

UNIVERSIDADE FEDERAL DE ALAGOAS
CENTRO DE TECNOLOGIA
GRADUAÇÃO EM ENGENHARIA DE PETRÓLEO

DOUGLAS ALBUQUERQUE MONTEIRO DE LIMA FILHO

Simulação numérica da recuperação avançada de petróleo: Abordagem em CFD e Redes
Neurais Artificiais

Maceió

2022

DOUGLAS ALBUQUERQUE MONTEIRO DE LIMA FILHO

Simulação numérica da recuperação avançada de petróleo: Abordagem em CFD e Redes
Neurais Artificiais

TCC apresentado ao curso de Engenharia de
Petróleo, da Universidade Federal de
Alagoas, como requisito para obtenção do
grau de Bacharel em Engenharia do
Petróleo.

Orientador: Wagner Roberto de Oliveira
Pimentel

Co-orientador: Leonardo Mendonça Tenório
de Magalhães e Oliveira

Maceió

2022

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico
Bibliotecária: Taciana Sousa dos Santos – CRB-4 – 2062

L732s Lima Filho, Douglas Albuquerque Monteiro de.
Simulação numérica da recuperação avançada de petróleo: abordagem em
CFD e redes neurais artificiais / Douglas Albuquerque Monteiro de Lima
Filho. – 2022.
54 f. : il. color.

Orientador: Wagner Roberto de Oliveira Pimentel.
Coorientador: Leonardo Mendonça Tenório de Magalhães e Oliveira.
Monografia (Trabalho de Conclusão de Curso em Engenharia de
Petróleo) – Universidade Federal de Alagoas. Centro de Tecnologia. Maceió,
2022.

Bibliografia: f. 48-53.
Apêndice: f. 54.

1. Recuperação avançada de petróleo. 2. Nanofluidos. 3. Fluidodinâmica
computacional. 4. Redes neurais artificiais. I. Título.

CDU: 622.276: 004

RESUMO

A demanda energética mundial é crescente e para acompanhá-la a indústria petrolífera se utiliza de diferentes técnicas de recuperação. Dentre estas, existem os chamados métodos avançados de recuperação de petróleo, que visam produzir o óleo contido no reservatório, que não conseguem ser produzidos de forma economicamente viável por estratégias convencionais de injeção de água e gás imiscível. Nesse sentido, a engenharia de petróleo vem se beneficiando da nanotecnologia, com contribuições na área de reservatório, na qual os nanofluidos, com suas características químicas e físicas especiais, são capazes de transformar o meio poroso e deslocar de maneira bem mais eficiente o óleo quando comparado com os métodos de recuperação secundária. Para realização destes feitos, se faz necessária uma abordagem que alie aspectos econômicos e ambientais, e para isso, este trabalho objetivou avaliar a eficiência do nanofluido a base de CaCO_3 , que tem origem a partir da reutilização de conchas de sururu, no deslocamento de petróleo através de análise fluidodinâmica computacional comparando o fator de recuperação obtido pelo método de recuperação de injeção de água com o fator obtido pelo método avançado de injeção de nanofluidos. Ademais foi desenvolvida uma rede neural artificial de arquitetura *feed-forward* que realiza previsões de fator de recuperação, a partir de dados relacionados ao método de injeção, características permoporosas do meio e propriedades do óleo. Os resultados demonstraram um aumento do fator de recuperação de óleo com o aumento da concentração de nanopartículas, sendo superior ao fator de recuperação obtido pela injeção de água. Além disto, a rede neural obteve êxito na previsão dos fatores de recuperação a partir de diferentes características do meio poroso, do óleo e do fluido injetado, com R^2 de 0,887 e erro quadrático médio de 0,3362.

Palavras-chave: Nanofluido, Recuperação avançada de petróleo, Fluidodinâmica, Redes neurais artificiais

ABSTRACT

The global energy demand is growing and to accompany it, the oil industry uses different recovery techniques. Among these, there are the so-called enhanced oil recovery methods, which are methods that aim to produce the oil contained in the reservoir, which cannot be produced in an economically viable way by conventional strategies of water and immiscible gas injection. In this sense, petroleum engineering has benefited from nanoscience, with contributions in the reservoir area, in which nanofluids, with their special chemical and physical characteristics, are capable of transforming the porous medium and displacing oil much more efficiently than the secondary recovery method. To accomplish these feats, it is necessary an approach that combines economic and environmental aspects, and for that, this work aimed to evaluate the efficiency of the CaCO₃-based nanofluid, which originates from the reuse of sururu shells, in the displacement of oil through computational fluid dynamic analysis comparing the recovery factor obtained by the water injection recovery method with the recovery factor obtained by the enhanced nanofluid injection method. Furthermore, an artificial neural network with feed-forward architecture was developed that predicts the recovery factor, based on data related to the injection method, characteristics of the porous media, and oil properties. The results showed an increase in the oil recovery factor with the increase in the concentration of nanoparticles, being superior to the recovery factor obtained by the injection of water. In addition, the neural network was successful in predicting the recovery factors from different characteristics of the porous medium, the oil and the injected fluid, with R^2 of 0.887 and a mean square error of 0.3362.

Keywords: Nanofluid, Enhanced oil recovery, Fluid dynamic, Artificial neural network

LISTA DE ILUSTRAÇÕES

Figura 1 - Esquema de um campo sob recuperação primária de petróleo.....	12
Figura 2 - Esquema de um campo sob recuperação secundária ou terciária de petróleo.	13
Figura 3 - Número de publicações da SPE baseadas em nanotecnologia.	15
Figura 4 - Mecanismo primário do método de nanofluidos.	16
Figura 5 - Modelagem CFD de meios porosos de outros autores. (a) Modelagem 3D em escala de poro de Minakov, et. al. (2021); (b) Modelagem 2D de micro modelo poroso de Ejeh, et. al. (2020); (c) Modelagem 2D de micro modelo poroso de Gharibshahi, Jafari e Ahmadi H. (2019). (d) Modelagem 3D em formato de tronco de cone de Esfe, Hosseinizadeh e Mosaferi (2020).	22
Figura 6 - Esquematização do processo de um Perceptron.	26
Figura 7 - O <i>Multilayer</i> Perceptron.	27
Figura 8 - Fluxograma de trabalho.	29
Figura 9 - Pré-malha do cilindro poroso.	30
Figura 10 - Aparato experimental para medição de velocidade de entrada de fluido e malha numérica.	34
Figura 11 - Gráfico do comportamento da velocidade de injeção de fluido no meio poroso.	35
Figura 12 - Comparativo qualitativo da eficiência de deslocamento de óleo entre o método de recuperação secundária e o método de nanofluido de CaCO_3 sob diferentes concentrações. ..	41
Figura 13 - Gráfico comparativo dos métodos de recuperação de óleo.	42
Figura 14 - Comparativo qualitativo da velocidade de escoamento da água e dos nanofluidos.	43
Figura 15 - Comportamento das nanopartículas no meio poroso.....	44
Figura 16 - Gráfico de barras do fator de recuperação de nanofluidos de mesma concentração com diferentes tamanhos de nanopartículas.	44
Figura 17 - Dispersão dos dados de teste comparando os fatores de recuperação esperados e os preditos pela rede.	46

LISTA DE TABELAS

Tabela 1 - Propriedades e características do meio poroso e do óleo a ser recuperado pela ação de fluidos injetados.....	32
Tabela 2 - Condições de contorno do modelo utilizado.	33
Tabela 3 - Diâmetro fixo e concentração variável de nanopartículas.....	36
Tabela 4 - Diâmetro variável e concentração fixa de nanopartículas.	36
Tabela 5 - Parâmetros da rede neural.	38
Tabela 6 - Limites inferior e superior das propriedades permoporosas, das características do óleo a ser recuperado e do fluido a ser injetado.	38
Tabela 7 - Forma de RNA e acurácia das suas formas.	45

LISTA DE ABREVIATURAS E SIGLAS

ASP	Álcali-surfactante-polímero
CEOR	<i>Chemical Enhanced Oil Recovery</i>
CFD	<i>Computational Fluid Dynamics</i>
EOR	<i>Enhanced Oil Recovery</i>
EG	Etileno-glicol
IFT	<i>Interfacial Tension</i>
MLP	<i>Multilayer Perceptron</i>
NF	Nanofluido
NP	Nanopartículas
SLP	<i>Singlelayer Perceptron</i>
RNA	Rede Neural Artificial

LISTA DE SÍMBOLOS

$M_{\alpha\beta}$	Razão de Mobilidade
K_{rf}	Permeabilidade relativa ao fluido deslocante
K_{ro}	Permeabilidade relativa ao fluido deslocado
μ_f	Viscosidade do fluido deslocante
μ_o	Viscosidade do fluido deslocado
v	Velocidade do fluido deslocado
σ	Tensão interfacial
Θ	Ângulo de molhabilidade
U	Campo de Velocidades
Γ	Difusividade
w_{ij}	Peso sináptico i da camada j
x_{ij}	Sinal de entrada do neurônio i da camada j
b_{ij}	Bias do neurônio i da camada j
y	Sinal de saída de um neurônio
$\bar{y}$	Saída esperada de um neurônio
M	Momentum da rede
γ	Porosidade absoluta
H	Entalpia específica do fluido
ρ	Massa específica
U_x	Componente da velocidade na direção x
U_y	Componente da velocidade na direção y
U_z	Componente da velocidade na direção z
S	Termo fonte de energia
K	Tensor de porosidade
R	Tensor de resistência ao fluxo no meio poroso
Γ_e	Termo de difusividade térmica
φ_e	Porosidade efetiva

SUMÁRIO

1. INTRODUÇÃO	9
2. OBJETIVOS	11
2.1 OBJETIVOS GERAIS.....	11
2.2 OBJETIVOS ESPECÍFICOS	11
3. REVISÃO DA LITERATURA.....	12
3.1. RECUPERAÇÃO DE RESERVATÓRIO	12
3.2. MÉTODOS QUÍMICOS	14
3.3. MÉTODO DE NANOFLUIDOS.....	14
3.3.1. MATERIAIS UTILIZADOS NA PRODUÇÃO DE NANOFLUIDOS	17
3.3.2. PROPRIEDADES EXPLORADAS EM NANOFLUIDOS	18
3.3.3. TENDÊNCIAS FUTURAS	20
3.4. SIMULAÇÃO NUMÉRICA DE RESERVATÓRIOS	21
3.4.1. FLUIDODINÂMICA COMPUTACIONAL	21
3.4.2. REDES NEURAIIS ARTIFICIAIS.....	24
4. METODOLOGIA	29
4.1. SIMULAÇÕES FLUIDODINÂMICAS.....	29
4.1.1. GERAÇÃO DE GEOMETRIA E MALHA NUMÉRICA	29
4.1.2. MODELO NUMÉRICO.....	31
4.1.3. ESTUDOS DE CASOS SIMULADOS EM CFD.....	36
4.2. SIMULAÇÕES EM REDES NEURAIIS	37
4.2.1. TIPO DE REDE APLICADA	37
4.2.2. PARÂMETROS DE REDE	37
4.2.3. ESTUDOS DE CASO SIMULADOS PARA REDES NEURAIIS	38
5. RESULTADOS E DISCUSSÕES	40
5.1 ANÁLISE EM CFD DOS MÉTODOS DE RECUPERAÇÃO DE ÓLEO.....	40
5.3 RESULTADOS DA EFICIÊNCIA DAS REDES NEURAIIS	45
6. CONSIDERAÇÕES FINAIS.....	47
6.1 CONCLUSÕES	47
6.2 PROPOSTA DE TRABALHOS FUTUROS	47
7. REFERÊNCIAS.....	48
APÊNDICE A – Rede Neural Artificial.....	54

1. INTRODUÇÃO

Devido ao baixo fator de recuperação de petróleo por meio de métodos primários (que não utilizam injeção de fluidos no reservatório), ou ainda secundários de produção de poços, a recuperação terciária de petróleo, também chamada de *Enhanced Oil Recovery* (EOR), se torna uma das melhores alternativas para acompanhar o crescimento da demanda energética mundial, uma vez que o número de poços maduros é predominante em relação às jazidas de petróleo não maduras. Em poços no Brasil, segundo a ANP (2017), o fator de recuperação de petróleo era de 9% (11% considerando a produção acumulada), enquanto o fator de recuperação de reservas provadas e possíveis era de 15 e 20%, respectivamente.

