



Latin American Journal of Energy Research – Lajer (2023) v. 10, n. 2, pp. 131–139
<https://doi.org/10.21712/lajer.2023.v10.n2.p131-139>

Machine learning, inteligência artificial (IA), e a caracterização da subsuperfície: aplicações, possibilidades e riscos
Machine learning, artificial intelligence (AI), and subsurface characterization: applications, possibilities and risks

Fábio Berton^{1*}

¹ Geólogo de Reservatórios Sênior na Equinor Brasil

*Autor para correspondência, E-mail: fabe@equinor.com

Resumo: Soluções computacionais baseadas em *machine learning* e inteligência artificial (IA) têm sido adaptadas para o processamento e interpretação das informações de subsuperfície. Diante do que pode se tornar uma revolução tecnológica, é necessário pensar nos prováveis impactos das novas soluções para as atividades relacionadas à caracterização de reservatórios e sistemas petrolíferos. A IA já prova ter utilidade na indústria de óleo e gás ao lidar com grandes volumes de dados geológicos de padrão homogêneo, poupando o usuário humano de tarefas repetitivas. Essa característica faz com que os programas sejam úteis para o aumento de eficiência e da segurança do trabalho, mas da forma como funcionam atualmente, eles estão longe de serem capazes de lidar com a frequente complexidade geológica que pode representar riscos ou oportunidades em subsuperfície. Nem mesmo os melhores programas de IA são capazes de solucionar problemas inerentes aos dados indiretos, como a baixa resolução sísmica ou a baixa representatividade de poços. Tampouco conseguem encontrar soluções plausíveis para situações geológicas complexas. As novas soluções tecnológicas devem ser vistas como ferramentas para facilitar a vida dos profissionais de subsuperfície. Como qualquer ferramenta, sua existência tem propósitos específicos que não abrangem toda a complexidade dos sistemas geológicos. As interpretações geológicas derivadas de programas baseados em *machine learning* e IA devem ser avaliadas como aproximações geoestatísticas, não como a representação total da realidade construída a partir de múltiplos processos naturais. Essa característica faz com que os profissionais das geociências sigam sendo essenciais para aplicar as ferramentas de IA corretamente e filtrar as informações produzidas por elas.

Palavras-chave: Inteligência artificial, geologia do petróleo, análise de subsuperfície, métodos de interpretação automática, modelagem geológica

Abstract: *Software and plugins based on machine learning and artificial intelligence (AI) principles has been adapted to the processing and interpretation of subsurface data. In front of what might become a technological revolution, it is necessary to discuss the probable impacts of the new technologies. In subsurface studies in the oil and gas industry, AI has proven to be useful dealing with large volumes of geological data with homogeneous patterns, sparing the human user of repetitive tasks. This characteristic makes these software useful to increase efficiency and work safety, but the way they programmed now, they are far from being capable of dealing with the frequent geological complexity that might represent risks or opportunities in subsurface. Not even the best AI-based software are able to resolve the limitations that are inherent to subsurface data, such as lack of resolution, or lack of representativity. They also cannot generate plausible solutions to complex and specific geological conditions. The new AI-based technological solutions must be seen as tools to facilitate the work life of subsurface professionals. As any other tool, their existence have specific purposes that do not encompass the whole complexity of geological systems. The geological interpretation derived from machine learning and AI-based programs must be evaluated as geostatistical approximations, not as the representation of reality. Geoscientists will remain being necessary to apply AI-based tools correctly, and to filter the information provided by them.*

Keywords: *Artificial Intelligence, petroleum geology, subsurface analysis, automatic interpretation methods, geological modelling*

1 Introdução

A popularização das ferramentas de inteligência artificial (IA) parece anunciar a chegada de uma nova revolução tecnológica, baseada na crescente capacidade de aprendizado de sistemas computacionais (*machine learning*). Para que uma tecnologia seja chamada de “revolucionária”, ela deve ser capaz de substituir as ferramentas existentes a ponto de afetar desde os costumes e as atividades corriqueiras, até a forma como as pessoas trabalham (Dolfsma, 2022). Revoluções tecnológicas exigem adaptações e trazem oportunidades, mas sua aplicação também resulta em riscos previsíveis e imprevisíveis. A história humana prova o poder das revoluções tecnológicas, seja no advento do arado, da metalurgia, do tear, dos computadores, ou dos celulares. Desde a Revolução Industrial do final do Século XVIII, a velocidade das mudanças e a chegada de seus impactos parecem estar acelerados (Fig. 1), e esse é justamente o ponto que chama a atenção na popularização da IA: ainda que essa tecnologia não tenha se provado revolucionária, seu potencial e a velocidade de sua aplicação são claros. Parece ser questão de tempo até que a IA penetre direta ou indiretamente em todos os nichos da vida moderna.

