



وقائم مؤتمرات جامعة سبها  
Sebha University Conference Proceedings

Conference Proceeding homepage: <http://www.sebhau.edu.ly/journal/CAS>



مقارنة أداء نماذج وكلاء الذكاء الاصطناعي في تشخيص ومعالجة مشاكل تساقط الطبقات **Sloughing shale** في آبار النفط العميقة: دراسة حالة بئر بعمق 20,000 قدم

خالد صالح حموده

الأكاديمية الليبية للدراسات العليا ، بنغازي ، ليبيا

الكلمات المفتاحية:

الذكاء الاصطناعي  
الحفر  
محاكاة  
نموذج الذكاء الاصطناعي  
وكيل الذكاء الاصطناعي

الملخص

تناولت هذه الورقة دراسة تطبيقية لاستخدام 16 نموذجًا ووكيل ذكاء الاصطناعي في تحليل مشكلة تقنية حدثت أثناء حفر بئر نفط بعمق 20,000 قدم و المتمثلة في تساقط الطبقات المحفورة في صورة قطع مختلفة الحجم و السمك تسمى **sloughing shale**. زود الذكاء الاصطناعي بمعلومات متنوعة تشمل صور، نصوص، فيديوهات، بيانات رقمية، مع حجب المعلومات الحساسة مثل اسم و احداثيات البئر حفاظًا على الخصوصية. طلب من الذكاء الاصطناعي تحديد اسم المشكلة و تشخيصها بدقة و اقتراح حلول فعالة للمعالجة و ايضا تقديم توصيات للوقاية المستقبلية من تكرارها. بالإضافة إلى ذلك طلب من الذكاء الاصطناعي اختيار نوع و تصميم خواص سائل الحفر المناسب لهذا العمق الذي وقعت فيه المشكلة الي جانب اقتراح بارامترات الحفر المثلى للمساعدة في منع و تكرار هذه المشكلة مستقبلا. أظهرت النتائج تفاوتًا في دقة الأداء بين النماذج والوكلاء حيث تفوق وكلاء الذكاء الاصطناعي مثل **Manus** و **Minmax** بدقة تصل إلى 100% في تشخيص المشكلة واقتراح الحلول العلاجية و الوقائية بينما حققت نماذج الذكاء الاصطناعي مثل **GPT** و **Gemini** دقة تتراوح بين 90% و 95%. أما بقية النماذج فقد بلغت دقتها حوالي 80%. تعكس هذه النتائج الإمكانيات الكبيرة للذكاء الاصطناعي في تحسين عمليات الحفر النفطية، سواء من حيث التشخيص المبكر للمشاكل أو تصميم الحلول التقنية، كما تبرز دوره الفعال في تدريب وتطوير الكوادر العاملة من خلال محاكاة سيناريوهات الحفر والتعامل مع التحديات التشغيلية. تؤكد الدراسة على أهمية دمج وكلاء الذكاء الاصطناعي المتقدم ضمن منظومة العمل في قطاع النفط والغاز لتعزيز الكفاءة التشغيلية، وتقليل المخاطر، وخفض التكاليف، مما يفتح آفاقًا جديدة لتسريع التحول الرقمي في هذا القطاع الحيوي.

**A Comparative Analysis of AI Models and Agents for Diagnosing and Mitigating Sloughing Shale Issues in Deep Oil Wells: A Case Study of a 20,000-Foot Well**

Khalid Hamoudah

Libyan Academy for Postgraduate Studies, Benghazi, Libya

**Keywords:**

Artificial intelligence  
AI model  
AI agent  
Drilling  
Simulation

**ABSTRACT**

This scientific paper introduces an applied study using 16 artificial intelligence (AI) models and agents to manage a technical problem encountered while drilling a 20,000 ft oil well. The issue was sloughing shale, where formation layers collapse into the wellbore. The AI systems were trained on a comprehensive dataset of images, texts, videos, & numerical data, with sensitive details like well location and company name withheld for confidentiality. The AI identified and diagnosed the problem, proposed effective treatments, and recommended preventative measures. Furthermore, it was required to design a suitable drilling fluid for the problematic depth and suggest optimal drilling parameters to prevent future occurrences. The results revealed a significant variance in performance. AI agents such as Minmax and Manus demonstrated 100% accuracy in diagnosing the problem and proposing both remedial and preventive solutions. In contrast, AI models like GPT and Gemini achieved 90-95% accuracy, while the remaining models performed at approximately 80%. These findings underscore the immense potential of AI in enhancing oil drilling operations, from early problem detection to designing technical solutions. The study also highlights AI's vital role in training personnel by simulating operational challenges. It concludes by emphasizing the importance

\*Corresponding author:

E-mail addresses: [khalidsalih2010@yahoo.com](mailto:khalidsalih2010@yahoo.com)

Article History : Received 20 February 2025 - Received in revised form 01 September 2025 - Accepted 07 October 2025

## 1. المقدمة

في عام 2023 نشرت دراسة حديثة تشير الى ان استخدام الذكاء الاصطناعي في عمليات حفر ابار النفط والغاز يعد تحديا كبيرا بسبب تعقيد وديناميكية النظام وللتغلب على ذلك تم تطوير نموذج الذكاء الاصطناعي الهندسي للآبار - Artificial well engineering intelligence - AWEL الذي يربط عدة نماذج هندسية على شكل خدمات مصغرة microservices لتحليل وتوقع المشاكل التشغيلية مثل عدم استقرار البئر، تآكل رأس الحفر، تآكل انابيب التغليف، حيث أظهرت النتائج أن هذه التقنية يمكنها التنبؤ بالمشاكل بدقة عالية وتقديم حلول شبه مثالية فعالة في الوقت الفعلي مما يدعم اتخاذ القرار الفعال أثناء الحفر ويزيد من شفافية العمليات الحسابية المستخدمة في الذكاء الاصطناعي [4].

