

پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک ماسه‌سنگ‌ها با استفاده از شبکه عصبی مصنوعی و آنالیز رگرسیون چند متغیره

یاسین عبدی^{۱*} و آرتمیس قاسمی دهنوی^۲

۱ و ۲- گروه زمین‌شناسی، دانشکده علوم پایه، دانشگاه لرستان، خرم‌آباد

نویسنده مسئول: Abdi.ya@lu.ac.ir *

دریافت: ۹۷/۸/۱ پذیرش: ۹۸/۱/۲۰

چکیده

تعیین دقیق ویژگی‌های ژئومکانیکی سنگ‌ها از جمله مقاومت فشاری تک‌محوری و مدول الاستیک با استفاده از روش‌های مرسوم آزمایشگاهی، بسیار مشکل و نیازمند صرف زمان و هزینه زیادی می‌باشد. این موضوع به‌خصوص در مورد سنگ‌های ناهمسانگرد، با سطوح لایه‌بندی، متخلخل و ضعیف مطرح می‌باشد. به‌منظور غلبه بر این مشکلات، توسعه روابط و مدل‌های پیش‌بینی کننده برای تخمین این پارامترها در مهندسی سنگ ضروری به نظر می‌رسد. هدف از این مطالعه، پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک ماسه‌سنگ‌ها با استفاده از شبکه عصبی مصنوعی و آنالیز رگرسیون چند متغیره می‌باشد. به‌همین منظور، تعداد ۱۳۰ نمونه مغزه سنگی تهیه شده و آزمایش‌های جامعی بر روی آن‌ها انجام شده است. برای توسعه مدل شبکه عصبی پیش‌بینی کننده، ویژگی‌های فیزیکی سنگ‌های مورد مطالعه شامل سرعت موج، تخلخل، دانسیته خشک، شاخص دوام و درصد جذب آب به عنوان داده‌های ورودی در نظر گرفته شده‌اند، در حالی که مقاومت فشاری تک‌محوری و مدول الاستیک پارامترهای خروجی می‌باشند. عملکرد پیش‌بینی مدل شبکه عصبی پیشنهاد شده و آنالیز رگرسیون چند متغیره با استفاده از شاخص‌های آماری از قبیل R، RMSE و VAF ارزیابی شده است. مقایسه نتایج نشان می‌دهد که عملکرد شبکه عصبی مصنوعی پیشنهاد شده در پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک به مراتب بهتر از آنالیز رگرسیون می‌باشد.

واژه‌های کلیدی: مقاومت فشاری تک‌محوری، مدول الاستیک، شبکه عصبی مصنوعی، آنالیز رگرسیون، ماسه‌سنگ

۱- مقدمه

۱۹۹۴؛ سینگ و دوبی، ۲۰۰۰؛ تریاکی، ۲۰۰۸؛ اوزلیک و همکاران، ۲۰۱۳؛ کالابر و همکاران، ۲۰۱۲؛ یسیل اغلو و همکاران، ۲۰۱۳؛ راجیش کومار و همکاران، ۲۰۱۳؛ عبدی و همکاران، ۲۰۱۸؛ عبدی و خانلری، ۱۳۹۸؛ حق‌نژاد و همکاران، ۱۳۸۹). ایلماز و یوکسک (۲۰۰۸) یک مدل شبکه عصبی مصنوعی همراه با آنالیز رگرسیون چند متغیره برای پیش‌بینی مدول الاستیک ژئوسپس‌ها توسعه دادند. آن‌ها نشان دادند که تکنیک شبکه عصبی مصنوعی قادر است مدول الاستیک سنگ‌های مورد نظر را با دقت بالاتری پیش‌بینی کند. هم‌چنین ایلماز و یوکسک (۲۰۰۹) با استفاده از شبکه‌های عصبی مصنوعی و سیستم‌های فازی-عصبی، مقاومت فشاری تک‌محوری و مدول الاستیک نمونه‌های سنگ ژئوسپس را تخمین زده‌اند. نتایج آن‌ها حاکی از پیش‌بینی موفق مدل شبکه عصبی مصنوعی و فازی-عصبی در مقایسه با رگرسیون چند متغیره می‌باشد. در مطالعه‌ای دیگر، قهرمان و همکاران

مقاومت فشاری تک‌محوری و مدول الاستیک سنگ‌ها، دو عامل مهم و اساسی ژئوتکنیکی برای کاربردهای مهندسی همچون طراحی سد و تونل، انفجار سنگ، شیب‌های سنگی، پی‌های سنگی و حفاری‌های زیرزمینی می‌باشند. روش مستقیم برای تعیین مقاومت فشاری تک‌محوری و مدول الاستیک در آزمایشگاه نیازمند صرف زمان و هزینه زیادی می‌باشد. علاوه بر این، تعیین دقیق این پارامترها نیازمند نمونه‌های مغزه با کیفیت بالا می‌باشد که این امر به‌خصوص در مورد سنگ‌های ضعیف، لایه‌دار و متورق بسیار مشکل است. به‌منظور پرهیز از این مشکلات، بسیاری از محققین مقاومت فشاری تک‌محوری و مدول الاستیک انواع مختلف سنگ‌ها را با استفاده از روابط تجربی توسعه داده شده با آنالیز رگرسیون ساده و چند متغیره و هم‌چنین توسعه مدل‌های مختلف شبکه عصبی مصنوعی پیش‌بینی کرده‌اند (لیندکویست و گودمن،

