

پیش‌بینی زاویه اصطکاک خاک با استفاده از مدل یادگیری عمیق: مطالعه موردی ماسه فیروزکوه

سینا هاشمی سالانقوج^۱، احمدعلی فخمی^{۲*}

۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه تربیت مدرس
*۲- استاد، دانشکده مهندسی عمران و محیط‌زیست، دانشگاه تربیت مدرس

Email: A.fakhimi@modares.ac.ir

تاریخ پذیرش: [۱۴۰۱/۱۲/۰۵]

تاریخ دریافت: [۱۴۰۲/۰۹/۱۱]

چکیده

زاویه اصطکاک خاک یکی از پارامترهای اساسی در مهندسی ژئوتکنیک است و به شکل مستقیم بر پایداری سازه‌هایی مانند دیوارهای حائل، شیب‌ها و پی‌ها تأثیر دارد. در این پژوهش یک شبکه عصبی پیچشی (Convolutional neural network)، با استفاده از پارامترهای ورودی عکس و جرم مخصوص خشک، برای پیش‌بینی زاویه اصطکاک اوج ماسه فیروزکوه، توسعه داده شد. برای این منظور، ابتدا ۱۰ نمونه از ماسه فیروزکوه با دانه‌بندی‌های متفاوت S₁ تا S₁₀ تهیه و برای هر دانه‌بندی نیز سه جرم مخصوص خشک متفاوت در نظر گرفته شد. سپس زاویه اصطکاک اوج متناظر با ۳۰ جرم مخصوص خشک برای ۱۰ دانه‌بندی S₁ تا S₁₀ با استفاده از آزمایش برش مستقیم تعیین شد. برای آموزش و آزمون شبکه از هر نمونه ۵۰ عکس گرفته شد. با توجه به اینکه در فرآیند آموزش شبکه، برای هر نمونه سه جرم مخصوص خشک متفاوت در نظر گرفته شد، در مجموع ۱۵۰۰ عکس برای بانک اطلاعاتی شبکه تهیه شد. از این تعداد، ۱۱۲۵ عکس برای آموزش و ۳۷۵ عکس برای آزمون شبکه استفاده شد. نتیجه آزمون شبکه عصبی پیچشی این پژوهش نشان داد که این شبکه می‌تواند با استفاده از عکس و جرم مخصوص خشک خاک به‌عنوان پارامترهای ورودی، زاویه اصطکاک اوج ماسه فیروزکوه را، با خطای نسبی نرمال شده ۳/۰ درصد، پیش‌بینی کند.

واژگان کلیدی: یادگیری عمیق، زاویه اصطکاک خاک، ماسه فیروزکوه، شبکه عصبی پیچشی، پردازش تصویر دیجیتال.

۱- مقدمه

زاویه اصطکاک خاک یک پارامتر مهم در پروژه‌های مهندسی ژئوتکنیک است و به شکل مستقیم بر پایداری سازه‌هایی مانند دیوارهای حائل، شیب‌ها و پی‌ها تأثیر می‌گذارد. زاویه اصطکاک خاک‌ها معمولاً با استفاده از آزمایش‌های آزمایشگاهی و درجا تعیین می‌شود که زمان‌بر و پرهزینه هستند. به همین دلیل، ارائه روشی کارآمد و مقرون به‌صرفه برای پیش‌بینی زاویه اصطکاک خاک ضرورت دارد [1].

[2]. مطالعات اخیر نشان داده‌اند که پارامترهای مقاومت برشی خاک مثل زاویه اصطکاک و چسبندگی، به عوامل مختلفی مانند توزیع اندازه دانه‌ها، چگالی نسبی و شکل ذرات وابسته است [3-5].

پیشرفت‌های اخیر شبکه‌های عصبی مصنوعی (Artificial neural network) و مدل‌های یادگیری عمیق (Deep learning models)، آن‌ها را به یک ابزار قدرتمند برای پیش‌بینی ویژگی‌ها و رفتار خاک تبدیل کرده است. یک مدل یادگیری عمیق قوی می‌تواند زمان و هزینه مورد نیاز برای تخمین و پیش‌بینی ویژگی‌های خاک را به‌طور قابل توجهی کاهش دهد و مهندسان و زمین‌شناسان را قادر می‌سازد تا تصمیماتی آگاهانه و با دقت و کارایی بیشتر اتخاذ کنند. مطالعات مختلفی در زمینه استفاده از شبکه‌های عصبی و مدل‌های یادگیری عمیق در خصوص پیش‌بینی زاویه اصطکاک خاک انجام شده است. به‌عنوان نمونه نگوین و همکاران (۲۰۲۰) در مطالعه خود یک شبکه عصبی پس‌انتشار (Backpropagation neural network) را برای پیش‌بینی زاویه اصطکاک داخلی خاک بر اساس داده‌های تجربی پیشنهاد کردند. نتیجه مطالعه آن‌ها نشان داد که الگوریتم پیشنهادی به‌خوبی عمل کرده و قادر است زاویه اصطکاک خاک را با دقت ۸۸ درصد پیش‌بینی کند [6]. در پژوهش بوراک (۲۰۲۳)، شبکه‌های عصبی مصنوعی و الگوریتم‌های ژنتیک (GAs) برای محاسبه مقادیر زاویه اصطکاک داخلی (ϕ) برای خاک‌های دانه‌ای بر اساس داده‌های آزمون نفوذ استاندارد (SPT) استفاده شدند. هدف این پژوهش تعیین سیستمی بود که بهترین نتایج آماری را تولید کند. نتایج این مطالعه نشان داد که با استفاده از شبکه‌های عصبی

مصنوعی، می‌توان همبستگی بین پارامترهای مختلف خاک و داده‌های آزمایشی (مانند آزمایش نفوذ استاندارد و مخروط) به دست‌آمده از مناطق مختلف را بهبود بخشید و به پیش‌بینی‌های مؤثر دست یافت [7]. در پژوهش فام و همکاران (۲۰۲۱) یک مدل ترکیبی با استفاده از شبکه عصبی عمیق و الگوریتم بهینه‌سازی ازدحام ذرات (Particle swarm optimization algorithm)، توسعه داده شد. نتیجه مطالعه آن‌ها نشان داد که مدل ترکیبی با ۱۰ لایه پنهان عملکرد بهتری نسبت به مدل شبکه عصبی عمیق معمولی دارد. این مطالعه همچنین از یک تحلیل حساسیت برای تعیین مهم‌ترین پارامتر ورودی برای پیش‌بینی زاویه اصطکاک خاک استفاده کرده و از بین ۷ پارامتر ورودی مختلف N30_{SPT}، سختی خاک، نسبت تخلخل خاک، جرم مخصوص خاک، ارتفاع لایه خاک، فاصله لایه خاک از سطح زمین و ارتفاع پایه لایه خاک، N30_{SPT} را مهم‌ترین پارامتر برای پیش‌بینی زاویه اصطکاک خاک معرفی کرد [8].

