

کاربرد یادگیری ماشین در پیش‌بینی و مدیریت تولید ماسه در چاه‌های نفت و گاز - مطالعه‌ی مروری

محمد الیاس خدائشناس^۱، میثم محمدزاده شیرازی^۲، بهنام شاهسونی^{۳*}

۱. دانشجوی کارشناسی ارشد، گروه مهندسی نفت، دانشکده مهندسی شیمی، نفت و گاز، دانشگاه شیراز، شیراز، ایران

۲. استادیار، گروه مهندسی نفت، دانشکده مهندسی شیمی، نفت و گاز، دانشگاه شیراز، شیراز، ایران

آدرس پست الکترونیکی نویسنده مسئول مکاتبات: b.shahsavani@shirazu.ac.ir

مقاله‌ی مروری

صفحه ۵۴ - ۶۹

تاریخ پذیرش: ۱۴۰۴/۰۲/۳۰

تاریخ دریافت: ۱۴۰۳/۱۱/۳۰

چکیده

تولید ماسه در چاه‌های نفت و گاز، مشکلات متعددی مانند کاهش بهره‌وری از چاه و خرابی تجهیزات را به همراه دارد. به‌منظور جلوگیری از مشکلات و پیامدهای تولید ماسه، اجرای فرایندهای پیش‌بینی و کنترل ماسه در چاه‌ها توصیه می‌شود. این فرایندها شامل بررسی عوامل متعددی از جمله: عمق چاه، گرادیان شکست سازند و سایر پارامترهای زمین‌شناسی می‌باشد. به‌علت حجم انبوه داده‌ها و پیچیدگی‌های تحلیل، روش‌های مرسوم سنتی، زمان‌بر و با عدم قطعیت و احتمال خطای زیادی مواجه‌اند؛ به همین دلیل، استفاده از روش‌های کارآمدتر از اهمیت زیادی برخوردار است؛ در سال‌های اخیر، به‌کارگیری تکنیک‌های یادگیری ماشین برای تحلیل داده‌های زیاد و پیچیده، به‌عنوان روشی مناسب و دقیق در جهت بهبود دقت پیش‌بینی‌ها مطرح شده است. از این‌رو مهندسان بهره‌بردار نیز از الگوریتم‌های یادگیری ماشین، برای تحلیل داده‌های مرتبط با تولید ماسه استفاده کردند. در این مطالعه، مروری بر تحقیقات پیشین، در زمینه‌ی استفاده از یادگیری ماشین در مدیریت تولید ماسه ارائه شده است. همچنین به‌منظور فهم بهتر، مطالعات ذکر شده براساس موضوع به دسته‌های مناسب تفکیک و سازماندهی شده‌اند؛ به‌علاوه، الگوریتم‌ها و روش‌های اعتبارسنجی در هر مطالعه ذکر شده است تا به‌عنوان راهنما مورد استفاده قرار گیرد؛ بنابراین مطالعه‌ی حاضر می‌تواند همچون مرجعی برای مطالعات آینده در این زمینه عمل کند.

کلید واژه‌ها: پیش‌بینی تولید ماسه، تولید و بهره‌وری، تولید نفت، هوش مصنوعی، یادگیری ماشین

۱. مقدمه

امروزه، با پیشرفت فناوری و توسعه‌ی هوش مصنوعی^۱، کاربرد یادگیری ماشین^۲ در صنایع مختلف به‌طور چشمگیری رو به افزایش است. تا آنجا که در سال‌های اخیر، در اکثر صنایع و کسب و کارهای جهان در زمینه‌های متعددی، در جهت بهبود نتایج و تحلیل‌ها مورد استفاده قرار می‌گیرد. از سری کاربردهای مهم یادگیری ماشین می‌توان به مواردی مانند اینترنت اشیا^۳ اشاره کرد که به‌عنوان یک شبکه به کار گرفته می‌شود و می‌تواند تعداد زیادی از دستگاه‌های هوشمند

1. Artificial Intelligence
2. Machine Learning
3. Internet of Things



را به هم متصل کند [۱]. در زمینه‌ی تصفیه‌ی آب نیز مدل‌های ماشینی می‌توانند جهت بهبود تصفیه و کاهش آلودگی‌ها مؤثر باشند [۲]. گسترش کاربرد یادگیری ماشین در زمینه‌ی مهندسی نفت نیز قابل مشاهده است. از سری کاربردهای آن می‌توان به مطالعه‌ی پاندی و همکاران در زمینه‌ی تحلیل داده‌ها در بهینه‌سازی عملیات بالادستی اشاره کرد [۳]. در سال ۲۰۱۷، انیفوسه و همکاران نیز به مدل‌سازی مخازن و توصیف خصوصیات مخزن با استفاده از یادگیری ماشین گروهی پرداختند [۵]. در سال ۲۰۱۹، انیفوسه و همکاران نیز، به پیش‌بینی تراوایی^۱ در مخازن کربناته با استفاده از داده‌های نگاره^۲ و الگوریتم‌های یادگیری ماشین پرداختند [۷]. در سال ۲۰۱۹، صباح و همکاران نیز به کمک داده‌های پتروفیزیکی و نگاره با الگوریتم‌های یادگیری ماشین، به پیش‌بینی نرخ نفوذ حفاری در چاه‌ها پرداختند [۱۳]. در سال ۲۰۲۱ ژانگ و همکاران نیز به کمک تکنیک‌های یادگیری ماشین، تراوایی مخازن ماسه سنگی مستحکم^۳ را بررسی کردند [۸]. در سال ۲۰۲۱، اویشر و همکاران پارادایم‌های یادگیری ماشین نظارت‌شده را برای پیش‌بینی خصوصیات مخازن نفتی به کار گرفتند [۴]. در سال ۲۰۲۲، سالم و همکاران نیز به مطالعه و پیش‌بینی خرابی‌های یکپارچگی^۴ چاه به کمک الگوریتم‌های یادگیری ماشین پرداختند [۶]. در سال ۲۰۲۲، لعلام و همکاران نیز برای تشخیص و پیش‌بینی ترکیب کانی‌شناسی در منطقه‌ی نفتی باکن، به بررسی داده‌های نگاره و روش‌های یادگیری ماشین پرداختند [۹]. در سال ۲۰۲۳، ژی و همکاران نیز به کمک چهار مکانیزم ادغام اطلاعات فیزیکی و الگوریتم‌های یادگیری ماشین، به حل مسائل چندفیزیکی و چندمقیاسی در مهندسی نفت پرداختند [۱۰]. در سال ۲۰۲۲، مای-کائو و ترونک-کخ به پیش‌بینی تولید نفت با استفاده از الگوریتم‌های یادگیری ماشین را بررسی کردند [۱۱]. در سال ۲۰۲۲، اوجداپو و همکاران نیز به کمک یادگیری ماشین مدل‌هایی ایجاد کردند که بتوانند با روش‌های داده

محور تولید از مخازن نفتی را پیش‌بینی کنند [۱۲]. با توجه به عملکرد بهتر در پیش‌بینی نتایج واقعی توسط مدل‌های ماشینی در مقایسه با روش‌های سنتی، کاربردهای یادگیری ماشین در زمینه‌های مختلف صنعت نفت و گاز، رو به افزایش است.

۱-۱. مروری بر یادگیری ماشین و هوش مصنوعی

در این بخش، هوش مصنوعی و یادگیری ماشین به‌عنوان مفاهیم اساسی مورد استفاده در مطالعه‌ی حاضر، تعریف شده است و انواع زیرشاخه‌های هوش مصنوعی و دسته‌بندی تکنیک‌های یادگیری ماشین، به همراه الگوریتم‌های متداول آن به اختصار، توضیح داده شده است:


۱-۱-۱. هوش مصنوعی

هپگود هوش مصنوعی را به‌عنوان «علم تقلید تعریف کرد؛ یعنی گنجاندن توانایی‌های ذهنی انسان در کامپیوتر». به‌طور کلی هوش مصنوعی سعی در ایجاد سهولت در کارهای متنوع هوش مصنوعی به مدت ۵۰ سال، به‌عنوان یکی از شاخه‌ی فعال تحقیقاتی برای دانشمندان کامپیوتر و محققان در حال توسعه بوده است. از سری کاربردهای هوش مصنوعی می‌توان به ابزارها و تکنیک‌های کارآمد و متنوعی از جمله: قوانین، فریم‌ها، استدلال مبتنی بر مدل، استدلال مبتنی بر مورد، به‌روزرسانی بیزی، منطق فازی، سیستم‌های چندعاملی^۵، هوش جمعی، الگوریتم‌های ژنتیک و ... اشاره کرد [۱۴]. هوش مصنوعی دارای زیرشاخه‌های متعددی است که می‌تواند جنبه‌ها و کاربردهای مختلفی از مسائل مختلف را پوشش دهند؛ از جمله‌ی این زیرشاخه‌ها می‌توان به: یادگیری ماشین، یادگیری عمیق^۶، شبکه‌های عصبی مصنوعی^۷، پردازش زبان طبیعی^۸، ریاتیک^۹، سیستم‌های خبره^{۱۰}، هوش مصنوعی فازی^{۱۱} و ... اشاره کرد [۱۵]. زیر شاخه‌های متداول هوش مصنوعی در (شکل ۱) نمایش یافته‌اند:

