

A COMBINAÇÃO ENTRE ENGENHARIA DE RESERVATÓRIOS E A INTELIGÊNCIA ARTIFICIAL PARA OTIMIZAÇÃO DA PRODUÇÃO NA INDÚSTRIA DE PETRÓLEO

Sérgio Allan Barbosa de Ornellas¹
Lucas Velloso Oliveira da Silva²
Geraldo de Souza Ferreira³

RESUMO

Levando em consideração o impacto da engenharia de reservatórios na recuperação de hidrocarbonetos e o advento da indústria 4.0, esse trabalho visa analisar como a simulação de reservatórios, usando técnicas de inteligência artificial, se torna importante para a otimização da produção. No desenvolvimento dessa análise são apresentados, de forma simplificada, algoritmos responsáveis por calcular diversas propriedades vitais para uma recuperação economicamente viável. Por fim, são feitas comparações, com suporte na literatura, entre os resultados de algoritmos de inteligência artificial - redes neurais artificiais - e os esperados por outros modelos numéricos, bem como os valores observados experimentalmente da propriedade em questão.

Palavras-chave: Engenharia de reservatórios, Inteligência artificial, Indústria digital, ANN.

INTRODUÇÃO

De modo a aprimorar a análise de um reservatório contendo gás ou óleo, surgiu, com o passar dos anos, na indústria do petróleo, uma técnica baseada na junção da inteligência desenvolvida por humanos em máquinas, robôs, etc., e aquela própria cujo ser humano é capaz de desenvolver em si próprio, chegando ao produto final que hoje é conhecido como Inteligência Artificial (AI). Dona de muita análise e mistérios que apenas grandes mentes seriam capazes de pensar, a AI foi desenvolvida para facilitar, encurtar e acelerar processos que até então eram desenvolvidos muito bem, porém, a passos lentos e, a partir do século XXI, com o aumento da era da tecnologia, o mundo precisou adaptar-se e a desenvolver aparatos melhores que fossem capazes de solucionar problemas de forma mais ágil.

¹ Graduando do Curso de Engenharia de Petróleo da Universidade Federal Fluminense - RJ, sergioornellas@id.uff.br;

² Graduando do Curso de Engenharia de Petróleo da Universidade Federal Fluminense - RJ, lucas_velloso@id.uff.br;

³ Doutorado do Curso de Engenharia de Produção da Universidade Federal do Rio de Janeiro - RJ, geraldoferreira@id.uff.br;

A IA apresenta dezenas de formas de algoritmos que são armazenados em bancos de dados destinados a qualquer finalidade como, por exemplo, para análise de dados sísmicos, localização de hidrocarbonetos (HCs) em locais inóspitos, identificação de óleo pesado (Carpenter, 2019). Entretanto, para seu adequado uso, é necessário que haja um conhecimento básico de como um reservatório é modelado e simulado computacionalmente como função de características do fluido, do próprio reservatório, entraves operacionais e outras variáveis. A exemplo de um destes usos, temos a equação 1:

Equação 1: Modelo de equação utilizado na Engenharia de Reservatórios em IA

$$q = f(x_1, x_2, \dots, x_n, \& y_1, y_2, \dots, y_n, \& w_1, w_2, \dots, w_n)$$

Fonte: Mohaghegh, 2011

Na equação 1 temos uma equação muito utilizada e modelada quando o assunto é reservatório de petróleo e/ou gás em que a letra q representa a produtividade do reservatório; x_1, x_2, \dots, x_n são propriedades do fluido e do reservatório; y_1, y_2, \dots, y_n são os entraves operacionais; w_1, w_2, \dots, w_n são outros parâmetros e f é a função que relaciona as variáveis.

Essa equação apresenta que a produtividade de um campo ou um determinado poço é modelada usando funções entre as variáveis citadas no parágrafo anterior, além de outras propriedades como técnicas de completção, injeção de água, etc. A equação é usada tanto em modelos numéricos quanto em modelos baseados em inteligência artificial. Serão comentados durante o trabalho como os dois modelos diferem, principalmente no tempo necessário para realizar uma simulação, no conhecimento do processo em questão - escoamento em meio poroso - e as suposições feitas no processo de modelagem (Mohaghegh, 2011).