لین و همکاران (۲۰۲۲) در پژوهش خود از شبکه‌های عصبی مصنوعی برای پیش‌بینی ویژگی‌های مقاومت برشی و تراکم‌پذیری خاک‌های نرم استفاده کردند. در این پژوهش از یک پایگاه داده جامع از آزمایش‌های ژئوتکنیکی برای آموزش مدل‌های ANN استفاده شد. نتایج این پژوهش نشان داد که استفاده از شبکه‌های عصبی مصنوعی یک رویکرد قابل‌اعتماد و کارآمد برای ارزیابی ویژگی‌های مکانیکی خاک، فراهم می‌کند [9]. در پژوهش ژانگ و همکاران (۲۰۲۱) یک مدل هوش مصنوعی تعمیم‌یافته برای تخمین زاویه اصطکاک رس‌ها در ارزیابی پایداری شیب پیشنهاد شد. این مدل یک شبکه عصبی عمیق و الگوریتم بهینه‌سازی هریس هاکس (Harris Hawks) را برای بهبود دقت شبکه ترکیب کرد. نتیجه این مطالعه نشان داد که مدل پیشنهادی می‌تواند با دقت خوبی زاویه اصطکاک رس‌ها را پیش‌بینی کند و برای بررسی حساسیت زمین‌لغزش و ارزیابی پایداری شیب، مفید باشد [10]. ژو و همکاران (۲۰۲۲) در مطالعه خود، سه مدل شبکه عصبی پس‌انتشار، رگرسیون حداقل مربعات جزئی (Partial least squares regression) و رگرسیون بردار پشتیبان (Support vector regression)، را برای پیش‌بینی زاویه اصطکاک داخلی خاک‌های چسبنده پیشنهاد

مطالعات اخیر نشان می‌دهند که استفاده از شبکه‌های عصبی مصنوعی و مدل‌های یادگیری عمیق، در مسائلی مانند پیش‌بینی پارامترهای مقاومتی خاک، مدل‌سازی پایداری شیب‌ها، پیش‌بینی پتانسیل روانگرایی و طبقه‌بندی خاک امیدوارکننده است، اما مطالعات بیشتر برای استفاده کامل از پتانسیل‌های این تکنیک در پروژه‌های مهندسی ژئوتکنیک و زمین‌شناسی ضرورت دارد [15-18].

در این پژوهش، یک شبکه عصبی پیچشی (Convolutional neural network) با استفاده از پارامترهای ورودی عکس و جرم مخصوص خشک خاک، برای پیش‌بینی زاویه اصطکاک اوج ماسه فیروزکوه توسعه داده شد. برای این منظور، ابتدا ۱۰ نمونه با منحنی‌های دانه‌بندی متفاوت S1 تا S1۰ مطابق شکل (۱) آماده شدند. بعد از عکس‌برداری از نمونه‌ها، زاویه اصطکاک اوج متناظر با سه جرم مخصوص خشک متفاوت برای هر یک از نمونه‌ها با استفاده از آزمایش برش مستقیم تعیین و برای آموزش شبکه عصبی پیچشی استفاده شد. سپس این شبکه با استفاده از داده‌های آزمون، امتحان شد. نتیجه آزمون شبکه عصبی پیچشی در بخش ۴ ارائه شده است. در نهایت، نتایج به‌دست آمده، در بخش ۵ مورد بحث و بررسی قرار گرفته است.

۲- مطالعات آزمایشگاهی

آزمایش برش مستقیم یک روش مفید و مؤثر در مهندسی ژئوتکنیک برای تعیین مقاومت برشی خاک‌ها است [19-21]. در این پژوهش، به منظور تهیه داده برای آموزش و آزمون شبکه عصبی پیچشی، ۹۰ آزمایش برش مستقیم مطابق استاندارد ASTM D3080-D3080M، روی ماسه فیروزکوه انجام شد. فیروزکوه شهری کوچک در ۱۳۰ کیلومتری شرق تهران است که ماسه آن معمولاً به عنوان یک ماسه استاندارد در مطالعات مربوط به مهندسی ژئوتکنیک استفاده می‌شود. نمونه‌های ماسه فیروزکوه با ۱۰ دانه‌بندی S1 تا S1۰ (شکل ۱)، بعد از خشک شدن در گرمخانه، برای سه جرم مخصوص خشک مختلف و در سه تنش قائم متفاوت ۱۰۰kPa، ۲۰۰kPa

کردند. آن‌ها داده‌های آزمایش نفوذ مخروط (CPT) و ویژگی‌های خاک مانند درصد رطوبت خاک، مدول بالک و چسبندگی را به عنوان پارامترهای ورودی در نظر گرفتند. نتیجه مطالعه آن‌ها نشان داد که مدل رگرسیون بردار پشتیبان بهترین عملکرد را در پیش‌بینی زاویه اصطکاک داخلی خاک‌های چسبنده دارد [11]. در پژوهش انجام شده توسط داغستانی و همکاران (۲۰۲۳)، ویژگی‌های مقاومت برشی مخلوط ماسه و دانه‌های لاستیک مورد بررسی قرار گرفت. این مطالعه همچنین از تکنیک‌های یادگیری ماشین برای پیش‌بینی زاویه اصطکاک داخلی باقی‌مانده و اوج این مخلوط‌ها استفاده کرد. نتیجه بررسی آن‌ها نشان داد که مدل‌های رگرسیونی قادر به پیش‌بینی دقیق زاویه اصطکاک داخلی باقی‌مانده و اوج مخلوط ماسه و دانه‌های لاستیک هستند [12]. همچنین موسوی و شراهی (۲۰۲۱) مطالعه‌ای در خصوص تخمین مقاومت برشی خاک ماسه‌ای بر اساس ویژگی‌های دانه‌های آن با استفاده از شبکه‌های عصبی مصنوعی و تحلیل رگرسیونی، انجام دادند. آن‌ها پارامترهایی مانند توزیع اندازه، شکل و گرد گوشه بودن دانه‌های انواع مختلف ماسه را در نظر گرفته و سپس مدل‌های شبکه عصبی مصنوعی و تحلیل رگرسیون را برای پیش‌بینی پارامترهای مقاومت برشی خاک توسعه دادند. نتیجه مطالعه آن‌ها نشان داد که هر دو روش ارائه‌شده، برای پیش‌بینی مقاومت برشی خاک دقیق و مناسب هستند [13]. ژانگ و همکاران (۲۰۲۳) در مطالعه خود عملکرد الگوریتم‌های مختلف یادگیری ماشین (ML) یعنی شبکه عصبی مصنوعی، ماشین یادگیری افراطی (ELM) و درختان تقویت‌شده (Boosted) را در پیش‌بینی مقاومت برشی خاک ارزیابی و مقایسه کردند. این تحقیق نسبت‌های مختلف آموزش به آزمون را با استفاده از مجموعه داده‌ای از ۵۳۸ نمونه خاک در نظر می‌گیرد. نتایج این مطالعه نشان داد که مدل ANN عملکرد، دقت و ثبات آماری بالاتری نسبت به مدل‌های ELM و Boosted دارد. همچنین مقایسه نسبت‌های آموزش به آزمون نشان داد که نسبت ۷۰ به ۳۰ بهترین عملکرد مدل را به همراه دارد [14].

