



مقاله مروری

مروری بر کاربرد یادگیری ماشین در پیش‌بینی مخاطرات و مشکلات حفاری

پریبرخ ابراهیمی<sup>۱</sup>؛ علی رنجبر<sup>۲\*</sup>

۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی نفت، گاز و پتروشیمی، دانشگاه خلیج فارس  
۲- استادیار گروه مهندسی نفت، دانشکده مهندسی نفت، گاز و پتروشیمی، دانشگاه خلیج فارس

دریافت مقاله: ۱۴۰۲/۱۰/۱۱ پذیرش مقاله: ۱۴۰۳/۰۱/۱۸

شناسه دیجیتال (DOI): 10.22107/JPG.2024.421270.1222

واژگان کلیدی	چکیده
مشکلات حفاری، گیر لوله، هرزروی گردش سیال حفاری، شکستگی در سازند، لرزش کابل حفاری، یادگیری ماشین	هزینه بالای عملیات حفاری منجر به افزایش چالش‌ها در بهینه‌سازی عملیات حفاری شده است. رمز موفقیت در کاهش این هزینه‌ها طراحی برنامه چاه بر اساس پیش‌بینی مسائل و مشکلات بالقوه حفاری می‌باشد. در چند دهه گذشته، صنعت حفاری تمایل روزافزونی به یادگیری ماشین برای پیش‌بینی مشکلات حفاری نشان داده است. این مقاله، مروری جامع از مطالعات مرتبط با بکارگیری یادگیری ماشین در پیش‌بینی رویدادهای پر مخاطره حفاری را ارائه می‌کند. در هر مطالعه، الگوریتم‌های یادگیری ماشین، تعداد نقاط داده، پارامترهای ورودی و خروجی به ماشین و عملکرد الگوریتم مربوطه از مطالعات پیشین استخراج شده است. علاوه بر این، محدودیت‌ها، شباهت‌های مطالعات در هر دسته خلاصه شده و مروری از ادبیات به همراه توصیه‌هایی برای توسعه مطالعات آینده ارائه شده است. این بررسی‌ها نشان می‌دهد که الگوریتم شبکه عصبی مصنوعی محبوب‌ترین روش در بین الگوریتم‌های یادگیری ماشین در مطالعات انجام شده است؛ این در حالی است که دیگر الگوریتم‌ها نظیر الگوریتم ماشین بردار پشتیبان و جنگل تصادفی ممکن است عملکرد بهتری را در استخراج نتایج از خود نشان دهند. همچنین لازم به ذکر است، بسیاری از مدل‌های هوشمند ارائه شده توسط پژوهشگران از نمونه‌های محدود و برای شرایط خاص ارائه نتایج چنین مطالعاتی ممکن است قابل تعمیم نباشد.

۱. مقدمه

اهداف بهینه‌سازی فرآیند حفاری شامل کاهش زمان، صرفه‌جویی در هزینه، افزایش بازده عملیات و کاهش مشکلات حفاری می‌باشد [۲]. از آنجا که هزینه‌های حفاری به طور قابل توجهی در هزینه هر بشکه نفت اثر می‌گذارد، مطابق شکل ۱ هزینه‌های حفاری برای یک چاه نفتی بطور کلی به شش منبع هزینه تقسیم می‌شود.

بر اساس آنچه بیان شد، صنعت حفاری ناچار به یافتن راه‌هایی برای کاهش هزینه حفاری در هر فوت است. رمز موفقیت در دستیابی به حفاری ایده‌آل، ایمن و اقتصادی، طراحی برنامه‌های مناسب حفاری بر اساس پیش‌بینی مشکلات احتمالی چاه است [۳، ۴]. از شایع‌ترین مشکلات حفاری گیر

در حین عملیات حفاری، مشکلاتی در چاه‌ها رخ می‌دهد که ادامه روند حفاری را دچار چالش می‌کند. رخ دادن مشکلات حفاری حتی در چاه‌هایی که با دقت بسیار زیاد برنامه‌ریزی شده‌اند نیز امکان‌پذیر می‌باشد. دلیل این امر آن است که شرایط زمین‌شناسی حتی برای دو چاه حفاری شده در نزدیک یکدیگر (در سازند ناهمگن) نیز ممکن است، متفاوت باشد [۱]. عدم کنترل و جلوگیری از مشکلات حفاری منجر به مشکلات دیگری مانند ضررهای مالی، از دست دادن زمان، تحلیل توانایی انسان‌ها و خسارت‌های جانی کارکنان حفاری می‌شود. هزینه بالای عملیات حفاری منجر به تمرکز بسیار بر کاهش زمان عملیاتی و بهینه‌سازی فرآیند حفاری شده است.

نیاز به بررسی و شناخت پارامترهای حفاری و استفاده از آن‌ها در جهت پیش‌بینی مشکلات حفاری می‌باشد. مهم‌ترین پارامترهای ثبت‌شده و موثر بر مشکلات و مخاطرات عملیات حفاری در پژوهش‌های انجام شده در ادبیات این مقاله، در شکل ۲ گزارش شده است. این پارامترها و روند تغییرات آن‌ها توسط تجهیزات مربوطه و سیستم نظارت در دکل ثبت و ضبط شده و این امکان را فراهم می‌آورد تا داده‌ها بطور مستقیم برای اهداف مختلف از جمله بهینه‌سازی عملیات مورد استفاده قرار گیرند. همچنین این داده‌ها می‌توانند در پژوهش‌های آتی یا برای بازیابی اطلاعات در آینده مورد استفاده قرار گیرند. برای مطالعات بیشتر درمورد جزئیات این پارامترها می‌توان به کتب مبانی حفاری [۲۰-۲۲] مراجعه کرد.



شکل ۲. مهم‌ترین پارامترهای حفاری برای پژوهش

یادگیری ماشین سهم برجسته‌ای در طیف وسیعی از صنایع داشته است. ارزش دانش و تکنیک‌های یادگیری ماشین به طور گسترده در کاربردهای مختلف مورد توجه قرار گرفته است، در حالی که پتانسیل آن‌ها در صنعت نفت و گاز به طور

افتادن رشته‌حفاری<sup>۱</sup> [۵، ۶]، هرزروی گل حفاری<sup>۲</sup> [۷، ۸]، انحراف دهانه چاه<sup>۳</sup> [۹، ۱۰]، مچاله‌شدگی لوله جداره<sup>۴</sup> [۱۱]، برش لوله حفاری<sup>۵</sup> [۱۳، ۱۴]، ناپایداری دهانه چاه<sup>۶</sup> [۱۵]، آسیب سازند<sup>۷</sup> [۱۷، ۱۸] و مشکلات مرتبط با نیروی انسانی (پرسنل)<sup>۸</sup> [۱۹، ۲۰] می‌باشد. همچنین یکپارچگی تجهیزات حفاری و نگهداری آن‌ها از عوامل اصلی در به حداقل رساندن مشکلات حفاری است. هیدرولیک مناسب دکل (قدرت پمپ) برای تمیز کردن کف و فضای حلقوی (آنالوس) چاه بسیار مهم است. همچنین برای عملیات بالابری (لوله بالا) و پیمایش موثر، قدرت بالابری مناسب نیاز است. طراحی مناسب عملکرد دکل و بار کششی لوله حفاری، در صورت بروز مشکلات گیرکردگی رشته حفاری، اضافه بار ایمن را اجازه خواهد داد. یک سیستم کنترل چاه مناسب (شیر فوران‌گیر کوچ<sup>۹</sup>، شیر فوران‌گیر فضای حلقوی<sup>۱۰</sup>، شیر فوران‌گیر داخلی<sup>۱۱</sup>) امکان کنترل لرزش کابل حفاری<sup>۱۲</sup> را در هر شرایط لرزش کابل فراهم می‌کند [۲۰].



شکل ۱. مهم‌ترین هزینه حفاری چاه‌های نفتی

درک تمامی این مشکلات، علل اتفاق هر کدام از آن‌ها، پیش‌بینی و برنامه‌ریزی آن‌ها برای دستیابی سریع‌تر به راه حل‌ها، کنترل هزینه و دستیابی به هدف منطقه مورد نظر بسیار حائز اهمیت است. برای حل مسائل و مشکلات حفاری

<sup>۷</sup> Producing-formation damage

<sup>۸</sup> Personnel-related problems

<sup>۹</sup> Ram preventers

<sup>۱۰</sup> Annular preventers

<sup>۱۱</sup> Internal preventers

<sup>۱۲</sup> kick

<sup>۱</sup> Pipe sticking

<sup>۲</sup> Loss of circulation

<sup>۳</sup> Hole deviation

<sup>۴</sup> Casing collapse

<sup>۵</sup> Drill pipe failures

<sup>۶</sup> Borehole Instability

آن سیستم سعی می‌کند تنها با استفاده از داده‌ها دون هیچ‌گونه برچسب و مشخصه‌ای به هر شکل ممکن رابطه منطقی را بین این مجموعه داده کشف کند [۲۸]. یادگیری نظارت شده، با استفاده از مجموعه داده‌های برچسب‌گذاری شده برای آموزش الگوریتم‌هایی که داده‌ها را طبقه‌بندی می‌کنند یا نتایج را با دقت پیش‌بینی می‌کنند، تعریف می‌شود. در یادگیری نظارت‌شده الگوریتم سعی می‌کند یک رابطه بین داده‌های ورودی و خروجی ایجاد کند. هدف از رابطه ایجاد شده از طریق یادگیری، پیش‌بینی خروجی‌های مجموعه‌ای از ورودی‌هایی است که در طول یادگیری استفاده نشده‌اند [۲۹].

یادگیری تقویتی به یادگیری مبتنی بر تجربه اشاره دارد که در آن ماشین براساس پاداش یا جریمه که از کاربر دریافت می‌کند، سعی دارد عملکرد خود را بهبود ببخشد. در این روش سیستم با یک محیط تعامل می‌کند و بر اساس پیامدهای اعمال خود، یاد می‌گیرد [۳۰]. نمونه‌ای از کاربرد یادگیری تقویتی، رباتی است که یاد می‌گیرد چگونه وزن گل (چگالی گل) را در حین حفاری از طریق شبیه‌سازی‌ها تنظیم کند. این ربات می‌تواند از نتایج انتخاب‌های خود در تصمیم‌گیری مقادیر درست و غلط وزن گل برای استفاده در سناریوهای مختلف حفاری استفاده کند. همچنین یادگیری نیمه نظارتی وجود دارد که زمانی نتیجه می‌گیرد که برخی از داده‌ها به عنوان یادگیری نظارت‌شده برچسب‌گذاری شوند و برخی از داده‌ها تحت طبقه‌بندی یادگیری بدون نظارت قرار گیرند [۳۱].

علاوه بر دسته‌بندی یادگیری ماشینی بر اساس حالت یادگیری (یادگیری نظارت‌شده، بدون نظارت و تقویتی)، یادگیری ماشینی را می‌توان به عنوان انجام طبقه‌بندی<sup>۴</sup> یا رگرسیون<sup>۵</sup> بر اساس ماهیت کیفی یا کمی داده‌های خروجی دسته‌بندی کرد. یادگیری ماشین دسته‌بندی به مسائلی اطلاق می‌شود که خروجی مدل ماهیت کیفی داشته باشد و خروجی بصورت یک دسته یا کلاس با برچسب‌های گسسته نشان داده می‌شود. به همین ترتیب، یادگیری ماشین زمانی رگرسیون را انجام می‌دهد که خروجی ماهیت کمی داشته باشد [۳۲]. در

کامل و عملی مورد استفاده قرار نگرفته است [۲۳]. روش‌های آماده‌سازی و بررسی داده‌های سنتی به اندازه کافی قادر به استخراج سریع اطلاعات و تجسم واضح مجموعه داده‌های پیچیده بزرگ نیستند [۲۴]. بسیاری از چالش‌های موجود در صنعت حفاری با استفاده از یادگیری ماشین قابل کنترل هستند؛ به بیان دیگر، با توجه به تقاضای برآورده نشده صنعت حفاری، گردش کار صنعت به کمک یادگیری ماشین در زمینه‌های بهینه‌سازی حفاری و آنالیز پارامترهای زمان واقعی ارائه شده است. این مطالعه مشکلات حفاری، مزایا و کاستی‌های تکنیک‌ها و الگوریتم‌های یادگیری ماشین استفاده شده در پژوهش‌های موجود را برای جلوگیری از مخاطرات صنعت حفاری مورد بحث قرار می‌دهد. لازم به ذکر است الگوریتم‌های مورد بررسی در این مطالعه، زیرمجموعه الگوریتم‌های پیش‌بینی‌کننده نظارت شده می‌باشند.

## ۲. مقدمه‌ای بر یادگیری ماشین

یادگیری ماشین شاخه‌ای از علوم کامپیوتر است که برای حل مشکلات مهندسی با توانایی در نظر گرفتن همه پارامترهای مؤثر به طور همزمان بکار برده می‌شود [۲۵]. روش‌های یادگیری ماشین دارای ویژگی‌های تعمیم‌پذیری و یادگیری بالقوه به طور مستقیم از داده‌های میدانی است. هدف اصلی جستجوی روش‌های هوشمند، پیش‌بینی بروز برخی مشکلات بر اساس تجربه قبلی با هزینه و زمان مناسب است. قابلیت اطمینان روش به دقت پیش‌بینی و خطای بین برچسب‌های دسته واقعی و پیش‌بینی‌شده مسئله بستگی دارد. بسیاری از علوم مهندسی از هوش مصنوعی برای پیش‌بینی مسائل رایج استفاده کرده‌اند. آن‌ها به دلیل پیچیدگی‌های اکثر مشکلات امروزی که به سختی از طریق روش‌های سنتی و مرسوم یا آنچه محاسبات سخت‌نمیده می‌شود، به دنبال روش‌های هوش مصنوعی و بکارگیری الگوریتم‌های یادگیری ماشین هستند [۲۶].

یادگیری ماشینی را می‌توان به یادگیری بدون نظارت<sup>۱</sup>، یادگیری نظارت‌شده<sup>۲</sup> و یادگیری تقویتی<sup>۳</sup> دسته‌بندی کرد [۲۷]. یادگیری بدون نظارت به حالتی اطلاق می‌شود که در

<sup>۳</sup> Reinforcement learning

<sup>۴</sup> Classification

<sup>۵</sup> Regression

<sup>۱</sup> Unsupervised learning

<sup>۲</sup> Supervised learning

داده  $\hat{y}_i$  نام،  $\hat{y}_i$  مقدار خروجی پیش‌بینی شده توسط روش‌های یادگیری ماشین برای داده  $\hat{y}_i$  نام،  $\bar{y}_i$  مقدار میانگین خروجی واقعی اندازه‌گیری شده برای داده‌ها،  $\bar{y}_i$  مقدار میانگین خروجی پیش‌بینی شده توسط روش‌های یادگیری ماشین برای داده‌ها می‌باشد. همچنین  $N$  بیانگر تعداد کل مجموعه داده یکار گرفته شده در مدل‌سازی است. هرچه مقدار  $R^2$  بیشتر باشد، حاکی از آن است نتایج بهتر است اما برای  $MAE$ ،  $RMSE$  و  $AAPE$  مقدار کمتر حاکی از عملکرد بهتر نتایج است [۳۸].

الگوریتم‌های یادگیری ماشین نظارت‌شده رایج که در ادبیات مسائل و مشکلات حفاری بیشتر مورد استفاده قرار گرفته‌اند شامل درخت دسته‌بندی تصمیم<sup>۶</sup>، جنگل تصادفی<sup>۷</sup>، نزدیکترین همسایه- $k$ <sup>۸</sup>، ماشین بردار پشتیبان<sup>۹</sup>، شبکه عصبی مصنوعی<sup>۱۰</sup>، نایبو بیز<sup>۱۱</sup> و رگرسیون خطی<sup>۱۲</sup> می‌باشند [۳۹-۴۲]. در حالی که برخی از الگوریتم‌های یادگیری ماشین ممکن است از نظر دقت یادگیری قوی‌تر از بقیه باشند، با این حال عوامل دیگری نیز بر انتخاب نوع الگوریتم مؤثر می‌باشند. از جمله این عوامل می‌توان به سرعت پیاده‌سازی، سهولت در تفسیر نتایج، ماهیت وظیفه یادگیری ماشین (دسته‌بندی یا رگرسیون)، ماهیت و مقدار داده‌های ورودی و خروجی، و همچنین پیچیدگی مدل اشاره نمود [۴۳]. شکل ۳ بطور خلاصه یک گردش کار معمولی از یک پروژه یادگیری ماشین را نشان می‌دهد.



از آنجا که مطالعات مرتبط با موضوع مطالعه حاضر، اغلب

عملیات حفاری از مثال‌های داده‌های کیفی طبقه‌بندی، می‌توان به حالت‌های لرزش کابل، شرایط حفاری متوازن، هرزروی سیال، شرایط پمپ گل (نرمال، تحت فشار) اشاره کرد. از این داده‌ها می‌توان جهت تشخیص وضعیت حفاری ته چاه در یک نقطه زمانی معین استفاده نمود. البته باید در نظر داشت که در علوم مهندسی بیشتر مسائل، رگرسیونی هستند؛ زیرا بطور معمول در مسئله به پیش‌بینی مقدار یک ویژگی پرداخته می‌شود (به عنوان مثال ویسکوزیته [۳۳]، چگالی [۳۴]، فشار [۳۵] و غیره). از مثال‌های این بخش، می‌توان به الگوریتم یادگیری در تخمین پنجره بهینه گل حفاری [۳۶]، پارامترهای الاستیک سنگ [۳۷] و ... اشاره کرد.

