



مقاله پژوهشی

ارائه روش نو ترکیب هوش مصنوعی جهت پیش بینی نرخ نفوذ با استفاده از نگاره های حفاری

میثم رجبی^{۱*}؛ حمزه قربانی^۲

۱- استادیار گروه مهندسی معدن، دانشگاه صنعتی بیرجند، بیرجند، ایران

۲- دانش آموخته کارشناسی ارشد مهندسی نفت، باشگاه پژوهشگران جوان و نخبگان، دانشگاه آزاد اسلامی، اهواز، ایران

دریافت مقاله: ۱۴۰۲/۱۱/۱۸ پذیرش مقاله: ۱۴۰۳/۰۱/۳۱

شناسه دیجیتال (DOI): 10.22107/JPG.2024.442333.1228

واژگان کلیدی	چکیده
پیش بینی نرخ نفوذ، الگوریتم نو ترکیب هوش مصنوعی، نگاره های حفاری، نقشه های حرارتی	انجام فعالیت های حفاری، جهت دسترسی به منابع ارزشمند هیدروکربوری، ناگزیر می باشد. چنان که یکی از پارامترهای مهم و پر کاربرد در مبحث حفاری چاه های نفت و گاز، نرخ نفوذ مته حفاری است. در این مطالعه جهت تخمین نرخ نفوذ، از اطلاعات مربوط به سه چاه از یک میدان نفتی واقع در جنوب غرب ایران و ترکیبی از الگوریتم های نزدیک ترین همسایه K ، الگوریتم زنبور عسل، الگوریتم کرم شب تاب و پرسپترون چند لایه استفاده شده است. از قابلیت های شاخص این الگوریتم نو ترکیب، کاهش نوبز داده ها و افزایش دقت پیش بینی پارامتر مورد نظر می باشد. نتایج نشان داد که خطای جذر میانگین مربعات برای داده های مربوط به آموزش، آزمایش و اعتبارسنجی به ترتیب برابر با ۱/۰۵، ۱/۵۲ و ۱/۴۸ بوده که خود نشان دهنده دقت عملکرد بالای این الگوریتم نو ترکیب می باشد. همچنین با بررسی ضریب پیروسون مشخص گردید که پارامتر اندازه نازل مته حفاری با مقدار نرخ نفوذ رابطه مستقیم و مقادیر چگالی، نقطه تسلیم، ویسکوزیته پلاستیک، انرژی ویژه مکانیکی و جریان ورودی گل با مقدار نرخ نفوذ رابطه عکس داشته اند. لذا این تحقیق، علاوه بر ارائه یک مدل نو ترکیب، به بررسی پارامترهای تأثیر گذار بر روی نرخ نفوذ حفاری نیز پرداخته است. لذا محققان می توانند از الگوریتم معرفی شده در این مقاله برای پیش بینی سایر پارامترهای کلیدی مخزن، تولید، حفاری و ژئوفیزیک استفاده نمایند.

۱. پیش گفتار

تنها راه دسترسی به منابع هیدروکربنی، حفر چاه در لایه های نفوذ پذیر هیدروکربنی است و هزینه های قابل توجهی برای این فرآیند صرف می شود [۱]. به منظور افزایش بازدهی عملیات و کاهش هزینه ها، ارزیابی کارایی حفاری اهمیت بسزایی دارد [۲]. از این رو، می بایست در ابتدا، داده های میدانی با دقت جمع آوری گردد و سپس با استفاده از ابزارهای مناسب تجزیه و تحلیل شود [۳].

بهترین درک از عملیات حفاری^۱ زمانی به دست می آید که

نتایج حاصل از مدل های پیش بین با مشاهدات میدانی مقایسه و تصحیح شود [۴]. چنان که با تغییر و بهبود پارامترهای مؤثر در حفاری، می توان به نتایج بهتر و کارآمدتری دست یافت [۵]. بهینه سازی عملیات حفاری شامل در نظر گرفتن چندین متغیر از جمله هزینه، ایمنی و تکمیل چاه^۲ است، اما در کنار این عوامل، نرخ نفوذ^۳ یکی از متغیرهای اساسی در این عملیات محسوب می شود [۶]. زیرا پیش بینی نرخ نفوذ عامل مهمی در موفقیت پروژه های حفاری است و تحت تأثیر عوامل مختلفی مانند وزن روی مته^۴، نوع مته^۵، سرعت گردش گل^۶،

⁴ Weight on bit

⁵ Bit type

⁶ Mud circulation rate

¹ Drilling operation

² Well completion

³ Rate of penetration

بورگوین و یانگ^{۱۰} در سال ۱۹۷۴، یک مدل حفاری جامع معرفی کردند که شامل هشت تابع و هشت ضریب برای تخمین نرخ نفوذ از طریق روش رگرسیون چندگانه بود [۱۵]. واکر و همکاران^{۱۱} (۱۹۸۶)، نشان دادند که کاهش نرخ نفوذ در حفاری عمیق، به خواص و مقاومت سنگ وابسته است. با توجه به ماهیت پیچیده تعاملات بین متغیرهای مؤثر بر نرخ نفوذ، لازم است این کار با دقت بیشتری اجرا شود. این موضوع، توجه بسیاری از محققان را به استفاده از روش‌های مختلف هوش محاسباتی به‌عنوان ابزاری قدرتمند برای تخمین نرخ نفوذ جلب کرده است [۱۶]. چنان‌که بسیاری از محققان توانسته‌اند از هوش مصنوعی برای پیش‌بینی پارامترهای کلیدی در زمینه‌های مختلف از جمله نفت، گاز، محیط زیست، مهندسی مخازن، بهره‌برداری، حفاری و غیره استفاده کنند [۱۷].

الکاتاتی و همکاران^{۱۲} (۲۰۱۶)، مدلی را برای پیش‌بینی خصوصیات سیال حفاری بر اساس مشاهدات کیف مارش توسعه دادند. این مدل، پارامترهای رئولوژیکی و قرائت ویسکومتر را با دقت ۱ تا ۰.۵٪ و با استفاده از شبکه عصبی مصنوعی پیش‌بینی می‌کرد. آن‌ها نشان دادند که این ابزار برای طراحی هیدرولیک و پیش‌بینی عملکرد سیال حفاری می‌تواند قابل اعتماد باشد [۱۸].

الکاتاتی و همکاران (۲۰۱۷)، یک مدل دقیق برای پیش‌بینی پارامترهای نرخ نفوذ با استفاده از ویژگی‌های حفاری به‌خصوص گل، بر اساس ۳۳۳۳ داده میدانی با روش شبکه عصبی مصنوعی^{۱۳} ایجاد کردند که از همبستگی بهتری نسبت به مطالعات قبلی برخوردار بود [۱۹].

الکاتاتی و همکاران (۲۰۱۸)، از یک مدل شبکه عصبی مصنوعی بر اساس سه لاگ، برای تخمین نفوذپذیری مخزن ناهمگن استفاده کردند و با ضریب همبستگی ۰/۹۵، به دقت زیادی برای پیش‌بینی دست‌یافتند. آن‌ها معادله‌ای نیز برای پیش‌بینی دقیق نفوذپذیری ایجاد و متغیر جدیدی به نام شاخص تحرک را برای افزایش دقت پیش‌بینی، معرفی نمودند [۲۰].