Em uma modelagem numérica, as funções que relacionam as variáveis da equação 1 são: Lei de Darcy, Lei da Difusividade Hidráulica e relações termodinâmicas. Essas funções são admitidas como verdade absoluta e, assim, se a produtividade resultante da modelagem e simulação numérica não estiver de acordo com as medidas observadas do campo, conclui-se que as características do reservatório não foram medidas e interpretadas de forma correta. Logo, devem ser modificadas de forma a atingir convergência com os valores medidos experimentalmente.

A modelagem computacional foi usada por décadas e sua eficácia é mais do que definitiva. Contudo, é importante destacar que as funções usadas no simulador tornaram-se cada vez mais complexas conforme os anos, permitindo que modelos mais complexos como escoamentos multifásicos, porosidade dupla e geomecânicas fossem aplicados e evoluíssem. Portanto, pode-se concluir que a deficiência do modelo numérico está justamente nas funções

que relacionam as variáveis do problema. Conforme o conhecimento do fenômeno físico aumenta, novas funções podem ser aplicadas, os parâmetros mudados, e resultados mais precisos tornam-se realidade.

A modelagem baseada em inteligência artificial pode ser classificada em diversas categorias como: o output do simulador, o tipo de campo (marrom ou verde), sua funcionalidade e, mais importante do que todas, a base de dados que é usada para seu desenvolvimento. Em modelagem AI, algumas suposições feitas na modelagem numérica são alteradas. Ao invés de manter a função que rege o fenômeno constante, as relações entre as variáveis podem mudar de acordo com a variação nas características do reservatório. De forma simplificada, é necessário evitar uma equação determinística e não flexível.

A função que relaciona os dados é obtida por meio da mineração de dados de produção, que muitas vezes podem chegar a mais de 20 anos, também conhecido como Big Data e pela tecnologia de reconhecimento de padrões utilizando inteligência artificial. Quando uma determinada variável do reservatório é identificada razoável pelos geocientistas, ela é mantida constante ao longo do histórico de dados e a função é modificada até que haja convergência entre os valores experimentais e os simulados.

Assim, em uma modelagem AI, os dados não são utilizados para servir os conhecimentos prévios de um fenômeno físico, e sim para modelá-lo. Não se começa por uma equação e utilizam-se dados para validá-la, mas sim utiliza os dados para modelar o fenômeno e posteriormente comparam-se os resultados com as medidas observadas.

Isso significa que a modelagem AI permite que o problema seja visto por ângulos diferentes e, caso a modelagem AI e numérica estejam de acordo, é praticamente garantido que o resultado esteja próximo da realidade.

METODOLOGIA

O presente trabalho refere-se a um estudo de extrema importância na indústria do petróleo visto a necessidade de juntar dois aspectos importantes na produção de hidrocarbonetos nos reservatórios: Engenharia de Reservatório e a Tecnologia por meio da Linguagem de Programação.

Ao longo das décadas, a tecnologia tornou-se uma grande aliada dos profissionais dessa indústria pois verificou-se que esforços, quando aplicados aos meios de produção através da tecnologia, eram minimizados. Assim, surgiu-se a necessidade dessa interconexão.

Por conta disso, o presente estudo baseou-se em artigos científicos de anos anteriores com a finalidade de verificar os principais mecanismos utilizados na simulação de reservatórios, com o objetivo de otimizar a produção dos mesmos através de técnicas de inteligência artificial.

O principal meio utilizado foi a plataforma de pesquisa, conhecida e renomada na indústria de O&G “OnePetro”, que possui milhares de referências publicadas ao redor do mundo, sob importantes perspectivas de empresas conhecidas. Por fim, também foram feitas comparações sobre os diferentes tipos de tecnologias para verificar a aplicabilidade destas com base em estudos prévios.

