

پیش‌بینی پارامترهای الاستیک مخزن کربناته از داده‌های چاه‌نگاری با استفاده از روش‌های یادگیری ماشین و رگرسیون چند متغیره

محمد رضا آقاخانی امام قیسی^۱، منوچهر صانعی^{۱*}، محمد فاتحی مرجی^۱
۱- گروه استخراج، دانشکده مهندسی معدن و متالورژی، دانشگاه یزد، یزد، ایران.

پذیرش: ۱۴۰۲/۰۵/۳۱

دریافت: ۱۴۰۲/۰۱/۲۵

(نویسنده مسئول: m.sanei@yazd.ac.ir)

چکیده

پارامترهای ژئومکانیکی از جمله مدول یانگ و ضریب پواسون نقش بسیار کلیدی در عملیات حفاری و تولید چاه‌های نفت و گاز دارند. تعیین این پارامترها می‌تواند تا حد زیادی به شناخت وضعیت و مشکلات چاه کمک نماید. از آنجایی که تعیین این پارامترها به روش آزمایشگاهی بسیار پر هزینه و زمان‌بر می‌باشد در نتیجه در این پژوهش سعی شده است روشی جهت پیش‌بینی پارامترهای الاستیک خطی بر اساس روش‌های رگرسیون چند متغیره و یادگیری ماشین بر مبنای داده‌های چاه‌نگاری (زمان انتقال موج فشاری، چگالی و تخلخل) مربوط به یکی از چاه‌های گازی جنوب ایران ارائه نمود. پس از ساخت مدل‌ها، نتایج حاصل از هر روش مورد مقایسه قرار گرفت. این مقایسه نشان داد که روش یادگیری ماشین با کمترین مقادیر میانگین درصد خطای مطلق و ریشه میانگین مربعات خطا و همچنین بالاترین مقدار ضریب تعیین، عملکرد بهتری در پیش‌بینی پارامترهای الاستیک نسبت به روش رگرسیون چند متغیره دارد. بعلاوه در این پژوهش روابط تجربی بر مبنای اطلاعات مربوط به وزن‌ها و اریبی‌های (بایاس) روش شبکه چند لایه پرسپترون (*MLP*) برای پیش‌بینی پارامترهای الاستیک توسعه داده شد. این روابط برای روش *MLP* بر مبنای داده‌های چاه A مربوط به یکی از میادین ایران اعتبارسنجی شده و این نتیجه بدست آمد که با توجه به مقادیر ضریب تعیین ۰/۹۷ و ۰/۹۶ به ترتیب برای مدول یانگ و ضریب پواسون، روابط به دست آمده از این پژوهش دارای اعتبار مناسبی می‌باشند. در نتیجه معادلات جدید می‌توانند بدون نیاز به هیچ نرم افزار یادگیری ماشین و برای چاه‌های جدید بر مبنای داده‌های چاه‌نگاری استفاده شوند.

ژئومکانیک نفت، مدول یانگ، ضریب پواسون، یادگیری ماشین، رگرسیون چند متغیره، داده‌های چاه‌نگاری

واژگان کلیدی

۱- مقدمه

بنابراین شناسایی این پارامترها با استفاده از امکانات موجود یکی از چالش‌های مهندسی و زمین‌شناسان در تمام طول عمر میدان نفتی و گازی به شمار می‌آید. بطور کلی خصوصیات مکانیکی سنگی به دو روش کلی آزمایشگاهی و اندازه‌گیری‌های درون چاهی قابل محاسبه می‌باشند. روش‌های آزمایشگاهی به دلیل عدم دسترسی لازم به نمونه‌های آزمایشگاهی، هزینه‌بر بودن آزمایش‌ها و عدم امکان

پارامترهای ژئومکانیکی سنگ، از جمله مدول یانگ و ضریب پواسون، به درک وضعیت سازند و مخزن مورد مطالعه در طول دوران فعالیت میدان‌های نفتی و گازی کمک می‌نماید. این پارامترها نقش بسزایی در علم ژئومکانیک دارند و از جمله کاربرد آنها در آنالیز پایداری چاه، طراحی جداره-گذاری، شکست هیدرولیکی و بررسی تولید ماسه می‌باشد.

منظور استفاده کرده‌اند [۵,۶]. با این حال، برخی از این نتایج نشان داد که این روش‌ها برای ارائه مقادیر قابل اعتماد جهت محاسبه مدول یانگ و ضریب پواسون کافی نمی‌باشد و تنها می‌توان از این معادلات برای انواع سنگ‌های خاص استفاده نمود [۷,۸]. مطالعات اخیر کاربرد استفاده از روش‌های یادگیری ماشین جهت داشتن مقادیر با دقت بالاتر را برجسته نموده است. احمدی ندوشن [۹] یک مدل سیستم استنتاج فازی مبتنی بر شبکه تطبیقی ($ANFIS^1$) و سه مدل رگرسیون غیرخطی بهینه شده را برای پیش‌بینی مدول الاستیک بتن معمولی و با مقاومت بالا پیشنهاد نمود. این مدل به کمک داده‌های تجربی و سایر مدل‌های تجربی مقایسه و در نهایت نتایج نشان‌داد روش $ANFIS$ از مدل‌های رگرسیونی غیرخطی و سایر مدل‌ها بهتر عمل می‌کند و نتایج قابل اعتمادتری از خود نشان داد. ابوطالب و همکاران [۱۰] از مدل‌های شبکه عصبی و ماشین بردار پشتیبان جهت پیش‌بینی مقدار مدول یانگ استاتیکی و مقاومت فشاری تک محوره استفاده نموده‌اند. داده‌های این پژوهش مربوط به سنگ‌های کربناته سازند آسماری می‌باشد و پارامترهای دینامیکی به عنوان ورودی مدل‌ها قرار داده شده است. الکتاتنی و همکاران [۱۱] با استفاده از سه روش شبکه هوش مصنوعی، ماشین بردار پشتیبان و منطق فازی به پیش‌بینی پارامترهای مخزن به کمک داده‌های چاه‌نگاری پرداخته‌اند. طاروق و همکاران [۱۲] یک مدل تجربی تعمیم یافته برای پیش‌بینی نسبت پواسون استاتیکی سنگ‌های کربناته ارائه می‌نماید. در این پژوهش لاگ‌های پتروفیزیکی به عنوان ورودی و مقادیر نسبت پواسون استاتیکی اندازه‌گیری شده آزمایشگاهی به عنوان خروجی استفاده شد. عبدالحمید محمود و همکاران [۱۳] با استفاده از داده‌های لاگ چاه و روش شبکه عصبی مصنوعی به تخمین مدول یانگ استاتیکی سازند ماسه سنگی پرداخته و پس از آن، با استفاده از مقادیر وزن و اریبی^۲ استخراج‌شده از لایه‌های پنهان شبکه عصبی، یک رابطه تجربی برای محاسبه مدول یانگ استاتیکی ارائه شد. احمد و همکاران [۱۴] با استفاده از داده‌های حفاری به عنوان ورودی و به کمک روش‌های یادگیری ماشین شبکه عصبی مصنوعی، سیستم استنتاج

دسترسی به تجهیزات آزمایشگاهی مناسب تا حد زیادی دچار محدودیت می‌باشند. در نتیجه روش‌های اندازه‌گیری درون چاهی جهت محاسبه پارامترهای الاستیک، کاربرد بیشتری پیدا کرده‌اند. از جمله مزیت استفاده از روش‌های اندازه‌گیری دینامیکی غیر مخرب بودن، مقرون به صرفه بودن از نظر هزینه و زمان و همچنین پوشش دادن تمام فواصل چاه می‌باشد که این روش را به یک روش کارآمد تبدیل نموده است. با توجه به اینکه مقادیر دینامیکی و استاتیکی بسیار با یکدیگر متفاوت هستند و مقادیر استاتیکی مقدار بیشتری دارند در نتیجه جهت تبدیل مقادیر دینامیکی به استاتیکی از روابط تجربی مختلفی استفاده خواهد شد. تعیین پارامترهای دینامیکی نیازمند داشتن اطلاعات سرعت موج فشاری و برشی می‌باشد از آنجایی که این اطلاعات به طور کلی در تمام چاه‌ها وجود ندارد در نتیجه در سال‌های اخیر پژوهشگران به کمک استفاده از قابلیت روش‌هایی از جمله رگرسیون تک متغیره، رگرسیون چند متغیره و روش‌های هوش مصنوعی از جمله شبکه عصبی مصنوعی، منطق فازی، الگوریتم ژنتیک و غیره به پیش‌بینی پارامترهای الاستیک با دقت بیشتر اقدام نموده‌اند [۱].

با توجه به اهمیت تعیین پارامترهای ژئومکانیکی، مطالعات متعددی در این زمینه انجام شده است. یکی از این تحقیقات توسط کاوسیان و همکاران [۲] صورت گرفته که به بررسی پایداری چاه با استفاده از مدل‌سازی ژئومکانیکی بر اساس روابط تجربی پرداخته‌اند. در نهایت، نتایج تحلیل‌ها با داده‌های واقعی جمع‌آوری شده از حفاری و اطلاعات مورد نیاز مقایسه شدند تا دقت نتایج مورد ارزیابی قرار گیرد. صانعی و همکاران [۳] با بررسی داده‌های میدان ولو نروژ به ساخت یک مدل یک بعدی و سه بعدی استاتیکی با استفاده از داده‌های چاه پیمایی و لرزه نگاری پرداختند. آقاخانی امام قیسی و همکاران [۴] در یک مطالعه با استفاده از داده‌های چاه و روابط تجربی به محاسبه پارامترهای ژئومکانیکی پرداختند و در نهایت با ساخت مدل ژئومکانیکی به تعیین پنجره گل حفاری و با استفاده از مدل‌سازی عددی به بررسی اثر تنش‌های برجا بر تغییرات پنجره گل پرداختند. بعلاوه برخی محققان به دلیل اهمیت پیش‌بینی مدول الاستیسیته، از روش تحلیل رگرسیون چندگانه برای این

¹ Adaptive neuro-fuzzy inference system

² Bias

کارایی روش‌های هوشمند برای تخمین پارامترهای ژئومکانیکی است.