ولأهمية الذكاء الاصطناعي في صناعة النفط والغاز استثمرت شركات كبرى مثل Shell و BP و ExxonMobil في منصات الذكاء الاصطناعي للصيانة التنبؤية حيث تعتمد هذه النماذج على تحليل بيانات أجهزة الاستشعار في الوقت الحقيقي للتنبؤ بالأعطال قبل وقوعها فعلى سبيل المثال طبقت شركة shell صيانة تنبؤية مدعومة بالذكاء الاصطناعي على أكثر من 10000 بئر تشغيلي مما أدى الى خفض الأعطال غير المخطط لها بنسبة 20% وتقليل تكاليف الصيانة بنسبة 15% كما ساهمت في تحسين كفاءة القوى العاملة وسلامة العمليات وإطالة عمر البئر وتقليل المخاطر التشغيلية [19,20,21]. أظهرت دراسة منشورة في مجلة علمية ان الذكاء الاصطناعي وتحديدًا خوارزميات التعلم الآلي يمكنها التنبؤ بحدوث المشاكل في آبار النفط والغاز مثل التسريبات خلف انابيب التغليف casing leakage او تدفق سوائل الطبقات الغير مرغوب فيها من خلال تحليل بيانات التشغيل التاريخية للآبار حيث حققت النماذج دقة عالية في تحديد الآبار التي تعاني من مشاكل مما يسمح بتخطيط عمليات حفر وصيانة مستقبلية فعالة وبالتالي رفع كفاءة الحفر والإنتاج وتقليل التكاليف [22].

في الولايات المتحدة اعتمدت مبادرات مثل iPIPE على تقنيات التحليل الجغرافي المكاني المدعومة بالذكاء الاصطناعي للكشف ورصد التسريبات في خطوط أنابيب النفط والغاز ومواقع الآبار باستخدام بيانات الأقمار الصناعية والتحليل الطيفي تمكنت هذه الأنظمة من تحديد مواقع التسريبات بدقة وسرعة أكبر بكثير من الطرق التقليدية ما ساهم في توفير ملايين الدولارات في تكاليف التنظيف والغرامات التنظيمية بالإضافة الى تقليل الخطر البيئي [23].

خلال السنوات الخمس الأخيرة بدأت الكثير من الشركات النفطية العالمية مثل شركة ExxonMobil استخدام أنظمة حفر ذاتية مدعومة بالذكاء الاصطناعي قادرة على تحديد معايير الحفر المثلى بشكل مستقل مما ساهم في التقليل من الأخطاء البشرية وساعد على زيادة كفاءة العمليات النفطية. كما ساعدت الخوارزميات المتطورة على تمكين تعلم الآلة من تحليل بيانات الآبار النفطية في الوقت الحقيقي للكشف عن نوعية الصخور والطبقات الجيولوجية وكشف مشاكل الاهتزاز وتآكل رأس الحفر مما يسمح بالتدخل السريع للمعالجة وتقليل فترات التوقف [20].

مما سبق يتضح لنا أن الذكاء الاصطناعي أصبح تقنية أساسية لتحليل وكشف ومعالجة مشاكل آبار النفط والغاز أثناء الحفر والإنتاج [21,22].

تعد صناعة النفط والغاز من أكثر الصناعات الاستراتيجية والحيوية في الاقتصاد العالمي حيث يعتمد عليها في تلبية جزء كبير من احتياجات الصناعة والطاقة حول العالم. وتعتبر عمليات حفر آبار النفط والغاز العمود الفقري لهذه الصناعة إذ تمثل الخطوة الأولى والأساسية في سلسلة إنتاج النفط والغاز الأ أن هذه العمليات تتسم بتعقيد كبير وتواجه تحديات تشغيلية وتقنية متزايدة مثل تغير الظروف الجيولوجية، المخاطر البيئية، الأعطال المفاجئة، وارتفاع التكاليف التشغيلية الأمر الذي يتسدى البحث المستمر عن حلول فعالة ومبتكرة [4,5].

في العقد الأخير شهدت صناعة النفط والغاز تحولاً رقمياً غير مسبوق بفضل التطورات المتسارعة في تقنيات الذكاء الاصطناعي التي أصبحت تلعب دوراً أساسياً ورئيسياً في إعادة تشكيل طرق العمل التقليدية وتحسين كفاءة وجودة العمليات [6]. فقد أتاح الذكاء الاصطناعي بما يشمله من التعلم الآلي، الخوارزميات، تحليل البيانات الضخمة، إمكانية تحليل كميات هائلة من البيانات التشغيلية والجيوفيزيائية في الوقت الفعلي والتنبؤ بالمشكلات قبل وقوعها واتخاذ قرارات دقيقة تدعم سلامة وكفاءة عمليات الحفر [3,6,7]. تهدف هذه الورقة العلمية الى استعراض أهم وأحدث تقنيات الذكاء الاصطناعي في مجال حفر آبار النفط والغاز مع التركيز على أهمية ودور وفعالية هذه التقنيات في كشف وتحليل المشكلات التشغيلية أثناء الحفر وتحسين أداء الآبار وتقليل التكاليف والمخاطر المرتبطة بالعمليات. كما تناقش الورقة التحديات والفرص المستقبلية لتبني الذكاء الاصطناعي في صناعة النفط والغاز مع تسليط الضوء على أبرز الدراسات والابتكارات الحديثة التي شكلت نقلة نوعية في مجال حفر آبار النفط والغاز.

في ظل التطورات والتحويلات الرقمية المتسارعة التي يعيشها قطاع النفط والغاز أصبح الذكاء الاصطناعي أحد القواعد الأساسية لتطوير العمليات وتحقيق الكفاءة التشغيلية في مختلف مراحل إنتاج النفط والغاز بدءاً من الاستكشاف مروراً بالحفر وصولاً إلى الإنتاج والصيانة وتعد عمليات حفر آبار النفط والغاز من أكثر العمليات تعقيداً وتكلفةً إذ تواجه تحديات تشغيلية وتقنية متعددة مثل الأعطال المفاجئة، فقدان السيطرة على البئر، التسريبات، وتآكل المعدات، ما يستدعي حلولاً مبتكرة تضمن استمرارية العمليات وسلامتها بأقل خسائر ممكنة وبأقل التكاليف الغير مبررة [7,8,9]. لقد اسهم التطور في تقنيات الذكاء الاصطناعي ولا سيما تحليل البيانات الضخمة والتعلم الآلي في احداث نقلة نوعية في القدرة على رصد وتحليل البيانات التشغيلية الهائلة الناتجة عن أجهزة الاستشعار وأنظمة المراقبة الحديثة [11,12]. مما ساهم في تطوير نماذج لغة قادرة على التنبؤ المبكر بالمشكلات التشغيلية واقتراح الحلول المثلى في الوقت الفعلي بل وتحسين أداء آبار النفط والغاز بشكل مستدام [6,7]. كما ساهمت تقنيات الذكاء الاصطناعي في تعزيز الصيانة التنبؤية وتقليل فترات التوقف غير المخطط لها وتحسين كفاءة استخدام الموارد البشرية والمادية [10,13,14].

وفي ضوء هذه التطورات المتسارعة تزايدت جهود العلماء والباحثين في دراسة وتطوير تطبيقات الذكاء الاصطناعي لمعالجة مشاكل حفر آبار النفط والغاز مما ساهم في تحليل وكشف ومعالجة هذه المشاكل بشكل مبكر مما ساهم بشكل واضح في رفع كفاءة العمليات [15,16].