قرمز بالایی در جنوب قم و منطقه آوج و هم‌چنین ماسه‌سنگ‌های ژوراسیک در همدان) مورد استفاده قرار گرفته است. با توجه به مطالعات پتروگرافی و بر اساس طبقه‌بندی پتی‌جان (۱۹۸۷)، ماسه‌سنگ‌های سازند قرمز بالایی (۱۰۰ نمونه) عمدتاً شامل لیت‌آرنایت و فلدسپاتیک لیت‌آرنایت می‌باشند. در حالی‌که ماسه‌سنگ‌های ژوراسیک همدان (۳۰ نمونه) از نوع ساب‌لیت‌آرنایت و ساب‌آرکوز می‌باشند. هم‌چنین ماسه‌سنگ‌های لیت‌آرنایت سازند قرمز بالایی عمدتاً شامل کالک‌لیتایت‌ها، ولک‌آرنایت‌ها و فیلیت‌آرنایت‌ها می‌باشند. بر این اساس، مقاومت فشاری تک‌محوری، مدول الاستیک مماسی، تخلخل، دانسیته خشک، سرعت موج، شاخص دوام شکستگی و درصد جذب آب آن‌ها بر اساس دستورالعمل انجمن بین‌المللی مکانیک سنگ (۱۹۸۱) تعیین شده است. این مطالعه در نظر دارد که یک مدل شبکه عصبی مصنوعی همراه با آنالیز رگرسیون چند متغیره برای پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک ماسه‌سنگ‌ها توسعه دهد. لازم به ذکر است که مدل شبکه عصبی استفاده شده در این مطالعه از نوع MLP می‌باشد. ساختار شبکه MLP شامل لایه‌های ورودی، مخفی و خروجی می‌باشد. بر این اساس، چندین ویژگی فیزیکی از جمله تخلخل، سرعت موج، دانسیته خشک، دوام شکستگی و درصد جذب آب به عنوان لایه‌های ورودی و دو ویژگی مکانیکی مقاومت فشاری تک‌محوری و مدول الاستیک به عنوان لایه خروجی در نظر گرفته شده‌اند.

بحث و نتایج

به‌منظور توسعه یک شبکه پیش‌بینی کننده، ویژگی‌های مهندسی ۱۳۰ نمونه شامل مقاومت فشاری تک‌محوری، مدول الاستیک، تخلخل (n)، دانسیته خشک (γ_d)، سرعت موج (V_p)، دوام (ID_2) و درصد جذب آب (A_b) مطابق با دستورالعمل (ISRM 1981) تعیین شده است. از آنجائی که امکان آوردن نتایج آزمایشات انجام شده برای تمامی نمونه‌ها مقدور نمی‌باشد، ویژگی‌های فیزیکی-مکانیکی تعدادی از نمونه‌ها در جدول ۲ ارائه شده است. هم‌چنین در جدول ۳ نتایج آنالیزهای آماری توصیفی پایه برای داده‌های اصلی نشان داده شده است.

(۲۰۰۹) مقاومت فشاری تک‌محوری و مدول الاستیک سنگ برش را با توسعه یک مدل شبکه عصبی مصنوعی پیش‌بینی نموده‌اند. بر اساس نتایج آن‌ها مشخص شد که عملکرد شبکه عصبی توسعه داده شده در پیش‌بینی ویژگی‌های ژئوتکنیکی مدنظر به‌مراتب بهتر از آنالیز رگرسیون است. نتایج مشابهی نیز توسط یاگیز و همکاران (۲۰۱۲) برای سنگ‌های کربناته حاصل شده است. آن‌ها با مطالعه اثر دوام شکستگی بر مقاومت فشاری تک‌محوری و مدول الاستیک سنگ‌های آهکی با استفاده از شبکه‌های عصبی مصنوعی و آنالیز رگرسیون چند متغیره نشان دادند که شبکه عصبی روشی به‌مراتب دقیق‌تر می‌باشد. هم‌چنین ترابی‌کاوه و همکاران (۲۰۱۲)، به‌منظور پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک سنگ‌های آهکی آسماری با استفاده از ویژگی‌های فیزیکی، از یک مدل شبکه عصبی مصنوعی و آنالیز رگرسیون چند متغیره استفاده کردند. به این منظور آن‌ها با در نظر گرفتن تخلخل، دانسیته خشک، دوام و سرعت موج به عنوان پارامترهای ورودی، مشاهده کردند که عملکرد پیش‌بینی مدل شبکه عصبی پیشنهاد داده شده بهتر از آنالیز رگرسیون چند متغیره می‌باشد. در مطالعه‌ای دیگر، سونمز و همکاران (۲۰۰۶) مدول الاستیک سنگ‌ها را با استفاده از یک مدل شبکه عصبی مصنوعی و با در نظر گرفتن دانسیته خشک و مقاومت فشاری تک‌محوری به‌عنوان پارامترهای ورودی، پیش‌بینی کرده‌اند.

در جدول ۱، چندین مدل توسعه داده شده شبکه عصبی مصنوعی و فازی برای پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک سنگ‌های مختلف ارائه شده است. با توجه به مطالب عنوان شده، هدف اصلی این مطالعه توسعه یک مدل شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک انواع ماسه‌سنگ‌ها می‌باشد. هم‌چنین به منظور اعتبارسنجی و مقایسه عملکرد شبکه توسعه داده شده، آنالیز رگرسیون چندمتغیره نیز انجام شده است.