Levando este cenário em consideração, os métodos de recuperação terciária visam aumentar a eficiência de recuperação de óleo do meio poroso, isto é, aumentar a quantidade de óleo que é possível de ser produzida, após uma recuperação primária ou secundária (com injeção de água ou gás imiscível) através de diferentes mecanismos como redução da tensão superficial, alteração da molhabilidade do ambiente e realizando controle de viscosidade e mobilidade de fluido, com o objetivo de varrer o óleo residual o máximo possível. Todas essas propriedades devem ser obtidas com um EOR que apresente características que estejam de acordo com aquelas do reservatório, e que implementa o menor impacto ambiental possível (ESFE, HOSSEINIZADEH e MOSAFERI, 2020; LIU et. al., 2020).

Atualmente, os métodos EOR mais comumente aplicados são: métodos de gases miscíveis, métodos térmicos, métodos especiais (métodos microbiológicos, eletromagnéticos, entre outros) e os métodos químicos, chamados de *Chemical Enhanced Oil Recovery* (CEOR). Estes últimos têm sido objetos de estudo de diversos pesquisadores nos últimos anos (NOWROUZI, MANSHAD e MOHAMMADI, 2019; BRANTSON et. al., 2020; MEHRABIANFAR, BAHRAMINEJAD e MANSHAD, 2021) principalmente nos temas voltados a nanofluidos e injeção de polímeros onde, em razão da escassez de dados de reservatório ou problemas com os sistemas de polímeros, diversos projetos falharam no passado. Em outro segmento, o estudo de nanofluidos que, entre os anos 2017 a 2019, alcançou mais de 1400 publicações na *Society Petroleum Engineers* (SPE), apresenta tendência crescente em seus números de trabalhos devido às suas propriedades únicas (LASHARI e GANAT, 2020).

Até meados do século 20, um problema recorrente de fluidos com partículas sólidas dispersas era a sua instabilidade, que gerava um aumento da resistência ao fluxo. Graças ao desenvolvimento da nanociência, as partículas conseguem atingir diâmetros numa escala entre 1 e 100 nm, permitindo uma maior estabilidade em fluidos, maior capacidade de transferência de calor e de massa, além de propriedades magnéticas (COCCIA, TOMASSETI e NICOLA, 2021; ESFE, HOSSEINIZADEH e ESFANDEH, 2020). No meio poroso, estes nanofluidos são capazes de modificar as características do reservatório alterando sua condutividade e calor específico, as interações entre óleo e rocha, e alterando sua molhabilidade. Além disso, as nanopartículas (NP) dispersas em um fluido são capazes de modificar a viscosidade e densidade do fluido, reduzir a tensão interfacial e formação de emulsão (LASHARI e GANAT, 2020).

Desse modo, este trabalho avaliou a eficiência de produção de óleo em um modelo de reservatório a partir da injeção de nanofluido de CaCO_3 , uma estrutura de elevada disponibilidade na natureza, ambientalmente não agressivo e de baixo custo associado à sua fabricação e reprodução, que foi produzido previamente por Santos (2021) a partir de conchas de sururu e, para isso, é utilizado nesse trabalho o software de fluidodinâmica computacional (CFD) ANSYS® CFX 13.0, que permite a modelagem e a simulação de um sistema experimental capaz de representar o escoamento de nanofluidos em meios porosos saturados de óleo.

Em adição, uma rede neural artificial (RNA) foi treinada com base em dados de produção do software de simulação supracitado visando reduzir o tempo necessário e o custo computacional para obtenção de respostas de eficiência do método de injeção. Sendo assim, a RNA foi utilizada para predizer, a partir de informações de entrada referentes às características do meio poroso, do óleo e do fluido de injeção, o fator de recuperação associado ao método utilizado.

2. OBJETIVOS

2.1 OBJETIVOS GERAIS

Estudar a eficiência de deslocamento de óleo em um modelo de reservatório sujeito à injeção de nanofluidos de CaCO_3 a partir de uma abordagem fluidodinâmica e redes neurais artificiais.

2.2 OBJETIVOS ESPECÍFICOS

- a) Simular, via CFD, a recuperação secundária com água em modelo de reservatório em escala reduzida.
- b) Simular, via CFD, a injeção de nanofluidos de CaCO_3 , variando a concentração de nanopartículas na solução, bem como seus diâmetros.
- c) Avaliar o incremento do fator de recuperação óleo devido a injeção de nanofluido de CaCO_3 .
- d) Compreender os mecanismos de ação que permitem a eficiência do método
- e) A partir de redes neurais artificiais, e utilizando os dados simulados em CFD, realizar previsões do fator de recuperação associado ao método de injeção.


3. REVISÃO DA LITERATURA

3.1. RECUPERAÇÃO DE RESERVATÓRIO

Entende-se por métodos de recuperação reservatório, técnicas que permitam a produção de petróleo de uma jazida. São 3 os tipos macros de métodos de recuperação: Recuperação primária; recuperação secundária ou convencional e recuperação terciária ou avançada de petróleo.

Um poço é dito surgente, se este se utiliza apenas da energia do reservatório, da compressão dos poros e expansão dos fluidos presente neles, e este método é denominado recuperação primária, ilustrado na Figura 1. A quantidade de poços que consegue se manter economicamente viável utilizando esta recuperação é mínima, e como todos os poços, em um dado momento, entram em declínio de produção, logo se utilizam da recuperação secundária (RADWAN et. al., 2021).

Figura 1 - Esquema de um campo sob recuperação primária de petróleo.




Fonte: Autor (2022).

Os métodos de recuperação secundária englobam a injeção de água ou de gás no meio poroso. Visam fornecer energia suplementar ao reservatório, pressurizando-o, de modo que,

devido a imiscibilidade dos fluidos, a água consiga varrer os hidrocarbonetos (RADWAN et. al., 2021). Este é o método mais utilizado devido ao baixo custo associado, porém é bastante suscetível ao fenômeno de *fingers*, onde a água injetada, pelo fato da sua menor viscosidade conseguir atravessar o óleo e tomar caminhos preferenciais de tal forma que o tempo de *breakthrough*, isto é, o tempo que um campo leva para produzir o primeiro volume de água que foi injetada no reservatório, é encurtado. Conforme o deslocamento do óleo pela água prossegue, a fase de óleo eventualmente se desintegra em bolhas de óleo residual, que são imobilizadas nos poros por forças capilares (MANDAL, 2015).

Por sua vez, os métodos de recuperação terciária, envolvem a injeção de líquidos ou gases não convencionais e têm o objetivo de, além da pressurização do reservatório, alterar algumas de suas características. Entre elas, podem ser citadas: a alteração da molhabilidade da rocha, alteração da viscosidade do óleo, redução da tensão superficial. Dentro das EOR, existem os métodos de gases miscíveis, métodos térmicos e os métodos químicos. Portanto, para escolher o melhor deles, faz-se necessária uma análise rigorosa do histórico de produção, e estudos laboratoriais e de simulação do campo, tencionando a maximização do fator de recuperação (BERA, VIJ e SHAH, 2021). A Figura 2 esquematiza um campo de petróleo sob ação de um poço injetor de fluidos.

Figura 2 - Esquema de um campo sob recuperação secundária ou terciária de petróleo.



Fonte: Autor (2022).

3.2. MÉTODOS QUÍMICOS

Injeção química é um dos métodos que possibilitam recuperação adicional em torno de 35% de OOIP (*Original oil-in-place*). Dentro do campo dos métodos químicos, encontra-se a injeção de surfactantes, polímeros, álcali-surfactante-polímero e combinações destes métodos (MANDAL, 2015; RELLEGADLA, PRAJAPAT E AGRAWAL, 2017).

Com a injeção de surfactantes, o objetivo é reduzir a tensão interfacial entre os fluidos e a molhabilidade do meio poroso, de forma que a pressão capilar seja reduzida e desloque os hidrocarbonetos, gerando uma emulsificação (SHE et. al., 2021; JING et. al., 2021). Segundo Mandal (2015), o custo do surfactante é o principal fator limitante durante a escolha do CEOR, além de sua baixa eficiência em relação a outros métodos (DING et. al., 2019).

A injeção de polímeros é um dos métodos CEOR mais utilizados, em consequência do seu aumento considerável no fator de recuperação (LAMAS et. al., 2021). O principal objetivo é alterar a razão de mobilidade entre água e óleo através do aumento da viscosidade da fase contínua onde os polímeros estarão dispersos, como a salmoura, por exemplo. Entretanto, as limitações com os polímeros disponíveis tais como degradação química, mudança térmica e comportamento químico da reologia do polímero são desafios a serem superados (LASHARI e GANAT, 2020).


Para obtenção das melhores propriedades de cada um dos componentes, a injeção de álcali-surfactante-polímero (ASP) é um método promissor, quando se trata de CEOR (MANDAL, 2015). A injeção de ASP permite o aumento da viscosidade da fase contínua, consegue realizar alterações na molhabilidade do meio poroso e ainda reduz tensões interfaciais água/óleo. Todavia, Kurnia et. al. (2020), verificaram que haviam diversos problemas gerados por álcalis, como incrustações, corrosões e a consequente redução do tempo médio de avaliação de bombas.

3.3. MÉTODO DE NANOFLUIDOS

Em função das inúmeras características únicas dos nanomateriais com propriedades químicas e físicas especiais, tais como efeitos de superfície, efeitos de tamanho quântico, efeito de tunelamento quântico macroscópico, efeito de confinamento dielétrico e maior reatividade

química (LIU Z. et. al., 2020), eles estão sendo utilizados nas mais diversas áreas da indústria de O&G. Sajjadian M., Sajjadian V. e Rashidi A. (2020) estudaram a aplicação de nanomateriais no fluido de perfuração no processo de perfuração em poços HPHT, Liu J. et. al. (2020) verificaram melhorias nas propriedades do fluido de fraturamento, como incremento na tolerância à temperatura, módulo elástico e viscosidade aparente. Maagi, Lupyana e Jun (2020) revisaram diferentes trabalhos onde a qualidade da cimentação foi aumentada, graças as nanopartículas inseridas no cimento. Além das diversas áreas de atuação, nanomateriais vêm crescendo em número de trabalhos publicados como pode ser observado na Figura 3.

Figura 3 - Número de publicações da SPE baseadas em nanotecnologia.




Fonte: Lashari e Ganat (2020).