**3.1. أهمية الدراسة**

تحاول الدراسة الراهنة تسليط مزيداً من الضوء حول تقنيات الذكاء الاصطناعي المتمثلة في الذكاء الاصطناعي التوليدي وأنماط معالجة اللغة و هندسة الأوامر و نماذج اللغة الكبيرة و وكلاء الذكاء الاصطناعي و ابراز أهميتها و فاعليتها في تطوير صناعة النفط و الغاز [3,4,5,6] بما قد يسهم في اثاره انتباه القائمين على هذه المؤسسات و توجيههم نحو تبني تقنيات الذكاء الاصطناعي و آليات أدماجها في صناعة النفط و الغاز نظراً لفاعلية هذه التقنيات في تحسين جودة الأداء في عصر يتسم بعصر المعرفة التكنولوجية و التحولات الرقمية المتسارعة [13,14] كما قد يحقق الفائدة لمجتمع المعرفة لا سيما مؤسسات التعليم و التدريب من توصيات هذه الدراسة و المستندة الي نتائج محاكاة فعالة لاستخدام الذكاء الاصطناعي في تشخيص مشاكل حفر ابار النفط و معالجتها و الوقاية منها في تعزيز التعليم و التدريب و البحث العلمي مما يساهم في حل مشكلة غياب البيانات الحقيقية و أيضا التشجيع على الابداع و الابتكار [3].

**4.1. مصطلحات و اختصارات الدراسة****1- الذكاء الاصطناعي Artificial intelligence, AI:**

برامج حاسوبية صممت لكي تحاكي طريقة تفكير الانسان من خلال ما تتميز به من دوال رياضية قادرة على القيام بالاستنتاجات المختلفة و التعلم من اخطائها و هو ما يجعلها تؤدي مهامها و اعمالها بسرعة و مهارات فائقة [23]. و يعرف الذكاء الاصطناعي بأنه قيام أنظمة الكمبيوتر بمحاكاة للاعمال و المهام التي يقوم بها الانسان فهو ذكاء يظهر من خلال عمل الالات و ليس الأشخاص عن طريق برامج للحاسب الآلي لديها القدرة على محاكاة السلوك الإنساني بكفاءة عالية [24]. و يعرف أيضا بأنه قدرة جهاز يتحكم فيه الكمبيوتر على تنفيذ و انجاز المهام بطريقة شبيهة بالبشر [25].

**2- الذكاء الاصطناعي التوليدي, Generative Artificial intelligence:**

يعتبر فرع من فروع الذكاء الاصطناعي يتيح للآلات إنشاء محتوى جديد ومبتكر، بدلاً من مجرد تحليل البيانات الموجودة [26,27].

**3- هندسة أوامر الذكاء الاصطناعي Prompt engineering:**

هي فن صياغة و تكوين الأسئلة أو الأوامر التي تقدمها إلى نماذج الذكاء الاصطناعي لكي تحصل على افضل الإجابات أو النتائج التي تريدها. تخيل أنك تتحدث إلى مساعد ذكي، فكلما كانت أوامرك أكثر دقة ووضوحاً، كلما كان المساعد قادراً على فهم مطلبك وتلبية حاجتك بشكل أفضل [28].

**4- معالجة اللغة الطبيعية NLP, Natural Language processing :**

هي فرع من فروع الذكاء الاصطناعي يركز على لغة و اسلوب تفاعل الكمبيوتر مع اللغة البشرية. وهي تشمل مجموعة واسعة من المهام، مثل قراءة المقالات المكتوبة بلغات مختلفة و تحليل الجمل و الكلمات لفهم معناها، أبتكار نصوص جديدة، مثل كتابة القصص و الروايات أو ترجمة اللغات، ترجمة اللغات بتحويل النص من لغة إلى أخرى، تحديد المشاعر الموجودة في النص ( سلبية، إيجابية، محايدة) تقصير و تلخيص النصوص الطويلة مع الحفاظ على المعنى الأساسي [24,25].

**5- نماذج اللغات الكبيرة LLMs, Large language models :**

هي برامج حاسوبية تعتبر برامج تعلم آلي ضخمة تم تدريبها على كميات هائلة من المعلومات و البيانات. هذه النماذج قادرة على فهم و تحليل و توليد اللغة البشرية بطرق كانت تعتبر معقدة للغاية حتى وقت قريب. و من أمثلة نماذج

تشمل التطبيقات الرائدة للذكاء الاصطناعي عدة مجالات مهمة و فعالة مثل كشف التسربات النفطية، التنبؤ بالمشاكل التشغيلية، الحفر الذاتي، الصيانة التنبؤية، تحليل البيانات الجغرافية المكانية و قد اثبتت هذه التقنيات فعاليتها في تحسين و تطوير كفاءة العمليات النفطية و تقليل التكاليف و زيادة مستويات السلامة في القطاع النفطي [17,18].

**1.1. مشكلة الدراسة**

تواجه صناعة النفط و الغاز مشاكل و تحديات تقنية و تشغيلية كبيرة و متزايدة اثناء حفر الابار خاصة عند الحفر في أعماق كبيرة تصل الى عشرات الألاف من الاقدام في بيئات قاهرة ذات حرارة و ضغط مرتفع حيث تظهر مشاكل معقدة تؤثر على سلامة البئر و كفاءة الإنتاج مثل إضرابات الضغط و الحرارة وتآكل معدات الحفر و استخدام سوائل حفر غير مناسبة [22,23] ورغم توفر كميات هائلة من البيانات التشغيلية المتنوعة ( نصوص، صور، فيديوهات، بيانات رقمية ) الا ان تحليلها بشكل فعال لاتخاذ قرارات دقيقة و سريعة مازال تحديا كبيرا [5,6,7] علاوة على ذلك فأن الاعتماد على الخبرات البشرية في تشخيص و اقتراح الحلول قد يؤدي الى تأخير في الاستجابة و زيادة في التكاليف و المخاطر [20,21].

في هذا السياق يبرز الذكاء الاصطناعي كحل واعد يمكنه استيعاب و تحليل البيانات المتعددة المصادر و تقديم تفسير و تشخيص دقيق للمشكلات و تصميم معالجات و حلول فعالة فضلا على التنبؤ بالوقاية و الحماية المستقبلية من تكرارها [13,15,16]. و في ظل قلة الدراسات التي تقارن بين نماذج وكلاء الذكاء الاصطناعي في تشخيص مشاكل حفر آبار النفط تزداد لمزيد من الدراسات لتقييم مدى دقة و كفاءة نماذج و وكلاء الذكاء الاصطناعي المختلفة في هذا المجال خاصة عند تطبيقها على حالات واقعية معقدة مع الحفاظ على أمن و خصوصية البيانات الحساسة [4].