فشار جریان سیال^۱، وزن گل^۲، انحراف چاه^۳، سرعت چرخش^۴ و هیدرولیک^۵ قرار می‌گیرد [۷]. این عوامل به شرایط حفاری، عوامل زمین‌شناسی، عمق حفاری و نوع مته و ... وابسته است [۸]. هزینه حفاری چال با مته از دیگر جنبه‌های مهم در ارزیابی عملکرد حفاری به شمار می‌رود [۹]. اگر پارامترهای حفاری به‌درستی انتخاب شوند، هزینه حفاری کاهش قابل‌توجهی خواهد داشت [۱۰]. شایان‌ذکر این‌که، انتخاب گران‌ترین یا حتی ارزان‌ترین روش حفاری همیشه بهترین گزینه نیست. بلکه، انتخاب روش حفاری متناسب با نوع لایه‌ها می‌تواند گزینه بهتری باشد [۱۱].

گراهام و موناها^۶ (۱۹۵۹)، از پیشگامان پژوهش در حوزه بهینه‌سازی عملیات حفاری به شمار می‌آیند. آن‌ها یک رابطه تجربی برای تعیین عمر مته^۷، نرخ نفوذ، وزن روی مته و سرعت چرخش ارائه کردند [۱۲].

مائورر^۸ (۱۹۶۲)، یک معادله ریاضی برای محاسبه نرخ نفوذ بر اساس وزن روی مته و سرعت چرخش آن معرفی نمود. یکی از مفروضات مهم در این معادله، تمیز کردن موثر چاه از خرده‌های حفاری است (معادله ۱) [۱۳].

$$ROP = \frac{k}{s^2} \times \left(\frac{WOB}{db}\right)^2 \times RPM \quad (1)$$

جایی که ROP نشان‌دهنده نرخ نفوذ، RPM بیانگر سرعت چرخش مته، WOB ، وزن روی مته، db ، قطر مته، S مقاومت در برابر حفاری و k ، پارامتر قابلیت حفاری می‌باشد.

گاله و وودز^۹ (۱۹۶۳)، نیز از جمله اولین محققانی بودند که باهدف کاهش هزینه‌های حفاری به بررسی اثر وزن روی مته و سرعت چرخش آن بر روی نرخ نفوذ پرداختند. آن‌ها همچنین اثر نرخ سایش دندان‌های مته را در رابطه پیشنهادی مدنظر قرار دادند (معادله ۲) [۱۴].

$$ROP = k \times \frac{WOB^s}{a^b} \times RPM \quad (2)$$

جایی که پارامترهای a و b بر اساس شکل و نوع مته جایگذاری شده و بقیه پارامترهای معادله فوق همان پارامترهای معادله ۱، می‌باشد.

⁸ Maurer

⁹ Galle and Woods

¹⁰ Bourgoyne and Young

¹¹ Walker et al.

¹² Elkatatny et al.

¹³ Artificial neural network

¹ Fluid flow pressure

² Mud weight

³ Well deviation

⁴ Rotation speed

⁵ Hydraulic

⁶ Graham and Muench

⁷ Life of the drill

شبکه عصبی استفاده کرد و اثر الگوریتم را از جنبه های مختلف، مانند خطای نسبی و میانگین مربعات خطا مقایسه و تجزیه و تحلیل نمود. ال کیانی و همکاران [۲۹] از الگوریتم شبکه عصبی دایره‌ای برای پیش‌بینی نرخ نفوذ بر اساس داده‌های گزارش چاه و داده‌های ثبت گل، با دقتی تا ۸۵٪ استفاده کرد. در سال ۲۰۲۲، ژو و همکاران [۳۰] یک مدل پیش‌بینی از *ROP* بر اساس رگرسیون بردار پشتیبان (*SVR*) ایجاد کردند و یک الگوریتم بهبود یافته را برای حل مشکل غیر محدب تعیین مقادیر بهینه ابرپارامترهای مدل پیشنهاد کردند. در سال ۲۰۲۳، رن و همکاران [۳۱] یک مدل پیش‌بینی *ROP* بر اساس یادگیری مجموعه‌ای انباشته پیشنهاد کرد و میزان دقت پیش‌بینی در میداین نفتی خاص به ۹۲/۵٪ رسید.

۲. روش انجام کار

۱.۲. روش کار

شکل ۱، نمودار مربوط به روش پیش‌بینی نرخ نفوذ را با استفاده از یک الگوریتم نو ترکیب که شامل الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه *K*- الگوریتم زنبور عسل و پرسپترون چندلایه است را نشان می‌دهد. گام اول، شامل جمع‌آوری داده‌ها از یکی از میداین نفتی واقع در جنوب غرب ایران می‌باشد. سپس، مجموعه داده، تحت پیش‌پردازش قرار گرفته تا نقاط پرت و داده‌های تکراری حذف گردد. پس‌ازاین، داده‌ها با استفاده از معادله ۷، نرمال‌سازی شده و به‌طور تصادفی به مجموعه‌های آموزشی، آزمایشی و اعتبار سنجی تقسیم‌بندی می‌گردد. سپس متغیر هدف در محدوده ۱- تا ۱ نرمال شده و معیارهایی مانند خطای جذر میانگین مربعات و ضریب همبستگی محاسبه می‌شوند. در نهایت، عملکرد مدل‌ها مورد مقایسه قرار گرفته که منجر به انتخاب مدل نو ترکیب به‌عنوان رویکرد بهینه برای پیش‌بینی نرخ نفوذ می‌گردد.

۲.۲. الگوریتم نزدیک‌ترین همسایه *K*^۴

الگوریتم نزدیک‌ترین همسایه *K* یکی از الگوریتم‌های داده‌کاوی است که در درجه اول در کلاس‌بندی داده‌ها استفاده می‌شود [۳۲]. این الگوریتم، *k* نمونه از داده‌های

الکاتانتی و همکاران (۲۰۱۸)، از ۱۷۰۰ داده و مدل‌های شبکه عصبی مصنوعی، ماشین بردار پشتیبان^۱ و سیستم استنتاج فازی مبتنی بر شبکه تطبیقی^۲ برای پیش‌بینی تخلخل مخزن استفاده کردند. جایی که مدل شبکه عصبی پیشنهادی دارای ضریب همبستگی ۰/۹۸ است [۲۱].

الکاتانتی (۲۰۱۸)، از ۳۳۳۳ اندازه‌گیری میدانی برای ایجاد مدلی با استفاده از شبکه عصبی مصنوعی برای برآورد نرخ نفوذ استفاده کرد و به ضریب همبستگی ۰/۹۹ دست‌یافت. این مطالعه همچنین یک همبستگی جدید با درصد خطای میانگین ۴٪ با استفاده از وزن‌ها و سوگیری‌های شبکه عصبی مصنوعی تقویت‌شده ایجاد کرد [۲۲].

الکاتانتی و همکاران (۲۰۱۹)، از لاگ‌های سیمی و رویکردهای هوش مصنوعی برای پیش‌بینی زمان سیر موج‌های طولی و برشی استفاده کردند و بیان نمودند که با شبکه عصبی مصنوعی بهترین عملکرد وجود داشته و ضریب همبستگی ۰/۹۸ را ایجاد می‌کند. شایان‌ذکر این‌که، هنگامی که لاگ‌های صوتی وجود ندارند، همبستگی‌های ساده‌ای که دارای درصد خطای میانگین کمتر از ۵٪ هستند می‌توانند برای استخراج پارامترهای ژئومکانیکی دینامیکی استفاده شوند [۲۳].