REFERENCIAL TEÓRICO

TIPOS DE ALGORITMOS DE INTELIGÊNCIA ARTIFICIAL

ANN - ARTIFICIAL NEURAL NETWORK

A *Artificial Neural Network* (ANN) ou Rede Neural Artificial (RNA) é uma técnica criada no século 20 com o intuito de simular em uma máquina como funciona o cérebro humano para que seja possível viabilizar gastos e utilizar a cada vez mais o meio criado para investigar até onde a invenção humana é capaz de ir.

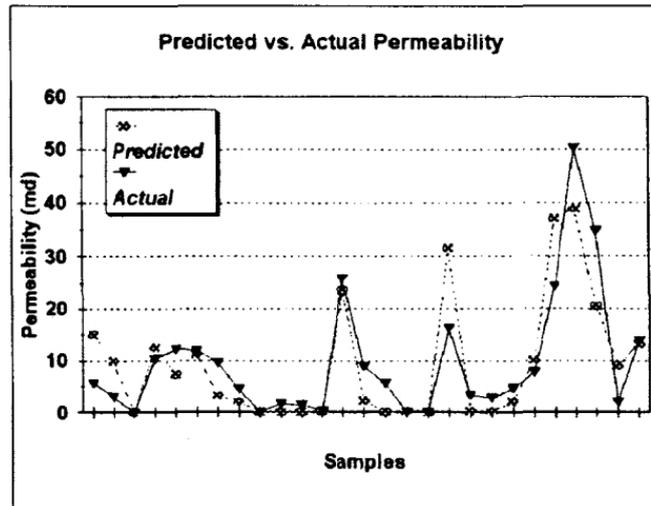
O cérebro humano é uma fonte incrível de estudo para os cientistas e os médicos, incansavelmente, investem tempo para analisá-lo, especialmente os neurônios, que são células nervosas do sistema nervoso que são as responsáveis pela condução dos impulsos nervosos e que controlam praticamente todo movimento corporal.

Diante disto, viu-se a necessidade da associação do cérebro com uma máquina para que assim pudéssemos chegar a um patamar em que uma simulação em uma máquina pudesse prever decisões de escolha e melhoramento em qualquer área, incluindo a área de O&G, em que o mecanismo é bastante utilizado para prever campos de perfuração, análise de rochas, viabilidade de poço e processos geológicos (Neta *et al*, 2002).

O procedimento simula um sistema de processamento de dados e é basicamente um mecanismo que tenta, através de um algoritmo, chegar ao mais próximo da realidade humana, aplicando vários conceitos e definições criadas e armazenadas em um banco de dados para que assim as empresas aproveitem desse meio para fornecer dados necessários para suas companhias, fazendo com que assim seja gasto menos recursos e com um tempo bem reduzido. Ou seja, o que demoraria horas ou meses feito diretamente por mãos humanas foi

substituído por softwares habilitados para solucionar e prever respostas pré-definidas em poucos minutos com uma tecnologia de ponta e altamente qualificada, a exemplo da análise que temos na figura 1.

Figura 1 - Previsão permeabilidade de rede neural versus medição de permeabilidade em laboratório.



Fonte: Mohaghegh, 1995 (Adaptado)

A ANN possui muitas vantagens e a principal delas é a possibilidade de armazenamento de grande quantidade de dados em sua memória. Mesmo se a máquina estiver danificada, ela ainda é capaz de responder aos mecanismos, viabilizando assim sua alta capacidade de armazenamento sem limite ou sem precisar de reparos regulares. Esse mecanismo também tem a capacidade de “aprender”, uma vez que é possível dizer a ela qual a resposta que ela precisa esperar quando algum comando for fornecido, fazendo com que assim seja tratada como um meio inteligente que responde a estímulos coerentemente.

O sistema é capaz de se auto-organizar, armazenando e realocando dados, sem a presença de uma pessoa para fazer isso por ela. O tempo de resposta da máquina também é algo que deve ser posto como um de seus benefícios porque ela apresenta um alto grau de eficiência, sendo possível obter respostas quase que instantâneas como por exemplo o grau de porosidade de uma rocha ou a porcentagem de gás ou óleo dentro do poço, feito tudo isso em poucos minutos. Por fim, essa técnica tem por objetivo simular em uma máquina o que um cérebro humano faria em determinadas condições, ou seja, funciona como um banco de dados feito em uma máquina em um período infinitesimalmente pequeno de tempo e sua função básica é “aprender” (Mohaghegh, 1995).