در این پژوهش سعی شده است به کمک استفاده از داده‌های زمان موج فشاری (DT)، چگالی ($RHOB$) و تخلخل ($NPHI$) به عنوان داده‌های ورودی و داده‌های مدول یانگ و ضریب پواسون استاتیکی به عنوان خروجی و به کمک دو روش رگرسیون چند متغیره خطی (MLR) و روش شبکه چند لایه پرسپترون (MLP) به پیش‌بینی پارامترهای الاستیک پرداخته شود. در نهایت با مقایسه مقادیر ضریب همبستگی و خطا، روش با دقت بالا جهت محاسبه پارامترهای ژئومکانیکی انتخاب شد. با توجه به نیاز صنعت به ارائه روش‌های با سرعت و دقت بالا در محاسبات، در این پژوهش به کمک روش‌های MLR و MLP ، روابط تجربی بر اساس داده‌های چاه‌نگاری ارائه خواهد شد. نوآوری این پژوهش در این است که از داده‌های چاه‌نگاری در سازندهای کربناته می‌توان بدون نیاز به نرم‌افزارهای یادگیری ماشین، روابط تجربی را برای پیش‌بینی پارامترهای الاستیک استاتیکی استخراج کرد.

۲- زمین‌شناسی منطقه مورد مطالعه

داده‌های مورد استفاده در این پژوهش مربوط به یکی از چاه‌های میادین گازی جنوب ایران می‌باشد. به طور عمده بخش مخزنی این میدان مربوط به سازندهای کنگان و دالان می‌باشد. همان‌طور که در شکل (۱) نشان داده شده این سازند به پنج لایه $K1$ تا $K5$ تقسیم می‌شود که در آن، لایه‌های $K1$ و $K2$ معادل کنگان، لایه‌های $K3$ و $K4$ معادل دالان بالایی و لایه $K5$ معادل دالان پایینی و بخش نار می‌باشد. از نظر زمین‌شناسی، لایه‌های مخزنی در سازندهای دالان و کنگان دارای سن پرمین بالایی تا تریاس پایینی می‌باشد و بر اساس مطالعات پتروفیزیکی انجام شده، سنگ‌های به دست آمده عمدتاً از نوع سنگ‌های کربناته متراکم شامل دولومیت و کانی‌های آهن دار نظیر سیدریت و ندرتا هماتیت و مگنتیت و همچنین انیدریت می‌باشند.

فازی-عصبی تطبیقی و ماشین بردار پشتیبان به محاسبه ضریب پواسون استاتیکی پرداخته‌اند که بر اساس نتایج به دست آمده روش ماشین بردار پشتیبان نسبت به دو روش دیگر از نتایج مناسب‌تری جهت محاسبه ضریب پواسون استاتیکی برخوردار بود. محمود و همکاران [۱۵] به کمک داده‌های چاه به تخمین مدول یانگ استاتیکی بر اساس تکنیک شبکه عصبی مصنوعی خود تطبیقی پرداخته‌اند. در نهایت نتایج ضریب تعیین و مقادیر خطا برای داده‌های آموزشی و آزمایشی نشان داد این روش نتایج با دقت بالایی در پیش‌بینی مدول یانگ استاتیکی دارد. آقاخانی امام‌قیسی و همکاران [۱۶] با بررسی سه روش یادگیری ماشین شامل ANN^3 , SVM^4 , $ANFIS^5$ برای پیش‌بینی مدول یانگ و ضریب پواسون این نتیجه به دست آمد که روش ANN می‌تواند با دقت بالاتری نسبت به دو روش دیگر به پیش‌بینی این پارامترها بپردازد. به علاوه در این مقاله از روش‌های ترکیبی استفاده شد که در نهایت این نتیجه به دست آمد که با روش‌های ترکیبی^۶ می‌توان نتایج بهتری به دست آورد. صانعی و همکاران [۱۷] در یک مطالعه با هدف استفاده از مدل‌های ترکیبی به خصوص الگوریتم ژنتیک-پرسپترون چند لایه ($GA-MLP$) و الگوریتم ژنتیک-تابع پایه شعاعی ($GA-RBF$)، برای تخمین پارامترهای ژئومکانیکی (GM) از یک مجموعه داده پیچیده توسعه داده شده است. این مدل‌ها با استفاده از داده‌های شش چاه در میدان نفتی ولو نروژ آموزش داده شده و با استفاده از داده‌های سه چاه دیگر بررسی و اعتبارسنجی شدند. دلاور و همکاران [۱۸] به بهینه‌سازی حفاری با استفاده از روش‌های هوشمند پرداختند. نتایج نشان داد که این روش‌ها امکان حفاری مطلوب را فراهم می‌نماید. صانعی و همکاران [۱۹] با استفاده از روش‌های هوشمند به تخمین فشار منفذی و تنش افقی حداقل براساس نگاره‌های چاه‌پیمایی پرداختند. نتایج تاکید بر کارایی این روش‌هاست. صانعی و همکاران [۲۰] با استفاده از روش‌های هوشمند به تخمین پارامترهای ژئومکانیکی براساس نگاره‌های چاه‌پیمایی پرداختند. نتایج تاکید بر

³ Artificial neural network

⁴ Support vector machine

⁵ Adaptive neuro fuzzy inference system

⁶ Ensemble Model

های خروجی آزمایشی از انجام آزمایش مقاومت فشاری تک محوره بر روی ۱۹ نمونه مغزه گرفته شده در عمق بین ۲۸۲۰-۲۶۵۰ از یکی از چاه های گازی جنوب ایران به دست آمده است. همچنین جهت آموزش مدل از ۲۷۹۰ داده استفاده شده که حاصل از داده های چاهنگاری می باشد. محدوده مقدار زمان عبور موج فشاری (DT) بین ۱۴۷٫۹۹ تا ۲۳۵٫۴۲ (بر حسب $\mu s / m$)، محدوده مقدار تخلخل نسبی ($NPHI$) بین ۰ تا ۰٫۲۹ (بر حسب V/V) و بازه مقدار چگالی بین ۱٫۳۷ تا ۳٫۹۵ (بر حسب g/cm^3) می باشد. مجموع داده ها به سه دسته تقسیم می شوند که ۷۰٪ (۱۹۵۳ عدد) داده ها به عنوان داده های آموزشی، ۲۰٪ (۵۵۹ عدد) به عنوان داده های آزمایشی و ۱۰٪ (۲۷۸ عدد) به عنوان داده های اعتبارسنجی انتخاب شده و به عنوان ورودی و خروجی مدل ها مورد استفاده قرار گرفته شد. در جدول (۱) به طور کامل اطلاعات آنالیز آماری توصیفی داده های مورد استفاده نشان داده شده است.

جدول ۱- آنالیز آماری توصیفی داده های ورودی و خروجی

انحراف معیار	میانگین	حد اقل	حداکثر	پارامتر
۳/۴	۵۰/۸۵	۴۵/۱۱	۷۱/۷۸	$DT(\mu s/ft)$
۰/۰۴	۰/۰۵	۰	۰/۲۹	$NPHI(v/v)$
۰/۲۲	۲/۸۸	۱/۳۷	۳/۹۵	$RHOB(g/cm^3)$
۴/۸	۳۸/۰۳	۲۴/۴	۵۴/۱۸	$E(GPa)$
۰/۰۲	۰/۲۸	۰/۰۵	۰/۳	ν

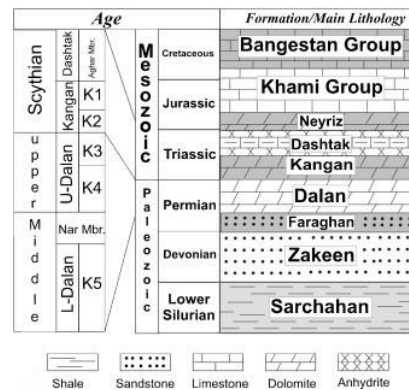
۲-۳- رگرسیون چند متغیره خطی (MLR^7)

به منظور تعیین رابطه بین دو یا چند متغیر، شاخص هایی وجود دارد که این شاخص ها رابطه بین متغیرها را به کمک بررسی ضریب همبستگی نشان می دهند.

به طور کلی هدف استفاده از روش رگرسیون چند متغیره خطی، تعیین معادله مناسب بین پارامترهای مستقل و وابسته مدل می باشد. این روش در مواردی که بیش از یک متغیر مستقل وجود داشته باشد، برای دستیابی به معادله مناسب استفاده می شود و می تواند رابطه بین این پارامترها را با دقت بالایی نشان دهد [۲۴]. رابطه بین متغیرهای وابسته و مستقل در روش MLR به کمک رابطه (۱) که در زیر آمده محاسبه می شود [۲۵]:

$$y = a + b_1x_1 + b_2x_2 + b_3x_3 + \dots + b_nx_n \quad (1)$$

⁷ Multiple linear regression



شکل ۱- ستون چینه شناسی سازندهای مورد مطالعه در جنوب ایران [۲۱]


۳- روش شناسی

در این قسمت ابتدا به شرح داده های مورد استفاده در پژوهش پرداخته شده و روش های مورد استفاده از جمله روش رگرسیون چند متغیره خطی و روش شبکه عصبی و نحوه ساخت مدل در این دو روش شرح داده شده است. همچنین معیارهای ارزیابی کارایی و دقت مدل ها نیز معرفی شده است.

۱-۳- شرح داده ها

مدیریت و آماده سازی داده ها یکی از گام های ضروری برای موفقیت در روش های یادگیری ماشین و آماری می باشد. کارایی این مدل ها تا حد زیادی به داشتن داده های حاصل از یک برداشت سیستماتیک با دقت مناسب، یکنواختی و ارتباط مستقیم با مسئله مورد بررسی بستگی دارد. در پژوهش حاضر، داده های مربوط به سرعت موج برشی (V_s) به طور کامل در تمامی فواصل چاه محاسبه نشده است. با توجه به هزینه بالای برداشت نگاره DSI ، محققان متعددی تلاش کرده اند تا این پارامتر را با استفاده از نگارهای دیگر چاهنگاری تعیین کنند [۲۲ و ۲۳]. با بررسی این روابط مشاهده شد که اکثر مطالعات انجام شده در این زمینه بر روی ماسه سنگ ها انجام گرفته است، بنابراین ارائه روابط تجربی برای سنگ های کربناته نیاز به مطالعات بیشتری دارد. با توجه به این محدودیت ها و همچنین محاسبه نتایج ضریب همبستگی، این نتیجه به دست آمد که از داده های چاهنگاری از جمله زمان انتقال موج فشاری (DT)، داده های چگالی ($RHOB$) و تخلخل ($NPHI$) به عنوان ورودی های مدل سازی در چاه A استفاده شود. در پژوهش حاضر، داده

آموزش این سیستم به صورت اصلاح تدریجی وزن‌ها در جهت کمینه کردن تابع خطا می‌باشد و تا زمانی این عمل ادامه می‌یابد که مدل مورد نظر به یکی از معیارهای توقف اعمال شده پاسخ مثبت نشان دهد [۲۸].