Os nanofluidos podem ser preparados a partir de diferentes materiais. Al-Anssari, et. al. (2016) realizaram um estudo sobre a alteração da molhabilidade de uma rocha carbonática molhável a óleo e verificou a eficiência da utilização do nanofluido, cujas nanopartículas de sílica (SiO_2) foram dispersas em salmoura, e observou que o nanofluido conseguiu adsorver à rocha tornando a rocha molhável à água, possibilitando um aumento de produção de óleo em reservatórios carbonáticos, além de poder transformar esse reservatório em um ambiente para armazenamento de CO_2 , importante para projetos de *Carbon Capture and Storage* (CCS). Além da sílica, existem diversos outros tipos de nanofluidos, tais como de óxido de zircônio (YEKEEN et. al., 2021), óxido de alumínio (REZVANI, et. al., 2020), óxido de ferro

(AMROUCHE et. al. 2021), nanotubos de carbono (KADHUM et. al. 2015) e CaCO_3 (AHMADI et. al., 2019).

No meio poroso, com sua escala mesoscópica, os nanofluidos dificilmente são capazes de fechar poros e diminuir a permeabilidade do reservatório. Dada a alta área superficial advinda das nanopartículas, esses fluidos conseguem aderir nos poros da rocha e são capazes de modificar a molhabilidade preferencial ao óleo ou intermediária para uma rocha molhável a água, em razão da pressão de separação, onde as nanopartículas formam uma espécie de calço (*wedge film*) entre a rocha e óleo. Quando essa pressão supera a pressão capilar, o óleo é desprendido da rocha, e então nanopartículas são capazes de aderir às paredes dos poros. Esse é considerado o mecanismo primário pelo qual o óleo consegue ser recuperado, conforme exibido na Figura 4, e as principais forças que orientam esse mecanismo são: força eletrostática repulsiva entre nanopartículas e o movimento Browniano entre as partículas (LASHARI e GANAT, 2020; ZHANG, NIKOLOV e WASAN, 2014). Com isso, bolhas de óleo são deslocadas por meio da pressurização provocada pelo fluido injetado, aumento da mobilidade da fase oleosa e da diminuição de forças capilares.

Figura 4 - Mecanismo primário do método de nanofluidos.



Fonte: Autor (2022).

Para evitar a ocorrência de *fingers*, também é utilizado nanofluidos, pois as nanopartículas são capazes de modificar o comportamento, diante de uma tensão cisalhante, do fluido base. Singh et. al. (2021) preparou um nanofluido do nanocompósito rGO-Al₂O₃ (óxido de grafeno reduzido-Al₂O₃), cuja fase contínua era água (fluido newtoniano), e verificou que o nanofluido se comportava como fluido não-newtoniano pseudoplástico. Ademais, a presença das nanopartículas é capaz de tornar o fluido mais viscoso, concedendo melhorias na razão de mobilidade da fase. A razão de mobilidade consiste na razão entre a mobilidade da fase deslocante e a fase deslocada, e é definida na Equação 1 como:

$$M_{\alpha\beta} = \frac{K_{rf} \cdot \mu_f}{K_{ro} \cdot \mu_o} \quad (1)$$

Onde K_{rf} , K_{ro} , μ_f e μ_o referem-se, respectivamente, a permeabilidade relativa ao fluido deslocante, a permeabilidade relativa ao óleo, viscosidade do fluido deslocante e viscosidade do óleo (fluido deslocado). Injeções de fluidos no reservatório que apresentem razão de mobilidade menor que a unidade, são consideradas estáveis, resultando em um deslocamento eficiente da fase oleosa (KUMAR, et. al., 2008).

3.3.1. MATERIAIS UTILIZADOS NA PRODUÇÃO DE NANOFLUIDOS

Um dos grandes desafios quando se trata da efetividade do método de injeção de nanofluidos (NFs) são os diferentes tipos de reservatórios, com suas heterogeneidades, condições de temperatura e pressão, tipo de rocha e forma. Para tanto, também são estudados diferentes nanofluidos, com suas diferentes composições de nanopartículas e tipos de fluido base.

Kamal et. al. (2017) reuniram em seu artigo algumas composições de nanofluidos e suas propriedades, estudadas por diferentes autores. TiO₂, *nanoclay* (nanoargila), polissilício, Fe₂O₃, ZrO₂, Ni₂O₃, são exemplos das diversas possibilidades de nanopartículas, além das citadas anteriormente. Todavia, não somente o tipo de nanopartícula possui influência na eficiência do método, mas também o fluido base, que, muito embora seja majoritariamente utilizada a água, são utilizados também etanol, água deionizada, água do mar e propanol (LI, WANG e JIANG, 2018; KAMAL, et. al., 2017). As diferentes constantes dielétricas do fluido base são diretamente responsáveis pelo potencial repulsivo das partículas, o que significa que,

quanto maior essas constantes, maior a estabilidade do nanofluido e, conseqüentemente, as nanopartículas não se aglomeram (CHAKRABORTY e PANIGRAHI, 2020).

Mohd, et. al., (2016) estudaram diferentes fluidos base sob a condição de uma mesma concentração de nanopartículas de SiO_2 e obteve como resultados valores distintos de viscosidade de nanofluido. As viscosidades médias dos nanofluidos foram 20 cp, 36,3 cp, 19,52 cp e 20,43 cp para os fluidos base água destilada, etileno-glicol (EG), etanol e salmoura, respectivamente. Mohd, et. al., (2016) ressaltou ainda que a viscosidade do EG e do etanol eram de aproximadamente 20 cp e 1 cp, respectivamente, reafirmando a dependência do nanofluido do seu fluido base.

3.3.2. PROPRIEDADES EXPLORADAS EM NANOFLUIDOS

Alteração da molhabilidade

Uma propriedade que é bastante observada em surfactantes é também possível com a utilização de nanofluidos. A alteração da molhabilidade permite que um meio poroso que é molhável preferencialmente a óleo, possa tornar-se molhável à água, desprendendo a bolha de óleo da rocha, facilitando sua produção. Azarshin, Moghadasi e Aboodasi (2017) mediram o ângulo de contato de uma gota de petróleo numa amostra de rocha reservatório e obtiveram um ângulo de 135° , caracterizando uma rocha extremamente molhável a óleo e após a injeção de nanofluido de SiO_2 0,25wt%, houve um decréscimo para 55° , tornando a rocha molhável à água, e gerou um aumento no fator de recuperação de petróleo de 10%.

Redução de tensão interfacial

Um fenômeno bastante associado à alteração de molhabilidade é a redução de tensão interfacial propiciada pela inundação de nanofluido, que reduz a pressão capilar, responsável por “succionar” fluidos no meio poroso. A tensão interfacial (IFT) consiste na energia gerada no limite entre dois fluidos imiscíveis, como por exemplo água e óleo, a redução dessa tensão permite uma maior interação entre os fluidos, de modo que é facilitada a remoção de bolhas de óleo que estão presas no meio poroso devido a pressão capilar. A redução da IFT permite o aumento do número capilar. Um número adimensional que está diretamente relacionado com a recuperação de petróleo (KAMAL, et. al., 2017) e é definido na Equação 2:

$$N_{ca} = \frac{\text{Forças viscosas}}{\text{Forças capilares}} = \frac{v\mu_o}{\sigma \cos \theta} \quad (2)$$

Onde v e μ_o correspondem a velocidade do fluido a ser deslocado e sua viscosidade, e σ e θ correspondem a tensão interfacial e o ângulo que define a molhabilidade do meio em relação ao fluido, respectivamente.

Nowrousi, Manshadi e Mohammadi (2019) produziram 3 diferentes nanofluidos de MgO, TiO₂ e γ -Al₂O₃, cada um com uma concentração de 500ppm e de 1000ppm e, sob diferentes condições de temperatura e pressão, verificaram a redução da tensão interfacial proporcionada pela injeção de nanofluidos. Azarshin, Mohadasi e Aboodasi (2017) também mediram a IFT antes e depois da inundação com nanofluido de SiO₂ e verificaram uma redução de aproximadamente 68% da IFT.

Alteração da viscosidade do fluido base

Sendo fundamental para o número capilar e a razão de mobilidade entre fases presentes em um meio poroso, o aumento da viscosidade proporcionado pela presença de nanopartículas reduz a possibilidade de ocorrência de *fingers* e aumenta o tempo de *breakthrough*. Um nanofluido, desenvolvido a partir da conjugação de nanofolhas de óxido de grafeno e surfactante aniônico (GONs), foi produzido por Khoramian, Kharrat e Golshokooh (2022) e foi comparado a um nanofluido de SiO₂. Com viscosidade superior de 3,27 cp, o nanofluido de GONs apresentou uma eficiência de varredura muito maior do que o nanofluido de SiO₂, cuja viscosidade é 1,15 cp, sob uma mesma concentração. Os tempos de *breakthrough* foram medidos e enquanto o resultado do NF de SiO₂ foi de 58min, o NF de GONs atingiu o *breakthrough* apenas com 118min de injeção, num mesmo micromodelo.

Pressão de separação (*Disjoining Pressure*)

Considerado o mecanismo principal de ação dos nanofluidos, a pressão de separação é provada através de resultados experimentais e cálculos teóricos como sendo formada a partir de uma camada de nanopartículas que se acumulam próximo ao óleo e são capazes de destacar o óleo da superfície rochosa (YAKASAI, et. al., 2021).

Zhang, Nikolov e Wasan (2014) verificaram o mecanismo de pressão de separação através do deslocamento de óleo cru por meio da injeção do nanofluido IIT (*Illinois Institute of Technology*), desenvolvido por eles, com fator de recuperação de 55% e comparou com o fator obtido a partir da injeção de salmoura que foi de 17%. Moghaddam, et. al., (2015) realizaram

experimentos com nanofluidos a partir de diversos materiais, e dentre eles TiO_2 , CaCO_3 e SiO_2 . Eles obtiveram incrementos entre 8 e 9% devido a ação dos nanofluidos injetados e concluíram, a partir da literatura, que o papel da pressão de separação é essencial para a eficiência do método de nanofluidos.

Área de superfície específica

Nanofluidos apresentam uma grande razão de área de superfície por volume devido ao pequeno diâmetro das partículas, onde esta propriedade permite ao nanofluido uma maior área de contato entre os fluidos base e óleo (LI, WANG e JIANG, 2018). Portanto, pode-se observar que quão menor for o tamanho da nanopartícula, para uma mesma concentração destas, maior a quantidade de nanopartículas atuando neste contato, aumentando assim a recuperação de óleo concedida pelas propriedades citadas anteriormente.

3.3.3. TENDÊNCIAS FUTURAS

Recentemente vêm sendo publicados artigos que exploram as propriedades dos chamados nanofluidos híbridos. Com o crescente interesse nas diferentes propriedades dos nanofluidos atualmente, Arif et. al. (2022) foram um dos pesquisadores que realizaram um trabalho de análise sobre o potencial de um nanofluido ternário de realizar transferência de calor, que utiliza 3 nanopartículas de diferentes formas: Nanotubos de carbono, nano esferas de Al_2O_3 e a forma chapeada de nanopartículas de grafeno. Para as soluções foi utilizado o software Mathcad e obteve como resposta um ganho no poder de transferência de calor quando comparado com o nanofluido unitário.

Com a motivação do fato de mono nanofluidos atingirem um limite no aumento de viscosidade com o aumento da concentração de NPs, Adun, Kavaz e Dagbasi (2021) também realizou um estudo acerca da síntese, estabilidade e propriedades termofísicas de diferentes nanofluidos híbridos ternários estudados por diferentes pesquisadores, verificando também a dificuldade de reduzir a aglomeração dessas nanopartículas para manter sua estabilidade e alcançar o máximo desempenho destes fluidos promissores.

