

**UNIVERSIDADE DO VALE DO RIO DOS SINOS
UNIDADE ACADÊMICA DE GRADUAÇÃO
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

AUGUSTO PASINI

**PREDIÇÃO DE PROPRIEDADES PERMOPOROSAS DE ROCHAS
CARBONÁTICAS UTILIZANDO REDES NEURAS CONVOLUCIONAIS**

São Leopoldo
2021

AUGUSTO PASINI

**PREDIÇÃO DE PROPRIEDADES PERMOPOROSAS DE ROCHAS
CARBONÁTICAS UTILIZANDO REDES NEURAS CONVOLUCIONAIS**

Artigo apresentado como requisito parcial para
obtenção do título de Bacharel em Ciência da
Computação, pelo Curso de Ciência da Compu-
tação da Universidade do Vale do Rio dos Sinos
(UNISINOS)

Orientador(a): Prof. Dr. Sandro José Rigo

São Leopoldo
2021

PREDIÇÃO DE PROPRIEDADES PERMOPOROSAS DE ROCHAS CARBONÁTICAS UTILIZANDO REDES NEURAS CONVOLUCIONAIS

Augusto Pasini¹

Sandro José Rigo²

Resumo: A identificação de propriedades físicas de rochas, como porosidade e permeabilidade, é muito importante para a indústria petrolífera na busca da melhor taxa de produção de petróleo, pois estas informações podem ajudar a definir a qualidade de um poço de extração. As técnicas utilizadas para identificação dessas características tendem a ser custosas, dependentes de acompanhamento por parte de especialistas e algumas podem inclusive ser destrutivas, modificando e prejudicando permanentemente as propriedades das amostras coletadas durante a perfuração do poço. Este trabalho utiliza aprendizado de máquina para propor um modelo de rede neural convolucional, sendo uma tarefa de regressão capaz de prever propriedades permoporosas das rochas diretamente a partir de imagens de forma ágil e sem depender do viés humano e de técnicas laboratoriais custosas ou destrutivas. Foram utilizadas 183 imagens de diversas amostras de rochas carbonáticas coletadas a partir da perfuração em diferentes profundidades de um único poço de um campo de petróleo localizado no pré-sal brasileiro. As 183 imagens foram então espelhadas para gerar uma maior quantidade de amostras para melhor treinamento de rede, gerando um total de 366 imagens divididas em 70% para treino, 15% para validação e 15% para teste. O modelo foi treinado em dois momentos distintos, sendo primeiramente para identificar a porosidade das rochas, e posteriormente para identificar a permeabilidade. Obteve-se um R^2 de 0,8385, MAE de 0,0132, MSE de 0,0004 e RMSE de 0,0209 para a porosidade e um R^2 de 0,9826, MAE de 0,0700, MSE de 0,0161 e RMSE de 0,1256 para a permeabilidade. Por fim, através das métricas obtidas e da comparação com trabalhos relacionados, concluiu-se que os resultados estão à par com o atual estado da arte. Além disso, é uma área de estudo promissora que, apesar dos bons resultados, ainda pode ser aprimorada com o estudo e aplicação de novas técnicas de inteligência artificial e através do uso de imagens mais complexas em três dimensões que representam de forma mais precisa a realidade.

Palavras-chave: Aprendizado de máquina. Aprendizado profundo. Redes neurais convolucionais. Porosidade. Permeabilidade. Rochas carbonáticas.

1 INTRODUÇÃO

Segundo Buryakovsky et al. (2012), as propriedades permoporosas estão entre as propriedades físicas mais importantes de serem medidas em rochas de reservatórios, em respeito ao transporte e transmissão de fluídos. São divididas em duas propriedades mais específicas: porosidade e permeabilidade. Enquanto a porosidade pode representar a capacidade de armazenamento de fluídos dos reservatórios, a permeabilidade pode representar a facilidade com que esses fluídos podem ser extraídos. Dessa forma, podem ser utilizados como indicativos da qualidade de um reservatório em relação à taxa de extração de fluídos como óleo e gás. Por isso, essas caracterís-

¹Graduando em de Ciência da Computação pela Unisinos. Email: pasini@edu.unisinos.br