**2.1. أهداف الدراسة**

تهدف هذه الدراسة إلى:

- 1- تقييم كفاءة أداء مجموعة متنوعة من نماذج و وكلاء الذكاء الاصطناعي في تحليل مشكلة تقنية حدثت أثناء حفر بئر نفط عميق (20,000 قدم)، من خلال تزويدهم بمعلومات شاملة ومتنوعة (نصوص، صور، فيديوهات، وبيانات رقمية) مع الحفاظ على سرية بعض البيانات الحساسة.
  - 2- تحليل كفاءة و قدرة هذه النماذج والوكلاء على تشخيص المشكلة بدقة وتقديم حلول فعالة لمعالجتها واقتراح تدابير وقائية لمنع تكرارها في المستقبل.
  - 3- تصميم نوع و خواص مانع الحفر المناسب للمقطع المتأثر الذي وقعت فيه المشكلة و أيضا اقتراح بارامترات الحفر المثلى باستخدام تقنيات الذكاء الاصطناعي.
  - 4- مقارنة دقة و كفاءة وكلاء الذكاء الاصطناعي مع نماذج الذكاء الاصطناعي وتحديد الفروقات في الأداء ومدى فائدة استخدام وكلاء الذكاء الاصطناعي المتقدم في تحسين عمليات حفر ابار النفط و الغاز .
  - 5- استكشاف إمكانيات الذكاء الاصطناعي في دعم تدريب وتطوير الكوادر البشرية في قطاع النفط والغاز عبر محاكاة سيناريوهات حفر الآبار والتعامل مع المشاكل التشغيلية المعقدة قبل وقوعها [1,2,3].
- تسعى الدراسة من خلال تحقيق هذه الأهداف إلى تعزيز فهم دور الذكاء الاصطناعي كأداة استراتيجية لتحسين كفاءة وسلامة عمليات حفر آبار النفط والغاز وتقليل المخاطر والتكاليف المرتبطة بها ودعم التحول الرقمي المستدام في هذا القطاع الحيوي.

في هذه الدراسة قمنا باختبار كفاءة الذكاء الاصطناعي عن طريق مقارنة أداء نماذج اللغة الكبيرة في تحليل وتفسير مشاكل حفر وقعت أثناء حفر بئر نفطي كامل ومقارنة النتائج المتحصل عليها برأي وتحليل الخبراء المتخصصين

## 2.2. البيانات الحقيقية Real data

في هذه الدراسة استخدمنا بيانات حقلية حقيقية مأخوذة من احد الابار النفطية التي وقعت فيها مشاكل أثناء حفرها كما موضح بالشكل رقم 1 .  
البيانات عبارة عن إدخال بيانات متعددة الوسائط Multimodal inputs تشمل نصوص و صور و أيضا مقاطع فيديو حقيقية مما يساهم في تدريب الذكاء الاصطناعي باستخدام الوسائط المتعددة Multimodal learning خضعت البيانات المدخلة لمعالجة دقيقة شملت 150 تقرير حفر و 150 تقرير موانع حفر عن طبيعة بارمترات الحفر ونوع و خواص مانع الحفر الذي استخدم في البئر اثناء وقوع المشكلة تم معالجة التقارير بالتأكد من سلامة البيانات و عدم وجود بيانات شاذة تسبب الانحراف او التحيز في نتائج الذكاء الاصطناعي كذلك تم معالجة عدد كبير من الصور لعينات الفتات الصخري المتساقط من البئر اثناء وقوع المشكلة .



شكل رقم 1 : يوضح اشكال و احجام الفتات الصخري المتساقط من البئر

## 3.2. نماذج الذكاء الاصطناعي المستخدمة في الدراسة

استخدمنا في هذه الدراسة 16 أداة ذكاء اصطناعي تنوعت ما بين نماذج لغة كبيرة و وكلاء ذكاء اصطناعي في أحدث إصدار حتى 2025 كما موضح في الجدول رقم 1 و الشكل رقم 2

الجدول 1 : أدوات الذكاء الاصطناعي LLMs المستخدمة في الدراسة

Tool	type	Version 2025	Company
GPT-4o	LLM	GPT-4o	Open AI
Grok	LLM	Grok 3	Xai
Gemini	LLM	Gemini-2.5-Pro	Google
Claude	LLM	Claude-4-sonnet	Anthropic
Llama	LLM	Llama-4	Meta
Mistral	LLM	Mistral-large-2-128k	Mistral
Molmo	LLM	1B, 7B-D, 7B-O, 72B	Ai2
Copilot	LLM	Microsoft copilot	Microsoft
Deepseek	LLM	Deepseek - R1	Deepseek
Nvidia	LLM	Nemotron-70b-instruct	Nvidia
Qwen	LLM	Qwen-3-235B-A22B	AliBABA
Perplexity	Agent/LLM	Perplexity Pro	Perplexity
Manus	Agent/LLM	Manus Pro	Manus
Genspark	AI agent	Genspark - Pro	Genspark
MiniMax	Agent/LLM	MiniMax - pro	Minimax
Kimi	LLM	Kimi 1.5	Kimi

LLMs الشهيرة، Claude، Gemini، GPT، [26].

## 6- الشبكات العصبية الاصطناعية Artificial Neural network, ANN

هي برامج حاسوبية مستوحاه من بنية الدماغ البشري وطريقة عمل الخلايا العصبية. تتكون هذه الشبكات من وحدات بسيطة تسمى "العصبونات الاصطناعية" متصلة ببعضها البعض في طبقات، تمامًا مثل الخلايا العصبية في دماغنا [24,25].

## 7- التعلم العميق Deep learning, DL:

هو فرع من فروع الذكاء الاصطناعي مستوحى من بنية الدماغ البشري. يتيح للآلات التعلم من البيانات الضخمة والمعقدة بطريقة مشابهة لكيفية تعلم البشر. تخيل أنك تعلمت التعرف على وجه صديقك من خلال رؤية العديد من الصور له في ظروف مختلفة. هذا هو بالضبط ما يفعله التعلم العميق، ولكنه على نطاق أوسع بكثير وأكثر تعقيداً [27,29].