یک مقدار میان دو جرم مخصوص خشک بیشترین و کمترین، به عنوان جرم مخصوص خشک سوم انتخاب شد. به عنوان نمونه، پوش گسیختگی نمونه S9 با سه جرم مخصوص خشک متفاوت در شکل (۱) نشان داده شده است. همچنین نتایج آزمایش‌های برش مستقیم انجام شده در این پژوهش، به‌طور خلاصه در جدول (۱) ارائه شده است.

شکل ۱. منحنی دانه‌بندی نمونه‌های S1 تا S10




Fig. 1. Granulation curves of samples S1 to S10

شکل ۲. پوش گسیختگی نمونه S9 با سه جرم مخصوص خشک متفاوت




Fig. 2. Failure envelope for S9 sample with three different dry densities

۳- مدل یادگیری عمیق

شبکه عصبی پیچشی که با نام CNN یا ConvNet نیز شناخته می‌شود، یک الگوریتم یادگیری عمیق است که برای پردازش داده‌هایی که ساختار شبکه‌ای (مانند تصاویر دیجیتال) دارند، کاربرد دارد. تصویر دیجیتال یک نمایش دودویی از داده‌های بصری است و شامل یک سری پیکسل می‌باشد که به شکل شبکه‌ای مرتب شده‌اند. هر پیکسل با یک مقدار نشان

پیش‌بینی زاویه اصطکاک خاک با استفاده از مدل یادگیری عمیق ...
و 300 kPa ، برای تعیین زاویه اصطکاک اوج، مورد آزمایش قرار گرفتند. ابعاد جعبه دستگاه برش $100 \times 100 \times 25$ میلی‌متر بود. معیار و روند انتخاب جرم مخصوص خشک برای تمام نمونه‌ها یکسان و به این صورت بود که ۱. نمونه از یک ارتفاع معین (۱۵ سانتی‌متر)، بدون کوبیدن، در سه لایه داخل جعبه نمونه دستگاه آزمایش برش مستقیم ریخته شد (کمترین جرم مخصوص خشک)، ۲. نمونه در سه لایه و هر لایه با ۲۰ ضربه چکش سه کیلوگرمی کوبیده شد (بیشترین جرم مخصوص خشک) و ۳.

جدول ۱. زاویه اصطکاک اوج هر نمونه برای ۳ جرم مخصوص خشک متفاوت (ماسه خوب دانه‌بندی شده: SW، ماسه بد دانه‌بندی شده: SP)

Sample	Soil classification	γ_d (gr/cm ³)	ϕ^{Peak} Experimental (Degree)
			36.9
S1	SP	1.60	38.2
S2	SP	1.67	39.4
S3	SW	1.50	35.8
S4	SW	1.47	37.6
S5	SW	1.67	43.5
S6	SP	1.68	37.3
S7	SP	1.80	38.1
S8	SP	1.80	42.6
S9	SP	1.53	37.4
S10	SP	1.70	38.5
			42.8
			36.7
			38.4
			41.8
			37.0
			38.5
			42.6
			36.2
			37.3
			39.0
			35.5
			36.4
			40.5
			37.0
			39.5
			44.0
			36.8
			38.4
			39.4

Table 1. Peak friction angle for each sample for three different dry densities

داده می‌شود که نمایانگر روشنایی و رنگ پیکسل در تصویر است.

عصبی پیچشی به‌طور کلی از سه نوع لایه تشکیل شده‌اند: ۱. لایه پیچشی، ۲. لایه ادغام و ۳. لایه تماماً متصل. این لایه‌ها در ادامه به‌صورت مختصر توضیح داده می‌شوند.

۳-۱- معرفی شبکه عصبی پیچشی

مانند هر شبکه عصبی دیگر، شبکه عصبی پیچشی نیز از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. در ابتدای مرحله آموزش مدل، هر گره با ضربی (وزن) مقداره‌ی می‌شود و برای بهینه‌سازی، تابع هزینه در مرحله پس‌انتشار به‌روز می‌شود. حال واضح‌ترین سؤال این است که اگر همه چیز یکسان است، چرا به نوع خاصی از شبکه عصبی برای داده‌هایی از نوع تصویر نیاز داریم؟ پاسخ ساده این است که: «شبکه‌های عصبی سنتی نمی‌توانند به‌خوبی تصویر را مقیاس کنند». برای درک بهتر موضوع، یک تصویر رنگی با ابعاد 5×5 پیکسل را در نظر بگیرید. از آنجایی که هر تصویر دارای سه کانال رنگی قرمز، سبز و آبی (RGB) است، می‌توان این تصویر را به صورت یک ماتریس با ابعاد $5 \times 5 \times 3$ در نظر گرفت که در این صورت شبکه عصبی ۷۵ عدد را به عنوان ورودی دریافت خواهد کرد که این تعداد ورودی قابل قبول است. از سوی دیگر اگر اندازه تصویر را به 500×500 پیکسل افزایش دهیم، تعداد ورودی شبکه عصبی به ۷۵۰۰۰۰ عدد افزایش خواهد یافت که این تعداد ورودی پیچیدگی و تعداد پارامترهای شبکه را به‌صورت تصاعدی افزایش داده و شبکه را بسیار غیرقابل کنترل و ناکارآمد می‌کند. در چنین شرایطی، استفاده از شبکه عصبی پیچشی ضرورت دارد. چیزی که این نوع شبکه‌ها را از شبکه‌های عصبی دیگر متمایز می‌کند، توانایی مقیاس‌بندی کارآمد تصویر، بدون افزایش پیچیدگی شبکه است. شبکه‌های عصبی پیچشی با استفاده از مجموعه‌ای بزرگ از داده‌های برچسب‌گذاری شده، از طریق فرآیندی به نام یادگیری نظارت شده آموزش می‌بینند. در طول آموزش، شبکه پارامترهای خود (المان‌های هر فیلتر) را از طریق فرآیند پس‌انتشار و نزول گرادیان (Gradient descent) تنظیم می‌کند. این نوع شبکه‌ها معمولاً در مسائل گوناگونی مانند طبقه‌بندی تصاویر، تشخیص اشیا و تقسیم‌بندی تصاویر (Image segmentation) کاربرد دارند. شبکه‌های

۳-۱-۱- لایه پیچشی (Convolutional layer)