²Orientador, professor da Unisinos, Doutor em Ciência da Computação pela Universidade Federal do Rio Grande do Sul (2008). Email: rigo@unisinos.br

ticas são muito importantes para a indústria para determinar a capacidade de um reservatório de armazenar fluídos internamente, além da facilidade de locomoção de fluídos pela sua superfície, sendo imperativo para que se obtenha uma taxa de produção de petróleo e gás comercialmente desejável (TEMBELY; ALSUMAITI; ALAMERI, 2020; VALENTÍN et al., 2019). A análise dessas propriedades geralmente envolve o uso de equipamentos laboratoriais custosos e potencialmente destrutivos, além de dependerem de especialistas na área para análise e manipulação correta dos equipamentos. Sendo assim, é extremamente importante identificar esses dados de forma ágil, econômica e precisa.

Em paralelo a isso, o aprendizado profundo (*Deep Learning*) é uma área de pesquisa que, apesar de já existir há muitos anos, atualmente vem ganhando um grande destaque. Quando sua ideia teórica surgiu em meados dos anos 60, a tecnologia da época não era suficiente para que fossem treinados e aplicados modelos com grandes quantidades de camadas de forma satisfatória e factível, visto que necessitam de uma quantidade de dados muito maior do que algoritmos tradicionais de aprendizado de máquina para que tenham uma acurácia superior (SCHMIDHUBER, 2015; WASON, 2018).

Apenas recentemente o aprendizado profundo recuperou sua popularidade e passou a ser aplicado de forma eficiente na solução de problemas reais. Resultados excelentes começaram a ser obtidos, como no modelo de rede neural profunda proposto por Krizhevsky, Sutskever e Hinton (2012) para classificar imagens da base de dados da *ImageNet*. Algumas das principais razões desse avanço significativo recente foram a evolução do poder computacional, da capacidade de armazenamento, da qualidade e quantidade de dados obtidos (muito devido ao *Big Data* e à Internet das Coisas), da complexidade dos algoritmos e dos estudos de conhecimento da neurociência (AREL; ROSE; KARNOWSKI, 2010; CHOLLET, 2017).

Com esse avanço da tecnologia, principalmente na captação de dados e imagens e no poder computacional, o uso de aprendizado profundo sobre dados complexos fundamentais para a geociência passou a ser possível. Diversas pesquisas e trabalhos vêm sendo feitos, aplicando técnicas de aprendizado profundo sobre imagens coletadas durante a extração de petróleo (TAHMASEBI et al., 2020).

Neste trabalho, serão apresentados experimentos com uma rede neural convolucional profunda para tratar um problema de regressão, identificando a porosidade e a permeabilidade de rochas a partir de imagens de amostras coletadas durante a perfuração de um poço de petróleo. O objetivo é utilizar da robustez das redes convolucionais ao trabalhar com dados espaciais e dos avanços na tecnologia que permitem o uso de aprendizado profundo em conjunto com dados coletados pela geociência. A partir disso, é elaborado e proposto um modelo que, devidamente treinado com um conjunto suficiente de dados, é capaz de definir a porosidade e permeabilidade do material de forma ágil e suficientemente precisa, além de outros benefícios, como a redução do custo, do tempo gasto pelos especialistas e redução do viés humano que pode acabar influenciando nos resultados obtidos em métodos tradicionais.

Destaca-se como diferencial deste trabalho em relação aos trabalhos relacionados o fato de

trabalhar com dados locais da região. O fato desses dados serem utilizados significa que a rede pode ser ajustada de forma que os resultados sejam os melhores possíveis no uso prático.

O restante do texto está organizado como segue. A seção 2 descreve a fundamentação teórica. A seção 3 apresenta os trabalhos relacionados utilizados. A seção 4 apresenta a metodologia e nas seções 5 e 6 são analisados os resultados e apresentadas as conclusões.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão apresentados os tópicos relevantes ao trabalho, assim como seus principais fundamentos obtidos a partir do estudo realizado durante sua elaboração.