شکل ۲- شماتیک شبکه چند لایه پرسپترون MLP

در نهایت جهت بررسی کارایی و دقت مدل‌های ساخته شده از چند معیار مهم استفاده می‌شود. این معیارها به طور کلی شامل میانگین درصد خطای مطلق ^{۱۱} (MAPE)، ریشه میانگین مربعات خطا ^{۱۲} (RMSE) هستند که به عنوان معیارهای آماری ضروری، عملکرد کلی مدل ساخته شده را بررسی می‌کنند. جهت محاسبه این پارامترها از روابط (۲) و (۳) استفاده می‌شود.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\left| \frac{M_{rm} - M_{rp}}{M_{rm}} \right| \right) \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (M_{rp} - M_{rm})^2}{n}} \quad (3)$$

در این روابط M_{rm} و M_{rp} به ترتیب مقدار اندازه‌گیری شده و پیش‌بینی شده، \bar{M}_{rm} ، \bar{M}_{rp} میانگین مقادیر اندازه‌گیری و پیش‌بینی شده و n بیانگر تعداد نمونه‌ها می‌باشد. مدل‌های پیش‌بینی با ضریب تعیین (R^2) نزدیک به یک و مقدار خطاهای نزدیک به صفر دارای بالاترین دقت در پیش‌بینی داده‌ها می‌باشند.

۴- نتایج و بحث

در این مطالعه سعی شده است تا توانایی مدل‌های رگرسیون چند متغیره خطی و شبکه عصبی در پیش‌بینی مقدارهای مدول یانگ و ضریب پواسون بررسی شود. این مدل‌ها به کمک داده‌های چاه‌نگاری ($DT, NPHI, RHOB$) به عنوان

در این رابطه y متغیر وابسته، $x_1 \dots x_n$ پارامترهای مستقل، a مقدار ثابت و $b_1 \dots b_n$ ضرایب پارامترها می‌باشند.

۳-۳- یادگیری ماشین

یادگیری ماشین، شاخه‌ای از هوش مصنوعی است که به توسعه سیستم‌هایی می‌پردازد که از داده‌ها یاد می‌گیرند. این روش به ایجاد برنامه‌هایی کمک می‌کند که با تجربیات و آموزش بیشتر به‌طور خودکار بهبود می‌یابند. یادگیری ماشین به سه دسته تقسیم می‌شود: یادگیری نظارتی، یادگیری بدون ناظر و یادگیری تقویتی. در یادگیری نظارتی، ورودی و خروجی الگوریتم مشخص است، در حالی که در یادگیری بدون ناظر، ورودی و خروجی نامشخص‌اند. در یادگیری تقویتی، سیستم با محیط تعامل دارد و از این طریق عملی بهینه برای دستیابی به هدف انتخاب می‌کند.

سیستم شبکه عصبی به طور کلی از سیستم عصبی زیستی به منظور پردازش اطلاعات الهام گرفته شده است و این سیستم همانند مغز انسان به پردازش اطلاعات می‌پردازد. وظیفه اصلی شبکه عصبی شناسایی الگوها، دسته‌بندی اطلاعات و تقریب تابع در طول یک پروسه یادگیری می‌باشد [۲۶]. به طور کلی همان‌طور که در شکل (۲) نشان داده شده مدل‌های شبکه عصبی از سه بخش اصلی لایه ورودی، لایه پنهان و لایه خروجی تشکیل شده‌اند که هر کدام از این لایه‌ها وظیفه دریافت داده‌ها، پردازش و تولید لایه‌های خروجی را بر عهده دارند. متداول‌ترین نوع شبکه‌های عصبی، شبکه‌های چند لایه پرسپترون پیش‌خور ^۸ می‌باشند. این نوع شبکه‌ها از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده‌اند و متناسب با هر اتصال، یک وزن در نظر گرفته شده است [۲۷]. الگوریتم پس انتشار خطا ^۹ یکی از پرکاربردترین الگوریتم‌ها برای آموزش شبکه عصبی مصنوعی چند لایه پیش‌خور می‌باشد. در این روش از تکنیک کاهش شیب تابع خطا ^{۱۰} استفاده می‌شود که طی آن خطاها از لایه ورودی به سمت لایه خروجی پخش شده و وزن‌ها به گونه‌ای اصلاح خواهند شد که خطا در کمترین حالت ممکن قرار بگیرد. بنابراین فرآیند

⁸ Feed-Forward

⁹ Back Propagation

¹⁰ Gradient Descent

¹¹ Mean Absolute Percentage Error

¹² Root Mean Square Error

استفاده از آزمون t ، همبستگی بین مدل و نتایج به دست آمده مورد بررسی قرار گرفت. این آزمون در رابطه با فرض صفر بودن یا نبودن اثر پارامترهای مستقل (زمان انتقال موج فشاری، چگالی و تخلخل) بر متغیرهای وابسته (مدول یانگ و ضریب پواسون استاتیکی) بر مبنای بررسی آماره p (سطح معناداری) بحث می‌کند. بر این اساس زمانی که مقدار سطح معناداری در این آزمون کمتر از 0.05 باشد، فرض صفر رد می‌شود و این پارامترها بر متغیر وابسته تاثیرگذار می‌باشند. در نتیجه در این پژوهش به کمک آماره t و p گزارش شده در جدول (۲) اعتبار هر یک از متغیرهای وابسته به طور جداگانه بر مبنای آزمون t مشخص شد. بر این اساس با توجه به نتایج به دست آمده برای هر دو مدل پیش‌بینی می‌توان گفت، مقدار سطح معناداری (p -Value) برای هر سه متغیر مستقل DT ، $NPHI$ ، $RHOB$ کمتر از مقدار 0.05 بوده که نشان دهنده وجود ارتباط قوی بین این پارامترها و متغیرهای الاستیک استاتیکی می‌باشد. علاوه بر این موارد با استفاده از مقدار خطاهای $MAPE$ و $RMSE$ (معادلات (۲) و (۳)) کیفیت مدل‌ها بررسی و در نهایت نتایج آن برای داده‌های آموزشی، آزمایشی و اعتبارسنجی در شکل (۴) و (۵) نشان داده شده است.

ورودی و مدول یانگ و ضریب پواسون به عنوان خروجی ساخته شده‌اند. در این قسمت نتایج حاصل از هر مدل شرح داده شده و با مقایسه این نتایج، مدل با دقت بالا در پیش‌بینی پارامترهای الاستیک معرفی می‌شود.

۴-۱- آنالیز رگرسیون چند متغیره

در این پژوهش جهت تعیین مدل‌های رگرسیون چند متغیره خطی (MLR) از نرم افزار $SPSS 26^{13}$ استفاده شده است. به منظور ارزیابی همبستگی بین پارامترهای مدول یانگ استاتیکی (E) و ضریب پواسون استاتیکی (ν) با سه پارامتر ورودی انتخاب شده شامل $DT, NPHI, RHOB$ دو مدل تجزیه و تحلیل MLR ساخته شده است. در جدول (۲) نتایج آماری حاصل از روش رگرسیون چندمتغیره خطی برای پیش‌بینی مدول یانگ استاتیکی و ضریب پواسون استاتیکی نشان داده شده است. پارامترهای جدول (۲) به ترتیب شامل ضرایب رگرسیونی (معادل ضرایب $b_1 \dots b_n$ در رابطه (۱))، خطای معیار و آماره‌های t و p که معیارهای تصمیم‌گیرنده در مورد لزوم وجود هر یک از متغیرهای زمان انتقال موج فشاری، چگالی و تخلخل در مدل نهایی می‌باشند.

با توجه به نتایج جدول (۲)، به ترتیب معادلات (۴) و (۵) بر اساس روش رگرسیون چند متغیره خطی برای پیش‌بینی مدول یانگ استاتیکی و ضریب پواسون استاتیکی ارائه شده است.

$$E = -1.308 DT + 10.952 NPHI + 13.754 RHOB + 64.217 \quad (4)$$

$$\nu = -0.006 DT + 0.039 NPHI - 0.011 RHOB + 0.604 \quad (5)$$

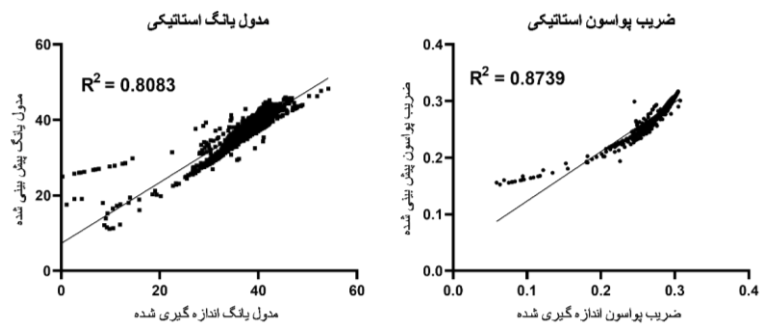
ضریب تعیین (R^2) بین مقادیر اندازه‌گیری شده و پیش‌بینی شده پارامتر مناسبی جهت ارزیابی عملکرد مدل پیش‌بینی می‌باشند. شکل (۳) مقدار R^2 بین مقادیر پیش‌بینی شده و اندازه‌گیری شده برای پارامترهای الاستیک استاتیکی را نشان می‌دهد. که این مقدار به ترتیب 0.808 و 0.873 برای مدول یانگ و ضریب پواسون می‌باشند.