لایه‌های پیچشی، هسته اصلی شبکه‌های عصبی پیچشی را تشکیل می‌دهند و اطلاعات مفیدی را از تصاویر استخراج می‌کنند. هر لایه پیچشی از تعدادی فیلتر قابل آموزش تشکیل شده است که به‌عنوان هسته نیز شناخته می‌شوند. درحالی‌که یک تصویر رنگی را می‌توان یک ماتریس سه‌بعدی از پیکسل‌ها در نظر گرفت (سه ماتریس دویبعدی که هرکدام مربوط به یک کانال رنگ RGB هستند)، یک فیلتر، یک ماتریس دویبعدی از وزن‌ها است که روی هرکدام از کانال‌های ورودی می‌لغزد. لازم به ذکر است که المان‌های ماتریس فیلتر (وزن‌ها)، در طی آموزش و از طریق فرآیند پس‌انتشار و نزول گرادیان، تنظیم می‌شوند. وقتی یک فیلتر به یک کانال تصویر ورودی اعمال می‌شود، خروجی آن، محصول ضرب داخلی ماتریس پیکسل‌های کانال ورودی در ماتریس وزن‌ها (فیلتر) است شکل‌های (۳ و ۴). خروجی این فرآیند، ماتریسی را ایجاد می‌کند که به آن نقشه ویژگی گفته می‌شود. نقشه ویژگی شامل اطلاعات مفیدی از ویژگی‌های تصویر ورودی است که با استفاده از حرکت فیلتر خاص روی ماتریس کانال ورودی استخراج می‌شود. به‌عنوان مثال، فیلتر استفاده‌شده در شکل‌های (۳ و ۴)، برای استخراج لبه‌های افقی استفاده می‌شود.

همانطور که در شکل (۳) مشخص شده است، یک فیلتر 3×3 در ماتریس ورودی ضرب داخلی شده و نتیجه آن در ماتریس خروجی ذخیره می‌شود. سپس فیلتر به اندازه یک پیکسل روی ماتریس ورودی حرکت می‌کند (شکل ۴) و فرآیند بالا تکرار می‌شود. این کار باعث می‌شود هر خروجی فقط به یک ناحیه محلی از ورودی متصل شود. فیلتر به روند حرکتی خود روی ماتریس ورودی ادامه می‌دهد تا تمام ماتریس ورودی را پوشش دهد و نقشه ویژگی متناظر با آن استخراج شود. از آنجایی که روش تشخیص یک ویژگی

۳-۲-۱- لایه ادغام (Pooling layer):

این نوع لایه‌ها باعث ادغام نقشه‌های ویژگی می‌شوند. به عبارت دیگر، لایه ادغام، بدون افزایش تعداد پارامترهای آموزشی (وزن‌ها)، نقشه‌های ویژگی را کوچکتر می‌کند و باعث کاهش مقدار محاسبات مورد نیاز برای پردازش داده‌ها می‌شود (شکل ۶). علاوه بر این، لایه‌های ادغام برای استخراج ویژگی‌های غالب تصاویر مفید هستند و باعث حفظ روند آموزش موثر می‌شوند. روش‌های مختلفی برای ادغام کردن نقشه‌های ویژگی وجود دارد:

۱. ادغام حداکثر (Max pooling) که پیکسل ورودی با بیشترین مقدار در ماتریس خروجی ذخیره می‌شود.
۲. ادغام میانگین (Average pooling) که میانگین پیکسل‌های ورودی در ماتریس خروجی ذخیره می‌شود.
۳. ادغام جمع (Sum pooling) که جمع پیکسل‌های ورودی در ماتریس خروجی ذخیره می‌شود.

۳-۳-۱- لایه تماماً متصل (Fully-Connected layer)

در لایه‌های پیچشی، هر آرایه یک نقشه ویژگی به تمام آرایه‌های ماتریس ورودی متصل نمی‌شود، بلکه فقط به فیلتری که از آن حاصل شده است متصل می‌شود. در شبکه‌های عصبی پیچشی لایه‌هایی به نام لایه‌های تماماً متصل وجود دارد که در آن، تمام گره‌های یک لایه به تمام گره‌های لایه قبل خود متصل است (مانند شبکه‌های عصبی سنتی). نقشه ویژگی سه‌بعدی به‌دست‌آمده از لایه‌های پیچشی و ادغام را می‌توان با عملیات مسطح کردن (Flatten) به بردار یک‌بعدی تبدیل کرد. در واقع عملیات مسطح کردن، عناصر نقشه ویژگی را به یک بردار منفرد تبدیل می‌کند. اگر یک کانال دارای ابعاد $10 \times 5 \times 5$ باشد که در آن 5×5 نشان‌دهنده ابعاد فضایی ماتریس نقشه ویژگی و ۱۰ نشان‌دهنده تعداد نقشه‌های ویژگی یا فیلترها است. عملیات مسطح کردن، این نقشه ویژگی را به برداری با اندازه $1 \times 250 = 1 \times (5 \times 5 \times 10)$ تبدیل می‌کند. این کار با پشت سرهم چیدن المان‌های نقشه‌های ویژگی در امتداد بُعد

خاص (مانند لایه‌های افقی) در ماتریس ورودی، یک کار تکراری و مشابه است و می‌تواند با استفاده از پارامترهای یکسانی انجام شود، بنابراین می‌توان از یک فیلتر یکسان برای تمام مکان‌های تصویر برای استخراج یک ویژگی خاص استفاده کرد. این یعنی وزن‌ها در سراسر مکان فضایی لایه ورودی به اشتراک گذاشته می‌شوند.

شکل ۳. مرحله اول فرایند پیچش در لایه پیچشی




Fig. 3. The first stage of the twisting process in convolution layer

شکل ۴. مرحله دوم فرایند پیچش در لایه پیچشی




Fig. 4. The second stage of the twisting process in convolution layer

هر لایه پیچشی، چندین فیلتر متفاوت دارد که باعث به وجود آمدن چندین نقشه ویژگی متفاوت (کانال سه‌بعدی) به‌عنوان خروجی می‌شود. این عمل باعث کوچک‌تر شدن نقشه ویژگی و در عین حال افزایش عمق آن خواهد شد. در این عملیات، هر فیلتر یک ویژگی خاص از تصویر را استخراج می‌کند. برای این نوع لایه‌ها معمولاً از تابع فعال‌ساز ReLU شکل (۵) و بهینه‌ساز Adam [22] استفاده می‌شود.

شکل ۸. یک شبکه عصبی پیچشی




Fig. 8. A convolutional neural network

از پرکاربردترین و معروفترین شبکه‌های عصبی پیچشی می‌توان به AlexNet (2012) [23]، VGG (2014) [24]، GoogleNet (2015) [25] و ResNet (2016) [26] اشاره کرد. جزئیات یک شبکه عصبی پیچشی معمول در شکل (۸) نشان داده شده است.