Com base nos trabalhos acima citados e no de Esfe, et. al. (2020) em seu artigo de revisão sobre as propriedades de nanofluidos em meios porosos e sua capacidade de transferência de calor, com o crescente número de publicações sobre nanofluidos e sua

estabilidade sob altas temperaturas, pode-se inferir que estes fluidos possam ser explorados de modo a mesclar métodos químicos de recuperação avançada de petróleo e métodos térmicos. Outra via de pesquisa a ser explorada é no tópico de estabilidade de nanofluidos unitários e híbridos, onde estes fluidos possam alcançar uma maior aplicabilidade em diversos reservatórios com a redução de manutenção destes fluidos e a consequente redução de custos associados a esse processo.

3.4. SIMULAÇÃO NUMÉRICA DE RESERVATÓRIOS


3.4.1. FLUIDODINÂMICA COMPUTACIONAL

A fluidodinâmica computacional (CFD) compreende os estudos voltados ao comportamento de fluidos, transferência de massa e de calor, além de fenômenos relacionados a reações química, combustão, entre outras, através de simulação numérica do método de elementos finitos (SILVA, 2016). É uma metodologia que viabiliza estudos avançados sob baixo custo, funcionando como um complemento as análises de laboratório, onde alguns mecanismos podem não ser devidamente notados ou a origem de algum resultado não ficou clara. De forma mais assertiva, a CFD garante aos seus usuários percepções críticas sob processos fluidodinâmicos que ocorrem entre fases de interação. Tendo como ponto negativo, em simulações mais avançadas, maior necessidade de poder e espaço computacional (EJEH et. al., 2020).

Em função de todas as possibilidades da CFD, esta também vem sendo utilizada recentemente para resolução de problemas da engenharia de petróleo em sistemas de recuperação avançada. Ejeh et. al. (2020), realizaram estudos experimentais e numéricos para comparar e avaliar a eficiência de nanofluidos a base de silicone, silano e sílica, com álcool como solvente, através geração de geometria 2D em software de modelagem incorporando ao modelo a problemática da molhabilidade do meio poroso. Minakov et. al., (2021) apresentaram uma modelagem 3D em escala de poro semelhante ao real, com diferentes porosidades e permeabilidades, e, operando com dados obtidos experimentalmente, verificou o aumento do deslocamento com as mudanças de molhabilidade do meio poroso com injeção simulada de uma nanosuspensão. Gharibshahi, Jafari e Ahmadi H. (2019) simularam tanto o método térmico de recuperação avançada (injeção de vapor) quanto o CEOR com injeção de nanofluidos, investigando a recuperação de um óleo de característica extra-pesada ($^{\circ}\text{API}$ menor que 10), e

notaram parâmetros críticos quanto a eficiência do método. Esfe, Hosseinizadeh e Mosaferi (2020), simularam um meio poroso de permeabilidade e porosidade variáveis, em formato tronco de cone, onde foi avaliada a eficiência da recuperação de petróleo a partir da injeção de nanofluido com diferentes concentrações de nanopartículas de SiO_2 , sendo estas: 0wt%, 1wt%, 2.5wt% e 5wt%. As geometrias destes trabalhos são exibidas na Figura 5.

Figura 5 - Modelagem CFD de meios porosos de outros autores. (a) Modelagem 3D em escala de poro de Minakov, et. al. (2021); (b) Modelagem 2D de micro modelo poroso de Ejeh, et. al. (2020); (c) Modelagem 2D de micro modelo poroso de Gharibshahi, Jafari e Ahmadi H. (2019). (d) Modelagem 3D em formato de tronco de cone de Esfe, Hosseinizadeh e Mosaferi (2020).



Fonte: Minakov, et. al. (2021); Ejeh, et. al. (2020); Gharibshahi, Jafari e Ahmadi H. (2019); Esfe, Hosseinizadeh e Mosaferi (2020).

Para resolução dos problemas, a CFD se utiliza de diferentes métodos e, dentre eles, o de volumes finitos. Este é um método numérico que aplica os princípios de conservação de massa, energia e momentum na modelagem matemática. Introduzido em 1970 por McDonald, MacCormack e Paullay, atualmente o método tem tido diversos avanços e é utilizado nos mais diversos softwares de modelagem e simulação como o ANSYS® CFX (MARINHO, KNUPP e VASCONCELLOS, 2019).

Método de volumes finitos

Problemas de transferência de calor, fluxo de fluidos e problemas relacionados tem como principal solução de discretização o método de volumes finitos no início do século XXI (JASAK e UROIC, 2020). Não sendo diferente de outros métodos, o de volumes finitos objetiva transformar um conjunto de equações diferenciais em equações lineares algébricas resolvidas de forma matricial a partir de condições iniciais e de contorno, e consiste em basicamente dois passos: Integração das equações diferenciais no primeiro passo e interpolação das variáveis para aproximar suas variações, no segundo. (MOUKALLED, MANGANI e DARWISH, 2016).

O método dos volumes finitos, aplicado como metodologia de resolução em muitos softwares de CFD, baseia-se no princípio da aplicação de leis básicas de conservação em pedaços menores de espaço, isto é, cada volume de uma malha numérica, analisando as interdependências dessas equações. Na Equação 3 é apresentada uma equação de transporte escalar, numa forma padrão, onde as leis de conservação se aderem (JASAK e UROIC, 2020).

$$\underbrace{\frac{\partial \phi}{\partial t}}_{\text{derivada temporal}} + \underbrace{\nabla \cdot (\phi U)}_{\text{termo convectivo}} - \underbrace{\nabla \cdot (\Gamma \nabla \phi)}_{\text{termo difusivo}} = \underbrace{q_v}_{\text{termo fonte}} \quad (3)$$

Onde ϕ é o local reservado para a variável em consideração, englobando valores como um vetor de velocidade (com componentes em x, y e z), massa específica e entalpia, a depender do tipo de equação de transporte de energia, momento ou continuidade. O campo de velocidade é representado pela variável U , na Equação 3 acima, Γ é um termo de difusividade e q_v é a contribuição do termo fonte ao balanço de ϕ .

O termo de derivada temporal representa a inércia do sistema. O termo de convecção representa o transporte convectivo de uma determinada característica, por exemplo uma energia, por um campo de velocidade prescrito. O termo difusivo resulta da hipótese do transporte de gradiente. Em termos de energia, o termo difusivo representa a transferência de

calor por difusão. Finalmente o termo fonte representa a produção ou a destruição de $\emptyset$ dentro do volume de controle (OLIVEIRA, 2015; JASAK e UROIC, 2020).

O modelo Euleriano-Euleriano

Este modelo é utilizado principalmente quando existe um fluido disperso em um meio contínuo como é o caso de dispersões de partículas e bolhas. É um modelo complexo e preciso que permite a mistura e a separação das fases presentes em um sistema. Este modelo utiliza um único gradiente de pressão para todas as fases envolvidas e resolve as equações de momento, energia, continuidade e turbulência, e ainda permite o acompanhamento das frações volumétricas das fases, nas quais cada uma varia de zero a um e a soma destas frações deve ser igual a unidade (JAFARI, et. al., 2020).

Neste trabalho, o modelo de partículas dispersas é adotado para modelagem do nanofluido, que constitui pequenas esferas de uma mistura ideal de água e nanopartículas, cujo tamanho destas é definido como o produto da fração mássica de CaCO_3 do nanofluido pelo tamanho da partícula que engloba a mistura de água e nanopartícula de CaCO_3 . É assumido que tais partículas não apresentam rugosidades e não rotacionam. Os fluidos são considerados newtonianos e incompressíveis, não ocorrem reações químicas, assim como não ocorrem transferência de massa entre as fases que escoam em regime transiente (OLIVEIRA, 2005; CHIESA, et. al., 2005).

Em razão de haverem fluidos imiscíveis no sistema, é utilizado o *Buoyancy Model* ou modelo de empuxo, que considera a diferença de densidades dos fluidos, utilizando como densidade de referência o fluido menos denso. Considerando o escoamento descendente devido a forças gravitacionais e sob condições normais de temperatura e pressão, o tipo de escoamento adotado foi laminar. O modelo de transferência de momento entre as fases também é inserido, através do coeficiente de arrasto que foi mantido o padrão do aplicativo da ANSYS® CFX 13.0, de 0,44.

3.4.2. REDES NEURAIS ARTIFICIAIS

As RNA são assim chamadas em virtude de o algoritmo funcionar de modo similar as redes neurais biológicas, pela forma como as informações são recebidas, interpretadas, ponderadas até enviarem uma informação de saída. O algoritmo de redes neurais artificiais

(RNA) é um algoritmo que, devido a sua estrutura não-linear altamente interconectada, possui capacidade de auto-organização, possibilitando o aprendizado diretamente a partir de dados do processo (PIMENTEL, 2005). Atualmente, as RNA têm atingido grandes resultados em diferentes áreas da indústria do petróleo. Sua alta capacidade de predição e detecção de padrões dão as redes neurais uma gama enorme de possibilidades, automatizando processos e aumentando a segurança de determinadas operações, tais como: análise de teste de poço; interpretação de perfis de poço; desenvolvimento de campo; caracterização de reservatório; propriedades PVT; danos à formação; produção e perfuração (CHEN, 2014).

A estrutura de uma RNA consiste em basicamente uma camada de entrada, com o número de neurônios associado a cada variável de entrada do problema, uma ou mais camadas ocultas, cuja quantidade de neurônios varia de acordo com a complexidade do problema, e uma camada de saída, onde o número de neurônios varia de acordo com as possíveis respostas a serem obtidas. Os neurônios são interligados por pesos sinápticos (w_{ij}), responsáveis pela inteligência da rede, que ponderam os sinais recebidos (x_{ij}) pelos neurônios da camada anterior. Ao sinal, é adicionada uma constante denominada *bias* (b_{ij}) que reduz ou aumenta o valor do sinal recebido e, à essa soma, aplica-se uma função de transferência (f) que reúne e transforma as contribuições dos sinais da camada anterior ponderadas pelo peso sináptico de cada neurônio e dos biases, e em seguida esta função converte os diferentes valores e os põe numa escala entre 0 e 1 ou entre -1 e 1, a depender da função utilizada, para facilitar a interpretação da RNA. A Equação 4 representa a saída (y) de um neurônio i da camada j .

$$y = f \left(\sum_j x_{ij} w_{ij} + b_{ij} \right) \quad (4)$$

Nos últimos anos, modelos heurísticos baseados em dados experimentais, tais como redes neurais artificiais e algoritmo genético são utilizados para prever algum dado com o objetivo de reduzir experimentos adicionais (HEIDARI, SOBATI e MOVAHEDIRAD, 2016). Tal abordagem recentemente foi aplicada para nanofluidos quando Wen et. al. (2021) utilizaram dados experimentais de um estudo das características térmicas e de escoamento de nanofluido de ZnO em dois canais multi-portas, simulou numericamente através de fluidodinâmica computacional este experimento para diversos outros nanofluidos (TiO₂, CuO, entre outros) com dados obtidos de outros trabalhos com outras concentrações volumétricas de nanofluidos e com esses resultados, eles treinaram uma RNA com a camada de entrada com 3 neurônios, uma camada oculta com 15 neurônios e a camada de saída com apenas 1 neurônio, cuja saída


prediz o número Nusselt, a partir dos dados de fração volumétrica, número de Reynolds e número Prandtl.

Heidari, Sobati e Movahedirad (2016) utilizaram redes neurais do tipo *feed-forward backpropagation Multilayer Perceptron* para prever a viscosidade dos nanofluidos a partir de dados de entrada de temperatura, tamanho de nanopartícula, densidade, fração volumétrica e viscosidade do fluido base. Uma vez que os modelos matemáticos disponíveis não conseguem prever a viscosidade para uma grande variação parâmetros de fabricação de nanofluido, a rede neural foi capaz de obter uma acurácia (R^2) de 0,99998, na determinação da viscosidade dos nanofluidos.