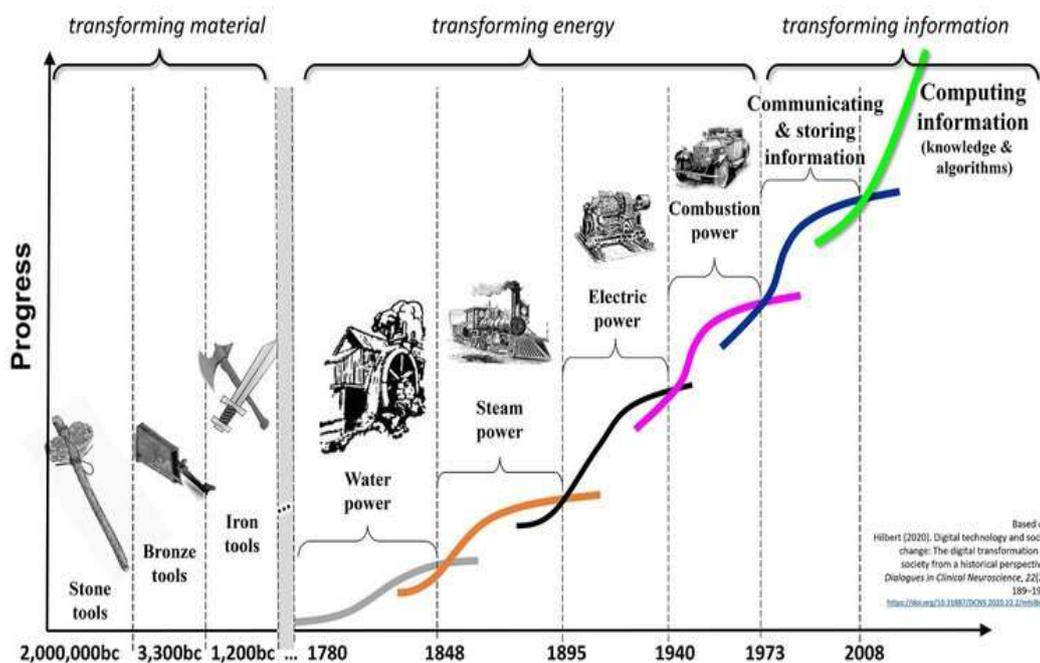


Figura 1. A velocidade de implementação e dos impactos das tecnologias revolucionárias tem sido gradualmente acelerado ao longo da história humana. A velocidade das mudanças trazidas pela IA provavelmente será sem precedentes. Imagem de Perez (2002).

O poder da IA está na facilidade de sua aplicação e na capacidade de auto-aprimoramento. Essa combinação pode ser o prelúdio de mudanças drásticas em um mundo digital, o que tem feito com que as mais diversas áreas da sociedade avaliem suas potenciais consequências para seus nichos. Entre argumentos que variam do otimismo irreal ao pessimismo distópico, todos com sólidas bases históricas e sociais, é importante manter o olhar crítico para identificar riscos, e a mente aberta para absorver novidades. Mais importante ainda é reconhecer as particularidades de cada área, e avaliar de forma lógica os impactos das novas tecnologias. Recentemente, li em um fórum da Indústria de Óleo e Gás (O&G) que a IA seria capaz de combinar dados geológicos e históricos para identificar áreas de exploração e promover a análise dos recursos. Em outra fase, ela poderia por si só atualizar e manter modelos geológicos e de reservatórios para guiar a drenagem de um campo, reduzindo drasticamente a necessidade de profissionais de Geologia e Geofísica (G&G) na cadeia de Exploração e Produção (E&P). O alerta é dado em um momento em que indústria de O&G começa a absorver ferramentas Transformadoras Generativas Pré-Treinadas (GPT's) em suas atividades diárias, mas o *machine learning* e a IA não são exatamente novidades nos estudos de subsuperfície.

Os indícios da chegada da IA afloraram há muito tempo na indústria de O&G. Seja no desenvolvimento de soluções para a automação offshore (e.g., Swiegers & Macfarlane, 2022), ou de softwares baseados em *machine learning* para o reconhecimento de padrões geológicos em dados sísmicos ou de poços (e.g., Fei et al., 2023), a indústria de O&G tem estado na vanguarda do uso da IA. As razões são simples: quando desenvolvidas até um nível razoável de confiabilidade, essas ferramentas podem reduzir a exposição de

trabalhadores humanos a situações de risco, podem facilitar a análise de grandes volumes de dados, e de forma geral reduzir o tempo dispendido em grande parte dos processos de interpretação e correlação de informações geológicas. Essas consequências levam invariavelmente à redução de custos, ao aumento da eficiência e da segurança em uma indústria constantemente pressionada pelos impactos ambientais e sociais de suas atividades. Mas a caracterização da subsuperfície carrega particularidades que exigem adaptações à aplicação de ferramentas de *machine learning* e IA, pois seu objetivo final é detalhar sistemas naturais que costumam ser complexos e variáveis demais para simplificações computacionais.