مواد و روش‌ها

در این مطالعه تعداد ۱۳۰ مغزه استوانه‌ای از ماسه‌سنگ‌های مختلف (شامل ماسه‌سنگ‌های سازند

جدول ۱. تعدادی از مطالعات اخیر برای پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک با استفاده از شبکه عصبی مصنوعی و

سیستم فازی

R ²	خروجی	ورودی	روش	رفرنس
۰/۹۷	UCS	R, Rn, n, ρ	ANN	مجیدی و رضایی (۲۰۱۳)
۰/۹۷۱	UCS	R, W, ρ, BTS, Vp, Is ₍₅₀₎	ANN	تونیزام محمد و همکاران (۲۰۱۵)
۰/۹۹	UCS	Vp, Is ₍₅₀₎ , Id, ρ	ANN	سرکار و همکاران (۲۰۱۰)
۰/۹۵	UCS	ρ, n, Vp	ANN	ترابی کاوه و همکاران (۲۰۱۴)
۰/۹۱	E	n _e , Is(50), Rn, Id	ANN	ایلماز و یوکسک (۲۰۰۸)
۰/۹۵	E	Vp, Is(50), Rn, WC	ANN ^۱ -	ایلماز و یوکسک (۲۰۰۹)
۰/۷۷	E	Vp, Is(50), Rn, n	ANN	دهقان و همکاران (۲۰۱۰)
۰/۸۹	E	ρ, RQD, n, NJ, GSI	ANN-GA	مجیدی و بیکی (۲۰۱۰)
۰/۶۷	E	-	ANN	سینگ و همکاران (۲۰۱۲)
۰/۸۱	E	Is(50), Rn, Vp	ANN	یزدانی و همکاران (۲۰۱۸)

R نوع لیتولوژی، Rn عدد سختی چکش‌اشمیت، n تخلخل، ρ دانسیته، BTS مقاومت کششی برزیلی، Vp سرعت سیر موج، Is₅₀ شاخص بار نقطه‌ای، Id شاخص دوام شکستگی، n_e تخلخل مؤثر، WC درجه هوازدگی، RQD شاخص کیفیت توده‌سنگ، NJ تعداد درزه‌ها در متر، GSI شاخص مقاومت زمین‌شناختی

جدول ۲. ویژگی‌های فیزیکی-مکانیکی تعدادی از نمونه‌های ماسه‌سنگ استفاده شده در این مطالعه

شماره نمونه	n (%)	γ _d (gr/cm ³)	V _p (km/sec)	A _b (%)	ID ₂ (%)	E (GPa)	UCS (MPa)
۱	۲/۶۲	۲/۸۹	۵/۲۳	۰/۵۳	۹۹/۱۴	۲۰/۴۵	۱۲۸/۱۳
۲	۶/۹۸	۲/۶۵	۳/۱۲	۰/۸۳	۹۸/۰۳	۱۵/۷۱	۹۴/۶۱
۳	۷/۹۶	۲/۴۳	۲/۸۱	۱/۹۳	۹۷/۱۸	۷/۱۵	۴۱/۹۱
۴	۵/۶۲	۲/۵۲	۲/۶۹	۰/۶۷	۹۸/۱۹	۱۲/۱۳	۷۲/۵۰
۵	۵/۸۶	۲/۶۰	۳/۳۶	۰/۵۹	۹۸/۰۸	۱۵/۶۹	۹۵/۴۰
۶	۹/۳۳	۲/۶۵	۲/۱۰	۱/۲۶	۹۸/۸۶	۱۳/۴۲	۸۲/۷۷
۷	۸/۹۰	۲/۵۰	۲/۴۸	۳/۲۵	۹۷/۴۶	۹/۷۵	۷۵/۲۳
۸	۱۳/۲۳	۲/۵۱	۱/۹۲	۴/۰۸	۹۵/۱۷	۶/۵۴	۵۳/۶۴
۹	۱۱/۲۵	۲/۵۷	۲/۰۸	۲/۶۵	۹۹/۱۲	۹/۱۷	۶۱/۷۸
۱۰	۷/۵۳	۲/۷۰	۲/۹۸	۰/۸۳	۹۹/۵۶	۱۲/۲۵	۸۹/۴۷
۱۱	۵/۴۶	۲/۵۹	۳/۱۵	۱/۳۴	۹۸/۵۲	۱۰/۱۲	۶۸/۳۰
۱۲	۷/۱۶	۲/۴۶	۳/۰۷	۱/۴۰	۹۸/۷۶	۹/۵۴	۵۵/۰۰
۱۳	۶/۵۴	۲/۵۳	۲/۹۸	۱/۳۱	۹۹/۰۱	۱۰/۳۲	۵۷/۳۰
۱۴	۷/۴۳	۲/۶۸	۲/۵۴	۲/۰۴	۹۸/۲۳	۹/۵۴	۴۹/۷۰
۱۵	۷/۵۴	۲/۶۱	۲/۷۸	۲/۱۳	۹۸/۳۲	۸/۵۴	۴۸/۹۰
۱۶	۹/۰۰	۲/۶۶	۱/۸۰	۲/۶۷	۹۸/۱۱	۷/۳۲	۴۲/۵۶
۱۷	۷/۸۱	۲/۷۴	۲/۵۶	۲/۴۶	۹۷/۴۸	۸/۴۱	۵۶/۰۰
۱۸	۷/۴۱	۲/۷۶	۲/۸۲	۲/۴۰	۹۷/۶۵	۱۰/۱۲	۶۰/۴۸
۱۹	۹/۲۱	۲/۶۷	۲/۳۵	۳/۰۱	۹۸/۰۸	۸/۴۳	۴۴/۶۴
۲۰	۷/۷۱	۲/۷۶	۲/۹۹	۱/۷۸	۹۷/۸۶	۱۱/۱۳	۶۶/۳۶

¹ Artificial Neural Network

² Adaptive Neuro-Fuzzy Inference System

جدول ۳. نتایج ارزیابی‌های آماری توصیفی پایه برای داده‌های اولیه (۱۳۰ داده)