با توجه به بالا بودن مقادیر ضریب تعیین برای مدل پیش‌بینی، همچنان نمی‌توان از دقت بالای این مدل در پیش‌بینی پارامترهای الاستیک اطمینان داشت. لذا با

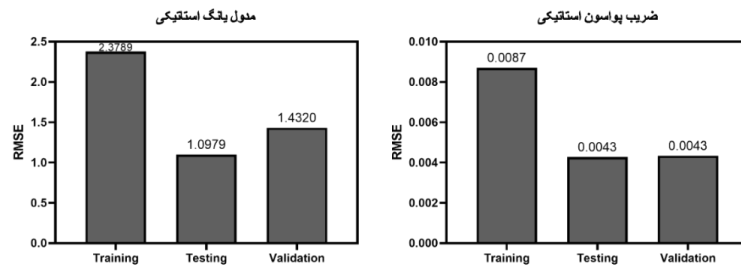
¹³ Statistical Package for Social Science (version of 26)

جدول ۲- نتایج آماری مدل‌های MLR جهت پیش‌بینی مدول یانگ و ضریب پواسون استاتیکی


مدل	مدول یانگ استاتیکی				ضریب پواسون استاتیکی			
	ضریب	خطای معیار	t-Value	p-Value	ضریب	خطای معیار	t-Value	p-Value
عرض از مبدا	۶۴,۲۱۷	۰,۶۹۲	۹۲,۷۸۵	۰,۰۰۰	۰,۶۰۴	۰,۰۰۳	۲۳۹,۴۳۸	۰,۰۰۰
<i>DT</i>	-۱,۳۰۸	۰,۰۱۳	-۹۹,۰۸۱	۰,۰۰۰	-۰,۰۰۶	۰,۰۰۰	-۱۱۸,۶۳۹	۰,۰۰۰
<i>NPHI</i>	۱۰,۹۵۲	۱,۲۴۷	۸,۷۸۴	۰,۰۰۰	۰,۰۳۹	۰,۰۰۵	۸,۶۷۲	۰,۰۰۰
<i>RHOB</i>	۱۳,۷۵۴	۰,۲۰۸	۶۶,۲۲۷	۰,۰۰۰	-۰,۰۱۱	۰,۰۰۱	-۱۴,۵۲۴	۰,۰۰۰



شکل ۳- نمودار R² بین مقادیر اندازه‌گیری شده و پیش‌بینی شده مدول یانگ و ضریب پواسون برای مدل MLR



شکل ۴- نتایج خطای RMSE برای داده‌های آموزشی، آزمایشی و اعتبارسنجی حاصل از روش MLR




شکل ۵- نتایج خطای MAPE برای داده‌های آموزشی، آزمایشی و اعتبارسنجی حاصل از روش MLR

۲-۴- پردازش مدل چند لایه پرسپترون

فعال‌سازی غیرخطی، به شبکه کمک می‌کنند تا روابط پیچیده میان ورودی‌ها و خروجی‌ها را یاد بگیرد و دقت پیش‌بینی را افزایش دهد. جهت تعیین تعداد نورون‌های این لایه در هر مرحله تعداد نورون بین ۱ تا ۲۰ تغییر داده شد و به وسیله اجرا سیستم و اندازه‌گیری خطا، مناسب‌ترین تعداد

مدل بعدی جهت پیش‌بینی پارامترهای ژئومکانیکی مربوط به شبکه چند لایه پرسپترون می‌باشد. در این پژوهش، از یک لایه مخفی در مدل *MLP* استفاده شده است تا امکان یادگیری الگوهای پیچیده و غیرخطی فراهم شود؛ زیرا این لایه‌ها با انجام محاسبات پیچیده و استفاده از توابع



پیش بینی، الف) مدول یانگ استاتیک، ب) ضریب پواسون استاتیکی



شکل ۷- شمایک شبکه چند لایه پرسپترون ساخته شده جهت محاسبه پارامترهای الاستیک استاتیکی

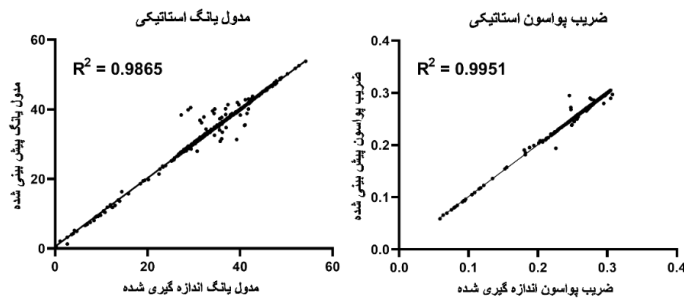
نتایج به دست آمده از روش *MLP* نشان داد مقدار R^2 برای پارامترهای مدول یانگ استاتیک و ضریب پواسون استاتیک به ترتیب مقدار ۰/۹۸ و ۰/۹۹ می باشد. نمودار مربوط به این مقادیر در شکل (۸) نشان داده شده است. علاوه بر آن، مقادیر خطای *RMSE* و *MAPE* حاصل از نتایج پیش بینی برای داده های آموزشی، آزمایشی و اعتبارسنجی روش *MLP* محاسبه شده که در شکل (۹) و (۱۰) آورده شده است. با توجه به این نتایج می توان گفت روش *MLP* دارای عملکرد مناسبی در پیش بینی پارامترهای الاستیک می باشد.

نورون لایه مخفی انتخاب شد. بنابراین بر اساس نتایج به دست آمده برای تخمین مدول یانگ و ضریب پواسون استاتیکی، تعداد نورون مورد استفاده جهت ساخت مدل ۲۰ عدد است. همچنین این مدل از نظر نحوه اتصالات نورون ها به یکدیگر از نوع پیش خور است. در این شبکه در لایه مخفی از تابع انتقال تانژانت سیگموئید و در لایه خروجی از تابع خطی یا همانی استفاده شده و همچنین جهت آموزش شبکه از الگوریتم پس انتشار خطا لونیبرگ-مارکوارت^{۱۴} استفاده شده است. در شکل (۶) و (۷) به ترتیب شماتیک مراحل مختلف روش *MLP* و نتایج مربوط به عملکرد شبکه در حین آموزش نشان داده شده است. با توجه به شکل (۷)، آموزش شبکه به ترتیب برای مدول یانگ استاتیکی و ضریب پواسون استاتیکی بعد از ۲۹ و ۱۴ دوره تکرار بر اساس خطای مجموع مربعات متوقف شده است.

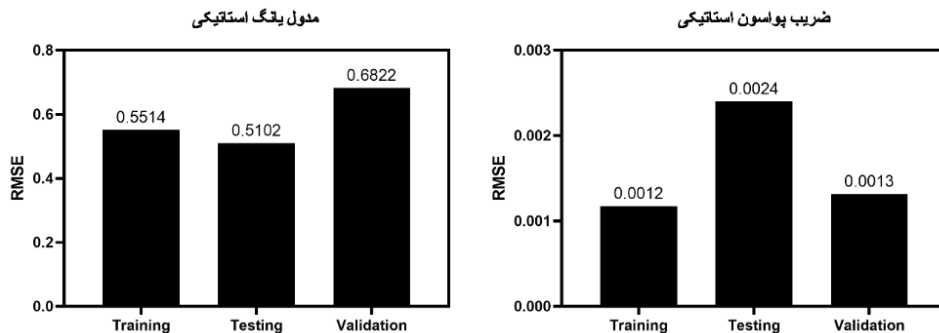


شکل ۶- عملکرد شبکه در حین آموزش روش *MLP* جهت

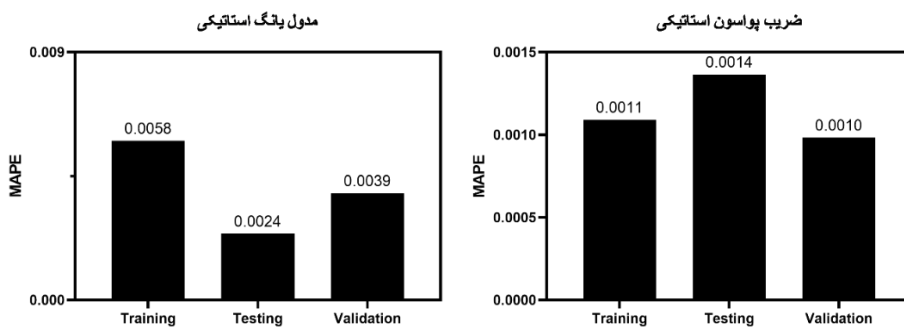
¹⁴ Levenberg-Marquardt



شکل ۸- نمودار R^2 بین مقادیر اندازه‌گیری شده و پیش‌بینی شده مدول یانگ و ضریب پواسون برای مدل MLP



شکل ۹- نتایج خطای RMSE برای داده‌های آموزشی، آزمایشی و اعتبارسنجی حاصل از روش MLP



شکل ۱۰- نتایج خطای MAPE برای داده‌های آموزشی، آزمایشی و اعتبارسنجی حاصل از روش MLP

شده است. معادله‌های تجربی توسعه داده شده برای مدول یانگ و ضریب پواسون استاتیکی بر اساس روش MLP در معادلات (۶) و (۷) آورده شده است.

$$E_{static_n} = \left[\sum_{i=1}^n W_{2i} \left(\frac{2}{1+e^{-2(W_{1i,1}DT+W_{1i,2}NPHI+W_{1i,3}RHOB+b_{1i})}} \right) \right] + (6)$$

$$\vartheta_{static_n} = \left[\sum_{i=1}^n W_{2i} \left(\frac{2}{1+e^{-2(W_{1i,1}DT+W_{1i,2}NPHI+W_{1i,3}RHOB+b_{1i})}} \right) \right] + (7)$$

با استفاده از این روابط و همچنین داده‌های موجود در

۳-۴- توسعه مدل ریاضی با استفاده از شبکه

عصبی چند لایه پرسپترون

پس از به دست آوردن نتایج و اطمینان از دقت مدل شبکه چند لایه پرسپترون در پیش‌بینی پارامترهای الاستیک می‌توان از نتایج آریبی و وزن حاصل از این روش جهت توسعه مدل ریاضی بر اساس ورودی‌های روش MLP استفاده نمود. وزن بین لایه‌های ورودی و پنهان با عنوان w_1 و وزن بین لایه‌های پنهان و خروجی با عنوان w_2 در جدول (۳) و (۴) به ترتیب برای مدول یانگ و ضریب پواسون استاتیکی آورده

در مرحله سوم مقادیر پارامترهای الاستیک محاسبه شده در مرحله قبل که به صورت نرمال می‌باشند می‌بایست به مقادیر اصلی بازگردانده شوند که در این حالت از رابطه (۱۰) استفاده خواهد شد.

$$Output = \frac{(Y_{max} - Y_{min})(Output_n - (-1))}{1 - (-1)} + Y_{min} \quad (10)$$

مقدار Y_{max} و Y_{min} مربوط به مقدارهای حداقل و حداکثر مدول یانگ و ضریب پواسون استاتیکی می‌باشد که این مقادیر در جدول (۱) آورده شده است. بنابراین رابطه ۱۰ برای پارامترهای الاستیک به صورت زیر تبدیل خواهد شد:

$$E_{static} = \frac{(54.18 - 0.24)(E_{static_n} + 1)}{2 + 0.24} \quad (11)$$

$$\rightarrow E_{static} = 26.97E_{static_n} + 27.21$$

$$\nu_{static} = \frac{(0.3 - 0.05)(\nu_{static_n} + 1)}{2} + 0.05 \quad (12)$$

$$\rightarrow \nu_{static} = 0.125\nu_{static_n} + 0.175$$

در نتیجه از روابط (۱۱) و (۱۲) می‌توان جهت پیش-بینی پارامترهای مدول یانگ و ضریب پواسون استاتیکی به کمک وزن‌ها و اریبی‌های روش شبکه چند لایه پرسپترون استفاده نمود.