برای مسائل رگرسیونی، معیارهای ارزیابی، تفاوت بین مقادیر پیش‌بینی شده و مقادیر واقعی/اندازه‌گیری شده را محاسبه می‌کنند. معیارهای رگرسیون رایج شامل ضریب تعیین<sup>۱</sup>، ضریب همبستگی<sup>۲</sup>، میانگین خطای مطلق<sup>۳</sup>، ریشه میانگین مربع خطا<sup>۴</sup> و متوسط درصد مطلق خطا<sup>۵</sup> می‌شود. روابط معیارهای مذکور به صورت زیر بیان می‌شود:

$$R^2 = \left( \frac{\sum_{i=1}^N (y_i - \bar{y}_i)(\hat{y}_i - \bar{\hat{y}}_i)}{\sqrt{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \sqrt{\sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}}_i)^2}} \right)^2 \quad (1)$$

$$r = R \quad (2)$$

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

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4)$$

$$AAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \quad (5)$$

که در آن‌ها  $y_i$  مقدار خروجی واقعی اندازه‌گیری شده برای

<sup>۷</sup> Random forest

<sup>۸</sup> K nearest neighbor (KNN)

<sup>۹</sup> Support vector machines (SVM)

<sup>۱۰</sup> Artificial neural network

<sup>۱۱</sup> Naïve bayes

<sup>۱۲</sup> Linear regression

<sup>۱</sup> Coefficient of determination ( $R^2$ )

<sup>۲</sup> Correlation coefficient ( $r$ )

<sup>۳</sup> Mean absolute error (MAE)

<sup>۴</sup> Root means square error (RMSE)

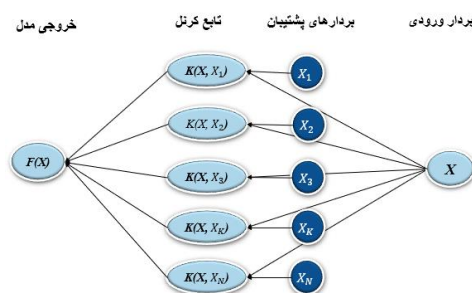
<sup>۵</sup> Average absolute percentage error (AAPE)

<sup>۶</sup> Classification decision tree

مدل مجموع توابع به فرم زیر برای پیش‌بینی استفاده می‌شوند [۴۶].

$$f(x) = w \cdot x + b \quad (۸)$$

که در آن  $w$  وزن بردار  $x$  و  $b$  مقدار بایاس می‌باشد. شماتیک ساده‌ای از عملکرد این الگوریتم در شکل ۴ نشان داده شده است.



شکل ۴. ساختار ماشین بردار پشتیبان

### ۳.۲. شبکه بیزین

شبکه بیزین برای اولین بار توسط جودا پرل<sup>۲</sup> در سال ۱۹۸۸ طراحی شد [۴۷]. از مزایای مهم این مدل، می‌توان به مواردی از قبیل تحلیل ریسک و عدم قطعیت با دقت بیشتر نسبت به سایر مدل‌ها، مدیریت مقادیر گمشده از بین داده‌های ورودی، توانایی در ترکیب داده‌های کمی و کیفی و ارائه حل‌های تقریبی با استفاده از تکنیک‌های شبیه‌سازی یا روش‌های تخمین در مواردی که حل دقیقی در دسترس نباشد، اشاره کرد. شبکه بیزین یک گراف مستقیم و چرخه‌ای می‌باشد که در آن، گره‌ها در حکم متغیرهای مسئله هستند. هر شبکه بیزین از سه جزء اصلی شامل مجموعه‌ای از گره‌ها، مجموعه‌ای از ارتباطات و مجموعه‌ای از احتمالات تشکیل شده است [۴۷]. معادله زیر رابطه بیز را نشان می‌دهد [۴۸، ۴۹]:

$$P(C_i | X) = \frac{P(X | C_i) P(C_i)}{P(X)} \quad (۹)$$

که در آن  $P(C_i)$  احتمال وقوع پیش آمد  $C$ ،  $P(X)$  احتمال وقوع پیش آمد  $X$ ،  $P(C_i | X)$  احتمال وقوع پیش آمد  $C$  به شرطی که پیش آمد  $X$  اتفاق بیافتد و  $P(X | C_i)$  احتمال وقوع پیش آمد  $X$  به شرطی که پیش آمد  $C$  اتفاق بیافتد.

روش‌های یادگیری ماشین مورد استفاده رگرسیون خطی، ماشین بردار پشتیبان، شبکه بیزین، شبکه عصبی مصنوعی و درخت دسته‌بندی تصمیم می‌باشد، لذا در ادامه به ارائه این روش‌های پرکاربرد در ادبیات به طور مختصر پرداخته شده است.

### ۱.۲. رگرسیون خطی

روش رگرسیون خطی یکی از روش‌های اولیه در مدل‌سازی در نظر گرفته می‌شود. این تکنیک توانایی آشکار کردن روابط پنهان بین یک یا چند متغیر پیش‌بینی‌کننده و یک ویژگی وابسته را دارد. یک مدل خطی برازش داده‌ها که از یک ویژگی مستقل تشکیل شده است که در آن  $Y$  به  $X$  وابسته است. مدل را می‌توان به شکل زیر توصیف کرد:

$$Y = a + bX + \varepsilon \quad (۶)$$

که در آن  $a$  و  $b$  پارامترهای رگرسیون از مجموعه داده محاسبه می‌شوند و مقدار خطا توسط  $\varepsilon$  ارائه می‌شود و خط بهترین برازش مطابق با معادله ۶ تعیین می‌شود. مقادیر بر اساس کمترین خطا بین جمع مجذور اعداد واقعی و پیش‌بینی شده تعیین می‌شوند [۴۴].

$$\begin{aligned} \min r(\hat{a}, \hat{b}) &= \sum_{i=1}^n (Y_i - Y_p(X_i))^2 \\ &= \sum_{i=1}^n (Y_i - \hat{a} - \hat{b}X_i)^2 \end{aligned} \quad (۷)$$

که در آن،  $Y_p$  عامل پیش‌بینی شده است.

### ۲.۲. ماشین بردار پشتیبان

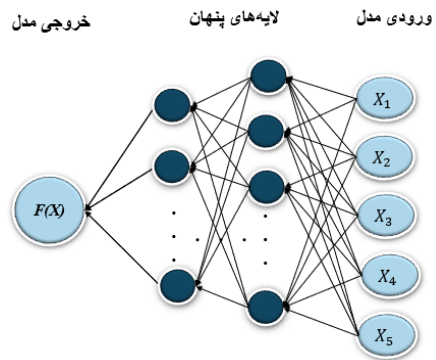
الگوریتم ماشین بردار پشتیبان نیز از دیگر الگوریتم‌های نظارت شده است. این الگوریتم بر مبنای تئوری یادگیری آماری<sup>۱</sup> استوار است که از اصل استقرای کمینه سازی خطای ساختاری استفاده می‌کند و یک جواب بهینه کلی را ارائه می‌دهد [۴۵]. به بیان دیگر، این الگوریتم تابع برازش داده‌ها را در مسائل رگرسیونی به گونه‌ای برآورد می‌کند که کمترین خطا در گروه‌بندی داده‌ها یا تابع برازش رخ دهد. در حالت رگرسیونی از ماشین بردار پشتیبان هدف آن است که تابع  $f(x)$  را برای الگوی آموزشی  $x$  طوری تشخیص دهد که بیشینه حاشیه را از مقادیر آموزشی  $y$  داشته باشد. در این

<sup>۲</sup> Judea Pearl

<sup>۱</sup> Statistical learning theory

### ۴.۲. روش شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یکی پرکاربردترین تکنیک‌های یادگیری ماشین است. شبکه عصبی مصنوعی یک سیستم محاسباتی و پردازش اطلاعات است [۵۰، ۵۱]. هر شبکه عصبی مصنوعی، صرف نظر از ساختار پیاده‌سازی، دارای چند ویژگی اساسی است [۵۲]. یک شبکه عصبی مصنوعی شامل تعداد زیادی عناصر پردازش است که «نورون» نامیده می‌شوند و همه این عناصر پردازشی دارای تعداد زیادی اتصالات وزنی بین خود هستند. بطور معمول این واحدهای پردازشی در یک توپولوژی چند لایه مرتب شده‌اند که به صورت یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی پیکربندی می‌شوند. [۵۳، ۵۴]. شکل ۵ ساختاری شبکه‌های عصبی مصنوعی را نشان می‌دهد که دارای دو سری لایه پنهان می‌باشد.



شکل ۵. ساختار یک شبکه عصبی مصنوعی

### ۵.۲. درخت تصمیم

یادگیری درخت تصمیم یکی از رایج‌ترین الگوریتم‌های داده کاوی است که از طبیعت الهام گرفته و برای حل مسائل طبقه‌بندی و رگرسیون به کار برده می‌شود. درخت‌های تصمیم برای حل‌های رگرسیونی و پیش‌بینی سریع هستند و از حافظه کمی استفاده می‌کنند [۵۵]. این الگوریتم شامل گره‌های داخلی، گره‌های برگ، گره‌های ریشه و شاخه‌ها می‌باشد. گره ریشه اولین قسمت از الگوریتم است که داده‌های ورودی را حمل می‌کند. گره‌های برگ یا گره‌های پایانی آخرین قسمت نمودار هستند و نتیجه مدل را نشان می‌دهند [۵۶].

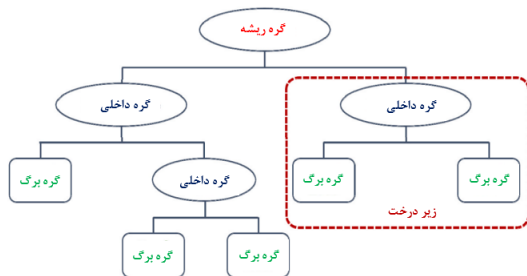
اگر فرض شود برای گره  $m$ ،  $N_m$  تعداد نمونه‌های آموزشی

رسیده به آن و برای گره ریشه<sup>۱</sup>، این مقدار  $N$  باشد،  $N_m$  متعلق به کلاس  $C_i$ ، با  $\sum_i N_m^i = N_m$  خواهد بود. با در نظر گرفتن رسیدن یک نمونه به گره  $m$ ، تخمین برای احتمال کلاس  $C_i$  از معادله ۱۰ حاصل می‌شود.

$$\hat{P}(C_i | x, m) \equiv P_m^i = \frac{N_m^i}{N_m} \quad (10)$$

$\hat{P}(C_i | x, m)$  احتمال وقوع پیش آمد  $C_i$  به شرطی که پیش آمد  $x$  در گره  $m$  اتفاق بیافتد. گره  $m$  خالص است اگر  $P_m^i$  برای تمامی آن‌ها ۰ یا ۱ باشد. مقدار آن زمانی که هیچ یک از نمونه‌های رسیده به گره  $m$  از کلاس  $C_i$  نباشد صفر، و زمانی که تمامی این نمونه‌ها از کلاس  $C_i$  باشند، یک است. اگر تقسیم خالص باشد، نیازی به تقسیم بیشتر نیست و یک گره برگ<sup>۲</sup> برای کلاسی که  $P_m^i$  برابر ۱ داشته باشد، برچسب‌گذاری می‌شود.

تصویر ساده‌ای از درخت تصمیم در شکل ۶ نشان داده شده است.



شکل ۶. شماتیکی از یک درخت تصمیم [۵۶]

نمی‌توان ادعا کرد که یک الگوریتم یادگیری ماشین بطور خاص بهترین عملکرد را در حل مسائل دارد؛ بنابراین، هیچ الگوریتم یادگیری ماشینی به طور کلی بهترین الگوریتم برای همه مسائل نیست. هر الگوریتم نقاط قوت و ضعف خود را دارد که برخی از آن‌ها در جدول ۱ ذکر شده است. بنابراین، اعمال چندین الگوریتم یادگیری ماشین و انتخاب الگوریتمی که بهترین عملکرد را دارد، یک روش معمول است. روش دیگر، به جای استفاده از یک الگوریتم واحد، ممکن است از روشی که نتایج چندین الگوریتم را ترکیب می‌کند نیز استفاده شود.

<sup>۲</sup> Leaf node

<sup>۱</sup> Root node

### ۳. حوادث پرمخاطره عملیات حفاری

رویدادهای پرخطری در حین عملیات حفاری ممکن است رخ دهد که علاوه بر پرهزینه کردن عملیات، باعث افزایش زمان کلی حفاری می‌شود. درک این حوادث، علل رخ دادن آن‌ها، پیش‌بینی و برنامه‌ریزی آن‌ها برای کنترل کلی هزینه ضروری است. این یخش به ارائه شایع‌ترین مشکلات حفاری که در مطالعات پیشین بسیار مورد توجه بوده‌اند، می‌پردازد.

#### جدول ۱. مزایا و معایب الگوریتم‌های یادگیری ماشین [۵۷، ۵۸]


الگوریتم	مزایا	معایب
رگرسیون خطی	- مقاوم در برابر نویز - دارای تفسیرپذیری مناسب با توجه به خروجی احتمال	- نیاز به پیش‌پردازش - کنترل مرزهای تصمیم خطی - رخ دادن بیش برآش
ماشین بردار پشتیبان	- دقیق در فضاها با ابعاد بالا و پیچیده - به خوبی با داده‌های پرت کنار می‌آید	- پیچیدگی زیاد الگوریتم و عملکرد ضعیف در زمان آموزش بالا (اگر تعداد داده‌های نویز زیاد باشد) - سختی یافتن کرنل مناسب
شبکه بیزین	- آسانی در درک و اجرا - عملکرد بهتر برای مجموعه نقطه داده کمتر	- نیاز به پیش‌پردازش - فرض ویژگی‌های مستقل
شبکه عصبی مصنوعی	- توانایی پردازش موازی - توانایی یادگیری روابط غیر خطی پیچیده - دارای عملکرد مناسب در برخی از کارها مانند تشخیص تصویر و متن - مقاوم در برابر نویز و مقادیر پرت	- تعداد زیاد ابرپارامترها - تعداد زیاد محاسبات - عدم تفسیرپذیری - نیاز به پیش‌پردازش داده‌ها دارد
درخت تصمیم	- تفسیر آسان - پوشش‌دهی ویژگی‌های پیوسته و گسسته - غیرپارامتریک - نیازمند به پیش‌پردازش کمتر	- مشکل انباشتگی خطاها - مکانیزم تصمیم‌گیری بهینه می‌تواند تصمیمات نادرستی به دنبال داشته باشد.

### ۱.۱.۳. گیرکردن رشته حفاری

در عملیات حفاری، لوله‌ای گیر افتاده تلقی می‌شود که نتواند به راحتی حرکت کند و بدون آسیب رساندن به لوله و بدون افزایش حداکثر بار قلاب مجاز دکل حفاری، از چاه خارج شود. پدیده گیر لوله می‌تواند اثرات فاجعه‌باری بر عملکرد حفاری داشته باشد. همراه با نتایجی که از تاخیر زمانی تا از دست دادن ماشین‌آلات گران‌قیمت متغیر است. برای برداشتن گام‌های مناسب برای بهترین پیشگیری، شناخت این مکانیسم‌ها و بسیاری از مؤلفه‌های مرتبط ضروری است. دو نوع مکانیسم گیرکردگی لوله وجود دارد که به تفصیل به توضیح آن در ادامه پرداخته می‌شود [۵۹].

#### ۱.۱.۳.۱. گیر اختلاف فشاری لوله

گیرکردن اختلاف فشاری لوله<sup>۱</sup> هنگامی اتفاق می‌افتد که بخشی از رشته حفاری در یک کیک گلی<sup>۲</sup> (یک فیلم از مواد جامد نفوذناپذیر) که در طول فرایند حفاری بر روی دیواره سازند نفوذپذیر ایجاد می‌شود، قرار می‌گیرد. اگر فشار گل که بر روی دیواره خارجی لوله تأثیر می‌گذارد، بیشتر از فشار سیال سازند باشد، لوله به طور متفاوت در چاه گیر می‌کند، که به طور کلی در حفاری نامتعادل اتفاق می‌افتد [۶۰]. مفهوم گیر لوله اختلاف فشاری در شکل ۷ نشان داده شده است.