Rede neural *multilayer perceptron*

Um *Perceptron* consiste na forma mais simples de uma rede neural. É um único neurônio que recebe uma ou mais informações de entrada, pondera esses sinais através de cada peso sináptico que liga as entradas ao neurônio, adiciona um valor constante (*bias*) e aplica uma função de ativação, que fornecerá um sinal de saída referente ao impulso de entrada. A Figura 6 ilustra o processo de um Perceptron.


Figura 6 - Esquematização do processo de um Perceptron.



Fonte: Autor (2020).

A combinação de Perceptrons em paralelo, geram um *Single-Layer Perceptron*, que permite que mais opções de saída sejam possíveis, como no caso de RNAs que tem o objetivo de realizar diferentes classificações de padrões ou ainda oferecer uma predição de diferentes características de um processo. Finalmente, o conjunto de duas ou mais camadas formam o *Multi-Layer Perceptron* (MLP), ilustrado na Figura 7, cuja organização permite o chamado *Deep Learning*, capaz de prever e/ou classificar processos ainda mais complexos, geralmente consistindo de uma camada com neurônios de entrada, uma camada oculta e uma de saída.

Figura 7 - O Multilayer Perceptron.



Fonte: Autor (2022).

Taud H., e Mas J. (2018) ressaltam que a performance de um MLP depende não somente da escolha de variáveis de entrada, número de camadas ocultas, neurônios ou dados de treinamento, mas também dos parâmetros de treinamento tais como a taxa de aprendizagem, número de iterações e tolerância, que influenciam a velocidade e a efetividade do treinamento de redes.

Algoritmo *Back-propagation*

No momento inicial que uma rede neural é concebida, seus pesos sinápticos e bias são gerados aleatoriamente. Zeng, et. al., (2017) caracteriza uma árvore neural que utiliza o algoritmo *backpropagation* como sendo muito similar ao cérebro humano, devido ao fato das RNAs conseguirem aprender e armazenar diferentes dados.

Uma vez que uma primeira resposta é emitida pela rede após o primeiro contato com os sinais de entrada, é realizada uma comparação com a resposta esperada, para compreender o quão inteligente foi aquela resposta. Isto feito, o processo de aprendizagem é realizado no sentido contrário ao da emissão da resposta do modelo com o ajuste dos pesos e bias entre as camadas, com o objetivo de aumentar a precisão numa próxima iteração avaliando os erros entre os dados previstos e medidos (ZENG, et. al., 2017). Portanto, o objetivo do treinamento de uma rede neural artificial é minimizar uma função de erro, cujas variáveis são os pesos e as

bias, como por exemplo uma função do erro quadrático médio entre a resposta esperada e a predita (TAUD e MAS, 2018).

Para ajustar os novos valores dos pesos que interconectam os neurônios se utiliza a Equação 5, a seguir.

$$w_{n+1} = (y - \bar{y})\lambda + Mw_n \quad (5)$$


Onde w_{n+1} e w_n correspondem ao novo peso e o peso atual, respectivamente; $\bar{y}$ e y correspondem a saída esperada e a saída predita pela rede; λ corresponde a taxa de aprendizagem da rede, que é um fator que controla a velocidade do processo de aprendizagem; e M é o *momentum*, uma constante de proporcionalidade que tem o objetivo de suavizar as oscilações dos pesos. Erb (1993) ressalta ainda sobre a taxa de aprendizagem que, se este valor é muito alto, pode ocorrer da rede nunca conseguir encontrar o mínimo global da função, bem como se o valor de λ for muito pequeno, o algoritmo pode ficar preso em um mínimo local.

Portanto o ideal é que a taxa inicie num valor mais alto e reduza gradativamente, para aumentar a chance de otimização da rede. Quando uma rede é otimizada, segundo a tolerância adotada, um conjunto de dados de teste, que são diferentes dos dados de treinamento, é utilizado para avaliar a performance da rede que, se validada, pode ser utilizada para predição de saídas baseadas em novas entradas (ERB, 1993).

4. METODOLOGIA

Este trabalho foi elaborado conforme fluxograma da Figura 8 abaixo:

Figura 8 - Fluxograma de trabalho.



Fonte: Autor (2022).

A proposta gerou um modelo físico de reservatório baseando-se em um cilindro poroso em escala reduzida, seguindo-se para a geração de redes neurais artificiais *feed-forward* que permitiu a realização de previsões de fator de recuperação de óleo, reduzindo o custo computacional de uma simulação computacional fluidodinâmica.

4.1. SIMULAÇÕES FLUIDODINÂMICAS

4.1.1. GERAÇÃO DE GEOMETRIA E MALHA NUMÉRICA


O Software da ANSYS® ICEM CFD 13.0 é utilizado neste trabalho para geração da geometria e da malha, construída a partir da criação de pontos, que conectam linhas e geram uma superfície. A geometria consiste em um cilindro vertical, no qual a entrada de fluidos se dá na parte superior e a saída na parte inferior, com 20 mm de diâmetro e 7 cm de altura,

preenchido por um meio poroso (através do pré-processamento no aplicativo ANSYS® CFX 13.0), por onde escoam o fluido injetado e o óleo a ser produzido.

A seleção deste modelo físico se dá por representar a estrutura de um reservatório para a avaliação em pequena escala da atuação de fluidos (água, óleo e nanofluido de CaCO_3) em meios porosos frente ao efeito da capacidade de recuperação de óleo da água e dos nanofluidos. Além do mais, esta configuração facilita uma posterior validação via estudos experimentais, pois o escoamento ocorre com ação gravitacional, gerando um escoamento descendente.

A partir da criação de dois pontos que determinam a altura do cilindro e seu eixo central, é possível, através da função de *Standard Shapes* do ANSYS® ICEM CFD 13.0, selecionar a opção *Cylinder*, para geração da superfície cilíndrica com as bases, inferior e superior, seladas e com as medidas especificadas anteriormente. Em seguida, foi realizada a blocagem da superfície criada, para a geração de uma malha estruturada que contém 90230 nós e 86940 elementos hexaédricos. A Figura 9 exhibe o cilindro poroso, exibindo seus elementos em forma de malha estruturada.

Figura 9 - Pré-malha do cilindro poroso.



Fonte: Autor (2022).

4.1.2. MODELO NUMÉRICO

O modelo de escoamento multifásico de partícula dispersa é aplicado para o nanofluido e o modelo de escoamento multifásico de fluido contínuo é aplicado para água e óleo, devido ao fato de existirem dois fluidos atuando no volume de controle (água ou nanofluido de CaCO_3 e óleo). As equações de conservação de massa, momento e energia são resolvidas para todo o volume, em estado transiente, e este modelo de partícula é adotado para a modelagem do nanofluido, que consiste em partículas que compõem uma mistura ideal de água e nanopartícula de CaCO_3 , permitindo que as fases do nanofluido possam interpenetrar, aprimorando a simulação (GHARIBSHAHI, JAFARI e AHMADI, 2019; EJEH et. al., 2020; MINAKOV et. al., 2021).

Equação de conservação de massa

$$\frac{\partial}{\partial t}(\gamma\rho) + \left[\frac{\partial}{\partial x}(U_x\rho) + \frac{\partial}{\partial y}(U_y\rho) + \frac{\partial}{\partial z}(U_z\rho) \right] = 0 \quad (6)$$

Na equação de conservação de massa, γ é a porosidade absoluta do meio poroso, ρ é a massa específica e U_x , U_y e U_z correspondem as componentes do vetor velocidade nas direções x, y e z. O termo transiente corresponde ao acúmulo de massa presente no volume poroso, enquanto o segundo termo diz respeito ao transporte desta massa presente no meio poroso.

Equação de Energia

$$\frac{\partial}{\partial t}(\rho H \gamma) + \nabla(\rho K \cdot U \cdot H) - \nabla(\Gamma_e K \cdot \nabla H) = \gamma S^H \quad (7)$$

O termo H corresponde a entalpia específica do fluido, o termo K é um tensor de porosidade de área, Γ_e é o termo de difusividade térmica e S é o termo de fonte de calor.

Nesta equação de transporte de energia, o termo transiente refere-se como o acúmulo de energia dos fluidos, o segundo termo refere-se ao termo advectivo e transfere calor através do movimento do fluido, o terceiro é o termo difusivo, referente ao transporte de calor por convecção e o membro à direita da equação é o responsável pela geração ou destruição de energia, caso não seja nulo, dentro do volume de controle em análise. Em simulações isotérmicas todos os termos são nulos (OLIVEIRA, 2005).

Equação de quantidade de movimento

$$\frac{\partial}{\partial t}(\rho U \gamma) + \nabla(\rho(K \cdot U) \times U) - \nabla(\mu_e K \cdot (\nabla U + (\nabla U)^T)) = -\gamma R U - \gamma \cdot \nabla p \quad (8)$$

Onde μ_e é a viscosidade efetiva do fluido e R é um tensor positivo de segunda ordem, capaz de representar a resistência ao fluxo no meio poroso e capta suas anisotropias.

À esquerda da Equação 8, o primeiro termo refere-se ao acúmulo de momento nos poros, o segundo termo é o advectivo e o terceiro termo é o termo difusivo, referente a transferência de massa entre as fases. Considerando que a transferência de massa entre as fases é desprezível, no problema que foi analisado neste trabalho, então este termo pode ser cancelado. À direita, são os termos fonte de momento e, de forma semelhante a equação de energia, representa a geração de momento, que é transferido para as partes sólidas. (OLIVEIRA, 2005)

Propriedades do sistema e condições de fronteira

Objetivando a padronização das condições sob as quais ocorre o fluxo de fluidos no meio poroso, foi selecionada as mesmas condições de fronteira em todos os casos simulados, assim como as propriedades permoporosas. A Tabela 1 apresenta tais propriedades.

Tabela 1 - Propriedades e características do meio poroso e do óleo a ser recuperado pela ação de fluidos injetados.

Propriedades	Características
Tipo de domínio	Poroso
Porosidade	35%
Permeabilidade	5,28E-11 m ² (WU, 2004)
Densidade do óleo	921,824 kg/m ³
Viscosidade do óleo	50 cp
Transferência de Calor	Isotérmico

Fonte: Autor (2022).

A porosidade de 35% foi estimada com base em um meio bastante poroso, com grãos não consolidados. Devido a dificuldade de se medir o parâmetro de permeabilidade de um meio poroso inconsolidado, foi utilizado um ajuste logarítmico do trabalho de Wu (2004), pois apresenta um range alto de porosidade das amostras utilizadas que permitem, ao seu ajuste, uma boa aproximação. A equação 9 exibe esta regressão cuja permeabilidade (γ) é medida em mD e ϕ_e é a porosidade efetiva.

$$\ln \gamma = 21,42 + 11,425 \ln \phi_e + 1,327 (\ln \phi_e)^2 \quad (9)$$

Com essa padronização para as simulações realizadas, as respostas obtidas a partir da variação das características dos fluidos injetados têm como resultado advindo apenas das propriedades desses fluidos. Além disso, tais propriedades permitem a reprodutibilidade em laboratório deste experimento simulado. Para garantir uma resposta de simulação condizente com a realidade é necessário que as condições de contorno e iniciais sejam selecionadas de acordo com um experimento em laboratório. A tabela 2 indica os parâmetros utilizados para padronizar a forma com que os fluidos são injetados no meio poroso, os limites dentro dos quais os fluidos podem se movimentar e o local de saída destes fluidos.