2 A caracterização da subsuperfície

A indústria de O&G moderna é tão dependente de ferramentas indiretas de análise de subsuperfície que é fácil se esquecer que os alvos geológicos situados a quilômetros de profundidade são partes de sistemas complexos, definidos por controles internos e externos dificilmente detectáveis, mas que definiram a distribuição e as características das rochas. Qualquer um que tenha comparado uma imagem sísmica com um afloramento entende que todo um universo de informações é perdido nas ferramentas indiretas de análise de subsuperfície (Fig. 2). Os dados sísmicos têm resolução baixa, incapaz de identificar praticamente qualquer coisa menos espessa do que algumas dezenas de metros (Fig. 2). As informações de poços são pontuais, dificilmente capazes de capturar aspectos tridimensionais ou resolver situações geológicas complexas.

Em alguns casos eles chegam a representar menos de um milionésimo por cento do volume de um reservatório (Howell et al., 2014). Todas as informações e incertezas derivadas destes dados são tratadas por técnicas de geoestatística, e traduzidas em modelos computacionais para simulações de reservatório. As soluções geoestatísticas são excelentes para representar tendências geológicas, mas caso o conceito utilizado para guiar o modelo não represente bem realidade, ele se torna inerentemente errado (Simons et al., 2023). E mesmo quando o conceito é bem conhecido, o modelo ainda pode ser pouco representativo.

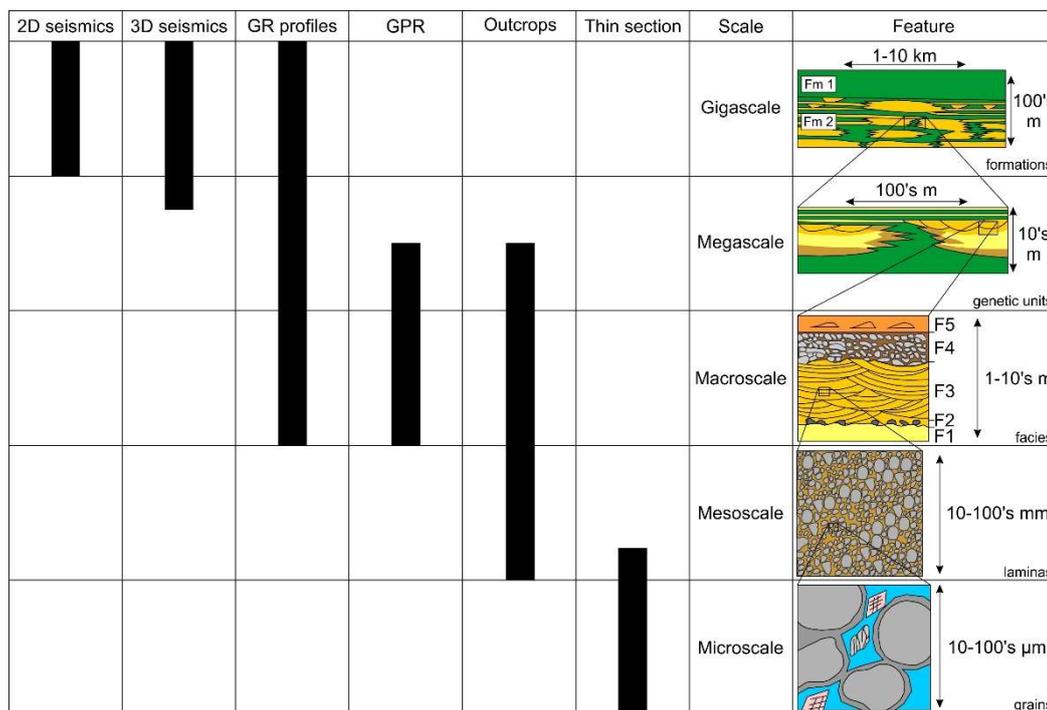


Figura 2. Escala das principais ferramentas de análise da subsuperfície. Praticamente todas as informações visíveis na escala de afloramentos ou de amostras de mão (macro e mesoescala, respectivamente) são perdidas nos dados sísmicos.

Alguns exemplos estão documentados em Vakarelov & Ainsworth (2013), que utilizaram sistemas costeiros modernos como base para a criação de modelos computacionais de reservatório (Fig. 3). Apesar da excelente resolução e da representação correta do análogo de reservatório, o modelo ainda assim deixa de capturar feições e estruturas centimétricas que podem ter grandes efeitos para o fluxo interno durante a produção de um campo. Nos sistemas costeiros escolhidos por Vakarelov & Ainsworth (2013), heterogeneidades imprevisíveis podem estar associadas à bioturbação, a eventos de energia anômala, e a alterações autogênicas (e.g., Berton et al., 2019) que formam heterogeneidades e compartimentação. Ou

seja, mesmo com um controle geológico impossível de se alcançar na subsuperfície e resolução computacional máxima, um modelo computacional não representa perfeitamente um reservatório de petróleo. A situação se torna ainda pior sob uma ótica mais ampla. Times de subsuperfície trabalham em áreas limitadas que representam apenas uma fração do contexto geológico regional (Simons et al., 2023).

Configurações e estruturas geológicas de grande porte, como contatos entre terrenos tectônicos, extrapolam enormemente as dimensões de um campo de petróleo, mas também podem ter efeitos sobre sua produtividade.