<sup>۱</sup> Differential pressure pipe sticking

<sup>۲</sup> Mud cake



### شکل ۷. گیر لوله اختلاف فشاری [۲۰]

پارامترهای قابل کنترل که باعث افزایش نیروی چسبندگی لوله و عدم توانایی بالقوه در آزادسازی لوله گیر شده می‌شود، عبارتند از:

- اختلاف فشار زیاد غیرضروری
- کیک گل ضخیم (هرزروی مداوم بالای سیال به سازند)
- کیک گل با خاصیت روان کنندگی کم<sup>۱</sup> (ضریب اصطکاک زیاد)
- طول لوله بیش از حد در کیک گل گیر کرده باشد (تاخیر زمانی در عملیات آزادسازی)

### ۲،۱،۳ گیر مکانیکی لوله

دلایل گیرکردگی مکانیکی لوله می‌تواند به علت تجمع بیش از حد خرده‌های حفاری در فضای حلقوی (آنالوس)، ناپایداری دهانه چاه (مانند ریزش چاه، پدیده گسیختگی یا مچاله‌شدگی لوله جداری در حین بهره‌برداری از چاه) و جاکلیدی<sup>۲</sup> باشد. تجمع بیش از حد خرده‌های حفاری در فضای حلقوی (آنالوس) به دلیل تمیز نکردن ناکافی چاه می‌تواند باعث گیرکردن مکانیکی لوله شود - به ویژه در حفر چاه انحرافی، که ممکن است یک بستر خرده‌ها در قسمت پایین دهانه چاه ایجاد شود. اگر این شرایط در حین عملیات لوله بالا وجود داشته باشد، احتمالاً گیرکردن لوله قریب الوقوع است [۶۱]. همچنین موضوع گیرکردگی لوله با مسائل و ناپایداری دیواره ی چاه همراه است. مشکل‌سازترین مسئله، حفاری در سازند شیلی است. بسته به ترکیب گل و وزن گل، شیل می‌تواند بصورت پوستی یا پلاستیکی به داخل چاه حرکت کند و باعث چسبندگی و گیرکردن مکانیکی لوله شود. در همه انواع سازندها، استفاده بیش از حد از وزن کم گل می‌تواند منجر به پدیده مچاله‌شدگی دهانه و در نهایت احتمالاً باعث گیرکردن مکانیکی لوله<sup>۳</sup> شود. همچنین، حفر لایه نمک که به نمایش رفتار پلاستیکی تحت فشار لایه‌های بالایی<sup>۴</sup> شناخته شده است، می‌تواند منجر به مشکلاتی شود. دلیل اصلی گیر مکانیکی لوله جاکلیدی است. مکانیک جاکلیدی شامل

پوشاندن یک چاله کوچک (شیار) در دیواره یک چاه کامل است. این شیار در اثر چرخش رشته حفاری با نیروی جانبی وارد بر آن ایجاد می‌شود. این شرایط در سگ‌پاه<sup>۵</sup> یا برآمدگی‌های شناسایی نشده در مجاورت محل‌های شسته‌شده (گشادشده)<sup>۶</sup> ایجاد می‌شود. نیروی جانبی که متمایل به فشار دادن لوله به دیواره است باعث فرسایش مکانیکی می‌شود و بنابراین یک جاکلیدی ایجاد می‌کند. حفاری طولانی مدت می‌تواند باعث ایجاد جاکلیدی شود. همچنین، استفاده از متعلقات درون چاهی<sup>۷</sup> سفت و سخت باعث کاهش وقایع شدید سگ‌پا می‌شود. در هنگام عملیات لوله بالا، یک مشکل گیرکردگی لوله که در جاکلیدی مشاهده می‌شود آن است که چندین شاخه لوله بیرون کشیده و سپس، به طور ناگهانی لوله گیر می‌کند. گیر مکانیکی لوله بسته به علت گیرکردگی، از بسیاری جهات قابل آزادسازی است. به عنوان مثال، اگر علت گیر کردن لوله تجمع خرده‌ها باشد، با چرخش و برگشت متقابل رشته حفاری و همزمان با افزایش نرخ جریان بدون افزایش حداکثر چگالی گردشی معادل<sup>۸</sup> مجاز، می‌توان لوله را آزاد کرد. اگر علت گیر لوله باریک شدن دهانه چاه به دلیل آماس‌پذیری شیل باشد، افزایش وزن گل ممکن است لوله را آزاد کند، در حالی که باریک شدن دهانه چاه به دلیل نمک باشد، گردش آب شیرین ممکن است لوله را آزاد کند. یک راه برای دوری از ریسک گیر لوله، پیش‌بینی آن با استفاده از پارامترهای حفاری در دسترسی است که برای اصلاح متغیرهای حفاری به کار می‌روند. این پیش‌بینی بالقوه می‌تواند برای کاهش هزینه چاه موثر باشد؛ همچنین با بررسی و تحلیل حاضر، به مهندس حفاری این اجازه داده می‌شود تا خطر بروز لوله گیر کرده در طول برنامه حفاری را ارزیابی کند [۵۹]. خلاصه‌ای از مطالعات یادگیری ماشین برای گیر لوله، از گذشته تاکنون در ادامه ارائه شده است. این مطالعات بطور عمده گیر/عدم گیر، نوع گیر را پیش‌بینی می‌کنند. مطالعه‌ای با استفاده از عمق اندازه‌گیری شده، عمق عمودی

<sup>۵</sup> Doglegs

<sup>۶</sup> Washouts

<sup>۷</sup> Bottom hole assembly (BHA)

<sup>۸</sup> Equivalent circulating density (ECD)

<sup>۱</sup> Low-lubricity

<sup>۲</sup> Key seat

<sup>۳</sup> Mechanical pipe sticking

<sup>۴</sup> Overburden pressure



میری و همکاران<sup>۱۷</sup> [۶۴] در سال ۲۰۰۷ مورد استفاده قرار گرفت که احتمال گیر لوله را با دقت ۸۳٫۳ درصد و احتمال عدم گیر لوله را با دقت ۱۰۰ درصد تخمین زد. موریلو و همکاران<sup>۱۸</sup> [۶۵] در سال ۲۰۰۹ با استفاده از پارامترهای ۱۸۵ حلقه چاه، شامل پارامترهای حفاری، اختلاف فشار، عمق چاه و خصوصیات گل حفاری به تخمین گیر با عدم گیر لوله حفاری در چاه پرداختند. داده‌ها به سه گروه ۵۹ لوله گیر اختلافی، ۶۸ گیر مکانیکی و ۵۸ عدم گیر لوله طبقه بندی شدند. آن‌ها برای این مطالعه شبکه عصبی مصنوعی و منطق فازی<sup>۱۹</sup> را مدل‌سازی کردند که منطق فازی با دقت ۹۸٫۴ درصد عملکرد بهتری نسبت به شبکه عصبی مصنوعی از خود نشان داد.

شادی‌زاده و همکاران [۶۶] در سال ۲۰۱۰ از مجموعه داده‌ای برای شرایط دینامیک که دارای ۱۵۵ مورد عدم گیر لوله و ۴۰ مورد گیر لوله بود و از مجموعه دیگر داده برای شرایط استاتیک که دارای ۱۵۶ مورد عدم گیر لوله و ۷۵ مورد گیر لوله بود، برای استفاده در مدل‌سازی با شبکه عصبی مصنوعی بهره برد. از پی‌اچ‌گل<sup>۲۰</sup>، ضریب هندسی<sup>۲۱</sup> (که تابعی از ابعاد دهانه چاه، متعلقات درون‌چاهی و طوق مته<sup>۲۲</sup> است)، نقطه تسلیم، گرانیوی پلاستیک، استحکام ژل ۱۰ دقیقه، مقدار کلراید، دور بر دقیقه<sup>۲۳</sup>، نرخ نفوذ<sup>۲۴</sup>، اختلاف فشار و سرعت فضای حلقوی<sup>۲۵</sup> به عنوان داده‌های ورودی به مدل استفاده شد. مجموعه داده‌ها به آموزش، اعتبارسنجی و آزمون با توجه به نسبت ۸۰٪، ۱۰٪ و ۱۰٪ برای هر دو شرایط دینامیک و استاتیک تقسیم شدند. دقت بالای پیش‌بینی گیر لوله با استفاده از پارامترهای انتخابی نشان داد که عمده دلایل وقوع

واقعی<sup>۱</sup>، متوسط گاز حفاری<sup>۲</sup>، گاز اتصال<sup>۳</sup>، حداکثر گاز حفاری<sup>۴</sup>، گاز عملیات<sup>۵</sup>، زاویه بازبینی<sup>۶</sup>، وزن گل، گرانیوی پلاستیک<sup>۷</sup>، نقطه تسلیم<sup>۸</sup>، استحکام ژل<sup>۹</sup> ۱۰ ثانیه، استحکام ژل ۱۰ دقیقه، هرزروی آب<sup>۱۰</sup>، فیلتره پی‌اچ، فیلتره کلراید، فیلتره کلسیم، درصد نفت، درصد آب، اندازه دهانه چاه، نرخ جریان، طوقه مته<sup>۱۱</sup>، عمق مته، طول متعلقات درون‌چاهی، طول طوق مته<sup>۱۲</sup>، کشش<sup>۱۳</sup>، زمان گیرکردن<sup>۱۴</sup>، گشتاور و درصد مواد جامد و مبتنی بر دسته‌بندی چند متغیره توسط همکین و همکاران<sup>۱۵</sup> [۶۲] در سال ۱۹۸۷ انجام شد. در این مطالعه از ۱۳۱ مورد برای گیر لوله و عدم گیر، برای آموزش و ۴۷ نقطه داده از ۳۵ چاه برای آزمون استفاده شد. بررسی دسته‌بندی چند متغیره برای تمایز بین گیر مکانیکی، گیر اختلافی و عدم گیر لوله در چاه‌ها با میزان موفقیت بالای ۸۱٪ روبرو بود.

سیرووری و همکاران<sup>۱۶</sup> [۶۳] در سال ۲۰۰۶ از پارامترهای حفاری نظیر اختلاف فشار، عمق چاه و از پارامترهای گل حفاری مانند ویژگی هرزروی سیال، مواد کلراید، گرانیوی پلاستیک، نقطه تسلیم، استحکام ژل و غیره به عنوان پارامترهای ورودی به مدل برای پیش‌بینی گیر یا عدم گیر لوله استفاده کردند. در این مطالعه از روش شبکه عصبی مصنوعی برای طراحی مدل بکاربرده شد که عدم گیر لوله را با دقت میانگین خطای مطلق ۱۰۰ درصد تخمین زد. این روش احتمال وقوع گیرکردن لوله را با دقت میانگین خطای مطلق ۱۰ درصد تخمین زد.

مدل شبکه عصبی مصنوعی دیگری با ۱۰۹ مجموعه نقطه داده از خواص گل حفاری، اختلاف فشار و عمق چاه توسط

<sup>۱۴</sup> Time stuck

<sup>۱۵</sup> Hemphkins et al

<sup>۱۶</sup> Siruvuri et al

<sup>۱۷</sup> Miri et al

<sup>۱۸</sup> Murillo et al

<sup>۱۹</sup> Fuzzy logic (FL)

<sup>۲۰</sup> Mud PH

<sup>۲۱</sup> Geometry factor (GF)

<sup>۲۲</sup> Bit sub

<sup>۲۳</sup> Revolution per minute (RPM)

<sup>۲۴</sup> Rate of penetration (ROP)

<sup>۲۵</sup> Annular velocity

<sup>۱</sup> True vertical depth (TVD)

<sup>۲</sup> Average drill gas

<sup>۳</sup> Connection gas

<sup>۴</sup> Maximum drill gas

<sup>۵</sup> Trip gas

<sup>۶</sup> Review angle

<sup>۷</sup> Plastic viscosity (PV)

<sup>۸</sup> Yield point (YP)

<sup>۹</sup> Gel strength (GS)

<sup>۱۰</sup> Water loss

<sup>۱۱</sup> Drill-collar OD

<sup>۱۲</sup> Drill-collar

<sup>۱۳</sup> Drag

۲۱۴ نقطه داده بهره برده شد که ۷۰ درصد آن برای آموزش و ۳۰ درصد آن برای آزمون استفاده شد. الگوریتم ماشین بردار پشتیبان عملکرد بهتری نسبت به نتایج الگوریتم شبکه عصبی مصنوعی از خود نشان داد.

چمکلانی و همکاران<sup>۲</sup> [۷۰] در سال ۲۰۱۳ با استفاده از ماشین بردار پشتیبان و با تکیه بر ۲۱۹ مجموعه نقطه داده از اختلاف فشار، عمق چاه، شرایط چاه، پارامترهای حفاری و خواص گل حفاری به تخمین گیر لوله حفاری در چاه پرداختند. این الگوریتم با دقت ۹۵ درصد احتمال وقوع گیر لوله حفاری را پیش‌بینی کرد.

مطالعه‌ای در سال ۲۰۱۹ توسط چمکلانی و همکاران [۶۱] بر روی کاربرد روش‌های یادگیری ماشین برای پیش‌بینی وقوع گیرکردن لوله (در سه حالت در حین حفاری، عملیات لوله پایین و عملیات لوله بالا) ارائه شده است که از توسعه مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای این تخمین استفاده شد. این مطالعه با استفاده از ۱۰۱۰ مجموعه داده از اطلاعات چاه و خواص گل به بررسی شرایط مختلف که باعث گیر لوله می‌شود، با استفاده از داده‌های حفاری چاه‌های حفر شده در جنوب عراق پرداخته شده است. براساس بررسی‌های این مطالعه شیب چاه، نرخ نفوذ، سنگ‌شناسی سازند و طول متعلقات درون چاهی تأثیر به‌سزایی در وقوع گیر لوله دارد. همچنین طیف گزارشات این مطالعه ماشین بردار پشتیبان نسبت به شبکه عصبی مصنوعی دارای دقت بالاتری در پیش‌بینی وقوع گیر لوله می‌باشد. دقت عملکرد ماشین بردار پشتیبان ۹۴ درصد گزارش شده است. مقاله دیگری در سال ۲۰۲۰ توسط کودپروو و شستاکوو<sup>۳</sup> [۷۱] انجام شد که در آن به بررسی کاربرد مفاهیم شبکه عصبی در مسئله گیر لوله می‌پردازد. این روش امکان تخمین خطر گیرکردن لوله در چاه را در حین حفاری در زمان واقعی فراهم می‌کند. این مقاله یک مطالعه موردی را ارائه می‌کند که در آن مدل‌سازی شبکه عصبی با موفقیت برای تخمین و پیش‌بینی گیرکردن لوله استفاده می‌شود. در این مقاله از ۴۳۵ نقطه داده جهت مدل‌سازی استفاده شد و آزمون‌هایی بر روی داده‌های واقعی انجام شد تا کیفیت مدل توسعه‌یافته سنجیده شود؛ نتیجه حاصل حاکی از برتری کیفیت مدل توسعه داده

این پدیده مرتبط با مقادیر نامناسب این پارامترها است. خروجی الگوریتم مدل‌سازی شده در این مطالعه قادر به دستیابی به دقت پیش‌بینی بیش از ۹۰ درصد احتمال گیر لوله بود.

مودنی و همکاران [۶۷] در سال ۲۰۱۱ در پژوهشی گیر لوله حفاری را با پارامترهای حفاری و مدل‌سازی شبکه عصبی هوشمند پیش‌بینی کردند. از پارامترهای ورودی به این مدل نوع سازند، عمق سازند بر حسب متر، شیب چاه در نقطه مورد نظر، عمق انحراف چاه، اندازه آخرین لوله جداری یا لاینر رانده شده در چاه، عمق آخرین لوله جداری یا لاینر رانده شده در چاه، اندازه مته، وزن گل، گرانروی قیف مارش، گرانروی پلاستیک، نقطه تسلیم، استحکام ژل اولیه و استحکام ژل ۱۰ دقیقه می‌باشد. کل داده‌های مورد استفاده دارای ۲۶۶ نقطه داده با ۱۶۶ نقطه داده مربوط به وقوع گیر لوله و ۱۰۰ نقطه داده بدون هیچ‌گونه مشکل بود. حدود ۷۰ درصد از داده‌های ورودی برای آموزش، ۱۵ درصد برای آزمون و ۱۵ درصد برای اعتبار سنجی استفاده شده است. مقدار  $R$  برای آموزش ۰٫۹۵، برای آزمون ۰٫۷۶ و برای اعتبار ۰٫۸۲ بدست آمد.

آل بیات و هاینز<sup>۱</sup> [۶۸] در سال ۲۰۱۲ مدل هوشمندی را برای پیش‌بینی گیر لوله براساس شبکه عصبی مصنوعی و ماشین بردار پشتیبان، با کمک ۶۶ مجموعه داده از ویژگی‌های یک چاه انحرافی، عمق چاه، اندازه چاه و خواص گل به کار برده شده در حفاری طراحی کردند. دقت بهترین مدل ۸۵ درصد گزارش شده است. در این مطالعه ماشین بردار پشتیبان عملکرد بهتری نسبت به شبکه عصبی مصنوعی داشت.

جهان‌بخشی و همکاران [۶۹] در سال ۲۰۱۲ با مدل‌سازی از طریق دو روش یادگیری ماشین به تخمین هوشمند گیر اختلاف فشاری لوله پرداختند. آن‌ها در مدل‌سازی خود از دو روش ماشین بردار پشتیبان و شبکه عصبی مصنوعی در بررسی موردی یکی از میادین نفتی دریایی ایران استفاده کردند. پارامترهای ورودی مدل شامل اختلاف فشار، عمق چاه، محتوای جامدات، نقطه تسلیم، استحکام ژل اولیه، استحکام ژل ۱۰ دقیقه، طول متعلقات درون چاهی، هرزروی سیال، زمان ثابت لوله، گرانروی فیلترات گل، گرانروی پلاستیک و اندازه دهانه چاه می‌باشد. برای این مدل‌سازی از

<sup>۲</sup> Qodirov and Shestakov<sup>۱</sup> Al-Baiyat, I. and L. Heinze<sup>۳</sup> Chamkalani et al

مصنوعی و روش ماشین بردار پشتیبان پرکاربردترین روش‌ها می‌باشند و در اکثر مطالعات مورد استفاده قرار گرفته‌اند؛ اما بر اساس ادبیات بررسی شده، روش شبکه عصبی مصنوعی در تقابل با روش ماشین بردار پشتیبان، در اغلب موارد عملکرد ضعیف‌تری داشته است. در بررسی مطالعات ادبیات، دقت روش شبکه عصبی مصنوعی در بازه بیش از ۷۵ درصد الی ۹۴ درصد در تخمین گیر یا عدم گیر لوله متغیر بوده است. این محدوده برای روش ماشین بردار پشتیبان ۸۵ درصد تا بالای ۹۶ درصد گزارش شده است. محدوده داده‌های استفاده شده در مطالعات بررسی شده از مینیوم ۱۰۹ نقطه داده تا ماکزیمم ۱۲۱۹۴۶ نقطه داده می‌باشد. همچنین از بین پارامترهای استفاده شده در مطالعات، پارامترهای اختلاف فشاری، عمق، نرخ نفوذ، گرانیوی پلاستیک، نقطه تسلیم، استحکام ژل و طول متعلقات درون چاهی بیشترین تاثیر را برای پیش‌بینی گیر کردن لوله دارند. پارامترهای سنگ‌شناسی و سازند عوامل مهمی در چسبندگی و گیر اختلاف فشاری لوله‌ها می‌باشند به گونه‌ای که در سازندهای تراوا این مخاطره بیشتر اتفاق می‌افتد. بنابراین انتخاب مقادیر مناسب برای این پارامترها اهمیت فراوانی در جلوگیری از گیر لوله حفاری دارد.