SVM - SUPPORT VECTOR MACHINE

A *Support Vector Machine* (SVM) ou Máquina de Suporte de Vetores (MSV) é um mecanismo que coloca dados em um banco de armazenamento e quando alguma informação é fornecida, ela direciona o que deve ser feito. Ou seja, entre vários caminhos, ela guia uma informação para aquela que mais se assemelha ao comando.

A funcionalidade é robotizada com o auxílio de uma tecnologia de ponta e é responsável por absorver diversas informações como o fluxo gás-óleo, o tipo de rocha que será perfurada, a quantidade de sedimentos instaurados no poço e indica a predição de zonas de perda de circulação (Alkinani et al, 2020). Com um pouco de cada informação em sua memória, quando o procedimento de comando é fornecido pelo operador, rapidamente, entre variados caminhos, o software direciona o que o operador quer saber com as informações presentes em seu banco de dados e direciona sua pesquisa para aquela que mais se enquadra em determinada funcionalidade, fazendo assim com que ao invés de uma pessoa procurar o melhor caminho para chegar a um ponto, essa informação é automaticamente realizada pela máquina em poucos minutos.

DLA - DEEP LEARNING ALGORITHM

O *Deep Learning Algorithm* (DLA) ou Algoritmo de Aprendizagem Profunda (AAP) é um algoritmo que tenta modelar muitas transformações que podem ser lineares ou não. O mecanismo utiliza partes de neurônios que são os responsáveis por processamentos lógicos para rotacionar informações, ser capaz de detectar a voz humana e identificar objetos.

A informação é passada por muitos processos, com a saída da camada anterior fornecendo entrada para a próxima camada, ou seja, uma saída fica encarregada de armazenar dados anteriores à outra. A primeira camada em uma rede é chamada de camada de entrada, enquanto a última é chamada de camada de saída. O interesse nesse meio tecnológico tem sido intensificado a cada vez mais pelas grandes indústrias, uma vez que, ao invés da utilização de funcionários, a facilidade na utilização de máquinas e até mesmo de robôs torna o processo bem mais eficiente e com uma margem de erros bem reduzidas, sendo também, um processo economicamente viável.

Já aplicada à indústria do óleo e gás, esse algoritmo de inteligência artificial tem facilitado bastante processos árduos e complexos, uma vez que na indústria é preciso ter uma alta precisão de dados para explorar um poço, analisar o tipo de rocha que estará sendo perfurada, o grau de porosidade e a quantidade de material proveniente do poço. Com esse

avanço tecnológico, foi possível reduzir custos e viabilizar indústrias na busca por outras formas de reconhecimento de campos e áreas de interesse (Biswas, 2019).

RESULTADOS E DISCUSSÃO

EXEMPLO DE APLICAÇÃO: OTIMIZAÇÃO DA LOCALIZAÇÃO DE UM POÇO COM INJEÇÃO DE GÁS USANDO SIMULAÇÃO AI-ANN

Este tópico do trabalho, elaborado com base na bibliografia especializada, ilustra a aplicação dos algoritmos de inteligência artificial - as redes neurais - nos problemas de determinação da localização de poços injetores. Os resultados alcançados mostram que a adoção e uso das ferramentas de IA na indústria de petróleo são promissores.

Maximizar a exploração das reservas é um dos desafios mais importantes da indústria de óleo e gás. Considerando que grande parte dos campos atuais já estão maduros, é necessário utilizar tecnologias de recuperação apurada de forma a aumentar a produtividade.

Uma das tecnologias mais utilizadas atualmente é a de gás-lift, cujo maior problema é a localização dos poços de injeção para atingir a pressão e produtividade ótima. Como cada campo requer uma localização diferente, faz-se necessário um estudo exclusivo para atingir a otimização, o que torna a utilização de software simuladores inviável por demorarem demais.