۳-۲- آموزش شبکه عصبی پیچشی برای پیش‌بینی زاویه اصطکاک اوج ماسه فیروزکوه

پارامترهای ورودی استفاده شده برای آموزش شبکه عصبی پیچشی، عکس و جرم مخصوص خشک متناظر با هر زاویه اصطکاک اوج است (جدول ۱). برای تهیه داده‌های تصویر و آموزش شبکه عصبی پیچشی، هر یک از نمونه‌های S_1 تا S_{10} روی یک سطح صاف پخش شده و از هر نمونه، ۵۰ عکس گرفته شد. در مجموع از ۱۰ نمونه با دانه‌بندی متفاوت، ۵۰۰ عکس تهیه شد. با توجه به اینکه هر نمونه با سه جرم مخصوص خشک متفاوت در روند آموزش شبکه مورد استفاده قرار گرفت، در مجموع ۱۵۰۰ عکس در بانک اطلاعاتی وجود دارد که از این تعداد، ۱۱۲۵ عکس برای آموزش و ۳۷۵ عکس برای آزمون شبکه عصبی پیچشی استفاده شد. عکس‌ها در محیط‌های متفاوت نوری (نور مصنوعی، نور آفتاب و در سایه)، با فواصل متفاوت عدسی دوربین از سطح خاک، تهیه شدند. همچنین از دو نوع سنسور دوربین متفاوت، دوربین تلفن همراه (۲۵۹۲ x ۶۰۸ پیکسل) و دوربین عکس‌برداری

کانال، به صورت افقی انجام می‌شود و یک بردار ردیفی ایجاد می‌کند. سپس این بردار برای عملیات نهایی شبکه عصبی، به صورت ردیفی به لایه تماماً متصل، متصل می‌شود. تابع فعال‌ساز این لایه‌ها معمولاً تابع سیگموئید (Sigmoid) است (شکل ۷).

شکل ۵. تابع فعال‌ساز ReLU




Fig. 5. ReLU activation function

شکل ۶. روش‌های مختلف ادغام




Fig. 6. Different pooling layers

شکل ۷. تابع فعال‌ساز سیگموئید




Fig. 7. Sigmoid activation function

باعث افزایش نرخ یادگیری، بالا رفتن سرعت آموزش و همچنین افزایش قابلیت شامل شبکه (Generalization) می‌شود.

$$z^N = \left(\frac{z - m_z}{s_z} \right) \quad (1)$$

در رابطه (۱)، z خروجی نورون‌ها، m_z میانگین خروجی‌ها، s_z انحراف معیار خروجی نورون‌ها و z^N خروجی نرمال شده هستند.

این شبکه در مجموع دارای ۷۷۴ پارامتر است که ۷۴۶ پارامتر آن، پارامترهای قابل آموزش هستند. با توجه به کارکرد این شبکه که پیش‌بینی زاویه اصطکاک خاک است، تابع هزینه، میانگین مربعات خطا (رابطه ۲)، تابع فعال‌ساز لایه‌های پیچشی، ReLU شکل (۵) و تابع فعال‌ساز لایه‌های تماماً متصل، سیگموئید شکل (۷) انتخاب شد.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2)$$

در رابطه (۲)، MSE میانگین مربعات خطا، N تعداد داده‌ها، y_i خروجی واقعی و \hat{y}_i خروجی پیش‌بینی شده هستند. این شبکه برای ۱۰۰۰ تکرار (Epoch) روی داده‌های آموزش، آموزش داده شد و در نهایت همانطور که در شکل (۱۳) قابل مشاهده است، میانگین مربعات خطا، به ۱/۸۴ رسید. لازم به ذکر است که در این پژوهش، برای تمامی مراحل پیش‌پردازش داده‌ها، ساخت مدل و آموزش و آزمون شبکه عصبی پیچشی، از زبان برنامه‌نویسی Python استفاده شده است.

استفاده شد. تصویرهای تهیه شده از نمونه‌ها در دو فاصله عدسی متفاوت در شکل‌های (۹ و ۱۰) نشان داده شده است.

معماری شبکه عصبی پیچشی استفاده شده در این پژوهش در شکل‌های (۱۱ و ۱۲) نشان داده شده است. این شبکه عصبی از ۵ لایه پیچشی متوالی، یک الگوریتم ادغام هرمی (Pyramid pooling module) با چهار اندازه ادغام متفاوت که به صورت موازی چیده شده‌اند و دو لایه تماماً متصل تشکیل شده است. الگوریتم ادغام هرمی، ظرفیت مدل را برای شناسایی اجزای ریز تصویر افزایش می‌دهد [27]. ورودی شبکه عصبی پیچشی یک تصویر خاکستری (Gray scale) با ابعاد $200 \times 200 \times 1$ است. با عبور این تصویر خاکستری از ۵ لایه پیچشی، یک کانال سه‌بعدی با ابعاد $71 \times 71 \times 6$ حاصل می‌شود که ورودی الگوریتم ادغام هرمی می‌باشد. بعد از اینکه عملیات ادغام با ۴ اندازه مختلف به صورت موازی انجام شد، یک ادغام میانگین کلی (Global average pooling) روی نتایج حاصل از لایه ادغام اعمال می‌شود تا هر نقشه ویژگی با یک عدد جایگزین شود. سپس اعداد حاصل از الگوریتم ادغام هرمی، از یک لایه تماماً متصل عبور داده می‌شود. در ادامه، خروجی که یک عدد (Scalar) است، با جرم مخصوص خشک نمونه ترکیب شده و از یک لایه تماماً متصل عبور می‌کند و زاویه اصطکاک اوج خاک حاصل می‌شود. همچنین یک نرمال‌سازی دسته‌ای روی خروجی هر لایه پیچشی با استفاده از رابطه (۱) انجام شد، که

شکل ۹. عکس‌های گرفته شده از نمونه‌ها با دوربین Nikon، در زیر نور آفتاب با فاصله عدسی ۱۰ سانتی‌متر




Fig. 9. Photos taken from samples with a Nikon camera in sunlight (Lens distance = 10 cm)

شکل ۱۰. عکس‌های گرفته شده از نمونه‌ها با دوربین Nikon، در سایه با فاصله عدسی ۳۰ سانتی‌متر




Fig. 10. Photos taken from samples with a Nikon camera in the shade (Lens distance = 30 cm)