### ۲.۳. هرزروی گل حفاری

هرزروی گل به عنوان جریان کنترل نشده کامل گل به سازند تعریف می‌شود، که بعضاً به عنوان منطقه دزدک<sup>۶</sup> شناخته می‌شود. سازندهایی که شکسته، تهی شده<sup>۷</sup> یا پر تخلخل<sup>۸</sup> هستند و یا از تراوایی بالایی برخوردار هستند، از یک طرف، مناطق بالقوه هرزروی گل هستند و از طرف دیگر، تحت شرایط خاص نامناسب حفاری، شکستگی‌های ایجاد شده در آن‌ها به مناطق بالقوه هرزروی سیال حفاری تبدیل می‌شوند [۷۶].

از جمله سازندهای پر تخلخل، لایه‌های سنگ آهکی با حفرات بزرگ است. در این سازندها هرزروی سیال حفاری سریع و از نوع کامل است و از دشوارترین‌ها برای درزگیری کردن (آب بندی) می‌باشد. سازندهای با تراوایی بالا که مناطق بالقوه هرزروی گل حفاری هستند، ماسه‌های کم عمق با تراوایی بیش از ۱۰ داری می‌باشند. به طور کلی، ماسه عمیق (در

شده از مدل‌های قبلی می‌باشد. مدل توسعه یافته شده در این مطالعه، پیش‌بینی وقوع گیر کردن لوله (بر اساس داده‌های تجربی) را با دقت پیش‌بینی ۸۶ درصد ممکن می‌سازد.

آل شیخی و همکاران<sup>۱</sup> [۷۲] در سال ۲۰۱۹ به مقایسه سه الگوریتم ماشین بردار پشتیبان، شبکه عصبی مصنوعی و درخت تصمیم در پیش‌بینی گیر کردن یا نکردن لوله حفاری پرداختند. آن‌ها در مطالعه‌شان از ۱۳ مجموعه پارامتر حفاری شامل ۱۲۱۹۴۶ نقطه داده استفاده کردند. در نهایت مدل‌های ساخته شده ماشین بردار پشتیبان، شبکه عصبی مصنوعی و درخت تصمیم به ترتیب با دقت ۹۶،۸۸ درصد، ۹۴،۲۸ درصد و ۹۳،۷۷ درصد عملکرد خود را در این مطالعه نشان دادند. مدلی از شبکه عمیق یادگیری براساس ۸۶۳۹ مجموعه داده از ۱۹ پارامتر حفاری توسط بیان و ذوالقرنین<sup>۲</sup> [۷۳] در سال ۲۰۲۰ طراحی شد. این مدل با دقت ۷۹،۴ درصد احتمال گیر لوله در چاه را تخمین زد. پارامترهای استفاده شده در این مطالعه شامل وزن روی مته، گردش بر دقیقه، نرخ نفوذ، گشتاور، نرخ پمپ و دیگر پارامترهای حفاری است.

تیسوهاشی و همکاران<sup>۳</sup> [۷۴] در سال ۲۰۲۱ با استفاده از کاربرد الگوریتم شبکه عصبی کانولوشنال<sup>۴</sup> و داده‌های حفاری ۳۰ چاه استفاده کردند و با تکیه بر این الگوریتم گیر لوله را در چاه تخمین زدند. آن‌ها در این مطالعه از ۱۹ پارامتر حفاری به عنوان پارامترهای ورودی به مدل استفاده کردند. در نهایت مدل طراحی شده در این مطالعه با دقت متوسط ۳۹،۴۱ درصد گیر لوله حفاری را پیش‌بینی کرد. همچنین اینوعه و همکاران<sup>۵</sup> [۷۵] نیز در سال ۲۰۲۲ با تکیه بر دو الگوریتم یادگیری ماشین و براساس پارامترهای حفاری به تخمین وقوع گیر لوله در چاه حفاری پرداختند.

بر اساس مطالعات صورت گرفته و مرور ادبیات موضوع در رابطه با گیر لوله حفاری، می‌توان دریافت که در روش‌های استفاده از یادگیری ماشین امکان ایجاد تفاوت بین گیر مکانیکی و اختلاف فشاری وجود دارد. مطالعات به طور رایج، به تخمین پیش‌بینی گیر لوله و عدم گیر لوله تمرکز دارند. در بین روش‌های گوناگون یادگیری ماشین، روش شبکه عصبی

<sup>۵</sup> Inoue et al

<sup>۶</sup> Thief zone

<sup>۷</sup> Depleted

<sup>۸</sup> Cavernous

<sup>۱</sup> Alshaikh et al

<sup>۲</sup> Bayan and Zulkarnain

<sup>۳</sup> Tsuchihashi et al

<sup>۴</sup> Convolutional Neural Network (CNN)

۰،۹۵، برای آزمون ۰،۷۶ و برای اعتبارسنجی ۰،۸۲ گزارش شده است.

در مطالعه دیگری توسط لیانگ و همکاران<sup>۵</sup> [۷۹] در سال ۲۰۱۴، اطلاعات چاه *YYL* از ۳۱۲۳،۵ متر تا ۳۱۳۳،۶ متر برای آموزش مدل مبتنی بر یادگیری ماشین مورد استفاده قرار گرفت و از بخش دیگری از چاه *YY* از ۳۱۲۲،۱ متر تا ۳۱۳۱،۴ متر برای آزمون استفاده شد. در مدل دسته‌بندی بیز طراحی شده، از فشار لوله جدار و فشار لوله ایستا به عنوان پارامترهای ورودی مدل استفاده شده است. طبق نتیجه این مطالعه، با تغییر در روند فشار لوله جدار و داده‌های فشار لوله ایستا، امکان تشخیص لرزش کابل حفاری و هرزروی سیال با استفاده از الگوریتم دسته‌بندی بیزین وجود خواهد داشت.

دو مدل هوش مصنوعی از ۱۶۳۰ مجموعه داده از ۳۸ حلقه چاه توسط تاریفی و همکاران<sup>۶</sup> [۸۰] در سال ۲۰۱۴ طراحی شد. هر دو مدل توسط شبکه عصبی مدولار برای پیش‌بینی سیستم گردش هرزروی سیال حفاری در کیفیت و کمیت توسعه داده شدند. سپس از الگوریتم بهینه‌سازی ازدحام ذرات برای به حداقل رساندن هرزروی استفاده شد. با مدل‌سازی انجام شده بر اساس پارامترهایی چون مختصات جغرافیایی (شرق و شمال)، عمق فعلی، عمق سازند، نرخ نفوذ، نوع سازند، حجم فضای حلقوی، فشار گل، سرعت جریان پمپ گل، فشار پمپ گل، گرانیوی فیلتره کیک گل، محتوای جامد، گرانیوی پلاستیک، نقطه تسلیم، استحکام اولیه و استحکام نهایی ۱۰ دقیقه این نتیجه حاصل شد که شبکه عصبی مدولار از نظر دقت برای داده‌های مورد استفاده بهتر از شبکه‌های پرسپترون چندلایه عمل می‌کند. برای انجام این تحقیقات ۶۰ درصد داده‌ها برای آموزش، ۲۰ درصد داده‌ها برای اعتبارسنجی و ۲۰ درصد داده‌ها برای آزمون استفاده شد. دقت دو مدل شبکه‌های پرسپترون چندلایه و شبکه عصبی مدولار در پیش‌بینی کمی و کیفی هرزروی سیال به ترتیب ۰/۹۴ و ۰/۹۸ است.

در مطالعه‌ای دیگر مدل مبتنی بر شبکه عصبی مصنوعی توسط جهان‌بخشی و همکاران [۸۱] در سال ۲۰۱۴ با ۲۶۰

عمق زیاد) تراوایی کمی دارد و بنابراین هیچ مشکلی در هرزروی سیال حفاری ندارد. در نواحی دزدک غیر حفارهای<sup>۱</sup>، سطح گل در مخازن گل به تدریج کاهش می‌یابد و در صورت ادامه حفاری، ممکن است هرزروی کلی گل رخ دهد. پیشگیری کامل از هرزروی سیال حفاری امکان پذیر نیست. دلیل این امر آن است که در حین عملیات حفاری برای دستیابی به منطقه هدف، از برخی سازندهای میان مسیر (مانند سازند شکافدار، مناطق کم فشار، نواحی متخلخل یا مناطق پر تراوا) قابل چشم‌پوشی و اجتناب نمی‌باشند. با این حال، در صورت انجام اقدامات احتیاطی خاص، به ویژه موارد مربوط به شکستگی‌های القایی (ناشی از حفاری)، کاهش هرزروی سیال حفاری امکان‌پذیر است [۷۷]:

- حفظ وزن مناسب گل
  - به حداقل رساندن هرزروی فشار اصطکاکی فضای حلقوی<sup>۲</sup> در حین حفاری و عملیات پیمایش (عملیات لوله پایین)
  - حفظ نظافت کافی حفره چاه و خودداری از تحدید<sup>۳</sup> در فضای آنالوس
  - تعبیه لوله جدار برای محافظت از سازندهای ضعیف فوقانی در طی یک منطقه گذار فشاری
  - به روز رسانی گرادیان فشار تخلخل و شکاف سازند برای نمودار و داده‌های حفاری دقیق‌تر
  - در صورت پیش‌بینی مناطق هرزروی گل حفاری، قبل از حفاری آن منطقه، انجام اقدامات آماده‌سازی گل<sup>۴</sup> با خرده‌های گل از دست رفته
- مطالعه‌ای که توسط مودنی و همکاران [۷۸] در سال ۲۰۱۲ صورت گرفت، از هجده پارامتر شامل عمق فعلی چاه از سطح زمین، عمق سازند آسماری، مختصات مکانی چاه، اندازه مته، متوسط خروجی پمپ، فشار متوسط پمپ، وزن گل، درصد جامد سیال حفاری و مقدار سیال هرزروی شده در روز گذشته از روز مورد نظر برای مدل‌سازی استفاده شد. در این مطالعه از داده‌های ۳۲ چاه برای مدل‌سازی شبکه عصبی مصنوعی بهره گرفته شد. ۷۰ درصد از داده‌های ورودی برای آموزش، ۱۵ درصد برای آزمون و ۱۵ درصد برای اعتبارسنجی در نظر گرفته شد. در نهایت مقدار ضریب همبستگی برای آموزش

<sup>۴</sup> Treating the mud

<sup>۵</sup> Liang et al

<sup>۶</sup> Toreifi et al

<sup>۱</sup> Noncavernous thief zones

<sup>۲</sup> Annular friction pressure losses

<sup>۳</sup> Restrictions

شده از داده‌های جمع آوری شده از ۵۰۰ حادثه هرزروی سیال حفاری، یک بار بصورت جداگانه و باری دیگر بصورت ترکیب طراحی شدند. مدل‌های ترکیب شده نسبت به حالت جداگانه عملکرد بهتری از خود نشان دادند. مدل ترکیبی از شبکه عصبی مصنوعی پرسپترون چند لایه<sup>۲۰</sup> و K\* مبتنی بر نمونه<sup>۲۱</sup> بهترین نتیجه را با دقت ۹۴٫۱ درصد ارائه کرد. بهترین دقت هر الگوریتم بررسی شده در این مطالعه، بصورت جداگانه، برای شبکه عصبی مصنوعی، مبتنی بر نمونه و نایبو بیز به ترتیب ۹۰٫۴ درصد، ۹۳٫۲ درصد و ۹۱٫۶ درصد گزارش شده است.

میزان تاثیر برخی پارامترهای حفاری مانند وزن گل، عمق، فشار پمپ و نرخ جریان پمپ بر روی میزان هرزروی سیال حفاری در مطالعه‌ای توسط بهنود فر و حسینی [۸۵] در سال ۲۰۱۷ انجام گرفت. طی این مطالعه از شبکه عصبی مصنوعی برای پژوهش و مدل‌سازی استفاده شد. به همین منظور از داده‌های مربوط به ۳ حلقه چاه مدل‌سازی انجام شد. ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد داده‌ها برای اعتبارسنجی و ۱۵ درصد داده‌ها برای آزمون استفاده شدند. در این مطالعه یک معادله با دقت ۰٫۹۹۹۱ برای نشان دادن تاثیر فشار پمپ و نرخ جریان پمپ بر روی میزان هرزروی سیال حفاری و معادله دیگری با دقت ۰٫۹۹۸۸ برای نشان دادن تاثیر فشار پمپ و وزن گل بر روی میزان هرزروی سیال حفاری ارائه شده است. نتیجه حاصل از این پژوهش نشان می‌دهد که هرزروی سیستم گل با افزایش فشار پمپ و همچنین وزن گل افزایش می‌یابد اما با افزایش دبی پمپ به دلیل تمیز کردن دهانه چاه و خارج شدن ذرات، کاهش می‌یابد.

مجموعه نقطه داده از عمق، متوسط فشار پمپ، نرخ نفوذ، خواص گل حفاری و خواص سنگ طراحی شد. در این مدل توسعه داده شده، هرزروی سیال با دقت ۹۴ درصد تخمین زده شد.

وو و همکاران<sup>۱</sup> [۸۲] در سال ۲۰۱۶ با تکیه بر ادبیات مطالعه خود از ۲۱ عامل حساس شامل طراحی غیر منطقی چگالی سیال حفاری<sup>۲</sup>، خرابی دبی سنج<sup>۳</sup>، میکرو شکاف طبیعی<sup>۴</sup>، فشار شکاف سازند کوچک<sup>۵</sup>، تخلخل سازند بزرگ<sup>۶</sup>، شکست لوله جداری، شکست سیمان<sup>۷</sup>، افزایش سرعت لوله حفاری<sup>۸</sup>، اثر دمای بالا، گرانبوی بالای سیال حفاری، پمپ خروجی دکل بزرگ<sup>۹</sup> و فشار پمپ بالا<sup>۱۰</sup> برای مدل‌سازی شبکه بیزین دینامیک استفاده کردند. در این مطالعه خطر از دست دادن سیستم گردش گل برای فاز یا سناریوهای زیر در نظر گرفته شد: «عدم وجود سیستم گردش گل<sup>۱۱</sup>»، «عملیات لوله پایین<sup>۱۲</sup>» و «وجود سیستم گردش گل<sup>۱۳</sup>». عوامل «چگالی منطقی سیال حفاری<sup>۱۴</sup>» و «در دسترس بودن اجزای سیستم حفاری تحت فشار مدیریت شده<sup>۱۵</sup>» مهم‌ترین عوامل در کاهش هرزروی سیال بودند. در سال ۲۰۱۹ وو و همکاران [۸۳] مطالعه مشابه دیگری را با استفاده از الگوریتم استنتاج بیزین و پارامترهای پدال خروج گل، فشار لوله ایستا، حجم کل گودال<sup>۱۶</sup> و سرعت جریان گل انجام دادند که علاوه بر تکیه بر اهمیت الگوی یادگیری ماشین در کاهش زمان محاسبات به این نتیجه پی بردند که ترکیب تشخیص مبتنی بر آستانه دینامیکی و تخمین بیزی می‌تواند عملکرد را بهبود بخشد. (همچنین مطالعه مشابه دیگر مبتنی بر شبکه عصبی مصنوعی، مبتنی بر نمونه<sup>۱۷</sup> و نایبو بیز<sup>۱۸</sup> توسط لیته کریستوفارو و همکاران<sup>۱۹</sup> [۸۴] در سال ۲۰۱۷ برای پیش‌بینی هرزروی سیال حفاری انجام شد. مدل‌های ایجاد

<sup>۱۲</sup> Tripping in

<sup>۱۳</sup> Circulating.

<sup>۱۴</sup> Reasonable drilling fluid density

<sup>۱۵</sup> Availability of the components of Managed pressure drilling (MPD) system

<sup>۱۶</sup> Total volume of pit

<sup>۱۷</sup> Instance-based

<sup>۱۸</sup> Naive Bayes

<sup>۱۹</sup> Leite Cristofaro et al

<sup>۲۰</sup> Multilayer Perceptron (MLP) Neural Network

<sup>۲۱</sup> KStar instance-based classifier (K\*)

<sup>۱</sup> Wu et al

<sup>۲</sup> Unreasonable design of drilling fluid density

<sup>۳</sup> Flow meter failure.