جدول‌های (۳) و (۴) می‌توان به تخمین پارامترهای الاستیک استاتیکی از داده‌های چاه‌نگاری ورودی به سیستم استفاده نمود. مزیت این روش، محاسبه این پارامترها بدون اجرای نرم‌افزارهای مورد استفاده برای یادگیری ماشین است.

۱-۳-۴- مراحل استفاده از معادله تجربی جدید برای

تعیین پارامترهای الاستیک

جهت استفاده از روابط تجربی در تخمین پارامترهای الاستیک به طور کلی نیاز به انجام سه مرحله می‌باشد. در مرحله اول قبل از استفاده از روابط (۶) و (۷) می‌بایست داده‌های ورودی بین بازه $[-1, 1]$ نرمال‌سازی شوند. نرمال‌سازی به کمک استفاده از روابط (۸) و (۹) انجام خواهد شد:

$$\frac{Y - Y_{min}}{Y_{max} - Y_{min}} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (8)$$

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

که در این روابط $Y_{min} = -1$ و $Y_{max} = 1$ پارامترهای ورودی، مقدار X_{min} مقدار پارامتر ورودی با کمترین مقدار، X_{max} پارامتر ورودی با بیشترین مقدار می‌باشد.

در مرحله دوم به کمک استفاده از روابط (۶) و (۷) و وزن‌ها و اریبی‌های تعریف شده در جداول (۳) و (۴) به-ترتیب مدول یانگ و ضریب پواسون استاتیکی در حالت نرمال‌سازی شده محاسبه خواهد شد. در این قسمت حائز اهمیت است که ورودی‌ها به ترتیب $RHOB$ و $NPHI$ و DT در روابط قرار داده شوند.

جدول ۳- نتایج وزن و اریبی‌های مدول یانگ استاتیکی حاصل از روش MLP

نورون های لایه پنهان (N)	وزن بین لایه ورودی و پنهان (W_1)			وزن بین لایه مخفی و خروجی (W_2)	اریبی لایه پنهان (b_1)	اریبی خروجی (b_2)
	DT	NPHI	RHOB			
۱	-۳,۱۷۴۶۹۶	۱,۷۵۹۱۳۲۶۹۷	-۰,۳۳۹۸۲۶۴۷	۰,۲۰۵۹۲۵۳۱۷	۳,۵۷۷,۰۲۵۷۵۷	-۰,۶۴۸۴۸
۲	-۲,۸۵۴۲۱۸	۰,۶۹۸۷۱۱۹۸۱	۱,۷۹۲۷,۵۲۲۱	-۰,۳۸۰۱۲۳۳۳۶	۳,۷۲۵۶۲۵۵۵۳	
۳	-۳,۳۲۲۳۴۲	۱,۳۶۰,۷۷۳۸۳۹	۰,۸۸۰,۷۵۲۵۳۹	۰,۶۳۶۸۶۸۷۴	۳,۵۰۸۳۶۰۴۲۲	
۴	۳,۱۵۲۱۹۴۳	-۰,۹۷۳۱۵۴۰۹۸	۲,۲۰۶۰۶۷۶۸۱	-۰,۲۶۱۶۲۸۴۴	-۲,۰۸۷۹۲۳۴۸۲	
۵	-۲,۱۱۶۹۹۱	-۲,۲۵۰,۴۴۲۰۳	-۲,۲۶۵۶۰۸۲	۰,۷۰۷۶۳۰۹۲۳	۳,۱۸۲۳۹۷۵۰۸	
۶	۰,۳۵۰۳۵۲۵	۳,۶۳۹۲۶۰۰۹	۰,۱۸۸۹۴۱۸۱	-۰,۳۹۹۸۸۱۳۷	-۱,۸۷۶۴۳۷۵۰۴	
۷	۰,۰۷۷۴۴۲۲	۳,۰۴۲۸۷۴۹۴۵	-۲,۲۶۴۲۸۰۳۶	-۰,۰۱۶۸۷۷۸۳۷	-۱,۴۰۵۶۱۷۴۹۷	
۸	۰,۳۰۸۱۶۱۹	-۱,۳۳۲۸۹۴۰۸۲	-۲,۳۳۸۵۹۶۹۶	-۰,۲۷۵۶۱۴۵۱۱	-۱,۵۷۳۸۱۵۶۴۱	
۹	-۰,۹۷۸۸۳۱	۲,۵۰۶۶۴۳۸۹۶	۳,۱۶۹۵۶۱۵۵۹	۰,۰۰۵۲۹۴۸۱۱	۰,۷۱۸۹۵۸۵۰۷	
۱۰	-۰,۹۹۹۸۶۸	-۱,۷۹۷۸۹۱۱۵۱	-۳,۷۷۷۴۰۹۲۹	-۰,۰۲۹۱۳۱۱۵۷	-۰,۱۵۱۸۵۲۷۰۶	

۱۱	-۳,۳۷۶۵۹۱	-۱,۸۲۲۳۰۱۱۸۶	۰,۶۰۲۵۹۷۸۲۹	۰,۲۰۵۵۸۸۳۹۴	۰,۸۶۶۶۱۰۸۵۸
۱۲	۳,۳۳۸۱۷۶	۱,۸۳۵۴۷۹۳۱۱	-۱,۵۴۶۶۸۵۵	-۰,۰۲۹۵۵۵۱۶۸	۱,۲۰۸۳۸۱۶
۱۳	-۱,۲۹۸۱۸۶	-۱,۴۱۴۳۲۲۱۵	-۰,۱۱۶۷۵۷۶۴	۰,۲۱۳۰۰۱۹۸۶	-۰,۸۱۶۶۸۷۶۲
۱۴	-۰,۹۵۸۷۷۶	۱,۲۲۳۷۹۳۲۷۱	۱,۱۹۷۲۱۱۳۴۴	۰,۸۰۸۲۱۰۷۳۷	-۰,۳۹۵۳۷۱۱۵۹
۱۵	۱,۷۸۸۶۳۳۳	-۱,۸۵۳۵۳۳۸۲۳	-۱,۰۴۸۶۴۱۰۴	۰,۳۲۶۲۶۸۴۷۳	۰,۳۴۰۵۵۴۸۴۳
۱۶	۰,۱۲۶۷۷۴۲	-۱,۶۸۶۵۸۳۶۳۵	۳,۴۴۵۸۰۳۰۲۲	-۰,۰۴۱۸۷۳۰۴۲	۲,۳۵۲۹۶۲۱۹
۱۷	-۰,۵۶۴۸۰۷	-۲,۰۶۱۷۳۴۴۶۱	۰,۳۶۵۸۱۰۰۷۹	۰,۱۳۶۸۸۷۷۸۶	-۲,۲۴۵۷۱۷۶۰۴
۱۸	۲,۵۴۵۰۸۷۸	۰,۸۸۹۸۰۳۹	-۲,۳۰۲۷۰۹۹	-۰,۰۴۲۱۵۴۶۱۷	۲,۹۵۸۶۹۵۲۶۳
۱۹	-۳,۱۲۴۸۹۴	۲,۵۸۸۵۰۷۹۱۴	۰,۶۱۹۷۶۴۴۰۳	-۰,۳۰۳۶۳۸۳۵۹	-۲,۷۰۲۶۸۳۹۷۲
۲۰	-۱,۱۵۳۷۸۶	۲,۶۰۶۲۸۵۷۸۱	-۲,۱۲۲۸۴۵۶۵	۰,۱۵۴۸۴۱۸۴۹	-۳,۹۵۹۰۶۶۳۳۱