1. Permeability
2. Log
3. Consolidate
4. Integrity
5. Multi-Agent Systems
6. Deep Learning
7. Artificial Neural Networks
8. Natural Language Processing
9. Robotics
10. Expert Systems
11. Fuzzy Logic



که در آن به ازای هر یک از نمونه داده‌های ورودی، یک نتیجه‌ی خروجی متناظر وجود دارد و الگوریتم‌ها به کمک این داده‌های برچسب گذاری شده آموزش داده می‌شوند. از آنجا که در یادگیری نظارت شده، خروجی‌ها از قبل در پایگاه داده^۲ مشخص شده‌اند؛ هدف مدل ساخته شده، ایجاد یک رابطه‌ی درست و منطقی بین ویژگی^۳ ورودی و نتایج خروجی می‌باشد تا بتواند مقادیر خروجی را برای ورودی‌های جدید و بدون برچسب خروجی، پیش‌بینی کند. الگوریتم‌های رگرسیون خطی^۴، رگرسیون لجستیک^۵، جنگل تصادفی^۶، درخت تصمیم‌گیری^۷، ماشین بردار پشتیبان^۸، نزدیک‌ترین همسایگی^۹، شبکه‌ی عصبی مصنوعی^{۱۰} و نایو بیس^{۱۱} از تکنیک‌های رایج مورد استفاده در یادگیری نظارت شده به شمار می‌روند. این روش نیاز به مجموعه بزرگی از نمونه‌های برچسب‌گذاری شده دارد و در کاربردهایی مانند شناسایی ایمیل‌های اسپم و تشخیص تصویر مورد استفاده قرار می‌گیرد. شماتیکی از نحوه‌ی کارکرد یادگیری نظارتی در (شکل ۲) نمایش یافته است:



شکل ۲: نحوه‌ی عملکرد یادگیری نظارت شده

۱-۲-۲-۱ یادگیری غیر نظارتی^{۱۲}

یادگیری غیر نظارتی زمانی اتفاق می‌افتد که نمونه‌های موجود در پایگاه داده، حاوی برچسب یا همان نتیجه‌ی خروجی نیست. در این حالت از یادگیری،



شکل ۱: زیرشاخه‌های متداول هوش مصنوعی

۱-۲-۱ یادگیری ماشین


یادگیری ماشین یکی از شاخه‌های مهم هوش مصنوعی است که حول ایده‌ی یادگیری و هوشمندسازی سیستم‌ها از طریق تحلیل اطلاعات، به‌وسیله‌ی به‌کارگیری الگوریتم‌های یادگیری ماشین شکل گرفته است. به‌طور کلی یادگیری ماشین به مطالعه‌ی چگونگی بهره‌جویی از یک سیستم ماشینی، در جهت شبیه‌سازی فعالیت‌های یادگیری انسانی می‌پردازد. از مزیت‌های مهم یادگیری ماشینی نسبت به مکانیزم‌های یادگیری انسانی، توانایی یادگیری سریع‌تر و تحلیل داده‌های با حجم زیاد و پیچیده و نیز کشف و درک روابط و الگوهای پنهان بین داده‌های ورودی و خروجی اشاره کرد [۱۶]. در فرایند حل مسئله به کمک یادگیری ماشین از روش‌ها و الگوریتم‌های متفاوتی (بسته به نوع مسئله‌ی موجود) استفاده می‌شود [۱۷] که در ادامه به بررسی آن‌ها پرداخته می‌شود:

۱-۲-۱-۱ یادگیری نظارت شده^۱

یادگیری نظارت شده نوعی از یادگیری می‌باشد

1. Supervised Learning
2. Dataset
3. Feature
4. Linear Regression
5. Logistic Regression
6. Random Forest
7. Decision Trees
8. Support Vector Machines
9. k-Nearest Neighbors
10. Neural Networks
11. Naive Bayes
12. Unsupervised Learning

الگوریتم‌ها در مدل ماشینی به کار گرفته می‌شوند تا از طریق مشابهت‌یابی و بررسی ساختار پنهان در داده‌های ورودی، الگوی ذاتی بین داده‌ها را یاد بگیرند و بتوانند آن‌ها را در مجموعه‌های مناسب قرار دهند. الگوریتم‌های: میانگین k - خوشه‌بندی^۱، خوشه‌بندی سلسله‌ای^۲، DBSCAN^۳، تحلیل مؤلفه‌های اصلی^۴ و... از تکنیک‌های رایج مورد استفاده در یادگیری غیر نظارتی بشمار می‌روند. در (شکل ۳) نحوه‌ی عملکرد یادگیری غیر نظارتی نمایش داده شده است:



شکل ۳: نحوه‌ی عملکرد یادگیری غیر نظارتی

۱-۲-۳. یادگیری نیمه نظارتی^۵

یادگیری نیمه نظارتی به روشی اطلاق می‌شود که در آن، پایگاه داده شامل تعداد کمی از داده‌های برچسب‌دار و تعداد زیادی از داده‌های بدون برچسب باشد. این روش بین یادگیری نظارتی و غیر نظارتی قرار می‌گیرد و عموماً این اتفاق زمانی رخ می‌دهد که دسترسی به داده‌های برچسب‌دار هزینه‌بر یا زمان‌بر باشد، اما تعداد زیادی از داده‌های بدون برچسب در دسترس باشد؛ در

این صورت از داده‌های برچسب‌دار جهت هدایت فرایند یادگیری استفاده می‌شود و از داده‌های بدون برچسب نیز برای تعمیم‌دهی و بهبود مدل استفاده می‌شود. از الگوریتم‌های: خودآموزی^۶، هم‌آموزی^۷، انتشار برچسب^۸، مدل‌های مولد^۹ و روش‌های مبتنی بر گراف^{۱۰} می‌توان به‌عنوان تکنیک‌های متداول موجود در این روش یادگیری نام برد. یادگیری نیمه‌نظارتی در کاربردهایی مانند دسته‌بندی تصاویر، تشخیص گفتار و پردازش زبان طبیعی^{۱۱} استفاده می‌شود.

۱-۲-۴. یادگیری تقویتی^{۱۲}

نوعی یادگیری ماشینی که دارای یک عامل تقویت کننده می‌باشد و در ازای اقداماتی که به تشخیص درست منجر می‌شوند نتایج مثبت بیشتر و بیشتری کسب می‌کند. یادگیرنده در ابتدا هیچ سرنخی در مورد اینکه در انتظار چه اقدامی باید انجام دهد ندارد اما در ادامه با اجرای سیستم پاداش، الگوریتم‌هایی که به جواب درست منجر شده‌اند تقویت می‌شوند و وزن بیشتری می‌یابند. الگوریتم‌های یادگیری تقویتی برای یادگیری بهینه‌تر جهت تصمیم‌گیری از طریق تعامل با یک محیط طراحی شده‌اند. الگوریتم‌های روش‌های مونت کارلو^{۱۳}، یادگیری ارزش^{۱۴}، شبکه‌ی عمیق یادگیری ارزش^{۱۵}، روش گرادیان پلیسی^{۱۶} و SARSA^{۱۷} از تکنیک‌های متداول در بحث یادگیری تقویتی به شمار می‌روند. یادگیری تقویتی در طبقه‌بندی تصویر و سیستم‌های توصیه و رانندگی خودران استفاده می‌شود [۱۶].

1. k-Means Clustering
2. Hierarchical Clustering
3. Density-Based Spatial Clustering of Applications with Noise
4. PCA
5. Semi-supervised Learning
6. Self-Training
7. Co-Training
8. Label Propagation
9. Generative Models
10. Graph-Based Methods
11. Natural Language Processing
12. Reinforcement Learning
13. Monte Carlo Methods
14. Q-Learning
15. Deep Q-Network
16. Monte Carlo Methods
17. State-Action-Reward-State-Action