پارامتر	حداقل	حداکثر	میانگین	انحراف استاندارد
تخلخل (/)	۲/۱۹	۱۴/۹۸	۶/۹۷	۲/۸۳
سرعت موج (کیلومتر بر ثانیه)	۲/۱۰	۲/۹۴	۲/۶۳	۰/۱۸
دانسیته (گرم بر سانتی‌متر مکعب)	۱/۰۹	۲/۶۳	۲/۵۷	۰/۱۷۳
جذب آب (/)	۰/۳۱	۶/۹۰	۱/۹۵	۱/۱۴
شاخص دوام (/)	۹۵/۱۷	۹۹/۵۶	۹۷/۸۳	۰/۸۷
مقاومت فشاری تک‌محوری (مگاپاسکال)	۲۹/۹۴	۱۴۳	۷۲/۴۱	۲۵/۶۷
مدول الاستیک (گیگاپاسکال)	۵/۲۳	۲۲/۵۱	۱۱/۲۰	۳/۷۷

شبکه عصبی مصنوعی (ANN)

ساختار شبکه‌های عصبی مصنوعی یک فاکتور بسیار مهم در طراحی یک پیش‌بینی ایده‌آل است. همان‌طور که پیش‌تر نیز ذکر شد، ساختار یک شبکه MLP شامل لایه‌های ورودی، مخفی و خروجی است. هر لایه در شبکه حاوی تعداد کافی نورون بسته به کاربری‌های خاص می‌باشد (اتکینسون و تاتنال، ۱۹۹۷). در این مطالعه، تعداد ۵ نورون در لایه ورودی بر اساس متغیرهای مستقل ذکر شده انتخاب شده است. همچنین بر اساس فاکتورهای وابسته (مقاومت فشاری تک‌محوری و مدول الاستیک برای هر شبکه) دو گره^۱ در لایه خروجی تعریف شده است. تعداد لایه‌های مخفی و نورون‌های آن‌ها بر اساس میزان دشوار بودن موضوع مورد مطالعه انتخاب می‌شوند. به‌طور نرمال، یک لایه مخفی با تعداد حداقل نورون‌ها ترجیح داده می‌شود، زیرا که این موضوع باعث کاهش در اندازه شبکه و افزایش در پتانسیل آموزش شبکه می‌شود (طاهری گراوند و همکاران، ۲۰۱۵). به منظور به دست آمدن یک ساختار بهینه برای شبکه، چندین ترکیب مختلف با تعداد نورون‌های متفاوت برای یک لایه مخفی اعمال شده است. این فرآیند با دو نورون شروع شده و تعداد نورون‌ها با روش سعی و خطا تا ۱۰ تا نیز افزایش یافته است. برای حصول بهترین ترکیب، درصد خطای مجذور میانگین (MSE) و ضریب همبستگی (R) به‌عنوان معیارهای استاندارد انتخاب مورد استفاده قرار گرفته‌اند. فرآیند انتخاب تعداد نورون‌ها در لایه‌های مخفی بسیار مهم است، زیرا در صورتی که تعداد نورون‌ها بیش از حد کم و یا زیاد در نظر گرفته شوند، نتایج مدل توسعه داده شده غیر واقعی و دور از انتظار خواهد بود. علاوه بر این، انتخاب تعداد زیاد نورون‌ها در

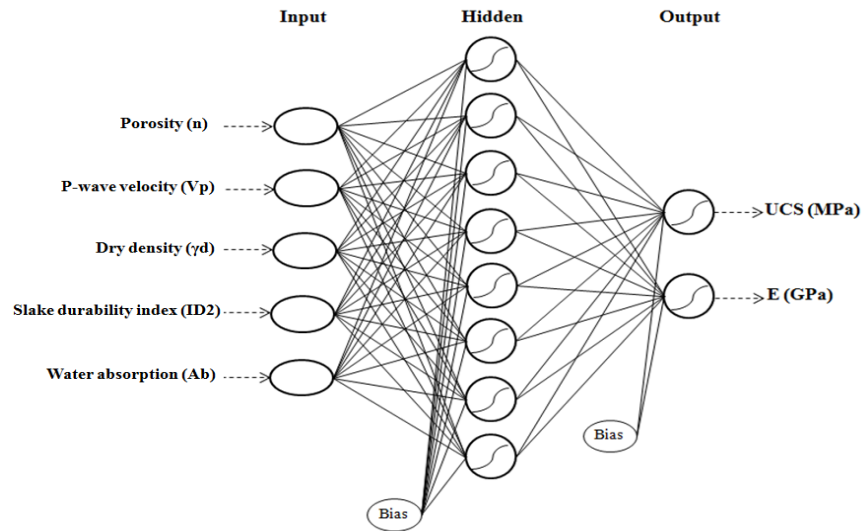
لایه مخفی باعث افزایش غیرواقعی زمان آموزش شبکه خواهد شد. به‌منظور بهینه کردن عملکرد شبکه در مرحله آموزش، در ابتدا بایستی تعداد نورون‌ها در لایه مخفی بهینه گردد. سپس شبکه مورد نظر با تعداد نورون‌های مختلف در لایه مخفی مورد ارزیابی قرار می‌گیرد. در این مطالعه، تعداد بهینه نورون‌ها در لایه مخفی شبکه ۸ در نظر گرفته شده است. لازم به ذکر است که در این تعداد نورون، ضریب همبستگی (r) و مقدار خطای مجذور میانگین یا MSE به ترتیب بیش‌ترین و کم‌ترین مقدار خود را دارا می‌باشند. لازم به ذکر است که شبکه پرسپترون چندلایه مورد استفاده در این مطالعه از نوع پس انتشار^۲ با الگوریتم آموزش لونیگ-مارکواردت^۳ می‌باشد. در نهایت توپولوژی ۵-۸-۲ با حداقل اندازه و حداکثر دقت پیش‌بینی به عنوان ساختار شبکه بهینه برای تخمین مقاومت فشاری تک‌محوری و مدول الاستیک حاصل شده است (شکل ۱). برای ارزیابی عملکرد و دقت پیش‌بینی شبکه، از دو معیار آماری رایج یعنی MSE و r استفاده شده است. به‌طور کلی در این مطالعه به‌منظور انتخاب شبکه ایده‌آل، از حداقل درصد خطای میانگین و حداکثر ضریب همبستگی استفاده شده است. بر این اساس، مقادیر r بزرگ‌تر از ۰/۹ نشان‌دهنده بهترین عملکرد مدل، مقادیر r بین ۰/۸ تا ۰/۹ بیانگر عملکرد خوب و مقادیر r کوچک‌تر از ۰/۸ حاکی از عملکرد غیرقابل قبول شبکه می‌باشند (احمدی و همکاران، ۲۰۱۳).