No tópico 3 foi apresentado que o ANN é mais eficiente quando comparado com métodos numéricos utilizados em simuladores e, se treinado corretamente, resulta na drástica redução no tempo necessário para escolha do local de perfuração do poço injetor.

Portanto, nos demais tópicos deste trabalho, será feita uma análise com a utilização desta ferramenta, reafirmando que a inteligência artificial mostra-se um aparato fundamental para a resolução de problemas.

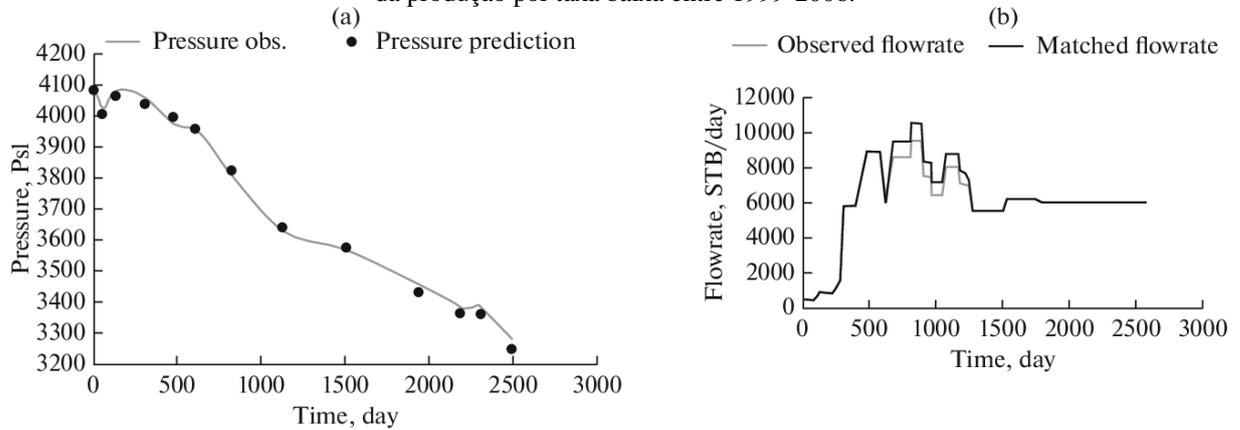
O MODELO DO SIMULADOR

O caso apresentado tem como objetivo gerar um modelo de estimativas para a localização de um poço de injeção de gás em um reservatório carbonático iraniano com histórico de produção de 7 anos (1999 - 2006) (Figura 2). Já o modelo simulado do reservatório e seus poços W1, W2 e W3 podem ser observados na figura 3.

Os parâmetros iniciais do reservatório estão disponíveis na tabela 1. Um total de 50 cenários foram conduzidos em localizações diferentes no reservatório, de forma a encontrar o melhor local para o poço injetor. Na tabela 2 observamos uma amostra dos dados de um desses cenários usados para treinar a rede neural do algoritmo. Usando uma rede neural

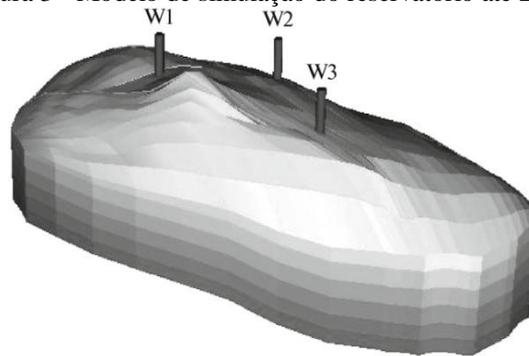
feedforward, foi possível obter a vazão e pressão em diferentes pontos de operação em meros 10 minutos, em contraste ao simulador numérico, onde apenas um dos cenários duraria em torno de 30 horas para ser simulado.

Figura 2 - (a) Correspondência histórica da pressão de produção entre 1999-2006, (b) Correspondência histórica da produção por taxa baixa entre 1999-2006.