شکل ۱۲. معماری CNN آموزش داده شده برای پیش‌بینی زاویه اصطکاک

اوج ماسه فیروزکوه

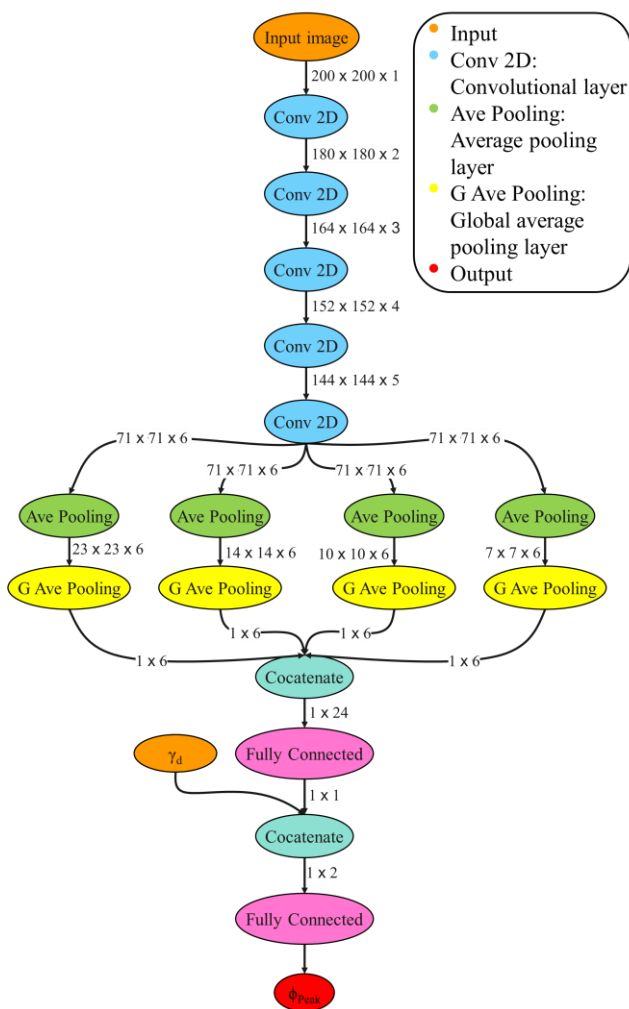


Fig. 12. CNN architecture trained to predict the peak friction angle of Firuzkuh sand

شکل ۱۱. معماری CNN آموزش داده شده برای پیش‌بینی زاویه اصطکاک

اوج ماسه فیروزکوه

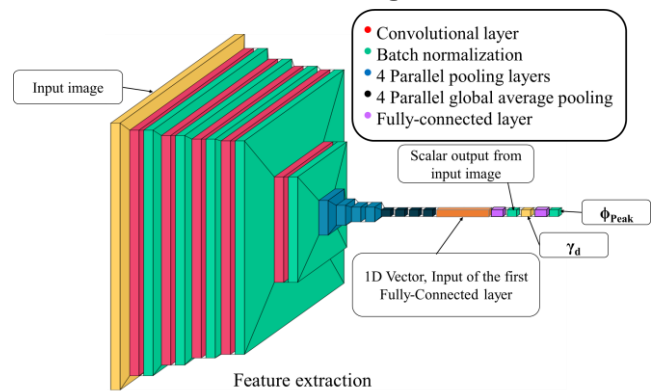


Fig. 11. CNN architecture trained to predict the peak friction angle of Firuzkuh sand

شکل ۱۳. تابع هزینه در برابر تعداد تکرارها برای داده‌های اعتبارسنجی




Fig. 13. The cost function against the number of iterations for the validation data

۴- نتایج

شکل ۱۵. زاویه اصطکاک اوج هر نمونه و زاویه اصطکاک اوج

پیش‌بینی شده (محور افقی نمایانگر ردیف‌های جدول (۲) است)




Fig. 15. Peak friction angle for each sample and predicted peak friction angle (The horizontal axis represents the rows of table (2))

جدول ۲. مقایسه زاویه های اصطکاک اوج واقعی و پیش‌بینی شده برای

تعدادی از نمونه‌ها

$ y_i - \hat{y}_i $	$\phi_{\text{Peak}} \hat{y}_i =$ Predicted (Degree)	$y_i = \phi_{\text{Peak}}$ Experimental (Degree)	Sample	Row
1.8	37.6	36.9		1
0.7	38.5	38.2	S1	2
0.2	39.5	39.4		3
0.5	36.0	35.8		4
1.3	37.1	37.6	S2	5
9.6	39.3	43.5		6
0.2	37.4	37.3		7
3.1	39.3	38.1	S3	8
4.4	40.7	42.6		9
0.0	37.4	37.4		10
2.3	39.4	38.5	S4	11
3.0	41.5	42.8		12
2.9	37.8	36.7		13
2.6	39.4	38.4	S5	14
2.6	40.7	41.8		15
1.6	37.6	37.0		16
2.0	39.3	38.5	S6	17
4.4	40.7	42.6		18
3.3	37.4	36.2		19
3.2	38.5	37.3	S7	20
4.3	40.7	39.0		21
5.3	37.4	35.5		22
5.7	38.5	36.4	S8	23
2.2	39.6	40.5		24
1.8	36.3	37.0		25
4.3	37.8	39.5	S9	26
10.6	39.3	44.0		27
4.6	38.5	36.8		28
1.5	39.0	38.4	S10	29
0.5	39.6	39.4		30

Table 2. Comparison of the actual and predicted peak friction angles

بعد از اینکه آموزش شبکه عصبی پیش‌بینی انجام شد، شبکه برای ۳۷۵ داده‌ای که برای آزمون شبکه در نظر گرفته شده بود (داده‌های آزمون)، امتحان شد. این شبکه زاویه اصطکاک اوج تصاویر مختلف گرفته شده از هر نمونه با جرم مخصوص خشک مشخص را یکسان پیش‌بینی می‌کند، پس برای جلوگیری از تکرار، هر یک از زاویه اصطکاک‌های اوج فقط یکبار در جدول و شکل‌های این بخش آورده شده است. زاویه اصطکاک‌های اوج پیش‌بینی‌شده توسط این شبکه در جدول (۲) نشان داده شده است. دقت زاویه اصطکاک اوج پیش‌بینی شده توسط شبکه برای داده‌های آزمون، در شکل‌های (۱۴ و ۱۵)، نشان داده شده است. میزان انحراف شبکه از رابطه زیر بدست آمد:

$$\text{Normalize relative error} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \quad (3)$$

در رابطه (۳)، N تعداد داده‌ها، y_i خروجی واقعی و \hat{y}_i خروجی پیش‌بینی شده هستند.

شکل ۱۴. میزان انحراف زاویه اصطکاک اوج پیش‌بینی شده توسط شبکه از

مقادیر آزمایشگاهی برای داده‌های آزمون




Fig. 14. The amount of deviation of the peak friction angle predicted by the network from the laboratory values for the test data

که می‌تواند نیاز به انجام آزمایش‌های آزمایشگاهی و درجا را کاهش دهد. در عکس‌های گرفته شده از نمونه‌های مختلف خاک، اطلاعات مهمی از جمله شکل و اندازه دانه‌های خاک وجود دارد که مانند جرم مخصوص خشک، بر روی زاویه اصطکاک اوج خاک تأثیر مستقیم دارند. این اطلاعات توسط شبکه عصبی پیچشی استخراج شده و بعد از ترکیب شدن با جرم مخصوص خشک خاک، برای پیش‌بینی زاویه اصطکاک اوج ماسه فیروزکوه استفاده می‌شوند.