الکاتانتی و همکاران در سال ۲۰۱۹، با استفاده از رویکردهای هوش مصنوعی و بر اساس ۶۰۰ داده، مدل دقیقی برای پیش‌بینی مدول یانگ استاتیکی معرفی نمودند. آن‌ها مشاهده کردند که شبکه عصبی مصنوعی، مؤثرترین روش پیش‌بینی است [۲۴].

در سال ۲۰۱۹، یک مدل قابل اعتماد پیش‌بینی نرخ نفوذ توسط عبدالجبار و همکاران^۳ ایجاد شد. جایی که با استفاده از ۷۰۰۰ داده به ضریب همبستگی ۰/۹۳ دست‌یافتند [۲۵].

الکاتانتی (۲۰۱۹)، نرخ نفوذ را با استفاده از یک مدل شبکه عصبی مصنوعی جدید در رابطه با رویکرد ارزیابی دیفرانسیل خود تطبیقی برآورد نمود. لایه پنهان مدلی که نمایش داده شد شامل سی نورون و پنج ورودی بود. اطلاعات مورد استفاده نیز شامل داده‌های ژئومکانیکی عملیات حفاری و خواص گل بودند [۲۶].

در سال ۲۰۲۱، حزه و همکاران [۲۷] و لاوال و همکاران [۲۸] از انواع الگوریتم‌های ژنتیک برای بهینه‌سازی الگوریتم

³ Al-AbdulJabbar et al.

⁴ K-nearest neighbours algorithm

¹ Support Vector Machine


² Adaptive-network-based fuzzy inference system

نمونه‌ها است. این معادله برای الگوریتم نزدیک‌ترین همسایه K استفاده می‌شود، اما در الگوریتم وزن‌دار K ، هر محور مختصات با توجه به فاصله آن از داده‌های آزمایش، وزن‌دار می‌شود. مقدار این وزن از معادله ۵ به دست می‌آید [۳۶]:

$$w_i = \frac{1/D_i}{\sum_{j=1}^k (1/D_j)}, \quad i = 1, 2, \dots, k \quad (5)$$

در معادله ۵، متغیر w وزن هر یک از نمونه‌ها است. در ادامه، مقدار نهایی با استفاده از معادله ۶ محاسبه می‌شود:

$$C_{un} = \sum_{i=1}^k w_i C_i \quad (6)$$



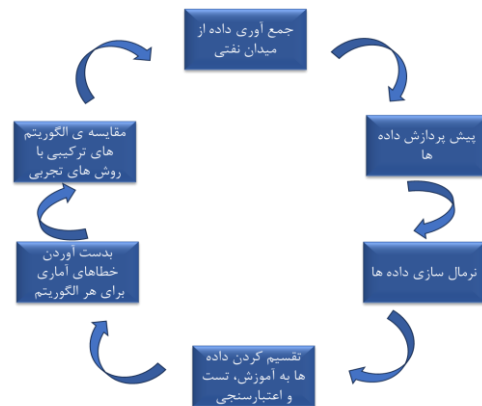
شکل ۲. الگوریتم نزدیک‌ترین همسایه K .

۳.۲. الگوریتم زنبورعسل^۱

الگوریتم زنبورعسل در سال ۲۰۰۵ توسعه یافت. این الگوریتم رفتار تغذیه در گروه‌های زنبورعسل را شبیه‌سازی می‌کند (شکل ۳) [۳۷]. در این مدل ریاضی، کلونی زنبورعسل مصنوعی دارای سه نوع زنبور است. زنبورهای کارگر روی گردآوری غذا و آوردن آن به کندو از یک منبع غذایی خاص کار می‌کنند. زنبورهای ناظر در میان کارگرها گشت می‌زنند تا تشخیص دهند یک منبع غذایی همچنان ارزش استفاده دارد یا خیر و در نهایت زنبورهای دیده‌بان که به دنبال کشف منابع غذایی جدید هستند.

در این الگوریتم یک منبع غذایی به‌عنوان حالتی در فضای جست‌وجو تعریف می‌شود (یک‌راه کار برای مساله بهینه‌سازی)، و تعداد منابع غذایی در ابتدا برابر با تعداد زنبورهای موجود در کندو است. کیفیت منابع غذایی نیز توسط مقدار تابع هدف در آن موقعیت (مقدار تناسب) تعیین می‌شود [۳۸].

آموزشی را یافته که از تمام داده‌های آموزشی به نمونه آزمایشی نزدیک‌تر هستند، سپس میانگین خروجی این k نمونه را محاسبه کرده و آن‌ها را به‌عنوان مقدار نهایی تخمین زده‌شده برای نمونه آزمایشی در نظر می‌گیرد [۳۳]. الزامات این الگوریتم عبارت‌اند از: الف- باید مجموعه‌ای از نمونه‌ها با داده‌های خروجی یا برچسب‌دار وجود داشته باشد، ب- برای محاسبه فاصله بین دو نمونه، یک واحد تشابه یا فاصله موردنیاز است، ج- بر اساس یک مقدار k ، تعداد همسایگان آن مشخص می‌شود [۳۴ و ۳۵]. شکل ۲، شماتیکی از الگوریتم نزدیک‌ترین همسایه K را نشان می‌دهد.



شکل ۱. روش کار برای پیش‌بینی نرخ نفوذ با استفاده از یک الگوریتم نو ترکیب.

در الگوریتم مذکور، ابتدا فاصله نمونه آزمون تا تمام نمونه‌های آموزشی با استفاده از معادله ۳ محاسبه می‌شود [۳۶].

$$D_i = \left(\sum_{j=1}^M |X_{ij} - X_j|^2 \right)^{1/2} \quad (3)$$

جایی که M نشان‌دهنده تعداد ویژگی‌ها یا ورودی‌ها، X_{ij} نمونه آموزشی و X_j نمونه آزمایشی است. سپس مقدار حداقل به‌دست‌آمده برای بردار D به‌عنوان k برای مرحله بعد انتخاب می‌شود. خروجی نقطه آزمون را می‌توان با معادله ۴ بیان کرد [۳۶].

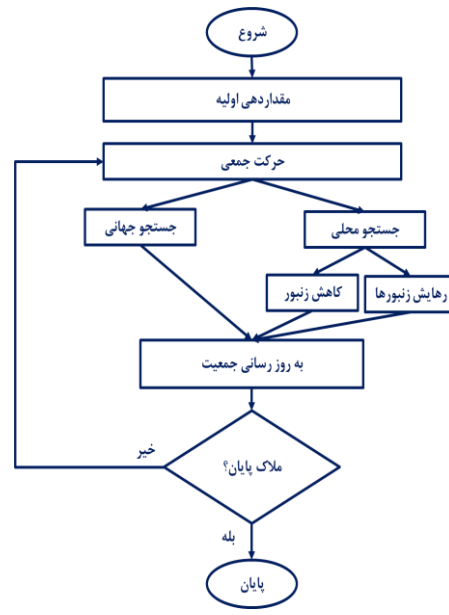
$$C_{un} = \frac{1}{k} \sum_{t=1}^k C_t \quad (4)$$

جایی که مقدار C نشان‌دهنده برچسب یا مقدار خروجی

¹ Bee algorithm



شکل ۴. شماتیک الگوریتم کرم شب تاب.