Tabela 2 - Condições de contorno do modelo utilizado.

Condição de contorno	Característica
Velocidade de entrada de fluido	Ajuste polinomial. Equação 7.
Condição de parede	Sem deslizamento
Saída de fluidos	<i>Opening</i> , pressão atmosférica


Fonte: Autor (2022).

A velocidade de entrada de fluido foi mensurada através de teste em laboratório em uma coluna graduada, que continha uma porção de areia de aproximadamente 22 mL que preenche a parte inferior da coluna com uma altura de 7 cm saturada com óleo e, acima do meio poroso, foi inserido 80 mL de nanofluido de CaCO_3 0,05 wt%, produzido no Laboratório de Eletroquímica Aplicada da Universidade Federal de Alagoas, que gerou uma coluna de 25,4 cm

de altura onde foram coletados o deslocamento de fluido, através da graduação em centímetros da coluna de acrílico, e o tempo necessário para o suceder este deslocamento.

As imagens à esquerda e centro da Figura 10 mostram o aparato experimental para esta medição. A imagem à direita da Figura 10 apresenta a porção da coluna do meio poroso que foi considerada para a confecção da malha numérica.


Figura 10 - Aparato experimental para medição de velocidade de entrada de fluido e malha numérica.



Fonte: Autor (2020).

A partir desses dados foi traçado o gráfico da Figura 11 que permitiu a geração da regressão polinomial do 2º grau cujo R^2 é 0,8412 e mede a velocidade com a qual o fluido injetado adentra o meio poroso em função do tempo. Em azul, os dados coletados experimentalmente e em laranja, a velocidade calculada por meio de regressão linear. O tempo total do experimento medido foi de aproximadamente 15 min, logo o tempo total de simulação adotado para as recuperações secundária e avançada é de 15 min. O *timestep* adotado para esta simulação foi de 0,5 s, e foi adotado com base no número de Courant, cujo valor máximo se manteve próximo a 1.

Figura 11 - Gráfico do comportamento da velocidade de injeção de fluido no meio poroso.



Fonte: Autor (2022).

O ajuste polinomial obtido pelo ensaio experimental é descrito na Equação 10 a seguir.

$$v(t) = -0,000000118t^2 + 0,000139t - 0,0042 \quad (10)$$

Onde t é o tempo em segundos e $v(t)$ é a velocidade em cm/s em função do tempo.

A opção de *Opening*, ou abertura, foi selecionada a fim de que não fosse imposto nenhuma condição restritiva de saída. Dessa forma o software fica responsável por determinar a vazão de saída, sob atuação da gravidade ($9,81 \text{ m/s}^2$) e a pressão na saída dos fluidos foi tomada como a atmosférica, 101.325 Pa .

Como condição inicial do modelo, foi imposto que todos os fluidos estão em completo repouso quando $t = 0 \text{ s}$. No mesmo período, não há qualquer outro fluido se não o óleo com as características citadas na tabela 1 saturando completamente o volume poroso do cilindro. Na entrada do cilindro, a água, para simulação da recuperação secundária, ou o nanofluido de CaCO_3 , para a simulação de recuperação avançada, são os únicos fluidos injetados com velocidade variável obedecendo a Equação 10.

4.1.3. ESTUDOS DE CASOS SIMULADOS EM CFD

Para avaliar a eficiência da CEOR de injeção de nanofluido de CaCO_3 , foram realizadas simulações com diferentes concentrações de nanopartículas de 0,05 wt%, 1 wt% e 1,5 wt%, com NP com o mesmo diâmetro de 50 nm, conforme a Tabela 3, seguindo a metodologia utilizada por Ejeh et. al. (2020) e comparar esses resultados com a injeção de água, sob as mesmas características e condições do meio poroso exibidos nas Tabelas 1 e 2.

Tabela 3 - Diâmetro fixo e concentração variável de nanopartículas.

Diâmetro da nanopartícula	Concentração do nanofluido
50 nm	0,05 wt% de CaCO_3
	1 wt% de CaCO_3
	1,5 wt% de CaCO_3

Fonte: Autor (2022).

Em seguida, foram realizadas variações nos diâmetros das nanopartículas de 5 nm, 50 nm e 100 nm, com uma mesma concentração de 1 wt%, conforme Tabela 4, mantendo constante as propriedades e características apresentados nas Tabelas 1 e 2, a fim de compreender como esse parâmetro influencia no mecanismo de ação e eficiência de deslocamento de óleo no meio poroso.

Tabela 4 - Diâmetro variável e concentração fixa de nanopartículas.

Diâmetro da nanopartícula	Concentração do nanofluido
5 nm	1 wt% de CaCO_3
50 nm	
100 nm	

Fonte: Autor (2022).

4.2. SIMULAÇÕES EM REDES NEURAIS

4.2.1. TIPO DE REDE APLICADA

Neste trabalho, é utilizada a rede neural do tipo *Multilayer Perceptron*, assim como é visto nos trabalhos de Babakhani et. al. (2017), Wang et. al (2020), que uma rede neural que apresenta uma camada de entrada, uma camada oculta e uma camada de saída de arquitetura *feed-forward* é a mais comumente utilizada por ser suficiente em suas aplicações. Para o processo de calibração/treinamento da RNA, é adotado o algoritmo de *backpropagation* e a performance da rede foi avaliada por meio do erro quadrático médio.

4.2.2. PARÂMETROS DE REDE

De acordo com Hanspal et. al. (2013), A camada de entrada apresenta o mesmo número de *inputs* responsáveis pelo fenômeno, e a escolha desses parâmetros auxiliará na compreensão de quais destes influenciam mais no fator de recuperação associado ao método e a vazão de produção (*outputs*). O número de neurônios pertencentes à camada oculta é determinado após investigação de qual tipo de rede apresenta maior coeficiente de correlação linear. Em geral, quão mais complexo é o problema, mais neurônios na camada oculta se fazem necessários (BEZERRA, 2005).

Foram realizados diversos testes a fim de se obter uma rede de alta acurácia e a menor complexidade possível, variando apenas a quantidade de camadas ocultas e a quantidade de neurônios nela contidos. Neste trabalho foi utilizada uma arquitetura semelhante a Figura 7, com 6 neurônios na camada de entrada, e apenas 1 neurônio de saída, cuja saída representa o fator de recuperação predito pela RNA. Para a construção da rede, foi utilizada a biblioteca Scikit-learn (PEDREGOSA, et. al., 2011), uma biblioteca Python que contém as ferramentas principais para se construir uma rede neural artificial MLP. Os parâmetros adotados estão listados na Tabela 5.

Tabela 5 - Parâmetros da rede neural.

Parâmetro	Configuração
<i>Solver</i>	SGD - <i>Stochastic Gradient Descent</i>
Função de ativação	Tangente hiperbólica
Máximo de iterações	10000
Taxa de Aprendizagem	0,001
Tolerância	0,0001

Fonte: Autor (2022).

4.2.3. ESTUDOS DE CASO SIMULADOS PARA REDES NEURAIAS

Para o processo de treinamento da rede do tipo *feed-forward* são utilizados 70% dos dados e para teste e validação 30%, de acordo com a metodologia apresentada por Gomaa et. al. (2021). Os dados são obtidos da simulação em CFD do meio poroso, modificando suas propriedades dentro do range de valores indicados na Tabela 6, onde cada simulação foi realizada com timestep de 1,5 s, objetivando uma aceleração do processamento do simulador. O número de Courant manteve-se controlado, atingindo valores máximos próximos de 5, indicando boa qualidade de simulação.

Tabela 6 - Limites inferior e superior das propriedades permoporosas, das características do óleo a ser recuperado e do fluido a ser injetado.

Propriedade	Min	Max	Unidade de medida
Porosidade	4%	34%	
Permeabilidade	1,98e-16	4,12e-11	m ²
Densidade do óleo	802	997	kg/m ³
Viscosidade do óleo	29	1972	cp
Concentração de NP	0%	2%	
Diâmetro de NP	8	97	nm

Fonte: Autor (2022).

A planilha foi gerada aleatoriamente, por meio de algoritmo em Python 3.6, com limite de valores, onde os valores de densidade variam de acordo com os limites de °API. A aleatoriedade controlada dos dados evita que a rede neural fique limitada a um padrão. Dessa forma, a rede consegue ser mais generalista e abrange uma gama de valores precisos muito maior. A concentração de nanopartículas varia de 0 a 2%, onde a concentração de 0% indica que o fluido injetado é água, simulando uma recuperação secundária.

5. RESULTADOS E DISCUSSÕES

5.1 ANÁLISE EM CFD DOS MÉTODOS DE RECUPERAÇÃO DE ÓLEO

Os estudos de caso foram simulados conforme indicado na Seção 4.1.3. e foram capturados os instantes de 300, 600 e 900 s do experimento para a simulação da injeção de fluidos água e nanofluido de CaCO_3 . Objetivando um estudo aprofundado do potencial dos nanofluidos, foi adotado inicialmente três diferentes concentrações de nanopartículas de CaCO_3 de 1,5 wt%, 1 wt% e 0,05 wt%, com um mesmo tamanho de partícula de 50nm, conforme a Tabela 3, e sob as mesmas condições permoporosas do meio, com porosidade de 35%, saturado com óleo, em concordância com a Tabela 1. A Figura 12 a seguir, demonstra qualitativamente o efeito de tais fluidos no meio poroso e seus respectivos desempenhos ao recuperar o óleo presente.


É possível observar que o método de menor eficiência é o de injeção de água pura no sistema e, à medida que a concentração de nanofluidos aumenta, a fração volumétrica de óleo no meio é reduzida. Ademais, na simulação de água vê-se na Figura 12 b) e c) que uma porção de óleo se mantém aderida às paredes do cilindro, indicando a tomada de caminhos preferenciais pela água no meio poroso devido a sua baixa viscosidade que influencia a razão de mobilidade e acaba por reduzir sua eficiência em deslocar óleo, diferentemente do que ocorre com os nanofluidos de CaCO_3 .

Com o aumento da concentração de nanopartículas presentes promove o ajuste da razão de mobilidade e, sob a condição de um mesmo tamanho de partícula, têm-se como resultado o aumento da área superficial específica de contato do nanofluido. Dessa forma, o nanofluido com mais partículas consegue ter uma melhor interação com o óleo e uma maior eficiência de varrido no meio poroso é obtida nesse processo. Este resultado é semelhante a resposta alcançada por Minakov, et. al. (2021), ao realizar a simulação de um reservatório tridimensional.


Em termos quantitativos, a recuperação de óleo proveniente dos nanofluidos de CaCO_3 com 1,5wt%, 1wt%, 0,05wt% e da água são exibidos no gráfico da Figura 13. Os resultados observados alcançaram resposta semelhante ao trabalho de Mohd, et. al. (2016), que também obteve aumento no fator de recuperação proporcional ao aumento da concentração do nanofluido.

Figura 12 - Comparativo qualitativo da eficiência de deslocamento de óleo entre o método de recuperação secundária e o método de nanofluido de CaCO_3 sob diferentes concentrações.


a) Tempo 300 s



b) Tempo 600 s




c) Tempo 900 s



Fonte: Autor (2022).

Figura 13 - Gráfico comparativo dos métodos de recuperação de óleo.




Fonte: Autor (2022).