<sup>۴</sup> Natural micro fracture,

<sup>۵</sup> Low formation fracture pressure

<sup>۶</sup> Large formation porosities

<sup>۷</sup> Cement failure

<sup>۸</sup> Increased running drill pipe rate

<sup>۹</sup> Large rig pump out

<sup>۱۰</sup> High pump pressure

<sup>۱۱</sup> Not circulating

شد. در نهایت مدل درخت تصمیم بهترین دقت را با ضریب همبستگی ۰,۹۳۵۵ و خطای جذر میانگین مربعات ۰,۰۹۱ از خود نشان داد.

جنگ و همکاران<sup>۷</sup> [۸۹] در سال ۲۰۱۹ به توسعه یک مدل از ترکیب سه الگوریتم جنگل تصادفی، ماشین بردار پشتیبان و رگرسیون لجستیک<sup>۸</sup> پرداختند. آن‌ها در این مطالعه از ۲۱۸۴۰۰ نقطه داده تخمینی استفاده کردند. پارامترهای استفاده شده در این مطالعه برای ارتباط‌گیری با هرزروی سیال، در مدل مورد بررسی، شامل داده‌های لرزه‌ای (واریانس، دامنه، شدت و غیره) می‌باشد. مدل توسعه داده شده احتمال وقوع هرزروی سیال در ۶ حلقه چاه را در محدوده دقت ۸۰ درصد تا ۱۰۰ درصد تخمین زد.

مطالعه‌ای توسط آلکینانی و همکاران<sup>۹</sup> [۹۰] برای مدل‌سازی شبکه عصبی مصنوعی با هدف تخمین نرخ هرزروی سیال حفاری در سال ۲۰۱۹ انجام شد که در آن از ۱۰۰۰۰ مجموعه پارامتر حفاری برای طراحی مدل استفاده شد. پارامترهای حفاری استفاده شده شامل وزن گل، چگالی گردشی معادل، گرانیوی پلاستیک، نقطه تسلیم، گردش بر دقیقه، وزن روی مته، نرخ جریان و سطح جریان کل نازل‌های مته می‌باشد. شبکه عصبی مصنوعی با عملکرد ۹۲,۵ درصد نرخ هرزروی سیال را پیش‌بینی کرد.

راه حل سریع مبتنی بر دو روش یادگیری ماشین توسط احمد عباس و همکاران [۹۱] در سال ۲۰۱۹ برای مطالعه هرزروی سیال انجام شد. از ۱۱۲۰ نقطه داده برای مدل‌سازی شبکه عصبی مصنوعی و ماشین بردار پشتیبان استفاده شد. داده‌ها به نسبت ۱:۳ برای آموزش و آزمون تقسیم شدند. مجموعه پارامترهای ورودی به مدل سنگ‌شناسی، وزن گل، نرخ جریان، نرخ نفوذ، فشار سیال، شیب، محتوای جامد، هرزروی سیال، دور بر دقیقه، وزن روی مته، نقطه تسلیم، گرانیوی پلاستیک، گرانیوی قیف مرداب، استحکام ژل ۱۰ ثانیه، استحکام ژل ۱۰ دقیقه، آزیموت، عمق و قطر چاه اندازه‌گیری شده می‌باشد. عملکرد ضریب همبستگی برای مجموعه آموزش و آزمون در روش شبکه عصبی مصنوعی به ترتیب

لی و همکاران<sup>۱</sup> [۸۶] در سال ۲۰۱۸ به مقایسه عملکرد چند الگوریتم یادگیری ماشین (شبکه عصبی مصنوعی، ماشین بردار پشتیبان و جنگل تصادفی) در پیش‌بینی هرزروی سیال حفاری پرداختند. از عمق، پارامترهای حفاری (مانند نرخ نفوذ، فشار پمپ و نرخ گل ورودی)، خصوصیات گل (مانند وزن گل، نقطه تسلیم، استحکام ژل)، فشار حفرات، سنگ‌شناسی سازند و ... برای توسعه این مدل‌ها بهره برده شد. در این مطالعه نشان داده شد که جنگل تصادفی و سپس ماشین بردار پشتیبان عملکرد بهتری نسبت به شبکه عصبی مصنوعی داشتند. دقت شبکه عصبی مصنوعی، ماشین بردار پشتیبان و جنگل تصادفی به ترتیب ۴۶,۶ درصد، ۵۵ درصد و ۵۶ درصد گزارش شده است. برای مدل‌سازی این الگوریتم‌ها ۶۹۷۶ مجموعه نقطه داده حفاری مورد مطالعه قرار گرفته شده است. الحمیدی و همکاران<sup>۲</sup> [۸۷] در سال ۲۰۱۹ با الگوریتم متفاوتی تحت عنوان رگرسیون خطی چندگانه<sup>۳</sup> به تخمین هرزروی سیال حفاری به کمک پارامترهای حفاری و خصوصیات گل (مانند نرخ نفوذ، وزن روی مته، نرخ جریان، وزن گل، گرانیوی پلاستیک، نقطه تسلیم، دور بر دقیقه و ...) پرداختند. در این مطالعه از مجموعه داده ۵۰۰ چاه برای مدل‌سازی استفاده شده است. این الگوریتم با دقت بالای ۹۰ درصد قادر به تخمین هرزروی سیال حفاری می‌باشد.

صباح و همکاران [۸۸] در سال ۲۰۱۹ مدل‌های پیش‌بینی‌کننده هوشمند شامل درخت تصمیم، سیستم‌های استنتاج عصبی فازی تطبیقی<sup>۴</sup> و شبکه‌های عصبی را برای تخمین میزان هرزروی گردش گل در یکی از میداین ایران به کار گرفتند. پارامترهای ورودی مدل از ۱۹۰۰ نقطه داده از ۶۱ چاه، شامل عمق، اندازه حفره، وزن روی مته، دبی پمپ، فشار پمپ، گرانیوی، تنش‌های برشی<sup>۵</sup> در نرخ‌های برشی<sup>۶</sup> ۶۰۰ و ۳۰۰ دور در دقیقه، استحکام ژل، زمان حفاری، درصد جامد حاصل از آزمایش تقطیر، سرعت چرخش مته، نوع سازند، فشار منفذی، مترای حفاری، زمان حفاری، فشار گل حفاری و فشار شکست سازند بود. ۷۰ درصد از پارامترهای ورودی برای آموزش و ۳۰ درصد برای آزمون به کار گرفته

<sup>۵</sup> Shear stress<sup>۶</sup> Shear rate<sup>۷</sup> Geng et al<sup>۸</sup> Logistic regression (LR)<sup>۹</sup> Alkinani et al<sup>۱</sup> Li et al<sup>۲</sup> AI-Hameedi et al<sup>۳</sup> Multiple Linear Regressions (MLR)<sup>۴</sup> Adaptive neuro-fuzzy inference system (ANFIS)

۰,۸۸ و ۰,۸۴ درصد گزارش شده است. عملکرد ضریب همبستگی برای مجموعه آموزش و آزمون در روش ماشین بردار پشتیبان نیز به ترتیب ۰,۹۷ و ۰,۹۵ درصد می‌باشد. براساس نتایج گزارش شده در این مطالعه ماشین بردار پشتیبان کمی بهتر از شبکه عصبی مصنوعی عمل کرده است. بر اساس اهمیت پارامترهای ورودی، سنگ‌شناسی، وزن گل، نرخ جریان، نرخ نفوذ، فشار سیال، شیب و محتوای جامد بیشترین تاثیرگذاری را بر خروجی مدل داشتند.

هو و همکاران<sup>۱</sup> [۹۲] در سال ۲۰۲۰ طی یک مطالعه‌ای به کمک اطلاعات ۵۰ چاه و شبکه عصبی مصنوعی نرخ هرزروی سیال را با دقت ۹۱ درصد تخمین زدند. آن‌ها در این مطالعه از برخی پارامترهای حفاری مانند سنگ‌شناسی، فشار شکاف، فشار حفرات، عمق، وزن روی مته، دور بر دقیقه، فشار ایستا لوله استفاده کردند.

مدلی مبتنی بر سیستم‌های استنتاج عصبی فازی تطبیقی توسط آگین و همکاران<sup>۲</sup> [۹۳] در سال ۲۰۱۸ توسعه داده شد که در آن با استفاده از ۲۴۰۰ نقطه داده به تخمین هرزروی گردش سیال پرداخته شده است. این داده‌ها از ۶۱ جلقه چاه استخراج شده‌اند. مدل توسعه داده شده پیش‌بینی‌های قابل اعتمادی با مقدار خطا ریشه میانگین مربع، آموزش، آزمون و اعتبارسنجی به ترتیب ۰,۰۸، ۰,۰۹ و ۰,۱۵ ارائه کرد.

مطالعه اخیر در سال ۲۰۲۲ حول محور پیش‌بینی هرزروی گردش گل حفاری توسط جعفری‌زاده و همکاران [۹۴] انجام شد که در آن از مدل‌هایی مبتنی بر الگوریتم شبکه عصبی کانولوشنال، ماشین یادگیری افراطی چند لایه<sup>۳</sup>، ماشین بردار پشتیبانی حداقل مربع<sup>۴</sup> با الگوریتم بهینه‌سازی فاخته<sup>۵</sup>، بهینه‌سازی ازدحام ذرات<sup>۶</sup> و الگوریتم ژنتیک<sup>۷</sup> با تکیه بر داده‌های حفاری و اطلاعات زمین‌شناسی ۳۰۵ حلقه چاه طراحی شد. پارامترهای حفاری ورودی به مدل شامل فشار پمپ، وزن گل، فشار شکاف، فشار حفرات، عمق، استحکام ژل ۱۰ دقیقه، استحکام ژل ۱۰ ثانیه، دبی جریان و نوع سازند است. در این مطالعه الگوریتم شبکه عصبی کانولوشنال با دقت ۰,۹۸ عملکرد بالاتری نسبت به دیگر الگوریتم‌های استفاده

شده در این مطالعه از خود نشان داد. مطالعه دنگ و همکاران [۹۵] در سال ۲۰۲۳ شامل استفاده از الگوریتم بهینه شده ماشین بردار پشتیبان برای پیش‌بینی هرزروی گردش گل حفاری می‌باشد. آن‌ها در مطالعه خود با استفاده از ۱۵ مجموعه داده‌های چاه‌پیمایی برای مدل‌سازی، یک رویکرد جدید با ترکیب تحلیل مؤلفه‌های اصلی<sup>۸</sup> و تحلیل تجربی برای کاهش ابعاد داده‌های مدل پیشنهاد دادند. همچنین در این مطالعه ذکر شده است که مدل پیش‌بینی بهبودیافته با عملکرد مناسب، با تکرار کم، دقتی معادل ۹۶ درصد دارد.

به طور خلاصه، در رابطه با کاربرد الگوریتم‌های یادگیری ماشین در کاهش هرزروی سیستم گردش گل می‌توان دریافت که مطالعات بطور عمده بر نرخ هرزروی سیال یا حجم گل از دست رفته معطوف می‌باشد. روش شبکه عصبی مصنوعی بیشترین استفاده را در میان دیگر روش‌های یادگیری ماشین دارد. این درحالی است که سایر الگوریتم‌های یادگیری ماشین مانند ماشین بردار پشتیبان و جنگل تصادفی (با آموزش مجموعه نقطه داده یکسان) عملکرد بهتری نسبت به روش شبکه عصبی مصنوعی داشته‌اند. در برخی دیگر از مطالعات مدل توسعه داده شده توسط الگوریتم شبکه عصبی مصنوعی دقتی فراتر از ۹۰ درصد را دارا بود. علاوه بر الگوریتم‌های ذکر شده، الگوریتم بیزین نیز از دیگر روش‌های هوشمند رایجی بود که برای تخمین میزان هرزروی سیال در مطالعات مورد استفاده قرار گرفته بود. محدوده دقت الگوریتم‌های بکاربرده شده با عملکرد عالی در مطالعات بصورت زیر می‌باشد.

شبکه عصبی مصنوعی: ۴۶ درصد تا ۹۹ درصد، ماشین بردار پشتیبان: ۵۵ درصد تا ۹۶ درصد، جنگل تصادفی: ۵۶ درصد تا ۹۳ درصد.

مینیموم تعداد داده‌های بکاربرده شده در مطالعات برای مدل‌سازی ۲۶۰ نقطه داده و ماکسیمم تعداد داده‌ها ۲۱۸۴۰۰ نقطه داده می‌باشد. عمق، پارامترهای فشار (به عنوان مثال لوله ایستا، لوله جداری، فشار پمپ)، دبی پمپ، سنگ‌شناسی، وزن گل، درصد جامد سیال حفاری، گرانروی گل، نقطه

<sup>۵</sup> Cuckoo optimization algorithm (COA)

<sup>۶</sup> Particle swarm optimization (PSO)

<sup>۷</sup> Genetic algorithm (GA)

<sup>۸</sup> Principal component analysis (PCA)

<sup>۱</sup> Hou et al

<sup>۲</sup> Agin et al

<sup>۳</sup> Multilayer extreme learning machine

<sup>۴</sup> Least square support vector machine (LSSVM)



بالای ۸۰ درصد چگالی شکاف را تخمین زد. نتایج این مطالعه نشان می‌دهد که داده‌های چاه‌پیمایی صوتی، قطرسنج و چگالی بهترین همبستگی را با تراکم شکست برای هشت حلقه چاه مورد مطالعه داشتند. همچنین ملاالله و سامی نشاوی<sup>۳</sup> [۹۸] با استفاده از شبکه عصبی مصنوعی و پارامترهای ورودی شامل گرادبان فشار حفرات، عمق و چگالی سنگ به مدل‌سازی مبتنی بر یادگیری ماشین پرداختند. آن‌ها در مطالعه خود از ۲۱۵۱۳ نقطه داده از شانزده چاه در هفت منطقه مختلف زمین‌شناسی استفاده کردند که ۲۰۹۷۵ نقطه داده از پانزده چاه برای آموزش و ۵۳۷ نقطه داده از شانزده چاه برای آزمون استفاده شد. بیش‌ترین درصد میانگین خطای نسبی مطلق شبکه عصبی مصنوعی در تمامی چاه‌ها ۰,۰۹ درصد گزارش شده است. در این مطالعه شبکه عصبی مصنوعی نتایج بهتری نسبت به روابط تجربی موجود در تمامی چاه‌ها در پیش‌بینی گرادبان شکست به دست آورد.

مطالعات چاغو و همکاران<sup>۴</sup> [۹۹] و فنگ و همکاران<sup>۵</sup> [۱۰۰] از دیگر مطالعاتی هستند که در آن با استفاده از شبکه عصبی مصنوعی به پیش‌بینی فشار شکاف پرداخته شده است، در این دو مطالعات از داده‌های مغزه و داده‌های چاه‌پیمایی نظیر آمپدانس موج<sup>۶</sup> به عنوان پارامترهای ورودی به مدل استفاده شده است. دقت این الگوریتم در تخمین فشار شکاف در مطالعه چاغو و همکاران بالای ۹۱ درصد و در مطالعه فنگ و همکاران حدود ۶۰ درصد گزارش شده است.

اشرف و همکاران<sup>۷</sup> [۱۰۱] طی پژوهشی از شرطی‌سازی داده‌ها با استفاده از فیلتر زمین آماری یکپارچه برای محاسبه شیب و آزیموت و همچنین فیلتر ساختاری<sup>۸</sup> برای بهبود خصوصیات ساختاری مانند گسل‌ها و شکستگی‌ها بهره بردند. آن‌ها از آنالیز چندگانه<sup>۹</sup>، شبکه‌های عصبی و ردیابی مورچه مصنوعی<sup>۱۰</sup> برای شناسایی پارامترهای شکست استفاده کردند. الگوریتم بهینه‌سازی کلونی مورچه‌ها<sup>۱۱</sup> به طور موثر برای مطالعه شیب، طول، آزیموت و مساحت سطح شکستگی‌ها استفاده شد. روش‌های مورد استفاده در این مطالعه برای ترسیم گسل‌ها و

تسلیم، استحکام زل و وزن روی مته بیشترین پارامترهایی بودند که در مطالعات به عنوان ورودی مدل برای تخمین مقدار هرزروی سیال استفاده شده‌اند. لذا انتخاب مناسب مقادیر این پارامترها می‌تواند تاثیر بسزایی در جلوگیری از رخ دادن هرزروی سیال حفاری داشته باشد.