شکل ۳. شماتیک الگوریتم زنبور عسل.

۵.۲. پرسپترون چندلایه^۲

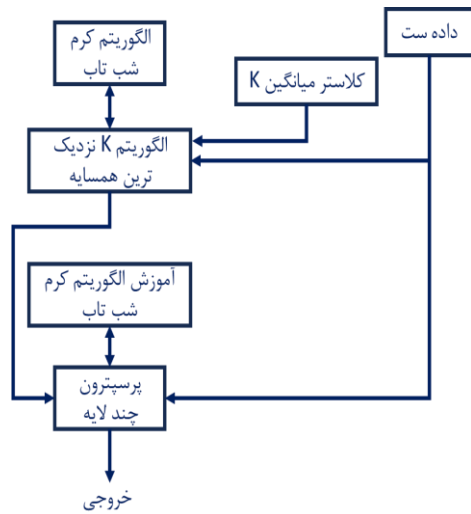
شبکه عصبی مصنوعی، ابزار هوشمندی است که برای ایجاد روابط پیچیده غیرخطی بین مجموعه‌ای از متغیرها استفاده می‌شود. در نتیجه، شبکه عصبی مصنوعی می‌تواند متغیر(های) وابسته (خروجی) موردعلاقه را با دقت بالا پیش‌بینی کند. انواع مختلفی از شبکه‌های عصبی وجود دارد که به‌طور گسترده در صنعت انرژی و سایر صنایع به کار گرفته شده‌اند. برای توسعه یک مدل پرسپترون چندلایه با کارایی بالا، چندین عامل کلیدی باید در نظر گرفته شود: الف) معماری شبکه (تعداد گره‌ها و لایه‌ها)، ب) توابع انتقال اعمال شده بین لایه‌ها، ج) انتخاب الگوریتم آموزشی مورد استفاده برای بهینه‌سازی عملکرد پیش‌بینی و د) انتخاب ویژگی‌های مناسب (یعنی نوع متغیرهای مستقل). لازم به ذکر است که عوامل فوق در تعیین میزان دقت پیش‌بینی مدل‌های پرسپترون چندلایه نقش حیاتی ایفا می‌نمایند. پرسپترون چندلایه به‌عنوان یکی از مهم‌ترین انواع شبکه عصبی مصنوعی مطرح بوده که از یک لایه ورودی و خروجی و همچنین یک یا چندلایه بین لایه‌های ورودی و خروجی، به نام "لایه(های) مخفی" تشکیل شده است. پرسپترون چندلایه که با روشی تحت نظارت الگوریتم انتشار برگشتی آموزش داده شده به‌طور

² Multilayer perception

۴.۲. الگوریتم کرم شب تاب^۱


الگوریتم کرم شب تاب یک الگوریتم فرا ابتکاری کارآمد است که از طبیعت الهام گرفته شده و مبتنی بر جمعیت است و راه حل خود را بر اساس ویژگی‌های کرم شب تاب استخراج می‌کند. الگوریتم کرم شب تاب از نحوه سیگنال دهی کرم شب تاب به یکدیگر با استفاده از نور چشمک‌زن برای جفت‌گیری یا شناسایی شکارچیان حاصل شده است. این الگوریتم، ویژگی‌هایی دارد که باید به آن‌ها توجه کرد: الف- کرم‌های شب تاب تک جنسیتی هستند به طوری که یک کرم شب تاب بدون توجه به جنسیت آن‌ها جذب سایر کرم‌های شب تاب می‌شود. ب- جذابیت متناسب با روشنایی است و هر دوی این‌ها با افزایش فاصله کاهش می‌یابند. ج- برای هر دو کرم شب تاب چشمک‌زن، کرم شب تاب کم‌نورتر به سمت پرنورتر حرکت می‌کند. د- در صورتی که روشن‌تر از یک کرم شب تاب خاص وجود نداشته باشد، به‌طور تصادفی حرکت می‌کند. ه- روشنایی یک کرم شب تاب توسط تابع هدف تعیین می‌شود. (شکل ۴) [۳۹ و ۴۰].

¹ Firefly Algorithm



شکل ۶. فلوجارت عمومی مرحله آموزش مدل نو ترکیب (الگوریتم کرم شب تاب-الگوریتم نزدیک ترین همسایه K-الگوریتم زنبور عسل-پرسپترون چند لایه).

گسترده در حل طیف وسیعی از مسائل استفاده می شود. همچنین، الگوریتم پرسپترون چند لایه در برخورد با مجموعه های بزرگ و پیچیده از داده ها، به عنوان یک شبکه عصبی مصنوعی انعطاف پذیر مطرح می باشد (شکل ۵) [۴۱ تا ۴۶].



شکل ۵. شماتیک الگوریتم پرسپترون چند لایه.

جدول ۱. تنظیمات کنترلی برای پیش بینی نرخ نفوذ توسط یادگیری ماشین هیبریدی جدید.

مقدار	پارامتر کنترل	مقدار	پارامتر کنترل
۱۰۰	الگوریتم زنبور عسل	۱۰۰	الگوریتم کرم شب تاب
۱۰۰	حداکثر تعداد تکرار	۵۰	تعداد الگوریتم کرم شب تاب
۵۰	تعداد منیع	۱	ضریب گاما
۵۰	تعداد تماشاگر	۲	ضریب جذب
۶۰	آزمایش	۰/۲	ضریب جهش
۳	تعداد متغیرها	۰/۹۸	نسبت میرایی
			ضریب جهش
	الگوریتم نزدیک ترین همسایه K	۰/۰۵	جهش یکنواخت
	مقدار K	۶	تعداد متغیرها
			پرسپترون چند لایه
	تعداد نورون های خروجی	۶	تعداد متغیرهای ورودی
		۱	تعداد لایه پنهان
		۹	تعداد نورون های لایه ورودی
		۱۰	تعداد نورون های لایه پنهان

۷.۲. مرحله آموزش

در ابتدا داده ها بر اساس معادله ۷ نرمال سازی می شود.

۶.۲. روش های ترکیبی

در این پژوهش، یک روش که از ترکیب چند الگوریتم همچون الگوریتم کرم شب تاب، پرسپترون چند لایه، زنبور عسل و الگوریتم نزدیک ترین همسایه K حاصل می شود، معرفی شده است. برای افزایش دقت پیش بینی، از داده های ۳ حلقه چاه استفاده شده است. در ابتدا، با استفاده از روش خوشه بندی K-میانگین، چاه هایی را که رفتار مشابهی دارند در یک گروه قرار داده و سپس شبکه عصبی، خروجی چاه را برای زمان $t+1$ تخمین می زند.

در الگوی پیشنهادی، الگوریتم نزدیک ترین همسایه K به عنوان روش پایه برای کلاس بندی و الگوریتم کرم شب تاب برای یافتن ضرایب بهینه داده های ورودی استفاده می شود. علاوه بر این، برای تخمین مقادیر خروجی از پرسپترون چند لایه و برای آموزش بهتر از الگوریتم زنبور عسل استفاده شده است. شکل ۶، نمودار مربوط به مرحله آموزش روش جدید را نشان می دهد. روش جدید از دو مرحله آموزش و آزمایش تشکیل شده است. پارامترهای کنترلی برای رویکردهای مورد استفاده در این مقاله نیز در جدول ۱ فهرست شده است.