جدول ۴- نتایج وزن و اربیی‌های ضریب پواسون استاتیکی حاصل از روش MLP

نورون های لایه پنهان (N)	وزن بین لایه ورودی و پنهان (W_1)			وزن بین لایه مخفی و خروجی (W_2)	اربی لایه پنهان (b_1)	اربی لایه خروجی (b_2)
	DT	NPHI	RHOB			
۱	۰,۰۱۴۸۷۷	-۲,۸۹۳۶۷۶	-۰,۳۲۳۸۷۷۹۱	-۱,۱۱۹۹۴۴۹۶۲	-۴,۸۲۷۹۳۴۹۹۷	۰,۲۵۹۸۳۸۹
۲	-۰,۸۶۶۲۸	-۱,۸۴۶۸۲	۲,۹۱۱۸۲۹۴۹	-۰,۰۸۴۸۵۸۸۲۴	۳,۳۱۳۱۸۴۰۰۳	
۳	۲,۶۲۹۵۷۹	۰,۶۹۹۶۱۹	-۲,۳۱۲۷۵۹۹	-۰,۰۵۶۳۷۱۷۷۵	-۳,۳۳۰۲۰۰۳۸۸	
۴	-۳,۰۴۷۲۳	۰,۹۸۵۹۹۸	۲,۰۶۲۲۰۲۰۵	-۰,۱۲۵۸۰۳۵۴۵	۲,۵۶۲۹۰۴۶۳۳	
۵	۳,۰۳۱۸۰۳	۲,۱۰۸۳۳۸	-۰,۷۷۹۰۹۷۹۴	۰,۰۸۳۵۴۴۵۴۱	-۲,۱۹۳۶۶۴۹۵۸	
۶	۰,۹۵۷۸۴۲	۲,۳۳۷۹۸۷	-۲,۸۸۴۲۲۱۹۸	-۰,۰۱۹۶۴۹۳۶	-۱,۷۲۸۴۶۷۵۵۴	
۷	۰,۳۰۱۸۰۶	-۲,۵۲۳۶۴	۲,۷۴۵۴۶۷۱۱	-۰,۰۱۲۹۳۵۷۲	-۱,۳۹۸۴۷۰۷۲۹	
۸	-۲,۰۷۳۹۳	۰,۲۲۱۵۷۵	۰,۸۳۱۵۵۵۴۸	۰,۵۰۷۱۰۲۱۱۸	۰,۸۴۹۸۷۶۸۴۸	
۹	-۲,۵۰۵۴۳	۲,۲۱۱۴۸۷	۰,۱۴۶۹۴۲۵۳	۰,۰۲۶۴۸۸۶۶	۱,۱۵۵۴۲۵۵۴۹	
۱۰	۲,۵۸۹۹۷۶	-۰,۳۳۵۳۲	۲,۸۰۶۷۷۴۵۴۶	-۰,۰۱۱۶۷۶۹۲۹	۰,۱۴۴۷۴۴۶۰۱	
۱۱	-۱,۱۱۰۶۴	-۱,۴۱۱۳۵۷	-۱,۶۲۹۳۶۵۱۷	۰,۲۰۷۰۹۰۴۴۴	۰,۵۹۲۷۸۲۷۸۵	
۱۲	۱,۶۷۹۲۷۴	-۲,۴۷۹۶۷	-۲,۳۹۵۷۰۷۱۲	-۰,۰۶۰۸۵۰۹۷۴	۰,۱۹۷۷۱۲۸۰۹	
۱۳	-۱,۱۳۷۱۹۴	-۲,۵۹۸۶۱۲	-۲,۲۲۹۴۵۷۱	۰,۰۵۶۳۴۸۱۱۹	-۱,۳۸۵۳۰۸۳۵۲	
۱۴	-۱,۹۷۳۹۷	۲,۵۵۲۹۵۸	-۲,۱۰۶۷۹۷۷۶۳	۰,۰۵۰۷۴۶۶۲	-۱,۴۵۲۶۶۰۱۸۱	
۱۵	۳,۲۸۱۵۵۳	-۰,۲۹۵۶۷۶	-۱,۱۳۹۷۰۹۵۴۲	-۰,۰۳۸۲۰۳۰۹۴	۱,۶۱۸۸۰۰۱۵۱	
۱۶	-۱,۶۰۷۷۰۱	۲,۱۵۰۸۵۵	۲,۲۶۱۵۰۰۹۸	۰,۷۸۰۵۵۷۰۴۸	-۲,۸۰۰۸۶۳۳۰۹	
۱۷	۲,۴۱۴۷۱۱	-۲,۰۱۰۰۸۵	-۰,۶۴۲۸۳۱۳۹	۰,۵۴۷۲۵۳۵۱۱	۲,۴۲۱۹۰۴۶۱۳	
۱۸	-۳,۱۵۸۹۴	۲,۱۹۰۰۴۴	۰,۶۶۸۵۴۵۲۵۳	۰,۷۲۷۱۶۴۷۶۵	-۳,۴۳۴۷۹۸۹۷	
۱۹	-۱,۵۶۹۴۷	-۳,۱۲۷۷۳۵	-۰,۶۴۷۱۳۲۱۷	۰,۰۰۹۵۸۷۱۸	-۳,۱۴۷۶۲۷۴۴۹	
۲۰	۲,۶۳۱۹۹۴	۲,۰۶۸۳۹۶	۱,۷۴۸۴۸۸۱۸	-۰,۰۳۹۸۸۵۵۲۳	۳,۷۵۳۷۹۲۱۸۴	

تعیین (R^2) و مقدار خطاهای $RMSE$ و $MAPE$ با یکدیگر مورد مقایسه قرار گرفت تا مدل پیش‌بینی با دقت بالا انتخاب شود. همان‌طور که در جدول (۵) نشان داده شده

۴-۴- مقایسه عملکرد مدل‌ها

روش‌های رگرسیون چند متغیره خطی و روش شبکه چند لایه پرسپترون به کمک شاخص‌های آماری از جمله ضریب

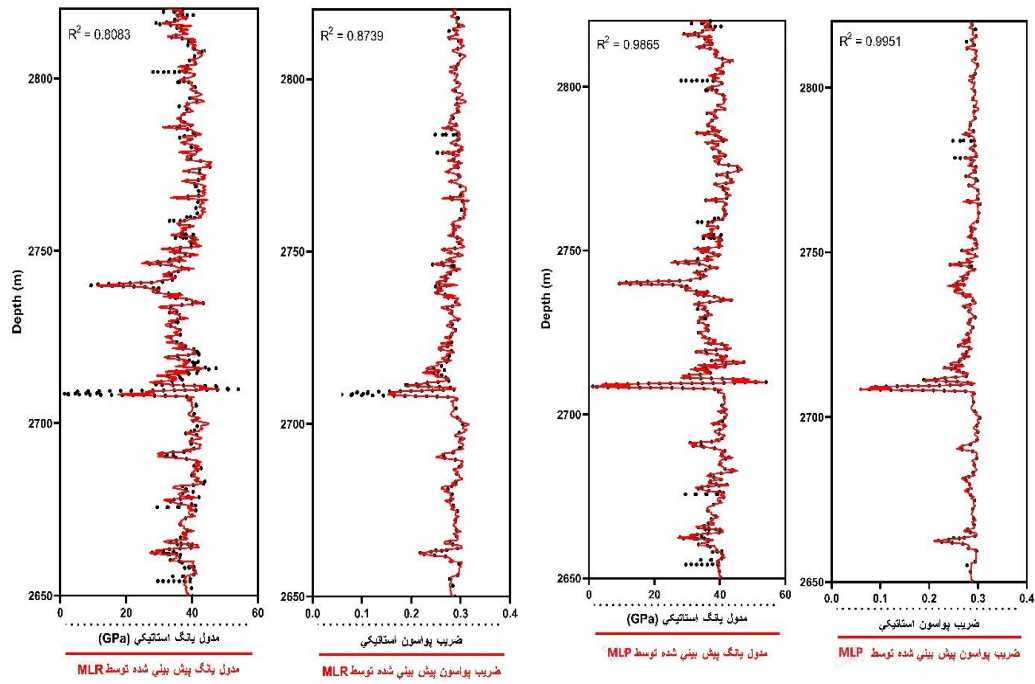
جدول ۵- مقایسه شاخص‌های عملکرد مدل‌های پیش‌بینی

	پارامترها	مدول یانگ	ضریب پواسون
R^2	MLR	۰/۸۰۸	۰/۸۷۴
	MLP	۰/۹۸۶	۰/۹۹۵
RMSE	MLR	۲/۰۹۹	۰/۰۷۶۵
	MLP	۰/۵۵۸	۰/۰۰۱۵
MAPE	MLR	۰/۰۹۱۴	۰/۰۱۹۶
	MLP	۰/۰۰۴۹	۰/۰۰۱۱

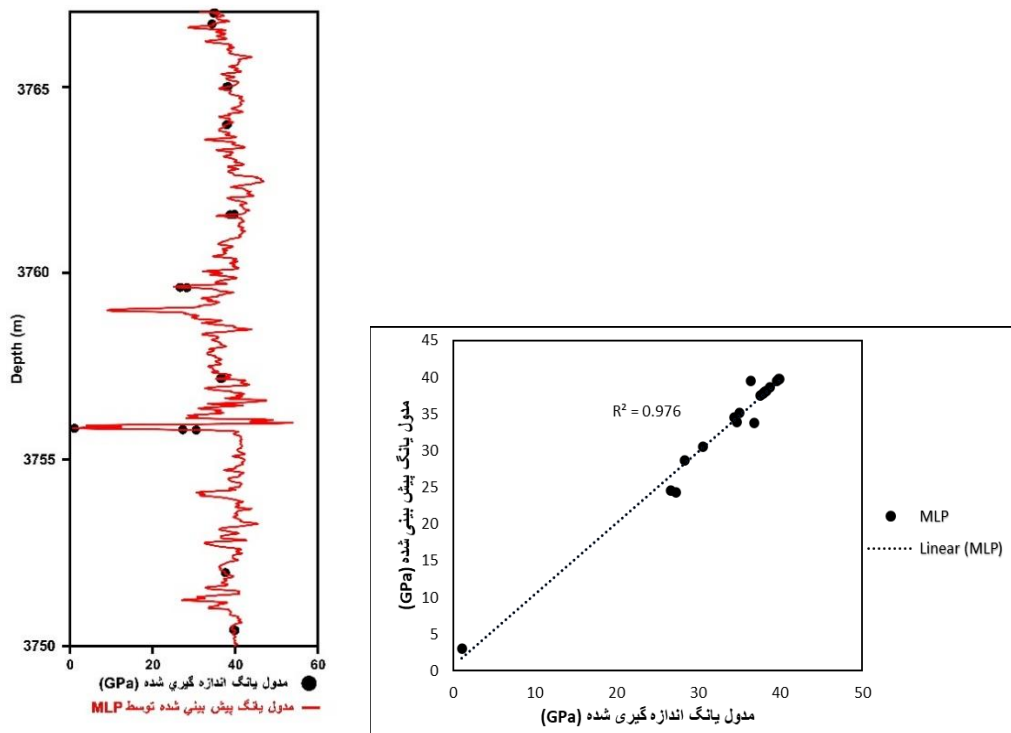
۴-۵- اعتبارسنجی روابط

با توجه به نتایجی که در بخش ۴-۴ به دست آمد، روش شبکه عصبی چند لایه پرسپترون در پیش‌بینی پارامترهای الاستیک دارای دقت مناسبی می‌باشد؛ در نتیجه در این بخش به منظور اعتبارسنجی روابط تجربی به دست آمده از روش شبکه عصبی چند لایه پرسپترون از داده‌های چاه A مربوط به یکی از میادین ایران استفاده خواهد شد. داده‌های چاه نگاری ورودی شامل زمان انتقال موج فشاری، چگالی و نمودار نوترون و داده‌های خروجی شامل ۱۹ نقطه اصلی از داده‌های آزمایشگاهی ضریب پواسون و مدول یانگ اندازه‌گیری شده توسط آزمایش سه محوره می‌باشد. در شکل‌های (۱۲) و (۱۳) مقایسه معادله MLP پیش‌بینی شده و ضریب پواسون استاتیکی و مدول یانگ استاتیکی آزمایشگاهی برای چاه A نشان داده شده است. با توجه به این شکل‌ها معادله MLP به ترتیب مدول یانگ استاتیکی و ضریب پواسون استاتیکی را برای فاصله عمقی بین ۳۷۵۰ تا ۳۷۷۰ را با ضریب تعیین ۰/۹۷ و ۰/۹۶ پیش‌بینی می‌کند.