نتایج عملکرد شبکه توسعه داده شده در این مطالعه به منظور تخمین مقاومت فشاری تک‌محوری و مدول الاستیک در طی مرحله آزمایش به‌ترتیب در شکل‌های ۲ و ۳ نشان داده شده است.

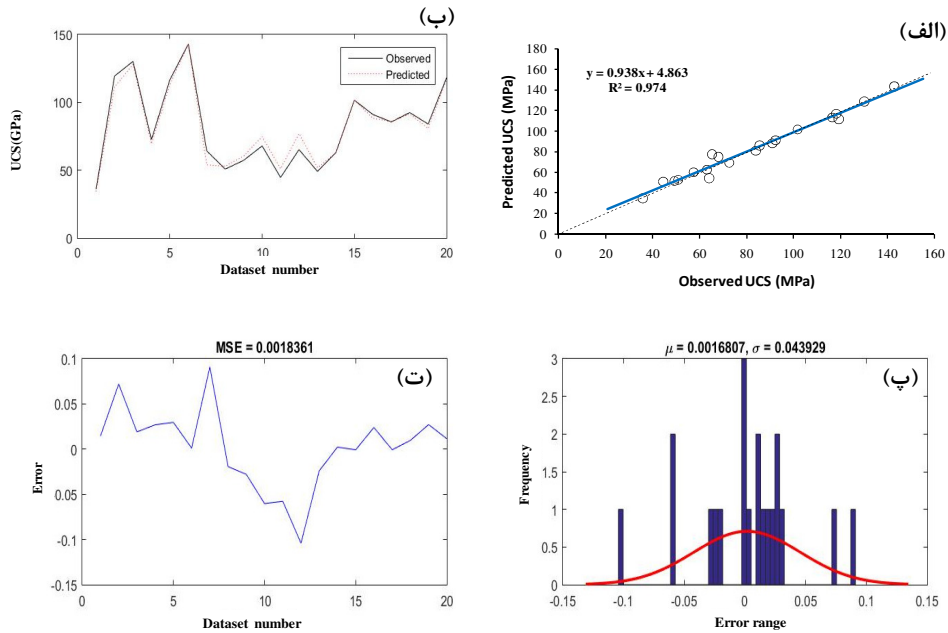
² Back Propagation (BP)

³ Levenberg-Marquardt

¹ Node



شکل ۱. ساختار شبکه عصبی مصنوعی استفاده شده در این مطالعه




شکل ۲. عملکرد شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری تک‌محوری در مرحله آزمایش: (الف) ارتباط بین داده‌های واقعی و پیش‌بینی شده توسط شبکه، (ب) مقایسه داده‌های واقعی و پیش‌بینی شده با هم، (پ) درصد خطای نسبی بین داده‌های واقعی و پیش‌بینی شده، (ت) نمودار ستونی توزیع خطای بین داده‌های واقعی و پیش‌بینی شده

برای مراحل آموزش و آزمایش محاسبه شده است. این شاخص اطلاعات بیشتری در ارتباط با توزیع خطا به دست می‌دهد. نمودار ستونی خطاها (هیستوگرام) نیز بیان‌کننده تمرکز خطا است. نتایج ارزیابی عملکرد شبکه عصبی برای مقاومت فشاری تک‌محوری، در شکل ۲ نمایش داده شده است. بر این اساس مشاهده می‌شود که ضریب همبستگی بین مقادیر واقعی و پیش‌بینی شده

همان‌طور که در این شکل‌ها نشان داده شده است، مقادیر پیش‌بینی شده توسط شبکه در مقابل داده‌های اندازه‌گیری شده در آزمایشگاه بر روی نمودار ترسیم شده است. قابل ذکر است که هر چقدر خط ضریب تطابق داده‌ها بر خط $X=Y$ یا منحنی شیب ۴۵ درجه منطبق‌تر باشد، نشان‌دهنده عملکرد خوب شبکه می‌باشد. همچنین به‌منظور ارزیابی عملکرد شبکه، شاخص خطای استاندارد

درصد خطای مجذور میانگین داده‌های واقعی و پیش‌بینی شده 0.00927 تعیین شده است که بیانگر درجه پیش‌بینی مناسبی توسط شبکه می‌باشد. با توجه به نتایج حاصل شده می‌توان نتیجه گرفت که قابلیت شبکه در پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک ماسه‌سنگ‌های مورد مطالعه مناسب و رضایت بخش است. مطالب عنوان شده این اطمینان را می‌دهد که می‌توان از شبکه مورد نظر برای تعیین پارامترهای مقاومتی سنگ‌های مورد مطالعه و یا سنگ‌های مشابه با صرف زمان و هزینه کم‌تری استفاده کرد.