از آنجایی که داده‌ها برچسب‌گذاری و خوشه‌بندی نشده‌اند، ابتدا می‌بایست تعداد کلاس‌ها و داده‌های آن‌ها برای این بلوک مشخص گردد. بنابراین، با استفاده از بلوک K -میانگین^۱، ابتدا تعداد بهینه کلاس‌ها و داده‌ها برای هر کلاس مشخص می‌شود. در اینجا، از مقدار دیویس بولدین^۲ برای رسیدن به تعداد بهینه کلاس‌ها استفاده شده است. به طوری که هرچه این مقدار کوچک‌تر باشد، تعداد کلاس‌ها بهینه‌تر خواهد بود (جدول ۲).

جدول ۲. تعیین تعداد خوشه یا کلاس برای هر داده.

شماره خوشه	۷	۶	۵	۴	۳	۲
مقدار دیویس بولدین	۷/۳۴۵۴	۷/۲۱۵۴	۶/۲۴۵۶	۵/۲۳۴۵	۴/۲۱۳۵	۰/۴۱۲۵

تشخیص پرت الگوریتم خوشه بندی K -means استفاده گردیده است. اطلاعات حفاری شامل انرژی ویژه مکانیکی^۳، چگالی گل^۴، ویسکوزیته پلاستیک گل^۵، نقطه تسلیم گل^۶، جریان ورودی گل^۷ و اندازه نازل مته حفاری^۸ بوده که مشخصات آماری آن در جدول ۳، آمده است.

جدول ۳. تجزیه و تحلیل داده‌ها برای یکی از چاه‌های واقع در جنوب غربی ایران.

متغیر واحد	انرژی ویژه مکانیکی psi	چگالی گل pcf	ویسکوزیته پلاستیک گل cP	نقطه تسلیم گل lb/100 ft ²	جریان ورودی گل gpm	اندازه نازل مته حفاری 1/32 inch	نرخ نفوذ m/h
میانگین	۲۳۹۶۹/۱۲	۷۰/۴۰	۱۵/۶۵	۱۷/۳۰	۳۵۰/۲۰	۱/۰۹	۵/۹۸
انحراف معیار	۸۶۴۷۲/۰۷	۱۱/۰۳	۴/۴۵	۵/۹۰	۷۹/۰۰	۰/۱۰	۳/۲۵
واریانس	۵۲۴۷۳۰۵۸/۳۴	۹۷/۲۰	۲۰/۰۰	۴۱/۲۹	۶۰۳۴/۲۸	۰/۰۶	۱۰/۱۲
مینیمم	۲۸۲۳/۵۰	۵۸/۹۶	۴/۹۸	۳/۰۰	۰/۰۰	۰/۷۳	۱/۷۰
ماکزیمم	۴۵۱۱۴/۷۴	۱۰۰/۲۰	۴۹/۰۰	۶۰/۰۶	۳۸۰/۵۹	۱/۲۹	۹/۶۰
چولگی	۱/۲۲	۱/۰۰	۱/۲۵	۳/۵۰	-۳/۴۷	-۰/۶۹	-۰/۲۹
کشیدگی	۰/۵۷	۲/۲۳	۶/۳۵	۹/۷۰	۴/۸۰	۱/۲۹	-۱/۶۲

می‌شود. از جمله معیارهای آماری رایج می‌توان به ضریب همبستگی^۹ و خطای جذر میانگین مربعات^{۱۰} اشاره کرد (معادلات ۸ و ۹). جداول ۴ تا ۶، نتایج مقایسه الگوریتم‌های هوش مصنوعی و معادلات تجربی را برای زیرمجموعه داده‌ی آموزش، آزمایش و اعتبارسنجی ارائه می‌دهد.

$$Q_i^l = \left(\frac{Q_i^l - Q_{min}^l}{Q_{max}^l - Q_{min}^l} \right) \times 2 - 1 \quad (7)$$

جایی که: Q_i^l = مقدار نرمال شده و Q_{max}^l, Q_{min}^l = حداقل و حداکثر مقدار هر متغیر است.

پس از نرمال‌سازی داده‌ها، باید یک ورودی جدید به داده‌ها اضافه شود که آن، تعداد خوشه یا کلاسی که هر داده به آن تعلق دارد را مشخص می‌کند. تعیین این‌که هر داده به کدام کلاس تعلق دارد توسط بلوک اول مشخص می‌شود، اما

۳- بحث و نتایج

در این مطالعه برای پیش‌بینی میزان نرخ نفوذ از ۱۹۶۰ داده مربوط به سه چاه از یک میدان نفتی واقع در جنوب غرب ایران استفاده شده است. به منظور کاهش نویز داده‌ها از روش

به منظور توسعه‌ی روش‌های نو ترکیب، از ۱۹۶۰ داده جمع‌آوری شده، ۷۰ درصد برای آموزش، ۱۵ درصد جهت آزمایش نتایج و ۱۵ درصد باقی‌مانده برای اعتبارسنجی روش‌ها استفاده می‌گردد. به منظور بررسی نتایج ارائه شده و یافتن الگوریتم کاراتر، از مقایسه پارامترهای آماری استفاده

⁶ Mud yield point (YP)

⁷ Mud flow in (Qin)

⁸ Drilling bits nozzles (BN)

⁹ Correlation coefficient

¹⁰ Root mean squared error

¹ K-means

² Davies Bouldin

³ Mechanical specific energy (MSE)

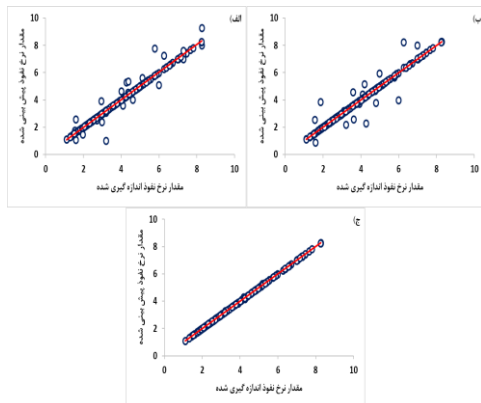
⁴ Mud density (D)

⁵ Mud plastic viscosity (PV)

جدول ۶. نتایج مربوط به داده‌های اعتبارسنجی برای پیش‌بینی نرخ نفوذ با استفاده از معیارهای مهم صحت آماری.