Fonte: Akhlaghi & Kharrat, 2017

Figura 3 - Modelo de simulação do reservatório até 2006.



Fonte: Akhlaghi & Kharrat, 2017

Tabela 1 - Parâmetros Gerais do Reservatório

Parâmetro	Quantidade
Pressão Primária	4100 psi
Pressão no Ponto de Bolha	2057 psi
Densidade do óleo em condições padrão	0,8624 g/cm ³
Relação Gás-Óleo	850 SCF/STB

Fonte: Akhlaghi & Kharrat, 2017 (Adaptado)

Tabela 2 - Amostra de dados que utilizados para simular o ANN

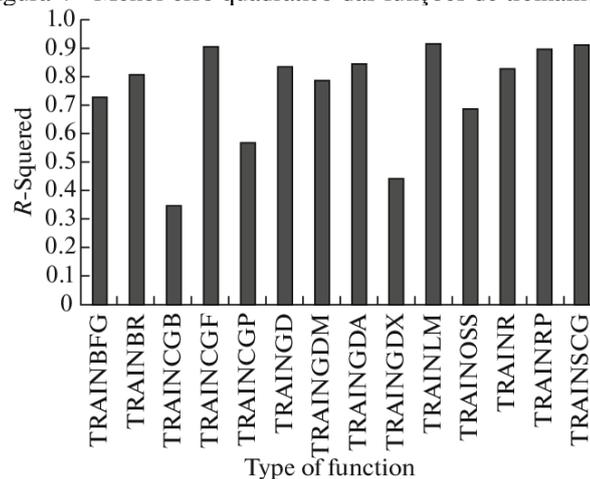
Posição X	Posição Y	Taxa de Fluxo (stb/dia)	Pressão (psi)
16	13	3,14E+08	46,3275
12	9	2,84E+08	44,95435
16	5	3,25E+08	49,30119
12	13	3,29E+08	60,3689
18	7	3,29E+08	60,3689
12	5	3,28E+08	57,14334
12	13	3,29E+08	60,3689
20	13	3,28E+08	52,35029
20	9	2,64E+08	43,91646
7	12	3,46E+08	245,844
11	16	3,42E+08	140,6123
11	12	3,29E+08	59,78711

Fonte: Akhlaghi & Kharrat, 2017 (Adaptado)

TREINAMENTO DA REDE NEURAL FEEDFORWARD

Tendo em mãos os dados das 50 simulações realizadas no simulador numérico, foi possível treinar a rede neural. As localizações dos poços injetores foram consideradas neurônios input e os parâmetros de pressão e vazão foram considerados neurônios output, separadamente. Durante esse procedimento, 14 funções possíveis foram investigadas de forma a encontrar a melhor função de treinamento, baseado no método dos mínimos quadrados. O resultado do procedimento pode ser visto na figura 4.

Figura 4 - Menor erro quadrático das funções de treinamento.



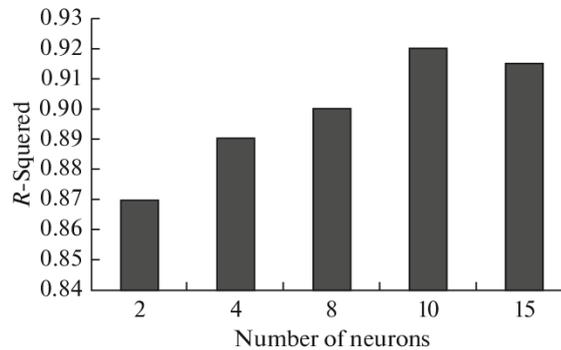
Fonte: Akhlaghi & Kharrat, 2017 (Adaptado)

O tipo de função escolhida foi a TRAINCGB, uma função de treinamento de rede que atualiza os valores de peso e polarização de acordo com o retropropagação do gradiente conjugado com reinicializações Powell-Beale.

Após a escolha da função de treinamento com menor erro, investigou-se o número de camadas escondidas. Segundo Mohaghegh (2000), uma camada escondida resulta em menor erro. Assim, para encontrar o número de neurônios escondidos em uma camada, foram

investigados 2, 4, 8, 10 e 15 neurônios e os resultados mostraram que o erro com 10 neurônios apresentou maior valor. Dessa forma, foram escolhidos 10 neurônios na camada escondida para treinar a rede neural (figura 5), novamente segundo a função de mínimos quadrados.