شبکه استفاده شده در این پژوهش برای استخراج جزئیات ریز تصویر از یک الگوریتم ادغام هرمی استفاده می‌کند که یکی از بهترین ابزارهای موجود در شبکه‌های عصبی پیچشی برای جداسازی تصاویر است. همچنین استفاده از الگوریتم ادغام هرمی در شبکه عصبی پیچشی باعث کاهش تصاعدی تعداد پارامترها و در نتیجه آموزش سریع‌تر شبکه، کاهش احتمال بیش برازش (Overfitting)، بهبود قابلیت تعمیم شبکه و کاهش حافظه مورد نیاز می‌شود. استفاده از این ویژگی‌ها در شبکه عصبی پیچشی پژوهش حاضر، باعث شده است تا این شبکه، برای حدود ۹۴ درصد از داده‌های آزمون، زاویه اصطکاک اوج را با دقت ۲ درجه (شکل ۱۴) پیش‌بینی کند.

با این حال، همان‌طور که از جدول (۲) و شکل‌های (۱۴ و ۱۵) قابل مشاهده است، بیشترین میزان خطای شبکه مربوط به داده‌هایی است که زاویه اصطکاک اوج بالایی دارند. دلیل این اتفاق می‌تواند به عدم تعادل داده‌ها و کم بودن تعداد داده‌هایی که زاویه اصطکاک اوج بالایی دارند، مربوط باشد. به عنوان راهکار، این مشکل می‌تواند با اضافه کردن داده‌هایی با زاویه اصطکاک بالا به داده‌های آموزش و ایجاد تعادل در شبکه تا حد زیادی برطرف شود.

منابع

[1] Sharma S, Ahmed S, Naseem M, Alnumay WS, Singh S, Cho GH, "A Survey on Applications of Artificial Intelligence for Pre-Parametric Project Cost and Soil Shear-Strength Estimation in Construction and Geotechnical Engineering", Sensors, 2021, 21 (2), 463.

از جدول (۲) و شکل‌های (۱۴ و ۱۵) مشاهده می‌شود که بیشترین مقدار انحراف از مقدار آزمایشگاهی (خطای نسبی نرمال شده) در بین داده‌های پیش‌بینی شده توسط شبکه عصبی پیچشی، متعلق به داده ردیف ۲۷ (نمونه با دانه‌بندی S9) است که در آن، شبکه، زاویه اصطکاک اوج آزمایشگاهی ۴۴/۰ درجه را ۳۹/۳ درجه پیش‌بینی کرده است. این یعنی بیشترین انحراف این شبکه برای پیش‌بینی زاویه اصطکاک اوج ماسه فیروزکوه از مقادیر آزمایشگاهی، ۱۰ درصد می‌باشد. همچنین خطای نسبی نرمال شده، برای کل داده‌های آزمون، با استفاده از رابطه (۳) برابر با ۳/۰ درصد محاسبه شد و این یعنی شبکه عصبی پیچشی آموزش داده شده، برای پیش‌بینی زاویه اصطکاک اوج ماسه فیروزکوه با استفاده از عکس و جرم مخصوص خشک خاک به عنوان ورودی، قابل اطمینان بوده و توانایی پیش‌بینی زاویه اصطکاک اوج ماسه فیروزکوه را دارد.

۵- نتیجه‌گیری

در پژوهش حاضر، روش جدیدی با استفاده از یک مدل یادگیری عمیق، برای پیش‌بینی زاویه اصطکاک اوج ماسه فیروزکوه ارائه شده است. مدل‌های یادگیری عمیق در مهندسی ژئوتکنیک، به‌ویژه در شرایطی که چالش‌هایی مانند کمبود امکانات آزمایشگاهی، مشکلات در نمونه‌برداری و نگهداری نمونه‌ها، یا منابع مالی محدود برای آزمایش وجود دارد، کارایی زیادی از خود نشان داده‌اند. یکی از دستاوردهای کلیدی فنی و مهندسی استفاده از مدل‌های یادگیری عمیق در مهندسی ژئوتکنیک، توانایی آن‌ها در ارائه پیش‌بینی‌های دقیق بر اساس داده‌های موجود بدون نیاز به آزمایش‌های آزمایشگاهی گسترده است. این امر به‌ویژه در مناطقی که محدودیت‌هایی در امکانات آزمایشگاهی یا منابع مالی برای انجام آزمایش‌های سنتی وجود دارد مفید است.

مزیت اصلی روش ارائه شده در این پژوهش، استفاده از عکس و جرم مخصوص خشک خاک به عنوان ورودی مورد نیاز برای به دست آوردن زاویه اصطکاک اوج خاک است