2.1 Rochas carbonáticas

As rochas carbonáticas são importantes nesse estudo pois estima-se que 60% de toda a reserva de óleo mundial está presente em reservatórios carbonáticos (AKBAR et al., 2000). Inclusive, as amostras de rochas utilizadas neste trabalho são rochas carbonáticas coletadas de um reservatório carbonático.

Essas rochas são sedimentares e heterogêneas, com estruturas complexas, divididas em calcário, compostas predominantemente por calcita, e dolomitas, compostas predominantemente por cálcio e magnésio. Além dos minerais carbonáticos, também podem ser compostas por materiais orgânicos (BURYAKOVSKY et al., 2012). Essas rochas são depositadas naturalmente em ambientes marinhos ou continentais de águas claras, quentes e rasas.

São diferentes de rochas sedimentares tradicionais em diversos aspectos. A maioria das rochas carbonáticas se desenvolvem a partir de sedimentos biogênicos formados através de atividades biológicas, como na formação de recifes e acúmulo de restos de organismos no fundo do mar (AKBAR et al., 2000).

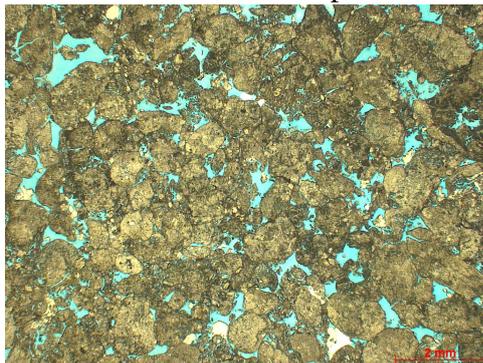
Nos carbonetos, a porosidade, permeabilidade e distribuição do espaço poroso estão relacionados tanto ao ambiente onde os sedimentos estão depositados, quanto às mudanças que ocorreram após o depósito. Diversos processos naturais ocorrem ao decorrer do tempo que podem modificar essas propriedades (BURYAKOVSKY et al., 2012).

2.2 Porosidade e permeabilidade

Nas rochas carbonáticas, a porosidade representa a proporção de espaço vazio (poros) em relação ao todo do mineral, sendo medida em forma de percentual. A porosidade é importante pois os poros podem conter óleo, gás, água ou outros fluídos de interesse para a geologia. Na escala de reservatórios, destaca-se dois tipos de porosidade mais importantes: a porosidade de matriz ou armazenamento, onde são armazenados os fluídos, e a porosidade de fissura ou fraturas, onde estão os "caminhos" por onde o fluído pode sair do reservatório (BERRYMAN;

WANG, 2000). A porosidade em rochas carbonáticas também pode ser dividida em porosidade primária - gerada durante a formação da rocha ou no final da deposição dos sedimentos, e secundária - originada por qualquer processo ocorrido após a formação da rocha ou deposição dos sedimentos (HARBAUGH, 1967). Na Figura 1 pode ser visualizada uma amostra de rocha carbonática, sendo possível distinguir o espaço poroso do material através de sua cor mais azulada.

Figura 1 – Amostra de rocha carbonática, com os poros sendo visíveis pela cor azulada



Fonte: Projeto Sapinhoá.

Já a permeabilidade diz respeito à facilidade de passagem de líquidos ou gases através do espaço poroso da rocha. É medida em Darcy (D), sendo 1 D o equivalente à 1 cm^3 de fluido com viscosidade de 1 cP (centipoise) fluindo por 1 cm^2 de uma seção cruzada de rocha em 1 segundo sob uma pressão de 1 atm/cm. Como a maioria das rochas possui uma permeabilidade média consideravelmente menor do que 1 D, geralmente a medida é feita em mD (mili-Darcy) (BURYAKOVSKY et al., 2012).

Uma forma comum utilizada para medir o desempenho de rochas carbonáticas presentes em reservatórios é através da injeção de mercúrio. Essa técnica consiste em forçar mercúrio com pressões cada vez mais altas em uma amostra da rocha. Após isso, é gerado um gráfico relacionando a quantidade de pressão e o volume de mercúrio injetado. A partir do gráfico, é possível visualizar as condições para, em ambientes reais, o óleo ser movido pela rocha (HARBAUGH, 1967). Além de ser custosa, essa técnica também pode ser destrutiva e prejudicar as propriedades da amostra permanentemente devido à quantidade de pressão necessária para os testes laboratoriais.