شکل ۳. عملکرد شبکه عصبی مصنوعی برای پیش‌بینی مدول الاستیک در مرحله آزمایش: (الف) ارتباط بین داده‌های واقعی و پیش‌بینی شده توسط شبکه، (ب) مقایسه داده‌های واقعی و پیش‌بینی شده با هم، (پ) درصد خطای نسبی بین داده‌های واقعی و پیش‌بینی شده، (ت) نمودار ستونی توزیع خطای بین داده‌های واقعی و پیش‌بینی شده

جذب آب. عموماً رگرسیون خطی چند متغیره به صورت ارتباط بین متغیرهای خروجی یا وابسته و متغیرهای ورودی یا مستقل بیان می‌شود که این موضوع در رابطه ۱ نشان داده شده است:

$$Y = c + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_nX_n \quad (1)$$

در این رابطه؛ Y ، متغیر وابسته؛ c یک ثابت؛ X_1 تا X_n متغیرها و b_1 تا b_n ضرایب رگرسیون برای X_1 تا X_n می‌باشند. بر اساس نتایج آنالیز رگرسیون، دو معادله

بیش‌تر از 0.9 است، که این موضوع حاکی از عملکرد پیش‌بینی بسیار خوب شبکه پیشنهاد داده شده می‌باشد. همچنین شاخص MSE نیز 0.0018361 است که نشان دهنده عملکرد رضایت بخش شبکه در مرحله آزمایش دارد.

همچنین نتایج ارزیابی عملکرد شبکه عصبی به‌منظور پیش‌بینی مدول الاستیک در دوره آزمایش، در شکل ۳ نشان داده شده است. ضریب همبستگی بالای بین داده‌های واقعی و پیش‌بینی شده ($R = 0.942$) در نمودار شکل ۳-الف بیانگر ارتباط بسیار مناسب بین آن‌ها و عملکرد پیش‌بینی رضایت‌بخش شبکه است. هم‌چنین

رگرسیون خطی چند متغیره

روش آنالیز رگرسیون چند متغیره برای به‌دست آوردن بهترین رابطه بین متغیرها، زمانی که بیش از یک پارامتر ورودی وجود داشته باشد، مورد استفاده قرار می‌گیرد. به طور کلی موضوع اصلی روش رگرسیون چند متغیره تولید یک ارتباط بین پارامترهای ورودی و خروجی است. در این مطالعه، متغیرهای مستقل مورد استفاده عبارتند از: تخلخل، سرعت سیر موج، دانسیته خشک، دوام و درصد





همان‌طور که در این شکل‌ها نشان داده شده است، مقادیر ضریب رگرسیون برای مقاومت فشاری تک محوری و مدول الاستیک به ترتیب ۰/۹۳۲ و ۰/۸۵۲ به دست آمده است. این بدین معنی است که روابط پیشنهاد شده با استفاده از آنالیز رگرسیون، دقت پیش‌بینی خوبی برای تخمین ویژگی‌های مقاومتی سنگ‌ها هستند. همچنین در شکل ۴- پ و ت توزیع اختلاف بین مقادیر واقعی و پیش‌بینی شده به ترتیب برای UCS و E نشان داده شده است. تمرکز بیش‌تر ستون‌ها اطراف عدد صفر حاکی از اختلاف کم‌تر مقادیر واقعی و پیش‌بینی شده توسط روابط تجربی ۲ و ۳ می‌باشد. به عبارت دیگر، این موضوع نشان‌دهنده دقت پیش‌بینی مناسب این روابط می‌باشد.

خطی با بالاترین ضریب رگرسیون برای پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک پیشنهاد داده شده است (روابط ۲ و ۳).

$$UCS = 13.276V_p + 19.66\gamma_d + 4.297A_b + 4.35ID_2 - 3.654n - 431.65 \quad (2)$$

$$E = 2.819V_p + 6.09\gamma_d + 0.519A_b + 0.01n - 0.04ID_2 - 15.44 \quad (3)$$

در این روابط، UCS مقاومت فشاری تک‌محوری (مگاپاسکال)؛ E مدول الاستیک مماسی (گیگاپاسکال)؛ n تخلخل (%); γ_d دانسیته خشک (گرم بر سانتی‌متر مکعب)؛ V_p سرعت موج (کیلومتر بر ثانیه)، ID_2 شاخص دوام (درصد) و A_b درصد جذب آب می‌باشد. شکل ۴- الف و ب ارتباط بین مقادیر مقاومت فشاری تک‌محوری و مدول الاستیک محاسبه شده با استفاده از روابط تجربی ۲ و ۳ و مقادیر اندازه‌گیری شده در آزمایشگاه را نشان می‌دهد.



شکل ۴. الف) و ب) ارتباط بین مقادیر واقعی و پیش‌بینی شده با استفاده از معادلات ۲ و ۳ به ترتیب برای UCS و E؛ پ) و ت) توزیع اختلاف بین مقادیر واقعی و پیش‌بینی شده برای UCS و E

مجذور میانگین مربعات (RMSE) و VAF با استفاده از روابط زیر محاسبه شده است:

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4)$$

مقایسه عملکرد شبکه عصبی مصنوعی و آنالیز رگرسیون

عملکرد شبکه عصبی و آنالیز رگرسیون انجام شده در این مطالعه با استفاده از شاخص‌های آماری مختلف ارزیابی شده است. به این منظور، مقادیر ضریب همبستگی (r)، خطای

مقاومت فشاری تک‌محوری و مدول الاستیک را دارند. با این وجود، مقایسه شاخص‌های آماری محاسبه شده در جدول ۴ بیانگر عملکرد بهتر شبکه عصبی مصنوعی در پیش‌بینی پارامترهای مورد نظر می‌باشد و نتایج آن به واقعیت نزدیک‌تر است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_i - Y_i)^2}{n}} \quad (5)$$

$$VAF = \left[1 - \frac{\text{var}(X_i - Y_i)}{\text{var}(X_i)} \right] \times 100 \quad (6)$$