## 8- تعلم الآلة Learning Machine, LM:

هو فرع من فروع الذكاء الاصطناعي يمنح الحواسيب القدرة على التعلم والتطو من المعلومات و البيانات المتنوعة ، دون الحاجة إلى برمجة صريحة لكل مهمة. تخيل أنك تعلم طفلاً جديداً الكلمات، ففي البداية لا يعرف أي شيء، لكن مع مرور وتكرار الكلمات واستخدامها في سياقات مختلفة، يبدأ الطفل بفهم المعنى واستخدامه بشكل صحيح. هذا هو بالضبط ما يفعله تعلم الآلة، ولكنه على نطاق أوسع بكثير وأكثر تعقيداً [24,25].

## 9- المدخلات متعددة الوسائط Multimodal inputs / التعلم متعدد الوسائط Multimodal learning

يطلق على إدخال عدة أنواع من البيانات مثل النصوص والصور والفيديوهات إلى نماذج اللغة الكبيرة (LLMs) مصطلح "المدخلات متعددة الوسائط" (Multimodal Input). هذا المصطلح يشير إلى قدرة النموذج على استقبال ومعالجة بيانات من مصادر وصيغ مختلفة بشكل متكامل، مما يتيح له فهم السياقات المعقدة وتوليد استجابات أكثر شمولية ودقة بناءً على هذه المدخلات المتنوعة.

في السياقات التقنية، قد يُستخدم أيضًا مصطلح "التعلم متعدد الوسائط" (Multimodal Learning) للإشارة إلى عملية تدريب النماذج على التعامل مع هذه الأنواع المختلفة من البيانات واستخلاص المعرفة منها [26,29].

## 10- وكلاء الذكاء الاصطناعي

هي نماذج لغة كبيرة LLMs طورت لتكون قادرة على أداء مهام كبيرة مثل تحليل البيانات، اتخاذ القرارات، أو أداء مهام محددة بطريقة تحاكي القدرات البشرية مثل التعلم والاستنتاج، وذلك بهدف حل المشكلات أو تحقيق أهداف معينة بكفاءة [24,25].

## 11- مشكلة Sloughing shale

هي عبارة عن تساقط الطبقات المحفورة أثناء الحفر في صورة قطع و أجزاء متنوعة في الحجم تعرف بـ Sloughing shale و تقع هذه المشكلة خاصة في طبقات جيولوجية محددة تسمى بـ shale formation تنتج هذه المشكلة بسبب ضعف خواص مائع الحفر او تفاعل هذه الطبقات مع الماء وتعتبر هذه المشكلة خطيرة جدا ان لم تعالج فقد تتسبب في المزيد من المشاكل مثل انحسار انابيب الحفر في البئر مما يعني خسائر مادية إضافية .

## 2. المواد وطرق العمل

### 1.1. حالة الدراسة

الاصطناعي المطور عبر عدة أبعاد أساسية، وذلك لتحديد مستوى فعاليته ودقته في أداء المهام المحددة له [3]. ركزت الدراسة على سبعة محاور رئيسية لمقارنة الأداء، والتي تضمنت ما يلي:

- 1- تحديد تسمية المشكلة المراد معالجتها .
  - 2- تحليل الأسباب التي أدت إلى ظهور هذه المشكلة .
  - 3- اقتراح الخطوات الفعالة لمعالجة المشكلة في الوقت الحالي .
  - 4- وضع خطط لتجنب تكرار المشكلة في المستقبل .
  - 5- تصميم مائع حفر مناسب، بما في ذلك تسميته وتحديد خصائصه، لمعالجة المشكلة المحددة .
  - 6- تطوير معايير حفر مثالية للتعامل مع المقطع الذي حدثت فيه المشكلة .
  - 7- تقديم توصيات واقتراحات لحماية البئر من وقوع أو تكرار وقوع هذه المشكلة
- من خلال هذه المحاور، سعت الدراسة إلى تقديم مقارنة شاملة ومتكاملة لقدرة النظام في مواجهة التحديات التقنية والبيئية المرتبطة بعمليات الحفر خاصة في غياب برامج متخصصة في تشخيص وإيجاد حلول مشاكل حفر ابار النفط العميقة خاصة تساقط البئر Sloughing shale.

## 6.2. منهجية المقارنة

اعتمدت الدراسة على منهجية تقييم (مقارنة) مزدوجة:

- 1- التقييم الكمي : في هذا التقييم تم استخدام نسبة الخطأ بين القيم المحسوبة والقيم الحقيقية لتقييم دقة المخرجات الرقمية [3] .
- 2- التقييم النوعي : في هذا التقييم تم الاعتماد على آراء الخبراء في تقييم جودة المخرجات النظرية للذكاء الاصطناعي ، وذلك من خلال مقارنتها بالبيانات الحقيقية والمعرفة المتراكمة في المجال [3]

## 7.2. أمن وخصوصية المعلومات

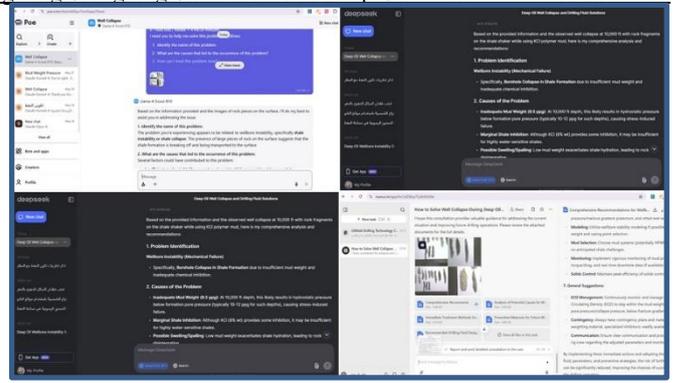
في هذه الدراسة، تم اتباع نهج دقيق في إدارة البيانات لضمان الحفاظ على خصوصية المعلومات الحساسة المتعلقة بعمليات الحفر. وبالتالي، تم استبعاد كافة البيانات الجغرافية الدقيقة، مثل إحداثيات الآبار ومواقع الحقول، والاكتفاء بتضمين بيانات عامة ومتاحة في المجال، مثل أنواع أنابيب التغليف وأقطارها وأعماق التغليف. هذا النهج، وإن كان يقلل من تعقيد البيانات، إلا أنه يضمن الحفاظ على سرية المعلومات الحيوية للشركة والامتثال للمعايير الأخلاقية في البحث العلمي [3] .

على الرغم من تبسيط البيانات، أظهرت النتائج قدرة النموذج على تحقيق دقة مقبولة في التنبؤ بالخواص والمشاكل المرافقة للحفر وكيفية الوقاية منها ومعالجتها . هذا يشير إلى أن المعلومات العامة المتعلقة بأنواع وأنماط التغليف كافية لتدريب نموذج ذكاء اصطناعي قادر على توليد و إنتاج بيانات متعلقة بحفر ابار النفط والغاز . هذا النهج يفتح آفاقاً جديدة لتطبيق تقنيات الذكاء الاصطناعي في مجال النفط والغاز، مع الحفاظ على أعلى معايير الخصوصية والأمان.