Importante ressaltar que uma rocha pode ser altamente porosa e com permeabilidade baixa. Isso pode acontecer caso os poros possuam poucas conexões entre si (gargantas), fazendo com que os fluidos não passem com facilidade pela rocha (BURYAKOVSKY et al., 2012).

2.3 Inteligência Artificial

A Inteligência Artificial (IA) é uma área com muitas aplicações práticas e tópicos de pesquisa ativos. Softwares inteligentes são utilizados para automatizar tarefas rotineiras, entender

falas ou imagens, fazer diagnósticos médicos e auxiliar pesquisas científicas (GOODFELLOW; BENGIO; COURVILLE, 2016).

De acordo com Chollet (2017), durante muito tempo acreditava-se que com um conjunto suficientemente grande e complexo de regras explícitas para gerenciar o conhecimento, seria possível atingir uma IA de nível humano. Apesar dessa forma de programação conseguir resolver problemas lógicos bem definidos, outros problemas mais complexos, como classificação de imagens, reconhecimento de fala e tradução de linguagens se tornam inviáveis.

Segundo Goodfellow, Bengio e Courville (2016), para que os computadores se comportem de uma maneira inteligente, não basta resolverem problemas formais compostos por uma sequência de regras. É necessário capturar o mesmo conhecimento de mundo dos seres humanos, um conhecimento subjetivo e intuitivo utilizado no dia a dia. Ironicamente, esse conhecimento que ocorre de forma natural na mente humana é um dos maiores desafios da IA.

2.4 Aprendizado de máquina

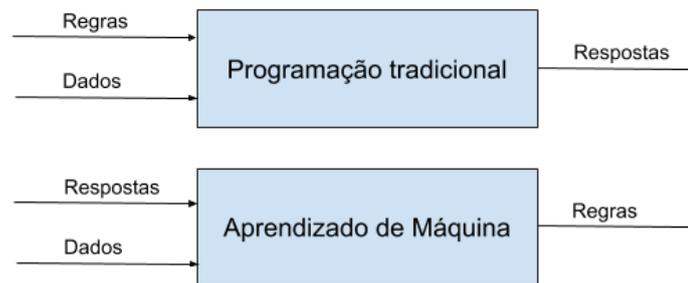
As dificuldades enfrentadas por sistemas codificados com conhecimento formal e conjuntos de regras sugerem a necessidade de que sistemas de IA tenham a capacidade de adquirir o seu próprio conhecimento, através da extração de padrões de dados brutos. Essa capacidade é conhecida como aprendizado de máquina (*Machine Learning*) (GOODFELLOW; BENGIO; COURVILLE, 2016). Mitchell (1997) definiu aprendizado de máquina da seguinte forma: "Um programa de computador é dito aprender a partir de uma experiência E em respeito a uma classe de tarefas T e métrica de desempenho P , se seu desempenho em tarefas de T , medidas por P , melhoram com a experiência E ."

No aprendizado de máquina, computadores são programados para aprender com a experiência passada. Para isso, empregam um princípio de inferência denominado indução, no qual se obtém conclusões genéricas a partir de um conjunto particular de exemplos. Assim, algoritmos de aprendizado de máquina aprendem a induzir uma função ou hipótese capaz de resolver um problema a partir de dados que representam instâncias do problema a ser resolvido (FACELI et al., 2011).

Enquanto na programação tradicional seria elaborado um conjunto de regras para que, junto de um conjunto de dados, seja realizado um processamento e seja obtida a resposta, no aprendizado de máquina o processamento é realizado a partir do conjunto de dados aliado aos resultados. A partir dessa combinação, o algoritmo é treinado calculando a hipótese que mapeia cada um dos dados de entrada para o resultado. Por esse motivo, é dito que o sistema é treinado ao invés de ser explicitamente programado (CHOLLET, 2017). A Figura 2 demonstra a diferença entre os paradigmas.