۲-۱. مطالعات پیشین به کارگیری یادگیری ماشین در حوزه‌های مختلف صنعت نفت

در سال ۲۰۱۹، لیو و همکاران به ایجاد یک مدل یادگیری عمیق شبکه عصبی حافظه بلندمدت- کوتاه مدت^۱ برای پیش‌بینی تولید نفت در میدان‌های نفتی چین پرداختند. نتایج نشان داد که مدل مذکور با دقت ۷۵ درصد میزان تولید را پیش‌بینی می‌کند و با داده‌های واقعی مطابقت دارد، این مدل پیش‌بینی تولید، به‌عنوان مدلی با دقت و سرعت بالا معرفی شد [۱۷]. در سال ۲۰۲۰، صباح و همکاران به منظور پیش‌بینی نرخ نفوذ حفاری^۲ با استفاده از داده‌های پتروفیزیکی و نگاره‌های گل حفاری به ایجاد یک مدل ماشینی پرداختند. آن‌ها از الگوریتم‌های مختلفی از جمله شبکه عصبی مصنوعی، رگرسیون بردار پشتیبان^۳ و مدل هیبریدی بهینه شده با الگوریتم بهینه‌سازی ازدحام ذرات^۴ را مورد بررسی قرار دادند. نتایج نشان داد که مدل بهینه‌سازی ادغام ذرات با دقت بالاتری نسبت به سایر مدل‌ها نرخ نفوذ حفاری را پیش‌بینی می‌کند [۱۳]. در سال ۲۰۲۱، ژانگ و همکاران با استفاده از یک مدل ماشینی به پیش‌بینی تراوایی در مخازن ماسه‌سنگی تحکیم‌یافته^۵ پرداختند. آن‌ها از داده‌های نگاره‌های سیمی مانند تراکم، مقاومت و سایر اطلاعات ژئوفیزیکی برای سه مدل پشتیبان بردار رگرسیون، جنگل تصادفی و شبکه عصبی بازمانده^۶ استفاده کردند. نتایج نشان داد که مدل شبکه عصبی بازمانده با استخراج بهترین الگوهای غیرخطی، عملکرد بهتری نسبت به سایر مدل‌ها داشت [۸]. در سال ۲۰۲۲، سالم و همکاران به منظور پیش‌بینی خرابی‌های یکپارچگی چاه^۷ به ایجاد یک مدل ماشینی پرداختند. آن‌ها به بررسی انواع مدل‌های ماشینی برای فیزیک سنگ، حفاری، بهینه‌سازی تولید، و شبیه‌سازی مخزن پرداختند. مهم‌ترین هدف این مطالعه، ارائه یک مدل یادگیری ماشین برای ارزیابی ریسک خرابی یکپارچگی چاه بود. نتایج نشان داد مدل

ماشینی توسعه یافته، می‌تواند در کاهش خطر خرابی یکپارچگی چاه و بهبود بهره‌وری مؤثر باشد [۶]. در سال ۲۰۲۳، مای-کائو و ترونک-کخ به ایجاد یک مدل ماشینی و تطبیق نتایج الگوریتم‌های مختلف یادگیری ماشین برای پیش‌بینی تولید نفت پرداختند. این مطالعه بر اساس داده‌های تولیدی یک چاه نفتی در جنوب ویتنام انجام شد. الگوریتم‌های نزدیک‌ترین همسایگی، جنگل تصادفی، رگرسیون بردار پشتیبان و مدل‌های شبکه عصبی عمیق به کار گرفته شد. نتایج نشان داد که الگوریتم‌های کلاسیک، به‌ویژه رگرسیون بردار پشتیبان، کارایی بالاتری در پیش‌بینی داده‌ها داشتند. مدل‌های شبکه عصبی در برخی موارد تطابق خوبی با داده‌های واقعی داشتند؛ اما در پیش‌بینی تغییرات ناگهانی عملکرد ضعیف‌تری نشان دادند [۱۱].

در مطالعه‌ی حاضر، به‌منظور گردآوری و تدوین یک مرجع راهنما برای پژوهشگران، مطالعات پیشین در زمینه‌ی به کارگیری مدل‌های ماشینی در مدیریت تولید ماسه شرح داده شده است و نتایج حاصل از مطالعات، براساس موضوع و کاربرد آن‌ها در بخش‌های مختلف مدیریت ماسه، شامل: پیش‌بینی تولید ماسه، کنترل و مدیریت تولید ماسه، مطالعات نرخ آستانه‌ی^۸ تولید ماسه، پیش‌بینی شرایط و رفتار تولید ماسه، نرخ و حجم تولید ماسه، توزیع اندازه‌ی ذرات تولید ماسه و پیش‌بینی کاهش فشار بحرانی کل برای تولید ماسه از چاه‌ها، مورد بررسی و تفکیک قرار گرفته است. در نهایت با جمع‌بندی و تفسیر نقاط قوت و ضعف این مطالعات، پرداخته شده است؛ بنابراین مطالعه‌ی حاضر با ارائه‌ی راهکارهای کارآمد و دقیق، می‌تواند در انجام مطالعات آینده، مدنظر قرار گیرد.

۲. مروری بر مطالعات انجام شده در زمینه‌ی کاربردهای یادگیری ماشین در تولید و مهار ماسه

در این بخش مقالات پیشین بر اساس موضوع مورد

1. LSTM
2. ROP
3. SVR
4. MLP-PSO
5. Consolidate
6. ResNet
7. Well Integrity
8. Critical Rate

مطالعه، در چند گروه (بر اساس موضوعات پرتکرار و حائز اهمیت) تفکیک و طبقه‌بندی شده است:

۱-۲. پیش‌بینی تولید ماسه

در سال ۲۰۱۱، آزاد و همکاران با داده‌های جامع حاصل از ۳۸ چاه در سه میدان نفتی به کمک یادگیری ماشین، به پیش‌بینی تولید ماسه از میداین پرداختند در مطالعه‌ی آن‌ها از شبکه‌های عصبی مصنوعی برای پیش‌بینی فشار بحرانی تولید ماسه در میداین جنوب غربی ایران استفاده شد و داده‌های ورودی شامل: پارامترهای زمین‌شناسی و فشار مخزن بود که فرایند آموزش برای مدل با استفاده از ۲۴ مجموعه داده و اعتبارسنجی مدل با ۷ مجموعه داده انجام شد. نتایج نشان داد که مدل ماشینی در مقایسه با مدل‌های تحلیلی سنتی، در پیش‌بینی شروع تولید ماسه دقت بالاتری دارد [۱۸]. در سال ۲۰۱۶، قراقیضی و همکاران با استفاده از داده‌های ۳۱ چاه در میدان‌های شمالی دریای آدریاتیک، یک مدل پیش‌بینی شرایط تولید ماسه از چاه را توسعه دادند. آن‌ها با داده‌هایی شامل: عمق عمودی کل، زمان عبور، نرخ جریان آب و... به کمک روش طبقه‌بندی ماشین بردار پشتیبان کمترین مربعات^۱ در مدل به کار گرفتند. در نهایت جهت بهینه‌سازی عملکرد مدل از تابع پایه شعاعی استفاده شد تا دقت بیشتری در تشخیص پیش‌بینی تولید ماسه حاصل گردد. نتایج نشان داد که مدل ارائه شده در این مطالعه، عملکرد بالایی در پیش‌بینی تولید ماسه از چاه‌ها دارد و می‌تواند جهت طراحی تکمیل چاه به مهندسان کمک کند [۱۹]. در سال ۲۰۱۷، اولادپس و همکاران با استفاده از داده‌های مخازن نفتی منطقه دلتای نیجر در چاه‌ها، یک مدل ماشینی را توسعه دادند و برای اولین بار از الگوریتم‌های ماشین بردار پشتیبان برای پیش‌بینی تولید ماسه استفاده کردند. در مطالعه آن‌ها ترکیبی از الگوریتم‌ها و شبیه‌سازی نرم‌افزاری برای غلبه بر محدودیت‌ها و نقاط ضعف الگوریتم‌ها استفاده شد؛ همچنین جهت تنظیم بهینه وزن پارامترها نیز از روش هسته‌ی RBF استفاده شد. آن‌ها برای ارزیابی خطا از تکنیک اعتبارسنجی متقابل استفاده کردند نتایج نشان داد که مدل ماشینی می‌تواند با دقت بالایی تولید ماسه را پیش‌بینی کند؛ همچنین استفاده از ماشین بردار پشتیبان توانست تصمیم‌گیری‌ها را بهبود بخشد و هزینه‌های تولید را کاهش دهد [۲۰]. در سال ۲۰۲۱، نوآشی

و همکاران به پیش‌بینی تولید ماسه در مخازن ماسه‌سنجی، به کمک الگوریتم‌های یادگیری ماشین پرداختند. آن‌ها از الگوریتم‌های ماشین بردار پشتیبان و شبکه‌ی عصبی مصنوعی دو لایه با الگوریتم پس‌انتشار خطا برای ساخت مدل بهینه استفاده کردند و پایگاه داده شامل: ویژگی‌های مخزنی و زمین‌شناسی چهار چاه در مخازن منطقه‌ی دلتای نیجر بود که فرایند پیش‌پردازش^۲ داده‌ها، تحلیل پیاده‌سازی و اعمال الگوریتم‌ها صورت گرفت و در نهایت به ارزیابی عملکرد هر یک از الگوریتم‌ها پرداخته شد. نتایج نشان داد که ماشین بردار پشتیبانی نسبت به شبکه عصبی مصنوعی عملکرد بهتری دارد و با دقت و کارایی بالاتری می‌تواند احتمال وقوع تولید ماسه را پیش‌بینی کند [۲۱]. در سال ۲۰۲۲، سونگ و همکاران به کمک داده‌های آزمایشگاهی حاصل از مخازن حاوی هیدرات‌های گاز طبیعی به توسعه‌ی یک مدل پیش‌بینی تولید ماسه با الگوریتم‌های یادگیری ماشین پرداختند. در مطالعه‌ی آن‌ها چهار الگوریتم اصلی یادگیری ماشین، شامل: نزدیک‌ترین همسایه، رگرسیون بردار پشتیبان، درخت تقویتی و پرسپترون چندلایه بر روی پایگاه داده اعمال شد و یک مدل پیش‌بینی ترکیبی برای تولید ماسه از طریق به‌کارگیری هر دو الگوریتم رگرسیون بردار پشتیبان و پرسپترون چندلایه نیز حاصل شد. نتایج نشان داد که الگوریتم درخت تقویتی می‌تواند با دقت بالایی تولید ماسه را پیش‌بینی کند و به‌عنوان بهترین الگوریتم شناخته شد [۲۲]. در سال ۲۰۲۳، جینگ و همکاران با استفاده از داده‌های نگاره و فرمول‌های تجربی، به کمک الگوریتم شبکه عصبی پیش‌خور به توسعه مدل پیش‌بینی تولید ماسه پرداختند. در مطالعه‌ی آن‌ها از اعمال فرمول‌های تجربی بر روی داده‌های نگاره برای یک چاه تولیدی خالص، محاسبات پیش‌بینی تولید ماسه انجام شد و در ادامه از این داده‌ها به‌عنوان ورودی برای آموزش یک مدل شبکه عصبی پس‌انتشار استفاده کردند تا برای سایر چاه‌های بلوک، یک مدل ماشینی جهت پیش‌بینی تولید ماسه ایجاد شود و دقت این مدل را از طریق تنظیم مداوم وزن‌ها و مقادیر بهبود بخشیدند و مشاهده کردند که نتایج حاصل مدل ماشینی با نتایج فرمول‌های تجربی همخوانی دارند. نتایج نشان داد که استفاده از این مدل یادگیری، می‌تواند به بهبود دقت پیش‌بینی تولید ماسه منجر شود [۲۳]. در سال ۲۰۲۳، آبه و همکاران با استفاده از ۴۵۷ مجموعه داده‌ی حاصل