## 3. النتائج والمناقشة

### 1.3. دقة تحديد تسمية المشكلة المراد معالجتها

من الشكل 4 اثبت وكيل الذكاء الاصطناعي Manus و نموذج الذكاء الاصطناعي Gemini كفاءة كبيرة في التحديد الدقيق لاسم المشكلة مقارنة ببقية الأدوات المستخدمة في الدراسة حدد Manus الاسم المتداول حقلها المعروف بـ sloughing shale والذي يعني تساقط الطبقات الصخرية ا

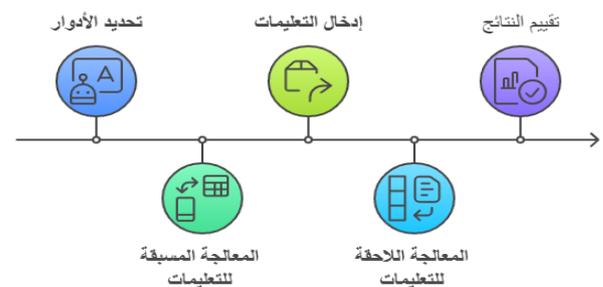


شكل 2: نماذج وكلاء الذكاء الاصطناعي المستخدمة في الدراسة

## 4.2 مخطط التنفيذ

في سبيل تحقيق أفضل النتائج الممكنة من استخدام الذكاء الاصطناعي، تم تصميم مجموعة من التعليمات الدقيقة (Prompts) التي تتألف من مراحل متكاملة كما موضح في الشكل 3، حيث تغطي كل مرحلة جانباً محدداً يساهم في تشكيل الهيكلية الشاملة للعملية [3] . يمكن تلخيص هذه المراحل على النحو التالي:

- 1- مرحلة تحديد الأدوار: تتضمن هذه المرحلة تعيين دور واضح ومحدد للذكاء الاصطناعي، بما يضمن توجيهه بشكل صحيح نحو مسار الدراسة أو الغرض المحدد دون الانحراف أو الحيود عن المسار الصحيح .
  - 2- مرحلة المعالجة المسبقة للتعليمات: تشمل هذه المرحلة إعداد البيانات وتنقيتها وترتيبها، بالإضافة إلى تهيئة النماذج لاستيعاب التعليمات بدقة عالية من خلال تصفية العناصر غير الضرورية وضمان جاهزية النظام.
  - 3- مرحلة إدخال التعليمات: في هذه المرحلة، يتم تقديم التعليمات أو المهام المطلوبة إلى النموذج بصورة واضحة ومحددة، لضمان فهم النظام للغاية المنشودة .
  - 4- مرحلة المعالجة اللاحقة للتعليمات: تركز هذه المرحلة على تهيئة النتائج وتنسيقها وفق الشكل المطلوب، مع إجراء التعديلات والتصحيحات اللازمة لتحسين جودة المخرجات .
  - 5- مرحلة تقييم النتائج: يتم خلال هذه المرحلة وضع معايير محددة لتقييم جودة النتائج المقدمة من النموذج، مع مقارنتها بالبيانات الواقعية للتأكد من دقتها وملاءمتها .
- للموصول إلى المخطط النهائي، استلزم الأمر تنفيذ عدة تجارب ومحاولات تصحيحية، بهدف تحسين الأداء وتوجيه الذكاء الاصطناعي نحو تحقيق الأهداف المرجوة بأعلى كفاءة ممكنة كما هو موضح بالشكل رقم 3



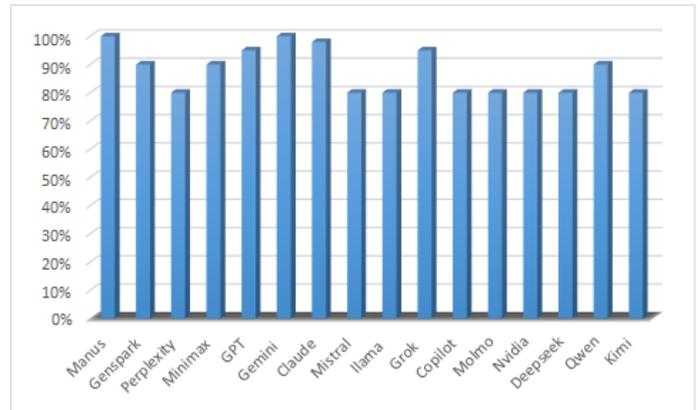
شكل 3: بوضوح مراحل اعداد Prompt المستخدم في الدراسة

## 5.2. تقييم أداء الذكاء الاصطناعي

تم تصميم هذه الدراسة بهدف مقارنة الأداء الوظيفي لنظام الذكاء

من الشكل 7 يتضح تفوق Minimax في تقديم واقتراح خطط فعالة لمنع تكرار المشكلة مستقبلا كما ان أدوات الذكاء الاصطناعي Manus, GPT, Gemini, 40, أظهرت تفوق نسبي مقارنة ببقية الأدوات المستخدمة في الدراسة

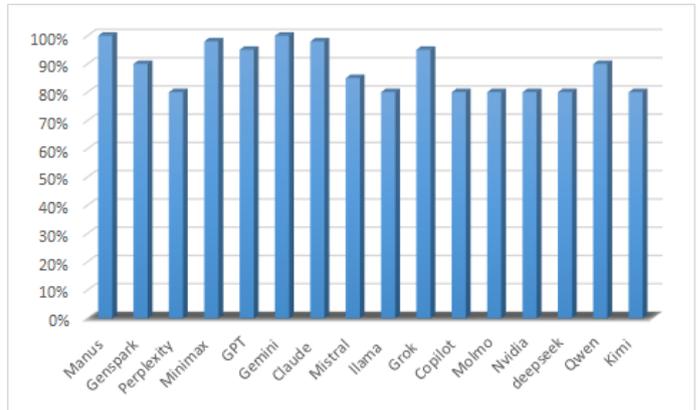
محفورة على هيئة أجزاء رقيقة. بقية أدوات الذكاء الاصطناعي اشارت للمشكلة بشكل عام مثل عدم استقرارية البئر instability wellbore او التكيف Caving.