مدل‌ها	خطای جذر میانگین مربعات	ضریب همبستگی
مانورر	۱۷/۸۶	۰/۶۵۰۰
گاله و وودز	۲۱/۵۷	۰/۵۶۷۱
الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K	۶/۷۰	۰/۸۳۴۸
الگوریتم زنبورعسل-الگوریتم نزدیک‌ترین همسایه K	۴/۱۲	۰/۹۰۰۸
الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K-الگوریتم زنبورعسل-پرسپترون	۱/۴۸	۰/۹۶۸۱

شکل‌های ۷ و ۸، به ترتیب نمودار مربوط به مقادیر پیش‌بینی شده و اندازه‌گیری شده برای الگوریتم‌های ترکیبی و روابط تجربی و همچنین محاسبه مقادیر خطای جذر میانگین مربعات و ضریب همبستگی را نشان می‌دهند. دقت عملکرد بالای روش ترکیبی در شکل‌های مذکور قابل مشاهده می‌باشد. در نتیجه بر اساس این دو پارمتر آماری، رده بندی روش‌ها به شکل ذیل است:



شکل ۷. نرخ نفوذ پیش‌بینی شده و اندازه‌گیری شده با استفاده از داده‌های آزمایش برای مقایسه الگوریتم‌های ترکیبی الف) الگوریتم کرم شب‌تاب-الگوریتم نزدیک‌ترین همسایه K؛ ب) الگوریتم زنبورعسل-الگوریتم نزدیک‌ترین همسایه K؛ ج) الگوریتم کرم شب‌تاب-الگوریتم نزدیک‌ترین همسایه K-الگوریتم زنبورعسل-پرسپترون چندلایه.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{Measured_i} - X_{Predicted_i})^2} \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_{Measured_i} - X_{Predicted_i})^2}{\sum_{i=1}^n (X_{Predicted_i} - \frac{\sum_{i=1}^n X_{Measured_i}}{n})^2} \quad (9)$$

بر اساس اطلاعات گزارش شده در جداول مذکور، می‌توان مقایسه صحیحی بین مدل‌های تجربی و ترکیبی انجام داد. پس از بررسی داده‌های ارائه شده در این جداول، می‌توان نتیجه گرفت که عملکرد مدل ترکیبی جدید الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K- الگوریتم زنبورعسل- پرسپترون چندلایه نسبت به سایر الگوریتم‌ها و مدل‌های تجربی دقت بالاتری دارد.

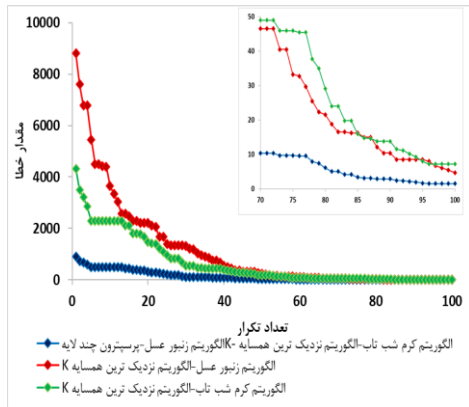
جدول ۴. نتایج مربوط به داده‌های آموزش برای پیش‌بینی نرخ نفوذ با استفاده از معیارهای مهم آماری.

مدل‌ها	خطای جذر میانگین مربعات	ضریب همبستگی
مانورر	۱۷/۴۳	۰/۶۶۷۸
گاله و وودز	۲۰/۶۸	۰/۵۸۳۲
الگوریتم کرم شب‌تاب-الگوریتم نزدیک‌ترین همسایه K	۶/۱۹	۰/۸۶۶۲
الگوریتم زنبورعسل-الگوریتم نزدیک‌ترین همسایه K	۳/۵۵	۰/۹۰۱۸
الگوریتم کرم شب‌تاب-الگوریتم نزدیک‌ترین همسایه K-الگوریتم زنبورعسل-پرسپترون	۱/۰۵	۰/۹۸۴۵

جدول ۵. نتایج مربوط به داده‌های آزمایش برای پیش‌بینی نرخ نفوذ با استفاده از معیارهای مهم آماری.

مدل‌ها	خطای جذر میانگین مربعات	ضریب همبستگی
مانورر	۱۸/۲۹	۰/۶۳۲۱
گاله و وودز	۲۲/۴۶	۰/۵۵۰۹
الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K	۷/۲۱	۰/۸۰۴۳
الگوریتم زنبورعسل-الگوریتم نزدیک‌ترین همسایه K	۴/۷۰	۰/۸۹۹۷
الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K-الگوریتم زنبورعسل-پرسپترون چندلایه	۱/۵۲	۰/۹۵۱۶

الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K - الگوریتم زنبور عسل- پرسپترون چند لایه می باشد. در نهایت می توان به این نتیجه رسید که دقت عملکرد الگوریتم نو ترکیب کرم شب تاب- الگوریتم نزدیک ترین همسایه K - الگوریتم زنبور عسل- پرسپترون چند لایه بسیار بالاتر از سایر مدل ها بوده است.

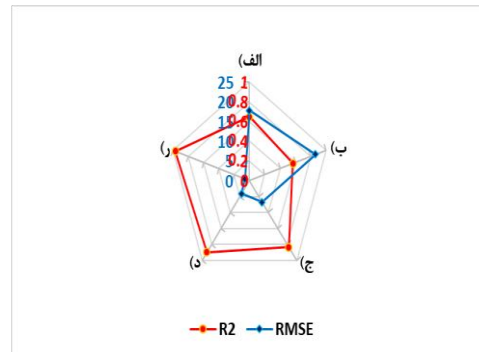


شکل ۹. مقدار خطا به ازای تکرار برای پیش بینی نرخ نفوذ بر اساس الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K ؛ الگوریتم زنبور عسل- الگوریتم نزدیک ترین همسایه K ؛ الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K - الگوریتم زنبور عسل- پرسپترون چند لایه.

ضریب پیرسون^۱ یک روش پر کاربرد برای ارزیابی تاثیر متغیرهای مستقل ورودی بر متغیرهای وابسته خروجی، مانند نرخ نفوذ است. ضریب مذکور بین -1 و $+1$ است و قدرت و جهت همبستگی را نشان می دهد. مقدار $+1$ نشان دهنده همبستگی مثبت قوی، -1 نشان دهنده همبستگی منفی قوی و مقدار نزدیک به 0 نشان دهنده عدم همبستگی است. معادله ۱۰، چگونگی محاسبه ضریب همبستگی پیرسون را نشان می دهد که معیاری آماری از رابطه خطی بین دو متغیر است. این ضریب به محققان اجازه می دهد تا میزان مرتبط بودن تغییرات یک متغیر با تغییرات متغیر دیگر را تعیین کنند.

$$R = \frac{\sum_{i=1}^n (Z_i - \bar{Z})(Q_i - \bar{Q})}{\sqrt{\sum_{i=1}^n (Z_i - \bar{Z})^2} \sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2}} \quad (10)$$

با توجه به نتایج نشان داده شده در شکل ۱۰، چنین برمی آید که اندازه نازل مته حفاری دارای بیشترین تاثیر مثبت بر روی



شکل ۸. نمودار عنکبوتی جهت تعیین مقادیر خطای جذر میانگین مربعات و ضریب همبستگی به منظور مقایسه ی معادلات تجربی و مدل های نو ترکیب برای پیش بینی نرخ نفوذ. (الف) مائورر؛ (ب) گاله و وودز؛ (ج) الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K ؛ (د) الگوریتم زنبور عسل- الگوریتم نزدیک ترین همسایه K ؛ (ر) الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K - الگوریتم زنبور عسل- پرسپترون چند لایه.

خطای جذر میانگین مربعات: گاله و وودز $<$ مائورر $<$ الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K $<$ الگوریتم زنبور عسل- الگوریتم نزدیک ترین همسایه K $<$ الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K - الگوریتم زنبور عسل- پرسپترون چند لایه.