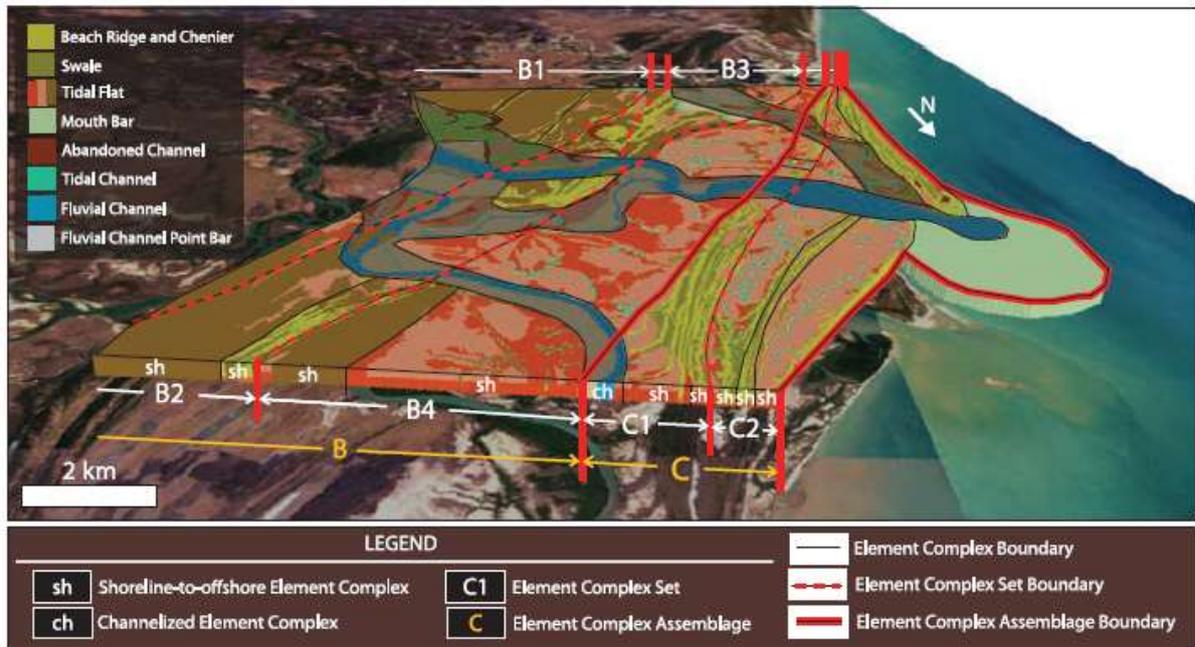


Figura 3. Modelo geo-celular construído a partir de um sistema costeiro moderno. Apesar de a arquitetura deposicional e as diferentes propriedades de reservatório estarem discretizadas e representadas em excelente resolução, fatores de escala muito maior ou muito menor que a escala do modelo são tratados como meras aproximações. Extraído de Vakarelov e Ainsworth (2013).

As estatísticas da indústria de O&G refletem as limitações para o entendimento e a representação da subsuperfície. Na Plataforma Continental Norueguesa (Norwegian Continental Shelf), as predições de reservas são em média 210% maiores do que a realidade (Berget, 2020), e os números não parecem próximos de melhorar. As grandes províncias petrolíferas já foram exaustivamente exploradas, e os prospectos mais promissores têm sido identificados em situações geológicas complexas que fogem dos padrões. Como resultado, os números recentes de exploração indicam que aproximadamente 50% dos poços exploratórios têm sido secos, ou sem ocorrências significativas (Milkov & Navidi, 2020). O caminho para melhorar esses números não parece estar na repetibilidade de padrões geológicos, mas na capacidade de utilizar informações e conceitos geológicos para resolver situações originadas por condições específicas. Conceito geológico se baseia em experiência de campo, algo que ferramentas de IA ainda são incapazes de absorver. Isso não significa que elas não tenham aplicações práticas na indústria de O&G, apenas que elas devem ser usadas de forma consciente e supervisionada, com as premissas e os propósitos corretos.

3 Oportunidades e riscos das ferramentas de IA

A automação baseada em IA aumenta a eficiência de processos em subsuperfície porque as máquinas não são afetadas pelas distrações que afetam um trabalhador humano, podendo lidar com grandes volumes de dados de maneira rápida, sistemática e consistente. Não à toa, a IA tem extrapolado os limites da experimentação e passado a fazer parte do cotidiano da indústria de O&G, até o momento com resultados positivos. Mas a dependência das ferramentas de IA baseadas em *machine learning* a partir de padrões que possam ser definidos e replicados faz com que sua maior vantagem seja também seu ponto fraco. Ao se deparar com situações que fogem do comum, a IA tende a criar interpretações geológicas irreais, baseadas em modelos tradicionais que resolveriam as situações geológicas mais comuns.