1. LSSVM
2. Preprocessing



از ۴۳ چاه واقع در میدان‌های نفتی دلتای نیجر، به ایجاد یک مدل ماشینی به‌منظور پیش‌بینی تولید ماسه پرداختند. در مطالعه‌ی آن‌ها پارامترهای ورودی مورد بررسی، شامل: پیش‌بینی پارامترهای فشار دهانه چاه، اندازه گلوگاه، فشار مخزن و... و پارامترهای خروجی شامل: درصد مواد جامد و آب و درصد ماسه بود و الگوریتم‌های مختلف شبکه عصبی مصنوعی بر این پایگاه داده اعمال شدند. نتایج نشان داد که مدل‌های عصبی چندورودی تک‌خروجی^۱ و چندورودی چندخروجی^۲ دقت بالایی در پیش‌بینی این پارامترها دارند و به‌عنوان ابزارهای کارآمدی برای پیش‌بینی در میدان نفتی توصیه شدند [۲۴]. در سال ۲۰۲۳، عبدالقانی و همکاران با استفاده از داده‌های دو چاه نفتی میدان هلال به توسعه‌ی یک مدل ماشینی به‌منظور پیش‌بینی تولید ماسه و ارزیابی پارامترهای ژئومکانیکی به‌وسیله‌ی شبکه‌ی عصبی مصنوعی پرداختند. برای محاسبه‌ی پارامترهای ژئومکانیکی مانند: مدل زمین مکانیکی و پارامترهای استحکام سنگ، داده‌های مربوط به فشار منفذی^۳ به کمک روش‌های ایتون و بانرز تخمین زده شد و برای ساخت مدل زمین مکانیکی و ارزیابی پایداری چاه‌ها از پارامترهایی مانند: مدول یانگ، ضریب بایوت و نسبت پواسون بهره گرفتند و در نهایت برای جایگزینی معادلات تجربی، جهت پیش‌بینی نگاره‌های کلیدی از روش‌های شبکه‌ی عصبی مصنوعی استفاده کردند. نتایج نشان داد که مدل مبتنی بر یادگیری ماشین با داده‌های تولید واقعی همخوانی دارد و خطر تولید ماسه را به‌درستی پیش‌بینی می‌کند؛ درحالی‌که مدل مبتنی بر معادله گاردنر نتایج نادرستی ارائه داد [۲۵]. در سال ۲۰۲۴، انجوپیندو و ژوزف به‌منظور بهینه‌سازی پیش‌بینی تولید ماسه در چاه‌های نفت از الگوریتم ماشین بردار پشتیبان، جنگل تصادفی، شبکه‌ی عصبی مصنوعی و نزدیک‌ترین همسایگی استفاده کردند. آن‌ها با داده‌های موجود از ۶۳ چاه نفت، شامل پارامترهای زمین‌شناسی و مکانیکی به توسعه‌ی مدل ماشینی پرداختند و در نهایت اعتبار مدل ساخته شده را به کمک داده‌های میدانی و تکنیک‌های اعتبارسنجی متقابل و روش‌های آماری مانند: دقت، حساسیت، ضریب همبستگی متیو و ... بررسی و ارزیابی کردند. نتایج نشان داد که مدل ساخته شده به کمک ماشین بردار پشتیبان دقت بالایی در

پیش‌بینی آغاز تولید ماسه دارد و قابل اطمینان و کارآمد می‌باشد [۲۶]. در سال ۲۰۲۴، شابدیروا و همکاران به کمک داده‌های ۴۳ چاه واقع در میدان گاز کارازان‌باس، به ایجاد یک مدل ماشینی پیش‌بینی مقدار تولید ماسه پرداختند. در مطالعه‌ی آن‌ها، ابتدا داده‌هایی مانند: ضخامت و عمق مخزن از طریق محاسبه فواصل چاه، به پایگاه داده اضافه شد و یک سیستم برای اندازه‌گیری بر پایه‌ی تخلخل و نسبت ناحیه خالص به ناخالص ایجاد شد و سپس از الگوریتم‌هایی مانند: جنگل تصادفی، ماشین بردار پشتیبان، درخت تصمیم‌گیری و نزدیک‌ترین همسایه استفاده شد و داده‌ها بر اساس نزدیکی به گسل‌ها به دو گروه نزدیک و دور تفکیک و ارزیابی شدند. در نهایت به اعتبارسنجی مدرن و ارزیابی دقت آن‌ها با روش‌های خطای ریشه‌ی مربعات میانگین و ضریب تعیین R^2 پرداخته شد. نتایج نشان داد که عوامل زمین‌شناسی به‌ویژه نزدیکی به گسل‌ها تأثیر زیادی بر دقت پیش‌بینی دارند. همچنین برای ارزیابی عملکرد مدل‌های یادگیری ماشین، معیارهای جدیدی مانند دقت پیش‌بینی اوج تولید ماسه معرفی شد [۲۷]. در سال ۲۰۲۴، اسفحا و همکاران به بررسی مکانیزم‌های تولید ماسه و پیش‌بینی تولید ماسه از طریق به‌کارگیری روش‌های یادگیری نظارت‌شده، یادگیری غیر نظارتی و یادگیری عمیق پرداختند. آن‌ها در یادگیری نظارت‌شده از مدل‌هایی مانند: شبکه‌های عصبی مصنوعی و جنگل‌های تصادفی برای داده‌های تاریخی برچسب‌دار چاه، به‌منظور پیش‌بینی تولید ماسه استفاده کردند؛ در یادگیری بدون نظارت در تحلیل سیگنال‌های ارتعاشی برای کشف الگوهای مخفی در داده‌های بدون برچسب، به‌جای استفاده از الگوریتم K-means پرداخته شد. بررسی‌ها نشان داد که تجمیع این روش‌ها می‌تواند دقت پیش‌بینی را افزایش دهد و مشکلات حاصل از تولید ماسه را بهبود بخشد [۲۸].

۱-۱-۲. پیش‌بینی نرخ یا حجم تولید ماسه

در سال ۲۰۲۰، کولا و همکاران با استفاده از داده‌های ۱۴۰ مورد از مطالعات پیشین، به‌منظور پیش‌بینی نرخ ماسه آستانه^۴ در مانیتورهای صوتی ماسه، به توسعه‌ی یک مدل ماشینی پرداختند. در مطالعه‌ی آن‌ها با کمک سه الگوریتم یادگیری نظارت‌شده، شامل: جنگل تصادفی، ماشین بردار