### ۳,۳. شکستگی

شکستگی هنگامی اتفاق می‌افتد که فشار سیال حفاری از فشار شکست سازند بیشتر شود. از مشکلات مرتبط با شکست سازند هرزروی سیال حفاری و احتمال وقوع لرزش کابل حفاری می‌باشد [۹۶]. با شکست سازند چاه ناپایدار شده و امکان ریزش چاه و از دست رفتن چاه را به دنبال دارد. عمده‌ترین علت شکستگی‌های القایی، نتیجه فشارهای بیش از اندازه ته چاهی و عمق نامناسب جداره رانی میانی، به ویژه در منطقه گذار<sup>۱</sup> است. شکستگی‌های القایی یا طبیعی ممکن است در عمق کم، افقی یا در عمق بیش از ۲۵۰۰ فوت، عمودی باشند. فشار بیش از حد چاه در اثر بالا بودن میزان نرخ جریان (زیاد از دست دادن فشار اصطکاک فضای حلقوی (آنالوس)) یا عملیات پیمایش بسیار سریع (کوبه فشار<sup>۲</sup> زیاد) ایجاد می‌شود، که می‌تواند منجر به چگالی گردشی معادل بالا شود. علاوه بر این موارد، موردهای دیگری مانند تمیز کردن نامناسب فضای حلقوی چاه، وزن زیاد گل، یا بستن یک چاه در فشار بالا نیز می‌تواند منجر به ایجاد شکستگی شود [۹۶]. از کاربردهای یادگیری ماشین در تخمین فشار شکاف می‌توان به مطالعه تخمه چی و همکاران [۹۷] اشاره کرد. در این مطالعه از رگرسیون خطی و توانی برای ارتباط‌سازی بین داده‌های چاه‌پیمایی و چگالی شکاف استفاده شده است. این داده‌های چاه‌پیمایی شامل داده‌های قطرسنجی، صوتی، چگالی و سنگ‌شناسی است. تمامی این داده‌های به کار برده شده، از هشت چاه برای برازش معادلات خطی و توانی (بدون در نظر گیری داده‌های آموزش و آزمون جداگانه) استفاده شدند. رگرسیون غیر خطی حاصل با دقت ضریب همبستگی

<sup>۱</sup> Transition zone

<sup>۲</sup> Surge pressure

<sup>۳</sup> Malallah and Nashawi

<sup>۴</sup> Chao et al

<sup>۵</sup> Fang et al

<sup>۶</sup> Wave impedance

<sup>۷</sup> Ashraf et al

<sup>۸</sup> Structural filtering

<sup>۹</sup> Multi-attribute analysis

<sup>۱۰</sup> Artificial ant-tracking

<sup>۱۱</sup> Ant-colony optimization (ACO)

شکستگی‌های کوچک مقیاس، استفاده ترکیبی از شرطی‌سازی داده، آنالیز چندگانه (با استفاده از شیب، انحنا، وارپانس، شباهت، احتمال خطای نازک‌شده، تراکم شکست و مجاورت شکست) را شامل می‌شود. از پارامترهای شیب قطبی<sup>۱</sup>، تشابه افزایش گسل<sup>۲</sup>، احتمال نازک شدن گسل<sup>۳</sup>، حداکثر انحنا<sup>۴</sup>، چگالی شکست، نزدیکی به شکست<sup>۵</sup> به عنوان پارامترهای ورودی به شبکه عصبی مصنوعی و رویکرد بهینه‌سازی کلونی مورچه‌ها استفاده کردند. دقت حاصل از تخمین چگالی شکست در این مطالعه ۱۰۰ درصد ارائه شده است.

مطالعه با هدف تخمین شکاف‌های موجود در نمونه مغزه با استفاده از الگوریتم توأم شبکه عصبی مصنوعی و الگوریتم ژنتیک<sup>۶</sup> توسط سو و همکاران<sup>۷</sup> [۱۰۲] انجام گرفت. در این مطالعه از ۶۱ نقطه داده استفاده شد که در نهایت مدل آموزش دیده نتایج کاملاً ثابتی را برای پیش‌بینی شکستگی‌ها در نمونه‌های مغزه ارائه کرد. محدوده دقت تخمین شکاف در مغزه‌ها توسط الگوریتم مورد استفاده از ۷۳ درصد تا ۹۹ درصد متغیر بوده است.

روی و همکاران<sup>۸</sup> [۱۰۳] علاوه بر استفاده از شبکه عصبی مصنوعی، از الگوریتم‌های دیگر سیستم‌های استنتاج عصبی فازی تطبیقی، سیستم استنتاج فازی<sup>۹</sup> و تحلیل رگرسیون چندگانه<sup>۱۰</sup> برای آموزش ۳۶ مجموعه داده و آزمون ۱۰ مجموعه داده برای توسعه مدل استفاده کردند. پارامترهای مورد استفاده در توسعه این مدل، استحکام کششی، سرعت موج فشارشی و سرعت موج برشی می‌باشد. در پیش‌بینی چقرمگی شکست حالت-۱<sup>۱۱</sup>، سیستم‌های استنتاج عصبی فازی تطبیقی بهترین عملکرد را داشت و پس از آن سیستم استنتاج فازی و شبکه عصبی مصنوعی عملکرد خوبی داشتند. تحلیل رگرسیون چندگانه کمترین عملکرد را داشت. سروش و همکاران [۱۰۴] با استفاده از داده‌های چاه‌پیمایی

صوتی، اشعه گاما، مقاومت، تخلخل، چگالی، فاکتور فوتوالکتریک، قطر سنج، وزن گل و تنش عمودی برجا به تعیین مناطق شکست پرداختند. آن‌ها از الگوریتم دسته‌بندی بیزین و داده‌های چهار چاه حفر شده برای مدل‌سازی استفاده کردند. از حدود ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای آزمون در مدل‌سازی بهره بردند. در این مطالعه دسته‌بندی‌کننده بیزین بر روی داده‌های بدون نویز، مناطق شکست و مناطق بدون شکست در چاه‌ها را با دقت متوسط بین ۷۸ تا ۹۳ درصد بسته به چاه‌های آزمون مورد استفاده، شناسایی کرد.

زروکی و همکاران<sup>۱۲</sup> [۱۰۵] با استفاده از داده‌های چاه‌پیمایی (چگالی، تخلخل نوترون و زمان گذرا<sup>۱۳</sup>) و خصوصیات گل (چگالی سیال و زمان گذرا اشباع سیال<sup>۱۴</sup>) به تخمین تخلخل شکاف پرداختند. آن‌ها از شبکه عصبی مصنوعی و منطق فازی به همراه ۴۲۰ نقطه داده از یک حلقه چاه واحد در مطالعه خود استفاده کردند. آن‌ها از رتبه‌بندی فازی برای رتبه دادن به داده‌های چاه‌پیمایی ورودی به همراه میزان تأثیر در خروجی مورد نظر شبکه عصبی مصنوعی استفاده کردند. نتایج بدست آمده از این مطالعه بر مهم بودن تمامی پارامترهای استفاده شده، تأکید دارد. ضریب همبستگی بین تخلخل شکست طبیعی به دست آمده از شبکه عصبی مصنوعی و داده‌های چاه‌پیمایی در ارزیابی چاه دیگری برابر با ۰.۸۷۸ گزارش شده است.

زازون<sup>۱۵</sup> [۱۰۶] طی انجام پژوهشی به ساخت مدلی پرداخت تا بتواند چگالی شکست را از داده‌های چاه‌پیمایی معمولی کالیبره شده با داده‌های مغزه با استفاده از شبکه عصبی مصنوعی پیش‌بینی کند. برای این منظور ۱۷۰ مغزه از ۱۷ حلقه چاه غیر جهت‌دار به تفصیل بررسی شد. پارامترهای ورودی به مدل شامل عمق مته، داده‌های چاه‌پیمایی (قطر سنج، نوترون تخلخل، اشعه گاما، زمان گذرا، صوتی<sup>۱۶</sup> و

<sup>۹</sup> Fuzzy inference system

<sup>۱۰</sup> Multiple Regression Analysis

<sup>۱۱</sup> Mode-I fracture toughness

<sup>۱۲</sup> Zerrouki et al

<sup>۱۳</sup> Transit time

<sup>۱۴</sup> Transit time of the saturating fluid

<sup>۱۵</sup> Zazoun

<sup>۱۶</sup> Sonic interval transit time

<sup>۱</sup> Polar-dip

<sup>۲</sup> Fault-enhancement Similarity

<sup>۳</sup> Thinned-fault likelihood

<sup>۴</sup> Maximum-curvature

<sup>۵</sup> Fracture-proximity

<sup>۶</sup> Genetic algorithm (GA)

<sup>۷</sup> Xue et al

<sup>۸</sup> Roy et al

چگالی پیکره‌ای) می‌باشد. طبق گزارش این مطالعه توافق خوبی بین پیش‌بینی مدل شبکه عصبی و اندازه‌گیری‌های شکست مغزه با دقت بالای ۸۰ درصد بدست آمد.

آبدیده [۱۰۷] در مطالعه خود از داده‌های چاه‌پیمایی پتروفیزیکی با استفاده از داده‌های چاه‌پیمایی قطرسنجی، صوت، چگالی و سنگ‌شناسی به دست آمده در ناحیه شکست به توسعه مدل یادگیری ماشین پرداخت. وی داده‌های یک چاه را برای برآزش معادلات خطی و توانی استفاده کرد. در نهایت رگرسیون توانی، ضریب همبستگی بهتری (بالای ۸۵ درصد) نسبت به رگرسیون خطی در تخمین چگالی شکست داشت.

بر اساس مطالعات موجود و ادبیات موضوع در رابطه با شکستگی می‌توان دریافت که عملکرد روش‌های یادگیری ماشین را می‌توان با نرمال کردن داده‌ها، حذف داده‌های پرت، انتخاب موثرترین پارامترها بر شکستگی (با تکیه بر مطالعات پیشین و انجام آزمون و خطا) و همچنین بهینه کردن الگوریتم‌ها افزایش داد. ابتدا شبکه عصبی مصنوعی و سپس روش رگرسیون در بین تمام روش‌های یادگیری ماشین استفاده شده در پیش‌بینی شکست بسیار رایج‌تر بوده و به عنوان محبوب‌ترین روش‌ها به حساب می‌آیند. الگوریتم شبکه عصبی مصنوعی توانایی عملکرد بهتری از معادلات تجربی موجود را نشان می‌دهد و در مطالعاتی که با دیگر الگوریتم‌ها توأم‌سازی شده است، با توانایی بالایی در پیش‌بینی همراه بوده است؛ اما این روش در تقابل با دیگر الگوریتم‌های یادگیری ماشین مانند سیستم‌های استنتاج عصبی فازی تطبیقی عملکرد ضعیف‌تری دارد. بطور کلی دقت شبکه عصبی مصنوعی با تکیه بر مطالعات پیشین برای پیش‌بینی شکست (یا ویژگی‌های شکست) در محدوده ۶۰ درصد تا ۹۹ درصد گزارش شده است. مهم‌ترین پارامترهایی که در اکثر مطالعات در مسیر توسعه مدل برای پیش‌بینی شکست استفاده شده‌اند شامل داده‌های چاه‌پیمایی (صوتی، قطرسنج، مقاومت، تخلخل و چگالی) و سنگ‌شناسی می‌باشند.

### ۴.۳. لرزش کابل حفاری

لرزش کابل حفاری می‌تواند به دلیل چندین دسته از عوامل مرتبط با فشار هیدرواستاتیک (مانند فشار غیرعادی حفارات، هرزروی سیال حفاری)، سیمان (به عنوان مثال اتصال ناکافی)، یا تجهیزات کنترل فشار برای حفاری تحت فشار ایجاد شود. لرزش کابل حفاری حادثه خطرناکی است که بطور مستقیم از استفاده از چگالی نادرست سیال حفاری به شدت تحت تاثیر قرار می‌گیرد؛ به بیان دیگر، هنگامی که گرادیان فشار ناشی از چگالی سیال حفاری کمتر از گرادیان فشار حفاری باشد، لرزش کابل حفاری ممکن است رخ دهد [۱۰۸]. تشخیص زودهنگام لرزش کابل حفاری در عملیات کنترل چاه و در جلوگیری از فوران احتمالی کنترل نشده بسیار مهم است. موارد زیر نشانه‌های رایجی هستند که احتمال وقوع لرزش کابل حفاری را بیان می‌کنند [۱۰۹]:

- افزایش ناگهانی بازگشت گل به سطح
- افزایش ناگهانی نرخ حفاری (شکست حفاری)<sup>۱</sup>
- کاهش ناگهانی فشار لوله حفاری در حال گردش<sup>۲</sup>
- پر کردن مجدد چاه<sup>۳</sup> کمتر از حد معمول در حین عملیات لوله بالا<sup>۴</sup>

پیش‌بینی احتمال لرزش کابل حفاری برای جلوگیری از حوادث پر مخاطره دیگری مانند فوران چاه، از موضوعات پر اهمیتی می‌باشد.

کامیاب و همکاران [۱۱۰] در سال ۲۰۱۰ با استفاده از روش شبکه عصبی مصنوعی به مطالعه ۴ چاه حفاری شده پرداختند. پارامترهای چاه استفاده شده در این مطالعه شامل عمق، نرخ نفوذ، وزن روی مته، بار قلاب<sup>۵</sup>، داده‌های ثبت شده توسط سنسور جلوگیری از فوران<sup>۶</sup> می‌باشد. الگوریتم استفاده شده در این مطالعه با دقت ۹۶٫۵ درصد لرزش کابل حفاری را پیش‌بینی کرد.

۱۲۲۰۰۰ مجموعه نقطه داده از بار قلاب، نرخ جریان، گشتاور، نرخ نفوذ، فشار گیج و غیره به عنوان پارامترهای ورودی با استفاده از پنج الگوریتم یادگیری ماشین توسط علوهالی و همکاران<sup>۷</sup> [۱۱۱] در سال ۲۰۱۸ مدل‌سازی شدند. الگوریتم‌های استفاده شده درخت تصمیم، نزدیک‌ترین همسایه- $k$ ، شبکه عصبی مصنوعی، حداقل بهینه‌سازی

<sup>۱</sup> Hook load

<sup>۲</sup> Blowout preventer (BOP)

<sup>۷</sup> Alouhali et al

<sup>۱</sup> Drilling break

<sup>۲</sup> Circulating drill pipe pressure

<sup>۳</sup> Hole refilling

<sup>۴</sup> Tripping out

خطای مطلق مدل ژنتیک و شبکه عصبی به ترتیب ۰,۰۲ و ۰,۱۱ بدست آمده است. آن‌ها همچنین یادآور شدند که دقت الگوریتم ژنتیک در مقایسه با اجرای معمولی شبکه عصبی پس انتشار (با استفاده از گرادینان تابع خطا که می‌تواند منجر به گیرکردن در حداقل محلی شود) بهتر عمل کرده و پیش‌بینی را بهبود می‌بخشد.

سی و همکاران<sup>۱۰</sup> [۱۱۴] در سال ۲۰۱۸ نیز با استفاده از الگوریتم توأم شبکه عصبی مصنوعی و ژنتیک به آموزش ۱۰۰۰ گزارش و ارزیابی مدل توسعه داده شده با ۴۴۰ گزارش پرداختند. آن‌ها نیز به این نتیجه دست یافتند که استفاده از الگوریتم ژنتیک باعث بهبود زمان آموزش مدل و دقت پیش‌بینی شبکه عصبی می‌شود. میانگین کل خطاهای پیش‌بینی مطلق الگوریتم شبکه عصبی بهینه شده با ژنتیک ۰,۰۸ است؛ طبق نتایج حاصل از این مطالعه، این الگوریتم قادر است لرزش کابل را در کمتر از یک ثانیه پیش‌بینی کند. در این مطالعه از پارامترهای نرخ نفوذ، جرم در واحد حجم سیال حفاری، وزن گل ورودی، وزن گل خروجی از چاه، وزن گل در گردش و عمق چاه برای ارتباط‌سازی مدل با وقوع لرزش کابل حفاری استفاده شده است.

آدیدیگا و همکاران<sup>۱۱</sup> [۱۱۵] در سال ۲۰۱۸ به آموزش شبکه بیزین با استفاده از فشار گل، فشار شکاف و فشار حفارات پرداختند. وقوع لرزش کابل حفاری وابسته به زمان برای ۳۵ نقطه داده ارزیابی شد و در نتیجه الگوریتم نابیو بایز یک رویکرد کارآمد برای پیش‌بینی ریسک دینامیکی عملیات حفاری ارائه کرد.

مطالعه‌ای توسط فجتلند و همکاران<sup>۱۲</sup> [۱۱۶] در سال ۲۰۱۹ برای تخمین و تعیین لرزش کابل حفاری، با استفاده از ۵۷۸۱ نقطه داده انجام شد. پارامترهای استفاده شده در این مطالعه برای ورودی مدل هوشمند شامل فشار چوک، نرخ جریان ورودی، نرخ جریان خروجی، میزان قطر چوک، فشار لوله ایستا و ... است؛ همچنین الگوریتم استفاده شده نیز شبکه بیزین می‌باشد. الگوریتم شبکه بیزین با محدوده دقت ۵۶,۷ درصد

متوالی<sup>۱</sup> و شبکه بیزین می‌باشد. عملکرد این پنج الگوریتم برای پیش‌بینی خروجی مدل یعنی لرزش کابل حفاری با یکدیگر مقایسه شدند. نزدیکترین همسایگان- $k^2$  و درخت تصمیم به ترتیب با دقت ۹۹ درصد و ۹۸ درصد بهترین عملکرد را نسبت به دیگر الگوریتم‌های استفاده شده در این مطالعه داشتند.

لیانگ و همکاران<sup>۳</sup> [۷۹] در سال ۲۰۱۴ از فشار لوله ایستا<sup>۴</sup> و فشار لوله جداری<sup>۵</sup> و با به کارگیری الگوریتم تفکیک‌کننده بیز<sup>۶</sup> به تخمین وقوع لرزش کابل حفاری پرداخت. مقطعی از چاه مورد مطالعه اول از ۲۳۱۰,۳ متر تا ۲۳۳۳,۷ متر برای آموزش مدل مورد استفاده قرار گرفت. مقطعی از چاه مورد مطالعه دوم نیز از ۲۳۱۲,۱ متر تا ۲۳۳۴,۶ متر برای آزمون مدل به کار برده شد. تغییر در روند فشار لوله جداری و داده‌های فشار لوله ایستا، احتمال وقوع لرزش کابل حفاری و هرزروی گل حفاری را با استفاده از الگوریتم تفکیک بیز قادر ساخت.