Exemplos dessa limitação podem ser encontrados em programas de interpretação sísmica automatizada baseada em *machine learning*. Se por um lado eles oferecem meios de delinear sismofácies, mapear refletores anômalos e identificar padrões regionais (e.g., Zhang et al., 2021), interpretações erradas

podem levar inadvertidamente à omissão de informações relevantes para um intérprete. Identifiquei um caso assim na aplicação do complemento de interpretação automática *Sequence Stratigraphic Interpretation System* do *software* OpendTect (dGB Earth Sciences, 2023) para a identificação das tendências deposicionais do intervalo Eoceno do norte da Bacia de Santos. O intervalo é formado por conjuntos progradantes de clinofomas de talude, interrompidos por cicatrizes de escorregamento (Berton & Vesely, 2016) (Fig. 4).

Durante o processo de interpretação automática, uma série de filtros foram aplicados para que o dado pudesse ser convertido em uma imagem passível de reconhecimento pelo programa, o que resultou na perda de resolução do dado de entrada. Importantes relações de terminações de refletores foram perdidas, fazendo o programa interpretar como uma coisa só os refletores anteriores às cicatrizes de escorregamento, e os refletores posteriores à cicatriz de escorregamento. O ganho do uso do programa para um estudo de estratigrafia de seqüências, nesse caso, seria nulo. Um nível de erro dessa magnitude pode facilmente ter impacto sobre a identificação e a caracterização de riscos e oportunidades em subsuperfície.

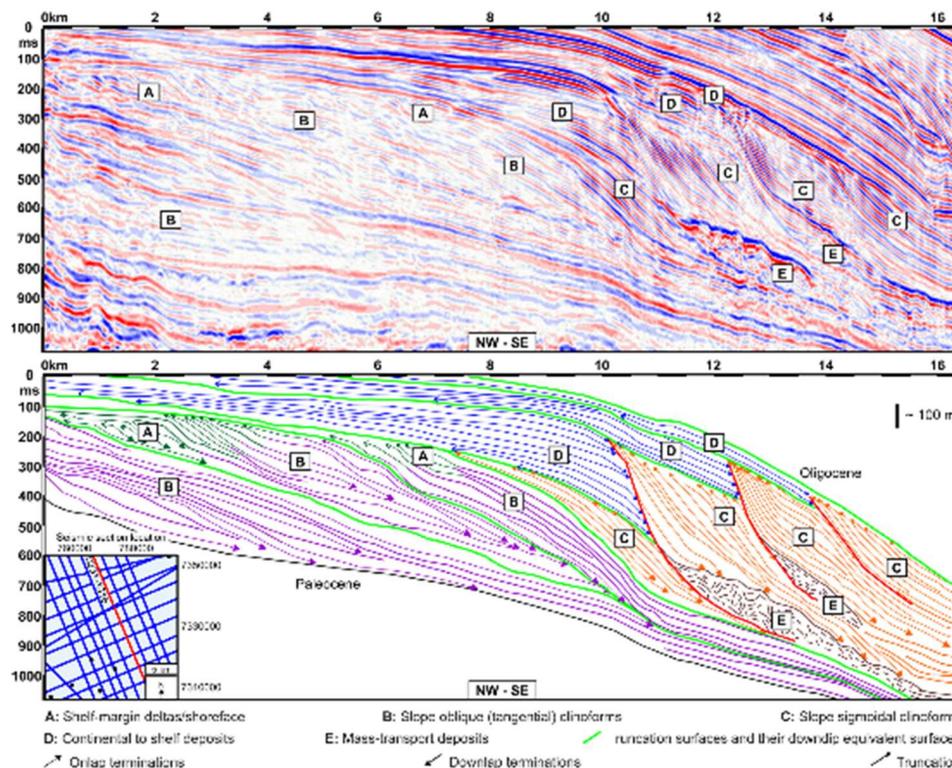


Figura 4: Sismofácies do intervalo Eoceno no norte da Bacia de Santos. Apesar da expressão sísmica nítida dos conjuntos de clinofomas de talude, a relação entre as clinofomas, as superfícies de truncamento geradas por escorregamentos, e as discordâncias causa uma complexidade que os programas de interpretação sísmica automática não conseguem capturar. Figura extraída de Berton e Vesely (2016).

Da forma como funcionam atualmente, os programas baseados em IA não são capazes entender as perguntas que estão tentando responder, apenas de retornar uma resposta estatística baseada nos inputs do usuário. Eles dificilmente seriam capazes de resolver algumas das condições geológicas mais emblemáticas. Um exemplo é o dos falsos prospectos originados por rochas vulcânicas, que frequentemente exibem sismofácies típicas de reservatórios e eventualmente enganam intérpretes sísmicos (Infante-Paez et al., 2018). Outro exemplo é o do reservatório do gigantesco campo de Johan Sverdrup, no Mar do Norte, cujas logfácies fogem dos padrões típicos de reservatórios siliciclásticos (Rønnevik et al., 2017). É justo dizer que os programas estão dando apenas os primeiros passos em termos de aprendizado, mas é difícil acreditar que estudos prospectivos ou análises de risco serão feitos de forma completamente não-supervisionada em um futuro próximo. Em algumas situações geológicas, ignorar padrões atípicos pode levar a erros ou à perda de oportunidades, indicando que os profissionais de G&G continuarão a ser necessários independentemente do desenvolvimento da IA. O mesmo é válido para médicos, juizes, biólogos, professores, e profissionais de qualquer área influenciada pela complexidade e a subjetividade dos sistemas naturais. Mas como ocorre em toda grande mudança, a revolução tecnológica exigirá adaptação.