شكل 4: دقة تحديد تسمية المشكلة المراد معالجتها

### 2.3 تحليل الأسباب التي أدت الى ظهور المشكلة

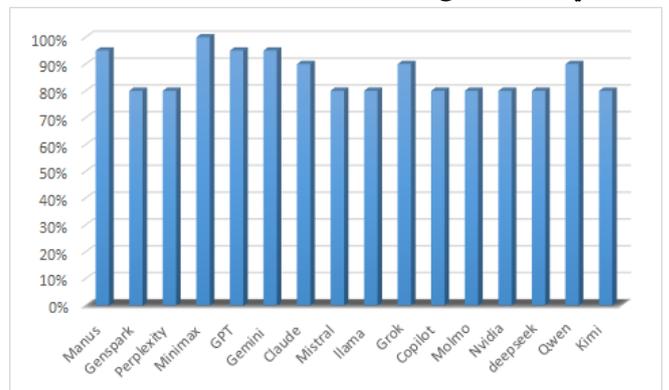
يوضح الشكل رقم 5 استمرار تفوق Manus و Gemini 2.5 في التحليل العلمي الدقيق لاسباب ظهور المشكلة مقارنة ببقية أدوات الذكاء الاصطناعي المستخدمة في الدراسة .



شكل 5: تحليل الأسباب التي أدت الى ظهور المشكلة

### 3.3 اقتراح استراتيجيات لمعالجة هذه المشكلة في الوقت الحالي

من خلال النتائج المتحصل عليها من الدراسة قفز وكيل الذكاء الاصطناعي Manus الى الصدارة ليقدم معالجات مفصلة ودقيقة لمعالجة هذه المشكلة متفوقا على Gemini 2.5 و Manus و بقية أدوات الذكاء الاصطناعي كما هو موضح بالشكل 6.

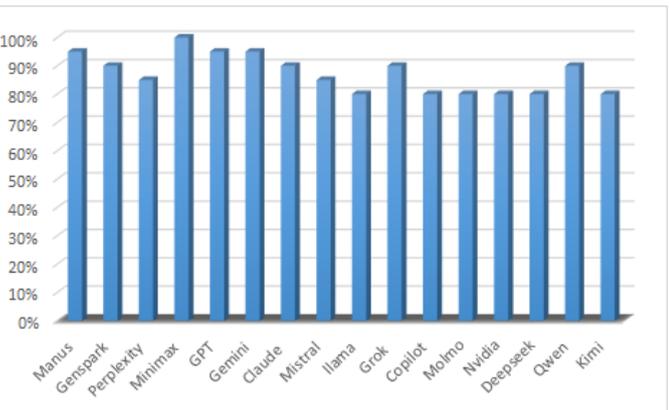


شكل 6: اقتراح استراتيجيات لمعالجة المشكلة لحظة وقوعها

### 4.3 وضع خطط لتجنب تكرار المشكلة في المستقبل

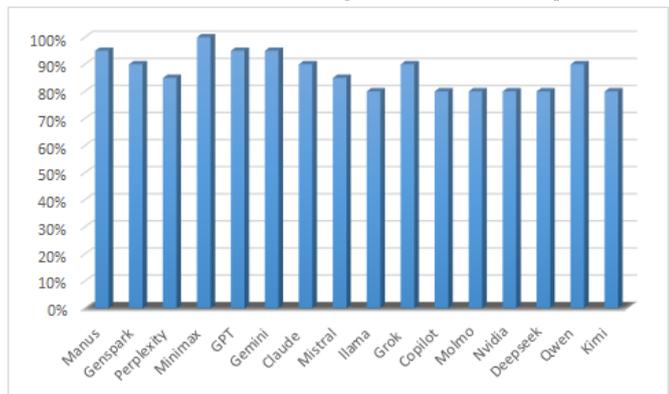
شكل 7: وضع خطط لتجنب تكرار المشكلة في المستقبل  
5.3 تصميم مائع حفر مناسب بما في ذلك تسميته وتحديد خصائصه لمعالجة المشكلة المحددة

اثبت Minimax كفاءة كبيرة في تصميم مائع حفر مناسب لمنع تكرار وقوع المشكلة هذا التصميم يشمل اسم ونوع و خواص مائع الحفر الشكل 8 يوضح أداء أدوات الذكاء الاصطناعي المستخدمة في هذه الدراسة



شكل 8: تصميم مائع حفر مناسب بما في ذلك تسميته وتحديد خصائصه لمعالجة المشكلة المحددة

6.3 تطوير معايير حفر مثالية للتعامل مع المقطع الذي حدث فيه المشكلة من خلال النتائج يظهر تفوق وكيل الذكاء الاصطناعي Minimax في تصميم ودقة اختيار معايير الحفر مقارنة ببقية أدوات الذكاء الاصطناعي المستخدمة في الدراسة كما هو موضح بالشكل رقم 9