1. MISO
2. MIMO
3. Pore Pressure
4. Threshold Sand Rate

پشتیبان و الاستیک خالص به منظور پیش‌بینی نسبت سیگنال به نویز آکوستیک^۱ از داده‌هایی شامل: نرخ ماسه آستانه، اندازه لوله‌ها، نرخ گاز و مایع و همچنین فرسایش (محاسبه شده توسط یک مدل مکانیکی) استفاده شد. نتایج نشان داد که مدل توسعه داده شده می‌تواند نرخ آستانه‌ی ماسه را تحت شرایط مختلف پیش‌بینی کند. همچنین تطابق خوب بین مدل ماشینی با داده‌های آزمایشی وجود داشت و در نهایت این مدل به‌عنوان یک ابزار پیش‌بینی کارآمد در صنعت معرفی شد [۲۹]. در سال ۲۰۲۱، ویرا و همکاران با استفاده از حدود ۲۵۰ مورد از مطالعات قبلی در زمینه‌ی تعیین نرخ آستانه ماسه در شرایط عملیاتی مختلف، به ایجاد یک مدل ماشینی پیش‌بینی نرخ آستانه تولید ماسه پرداختند. در مطالعه‌ی آن‌ها از الگوریتم‌هایی شامل: شبکه الاستیک، جنگل تصادفی و ماشین بردار پشتیبان استفاده شد و پس از آموزش و ارزیابی مدل‌ها، به تحلیل رابطه نرخ آستانه ماسه و تغییرات پارامترهای ورودی پرداختند. نتایج نشان داد که پیش‌بینی نرخ آستانه‌ی ماسه توسط مدل‌ها دقیق است و می‌تواند در جهت پیش‌بینی و مدیریت تولید ماسه راهگشا باشد [۳۰]. در سال ۲۰۲۳، شابدیروا و همکاران به منظور پیش‌بینی حجم تولید ماسه در مخازن ماسه‌سنگی غیرمستحکم آقزاقستان، یک مدل ماشینی توسعه دادند. آن‌ها با استفاده از پایگاه داده‌های چاه‌های و از ابزارهای آماری مانند برای شناسایی مقادیر پرت هر ویژگی استفاده کردند و با نمودارهای همبستگی، روابط بین ویژگی‌ها را بررسی کردند. در نهایت شش الگوریتم یادگیری ماشین شامل: رگرسیون خطی، مدل خطی تعمیم یافته با استفاده از تنظیمات لاسو یا لاستیک خالص، ماشین بردار پشتیبان، درخت تصمیم‌گیری، رگرسیون کارترین و الگوریتم نزدیک‌ترین همسایه را در مدل برای تحلیل داده‌ها به کار گرفتند. نتایج نشان داد که الگوریتم نزدیک‌ترین همسایه می‌تواند به‌خوبی رفتار و حجم تولیدی ماسه را پیش‌بینی کند [۳۱]. در سال ۲۰۲۳، چیکوی و همکاران با استفاده از داده‌های چاه‌های نفت منطقه‌ی دلتای نیجر، یک مدل ماشینی را به منظور پیش‌بینی نرخ تولید ماسه توسعه دادند. در مطالعه‌ی آن‌ها، پارامترهای بی‌بعد ورودی شامل: عدد رینولدز، عامل بارگذاری، نسبت گاز به مایع و درصد آب تولیدی و پارامتر خروجی، نرخ تولید ماسه در نظر گرفته

شده است و به منظور ارزیابی مدل از نرم‌افزار طراحی آزمایش و معادلات ریاضی استفاده شده است؛ همچنین برای تحلیل داده‌ها از روش سطح پاسخ استفاده شده است. نتایج نشان داد که مدل ماشینی توسعه یافته می‌تواند در مدیریت مخازن طراحی تکمیل چاه و برنامه‌ریزی‌های میدانی جهت بهینه‌سازی به کار رود [۳۲].

۲-۱-۲. پیش‌بینی افت فشار بحرانی کل و پیش‌بینی تولید ماسه

در سال ۲۰۱۴، خامه‌چی و همکاران به کمک داده‌های حاصل از ۳۱ چاه مربوط به ۹ میدان گازی در نواحی شمالی و مرکزی دریای آدریاتیک، یک مدل یادگیری ماشین برای پیش‌بینی تولید ماسه ایجاد کردند. در مطالعه‌ی آن‌ها افت فشار بحرانی کل به‌عنوان معیار پیش‌بینی تولید ماسه قرار داده شد؛ همچنین به منظور توسعه‌ی مدل از الگوریتم‌های رگرسیون خطی ساده، رگرسیون خطی بهبود یافته با الگوریتم ژنتیک و دو شبکه عصبی مصنوعی با الگوریتم‌های پس‌انتشار خطا و بهینه‌سازی ازدحام ذرات، استفاده کردند. نتایج نشان داد که مدل‌های شبکه عصبی، به‌ویژه شبکه عصبی مصنوعی با الگوریتم بهینه‌سازی ازدحام ذرات، توانایی و عملکرد بالاتری در پیش‌بینی تولید ماسه از خود نشان می‌دهند و نسبت به مدل‌های سنتی دقیق‌تر هستند [۳۳]. در سال ۲۰۲۲، الاکبری و همکاران به منظور پیش‌بینی افت فشار بحرانی کل و تولید ماسه، از یک مدل ماشینی استفاده کردند. آن‌ها از یک پایگاه داده شامل: ۲۳ مجموعه داده از ۱۵ چاه و اعمال الگوریتم‌های روش سطح پاسخ و ماشین بردار پشتیبان برای توسعه‌ی مدل ماشینی استفاده کردند و برای ارزیابی مدل‌ها و اطمینان از برقراری ارتباط صحیح و معنادار بین پارامترهای ورودی با خروجی، از روش‌های آماری مختلفی شامل: آزمون F، آزمون آنالیز واریانس^۲، آمارهای تناسب برازش و نمودارهای تشخیصی استفاده شد. نتایج نشان داد که مدل ماشین بردار پشتیبان با دقت بیشتری نسبت به مدل‌های موجود عمل می‌کند و خطای نسبی و مطلق کمتری دارد [۳۴]. در (جدول ۱) خلاصه‌ای از کارهای صورت گرفته در زمینه‌ی کاربرد یادگیری ماشین در پیش‌بینی تولید ماسه ذکر شده است:

1. Acoustic
2. Unconsolidated
3. ANOVA

جدول ۱: مطالعات پیشین در زمینه کاربرد یادگیری ماشین در پیش‌بینی تولید ماسه

نویسندگان مقاله (سال چاپ)	شماره منبع	هدف مطالعه	داده‌های ورودی	روش‌شناسی	اعتبارسنجی
آزاد و همکاران (۲۰۱۱)	[۱۸]	پیش‌بینی تولید ماسه	۳۸ چاه از سه میدان نفتی	شبکه‌های عصبی مصنوعی	R^2
قراقیسی و همکاران (۲۰۰۶)	[۱۹]	پیش‌بینی شرایط تولید ماسه	۳۱ چاه در دریای آدریاتیک	طبقه‌بندی ماشین بردار پشتیبان کمترین مربعات	محاسبه‌ی ماتریسی ^۱
اولادیو و همکاران (۲۰۱۷)	[۲۰]	پیش‌بینی وقوع تولید ماسه در چاه‌ها	منطقه‌ی دلتای نیجر	الگوریتم‌های ماشین بردار پشتیبان برای پیش‌بینی، روش هسته‌ی RBF برای تنظیم وزن پارامترها	اعتبارسنجی کراس به روش یک‌به‌یک ^۲
نواشی و همکاران (۲۰۲۱)	[۲۱]	پیش‌بینی تولید ماسه در مخازن ماسه‌سنگی	چهار چاه در مخازن منطقه دلتای نیجر	ماشین بردار پشتیبان و شبکه‌ی عصبی مصنوعی دو لایه	Confusion Matrix, Precision, Recall, F1-Score
سونگ و همکاران (۲۰۲۲)	[۲۲]	توسعه‌ی یک مدل پیش‌بینی تولید ماسه	مخازن حاوی هیدرات‌های گاز طبیعی	نزدیک‌ترین همسایه، رگرسیون بردار پشتیبان، درخت تقویتی و پرسپترون چند لایه	R^2 و میانگین مربعات خطا ^۳
جینگ و همکاران (۲۰۲۳)	[۲۳]	پیش‌بینی تولید ماسه	داده‌های نگاره و فرمول‌های تجربی	شبکه عصبی پیش‌خور	تطابق با نتایج فرمول‌های تجربی
آبوه و همکاران (۲۰۲۳)	[۲۴]	پیش‌بینی تولید ماسه	۴۵۷ مجموعه داده‌ی حاصل از ۴۳ چاه در نیجر	الگوریتم‌های مختلف شبکه عصبی مصنوعی	R^2 و میانگین مربعات خطا ^۳
عبدالقانی و همکاران (۲۰۲۳)	[۲۵]	پیش‌بینی تولید ماسه و ارزیابی پارامترهای ژئومکانیکی	دو چاه نفتی میدان هلال	شبکه عصبی مصنوعی	تطابق با داده‌های واقعی تولیدی
انجوپیندو و ژوزف (۲۰۲۴)	[۲۶]	بهینه‌سازی پیش‌بینی تولید ماسه در چاه‌های نفت	۶۳ چاه نفت	ماشین بردار پشتیبان، جنگل تصادفی، شبکه‌ی عصبی مصنوعی و نزدیک‌ترین همسایگی	دقت، حساسیت، ضریب همبستگی متیو و ...
شایدیرو و همکاران (۲۰۲۴)	[۲۷]	ایجاد یک مدل پیش‌بینی مقدار تولید ماسه در میدان کارازان‌بایس	۴۳ چاه واقع در میدان گاز کارازان-بایس	جنگل تصادفی، ماشین بردار پشتیبان، درخت تصمیم‌گیری و نزدیک‌ترین همسایگی	R^2 و میانگین مربعات خطا ^۳
اسفخا و همکاران (۲۰۲۴)	[۲۷]	مکانیزم‌های تولید ماسه در چاه‌های نفت و گاز و روش‌های پیش‌بینی تولید ماسه	داده‌های تاریخی چاه منتخب	انواع روش‌های یادگیری نظارت‌شده، روش‌های یادگیری غیرنظارتی و یادگیری عمیق	تطابق با نتایج حاصل از ارزیابی چاه
کولا و همکاران (۲۰۲۰)	[۲۹]	پیش‌بینی نرخ ماسه آستانه	۱۴۰ مورد از مطالعه‌های پیشین	جنگل تصادفی، ماشین بردار پشتیبان و الاستیک خالص	تطابق خوب با داده‌های آزمایشی
ویرا و همکاران (۲۰۲۱)	[۳۰]	تعیین نرخ آستانه‌ی ماسه در شرایط عملیاتی مختلف	حدود ۲۵۰ مورد از مطالعات قبلی	شبکه الاستیک، جنگل تصادفی و ماشین بردار پشتیبان	تطابق با مدل مکانیکی چاه
شایدیرو و همکاران (۲۰۲۳)	[۳۱]	پیش‌بینی حجم تولید ماسه در مخازن ماسه‌سنگی ضعیف قزاقستان	مخازن ماسه‌سنگی قزاقستان	رگرسیون خطی، مدل خطی تعمیم یافته، ماشین بردار پشتیبان، درخت تصمیم‌گیری، رگرسیون کارترین و الگوریتم نزدیک‌ترین همسایگی	تطابق با تاریخچه‌ی تولید ماسه‌ی میدان
چیکوی و همکاران (۲۰۲۳)	[۳۲]	پیش‌بینی نرخ تولید ماسه	چاه‌های نفت منطقه‌ی دلتای نیجر	منحنی سطح پاسخ ^۴	تحلیل خطا ^۵ و کراس پلات‌ها ^۶
خامه‌چی و همکاران (۲۰۱۴)	[۳۳]	پیش‌بینی تولید ماسه و افت فشار بحرانی کل	۳۱ چاه گازی در دریای آدریاتیک	رگرسیون خطی ساده، رگرسیون خطی بهبود یافته با الگوریتم ژنتیک و دو شبکه عصبی مصنوعی متفاوت	APE, AAPE, MSE, MINAPE, MAXAPE, R^2
الاکبری و همکاران (۲۰۲۳)	[۳۴]	پیش‌بینی افت فشار بحرانی کل و پیش‌بینی تولید ماسه	۲۳ مجموعه داده از چاه‌ها	روش سطح پاسخ و ماشین بردار پشتیبان	آزمون F، آزمون آنالیز واریانس و نمودارهای تشخیصی