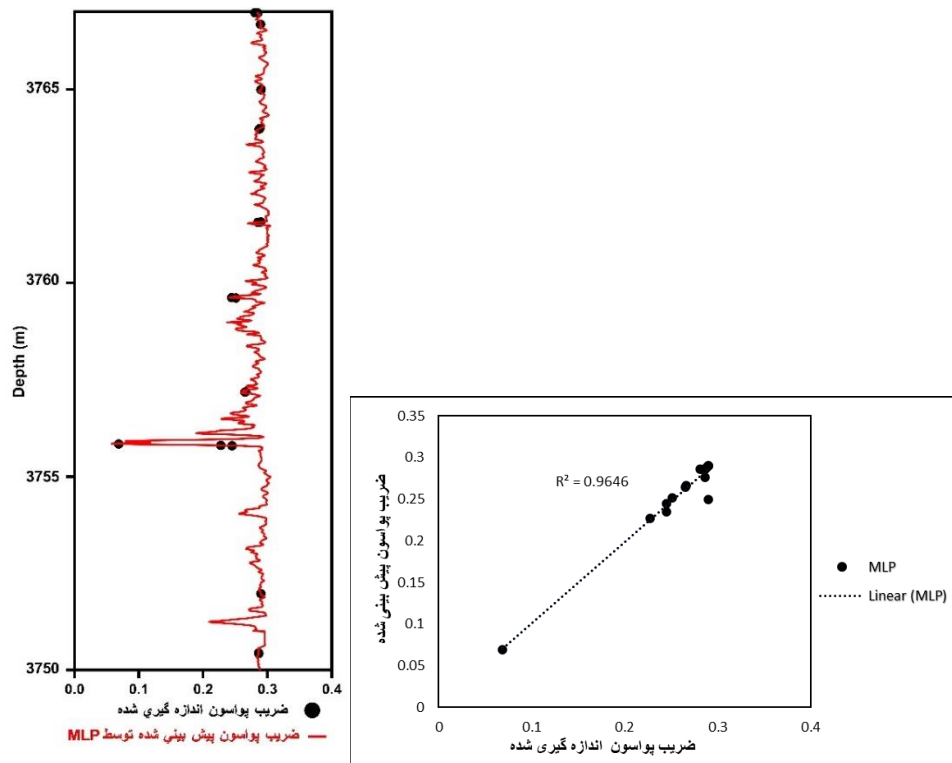
است مقدار R^2 بدست آمده برای روش رگرسیون چند متغیره خطی به ترتیب برای مدول یانگ و ضریب پواسون استاتیکی مقادیر ۰/۸۷۳ و ۰/۸۰۸ بدست آمده است. بعلاوه این مقدار برای روش شبکه چند لایه پرسپترون مقادیر ۰/۹۸۶ و ۰/۹۹۵ می‌باشد. از طرفی شاخص $RMSE$ حاصل از روش شبکه عصبی با مقادیر ۰/۵۵۸ برای مدول یانگ استاتیکی و ۰/۰۰۱۵ برای ضریب پواسون استاتیکی، کوچک تر از مقادیر به دست آمده این پارامتر از روش رگرسیون چند متغیره با مقادیر ۲/۰۹۹ برای مدول یانگ و ۰/۰۷۶۵ برای ضریب پواسون استاتیکی می‌باشد. همچنین شاخص $MAPE$ حاصل از روش شبکه عصبی با مقادیر ۰/۰۰۴۹ برای مدول یانگ استاتیکی و ۰/۰۰۱۱ برای ضریب پواسون استاتیکی، کوچک‌تر از مقادیر به دست آمده این پارامتر از روش رگرسیون چند متغیره با مقادیر ۰/۰۹۱۴ برای مدول یانگ و ۰/۰۱۹۶ برای ضریب پواسون استاتیکی می‌باشد. نتایج به دست آمده حاکی از آن است که شبکه عصبی چند لایه پرسپترون (MLP) در پیش‌بینی پارامترهای الاستیک دارای عملکرد مناسب‌تر و دقت بالاتری نسبت به روش رگرسیون چند متغیره خطی (MLR) می‌باشد. همچنین جهت مقایسه بهتر نتایج، در شکل (۱۱) خروجی‌های به دست آمده بین داده‌های اندازه‌گیری و پیش‌بینی شده در عمق بین ۲۶۵۰ تا ۲۸۲۰ از میدان مورد مطالعه بر اساس روش‌های MLR و MLP نشان داده شده است.



شکل ۱۱- مقایسه بین مقدار مدول یانگ و ضریب پواسون اندازه‌گیری شده و پیش‌بینی شده بر اساس روش‌های MLR و MLP بر اساس عمق



شکل ۱۲- مدول یانگ استاتیکی پیش‌بینی شده با استفاده از معادله پیشنهادی MLP در چاه A



شکل ۱۳- ضریب پواسون استاتیکی پیش‌بینی شده با استفاده از معادله پیشنهادی MLP در چاه A

۰/۰۰۴۹ برای مدول یانگ استاتیکی و ۰/۰۰۱۱ برای ضریب پواسون استاتیکی، عملکرد مناسب‌تری در پیش‌بینی پارامترهای الاستیک دارد. بعلاوه در این پژوهش روابط تجربی بر مبنای اطلاعات مربوط به وزن ها و اریبی‌های روش شبکه عصبی برای پیش‌بینی پارامترهای الاستیک توسعه داده شده و در نهایت این روابط بر مبنای داده‌های چاه A مربوط به یکی از میداین ایران اعتبارسنجی شده و این نتیجه به دست آمد که با توجه به مقدار ضریب تعیین (R^2) ۰/۹۷ و ۰/۹۶ به ترتیب برای مدول یانگ و ضریب پواسون استاتیکی روابط به دست آمده از این پژوهش دارای اعتبار مناسبی می‌باشند. به کمک این روابط تجربی می‌توان در غیاب داده‌های اصلی و تنها با در دست داشتن داده‌های چاه‌نگاری، پارامترهای الاستیک مخزن کربناته را پیش‌بینی نمود.

۵- نتیجه گیری

هدف این تحقیق پیش‌بینی پارامترهای الاستیک استاتیکی به کمک استفاده از روش‌های رگرسیون چند متغیره خطی و شبکه عصبی چند لایه پرسپترون بر روی داده‌های یکی از میداین گازی واقع در جنوب ایران می‌باشد. به کمک استفاده از داده‌های چاه‌نگاری DT , $NPHI$, $RHOB$ به عنوان ورودی، دو مدل کلی برای پیش‌بینی مدول یانگ استاتیکی و ضریب پواسون استاتیکی ساخته شد. با توجه به نتایج به دست آمده با این ورودی‌ها و مقایسه بین مقدار R^2 و خطاهای $RMSE$ و $MAPE$ ، مدل‌های ساخته شده در هر مرحله از نظر کارایی ارزیابی شد. این نتایج نشان داد پیش‌بینی‌های انجام شده به کمک روش‌های MLR و MLP می‌تواند نتایج قابل قبولی در پیش‌بینی پارامترهای الاستیک داشته باشد. اما روش شبکه پرسپترون با توجه به مقادیر ضریب تعیین ۰/۹۸۶ برای مدول یانگ استاتیکی و ۰/۹۹۵ برای ضریب پواسون استاتیکی و همچنین مقدار $RMSE$ ، با مقادیر ۰/۵۵۸ برای مدول یانگ استاتیکی و ۰/۰۰۱۵ برای ضریب پواسون استاتیکی و شاخص $MAPE$ ، با مقادیر

۶- منابع

- [1] Salih, A. M., Alshahrani, A. A., & Alharthi, S. (2023). Rock physics and machine learning comparison: Elastic properties prediction and scale dependency. *Frontiers in Earth Science*, 11, Article 1095252. <https://doi.org/10.3389/feart.2023.1095252>
- [2] Kavosian, E., Sanei, M., Yarahmadi, A. (2023). Geomechanical modelling and numerical stability analysis of an Oil field wellbore. *4th National Petroleum Geomechanics Conference*, Iran.
- [3] Sanei, M., Ramezanzadeh, A., & Asgari, A. (2023). Building 1D and 3D static reservoir geomechanical properties models in the oil field. *Journal of Petroleum Exploration and Production Technology*, 13(1), 329-351. DOI: 10.1007/s13202-022-01553-7.
- [4] Aghakhani Emamqeyssi, M. R., Fatehi Marji, M., Hashemizadeh, A., Sanei, M., & Abdollahipour, A. (2022). 3D Numerical modeling of the effect of in-situ stress ratio on mud weight window in the drilling of the Zagros sedimentary basin. *Journal of Petroleum Geomechanics*, 5(3), 26-42. DOI: 10.22107/jpg.2022.349740.1172.
- [5] Gokceoglu, C., & Zorlu, K. (2004). A fuzzy model to predict the uniaxial compressive strength and the modulus of elasticity of a problematic rock. *Engineering Applications of Artificial Intelligence*, 17(1), 61-72. DOI: 10.1016/j.engappai.2003.11.006
- [6] Yilmaz, I., & Yuksek, G. (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. DOI: 10.1016/j.ijrmms.2008.09.002
- [7] Dehghan, S., Sattari, G. H., Chelgani, S. C., & Aliabadi, M. A. (2010). Prediction of uniaxial compressive strength and modulus of elasticity for Travertine samples using regression and artificial neural networks. *Mining Science and Technology (China)*, 20(1), 41-46. DOI:10.1016/S1674-5264(09)60158-7
- [8] Beiki, M., Majdi, A., & Givshad, A. D. (2013). Application of genetic programming to predict the uniaxial compressive strength and elastic modulus of carbonate rocks. *International Journal of Rock Mechanics and Mining Sciences*, 63, 159-169. DOI: 10.1016/j.ijrmms.2013.08.004
- [9] Ahmadi-Nedushan, B. (2012). Prediction of elastic modulus of normal and high strength concrete using ANFIS and optimal nonlinear regression models. *Construction and Building Materials*, 36, 665-673. DOI: 10.1016/j.conbuildmat.2012.06.002
- [10] Aboutaleb, S., Behnia, M., Bagherpour, R., & Bluekian, B. (2018). Using non-destructive tests for estimating uniaxial compressive strength and static Young's modulus of carbonate rocks via some modeling techniques. *Bulletin of Engineering Geology and the Environment*, 77, 1717-1728. DOI: 10.1007/s10064-017-1043-2
- [11] Elkhatny, S., Tariq, Z., Mahmoud, M., Abdulraheem, A., & Mohamed, I. (2019). An integrated approach for estimating static Young's modulus using artificial intelligence tools. *Neural Computing and Applications*, 31, 4123-4135. DOI: 10.1007/s00521-018-3344-1
- [12] Tariq, Z., Mahmoud, M., & Abdulraheem, A. (2019). Core log integration: a hybrid intelligent data-driven solution to improve elastic parameter prediction. *Neural Computing and Applications*, 31, 8561-8581. DOI: 10.1007/s00521-019-04101-3
- [13] Mahmoud, A. A., Elkhatny, S., Ali, A., & Moussa, T. (2019). Estimation of static young's modulus for sandstone formation using artificial neural networks. *Energies*, 12(11), 2125. DOI: 10.3390/en12112125
- [14] Ahmed, A., Elkhatny, S., & Alsaihati, A. (2021). Applications of artificial intelligence for static Poisson's ratio prediction while drilling. *Computational Intelligence and Neuroscience*, 2021. DOI: 10.1155/2021/9956128.
- [15] Mahmoud, A. A., Elkhatny, S., Ali, A., & Moussa, T. (2022, March). A Self-Adaptive Artificial Neural Network Technique to Estimate Static Young's Modulus Based on Well Logs. In *SPE EOR Conference at Oil and Gas West Asia* (p. D011S007R003). SPE. DOI: 10.2118/200139-MS.