یین و همکاران<sup>۷</sup> [۱۱۲] در سال ۲۰۱۴ با آموزش داده‌هایی از مقطعی از چاه مورد مطالعه اول از ۲۵۶۰,۷ متر تا ۲۶۰۱,۲ متر و آزمون داده‌هایی از مقطعی از چاه مورد مطالعه دوم از ۱۳۷۴,۹ متر تا ۱۴۳۴,۳ متر به طراحی مدل پرداختند. مدل براساس شبکه عصبی مصنوعی و به کمک تغییرات فشار لوله ایستا، تغییر زمان حفاری، تغییر حجم حفره، تغییر نرخ جریان خروجی، تغییر هدایت خروجی، تغییر چگالی حجم خروجی، تغییر دمای خروجی، تغییرات حجم گاز کل هیدروکربن و تغییرات محتوای جزء  $Cl^8$  توسعه داده شده است. این الگوریتم به کار گرفته شده به دقت ۹۱,۴ درصد و ۸۶,۷ درصد برای هشدار اولیه برای وقوع احتمالی لرزش کابل حفاری دست یافته است. مطالعه مشابهی نیز در این زمینه توسط لیانگ و همکاران [۱۱۳] در سال ۲۰۱۹ انجام شد که در آن به استفاده از الگوریتم ژنتیک به عنوان یک روش بهینه‌سازی برای آموزش شبکه عصبی پس انتشار<sup>۹</sup> پرداختند. این مقاله از داده‌های فشار لوله ایستا و فشار لوله جداری بر اساس انتقال موج فشار برای حذف تأثیر لرزش استفاده کرده است. میانگین

<sup>۱</sup> Yin et al

<sup>۲</sup> Variation and C1 component

<sup>۳</sup> Back propagation

<sup>۴</sup> Xie et al

<sup>۵</sup> Adedigba et al

<sup>۶</sup> Fjetland et al

<sup>۱</sup> Sequential minimal optimization (SMO)

<sup>۲</sup> K-Nearest Neighbors (KNN)

<sup>۳</sup> Liang et al

<sup>۴</sup> Stand pipe pressure (SPP)

<sup>۵</sup> Casing pressure (CP)

<sup>۶</sup> Bayes discriminant

#### ۴. بحث و نتایج

با توجه به پژوهش‌های مورد اشاره دسته‌بندی نسبی از میزان استفاده آن‌ها از الگوریتم‌های گوناگون برای مدل‌سازی و پیش‌بینی مشکلات حفاری در طول سال‌های گذشته استخراج شده است. شکل ۸ الی ۱۲ میزان استفاده پژوهشگران از تکنیک‌های گوناگون در این رابطه را در طول دهه اخیر نشان می‌دهد. همانگونه که در نمودار مشهود می‌باشد میزان محبوبیت شبکه عصبی مصنوعی در بین مطالعات در طی سالیان طولانی پابرجا بوده است و میزان استفاده نسبی پژوهشگران از الگوریتم درخت تصمیم (بین سال‌های ۲۰۱۰-۲۰۲۳) شتاب بیشتری پیدا کرده است. شبکه بیزین از دیر باز وجودش مشهود بوده است اما از سال ۲۰۱۰ به بعد میزان استفاده پژوهشگران از این الگوریتم برای پیش‌بینی مشکلات حفاری افزایش یافته است. استفاده از الگوریتم ماشین بردار پشتیبان از سال ۲۰۰۲ بین پژوهشگران آغاز شده و تاکنون ادامه پیدا کرده است؛ به گونه‌ای که میزان استفاده از این الگوریتم در ۲۰۲۳ به بیشترین حد خود رسیده است. الگوریتم ماشین بردار پشتیبان به علت بازخورد بسیار مثبت و عملکرد بالایی که از خود نشان داده است، بعد از الگوریتم شبکه عصبی مصنوعی بیشترین استفاده را داشته است، به طوری که تاکنون در بیشتر زمینه‌های علوم مهندسی از این الگوریتم استفاده فراوان شده است. با این حال بیشترین درصد استفاده پژوهشگران در مقایسه با درصد استفاده از دیگر الگوریتم‌ها، همچنان مختص به شبکه عصبی مصنوعی بوده است. الگوریتم ماشین بردار پشتیبان از سال ۲۰۱۶ به بعد در مقایسه درصدی نسبت به الگوریتم‌های درخت تصمیم و شبکه بیزین محبوبیت بیشتری داشته است. ولی هر سه الگوریتم مذکور در سال‌های ۲۰۱۶ به بعد بیشترین استفاده از آن‌ها نسبت به سال‌های پیشین خود مشهود است. از طرفی میزان استفاده پژوهشگران از الگوریتم رگرسیون خطی نسبت به سال‌های گذشته کاهش یافته است. دلیل این موضوع می‌تواند به ضعیف بودن عملکرد این روش نسبت به روش‌های دیگر یادگیری ماشین اشاره داشته باشد. طبق ادبیات موضوع این مقاله، بیشترین استفاده پژوهشگران از الگوریتم رگرسیون خطی در سال‌های ۲۰۰۴-۲۰۰۵ می‌باشد. ترکیب الگوریتم‌ها

تا ۶۶٫۵ درصد، لرزش کابل حفاری را تخمین زد. یانگ و همکاران<sup>۱</sup> [۱۱۷] در سال ۲۰۱۹ از شبکه عصبی مصنوعی به همراه الگوریتم آنالیز مولفه اصلی<sup>۲</sup> به تعیین لرزش کابل حفاری با استفاده از پارامترهای حفاری شامل عمق، بار قلاب، وزن روی مته، دور بر دقیقه، گشتاور و ... پرداخت. تعداد پارامترهای استفاده شده در این مطالعه بیش از ۱۰۰۰ نقطه داده است که با استفاده از آن الگوریتم شبکه عصبی با آنالیز اجزا اصلی، لرزش کابل حفاری را با دقت بیش از ۹۵ درصد پیش‌بینی می‌کند.

آساروجیاگون و همکاران<sup>۳</sup> [۱۱۸] در سال ۲۰۲۰ با ارتباط‌سازی بین فشار لوله ایستا و توان با لرزش کابل حفاری مدلی مبتنی بر الگوریتم‌های شبکه عصبی مصنوعی و شبکه حافظه بلند کوتاه‌مدت<sup>۴</sup> طراحی کردند که در آن لرزش کابل حفاری با دقت بیش از ۹۵ درصد تخمین زده شد.

به طور خلاصه، می‌توان از پژوهش‌های انجام گرفته برای پیش‌بینی وقوع احتمالی لرزش کابل حفاری دریافت که پارامترهای رایج در تشخیص لرزش کابل حفاری شامل پارامترهای فشار (مانند فشار لوله ایستاده، فشار لوله جداری)، وزن گل، نرخ جریان، بار قلاب، نرخ نفوذ، وزن روی مته و عمق می‌باشد. لذا تغییر در روند و مقادیر پارامترهای ورودی می‌تواند برای تشخیص بهتر و تاثیرگذارتر لرزش کابل حفاری مورد استفاده قرار گیرد. در اینجا نیز روش شبکه عصبی مصنوعی رایج‌ترین الگوریتم است. الگوریتم‌های بهینه‌سازی مورد استفاده برای شبکه عصبی مصنوعی نقش مهمی در عملکرد این الگوریتم دارد؛ چرا که در مطالعاتی که شبکه عصبی مصنوعی همراه دیگر الگوریتم‌ها استفاده شده است، دقت آن نسبت به حالت تکی بطور چشمگیری افزایش یافته است. علاوه بر روش شبکه عصبی، شبکه بیزین نیز بسیار در تعیین لرزش کابل حفاری در مطالعات استفاده شده است. با توجه به اینکه نمونه‌های دارای لرزش کابل حفاری بطور معمول بسیار کمتر از نمونه‌های بدون لرزش کابل حفاری هستند، می‌توان از تکنیک‌های داده‌کاوی مانند نمونه‌برداری و نمونه‌سازی برای بهبود عملکرد مدل استفاده کرد. مشابه سایر مشکلات حفاری، درک سایر ناهنجاری‌های حفاری برای تشخیص وقوع لرزش کابل حفاری می‌تواند بسیار مفید باشد.


<sup>۲</sup> Osarogiagbon et al

<sup>۴</sup> Long short-term memory networks (LSTM)

<sup>۱</sup> Yang et al

<sup>۲</sup> Principal component analysis (PCA)


**عصبی مصنوعی در دهه اخیر**



شکل ۱۲. شماتیکی از روند استفاده از الگوریتم درخت

**تصمیم در دهه اخیر**

در یک دیدگاه کلی از میزان تغییرات روند کاربردی روش‌های یادگیری ماشین در موضوعات مشکلات حفاری نموداری در شکل ۱۳ ارائه شده است. همانطور که از نمودار رسم شده قابل مشاهده است، شبکه عصبی مصنوعی همچنان پرکاربردترین روش محسوب می‌شود. استفاده از رگرسیون خطی نیز در طی سال‌ها کاهش یافته است. در مقابل کاربرد روش‌های درخت تصمیم، شبکه بیزین و ماشین بردار پشتیبان رو به افزایش است.



شکل ۱۳. شماتیکی از روند استفاده از الگوریتم‌های


**یادگیری ماشین در دهه اخیر**

**۵. نتیجه‌گیری**

این پژوهش با تکیه بر تحلیل دقیق نتایج مطالعات پیشین در مورد برخی مشکلات حفاری شامل گیرکردن لوله حفاری، هرزروی سیستم گردش گل، شکستگی و لرزش احتمالی کابل حفاری به موارد زیر دست یافته است.


۱- به نظر می‌رسد عملکرد شبکه عصبی مصنوعی را می‌توان تحت تأثیر الگوریتم بهینه‌سازی افزایش داد. شبکه عصبی

عملکرد خوبی بهتری نسبت به اجزای یگانه دارند. همچنین بهینه کردن الگوریتم‌ها باعث افزایش میزان دقت آن‌ها در پیش‌بینی مشکلات حفاری را داشته است.




شکل ۸. شماتیکی از روند استفاده از الگوریتم رگرسیون

**خطی در دهه اخیر**




شکل ۹. شماتیکی از روند استفاده از الگوریتم ماشین بردار

**پشتیبان در دهه اخیر**



شکل ۱۰. شماتیکی از روند استفاده از الگوریتم شبکه بیزین

**در دهه اخیر**



شکل ۱۱. شماتیکی از روند استفاده از الگوریتم شبکه



Journal of Oil and Gas Science and Technology, 2014. 3(3): p. 26-38.

3. Bai, K., et al., Drilling Parameter Optimization of Shale Gas Wells Based on Saw-Tooth Genetic Algorithm to Reduce Drilling Costs. Geofluids, 2023. 2023.

4. Self, R., A. Atashnezhad, and G. Hareland. Reducing drilling cost by finding optimal operational parameters using particle swarm algorithm. in SPE Deepwater Drilling and Completions Conference. 2016. SPE.

5. Issa, M.A., A.A.A.A. Alrazzaq, and Y. Mukhtar, Review of the Mechanisms for Preventing, Diagnosing, and Treatment of Pipe Sticking in Drilling Operations. Iraqi Journal of Chemical and Petroleum Engineering, 2023. 24(3): p. 133-140.

6. Rostami, H. and A. Khaksar Manshad, A new support vector machine and artificial neural networks for prediction of stuck pipe in drilling of oil fields. Journal of Energy Resources Technology, 2014. 136(2): p. 024502.

7. Yang, J., et al., Status and prospect of drilling fluid loss and lost circulation control technology in fractured formation. Gels, 2022. 8(5): p. 260.

8. Saleh, F., et al. Geothermal drilling: A review of drilling challenges with mud design and lost circulation problem. in Proceedings of 45th Annual Stanford Geothermal Workshop, Stanford University, Stanford, CA. 2020.

9. Biswas, K., et al., A review of metaheuristic algorithms for optimizing 3D well-path designs. Archives of Computational Methods in Engineering, 2021. 28: p. 1775-1793.

10. Zamora, M. and D. Jefferson, Controlling barite sag can reduce drilling problems. Oil and Gas Journal;(United States), 1994. 92(7).

11. Mohamadian, N., et al., A geomechanical approach to casing collapse prediction in oil and gas wells aided by machine learning. Journal of Petroleum Science and Engineering, 2021. 196: p. 107811.

12. Dashtaki, B.B., et al., Numerical modeling of casing collapse in Gachsaran formation in Sirri-E oilfield in Persian Gulf. Journal of Petroleum Science and Engineering, 2021. 196: p. 108009.

13. Zamani, S.M., S.A. Hassanzadeh-Tabrizi, and

مصنوعی الگوریتم پرکاربردی در ارتباطسازی بین پارامترهای حفاری و مشکلات حفاری است. طبق مطالعات عملکرد این الگوریتم بصورت توأم با الگوریتم ژنتیک بصورت چشمگیری افزایش می‌یابد.

۲- با بررسی نتایج مطالعات، می‌توان دریافت که الگوریتم های ماشین بردار پشتیبان و جنگل تصادفی در مطالعات یکسان بهتر از شبکه عصبی مصنوعی عمل می‌کنند.

۳- در هر بخش از بررسی استفاده مدل‌های هوشمند در پیش‌بینی مشکلات حفاری تاثیرگذارترین پارامترها ارائه شده است.

۴- بسیاری از مدل‌های هوشمند با استفاده از نمونه‌های محدود و برای نوع خاصی از سازندها و مناطق طراحی شده‌اند. همچنین، برای مدل‌سازی تمام پارامترهای تاثیرگذار بر هدف استفاده نشده است. لذا نتایج چنین مطالعاتی ممکن است قابل تعمیم نباشد.

۵- برای بالا بردن عملکرد الگوریتم‌های یادگیری ماشین حذف داده‌های پرت و انتخاب بهترین پارامترهای الگوریتم توصیه می‌شود. همچنین ماهیت و مقادیر پارامترهای مهم برای رسیدن به نتایج دقیق‌تر مهم می‌باشد.

۶- در مطالعات انجام شده، هر مطالعه به پیش‌بینی تنها یک یا نهایت دو مشکل حفاری می‌پردازد. از آنجا که در واقعیت مشکلات حفاری بر یکدیگر تأثیر می‌گذارد، بنظر می‌رسد مطالعه همزمان چندین مشکل اطلاعات دقیق‌تر و مدل‌های هوشمند کارآمدتری را فراهم می‌آورد.

۷- می‌توان از مشکلات حفاری که منجر به وقوع مشکل دیگری می‌شود، بعنوان داده ورودی استفاده کرد. از طرفی مدل‌های هوشمند قادر به تخمین همزمان چندین خروجی را دارند که می‌توان همزمان احتمال رخ دادن چندین مشکل را تخمین زد.

## ۶. مراجع

1. Halafawi, M. and L. Avram, Application of risk analysis in drilling well problems and operations-field case study. Journal of Engineering Sciences and Innovation, Petroleum and Mining Engineering Section (F), 2018. 3(4): p. 393-404.

