumadu, D., "Stress Strain Modeling of Sands Using Artificial Neural Networks", J. Geo. Engrg; Vol. 121, No. 5, (1995) 429-435.

10. Penumadu, D., Jin-Nan. L., Chamcau J-L., Arumugam, S., "Rate Dependent Behavior of Clays Using Neural Networks", Proc.13th Conference of Int. Soc. Soil Mechanics and Foundation Engrg; Vol. 4, (1994) 1445-1448.

11. Abu Kiefa, M. A., "General Regression Neural Networks for Driven Piles in Cohesionless Soils", Geotechnic and Geoenv. Engrg., ASCE; 124 (12), 1177-1185

۱۲. بنی‌مهد، م.، یثربی، ش.، *کاربرد شبکهٔ عصبی مصنوعی در مهندسی ژئوتکنیک: مدلسازی، تحلیل، طراحی*، نشریهٔ فنی و مهندسی مدرس، شماره ۱٤(۱۳۸۲).

۱۳. بابایی، ب.، *کاربرد شبکهٔ عصبی در پیش‌بینی و تفسیر نتایج آزمایش بارگذاری صفحه در خاک‌های ریزدانه*، پایان‌نامهٔ کارشناسی ارشد، دانشگاه تربیت مدرس (۱۳۸۸).

14. Habibagahi, G., Katebi, S., Johari, "A Neural Network Framwork for Asia, eds; Toll & Leong. Balkema", Roucrdam (2000) 107-111.

15. Juang C. h, and Coen, c. J., "CPT-based liquefaction evalution using artificial neural networks", Computer Aided Civil and Infrastructure Engineering, 14 (3) (1999) 221-229.

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

16. Najjar, Y. M., Basheer, I. A., "Utilizing Computional Neural Networks for Evaluating the Permeability of Compacted Clay Liners", Geotechnical and Geological Eng, Vol. 14. No.3 (2000)193-212.

17. Najjar, Y. M., Ali, H. E., "Simulating the stress-strain behavior of Nevada sand by ANN.", Proc, 5th U.S.National Congress on Computional Mechanics (USACM), Boulder, Colorado, August (1999) 4-6.

18. Najjar, Y. M, Ali, H. E., Basheer, I. A., "On the use of neurons for simulating the stress-strain behavior of soils", Proc., 7th Int. symposium on Numerical Models in Geomechanics", G. N. Pande, ed., Graz, Austria, NUMOG VII, September 1-3 (1999) 657-662.

19. Najjar, Y. M., Basheer, I. A., "Neural Network approach for site characterization and uncertainty prediction", Geotechnical Special Publication, ASCE, 58 (1) (1996a) 134-148.

20. Najjar, Y. M., Basheer, I. A., McReynolds, R., "Neural modeling of Kansan soil swelling", Transportation Research Record No.1526, (1996a) 14-19.

21. Najjar, Y. M., Basheer, I. A., Naouss, W. A., "On the identification of compaction characteristics by neuronets", J. Computers and Geotechnics, 18 (3) (1996b) 167-187.

22. Najjar, Y. M., Basheer, I. A., Naouss, W. A., "On the identification of compaction characteristics by neuronets", J. Computers and Geotechnics, 18 (3), (1996b) 167-187.

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]

23. Najjar, Y. M., Ali, H. E., "CPT-based liquifaction potential assess-ment, Aneural approach", Geotechnical Special Publication, ASCE, 1 (1998) 542-553.

24. Shibata. T., Teparaksa, W., "Evaluation of liquefaction potentials of soils using cone peneteration tests", Soils and Foundations, 28 (2), (1988) 49-60.

25. Shahin, M. A., Majer, R. H., Jaksa, M.B., "Predicting Settlement of Shallow Foundtions Using Neural Networks", J. Geo & Geoenvir, Engrg, Vol. 128. No.9 (2002) 785-793.

۲۶. صمدی بخارائی، و.، *کاربردهای MATLAB و SIMULINK درمهندسی*، *انتشارات خراسان*، (۱۳۸۷) صفحات ۱۵۷ و ۱۹۷.

۲۷. منهاج، م.، *مبانی شبکه‌های عصبی ج ۱*، انتشارات صنعتی امیرکبیر(۱۳۸۸) صفحات ۱۶۵و ۱۷۷ تا ۱۸۳.

28. Engelbrecht, A.P., "Computation Intelligence; An Introduction", 2nd ed., John Wiley & Sons Ltd (2007).

۲۹. *مشخصات فنی و خصوصی سد مخزنی سرابی*، جلد سوم، مهندسین مشاور آبدان فراز(۱۳۸۲) صفحات ۲ تا ۱۰۸.

۳۰. *اطلس نقشه راه‌های ایران*، انتشارات مرکز اطلاع رسانی ایران (۱۳۸۷)، صفحات ۱ و ۵۰.

۳۱. *اسناد و اوراق آزمایشگاهی سد مخزنی سرابی*، مهندسین مشاور آبدان فراز و زمین کاوان جنوب (۱۳۸۳ تا ۱۳۸۹).

۳۲. شریفی، علی‌حسن، *ارزیابی خصوصیات تراکم پذیری خاک‌های ریزدانه در ساختمان سد سرابی با استفاده از روش‌های تحلیلی و سیستم شبکه عصبی*، پایان‌نامهٔ کارشناسی ارشد، دانشگاه آزاد اسلامی واحد علوم و تحقیقات (۱۳۸۹).

[Downloaded from ndea10.khu.ac.ir on 2026-11-01]

[DOR: 20.1001.1.22286837.1389.4.2.5.5]