- [16] Aghakhani Emamqeyysi, M. R., Fatehi Marji, M., Hashemizadeh, A., Abdollahipour, A., & Sanei, M. (2023). Prediction of elastic parameters in gas reservoirs using ensemble approach. *Environmental Earth Sciences*, 82(11), 269. DOI: 10.1007/s12665-023-10958-4
- [17] Sanei, M., Ramezanzadeh, A., & Delavar, M. R. (2023). Applied machine learning-based models for predicting the geomechanical parameters using logging data. *Journal of Petroleum Exploration and Production Technology*, 1-23. DOI: 10.1007/s13202-023-01687-2.
- [18] Delavar, M. R., Ramezanzadeh, A., Gholami, R., & Sanei, M. (2023). Optimization of drilling parameters using combined multi-objective method and presenting a practical factor. In *Computers & Geosciences* (Vol. 175, p. 105359). Elsevier BV. <https://doi.org/10.1016/j.cageo.2023.105359>.
- [19] Sanei, M., Ramezanzadeh, A. & Asgari, A. Applied machine learning-based models for determining the magnitude of pore pressure and minimum horizontal stress. *Arab J Geosci* 17, 210 (2024). <https://doi.org/10.1007/s12517-024-11997-2>.
- [20] Sanei, M., Ramezanzadeh, A. & Delavar, M.R. Applied machine learning-based models for predicting the geomechanical parameters using logging data. *J Petrol Explor Prod Technol* 13, 2363–2385 (2023). <https://doi.org/10.1007/s13202-023-01687-2>.
- [21] Rahimpour Bonab, Hossein, Salmani, Aisha, Ranjbaran, Mohsen, and Al-Ali, Seyed Mohsen. (2018). Effects of sedimentary environment and diagenetic processes on reservoir quality of Asmari Formation in Qaleh-e-Nar field, Dezful depression. *Applied Sedimentology*, 6(11), 15-34. SID. <https://sid.ir/paper/260582/fa>.
- [22] Brocher, T. M. (2005). Empirical relations between elastic wave speeds and density in the Earth's crust. *Bulletin of the seismological Society of America*, 95(6), 2081-2092. DOI: 10.1785/0120050077.
- [23] Castagna, J. P., Batzle, M. L., Kan, T. K., & Backus, M. M. (1993). Rock physics—The link between rock properties and AVO response. *Offset-dependent reflectivity—Theory and practice of AVO analysis: SEG*, 8, 135-171.
- [24] Khandelwal, M., & Monjezi, M. (2013). Prediction of backbreak in open-pit blasting operations using the machine learning method. *Rock mechanics and rock engineering*, 46, 389-396. DOI: 10.1007/s00603-012-0269-3.
- [25] Jahed Armaghani, D., Hajihassani, M., Sohaei, H., Tonnizam Mohamad, E., Marto, A., Motaghedi, H., & Moghaddam, M. R. (2015). Neuro-fuzzy technique to predict air-overpressure induced by blasting. *Arabian Journal of Geosciences*, 8, 10937-10950. DOI: 10.1007/s12517-015-1984-3.
- [26] Kalkan, E., Akbulut, S., Tortum, A., & Celik, S. (2009). Prediction of the unconfined compressive strength of compacted granular soils by using inference systems. *Environmental geology*, 58, 1429-1440. DOI: 10.1007/s00254-008-1645-x.
- [27] Adhikary, B. B., & Mutsuyoshi, H. (2006). Prediction of shear strength of steel fiber RC beams using neural networks. *Construction and Building Materials*, 20(9), 801-811. DOI: 10.1016/j.conbuildmat.2005.01.047.
- [28] Mukherjee, A., & Biswas, S. N. (1997). Artificial neural networks in prediction of mechanical behavior of concrete at high temperature. *Nuclear engineering and design*, 178(1), 1-11. DOI: 10.1016/S0029-5493(97)00152-0



Prediction of Elastic Parameters of Carbonate Reservoir from Well Logging Data Using Machine Learning and Multivariate Regression Methods

Mohammad Reza Aghakhani Emamqeyssi¹; Manouchehr Sanei^{1*}; Mohammad Fatehi Marji¹

1-Mine Exploitation Engineering Department, Faculty of Mining and Metallurgical Engineering, Yazd University, Yazd, Iran.

Received: 14. April. 2023; Accepted: 22. August .2023
(Corresponding author: m.sanei@yazd.ac.ir)

Keywords

Petroleum Geomechanics
Young's modulus
Poisson's ratio
Machine Learning
Multiple linear regression
Well logs

Final English Extended Abstract

Geomechanical parameters, such as Young's modulus and Poisson's ratio, play a crucial role in drilling and production operations of oil and gas wells. Determining these parameters can greatly assist in understanding the well's condition and issues. Since laboratory testing to determine these parameters is very expensive and time-consuming, this study attempts to predict linear geomechanical parameters based on multivariate regression and machine learning methods using well logging data (including sonic transit time, density, and porosity) from a gas well in southern Iran. After constructing the

models, the results obtained from each method were compared, and the results showed that the machine learning method had a better performance in predicting elastic parameters with lower mean absolute percentage error, root mean square error, and higher coefficient of determination. Additionally, empirical relationships based on information related to weights and biases of the multilayer perceptron (MLP) network method were developed to predict elastic parameters. These relationships were validated using well A data from one of Iran's fields, and the results showed that the obtained equations had a suitable validity with coefficient of determination values of 0.97 and 0.96 for Young's modulus and Poisson's ratio, respectively. Therefore, these new equations can be used for new wells based on well logging data without the need for any machine learning software.

Introduction

Multiple regression analyses have been used by some researchers to predict elastic parameters. However, some of these results have indicated that these methods are not sufficient for providing reliable amounts to calculate Poisson's ratio and Young's modulus, and that these equations are needed only for specific types of rocks. Thus, in recent studies, artificial intelligence methods have been considered in order to achieve high accuracy and minimize error. The purpose of this study is to develop empirical correlations based on well log data in order to determine elastic parameters. Finally, the elastic parameter prediction was conducted using multiple regression and artificial neural networks, and the best method was determined by comparing the RMSE, MAPE, and R^2 .

Methodology and Approaches

The study examined the prediction of elastic parameters using linear multiple regression and machine learning. The research used well logs (DT, NPHI, and RHOB) as inputs, and laboratory measurements, including the static Poisson's ratio and Young's modulus as outputs. The linear multiple regression models were developed using SPSS 26 software. Statistical results of MLR were obtained to predict elastic parameters. Finally, the results obtained for elastic parameters were evaluated using the R^2 , t-test, and MAPE and RMSE errors. ANN model was constructed in this study using one hidden layer. To create the MLP models for YM and PR, 20 neurons were used. The input and hidden layers are transferred using linear-type activation functions, while the hidden and output layers are transferred using



TAN-sigmoidal-type activation functions. The Levenberg-Marquardt backpropagation algorithm is used as a training method. Moreover, to predict elastic parameters, weights and biases of the optimized MLP model were used to develop empirical correlations. In the end, the best method was selected for predicting elastic parameters based on comparisons between MLR and MLP. This study used MLR and ANN methods to predict elastic parameters. As shown in Table 1, the ANN method has higher accuracy and better performance in predicting elastic parameters when comparing error values and R². Also, in order to validate the empirical correlation obtained by the MLP method for elastic parameters, the data of well-A related to one of Iran's fields was used. The input well log data includes DT, NPHI and RHOB and the output data includes 19 main points of PR and YM laboratory data measured by the triaxial test.

Results and Conclusions

The results showed that the MLP method with coefficient determinations of 0.986 for Young's modulus (YM) and 0.995 for Poisson's ratio (PR), as well as RMSE, with values of 0.558 for YM and 0.0015 for PR, and MAPE index, with values of 0.0049 for YM and 0.0011 for PR, performed better than MLR in predicting elastic parameters. Additionally, empirical correlations have been developed based on the weights and biases of the MLP method to determine the elastic parameters. These equations were validated based on data from a well-A in one of Iran's fields. According to the results, Young's modulus and Poisson's ratio have good validity, with R² values of 0.97 and 0.96, respectively. So, in the absence of laboratory core samples, the developed empirical correlation can be used by geomechanical engineers to determine elastic parameters.