Figura 5 - Erros mínimos quadrados para diferentes números de neurônios ocultos.



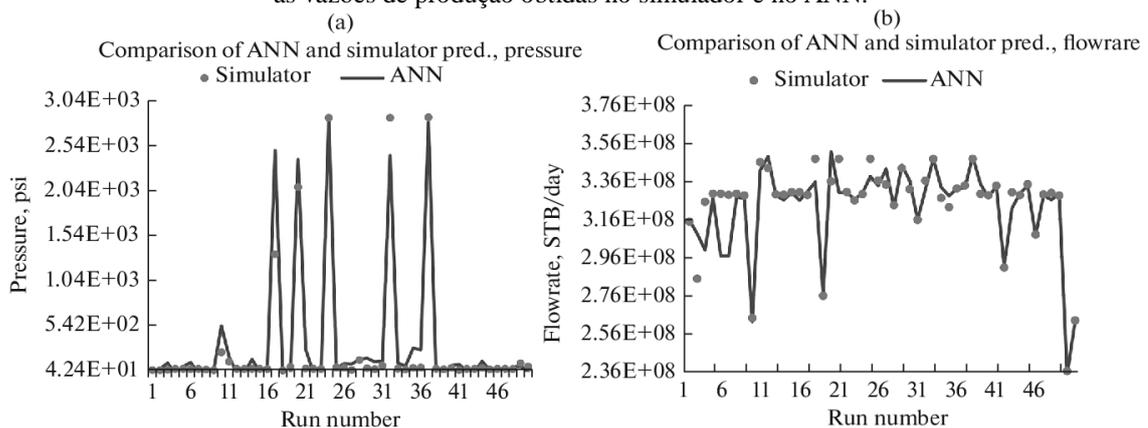
Fonte: Akhlaghi & Kharrat, 2017 (Adaptado)

OTIMIZANDO A LOCALIZAÇÃO DO POÇO DE INJEÇÃO

A rede neural *feedforward* com dois neurônios de entrada (orientações horizontais do poço de injeção), uma camada escondida com dez neurônios e um neurônio de saída (vazão e pressão de produção) foi treinada como a função de predição mais adequada e com o menor erro possível. De forma a observar a funcionalidade da rede neural, 20 bases de dado input foram alimentadas ao algoritmo e os valores esperados de vazão e queda de pressão foram comparados com os resultados do simulador numérico padrão.

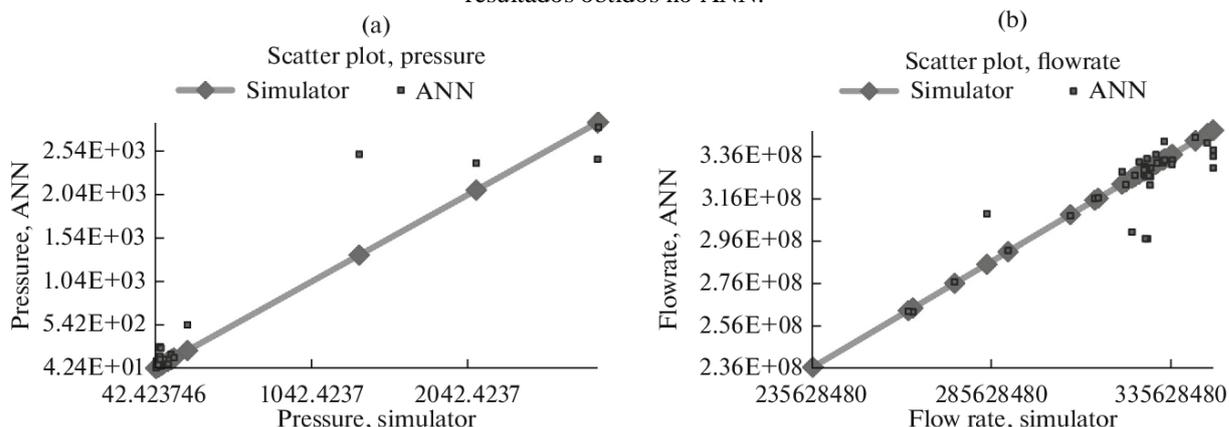
A comparação pode ser observada no conjunto de gráficos da figura 6, em que é evidente a acurácia entre os dois métodos tanto na medida da queda de pressão quanto na vazão. Já na figura 7, observa-se o gráfico de dispersão entre o método ANN e o simulador numérico. A correspondência entre os pontos é uma forte evidência de que os resultados são satisfatórios.