2. Maleki, B., K. Ahmadi, and A. Jafari, Optimization of the Cost Function in the Drilling of Oil Well Network by Balas Algorithm. Iranian



- support vector machines, neural networks, and fuzzy logic models. 2001: MIT press.
27. Zhou, Z.-H., Machine learning. 2021: Springer Nature.
  28. Alloghani, M., et al., A systematic review on supervised and unsupervised machine learning algorithms for data science. Supervised and unsupervised learning for data science, 2020: p. 3-21.
  29. Nasteski, V., An overview of the supervised machine learning methods. Horizons. b, 2017. 4: p. 51-62.
  30. Szepesvári, C., Algorithms for reinforcement learning. 2022: Springer Nature.
  31. Mohammed, M., M.B. Khan, and E.B.M. Bashier, Machine learning: algorithms and applications. 2016: Crc Press.
  32. James, G., et al., An introduction to statistical learning (Vol. 112, p. 18). 2013, New York: springer.
  33. Sun, P., S. Huo, and T. He, Multiple machine learning models in estimating viscosity of crude oil: Comparisons and optimization for reservoir simulation. Journal of Molecular Liquids, 2023: p. 122251.
  34. Jamei, M., et al., Estimating the density of hybrid nanofluids for thermal energy application: Application of non-parametric and evolutionary polynomial regression data-intelligent techniques. Measurement, 2022. 189: p. 110524.
  35. Pwavodi, J., et al., Pore pressure prediction in offshore Niger delta using data-driven approach: Implications on drilling and reservoir quality. Energy Geoscience, 2023. 4(3): p. 100194.
  36. Gowida, A., A.F. Ibrahim, and S. Elkatatny, A hybrid data-driven solution to facilitate safe mud window prediction. Scientific Reports, 2022. 12(1): p. 15773.
  37. Ebrahimi, P., et al., Young's Modulus Estimation Using Machine Learning Methods and Daily Drilling Reports. Journal of Oil, Gas and Petrochemical Technology, 2023. 10(1): p. 1-24.
  38. Ebrahimi, A., et al., Estimation of shear wave velocity in an Iranian oil reservoir using machine learning methods. Journal of Petroleum Science and Engineering, 2022. 209: p. 109841.
  - H. Sharifi, Failure analysis of drill pipe: A review. Engineering Failure Analysis, 2016. 59: p. 605-623.
  14. Macdonald, K. and J. Bjune, Failure analysis of drillstrings. Engineering Failure Analysis, 2007. 14(8): p. 1641-1666.
  15. Dahab, A., et al. Managing wellbore instability through geomechanical modeling and wellbore stability analysis. in ARMA US Rock Mechanics/Geomechanics Symposium. 2020. ARMA.
  16. Allawi, R.H. and M.S. Al-Jawad, Wellbore instability management using geomechanical modeling and wellbore stability analysis for Zubair shale formation in Southern Iraq. Journal of Petroleum Exploration and Production Technology, 2021. 11: p. 4047-4062.
  17. Krueger, R.F., An overview of formation damage and well productivity in oilfield operations. Journal of petroleum technology, 1986. 38(02): p. 131-152.
  18. Bennion, D.B., An overview of formation damage mechanisms causing a reduction in the productivity and injectivity of oil and gas producing formations. Journal of Canadian Petroleum Technology, 2002. 41(11).
  19. Pierce, W.D. [8] Reducing drilling costs. in World Petroleum Congress. 1991. WPC.
  20. Azar, J.J. and G.R. Samuel, Drilling engineering. (No Title), 2007.
  21. Bourgoyne, A.T., et al., Applied drilling engineering. Vol. 2. 1986: Society of Petroleum Engineers Richardson.
  22. Aadnoy, B., et al., Advanced drilling and well technology. 2009: SPE Richardson, Texas.
  23. Olukoga, T. and Y. Feng, Practical machine-learning applications in well-drilling operations. SPE Drilling & Completion, 2021. 36(04): p. 849-867.
  24. Noshi, C.I. and J.J. Schubert. The role of machine learning in drilling operations; a review. in SPE Eastern Regional Meeting. 2018. SPE.
  25. Bhattacharyya, P., CS344: Introduction to Artificial Intelligence (associated lab: CS386). 2011.
  26. Kecman, V., Learning and soft computing:

- the total organic carbon (TOC) based on conventional well logs using artificial neural network. *International Journal of Coal Geology*, 2017. 179: p. 72-80.
52. ElectronicsHub. Artificial Neural Networks (ANN) | Basics, Characteristics, Elements, Types. 2020; Available from: <https://www.electronicshub.org/artificialneural-networks-ann>.
53. Abbas, A.K., et al., Drilling rate of penetration prediction of high-angled wells using artificial neural networks. *Journal of Energy Resources Technology*, 2019. 141(11).
54. Bello, O., et al., Application of artificial intelligence methods in drilling system design and operations: a review of the state of the art. *Journal of Artificial Intelligence and Soft Computing Research*, 2015. 5.
55. Li, X. and C.W. Chan, Application of an enhanced decision tree learning approach for prediction of petroleum production. *Engineering Applications of Artificial Intelligence*, 2010. 23(1): p. 102-109.
56. Amar, M.N., et al., Modeling oil-brine interfacial tension at high pressure and high salinity conditions. *Journal of Petroleum Science and Engineering*, 2019. 183: p. 106413.
57. Pirizadeh, M., et al., A new machine learning ensemble model for class imbalance problem of screening enhanced oil recovery methods. *Journal of Petroleum Science and Engineering*, 2021. 198: p. 108214.
58. Zhong, R., R.L. Johnson Jr, and Z. Chen, Using machine learning methods to identify coal pay zones from drilling and logging-while-drilling (LWD) data. *SPE Journal*, 2020. 25(03): p. 1241-1258.
59. Gaurina-Medjimurec, N. and B. Pasic, Risk due to pipe sticking, in *Risk Analysis for Prevention of Hazardous Situations in Petroleum and Natural Gas Engineering*. 2014, IGI Global. p. 47-72.
60. Kayode, E.S. and O. Lami, Evaluation of Differential Pressure Sticking and Stuck Pipe in Oil and Gas Drilling Technology and Its Production Operations. *Evaluation*, 2020. 7(2): p. 114-130.
61. Abbas, A.K., et al. Application of machine
39. Zhang, B., J. Zhu, and H. Su, Toward the third generation artificial intelligence. *Science China Information Sciences*, 2023. 66(2): p. 121101.
40. Zare, F. and P. Mahmoudi-Nasr, Feature Engineering Methods in Intrusion Detection System: A Performance Evaluation. *International Journal of Engineering, Transactions A: Basics*, 2023. 36(07): p. 1343-1353.
41. Aggarwal, S., Machine Learning algorithms, perspectives, and real-world application: Empirical evidence from United States trade data. 2023.
42. Ahmed, S.A., M. Hussain, and Z.U. Khan, Supervised machine learning for predicting shear sonic log (DTS) and volumes of petrophysical and elastic attributes, Kadanwari Gas Field, Pakistan. *Frontiers in Earth Science*, 2022. 10: p. 919130.
43. Xue, M., et al., Machine learning security: Threats, countermeasures, and evaluations. *IEEE Access*, 2020. 8: p. 74720-74742.
44. James, G., et al., Linear regression, in *An Introduction to Statistical Learning: With Applications in Python*. 2023, Springer. p. 69-134.
45. Vapnik, V., *The nature of statistical learning theory*. 1999: Springer science & business media.
46. Steinwart, I. and A. Christmann, *Support vector machines*. 2008: Springer Science & Business Media.
47. Pearl, J., *Probabilistic reasoning in intelligent systems: networks of plausible inference*. 2014: Elsevier.
48. Uusitalo, L., Advantages and challenges of Bayesian networks in environmental modelling. *Ecological modelling*, 2007. 203(3-4): p. 312-318.
49. Aguilera, P.A., et al., Bayesian networks in environmental modelling. *Environmental Modelling & Software*, 2011. 26(12): p. 1376-1388.
50. Elkatatny, S., Real-Time Prediction of the Dynamic Young's Modulus from the Drilling Parameters Using the Artificial Neural Networks. *Arabian Journal for Science and Engineering*, 2021: p. 1-10.
51. Mahmoud, A.A.A., et al., Determination of

- pipe sticking in real-time well drilling process. in 2020 Global Smart Industry Conference (GloSIC). 2020. IEEE.
72. Alshaikh, A., et al. Machine learning for detecting stuck pipe incidents: Data analytics and models evaluation. in International petroleum technology conference. 2019. OnePetro.
73. Bayan, M. and Zulkarnain. Stuck pipe prediction in geothermal well drilling at darajat using statistical and machine learning application. in Proceedings of the 3rd Asia Pacific Conference on Research in Industrial and Systems Engineering. 2020.
74. Tsuchihashi, N., et al., Early stuck pipe sign detection with depth-domain 3D convolutional neural network using actual drilling data. SPE Journal, 2021. 26(02): p. 551-562.
75. Inoue, T., et al. Early Stuck Detection Using Supervised and Unsupervised Machine Learning Approaches. in Offshore Technology Conference Asia. 2022. OTC.
76. Feng, Y. and K. Gray, Review of fundamental studies on lost circulation and wellbore strengthening. Journal of Petroleum Science and Engineering, 2017. 152: p. 511-522.
77. Wang, H.M., et al., Best practice in understanding and managing lost circulation challenges. SPE Drilling & Completion, 2008. 23(02): p. 168-175.
78. Moazzeni, A., M. Nabaei, and S. Jegarluei, Decision making for reduction of nonproductive time through an integrated lost circulation prediction. Petroleum science and technology, 2012. 30(20): p. 2097-2107.
79. Liang, H., et al., RESEARCH ON DRILLING KICK AND LOSS MONITORING METHOD BASED ON BAYESIAN CLASSIFICATION. Pakistan Journal of Statistics, 2014. 30(6).
80. Toreifi, H., H. Rostami, and A.K. Manshad, New method for prediction and solving the problem of drilling fluid loss using modular neural network and particle swarm optimization algorithm. Journal of Petroleum Exploration and Production Technology, 2014. 4: p. 371-379.
81. Jahanbakhshi, R., R. Keshavarzi, and S. Jalili, Artificial neural network-based prediction and geomechanical analysis of lost circulation in naturally fractured reservoirs: a case study. learning approach for intelligent prediction of pipe sticking. in Abu Dhabi International Petroleum Exhibition and Conference. 2019. SPE.
62. Hempkins, W., et al., Multivariate statistical analysis of stuck drillpipe situations. SPE Drilling Engineering, 1987. 2(03): p. 237-244.
63. Siruvuri, C., S. Nagarakanti, and R. Samuel. Stuck pipe prediction and avoidance: A convolutional neural network approach. in IADC/SPE Drilling Conference. 2006. OnePetro.
64. Miri, R., et al. Development of artificial neural networks to predict differential pipe sticking in iranian offshore oil fields. in SPE International Oil Conference and Exhibition in Mexico. 2007. SPE.
65. Murillo, A., J. Neuman, and R. Samuel. Pipe sticking prediction and avoidance using adaptive fuzzy logic and neural network modeling. in SPE Oklahoma City Oil and Gas Symposium/Production and Operations Symposium. 2009. SPE.
66. Shadizadeh, S., F. Karimi, and M. Zoveidavianpoor, Drilling stuck pipe prediction in iranian oil fields: An artificial neural network approach. Iranian Journal of Chemical Engineering, 2010. 7(4): p. 29-41.
67. Alireza, M., N. Mohammad, and A. Ahmad, Reducing consumed energy while drilling an oil well through a deep rig time analysis. Advances in Petroleum Exploration and Development, 2011. 1(1): p. 22-31.
68. Al-Baiyat, I. and L. Heinze. Implementing artificial neural networks and support vector machines in stuck pipe prediction. in SPE Kuwait International Petroleum Conference and Exhibition. 2012. SPE.
69. Jahanbakhshi, R., et al., Intelligent prediction of differential pipe sticking by support vector machine compared with conventional artificial neural networks: an example of Iranian offshore oil fields. SPE Drilling & Completion, 2012. 27(04): p. 586-595.
70. Chamkalani, A., M. Pordel Shahri, and S. Poordad. Support vector machine model: a new methodology for stuck pipe prediction. in SPE unconventional gas conference and exhibition. 2013. OnePetro.
71. Qodirov, S. and A. Shestakov. Development of artificial neural network for predicting drill

- circulation. *Egyptian Journal of Petroleum*, 2019. 28(4): p. 339-347.
92. Hou, X., et al. Lost circulation prediction in south China sea using machine learning and big data technology. in *Offshore Technology Conference*. 2020. OTC.
93. Agin, F., et al., Application of adaptive neuro-fuzzy inference system and data mining approach to predict lost circulation using DOE technique (case study: Maroon oilfield). *Petroleum*, 2020. 6(4): p. 423-437.
94. Jafarizadeh, F., et al., A new robust predictive model for lost circulation rate using convolutional neural network: A case study from Marun Oilfield. *Petroleum*, 2023. 9(3): p. 468-485.
95. Deng, S., et al., Lost Circulation Prediction Method Based on an Improved Fruit Fly Algorithm for Support Vector Machine Optimization. *ACS omega*, 2023.
96. Dong, S., et al., Fracture identification and evaluation using conventional logs in tight sandstones: A case study in the Ordos Basin, China. *Energy Geoscience*, 2020. 1(3-4): p. 115-123.
97. Tokhmchi, B., H. Memarian, and M.R. Rezaee, Estimation of the fracture density in fractured zones using petrophysical logs. *Journal of Petroleum Science and Engineering*, 2010. 72(1-2): p. 206-213.
98. Malallah, A. and I.S. Nashawi, Estimating the fracture gradient coefficient using neural networks for a field in the Middle East. *Journal of petroleum science and engineering*, 2005. 49(3-4): p. 193-211.
99. Chao, W., et al., A prediction of borehole stability while drilling preliminary prospecting wells based on seismic impedance. *Petroleum Exploration and Development*, 2015. 42(3): p. 427-433.
100. Fang, J., F. Zhou, and Z. Tang, Discrete fracture network modelling in a naturally fractured carbonate reservoir in the Jingbei oilfield, China. *Energies*, 2017. 10(2): p. 183.
101. Ashraf, U., et al., Application of unconventional seismic attributes and unsupervised machine learning for the identification of fault and fracture network. *Applied Sciences*, 2020. 10(11): p. 3864.
- European journal of environmental and civil engineering*, 2014. 18(3): p. 320-335.
82. Wu, S., et al., A DBN-based risk assessment model for prediction and diagnosis of offshore drilling incidents. *Journal of Natural Gas Science and Engineering*, 2016. 34: p. 139-158.
83. Wu, S., et al., Real-time risk analysis method for diagnosis and warning of offshore downhole drilling incident. *Journal of Loss Prevention in the Process Industries*, 2019. 62: p. 103933.
84. Leite Cristofaro, R., et al. Artificial intelligence strategy minimizes lost circulation non-productive time in Brazilian deep water pre-salt. in *Offshore Technology Conference Brasil*. 2017. OTC.
85. Hosseini, P., Estimation of lost circulation amount occurs during under balanced drilling using drilling data and neural network. *Egyptian Journal of Petroleum*, 2017. 26(3): p. 627-634.
86. Li, Z., et al. Study on intelligent prediction for risk level of lost circulation while drilling based on machine learning. in *ARMA US Rock Mechanics/Geomechanics Symposium*. 2018. ARMA.
87. Al-Hameedi, A.T.T., et al., Mud loss estimation using machine learning approach. *Journal of Petroleum Exploration and Production Technology*, 2019. 9: p. 1339-1354.
88. Sabah, M., et al., Application of decision tree, artificial neural networks, and adaptive neuro-fuzzy inference system on predicting lost circulation: A case study from Marun oil field. *Journal of Petroleum Science and Engineering*, 2019. 177: p. 236-249.
89. Ezeakacha, C.P. and S. Salehi, Experimental and statistical investigation of drilling fluid loss in porous media: Part 2 (Fractures). *Journal of Natural Gas Science and Engineering*, 2019. 65: p. 257-266.
90. Alkinani, H.H., et al. Prediction of lost circulation prior to drilling for induced fractures formations using artificial neural networks. in *SPE Oklahoma City Oil and Gas Symposium/Production and Operations Symposium*. 2019. SPE.
91. Abbas, A.K., N.A. Al-haideri, and A.A. Bashikh, Implementing artificial neural networks and support vector machines to predict lost

- Journal of Statistics, 2014. 30(6).
113. Liang, H., J. Zou, and W. Liang, An early intelligent diagnosis model for drilling overflow based on GA-BP algorithm. *Cluster Computing*, 2019. 22: p. 10649-10668.
114. Xie, H., A.K. Shanmugam, and R.R. Issa, Big data analysis for monitoring of kick formation in complex underwater drilling projects. *Journal of Computing in Civil Engineering*, 2018. 32(5): p. 04018030.
115. Adedigba, S.A., et al., Data-driven dynamic risk analysis of offshore drilling operations. *Journal of petroleum science and engineering*, 2018. 165: p. 444-452.
116. Fjetland, A.K., et al. Kick detection and influx size estimation during offshore drilling operations using deep learning. in *2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA)*. 2019. IEEE.
117. Yang, J., et al. Advanced real-time gas kick detection using machine learning technology. in *ISOPE International Ocean and Polar Engineering Conference*. 2019. ISOPE.
118. Osarogiagbon, A., et al., A new methodology for kick detection during petroleum drilling using long short-term memory recurrent neural network. *Process Safety and Environmental Protection*, 2020. 142: p. 126-137.
102. Xue, Y., et al., A new fracture prediction method by combining genetic algorithm with neural network in low-permeability reservoirs. *Journal of Petroleum Science and Engineering*, 2014. 121: p. 159-166.
103. Roy, D.G., T. Singh, and J. Kodikara, Predicting mode-I fracture toughness of rocks using soft computing and multiple regression. *Measurement*, 2018. 126: p. 231-241.
104. Soroush, H., V. Rasouli, and B. Tokhmechi, A data processing algorithm proposed for identification of breakout zones in tight formations: A case study in Barnett gas shale. *Journal of petroleum science and engineering*, 2010. 74(3-4): p. 154-162.
105. Zerrouki, A.A., T. Aifa, and K. Baddari, Prediction of natural fracture porosity from well log data by means of fuzzy ranking and an artificial neural network in Hassi Messaoud oil field, Algeria. *Journal of Petroleum Science and Engineering*, 2014. 115: p. 78-89.
106. Zazoun, R.S., Fracture density estimation from core and conventional well logs data using artificial neural networks: The Cambro-Ordovician reservoir of Mesdar oil field, Algeria. *Journal of African Earth Sciences*, 2013. 83: p. 55-73.
107. Abdideh, M., Estimation of the fracture density in reservoir rock using regression analysis of the petrophysical data. *Geodesy and Cartography*, 2016. 42(3): p. 85-91.
108. Huque, M.M., et al., Kick detection and remedial action in managed pressure drilling: a review. *SN Applied Sciences*, 2020. 2: p. 1-29.
109. Grace, R.D., *Blowout and well control handbook*. 2017: Gulf Professional Publishing.
110. Kamyab, M., et al. Early kick detection using real time data analysis with dynamic neural network: A case study in iranian oil fields. in *SPE Nigeria Annual International Conference and Exhibition*. 2010. SPE.
111. Alouhali, R., et al. Drilling through data: automated kick detection using data mining. in *SPE International Heavy Oil Conference and Exhibition*. 2018. OnePetro.
112. Yin, H., M. Si, and H. Wang, THE WARNING MODEL OF THE EARLY KICK BASED ON BP NEURAL NETWORK. *Pakistan*