A Figura 14 exibe o comportamento da velocidade dos fluidos água e nanofluido de CaCO_3 através de vetores ao longo do meio poroso, em 300, 600 e 900 segundos de simulação. Por meio desta figura, é possível compreender a forma como a concentração de nanofluidos influencia na melhor eficiência de varredura. Com maior concentração de nanopartículas, o nanofluido de 1,5 wt% mantém sua velocidade mais baixa ao longo de todo o experimento, quando comparado com as demais simulações, demonstrando um comportamento mais viscoso que os demais, refletindo na razão de mobilidade.


A Figura 15 mostra o comportamento inicial das nanopartículas durante a injeção de nanofluido de CaCO_3 com concentração de 1 wt%, onde são mostrados os tempos de 5, 10, 20 e 300 segundos da simulação. Sendo assim, um outro fator que influencia no fato da recuperação avançada superar a recuperação secundária é o modo como atuam as nanopartículas, que tendem a se acumular nas extremidades do meio poroso e vêm varrendo óleo das extremidades para o eixo, reduzindo um possível efeito de fingers da água.

Figura 14 - Comparativo qualitativo da velocidade de escoamento da água e dos nanofluidos.


a) Tempo 300 s



b) Tempo 600 s




c) Tempo 900 s



Fonte: Autor (2022).

Figura 15 - Comportamento das nanopartículas no meio poroso.


Concentração do nanofluido: 1wt%



Fonte: Autor (2022).

Para compreender o papel do tamanho da nanopartícula para o escoamento de óleo, foi adotada a estratégia de se manter fixada uma mesma concentração de nanofluido (1 wt%) e variar o diâmetro da nanopartícula, conforme exibido na Tabela 4, com diâmetros de 5, 50 e 100 nm. As propriedades permoporosas, característica do óleo e condições de contorno permanecem as mesmas das simulações anteriores e estão disponíveis nas Tabelas 1 e 2. O gráfico presente na Figura 16 exibe o fator de recuperação obtido por meio desses nanofluidos com diferentes tamanhos de nanopartículas.

Figura 16 - Gráfico de barras do fator de recuperação de nanofluidos de mesma concentração com diferentes tamanhos de nanopartículas.



Fonte: Autor (2022).

É possível observar através destes resultados que há um incremento do fator de recuperação de óleo com a diminuição do tamanho de nanopartícula. A tendência é o fator de recuperação não ter uma taxa de crescimento tão expressiva com um diâmetro inferior a 5nm. Outro ponto a ser levado em consideração é que este resultado evidencia o papel da maior área específica de contato na eficiência de varrido, em relação a diminuição do diâmetro das NPs. Quando o diâmetro da nanopartícula reduz, sob a condição de uma mesma concentração de nanopartículas, têm-se o aumento da quantidade de partículas presentes no nanofluido, aumentando a sua dispersão no meio poroso, permitindo que mais óleo possa ser produzido.

5.3 RESULTADOS DA EFICIÊNCIA DAS REDES NEURAIS

Utilizando os parâmetros informados na seção 4.2.2 e com dados indicados na Tabela 6 da seção 4.2.3, realizaram-se diferentes testes com a RNA MLP acerca da melhor configuração da rede, em termos de quantidade de neurônios na camada oculta. A Tabela 7 a seguir, demonstra os resultados dos diferentes testes realizados com os 56 dados dos estudos de caso simulados. A forma da RNA é lida como o primeiro número sendo o número de neurônios da camada de entrada; o último valor é a quantidade de neurônios de saída da última camada e o valor presente no meio destes é a quantidade de neurônios presentes na camada oculta. Havendo dois ou mais números nesse intermédio, significa que a quantidade de números presentes é o número de camadas e cada número é o número de neurônios de sua respectiva camada.


Tabela 7 - Forma de RNA e acurácia das suas formas.

Forma da RNA	Erro quadrático médio	R²
6-4-1	0,4209	0,8228
6-6-1	0,4689	0,7801
6-8-1	0,5611	0,6852
6-10-1	0,3362	0,8870
6-4-4-1	0,4588	0,7895
6-6-6-1	0,5918	0,6497
6-8-8-1	0,5601	0,6863
6-10-10-1	0,4484	0,7989
6-11-1-1	0,4052	0,8358
6-11-4-1	0,3519	0,8762

Fonte: Autor (2022).

Notou-se que o melhor resultado em termos de precisão na predição de valores pela rede neural é a de forma 6-10-1, com 6 neurônios na camada de entrada, 10 na camada oculta e 1 neurônio na camada de saída, com erro quadrático médio de 0,3362 e R^2 de 0,887. O gráfico da Figura 17 exibe o quão distante os valores preditos estão dos valores esperados, com a utilização dos 30% restantes do total de dados para realização do teste de validação da RNA.

Figura 17 - Dispersão dos dados de teste comparando os fatores de recuperação esperados e os preditos pela rede.



Fonte: Autor (2022).

Diante dos testes realizados, o R^2 não pôde ser tão mais próximo de 1 e o erro quadrático médio mais próximo de 0, devido ao fato de haverem 56 dados de simulação CFD, onde 70% desses dados foram selecionados aleatoriamente para realizar o treinamento da rede. Todavia, a RNA demonstra ser promissora, apresentando como grande vantagem o tempo bastante inferior ao de uma simulação em CFD. O código em linguagem computacional Python 3.6 está disponível no Apêndice A – Rede Neural Artificial, para consulta.

6. CONSIDERAÇÕES FINAIS

6.1 CONCLUSÕES

A partir dos resultados obtidos e discutidos, pode-se concluir que:

- a) O modelo conseguiu demonstrar que a recuperação avançada de petróleo por meio de nanofluidos aumenta o fator de recuperação de um reservatório consideravelmente, por meio das propriedades características dos nanofluidos, e em específico, através da sua peculiaridade simulada neste trabalho da sua maior área superficial específica de contato.
- b) A presença das nanopartículas agindo inicialmente pelas paredes do cilindro e posteriormente se acumulando no centro, permite uma maior eficiência de varredura em relação a injeção de água.
- c) Devido a baixa viscosidade da água e sua alta velocidade de escoamento, esta acaba por determinar uma razão de mobilidade ruim, com maior tendência a *fingers* e um encurtamento do tempo de *breakthrough*.
- d) Com relação ao tempo de processamento dos principais softwares de simulação, e entre eles o ANSYS® CFX 13.0, a utilização de uma rede neural artificial para realizar previsões mostrou-se bastante interessante, ainda que com poucos dados de simulação, apresentou resultados em poucos segundos, além de retorná-los com certa confiabilidade, com R^2 de 0,887.

6.2 PROPOSTA DE TRABALHOS FUTUROS

Diante do que foi analisado, recomenda-se o aperfeiçoamento da modelagem de nanofluidos, trazendo para a simulação comportamentos vistos nos trabalhos já citados da redução da tensão interfacial, alteração de molhabilidade e do mecanismo primário dos nanofluidos, a pressão de separação. Além disso, é interessante avaliar outros materiais de nanofluidos, que vão apresentar diferentes densidades de partícula, bem como outros fluidos base além da água. Para as redes neurais, recomenda-se a utilização de um volume maior de dados de simulação de modo a torná-la ainda mais confiável, assim como a utilização de algoritmos que reduzam a necessidade de testes com diferentes quantidades de camadas ocultas e neurônios nela presentes.

7. REFERÊNCIAS

- AHMADI, R., FARMANI, Z., OSFOURI, S., AZIN, R., Condensate blockage remediation in a gas reservoir through wettability alteration using natural CaCO_3 nanoparticles. *Colloids and Surfaces A* 579. 2019.
- AL-ANSSARI, S., BARIFCANI, A., WANG, S., MAXIM, L., IGLAUER, S., Wettability alteration of oil-wet carbonate by silica nanofluid. *Journal of Colloid and Interface Science* 461. 2016.
- AMROUCHE F., GOMARI, S., ISLAM, M., XU, D., A novel hybrid technique to enhance oil production from oil-wet carbonate reservoirs by combining a magnetic field with alumina and iron oxide nanoparticles. *Journal of Cleaner Production* 281. 2021.
- ANP – ASSOCIAÇÃO NACIONAL DO PETRÓLEO. Relatório do seminário sobre aumento do fator de recuperação no Brasil. Rio de Janeiro, 14 de junho de 2017. Disponível em <<http://www.anp.gov.br/>> Acesso em: 16 de agosto de 2021.
- ARIF, M., KUMAN, P., KUMAN, W., MOSTAFA, Z., Heat transfer analysis of radiator using different shaped nanoparticles water-based ternary hybrid nanofluid with applications: A fractional model. *Case Studies in Thermal Engineering* 31. 2022.
- AZARSHIN, S., MOGHADASI, J., ABOOSADI, Z., Surface functionalization of silica nanoparticles to improve the performance of water flooding in oil wet reservoirs. *Energy Exploration & Exploitation*. 2017.
- BABAKHANI P., BRIDGE J., DOONG, R., PHENRAT. T., Parameterization and prediction of nanoparticle transport in porous media: A reanalysis using artificial neural network. *Water Resour. Res.*, 53. 2017.
- BERA, A., VIJ, R., SHAH, S., Impact of newly implemented enhanced oil and gas recovery screening policy on current oil production and future energy supply in India. *Journal of Petroleum Science and Engineering* 207. 2021.
- BEZERRA. Redes neurais artificiais e redes complexas: Aplicações em processos químicos. Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Química, Programa de Pós-Graduação em Engenharia Química, Fortaleza. 2005.

CHAKRABORTI, S., PANIGRAHI, P., Stability of nanofluid: A review. *Applied Thermal Engineering* 174. 2020.

CHEN, G., FU, K., LIANG, Z., SEMA, T., LI, C., TONTIWACHWUTHIKUL, P., IDEM, R., The genetic algorithm based back propagation neural network for MMP prediction in CO₂-EOR process. *Fuel* 126. 2004.

CHIESA, M., MATHIESEN, V., MELHEIM, J., HALVORSEN, B., Numerical simulation of particulate flow by the Eulerian–Lagrangian and the Eulerian–Eulerian approach with application to a fluidized bed. *Computers and Chemical Engineering* 29. 2005..

DING, M., WANG, Y., LI, Z., ZHONG, D., YUAN, F., ZHU, Y., The role of IFT and emulsification in recovering heavy oil during S or SP flooding. *Journal of Industrial and Engineering Chemistry* 77. 2019.

EJEH, C., AFGAN, I., ALMANSOB, H., BRANTSON, E., FEKALA, J., ODIATOR, M., STANLEY, P., ANUMAH, P., ONYEKPEREM, C., BOAH, E., Computational fluid dynamics for ameliorating oil recovery using silicon-based nanofluids and ethanol in oil-wet reservoirs. 2020.

ESFE, M., HOSSEINIZADEH, E., MOSAFERI, M., Investigation on nanofluid flooding effect on enhancement oil recovery process in a random pore distribution incomplete cone. *International Communications in Heat and Mass Transfer* 117. 2020.

ESFE, M., ESFANDEH, S., HOSSEINIZADEH, E., Nanofluid flooding for enhanced oil recovery in a heterogeneous two-dimensional anticline geometry. *International Communications in Heat and Mass Transfer* 118. 2020.

ESFE, M., BAHIRAEI, M., HAJBARATI, H., VALADKHANI, M., A comprehensive review on convective heat transfer of nanofluids in porous media: Energy-related and thermohydraulic characteristics. *Applied Thermal Engineering* 178. 2020.

GHARIBSHAHI, R., JAFARI, A., AHMADI, H., CFD investigation of enhanced extra-heavy oil recovery usign metallic nanoparticles/steam injection in a micromodel with random pore distribution. *Journal of Petroleum Science and Engineering* 174. 2019.