Figura 6 - (a) Comparação entre as pressões de produção obtidas no simulador e no ANN, (b) Comparação entre as vazões de produção obtidas no simulador e no ANN.



Fonte: Akhlaghi & Kharrat, 2017

Figura 7 - (a) Gráfico de dispersão das pressões de produção obtidas a partir do simulador versus os resultados obtidos no ANN, (b) Gráfico de dispersão das taxas de fluxo de produção obtidas a partir do simulador versus os resultados obtidos no ANN.



Fonte: Akhlaghi & Kharrat, 2017.

CONSIDERAÇÕES FINAIS

O presente trabalho elencou diferentes tipos de algoritmos utilizados pela Inteligência Artificial para explicar como a tecnologia pode ser uma aliada na redução de custo para solução de problemas na indústria de petróleo e na redução da quantidade de cálculos e consequente diminuição de tempo necessário para obter a resposta do simulador, tendo como objetivo a capacitação e a produtividade da Indústria do Óleo e Gás.

A pesquisa desenvolvida neste trabalho apresentou um exemplo de utilização da rede neural *feedforward* para determinar a melhor localização de poços em um campo produtor de petróleo. Os valores de saída de um simulador numérico e os valores fornecidos por um algoritmo baseado em ANN para determinar a melhor localização de poços injetores indicam que as previsões obtidas são muito próximas, fato que valida a utilização das redes neurais na indústria de petróleo.

REFERÊNCIAS

- Akhlaghi, N & Kharrat, Riya. (2017). Optimizing the location of the gas injection well during gas assisted gravity drainage in a fractured carbonate reservoir using artificial intelligence. **Theoretical Foundations of Chemical Engineering**. 51. 65-69. 10.1134/S004057951701002X.
- Alkinani, H. H., Al-Hameedi, A. T., and S. Dunn-Norman. "Predicting the Risk of Lost Circulation Using Support Vector Machine Model." **Paper presented at the 54th U.S. Rock Mechanics/Geomechanics Symposium**, physical event cancelled, June 2020.

Biswas, Deepankar "Adapting Shallow and Deep Learning Algorithms to Examine Production Performance – Data Analytics and Forecasting." **Paper presented at the SPE/IATMI Asia Pacific Oil & Gas Conference and Exhibition**, Bali, Indonesia, October 2019. doi: <https://doi.org/10.2118/196404-MS>

Carpenter, Chris. "Augmented Artificial Intelligence Improves Data Analytics in Heavy-Oil Reservoirs." **J Pet Technol** **71** (2019): 68–70. doi: <https://doi.org/10.2118/0519-0068-JPT>

Mohaghegh, Shahab. "Neural Network: What It Can Do for Petroleum Engineers." **J Pet Technol** **47** (1995): 42. doi: <https://doi.org/10.2118/29219-PA>

Mohaghegh, Shahab. (2011). Reservoir simulation and modeling based on artificial intelligence and data mining (AI&DM). **Journal of Natural Gas Science and Engineering**. 3. 10.1016/j.jngse.2011.08.003.

Neta, R. do A., Ebecken, N., Caloba, L. P., and R. P. Bedregal. "ARTIFICIAL NEURAL NETWORK USE ON SIMULATION OF GEOLOGICAL PROCESSES." **Paper presented at the 17th World Petroleum Congress**, Rio de Janeiro, Brazil, September 2002