جایی که X_i و Y_i به ترتیب داده‌های واقعی و پیش‌بینی شده هستند و n تعداد داده‌های مورد استفاده می‌باشد. بر اساس نتایج خلاصه شده در جدول ۴، هر دو روش استفاده شده در این مطالعه با یک درجه دقت بالایی، توانایی پیش‌بینی

جدول ۴. نتایج محاسبه شاخص‌های آماری مختلف برای پیش‌بینی UCS و E

مدول الاستیک (E)		مقاومت فشاری تک محوری (UCS)			نام مدل	
VAF	RMSE	R	VAF	RMSE	R	
۷۲	۰/۱۸۸	۰/۸۵۲	۸۷	۰/۱۵۶	۰/۹۳۲	آنالیز رگرسیون
۸۹	۰/۰۹۵	۰/۹۴۲	۹۷	۰/۰۴۲	۰/۹۸۷	شبکه عصبی

مطالعه تنها برای سنگ‌های انتخاب شده یا سنگ‌های با ویژگی‌های مشابه قابل استفاده هستند. واضح است که به منظور توسعه و تأیید این روابط، مطالعات بیش‌تری در آینده نیاز می‌باشد.

منابع

- حق‌نژاد، ع.، آهنگری، ک.، نورزاد، ع (۱۳۸۹) بررسی ارتباط میان سرعت موج P با وزن واحد حجم، تخلخل و مقاومت فشاری تک‌محوری سنگ‌ها با استفاده از روش آماری و شبکه عصبی، مطالعه موردی: ساختگاه سد رودبار لرستان. نشریه یافته‌های نوین زمین‌شناسی کاربردی، دوره ۴، شماره ۸، ۴۴-۵۳
- عبدی، ی.، خانلری، غ (۱۳۹۸) تخمین ویژگی‌های مکانیکی ماسه‌سنگ‌ها با استفاده از آزمایش سرعت سیر موج و چکش‌اشمیت. نشریه یافته‌های نوین زمین‌شناسی کاربردی، دوره ۱۳، شماره ۲۵، ۳۳-۴۷.
- Abdi, Y., Taheri-Garavand, A., Zarei-Sahamieh, A (2018) Prediction of strength parameters of sedimentary rocks using artificial neural networks and regression analysis. *Arabian Journal of Geosciences*, 11:587. <https://doi.org/10.1007/s12517-018-3929-0>.
- Ahmadi, M. A., Ebadi, M., Shokrollahi, A., Majidi, SMJ (2013) Evolving artificial neural network and imperialist competitive algorithm for prediction oil flow rate of the reservoir. *Applied Soft Computing*, 13: 1085-1098.
- Atkinson, P. M., Tatnall, ARL (1997) Neural networks in remote sensing. *International Journal of Remote Sensing*, 18: 699-709.
- Bejarbaneh, B. Y., Bejarbaneh, E. Y., Amin, M. F. M., Fahimifar, A., Jahed Armaghani, D., Majid, MZA (2018) Intelligent modelling of sandstone deformation behaviour using fuzzy logic and neural network systems. *Bulletin of*

نتیجه‌گیری

در این مطالعه، یک مدل شبکه عصبی مصنوعی برای پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک ماسه‌سنگ‌ها مورد استفاده قرار گرفته است. به این منظور، تعداد ۱۳۰ نمونه مغزه سنگی مورد آزمایش قرار گرفته و برای توسعه مدل استفاده شده‌اند. مهم‌ترین نتایج به دست آمده از این مطالعه به شرح زیر است:

با توجه به مطالعه انجام شده، یک مدل شبکه عصبی پرسپترون چند لایه یا MLP با توپولوژی ۲-۸-۵ و یا به عبارتی ۵ لایه ورودی، ۸ لایه مخفی و دو خروجی برای پیش‌بینی ویژگی‌های مکانیکی ماسه‌سنگ‌های مورد نظر پیشنهاد داده شده است. ضرائب رگرسیون (r) بین مقادیر واقعی و پیش‌بینی شده با استفاده از شبکه عصبی پیشنهاد شده در مرحله آزمایش برای مقاومت فشاری تک‌محوری و مدول الاستیک به ترتیب ۰/۹۸۷ و ۰/۹۴۲ می‌باشد. این نتایج حاکی از عملکرد بسیار خوب شبکه توسعه داده شده در پیش‌بینی پارامترهای مقاومتی است. همچنین بر اساس نتایج خطای مجذور میانگین برای مقاومت فشاری تک‌محوری و مدول الاستیک به ترتیب ۰/۰۰۱۸۳ و ۰/۰۰۹۲۷ می‌باشد که نشان‌دهنده عملکرد پیش‌بینی مناسب شبکه توسعه داده شده است. مقایسه شاخص‌های آماری ضریب همبستگی (r)، خطای مجذور میانگین مربعات (RMSE) و VAF نشان داد که شبکه عصبی مصنوعی پتانسیل بالاتری برای پیش‌بینی مقاومت فشاری تک‌محوری و مدول الاستیک در مقایسه با آنالیز رگرسیون دارد. اگرچه باید به این نکته اشاره کرد که مدل شبکه عصبی و روابط تجربی پیشنهاد شده در این