Um profissional bem adaptado à IA será aquele capaz de aplicar as novas ferramentas para aumentar sua eficiência, sem depender cegamente delas. Para isso será necessário conhecer tanto os princípios

computacionais das ferramentas que estão sendo aplicadas, quanto os princípios geológicos por trás de sua aplicação. As bases conceituais geológicas e computacionais serão mais do que nunca diferenciais, garantias de que a IA será utilizada de forma eficiente, e de que os produtos gerados por ela serão de boa qualidade. E com a compreensão de que a dependência de padrões pode ser usada para ressaltar feições que fogem do comum, os produtos gerados de forma automática podem adquirir relevância exploratória. A supervisão e o controle de qualidade baseado em conceito geológico seguirão sendo essenciais, mas é provável que se reduza o tempo dedicado às tarefas mais morosas. A multidisciplinaridade ganha ainda mais valor nessas condições, pois se torna necessária para entender e filtrar resultados apresentados por ferramentas baseadas em IA.

4 Usos atuais e potenciais das ferramentas em atividades de subsuperfície

Os usos atuais das ferramentas de IA são abrangentes a ponto de atingir nichos específicos, como a exploração de gás de folhelho (e.g., Zhu et al., 2021), ou a captura e armazenamento de carbono (e.g., Msika & Findlay, 2023). A continuação estão listadas algumas aplicações mais comuns e mais promissoras de ferramentas baseadas em *machine learning* e IA para a caracterização de subsuperfície. Algumas delas já estão disponíveis comercialmente, outras estão em fase de aprimoramento. Nenhuma delas é à prova de erro ou pode ser aplicada de forma completamente não supervisionada, sem bom controle de qualidade. Sua aplicabilidade também depende da complexidade geológica e da qualidade e resolução dos dados de entrada. Em determinadas situações, a aplicação de métodos automáticos pode demandar mais do usuário do que técnicas mais clássicas.

4.1 Processamento e interpretação sísmica

O dado sísmico oferece inúmeras oportunidades de aplicação de ferramentas baseadas em *machine learning* e IA, incluindo o processamento (e.g., Zoo & Zwartjes, 2022), a inversão (e.g., Wang et al., 2023), e a interpretação sísmica (e.g., Fei et al., 2023). As soluções atuais são excelentes na captura de padrões gerais de refletores, mas ainda não respondem bem a padrões sísmicos ambíguos ou não-geológicos. Os programas automáticos com aplicação sísmica são úteis na análise preliminar de grandes volumes de dados e na seleção de regiões para detalhamento manual.

4.2 Petrofísica

Assim como no caso dos dados sísmicos, os dados petrofísicos podem ser beneficiados desde o processamento até a interpretação. Se destacam os usos no reconhecimento de logfácies (e.g., Wood, 2022), no cálculo de permeabilidade (Cuddy, 2021), e na geração de perfis sintéticos (e.g., Kim, 2022). A conversão dos perfis em interpretações litológicas ainda depende muito da previsibilidade do meio, o que exige revisão cuidadosa do usuário para que interpretações erradas não sejam atribuídas a fácies de ocorrência pontual.

4.3 Análises de amostras

A análise de amostras de rochas é desafiadora para os programas baseados em *machine learning* e IA, pois depende de imagens das amostras que dificilmente seguem padrões consistentes. O dado de entrada é afetado por detalhes como a iluminação, a resolução da câmera, o enquadramento e a distância de tomada da imagem. São desafios inexistentes em dados geofísicos ou geoquímicos. Apesar disso, já existem ferramentas automáticas de interpretação de amostras de testemunhos (e.g., Baraboshkin et al., 2022), e soluções comerciais de interpretação automática de amostras de calha (e.g., SLB, 2023).

4.4 Interpretações de LWD em tempo real

A grande vantagem das ferramentas baseadas em *machine learning* e IA no acompanhamento de operações de perfuração está na capacidade de reconhecer padrões de perfis de LWD e parâmetros de perfuração com rapidez, auxiliando na tomada de decisões em tempo real (e.g., Arnø et al., 2022). A interpretação litológica dos perfis, de forma supervisionada, poupa o usuário da necessidade de adicionar manualmente informações repetitivas e diminui o tempo de atualização de relatórios técnicos.

4.5 Atualização de modelos geológicos

A atualização contínua de modelos geológicos de reservatório é necessária em campos em produção, onde a frequência das perfurações de poços e o comportamento dinâmico decorrente da produção exigem atualizações rápidas. A incorporação de novos dados é beneficiada pelo desenvolvimento de ferramentas baseadas em *machine learning* e IA, mas a distribuição de informações geológicas ainda demonstra ser muito dependente da homogeneidade e previsibilidade do meio que está sendo representado (e.g., Pandey et al., 2022).