Algoritmos treinados ao invés de programados tendem a ser vantajosos em problemas complexos pois não dependem de uma grande quantidade de regras explicitamente programadas para funcionar como esperado. Outro benefício é a flexibilidade a novos exemplos. Um modelo

Figura 2 – Comparativo entre programação tradicional e aprendizado de máquina

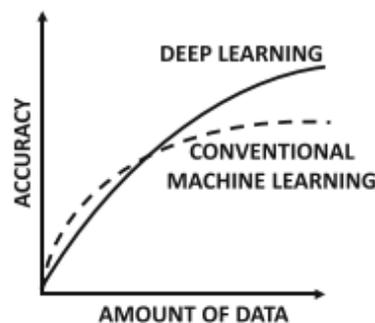


Fonte: Elaborada pelo autor com base em Chollet (2017).

com uma boa capacidade de generalização não depende de nenhuma alteração manual ou regra adicional.

Em relação ao aprendizado de máquina, o aprendizado profundo busca resolver problemas com representações complexas que um algoritmo normal de aprendizado de máquina não consegue resolver de forma eficiente. Através do aprendizado em sucessivas camadas de representações cada vez mais significativas, consegue transformar conceitos complexos numa sequência de conceitos simples (CHOLLET, 2017). A Figura 3 mostra a relação entre a acurácia e a quantidade de dados para as abordagens de aprendizado de máquina em contraste ao aprendizado profundo, evidenciando a melhoria na acurácia a medida que a quantidade de dados aumenta.

Figura 3 – Crescimento da acurácia em relação à quantidade de dados



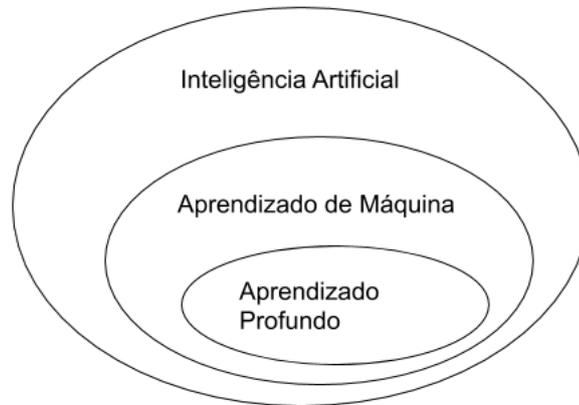
Fonte: (AGGARWAL, 2018).

Assim como o aprendizado de máquina é uma subárea da IA, o aprendizado profundo é uma subárea do aprendizado de máquina. A relação entre as três áreas de conhecimento pode ser visualizada na Figura 4.

Conforme Russell e Norvig (2013), algoritmos de aprendizado de máquina podem ser classificados de acordo com a relação entre uma determinada entrada e o *feedback* sobre essa entrada, definindo três formas principais de aprendizagem por parte de um agente inteligente:

- **Aprendizado supervisionado** - O agente observa pares de entrada e saída e aprende

Figura 4 – Relação entre Inteligência Artificial, aprendizado de máquina e aprendizado profundo



Fonte: Elaborada pelo autor com base em Chollet (2017).

uma função que mapeia a entrada para a saída. Por isso, depende dos dados já estarem rotulados com suas respectivas saídas;

- **Aprendizado não supervisionado** - O agente aprende padrões nas entradas sem qualquer *feedback* explícito. Os dados de entrada não são rotulados como no aprendizado supervisionado;
- **Aprendizado por reforço** - Processo de tomada de decisão sequencial, onde o agente aprende através de uma série de reforços, recompensas e punições recebidos ao interagir com o ambiente.