ضریب همبستگی: گاله و وودز $>$ مائورر $>$ الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K $>$ الگوریتم زنبور عسل- الگوریتم نزدیک ترین همسایه K $>$ الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K - الگوریتم زنبور عسل- پرسپترون چند لایه.

شکل ۹، از زاویه ای دیگر به مقایسه عملکرد الگوریتم ها بر اساس میزان تکرار و خطای محاسبه ای می پردازد. همان گونه که در این شکل مشخص است، در تکرارهای اولیه مقدار خطا برای الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K بالاتر از دو الگوریتم دیگر می باشد که رفته رفته به صورت یک شیب تند، مقدار خطای آن کاهش می یابد. پس از بررسی مقادیر خطا به ازای ۱۰۰ تکرار، مشخص می شود که مقدار خطا برای سه الگوریتم از مقدار بیشتر به کمتر به ترتیب متعلق الگوریتم کرم شب تاب- الگوریتم نزدیک ترین همسایه K ، الگوریتم زنبور عسل- الگوریتم نزدیک ترین همسایه K و

¹ Pearson's coefficient

زیرا ضریب همبستگی برای داده‌های مربوط به آموزش، آزمایش و اعتبارسنجی به ترتیب برابر با ۰/۹۸۴۵، ۰/۹۵۱۶ و ۰/۹۶۸۱ می باشد.

۲. نوآوری در الگوریتم نو ترکیب ارائه شده، این است که ابتدا با ارائه بلوک اول (ترکیب الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K) کلاس‌بندی انجام می‌شود و با بلوک دوم (ترکیب الگوریتم زنبورعسل- پرسپترون چندلایه) پیش‌بینی صورت می‌پذیرد و توانایی الگوریتم برای کاهش نویز داده‌ها با این ویژگی فعال می‌شود.

۳. خطای جذر میانگین مربعات برای داده‌های مربوط به آموزش، آزمایش و اعتبارسنجی نیز به ترتیب برابر با ۱/۰۵، ۱/۵۲ و ۱/۴۸ بوده که قابلیت بالای الگوریتم نو ترکیب در پیش‌بینی را نشان می‌دهد.

۴. با بررسی ضریب پیرسون، نتیجه شد که اندازه نازل متعادل حفاری تاثیر مستقیم و انرژی ویژه مکانیکی تاثیر عکس بر نرخ نفوذ داشته‌اند.

علائم اختصاری


ABC	Artificial bee colony
ANFIS	Adaptive-network-based fuzzy inference system
FF	Firefly Algorithm
MLP	Multilayer perception
R^2	Correlation coefficient
RMSE	Root mean squared error
ROP	Rate of penetration
RPM	Rotations per minute
SVM	Support Vector Machine
WOB	Weight on bit

۵- مراجع

- [1] Jiang, G., Sun, J., He, Y. & et al. (2021). Novel water-based drilling and completion fluid technology to improve wellbore quality during drilling and protect unconventional reservoirs. *Engineering*, (18), 129-142.
- [2] Zausa, F., Pellicciotta, L., Spelta, A. & et al. (2018). Multi source data analysis to improve drilling efficiency, reduce costs and enhance performance monitoring. *SPE*, D021S056R003 .
- [3] Anderson, DR. & Burnham, KP. (2002). Avoiding pitfalls when using information-theoretic methods. *The Journal of wildlife management*, 66 (3), 912-918 .
- [4] Pilehvari, AA., Azar, JJ. & Shirazi, SA. (1999). State-of-the-art cuttings transport in horizontal

نرخ نفوذ حفاری می‌باشد. این بدان معنی است که پارامتر اندازه نازل متعادل حفاری با مقدار نرخ نفوذ رابطه مستقیم و مقادیر چگالی، نقطه تسلیم، ویسکوزیته پلاستیک، انرژی ویژه مکانیکی و جریان ورودی گل با مقدار نرخ نفوذ رابطه عکس داشته‌اند که توسط معادله ۱۱، تشریح می‌گردد.

$$ROP \propto (BN) \frac{1}{(D, Q_{in}, PV, YP, MSE)} \quad (11)$$



شکل ۱۰. ارزیابی تاثیر متغیرهای مستقل ورودی (انرژی ویژه مکانیکی، چگالی گل، ویسکوزیته پلاستیک گل، نقطه تسلیم گل، جریان ورودی گل و اندازه نازل متعادل حفاری) بر متغیر وابسته خروجی (نرخ نفوذ) بر اساس ضریب پیرسون.

۴- نتیجه گیری

در این مطالعه برای پیش‌بینی میزان نرخ نفوذ از ۱۹۶۰ داده مربوط به سه چاه از یک گازی نفتی واقع در جنوب غرب ایران استفاده شده است. اطلاعات ورودی شامل انرژی ویژه مکانیکی، چگالی گل، ویسکوزیته پلاستیک گل، نقطه تسلیم گل، جریان ورودی گل و اندازه نازل متعادل حفاری می‌باشد. به منظور پیش‌بینی نرخ نفوذ، از سه الگوریتم ترکیبی هوش مصنوعی جدید که شامل الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K ، الگوریتم زنبورعسل- الگوریتم نزدیک‌ترین همسایه K و الگوریتم هیبریدی جدید کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K - الگوریتم زنبورعسل- پرسپترون چندلایه می‌باشد، استفاده شده است. نتایج حاصل از این تحقیق به شرح ذیل می‌باشد:

۱. الگوریتم کرم شب‌تاب- الگوریتم نزدیک‌ترین همسایه K - الگوریتم زنبورعسل- پرسپترون چندلایه در مقایسه با سایر الگوریتم‌ها و معادلات، دقت عملکرد بالاتری را نشان می‌دهد.