4.6 Comunicação técnica e científica

Weijermars et al. (2023) detalham o uso de ferramentas GPT para a escrita técnica, científica e didática de geociências. Diversos profissionais relatam vantagens que se baseiam principalmente na redução de tarefas administrativas e no aumento da produtividade, e alguns ressaltam a facilidade de resumir conceitos difíceis. Entretanto, muitos relataram ter encontrado informações falsas ou erradas, além de vocabulário vago.

4.7 Exploração de *brownfields*

Talvez o uso mais promissor das ferramentas de IA em subsuperfície seja a exploração de áreas já conhecidas, cujo banco de dados permite a aplicação de todos os métodos citados acima. Sob supervisão e com uma abordagem sistemática, a IA pode dar nova vida a campos maduros ou já considerados esgotados. Aplicações desse tipo têm sido feitas com relativo sucesso na mineração de ouro (e.g., GOLDSPOT, 2022).

5 Conclusões

O ganho de importância das ferramentas baseadas em IA exigirá a adaptação dos profissionais de subsuperfície, tanto para extrair o máximo das possibilidades que elas oferecem, quanto para filtrar as informações derivadas delas. A demanda por profissionais com conhecimento variado não é uma novidade imposta pela chegada de ferramentas de IA, é simplesmente uma tendência que vinha se desenhando há muito tempo na indústria de O&G, e que agora pode ser acelerada. Não se espera que todo geólogo no futuro seja um especialista em *machine learning* ou IA, mas será necessário um nível de conhecimentos básicos sobre esses temas para desenvolver algumas atividades corriqueiras. Ao mesmo tempo, a realidade da indústria prova que é mais necessário do que nunca aproximar os profissionais de G&G das rochas e da realidade geológica em campo, longe do viés das incertezas de subsuperfície e das aproximações da geoestatística.

Toda revolução tecnológica deve ser vista com cuidado, sem excesso de otimismo ou de pessimismo. A IA pode ter um impacto muito amplo na sociedade, mas ao menos no nicho das atividades da indústria de O&G, ela tem um bom potencial construtivo para a segurança das operações e para a eficiência e desenvolvimento técnico dos profissionais. Mente aberta, senso crítico e capacidade de adaptação são necessários para se extrair o melhor das novas soluções de subsuperfície, além da consciência de que “a mudança é a única constante”, como ensinou Heráclito de Éfeso.

Agradecimentos

Agradeço aos colegas Mauro Ribeiro e José F. Caparica Jr. pela revisão da versão original deste texto, e Renata Ribas Zanella pela revisão final.

Referências Bibliográficas

Arnø, M.L., Godhavn, J.-M., Aamo, O.M. 2022. Classification of Drilled Lithology in Real-Time Using Deep Learning with Online Calibration. *SPE Drilling & Completion* 37(1), 26-37, No SPE-204093-PA, doi:10.2118/204093-PA

Baraboshkin, E.E., Panchenko, E.A., Demidov, A.E., Sharipova, Y.D., Gatina, N.N., Koroteev, D.A., 2022. Automated core description system application for sedimentological analysis. 21st International Sedimentological Congress, ID: T11-21082.