- Wave) in Coal Measures sandstone. *Journal of Scientific and Industrial Research*, 59: 482–486.
- Sonmez, H., Gokceoglu, C., Nefeslioglu, H.A., Kayabasi, A (2006) Estimation of rock modulus: for intact rocks with an artificial neural network and for rock masses with a new empirical equation. *International Journal of Rock Mechanics and Mining Sciences*, 43: 224–235.
- Taheri-Garavand, A., Ahmadi, H., Omid, M., Mohtasebi, S.S., Mollazade, K., Russell-Smith, J.R., Carlomagno, GM (2015) An intelligent approach for cooling radiator fault diagnosis based on infrared thermal image processing technique. *Applied Thermal Engineering*, 87: 434–443.
- Tiryaki, B (2008) Predicting intact rock strength for mechanical excavation using multivariate statistics, artificial neural networks and regression trees. *Engineering Geology*, 99: 51–60.
- Tonnizam-Mohamad, E., Jahed-Armaghani, D., Momeni, E., Alavi-Nezhad-Khalil-Abad, SV (2015) Prediction of the unconfined compressive strength of soft rocks: a PSO-based ANN approach. *Bulletin of Engineering Geology and the Environment*, 74: 745–757.
- Torabi-Kaveh, M., Naseri, F., Sanei, S., Sarshari, B (2014) Application of artificial neural networks and multivariate statistics to predict UCS and E using physical properties of Asmari limestones. *Arabian Journal of Geosciences*, 8 (5): 2889–2897.
- Yagiz, S., Sezer, E. A., Gokceoglu, C (2012) Artificial neural networks and nonlinear regression techniques to assess the influence of slake durability cycles on the prediction of uniaxial compressive strength and modulus of elasticity for carbonate rocks. *International Journal for Numerical and Analytical Methods in Geomechanics*, 36 (14): 1636–1650.
- Yesiloglu-Gultekin, N., Gokceoglu, C., Sezer, EA (2013) Prediction of uniaxial compressive strength of granitic rocks by various nonlinear tools and comparison of their performances. *International Journal of Rock Mechanics and Mining Sciences*, 62: 113–122.
- Yilmaz, I., Yuksek, AG (2008) An example of artificial neural network (ANN) application for indirect estimation of rock parameters. *Rock Mechanics and Rock Engineering*, 41(5): 781–795.
- Yilmaz, I., Yuksek, AG (2009) Prediction of the strength and elasticity modulus of gypsum using multiple regression, ANN and ANFIS models. *International Journal of Rock Mechanics and Mining Sciences*, 46(4): 803–810.
- Engineering Geology and the Environment*, 77: 345–361.
- Cabalar, A. F., Cevik, A., Gokceoglu, C (2012) Some applications of adaptive neuro-fuzzy inference system (ANFIS) in geotechnical engineering. *Computer and Geotechnics*, 40: 14–33.
- Dehghan, S., Sattari, G. H., Chehre-Chelgani, S., Aliabadi, MA (2010) Prediction of uniaxial compressive and modulus of elasticity for travertine sample using regression and artificial neural networks. *International journal of Mining Science and Technology*, 20: 41–46.
- ISRM (1981) Rock characterization, testing and monitoring, ISRM suggested methods. *International Society for Rock Mechanics*, 211pp.
- Kahraman, S., Gunaydin, O., Alber, M., Fener, M (2009) Evaluating the strength and deformability properties of misis fault breccia using artificial neural networks. *Expert Systems Applications*, 36: 6874–6878.
- Lindquist, E. S., Goodman, RE (1994) Strength and deformation properties of a physical model melange. In: Nelson PP, Laubach SE (ed) *Proceedings of the 1st North American rock mechanics symposium*. Balkema, Rotterdam, 843–850.
- Majdi, A., Beiki, M (2010) Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses. *International Journal of Rock Mechanics and Mining Sciences*, 47: 246–253.
- Majidi, A., Rezaei, M (2013) Prediction of unconfined compressive strength of rock surrounding a roadway using artificial neural network. *Neural Computing & Applications*, 23: 381–389.
- Ozcelik, Y., Bayram, F., Yasitli, NE (2013) Prediction of engineering properties of rocks from microscopic data. *Arabian Journal of Geosciences*, 6: 3651–3668.
- Rajesh-Kumar, B., Vardhan, H., Govindaraj, M., Vijay, GS (2013) Regression analysis and ANN models to predict rock properties from sound levels produced during drilling. *International Journal of Rock Mechanics and Mining Sciences*, 58: 61–72.
- Sarkar, K., Tiwary, A., Singh, TN (2010) Estimation of strength parameters of rock using artificial neural networks. *Bulletin of Engineering Geology and the Environment*, 69: 599–606.
- Singh, R., Kainthola, A., Singh, TN (2012) Estimation of elastic constant of rocks using an ANFIS approach. *Applied Soft Computing*, 12(1): 40–45.
- Singh, T.N., Dubey, RK (2000) A study of transmission velocity of primary wave (P-

Prediction of uniaxial compressive strength and modulus of elasticity of sandstones using artificial neural network and multiple regression analysis

Y. Abdi*¹ and A. Ghasemi Dehnavi²

1, 2- Dept., of Geology, Faculty of sciences, Lorestan University, Khoramabad

*Abdi.ya@lu.ac.ir

Received: 2018/10/23 Accepted: 2019/4/9

Abstract

Determining UCS and E using standard laboratory tests is a difficult, expensive and time consuming task. This is particularly true for thinly bedded, highly fractured, foliated, highly porous and weak rocks. Consequently, prediction models become an attractive alternative for engineering geologists. The main purpose of this study is to develop an artificial neural network (ANN) and multiple regression analysis (MLR) models in order to predict UCS and E of sandstones. For this, a database of laboratory tests (including 130 sandstone samples) was prepared, which includes porosity, P-wave velocity, dry density, slake durability index, and water absorption as input parameters and UCS and E as output parameter. The performance of the MLR and ANN models are evaluated by comparing statistic parameters, including correlation coefficient (r), root mean square error (RMSE), and variance account for (VAF). Comparison of the multiple linear regressions and ANNs results indicated that respective ANN models were more acceptable for predicting UCS and E than the other.

Keywords: Uniaxial compressive strength, Modulus of elasticity, Artificial neural network, Regression analysis, Sandstone