1. Evaluation of the quality of a classification model is to compute a confusion matrix of the actual class versus predicted class
2. Leave-one-out cross validation
3. MSE
4. Response Surface Method (RSM)
5. Error Analysis
6. Cross Plots

۲-۲. کنترل و مدیریت تولید ماسه در چاهها

در سال ۲۰۱۸، کتملی و باندیوپاندیاه، به توسعه‌ی یک مدل ماشینی بر اساس الگوریتم شبکه‌های عصبی مصنوعی برای مدیریت تولید ماسه با داده‌های حاصل از نگاره عبور صوتی و چگالی حجمی و سایر نگاره‌ها پرداختند. در مطالعه‌ی آن‌ها برای یادگیری الگوهای پاسخ از سایر نگاره‌های مرتبط، مانند مقاومت الکتریکی، گامای شعاعی و تخلخل نوترونی، یک مدل ساخته شد. در نهایت مدل آموزش‌دیده بر روی داده‌های جدید نیز آزمایش شد و مشخص شد که قابلیت تعمیم‌پذیری دارد و عملکرد مدل توسط سایر روش‌های مصنوعی مانند معادله گاردنر، سنتز عمق، سنتز تخلخل و وارونگی لرزه‌ای ارزیابی شد. نتایج نشان داد که پیش‌بینی‌های این مدل‌های جدید با تولید واقعی ماسه همخوانی دارند و استفاده از این روش باعث کاهش هزینه‌ها و ریسک‌ها در زمینه‌ی مدیریت مخازن می‌شود [۳۵]. در سال ۲۰۲۲، لوفای و همکاران با استفاده از یک پایگاه داده‌ی کنترل تولید ماسه‌ی مربوط به بیش از ۱۹۰۰ چاه، به ایجاد یک مدل ماشینی برای بهینه‌سازی کنترل ماسه پرداختند. در مطالعه‌ی آن‌ها داده‌ها ابتدا پیش‌پردازش شدند و ویژگی‌های کلیدی برای ساخت یک مدل طبقه‌بندی شده‌ی کنترل تولید ماسه مشخص شدند.

چهار الگوریتم، شامل: نزدیک‌ترین همسایگی، ماشین بردار پشتیبان، درخت تصمیم‌گیری و جنگل تصادفی بر روی داده‌ها اعمال شدند. نتایج نشان داد که مدل جنگل تصادفی، بهترین عملکرد را نسبت به سایر الگوریتم‌ها دارد و با دقت بالا می‌تواند به‌عنوان یک مدل تشخیصی برای ارزیابی و انتخاب روش‌های کنترل ماسه در مخازن مختلف به‌صورت مؤثر عمل کند [۳۶]. در سال ۲۰۲۳، عبدالحمید و همکاران با استفاده از پایگاه داده‌ی غیرساختاریافته‌ی مربوط به ۳۶۱ چاه، به توسعه‌ی یک مدل ماشینی بهینه‌سازی کنترل تولید ماسه پرداختند. در مطالعه‌ی آن‌ها از الگوریتم‌هایی مانند: شبکه مصنوعی عمیق، پردازش زبان طبیعی و تشخیص کاراکترهای نوری استفاده شد و اطلاعات جدولی تصاویر به‌صورت جدول طبقه‌بندی و پردازش شدند. آن‌ها برای تحلیل داده‌های بزرگ مقیاس، فرایندهایی طراحی کردند که جستجو و تحلیل داده‌ها را با دقت بالا انجام دهد. نتایج نشان داد که این تکنیک می‌تواند به بهبود کنترل تولید ماسه در میدان‌های نفتی نروژ کمک شایانی کند [۳۷]. در (جدول ۲) خلاصه‌ای از کارهای صورت گرفته در زمینه‌ی کاربرد یادگیری ماشین در کنترل تولید ماسه ذکر شده است:

جدول ۲: مطالعات پیشین در زمینه‌ی کاربرد یادگیری ماشین در کنترل و مدیریت تولید ماسه

نویسندگان مقاله (سال چاپ)	شماره منبع	هدف مطالعه	داده‌های ورودی	روش‌شناسی	اعتبارسنجی
کتملی و باندیوپاندیاه (۲۰۱۸)	[۳۵]	مدیریت تولید ماسه	نگار عبور صوتی و چگالی حجمی و سایر نگاره‌ها	اساس الگوریتم شبکه‌های عصبی مصنوعی	تطابق با تولید واقعی ماسه
لوفای و همکاران (۲۰۲۲)	[۳۶]	بهینه‌سازی کنترل ماسه	داده‌ی کنترل تولید ماسه‌ی مربوط به بیش از ۱۹۰۰ چاه	نزدیک‌ترین همسایگی، ماشین بردار پشتیبان، درخت تصمیم‌گیری و جنگل تصادفی	F1 score, Precision, Recall
عبدالحمید و همکاران (۲۰۲۳)	[۳۷]	بهینه‌سازی مدیریت و کنترل تولید ماسه در میدان‌های نفتی نروژ	داده‌های غیر ساختاریافته‌ی ۳۶۱ چاه	شبکه مصنوعی عمیق، پردازش زبان طبیعی و تشخیص کاراکترهای نوری	-

۲-۳. توزیع اندازه‌ی دانه‌ها و تأثیر آن‌ها بر روی تولید ماسه

در سال ۲۰۲۴، لیو از داده‌های یک میدان نفتی در خلیج بیبو^۱ در دریای جنوبی چین به‌منظور توسعه‌ی یک مدل ماشینی برای پیش‌بینی پروفایل اندازه دانه‌های متوسط^۲ در مخازن ماسه‌ای غیرمستحکم و کنترل تولید ماسه پرداخت.

در مطالعه‌ی وی دو مدل یادگیری ماشینی XG Boost و شبکه عصبی مصنوعی را به‌منظور افزایش دقت پیش‌بینی به‌صورت ترکیبی به‌کار گرفته شده‌اند. در این مدل با وزن‌دهی به مدل‌ها با روش معکوس خطا و مهندسی ویژگی‌ها، یک

1. Beibu Gulf
2. d50



دادند و داده‌های به‌دست آمده از چاه اول برای آموزشی مدل ماشینی به کار گرفته شد و مدل به‌دست آمده بر روی داده‌های چاه دوم آزمایش شد و مدل به‌دست آمده، برای تخمین توزیع اندازه دانه‌های ماسه در سایر چاه‌ها نیز به کار گرفته شد و توانست خواص ماسه‌ی تولیدی از جمله: ترکیب مواد تشکیل دهنده، اندازه متوسط دانه‌ها و سایر عوامل تأثیرگذار بر تولید ماسه را پیش‌بینی کند. نتایج نشان داد که انتخاب نرخ تولید بهینه و فشارهای ایمن برای جلوگیری از انباشت ماسه در چاه مذکور ضروری است و باید از سیستم‌های کنترل ماسه مانند گراول‌پک و نیز طراحی مناسب حفاری استفاده شود [۳۹]. در (جدول ۳) خلاصه‌ای از کارهای صورت گرفته در زمینه‌ی کاربرد یادگیری ماشینی برای توزیع اندازه‌ی دانه‌ها و تأثیر آن‌ها بر روی تولید ماسه ذکر شده است:

جدول ۳: مطالعات پیشین در زمینه‌ی کاربرد یادگیری ماشینی برای توزیع اندازه‌ی دانه‌ها و تأثیر آن‌ها بر روی تولید ماسه

نویسندگان مقاله (سال چاپ)	شماره منبع	هدف مطالعه	داده‌های ورودی	روش‌شناسی	اعتبارسنجی
لیو (۲۰۲۴)	[۳۸]	پیش‌بینی پروفایل اندازه دانه‌های متوسط در مخزن ماسه‌ای غیر مستحکم و کنترل تولید ماسه	یک میدان نفتی در خلیج بیبو	XG Boost و شبکه عصبی مصنوعی به‌صورت ترکیبی	تطبیق با داده‌های اندازه‌گیری شده
حکیمی داوود و همکاران (۲۰۲۴)	[۳۹]	پیش‌بینی و تخمین توزیع اندازه سازندهای تحت‌الارضی و تأثیر آن بر روی عوامل تولید ماسه	یک مخزن در نواحی فراساحل مالزی	شبکه عصبی مصنوعی	تطبیق با داده‌های مخزن

بررسی مطالعات و نتایج حاصل از آن‌ها نشان داد:

۱. الگوریتم‌های یادگیری ماشینی با توانایی تحلیل داده‌های پیچیده، در پیش‌بینی نتایج، عملکرد قابل توجهی ارائه کردند؛ به‌طوری‌که دقت مدل‌های توسعه‌یافته‌ی ماشینی نسبت به روش‌های سنتی تحلیل داده‌های ماسه، دارای دقت بالاتر و عملکرد بهتری می‌باشند. از این‌رو می‌توانند جایگزین مناسبی برای روش‌های سنتی محسوب شوند.

۲. با توجه به مطالعات ارائه شده و نتایج حاصل از (جدول ۱، ۲ و ۳)، می‌توان دریافت که ماشین بردار پشتیبان، شبکه‌ی عصبی مصنوعی و جنگل تصادفی پرتکرارترین الگوریتم‌های به کار گرفته شده در زمینه‌ی تولید ماسه می‌باشند که نشانگر توانایی این تکنیک‌ها در ایجاد مدل‌های دقیق برای تشخیص و پیش‌بینی تولید ماسه می‌باشد. در برخی از مطالعات نیز از ترکیب چند روش

مدل ترکیبی شامل اطلاعات چند بعدی ارائه شد. نتایج نشان داد که این مدل ترکیبی می‌تواند دقت پیش‌بینی پروفایل اندازه دانه‌های متوسط را تا ۱۶/۵ درصد نسبت به مدل‌های منفرد بهبود بخشد و کاربرد موفق‌تری در طراحی لایه‌بندی ماسه برای کنترل تولید ماسه در چاه‌های مجاور داشته باشد [۳۸]. در سال ۲۰۲۴، حکیمی داوود و همکاران با استفاده از داده‌های یک مخزن در نواحی فراساحل مالزی به توسعه‌ی مدل ماشینی برای پیش‌بینی و تخمین توزیع اندازه سازندهای تحت‌الارضی و تأثیر آن بر روی عوامل تولید ماسه پرداختند. در مطالعه‌ی آن‌ها برای تطبیق داده‌های مخزن با داده‌های NMR از تکنیک‌های آماری و الگوریتم‌هایی مانند شبکه عصبی مصنوعی استفاده شد. آن‌ها برای حذف اثرات هیدروکربن‌ها در مخزن یک فرایند جایگزینی سیال انجام

به‌طور کلی در سال‌های اخیر به دلیل اهمیت روزافزون بهره‌گیری از تکنیک‌های یادگیری ماشینی برای حل مسائل مرتبط با چالش‌ها و معضلات ایجاد شده‌ی ناشی از تولید ماسه در چاه‌ها می‌باشد که نشانگر حرکت صنعت نفت و گاز، در سراسر جهان، در جهت استفاده از الگوریتم‌های یادگیری ماشینی در مواجهه با چالش تولید ماسه می‌باشد.

۳. نتیجه‌گیری

در مطالعه‌ی حاضر، نحوه‌ی به‌کارگیری مدل‌های ماشینی و ارزیابی عملکرد آن‌ها برای مدیریت تولید ماسه در چاه‌های نفت و گاز، در مطالعات پیشین شرح داده شد؛ همچنین به‌منظور درک بهتر روش‌های استفاده از یادگیری ماشینی در هریک از مطالعات، الگوریتم‌های به کار گرفته شده و روش انجام کار آن‌ها در دسته‌بندی‌های مرتبط ذکر شد. درنهایت، بررسی و تحلیل نتایج موفقیت‌آمیز مطالعات مذکور می‌تواند برای انجام مطالعات آینده راهگشا باشد.

با یکدیگر برای ایجاد مدل کارآمدتر استفاده شده است و نتایج نشان داد که در صورت ترکیب درست الگوریتم‌ها، می‌توان دقت مدل را افزایش داد.

۳. در مطالعات پیشین، هر یک از محققان با توجه به ویژگی‌ها و ماهیت پایگاه داده‌ی مورد مطالعه، شامل شرایط عملیاتی چاه و خصوصیات مخزن، از الگوریتم‌های مشخصی جهت بهینه‌سازی مدل‌ها

استفاده کرده‌اند که بیشترین همخوانی احتمالی با پایگاه داده را داشته باشد.

۴. در برخی از مطالعات، به کارگیری تعداد محدودی از الگوریتم‌ها، می‌تواند در دستیابی به بهترین مدل، محدودیت ایجاد کند؛ بنابراین می‌توان از سایر الگوریتم‌های مرتبط نیز جهت بهبود دقت و عملکرد مدل، در این مطالعات استفاده کرد.

فهرست علائم اختصاری

AI	هوش مصنوعی (Artificial Intelligence)
ANN	شبکه عصبی مصنوعی (Artificial Neural Network)
SVM	ماشین بردار پشتیبان (Support Vector Machine)
RF	جنگل تصادفی (Random Forest)
KNN	نزدیک‌ترین همسایگی (K-Nearest Neighbors)
DT	درخت تصمیم‌گیری (Decision Tree)
XGBoost	گرا دیان تقویتی شدید (Extreme Gradient Boosting)
MLP	پرسپترون چندلایه (Multi-Layer Perceptron)
RSM	روش سطح پاسخ (Response Surface Methodology)
LSTM	حافظه بلندمدت-کوتاهمدت (Long Short-Term Memory)
PSO	بهینه‌سازی ازدحام ذرات (Particle Swarm Optimization)
RBF	تابع پایه شعاعی (Radial Basis Function)
DBSCAN	خوشه‌بندی مبتنی بر چگالی با نویز (Density-Based Spatial Clustering of Applications with Noise)
PCA	تحلیل مؤلفه‌های اصلی (Principal Component Analysis)
NMR	رزونانس مغناطیسی هسته‌ای (Nuclear Magnetic Resonance)
R ²	ضریب تعیین (Coefficient of Determination)
MSE	میانگین مربعات خطا (Mean Squared Error)
APE	خطای درصد مطلق (Absolute Percentage Error)
AAPE	میانگین خطای درصد مطلق (Average Absolute Percentage Error)
MINAPE	حداقل خطای درصد مطلق (Minimum Absolute Percentage Error)
MAXAPE	حداکثر خطای درصد مطلق (Maximum Absolute Percentage Error)
F1-Score	معیار اف ۱ (F1 Score)
IoT	اینترنت اشیا (Internet of Things)



- seismic attributes and wireline data. *Journal of Petroleum Science and Engineering*, 2019. 176: p. 762-774.
- [8]. Zhang, G., et al., Pattern visualization and understanding of machine learning models for permeability prediction in tight sandstone reservoirs. *Journal of Petroleum Science and Engineering*, 2021. 200: p. 108142.
- [9]. Laalam, A., et al. Application of Machine Learning for Mineralogy Prediction from Well Logs in the Bakken Petroleum System. in *SPE Annual Technical Conference and Exhibition? 2022. SPE*.
- [10]. Xie, C., et al., Intelligent modeling with physics-informed machine learning for petroleum engineering problems. *Advances in Geo-Energy Research*, 2023. 8(2).
- [11]. Mai-Cao, L. and H. Truong-Khac, A comparative study on different machine learning algorithms for petroleum production forecasting. *Improved Oil and Gas Recovery*, 2022. 6.
- [12]. Ojedapo, B., S.S. Ikiensikimama, and V.U. Wachikwu-Elechi. Petroleum Production Forecasting Using Machine Learning Algorithms. in *SPE Nigeria Annual International Conference and Exhibition. 2022. SPE*.
- [13]. Sabah, M., et al., A machine learning approach to predict drilling rate using petrophysical and mud logging data. *Earth Science Informatics*, 2019. 12: p. 319-339.
- [14]. Hopgood, A.A., The state of artificial intelligence. *Advances in computers*, 2005. 65: p. 1-75.
- [15]. Krithiga, G., V. Mohan, and S. Senthilkumar, A BRIEF REVIEW OF THE
- [1]. Cui, L., et al., A survey on application of machine learning for Internet of Things. *International Journal of Machine Learning and Cybernetics*, 2018. 9: p. 1399-1417.
- [2]. Zhu, M., et al., A review of the application of machine learning in water quality evaluation. *Eco-Environment & Health*, 2022. 1(2): p. 107-116.
- [3]. Pandey, R.K., A.K. Dahiya, and A. Mandal, Identifying applications of machine learning and data analytics based approaches for optimization of upstream petroleum operations. *Energy Technology*, 2021. 9(1): p. 2000749.
- [4]. Otchere, D.A., et al., Application of supervised machine learning paradigms in the prediction of petroleum reservoir properties: Comparative analysis of ANN and SVM models. *Journal of Petroleum Science and Engineering*, 2021. 200: p. 108182.
- [5]. Anifowose, F.A., J. Labadin, and A. Abdulraheem, Ensemble machine learning: An untapped modeling paradigm for petroleum reservoir characterization. *Journal of Petroleum Science and Engineering*, 2017. 151: p. 480-487.
- [6]. Salem, A.M., M.S. Yakoot, and O. Mahmoud, Addressing diverse petroleum industry problems using machine learning techniques: literary methodology—spotlight on predicting well integrity failures. *ACS omega*, 2022. 7(3): p. 2504-2519.
- [7]. Anifowose, F., A. Abdulraheem, and A. Al-Shuhail, A parametric study of machine learning techniques in petroleum reservoir permeability prediction by integrating