- Berget, E.F. 2020. Redevelopment projects on the NCS: a statistical analysis of the Norwegian petroleum industry's ability to generate unbiased production forecasts. Master's Thesis, University of Stavanger.
- Berton, F., Guedes, C.C.F., Vesely, F.F., Souza, M.C., Angulo, R.J., Rosa, M.L.C.C., Barboza, E.G. 2019. Quaternary coastal plains as reservoir analogs: wave-dominated sand-body heterogeneity from outcrop and ground-penetrating radar, central Santos Basin, Southeast Brazil. *Sedimentary Geology* 379, 97-113, doi:10.1016/j.sedgeo.2018.11.008.
- Berton, F., Vesely, F.F. 2016. Stratigraphic evolution of Eocene clinoforms from northern Santos Basin, offshore Brazil: evaluating controlling factors on shelf-margin growth and deep-water sedimentation. *Marine and Petroleum Geology* 76, 356-372, doi:10.1016/j.marpetgeo.2016.09.007.
- Chen, L., Wang, L., Miao, J., Gao, H., Zhang, Y., Yao, Y., Bai, M., Mei, L., He, J. 2020. Review of the Application of Big Data and Artificial Intelligence in Geology. *Journal of Physics: Conference Series* 1684, No 012007, doi:10.1088/1742-6596/1684/1/012007.
- Cuddy, S. 2021. The benefits and dangers of using artificial intelligence in petrophysics. *Artificial Intelligence in Geosciences* 2, 1-10, doi:10.1016/j.aiig.2021.04.001.
- dGB Earth Sciences. 2023. OpendTect. <https://www.dgbes.com/software/opendtect> (accessed in 16 July 2023).
- Dolfsma, W. 2022. Different types of technological revolution. *Opinion* 10(4), No 1000200. doi: 10.35248/2311-3278.22.10.200
- Fei, Y., Cai, H., Yang, J., Liang, J., Hu, G. 2023. Unsupervised pre-stack seismic facies analysis constrained by spatial continuity. *Artificial Intelligence in Geosciences* 4, 22-27, doi: 10.1016/j.aiig.2023.01.003.
- Goldspot. 2022. MacDonald mines successfully intersects high-grade mineralization on the Earthlabs's Alwyn Trend Target, SPJ property. <https://www.goldspot.ca/news/macdonald-mines-successfully-intersects-high-grade-mineralization-on-the-earthlabss-alwyn-trend-target-spj-property/> (accessed 15 July 2023).
- Howell, J.A., Martinius, A.W., Good, T.R. 2014. The application of outcrop analogues in geological modelling: a review, present status and future outlook. Geological Society, London, Special Publications 387, 1-25, doi:10.1144/SP387.12.
- Infante-Paez, L., Marfurt, K.J., Wallet, B. 2018. Igneous bodies that look like sedimentary features in seismic data: a way to avoid pitfalls in seismic interpretation. SEG International Exposition and 88th annual meeting, 1613-1617, doi:10.1190/segam2018-2998555.1.
- Kim, J. 2022. Synthetic shear sonic log generation utilizing hybrid machine learning techniques. *Artificial Intelligence in Geosciences* 3, 53-70, doi:10.1016/j.aiig.2022.09.001.
- Milkov, A.V., Navidi, W.C. 2020. Randomness, serendipity, and luck in petroleum exploration. *AAPG Bulletin* 104, 145-176, doi:10.1306/05061918128.
- Msika, C., Findlay, R. 2023. Using a self-growing neural network approach to CCS monitoring. *First Break* 41, 63-67, doi:10.3997/1365-2397.fb2023044.
- Pandey, R.K., Aggarwal, S., Nath, G., Kumar, A., Vaferi, B. 2022. Metaheuristic algorithm integrated neural networks for well-test analyses of petroleum reservoir. *Scientific Reports* 12, No 16551, doi:10.1038/s41598-022-21075-w.
- Perez, C. 2002. Technological revolutions and financial capital – the dynamics of bubbles and golden ages. Cheltenham: Edward Elgar Publishing Limited, ISBN: 978 1 84064 922 2.
- Rønnevik, H.C., Jørstad, A., Lie, J.E. 2017. The discovery process behind the giant Johan Sverdrup Field. *AAPG Memoir* 113: Giant Fields of the decade 2000-2010, 195-220, doi:10.1306/13572008M1133687.
- Simons, M., Davies, A., Cowliff, L. 2023. Plausible characterization of subsurface geology is essential for the energy transition. *First Break* 41, 69-74, doi:10.3997/1365-2397.fb2023045.
- SLB. 2023. Automated lithology. <https://www.slb.com/products-and-services/innovating-in-oil-and-gas/drilling/surface-and-downhole-logging/logging-while-drilling-services/automated-lithology> (accessed in 15 June 2023).

- Swiegers, H., Macfarlane, R. 2022. The autonomous and digital future of offshore environments: Fugro. *Oil & Gas Middle East*, <https://www.oilandgasmiddleeast.com/products-services/offshore-environment> (accessed in 15 June 2023).
- Vakarelov, B.K., Ainsworth, R.B. 2013. A hierarchical approach to architectural classification in marginal-marine systems: bridging the gap between sedimentology and sequence stratigraphy. *AAPG Bulletin* 97(7), 1121-1161, doi:10.1306/11011212024.
- Wang, Z., Zhang, B., Gao, Z., Gao, J. 2023. Seismic swarm intelligence inversion with sparse probability distribution of reflectivity. *Artificial Intelligence in Geosciences* 4, 1-8, doi:10.1016/j.aiig.2023.02.001.
- Weijermars, R., bin Waheed, U., Suleymanli., K. 2023. Will ChatGPT and related AI-tools alter the future of the geosciences and petroleum engineering? *First Break* 41, 53-61, doi:10.3997/1365-2397.fb2023043.
- Wood, D.A. 2022. Optimized feature selection assists lithofacies machine learning with sparse well log data combined with calculated attributes in a gradational fluvial sequence. *Artificial Intelligence in Geosciences* 3, 132-147, doi:10.1016/j.aiig.2022.11.003.
- Zhang, H., Chen, T., Liu, Y., Liu, J. 2021. Automatic seismic facies interpretation using supervised deep learning. *Geophysics* 86(1), doi:10.1190/geo2019-0425.1.
- Zhu, L., Zhou, X., Zhang, C. 2021. Rapid identification of high-quality marine shale gas reservoirs based on the oversampling method and random forest algorithm. *Artificial Intelligence in Geosciences* 2, 76-81, doi:10.1016/j.aiig.2021.12.001.
- Zoo, J., Zwartjes, P. 2022. Attenuation of seismic migration smile artifacts with deep learning. *Artificial Intelligence in Geosciences* 3, 123-131, doi:10.1016/j.aiig.2022.11.002.