- [19] Elkatatny, S., Tariq, Z., Mahmoud, M. & Al-AbdulJabbar, A. (2017). Optimization of rate of penetration using artificial intelligent techniques. 51st U.S. Rock Mechanics/Geomechanics Symposium, San Francisco, California, USA.
- [20] Elkatatny, S., Mahmoud, M., Tariq, Z. & Abdurraheem, A. (2018). New insights into the prediction of heterogeneous carbonate reservoir permeability from well logs using artificial intelligence network. *Neural Computing and Applications*, 30, 2673-2683.
- [21] Elkatatny, S., Tariq, Z., Mahmoud, M. & Abdurraheem, A. (2018). New insights into porosity determination using artificial intelligence techniques for carbonate reservoirs. *Petroleum*, 4, 408-418.
- [22] Elkatatny, S. (2018). New approach to optimize the rate of penetration using artificial neural network. *Arabian Journal for Science and Engineering*, 43, 6297-6304.
- [23] Elkatatny, S., Tariq, Z., Mahmoud, M., Mohamed, I. & Abdurraheem, A. (2018). Development of new mathematical model for compressional and shear sonic times from wireline log data using artificial intelligence neural networks (white box). *Arabian Journal for Science and Engineering*, 43, 6375-6389.
- [24] Elkatatny, S., Tariq, Z., Mahmoud, M., Abdurraheem, A. & Mohamed, I. (2019). An integrated approach for estimating static Young's modulus using artificial intelligence tools. *Neural Computing and Applications*, 31, 4123-4135.
- [25] Al-AbdulJabbar, A., Elkatatny, S., Mahmoud, M., Abdelgawad, K. & Al-Majed, A. (2019). A robust rate of penetration model for carbonate formation. *Journal of Energy Resources Technology*, 141, 1-9.
- [26] Elkatatny, S. (2019). Development of a new rate of penetration model using self-adaptive differential evolution-artificial neural network. *Arabian Journal of Geosciences*, 12, 1-10.
- [27] Hazbeh O, Aghdam SK-y, Ghorbani H et al. (2021). Comparison of accuracy and computational performance between the machine learning algorithms for rate of penetration in directional drilling well. *Petroleum Research*, 6, 271-282 .
- [28] Lawal AI, Kwon S, Onifade M. (2021). Prediction of rock penetration rate using a novel antlion optimized ANN and statistical modelling. *Journal of African Earth Sciences*, 1, 104287 .
- [29] Alkinani HH, Al-Hameedi ATT, Dunn-Norman S. (2021). Data-driven recurrent neural network model to predict the rate of penetration: Upstream Oil and Gas Technology. *Upstream Oil and Gas Technology*, 7, 100047.
- [30] Zhou Y, Lu C, Zhang M et al . (2022) A novel rate wellbores. *SPE drilling & completion*, 14, 196-200.
- [5] Ramba, V., Selvaraju, S., Subbiah, S. & et al. (2021). Optimization of drilling parameters using improved play-back methodology. *Journal of Petroleum Science and Engineering*, 206, 108991.
- [6] Alali, AM., Abughaban, MF., Aman, BM. & et al. (2021). Hybrid data driven drilling and rate of penetration optimization. *Journal of Petroleum Science and Engineering* , 200, 108075.
- [7] Shi, X., Liu, G., Gong, X. & et al. (2016). An efficient approach for real-time prediction of rate of penetration in offshore drilling. *Mathematical Problems in Engineering* , 2016,1-13.
- [8] Kaiser, MJ. (2009). Modeling the time and cost to drill an offshore well. *Energy* , 34, 1097-1112.
- [9] Hocheng, H. & Tsao, CC. (2006). Effects of special drill bits on drilling-induced delamination of composite materials. *International Journal of Machine Tools and Manufacture* , 46, 1403-1416.
- [10] Amadi, K. & Iyalla, I. (2012) Application of mechanical specific energy techniques in reducing drilling cost in deepwater development. SPE Deepwater Drilling and Completions Conference, Galveston, Texas, USA.
- [11] Hasan, M., Zhao, J. & Jiang, Z. (2017). A review of modern advancements in micro drilling techniques. *Journal of Manufacturing Processes*, 29, 343-375.
- [12] Graham, JW. & Muench, NL. (1959). Analytical determination of optimum bit weight and rotary speed combinations. *SPE*, 1349-G.
- [13] Maurer, WC. (1962). the perfect-cleaning theory of rotary drilling. *Journal of Petroleum Technology*, 14, 1270-1274.
- [14] Galle, EM. & Woods, HB. (1963). Best constant weight and potary speed for rotary rock bits. *Hughes Tool Company*, 1-36.
- [15] Bourgoyne, AT. & Young, FS. (1974). A multiple regression approach to optimal drilling and abnormal pressure detection. *Society of Petroleum Engineers Journal*, 14, 371-384.
- [16] Yang, J-F., Zhai, Y-J., Xu, DP. & Han, P. (2007). SMO algorithm applied in time series model building and forecast. *IEEE*, 4, 2395-2400.
- [17] Ertekin, T. & Sun, Q. (2019). Artificial intelligence applications in reservoir engineering: a status check. *Engines*, 12, 2897.
- [18] Elkatatny, S., Tariq, Z. & Mahmoud, M. (2016). Real time prediction of drilling fluid rheological properties using Artificial Neural Networks visible mathematical model (white box). *Journal of Petroleum Science and Engineering*, 146, 1202-1210.

SmartCom, Springer, Pages 205-221.

[44] Khilar, R., Mariyappan, K., Christo, MS., Amutharaj, J., Anitha, T. & Rajendran, T. (2022). Artificial intelligence-based security protocols to resist attacks in internet of things. *Wireless Communications and Mobile Computing*, 2022.

[45] Isabona, J., Imoize, AL., Ojo, S., Karunwi, O., Kim, Y. & Lee, C. (2022). Development of a multilayer perceptron neural network for optimal predictive modeling in urban microcellular radio environments. *Applied Sciences*, 12, 5713.

[46] Lin, H. & Jegelka, S. (2018). Resnet with one-neuron hidden layers is a universal approximator. 32nd Conference on Neural Information Processing Systems (NeurIPS 2018), Montréal, Canada. .

of penetration model based on support vector regression and modified bat algorithm. *IEEE Transactions on Industrial Informatics* 2022 .

[31] Ren Y, Lu B, Zheng S et al. (2023) Research on the Rate of Penetration Prediction Method Based on Stacking Ensemble Learning. *Geofluids*, 2023.

[32] Gazalba, I. & Reza, NGI. (2017). Comparative analysis of k-nearest neighbor and modified k-nearest neighbor algorithm for data classification. 2nd International conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE), 294-298.

[33] Papernot, N. & McDaniel, P. (2018). Deep k-nearest neighbors: Towards confident, interpretable and robust deep learning. arXiv preprint arXiv:180304765 2018 .

[34] Kaghyan, S. & Sarukhanyan, H. (2012). Activity recognition using k-nearest neighbor algorithm on smartphone with tri-axial accelerometer. *International Journal of Informatics Models and Analysis (IJIMA)*, ITHEA International Scientific Society, Bulgaria, 146-156 .

[35] Gou, J., Qiu, W., Yi, Z., Shen, X., Zhan, Y. & Ou, W. (2019). Locality constrained representation-based K-nearest neighbor classification. *Knowledge-Based Systems*, 167, 38-52.

[36] Suykens, JAK. (2001). Nonlinear modelling and support vector machines. In: *IEEE*, 287-294.

[37] Basu, M. (2011). Bee colony optimization for combined heat and power economic dispatch. *Expert Systems with Applications*, 38, 13527-13531 .

[38] Bitam, S., Batouche, M. & Talbi, E-g. (2010). A survey on bee colony algorithms. In: *IEEE*, 1-8 .

[39] Hajarian, M., Shahbahrani, A. & Hoseini, F. (2016). A parallel solution for the 0-1 knapsack problem using firefly algorithm. *IEEE*, 1, 25-30.

[40] Ball, A.K. , Roy, S.S., Kisku, D.R. & et al. (2024). Optimization of drop ejection frequency in EHD inkjet printing system using an improved Firefly Algorithm. *Applied Soft Computing*, 94, 106438 .

[41] Atefinia, R. & Ahmadi, M. (2021). Network intrusion detection using multi-architectural modular deep neural network. *The Journal of Supercomputing*, 77, 3571-3593.

[42] Rolon, L., Mohaghegh, SD., Ameri, S., Gaskari, R. & McDaniel, B. (2009). Using artificial neural networks to generate synthetic well logs. *Journal of Natural Gas Science and Engineering*, 1, 118-133.

[43] Pothina, H. & Nagaraja, KV. (2022). Artificial neural network and math behind it. *Smart Trends in Computing and Communications, Proceedings of*