GOMAA, S., EMARA, R., MAHMOUD, O., EL-HOSHOUDY, A., New correlations to calculate vertical sweep efficiency in oil reservoirs using nonlinear multiple regression and artificial neural network. *Journal of King Saud University – Engineering Sciences*. 2021.

HANSPAL, N., ALLISON, B., DEKA, L., DAS, D., Artificial neural network (ANN) modeling of dynamic effects on two-phase flow in homogenous porous media. *Journal of Hydroinformatics* 540. 2013.

JAFARI, A., HASANI, M., HOSSEINI, M., GHARIBSHAHI, R., Application of CFD technique to simulate enhanced oil recovery processes: current status and future opportunities. *Petroleum Science*. 2020.

JASAK, H., UROIĆ, T., Practical Computational Fluid Dynamics with the Finite Volume Method. In: De Lorenzis L., Düster A. (eds) *Modeling in Engineering Using Innovative Numerical Methods for Solids and Fluids*. CISM International Centre for Mechanical Sciences (Courses and Lectures), vol 599. Springer, Cham. 2020.

JING, W., FU, S., ZHANG, L., LI, A., REN, X., XU, C., GAO, Z., Pore scale experimental and numerical study of surfactant flooding for enhanced oil recovery. *Journal of Petroleum Science and Engineering* 196. 2021.

KADHUM, M., SWATSKE, D., CHEN, C., RESASCO, D., HARWELL, J., SHIAU, B., Propagation of carbon nanotube hybrids through porous media for advancing oilfield technology. *SPE International Symposium on Oilfield Chemistry*. 2015.

KAMAL, M., ADEWUNMI, A., SULTAN, A., AL-HAMAD, M., MEHMOOD, U., Recent advances in nanoparticles enhanced oil recovery: Rheology, interfacial tension, oil recovery, and wettability alteration. *Journal of Nanomaterials*. 2017.

KHORAMIAN, R., KHARRAT, R., GOLSHOKOOH, S., The development of novel nanofluid for enhanced oil recovery application. *Fuel* 311. 2022.

KUMAR, M., HOANG, V., SATIK, C., High-Mobility-Ratio-Waterflood performance prediction: Challenges and new insights. *SPE Reservoir Evaluation & Engineering*. 2008.

KURNIA, I., ZHANG, G., HAN, X., YU, J., Zwitterionic-anionic surfactant mixture for chemical enhanced oil recovery without alkali. *Fuel* 259. 2020.

LAMAS, L., BOTECHIA, V., SCHIOZER, D., ROCHA, M., DELSHAD, M., Application of polymer flooding in the revitalization of a mature heavy oil field. *Journal of Petroleum Science and Engineering* 204. 2021.

LASHARI, N., GANAT, T., Emerging applications of nanomaterials in chemical enhanced oil recovery: Progress and perspective. *Chinese Journal of Chemical Engineering* 28. 2020.

LI, K., WANG, D., JIANG, S., Review on enhanced oil recovery by nanofluids. *Oil & Gas Science and Technology*. 2018.

LIU, J., WANG, S., WANG, C., ZHAO, F., LEI, S., YI, H., GUO, J., Influence of nanomaterial morphology of guar gum fracturing fluid, physical and mechanical properties. *Carbohydrate Polymers* 234. 2020.

LIU, Z., LIANG, Y., WANG, Q., GUO, Y., GAO, M., WANG, Z., LIU, W., Status and progress of worldwide EOR field applications. *Journal of Petroleum Science and Engineering* 193. 2020.

MAAGI, M., LUPYANA, S., JUN, G., Nanotechnology in the petroleum industry: Focus on the use of nanosilica in oil-well cementing applications. *Journal of Petroleum Science and Engineering* 193. 2020.

MANDAL, A., Chemical flood enhanced oil recovery: a review. *Int. J. Oil, Gas and Coal Technology*. Vol. 9. No. 3. 2015.

MAS, J. F.; PAEGELOW, M.; CAMACHO OLMEDO, M. T. LUCC modeling approaches to calibration. In: *Geomatic Approaches for Modeling Land Change Scenarios*. Springer, Cham, 2018. p. 451-455.

MARINHO, G., KNUPP, D., VASCONCELLOS, J., Uma comparação entre o método de volumes finitos e a técnica da transformada integral generalizada para a solução de uma equação de difusão bidimensional. *Revista Mundi Engenharia, Tecnologia e Gestão*. Paranaguá, PR, v.4, n.3, maio de 2019.

MEHRABIANFAR, P., BAHRAMINEJAD, H., MANSHAD, A., An introductory investigation of a polymeric surfactant from a new natural source in chemical enhanced oil recovery (CEOR). *Journal of Petroleum Science and Engineering* 198. 2021.

MINAKOV, A., GUZEI, D., PRYAZHNIKOV, M., FILIMONOV, S., VORONENKOVA, Y., 3D pore-scale modeling of nanofluids-enhanced oil recovery. *Petrol. Explor. Develop* 48. 2021.

MOHD, T., BACO, J., BAKAR, N., JAAFAR, M., Effects of particle shape and size on nanofluid properties for potential Enhanced Oil Recovery (EOR). *MATEC Web of Conferences* 6. 2016.

MOUKALLED F., MANGANI, L., DARWISH, M., The Finite Volume Method. In: The Finite Volume Method in Computational Fluid Dynamics. Fluid Mechanics and Its Applications, vol 113. Springer, Cham. 2016.

NOWROUZI, I., MANSHAD, A., MOHAMMADI, A., Effects of TiO₂, MgO, and Ghama-Al₂O₃ nano-particles in carbonated water on water-oil interfacial tension (IFT) reduction in CEOR. Journal of Molecular Liquids 292. 2019.

OLIVEIRA, L., Modelagem e simulação da recuperação secundária em reservatórios de petróleo utilizando configuração Five-Spots. Programa de pós-graduação em engenharia química. 2015.

PEDREGOSA, F., VAROQUAUX, G., GRAMFORT, A., MICHEL, V., THIRION, B., Scikit-learn: Machine Learning in Python. JMLR 12, pp. 2825-2830. 2011.

PIMENTEL, W., Aplicação de redes neurais artificiais e de quimiometria na modelagem do processo de craqueamento catalítico fluido. Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Química, Campinas. 2005.

RADWAN, A., NABAWYM, B., KASSEM, A., HUSSEIN, W., Implementation of rock typing on waterflooding process during secondary recovery in oil reservoirs: a case study, El Morgan oil field, Gulf of Suez, Egypt. Natural Resources Research, Vol. 30, No. 2. 2021.

RELLEGADLA, S., PRAJAPAT, G., AGRAWAL, A., Polymers for enhanced oil recovery: fundamentals and selection criteria. Appl Microbiol Biotechnol. 2017.

REZVANI, H., PANAHPoori, D., RIAZI, M., PARSAEI, R., TABAEI, M., CORTES, F., A novel foam formulation by Al₂O₃/SiO₂ nanoparticles for EOR applications: A mechanistic study. Journal of Molecular Liquids 304. 2020.

SAJJADIAN, M., SAJJADIAN, V., RASHIDI, A., Experimental evaluation of nanomaterials to improve drilling fluid properties of water-based muds HP/HT applications. Journal of Petroleum Science and Engineering 190. 2020.

SANTOS, E., Reaproveitamento de resíduos pesqueiros para produção de nanofluidos voltados à recuperação avançada de petróleo. Orientador: Dr. Leonardo Mendonça Tenório de Magalhães Oliveira. 2021. TCC. Engenharia de Petróleo, Centro de Tecnologia, Universidade Federal de Alagoas, Maceió. 2021.

- SHE, Y., ZHANG, C., MAHARDIKA, M., PATMONOAJI, A., HU, Y., MATSUSHITA, S., SUEKANE, T., Pore-scale study of in-situ surfactant flooding with strong oil emulsification in sandstone based on X-ray microtomography. *Journal of Industrial and Engineering Chemistry* 98. 2021.
- SILVA, A., Utilização de fluidodinâmica computacional (CFD) na simulação de vazamentos em dutos. Dissertação (mestrado) – Universidade Federal do Rio de Janeiro/COPPE/Programa de Engenharia Mecânica. Rio de Janeiro. 2016.
- SINGH, K., BARAI, D., CHAWHAN, S., BHANVASE, B., Synthesis, characterization and heat transfer study of reduced graphene oxide-Al₂O₃ nanocomposite based nanofluids: Investigation on thermal conductivity and rheology. *Materials Today Communications* 26. 2021.
- WANG, Y., ZHANG, S., MA, Z., YANG, Q., Artificial neural network model development for prediction of nonlinear flow in porous media. *Powder Technology* 373. 2020.
- WEN, T., ZHU, G., JIAO, K., LU, L., Experimental study on the thermal and flow characteristics of ZnO_water nanofluid in mini-channels integrated with GA-optimized ANN prediction and CFD simulation. *International Journal of Heat and Mass Transfer* 178. 2021.
- WU, T., Permeability prediction and drainage capillary pressure simulation in sandstone reservoirs. Dissertação de Doutorado. 2004.
- YAKASAI, F., JAAFAR, M., BANDYOPADHYAY, S., AGI, A., Current developments and future outlook in nanofluid flooding: A comprehensive review of various parameters influencing oil recovery mechanisms. *Journal of Industrial and Engineering Chemistry* 93. 2021.
- YEKEEN, N., AL-YASERI, A., IDRIS, A., KHAN, J., Comparative effect of zirconium oxide (ZrO₂) and silicon dioxide (SiO₂) nanoparticles on the adsorption properties of surfactant-rock system: Equilibrium and thermodynamic analysis. *Journal of Petroleum Science and Engineering* 205. 2021.
- ZENG, YU-RONG, ZENG, Yi, CHOI, B., WANG, L., Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network. *Energy* 127. 2017.
- ZHANG, H., NIKOLOV, A., WASAN, D., Enhanced oil recovery using nanoparticle dispersions_ Underlying mechanism and Imbibition Experiments. *Energy Fuels*. 28. 2014.

APÊNDICE A – Rede Neural Artificial

Código em Python da programação da rede neural artificial

```

from sklearn.neural_network import MLPRegressor
from sklearn.model_selection import train_test_split
import pandas as pd
import numpy as np
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import mean_squared_error

df = pd.read_excel("/content/simulations.xlsx")

x = df[['Porosity', 'Permeability', 'OilDensity', 'OilViscosity', 'NPConcen
tration', 'NPDiameter']]
y = df['RecoveryFactor']

X_train, X_test, y_train, y_test = train_test_split(x, y,
test_size=0.3, random_state=0)
y_train = np.array(y_train).reshape(-1, 1)
y_test = np.array(y_test).reshape(-1, 1)

'''Normalização'''
#Dados de entrada
scalerInput = StandardScaler()
X_train = scalerInput.fit_transform(X_train)
X_test = scalerInput.fit_transform(X_test)

# Dados de saída
scalerOutput = StandardScaler()
y_train = scalerOutput.fit_transform(y_train)
y_test = scalerOutput.fit_transform(y_test)

# Rede
mlp = MLPRegressor(hidden_layer_sizes=(10),
                    solver='sgd',
                    activation='tanh',
                    max_iter=10000,
                    random_state=1
                    )
mlp.fit(X_train, y_train.ravel())
y_pred = mlp.predict(X_test)

# Eficiencia da rede
RMSE_mlp = mean_squared_error(y_test, y_pred, squared=False)
score = mlp.score(X_test, y_test)
print(RMSE_mlp, score)

```