- [15] Moayed H, Mosallanezhad M, Rashid AS, Jusoh WA, Muazu MA, "A Systematic Review and Meta-Analysis of Artificial Neural Network Application in Geotechnical Engineering: Theory and Applications", *Neural Computing and Applications*, 2019, 32 (6), 495–518.
- [16] Srivastava P, Shukla A, Bansal A, "A Comprehensive Review on Soil Classification Using Deep Learning and Computer Vision Techniques", *Multimedia Tools and Applications*, 2021, 80(2), 887-914.
- [17] Zhang W, Gu X, Tang L, Yin Y, Liu D, Zhang Y, "Application of Machine Learning, Deep Learning and Optimization Algorithms in Geoenvironment and Geoscience: Comprehensive Review and Future Challenge", *Gondwana Research*, 2022, 109 (9), 1–17.
- [18] Zhang W, Li H, Li Y, Liu H, Chen Y, Ding X, "Application of Deep Learning Algorithms In Geotechnical Engineering: a Short Critical Review", *Artificial Intelligence Review*, 2021, 54(8), 5633-5673.
- [19] Fakhimi A, Hosseinpour H, "Experimental and Numerical Study of the Effect of an Oversize Particle on the Shear Strength of Mined-Rock Pile Material", *Geotechnical Testing Journal*, 2011, 34(2): 131-138.
- [20] Afrazi M, Yazdani M, Alitalesh M, Fakhimi AA, "Numerical Analysis of Effective Parameters in Direct Shear Test by Hybrid Discrete-Finite Element Method", 2018, 18(2), 13-24.
- [21] Fareghian M, Afrazi M, Fakhimi A, "Soil Reinforcement by Waste Tire Textile Fibers: Small-Scale Experimental Tests", *Journal of Materials in Civil Engineering*, 2023, 35 (2), 04022402.
- [22] Kingma DP, Ba J, "Adam: A Method for Stochastic Optimization", In *Proceedings of 3rd International Conference on Learning Representations*, San Diego, CA, USA, 2015.
- [23] Krizhevsky A, Sutskever I, Hinton GE, "ImageNet Classification with Deep Convolutional Neural Networks", *Communications of the ACM*, 2012, 60, 84-90.
- [24] Simonyan K, Zisserman A, "Very Deep Convolutional Networks for Large-Scale Image Recognition", *CoRR*, 2014, abs/1409.1556.
- [25] Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A, "Going Deeper with Convolutions", 2015 Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 2015, 1-9.
- [26] He K, Zhang X, Ren S, Jian S, "Deep Residual Learning for Image Recognition", 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, 770-778.
- [27] Zhao H, Shi J, Qi X, Wang X, Jia J, "Pyramid Scene Parsing Network", *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, 2016.
- [2] Wang Y, Akeju OV, "Quantifying the Cross-Correlation between Effective Cohesion and Friction Angle of Soil from Limited Site-Specific Data", *Soils and Foundations*, 2016, 56 (6), 1055–70.
- [3] Islam M, Siddika A, Belal Hossain M, Rahman A, Abdullah Asad M, "Effect of Particle Size on the Shear Strength Behavior of Granular Materials", *Journal of Australian Geomechanics*, 2011, 46 (3), 85-95.
- [4] Nakao T, Fityus S, "Direct Shear Testing of a Marginal Material Using a Large Shear Box", *Geotechnical Testing Journal*, 2008, 31(5), 393-403.
- [5] Zelasko JS, Krizek RJ, Edil TB, "Shear Behavior of Sand as a Function of Grain Characteristics", *Proc. Conference on Soil Mechanics and Foundation Engineering*, Istanbul, Turkey, 1975.
- [6] Nguyen TA, Ly HB, Pham BT, "Backpropagation Neural Network-Based Machine Learning Model for Prediction of Soil Friction Angle", Edited by Mauro Gaggero. *Mathematical Problems in Engineering*, 2020, (5), 1–11.
- [7] Burak EA, "Evaluation of SPT-*N* Values and Internal Friction Angle Correlation Using Artificial Intelligence Methods in Granular Soils", *Soil Research*, 2023, 61, 495-509.
- [8] Pham TA, Tran VQ, Vu HL, "Evolution of Deep Neural Network Architecture Using Particle Swarm Optimization to Improve the Performance in Determining the Friction Angle of Soil", *Mathematical Problems in Engineering*, 2021, (Z4), 1–17.
- [9] Lin P, Chen X, Jiang M, Song X, Xu M, Huang S, "Mapping Shear Strength and Compressibility of Soft Soils with Artificial Neural Networks", *Engineering Geology*, 2022, 300, 106585.
- [10] Zhang H, Nguyen H, Bui XN, Pradhan B, Asteris PG, Costache R, Aryal J, "A Generalized Artificial Intelligence Model for Estimating the Friction Angle of Clays in Evaluating Slope Stability Using a Deep Neural Network and HarrisHawks Optimization Algorithm", *Engineering with Computers*, 2021, 38 (S5), 1–14.
- [11] Zhu L, Liao Q, Wang Z, Chen J, Chen Z, Bian Q, Zhang Q, "Prediction of Soil Shear Strength Parameters Using Combined Data and Different Machine Learning Models", *Applied Sciences*, 2022, 12 (10), 5100.
- [12] Daghistani F, Baghbani A, Abuel Naga H, Faradonbeh RS, "Internal Friction Angle of Cohesionless Binary Mixture Sand-Granular Rubber Using Experimental Study and Machine Learning", *Geosciences*, 2023, 13 (7), 197.
- [13] Mousavi M, Jiryaei Sharahi M, "Estimating the Sand Shear Strength from Its Grain Characteristics Using an Artificial Neural Network Model and Multiple Regression Analysis", *AUT Journal of Civil Engineering*, 2021, 5(3), 403-420.
- [14] Zhang P, Yin ZY, Jin YF, "Bayesian Neural Network-Based Uncertainty Modelling: Application to Soil Compressibility and Undrained Shear Strength Prediction", *Canadian Geotechnical Journal*, 2021, 59(4), 546-557.

Prediction of soil friction angle using a deep learning model: A case study of Firuzkuh sand

S.Hashemi Salanghouch¹, A.Fakhimi^{2*}

1- M.Sc. Student, School of Civil and Environmental Engineering, Tarbiat Modares University, Tehran, Iran.

*2- Professor, School of Civil and Environmental Engineering, Tarbiat Modares University, Tehran, Iran.

Email: *A.fakhimi@modares.ac.ir

Abstract:

Friction angle of soil is a critical parameter in the geotechnical engineering and has a direct impact on the design of various structures, such as retaining walls, slopes, and piles. This parameter plays a crucial role in determining the overall safety and performance of these structures, making it a key player in the geotechnical analysis and design. In recent years, there have been some impressive advancements in the field of artificial neural networks and deep learning models. These advancements have transformed these models into the highly effective tools for predicting the properties and behavior of soil. By using a powerful deep learning model, it is now possible to save a considerable amount of time and money when it comes to estimating and predicting soil properties. In this particular study, a convolutional neural network was developed to predict the peak friction angle of Firuzkuh sand using some soil images and the dry density as the input parameters. The network itself consisted of five consecutive convolutional layers, as well as a pyramid pooling module that utilized four different pooling sizes arranged in parallel. In addition, two fully connected layers were incorporated into the network's design, which enabled it to satisfactorily process the input parameters of the images and the dry densities with respect to the speed and precision. This network converts the soil image into a scalar (number) by using these 5 convolutional layers, the pyramid pooling module and a fully connected layer. Then, this scalar is concatenated with the dry density of the soil, is passed through a fully connected layer, and the peak friction angle of the soil is obtained as an output. For data generation, a total of ten samples of Firuzkuh sand were prepared. These samples had different gradation curves, which are referred to as S1 to S10 specimens. Each soil specimen was compacted at three different dry densities. The peak friction angle associated with the 30 different densities for the 10 different particle size distributions (S1 to S10 specimens) was determined using the direct shear test apparatus. The direct shear test box was 100 × 100 × 25 mm in size. For network training and testing, the soil specimens were spread on a flat surface and 50 photos in different light environments with varying distances of the camera from the soil surface, were taken from each specimen. Since in the network training process, three dry densities were considered for each sample, a total of 1500 images were prepared for the network database. Of these, 1125 photos were used for training and 375 photos were saved for testing the network. The network was trained for 1000 epochs on the training data, and the mean square error after 1000 epochs was reduced to 1.84. The outcome of the assessment conducted on the designed convolutional neural network in this study, using 375 test data, revealed that the network can predict the peak friction angle of Firuzkuh sand by incorporating the image and dry density of the soil as input variables. The total normalized relative error was 3.0%, while the maximum normalized relative error was 10%. This indicates that the network has the ability to quickly predict the peak friction angle of the Firuzkuh sand with a good accuracy.

Keywords: Deep learning, Soil friction angle, Firuzkuh sand, Convolutional neural Network, Digital image processing.