Based on Deep Learning and BP Neural Network. in ARMA US Rock Mechanics/ Geomechanics Symposium. 2023. ARMA.

- [24]. Abuh, F.A., J.U. Akpabio, and A.N. Okon, Machine Learning-Based Models for Basic Sediment & Water and Sand-Cut Prediction in Matured Niger Delta Fields. *Journal of Energy Research and Reviews*, 2023. 15(2): p. 70-93.
- [25]. Abdelghany, W.K., M. Hammed, and A.E. Radwan, Implications of machine learning on geomechanical characterization and sand management: a case study from Hilal field, Gulf of Suez, Egypt. *Journal of Petroleum Exploration and Production Technology*, 2023. 13(1): p. 297-312.
- [26]. Ngochindo, G.N. and A. Joseph, Predicting Onset of Sand Production in Oil Wells using Machine Learning. *Journal of Engineering Research and Reports*, 2024. 26(4): p. 165-176.
- [27]. Shabdirova, A., et al., Sand Production Prediction with Machine Learning using Input Variables from Geological and Operational Conditions in the Karazhanbas Oilfield, Kazakhstan. *Natural Resources Research*, 2024: p. 1-17.
- [28]. Asfha, D.T., et al., Mechanisms of sand production, prediction—a review and the potential for fiber optic technology and machine learning in monitoring. *Journal of Petroleum Exploration and Production Technology*, 2024: p. 1-40.
- [29]. Kolla, S.S., et al. Utilizing artificial intelligence for determining threshold sand rates from acoustic monitors. in *SPE Annual Technical Conference and Exhibition?* 2020. SPE.
- [30]. Vieira, R.E., B. Xu, and S.A. Shirazi. DEVELOPMENT PATH OF ARTIFICIAL INTELLIGENCE AND ITS SUBFIELDS. 2023.
- [16]. Chaudhary, S., et al., A brief review of machine learning and its applications. *SAMRIDDHI: A Journal of Physical Sciences, Engineering and Technology*, 2020. 12(SUP 1): p. 218-223.
- [17]. Liu, W., W.D. Liu, and J. Gu. Petroleum production forecasting based on machine learning. in *Proceedings of the 2019 3rd International Conference on Advances in Image Processing*. 2019.
- [18]. Azad, M., et al., A new approach to sand production onset prediction using artificial neural networks. *Petroleum science and technology*, 2011. 29(19): p. 1975-1983.
- [19]. Gharagheizi, F., et al., Prediction of sand production onset in petroleum reservoirs using a reliable classification approach. *Petroleum*, 2017. 3(2): p. 280-285.
- [20]. Olatunji, O.O. and O. Micheal. Prediction of sand production from oil and gas reservoirs in the Niger Delta using support vector machines SVMs: A binary classification approach. in *SPE Nigeria Annual International Conference and Exhibition*. 2017. SPE.
- [21]. Ngwashi, A.R., D.O. Ogbe, and D.O. Udebhulu. Evaluation of machine-learning tools for predicting sand production. in *SPE Nigeria Annual International Conference and Exhibition*. 2021. SPE.
- [22]. Song, J., et al., Comparison of Machine Learning Algorithms for Sand Production Prediction: An Example for a Gas-Hydrate-Bearing Sand Case. *Energies*, 2022. 15(18): p. 6509.
- [23]. Jing, H., et al. Sand Production Prediction



- [38].Liu, S., A Grain Size Profile Prediction Method Based on Combined Model of Extreme Gradient Boosting and Artificial Neural Network and Its Application in Sand Control Design. SPE Journal, 2024: p. 1-15.
- [39].Daud, M.S.H., S.M. Tabatabai, and F.K. Wong. Cascaded Machine Learning in NMR: Unveiling a Continuous Grain Size Distribution Approach for Tackling Sand Production Challenges. in SPWLA Annual Logging Symposium. 2024. SPWLA.
- Prediction of Sand Transport in Horizontal and Inclined Flow Based on Machine Learning Algorithms. in PSIG Annual Meeting. 2021. PSIG.
- [31].Shabdirova, A., et al. A Novel Approach to Sand Volume Prediction Using Machine Learning Algorithms. in International Petroleum Technology Conference. 2023. IPTC.
- [32].Chikwe, A.O., et al., A Response Surface Model for Predicting Sand Production Rate for Oil Wells in the Niger Delta. Petroleum & Coal, 2024. 66(1).
- [33].Khomehchi, E., I.R. Kivi, and M. Akbari, A novel approach to sand production prediction using artificial intelligence. Journal of Petroleum Science and Engineering, 2014. 123: p. 147-154.
- [34].Alakbari, F.S., et al., Prediction of critical total drawdown in sand production from gas wells: Machine learning approach. The Canadian Journal of Chemical Engineering, 2023. 101(5): p. 2493-2509.
- [35].Ketmalee, T. and P. Bandyopadhyay. Application of neural network in formation failure model to predict sand production. in Offshore Technology Conference Asia. 2018. OTC.
- [36].Laoufi, H., et al. Selection of sand control completion techniques using machine learning. in ARMA/DGS/SEG International Geomechanics Symposium. 2022. ARMA.
- [37].Abdul Hamid, Z.H., et al. A Use Case of Production and Sand Control Benchmarking Through Unstructured Data and Machine Learning Analysis. in SPE Asia Pacific Oil and Gas Conference and Exhibition. 2023. SPE.



Machine Learning Applications in the Prediction and Management of Sand Production in Oil and Gas Wells-a Review Study

Mohammad Elyas Khodashenas¹, Meysam Mohammadzadeh Shirazi², Behnam Shahsavani^{2*}

1. M.Sc. student, Department of Petroleum Engineering, School of Chemical Engineering, Oil and Gas, Shiraz University, Shiraz, Iran
2. Assistant Professor, Department of Petroleum Engineering, School of Chemical Engineering, Oil and Gas, Shiraz University, Shiraz, Iran

ARTICLE INFO

REVIEW ARTICLE

Article History:

Received: 18 February 2025

Revised: 20 May 2025

Accepted: 07 Jun 2025

Keywords:

Sand Production Prediction
Production and Productivity
Oil Production
Artificial Intelligence
Machine Learning

ABSTRACT

Sand production in oil and gas wells leads to numerous issues, including reduced well productivity and equipment damage. To mitigate the challenges and consequences of sand production, implementing sand prediction and control processes in wells is recommended. These processes involve evaluating multiple factors, such as well depth, formation failure gradient, and other geological parameters. Due to the vast volume of data and the complexity of analysis, conventional traditional methods are time-consuming and prone to significant uncertainties and errors. Consequently, the adoption of more efficient methods has gained considerable importance. In recent years, the application of machine learning techniques for analyzing large and complex datasets has emerged as an effective and accurate approach to improving prediction accuracy. As a result, production engineers have utilized machine learning algorithms to analyze data related to sand production. This study provides a review of previous research on the application of machine learning in managing sand production. To facilitate better understanding, the referenced studies have been categorized and organized based on their focus. Furthermore, the algorithms and validation methods used in each study are specified to serve as a guide. Therefore, this study can serve as a reference for future research in this field.

DOR: [20.1001.1.25011083.1404.02.30](https://doi.org/10.25011083.1404.02.30)

How to cite this article

M.E. Khodashenas, M. Mohammadzadeh Shirazi, B. Shahsavani, Machine Learning Applications in the Prediction and Management of Sand Production in Oil and Gas Wells-a Review Study. *Iranian Journal of Gas Engineering*. 2025 12(1): 54-69. (https://www.ijge.irangi.org/article_725750.html)

* Corresponding Author.

E-mail address: b.shahsavani@shirazu.ac.ir, (B. Shahsavani).

Available online 22 Jun 2025

25885-5251/© 2014 The Authors. Published by Iranian Gas Institute.

This is an open access article under the CC BY license. (<https://creativecommons.org/licenses/by/4.0>)