شكل 9: تطوير معايير حفر مثالية للتعامل مع المشكلة



- Technology Showcase and Conference (p. D011S015R002). SPE.
- [13]- Qamar, R., & Zardari, B. A. (2025). Revolutionizing AI and Robotics in the Oil and Gas Industry. In *Revolutionizing AI and Robotics in the Oil and Gas Industry* (pp. 145-164). IGI Global Scientific Publishing.
- [14]- Dob, A., & Bennouna, M. L. (2024). Integration of Artificial Intelligence in Proactive Safety Analytics for Oil and Gas Operations Case Study of SLB.
- [15]- Alanazi, A. M., Altuwaijri, I. A., Bagabas, A. M., Khan, F., & Otaibi, B. (2025, May). Generative Edge Artificial Intelligence at Oil Rigs. In *SPE/IADC Middle East Drilling Technology Conference and Exhibition* (p. D021S007R002). SPE.
- [16]- Choubey, S., & Karmakar, G. P. (2021). Artificial intelligence techniques and their application in oil and gas industry. *Artificial Intelligence Review*, 54(5), 3665-3683.
- [17]- Abudooh, M. M., Negahban, S., Ibrahim, N. S., Hassan, A., Adel, A., Aboelhassan, M. G., ... & Chamberlain, D. (2025, April). Innovative Ai-Driven Field Development Planning: A Case Study in a Giant GOS Field Utilizing a Top-Down Modeling Approach. In *SPE Gas & Oil Technology Showcase and Conference* (p. D021S021R001). SPE.
- [18]- Hanif, H. R. (2024). *The Role of Artificial Intelligence in Optimizing Oil Exploration and Production*, *EJCMPR*. 2024; 3 (5): 176-190. artificial intelligence.
- [19]- Aniceto, K. (2025). The Role of Artificial Intelligence (AI) and Machine Learning (ML) in the Oil and Gas Industry. *Journal of Technology and Systems*, 7(1), 6-27.
- [20]- Agwu, O. E., Akpabio, J. U., Alabi, S. B., & Dosunmu, A. (2018). Artificial intelligence techniques and their applications in drilling fluid engineering: A review. *Journal of Petroleum Science and Engineering*, 167, 300-315.
- [21]- Sheng, K., He, Y., Du, M., & Jiang, G. (2024). The application potential of artificial intelligence and numerical simulation in the research and formulation design of drilling fluid gel performance. *Gels*, 10(6), 403.
- [22]- Solanki, P., Baldaniya, D., Jogani, D., Chaudhary, B., Shah, M., & Kshirsagar, A. (2022). *Artificial intelligence: New age of transformation in petroleum upstream*. *Petroleum Research*, 7 (1), 106-114.
- [23]- Kusimova, E., Saychenko, L., Islamova, N., Drofa, P., Safiullina, E., & Dengaev, A. (2023). Application of machine learning methods for predicting well disturbances. *Journal of Applied Engineering Science*, 21(1), 76-86.
- [24]- Caleb, A., Mayowa, G., & Adeola, F. R. (2024). Leveraging AI and Geospatial Intelligence for Enhanced Leak Detection in Pipeline Networks.
- [25]- Hwang, G. J., & Chen, N. S. (2023). Exploring the potential of generative artificial intelligence in education: applications, challenges, and future research directions. *Journal of Educational Technology & Society*, 26(2).
- [26]- Baidoo-Anu, David, and Leticia Owusu Ansah. "Education in the era of generative artificial intelligence (AI): Understanding the potential benefits of ChatGPT in promoting teaching and learning." *Journal of AI* 7.1 (2023): 52-62.
- [27]- Baidoo-Anu, D., & Ansah, L. O. (2023). Education in the era of generative artificial intelligence (AI): Understanding the potential benefits of ChatGPT in promoting teaching and learning. *Journal of AI*, 7(1), 52-62.
- [28]- Watermeyer, R., Phipps, L., Lanclous, D., & Knight, C. (2024). Generative AI and the automating of academia. *Postdigital Science and Education*, 6(2), 446-466.
- [29]- Al-Zahrani, A. M. (2024). The impact of generative AI tools on researchers and research: Implications for academia in higher education. *Innovations in Education and Teaching International*, 61(5), 1029-1043.
- (Multi-Agent اصطناعي متعددة الوكلاء Systems) - تطوير نماذج ذكاء اصطناعي متعددة الوكلاء (Multi-Agent Systems) لتعمل بشكل تعاوني لإدارة عمليات الحفر المعقدة وتحسين التنسيق بين مختلف مراحل العمل.
- 3 - استخدام الذكاء الاصطناعي في تقييم المخاطر البيئية والسلامة و الصحة المرتبطة بعمليات الحفر بهدف تقليل الأثر البيئي وتعزيز سلامة العاملين.
- 4 - تطبيق تقنيات الذكاء الاصطناعي في تصميم مواد وتقنيات حفر جديدة تناسب مع ظروف الحفر العميقة والمعقدة.
- تؤسس هذه الدراسة قاعدة لتسريع تبني الذكاء الاصطناعي في قطاع النفط والغاز، مما يفتح آفاقاً للتحويل الرقمي المستدام في مجال حفر الآبار.
9. المراجع
- [1]- لطروش، & أمينة. (2025). تطبيق الذكاء الاصطناعي في التعليم العالي: الإيجابيات والتحديات
- Higher Education: Benefits and Challenges. التراث، 15(1)، 11-22.
- [2]- بدوي، & ا. د. وائل ماجد السيد. (2025). تنافسية التعليم العربي- التعليم والتدريب في ضوء رؤية 2030 ودور الذكاء الاصطناعي
- Competitiveness of Arab Education: Education and Training in Light of Vision 2030 and the Role of Artificial Intelligence
- المجلة العربية للعلوم التربوية والتكنولوجية، 2(5)، 1-29.
- [3]- خالد صالح إبراهيم حموده. (2024). أهمية دمج الذكاء الاصطناعي في التعليم والتدريب: مقارنة أداء نماذج الذكاء الاصطناعي في توليد بيانات حفر الآبار النفطية مع البيانات الفعلية (دراسة حالة). المجلة الأفروآسيوية للبحث العلمي (AAJSR)، 497-515.
- [4]- Samuel, R., & Kumar, K. (2023, March). Artificial Well Engineering Intelligence (AWEI): Is It a Drilling Engineer's Dream or a Driller's Nightmare? In *SPE Middle East Oil and Gas Show and Conference* (p. D021S073R002). SPE.
- [5]- Sircar, A., Yadav, K., Rayavarapu, K., Bist, N., & Oza, H. (2021). Application of machine learning and artificial intelligence in oil and gas industry. *Petroleum Research*, 6(4), 379-391.
- [6]- Kuang, L., He, L. I. U., Yili, R. E. N., Kai, L. U. O., Mingyu, S. H. I., Jian, S. U., & Xin, L. I. (2021). Application and development trend of artificial intelligence in petroleum exploration and development. *Petroleum Exploration and Development*, 48(1), 1-14.
- [7]- Koroteev, D., & Tekic, Z. (2021). Artificial intelligence in oil and gas upstream: Trends, challenges, and scenarios for the future. *Energy and AI*, 3, 100041.
- [8]- Sircar, A., Yadav, K., Rayavarapu, K., Bist, N., & Oza, H. (2021). Application of machine learning and artificial intelligence in oil and gas industry. *Petroleum Research*, 6(4), 379-391.
- [9]- Qing, W. (2021). Global practice of AI and big data in oil and gas industry. In *Machine learning and data science in the oil and gas industry* (pp. 181-210). Gulf Professional Publishing.
- [10]- Ahmadi, M. (2024). *Artificial Intelligence for a More Sustainable Oil and Gas Industry and the Energy Transition: Case Studies and Code Examples*. Elsevier.
- [11]- He, L. I. U., Yili, R. E. N., Xin, L. I., Yue, D. E. N. G., Yongtao, W. A. N. G., Qianwen, C. A. O., ... & Wenjie, W. A. N. G. (2024). Research status and application of artificial intelligence large models in the oil and gas industry. *Petroleum Exploration and Development*, 51(4), 1049-1065.
- [12]- Aljarwan, R., Alshehhi, M., Khammo, M., Obedkov, A., Alamri, M., Alhebshi, M., ... & Alsharif, A. (2025, April). Leveraging Artificial Intelligence Models for Enhanced Operational Efficiency in the Oil & Gas Industry: Driving Production, Safety, and Cost Optimization. In *SPE Gas & Oil*