Tarefas de aprendizado de máquina também são comumente divididos de acordo com diferentes classes de problemas que serão tratados. Segundo Mohri, Rostamizadeh e Talwalkar (2018), são eles:

- **Classificação** - Dados de entrada devem ser classificados em alguma categoria numérica discreta, dentro de um conjunto finito de valores. Pode conter duas categorias (classificação binária) ou múltiplas categorias (classificação multiclasse). Exemplos: Classificação de imagens como sendo de um cachorro ou gato (binário) e classificação de imagens de caracteres escritos à mão (multiclasse);
- **Regressão** - Dados de entrada devem ser mapeados para um valor numérico contínuo. Exemplos: Predição do valor de uma ação na bolsa de valores e predição do valor de um imóvel;
- **Ranqueamento** - Ordenação de itens de acordo com algum critério. Exemplo: Determinação dos documentos e páginas *web* mais relevantes em uma pesquisa;

- **Clusterização** - Divisão de um conjunto de itens em conjuntos menores a partir de semelhanças entre si. Exemplo: Identificação de características em comum entre diferentes usuários de uma loja virtual;
- **Redução de dimensionalidade** - Transformação de uma representação inicial de um conjunto de itens para uma representação em menos dimensões sem perda de propriedades importantes. Exemplo: Pré-processamento de imagens digitais para tarefas mais complexas de aprendizado profundo.

Neste trabalho será utilizada uma abordagem de treinamento com ensino supervisionado para tratar um problema de regressão. Os dados são rotulados com a saída esperada para cada uma das entradas e os rótulos fazem parte de um conjunto contínuo de valores.

2.5 Redes neurais artificiais

Redes neurais artificiais (ANN - *Artificial Neural Networks*) foram desenvolvidas baseadas no funcionamento do cérebro humano, onde suas unidades computacionais são tratadas de forma análoga aos neurônios biológicos. São teoricamente capazes de aprender qualquer função matemática a partir do treinamento em um conjunto de dados suficiente (AGGARWAL, 2018).

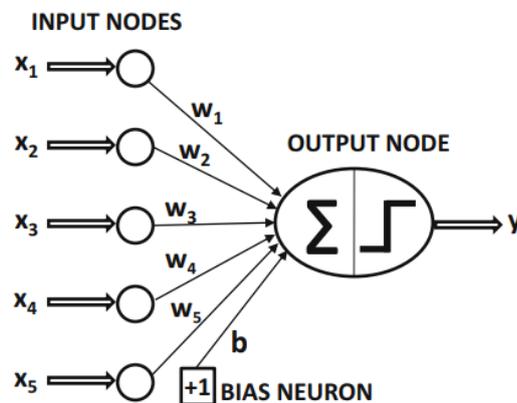
O neurônio de uma rede neural artificial aplica uma função de ativação sobre a soma de um conjunto de entradas multiplicados por um conjunto de pesos e somado a uma constante, ou viés. O resultado é propagado e passa a servir de entrada para o próximo neurônio. Esta é a forma mais simples de um neurônio artificial, sendo chamado de *Perceptron* (AGGARWAL, 2018). Na Figura 5 está sendo representado um neurônio com as entradas (x_1, x_2, x_3, x_4, x_5), os pesos (w_1, w_2, w_3, w_4, w_5), o viés (b) e a saída (y). Uma rede neural nada mais é do que um conjunto de neurônios artificiais interconectados entre si com múltiplas camadas, conforme a Figura 6. A primeira camada da rede é denominada camada de entrada (*input layer*), a última é denominada camada de saída (*output layer*) e as demais camadas intermediárias são denominadas camadas ocultas (*hidden layers*).

2.5.1 Descida de gradiente

A descida de gradiente (*gradient descent*) é um processo aplicado durante o treinamento de uma rede neural para ajustar seus pesos com o objetivo de encontrar um valor mínimo global para a função de erro. A partir do cálculo da derivada parcial do erro em relação a cada um dos pesos, é possível determinar se o peso deve aumentar ou diminuir (HEATON, 2015).

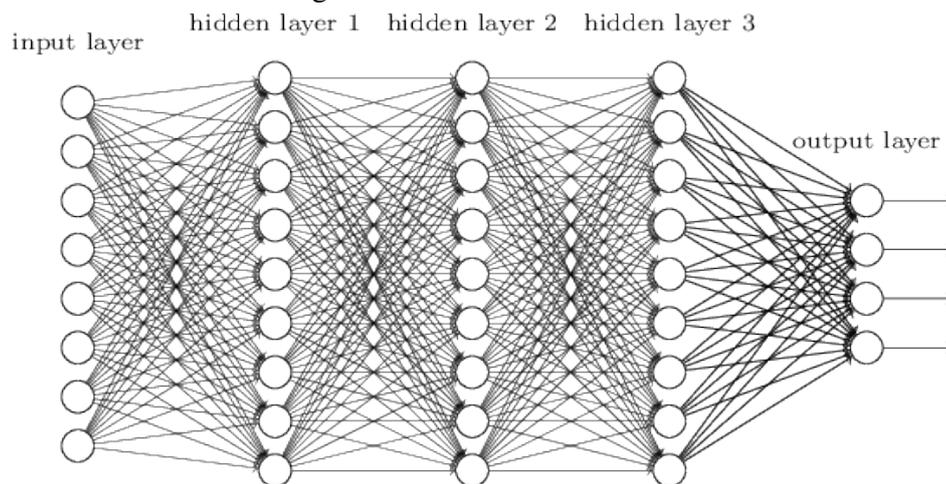
O valor de cada passo em direção ao valor mínimo é definido por uma taxa de aprendizado (*learning rate*). Esse valor deve ser definido para não ser muito baixo, o que poderia causar uma convergência muito lenta, e nem muito alto, o que poderia causar uma divergência do valor mínimo global (GÉRON, 2019).

Figura 5 – Neurônio artificial, ou *Perceptron*



Fonte: (AGGARWAL, 2018).

Figura 6 – Rede neural artificial



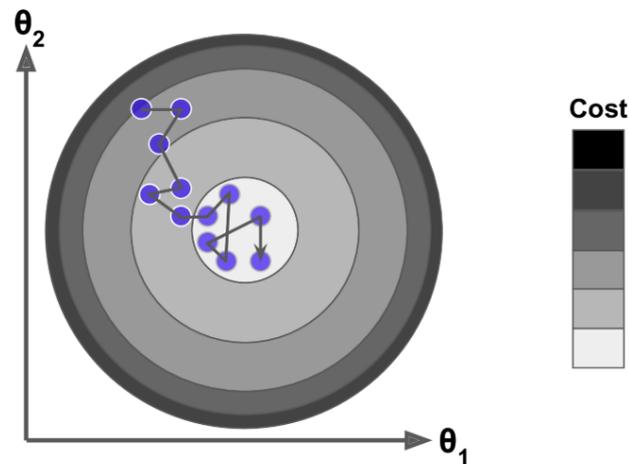
Fonte: (NIELSEN, 2015).

Nas redes neurais, costuma ser utilizada uma variação do algoritmo de descida de gradiente chamada de descida de gradiente estocástico (SGD - *Stochastic Gradient Descent*). Consiste em aplicar a descida de gradiente em pequenos conjuntos, ou lotes (*batches*), de exemplos ao invés de todo o conjunto de treinamento. Isso permite uma melhora significativa de desempenho, diminuindo o tempo de treinamento da rede (LECUN; BENGIO; HINTON, 2015). A Figura 7 demonstra o processo da descida de gradiente estocástico em busca do menor valor para uma função de erro.

Para que seja aplicada a descida de gradiente sobre todos os pesos de uma rede neural de forma retroativa, é utilizada a técnica de *Backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986). Iniciando com o valor do erro na saída, consegue trabalhar de forma reversa das camadas finais até as iniciais, atualizando os parâmetros com uma técnica chamada de *chain rule* (CHOLLET, 2017).

Dois problemas comuns relacionados à descida de gradiente em redes neurais são a explo-

Figura 7 – Descida de gradiente estocástico



Fonte: (GÉRON, 2019).

são do gradiente e a fuga do gradiente. Ocorrem quando os gradientes se tornam extremamente grandes ou pequenos a ponto de prejudicarem ou não influenciarem no treinamento da rede. Ambas causam problemas durante o treinamento, tornando-o instável e muitas vezes impossibilitando que a rede evolua durante o processo (AGGARWAL, 2018; GÉRON, 2019).

2.5.2 *Overfitting* e *underfitting*

Todos os modelos treinados com aprendizado de máquina podem sofrer do problema de *overfitting*. Isso ocorre quando o modelo começa a performar bem nos dados de treino mas performar mal com dados novos, ou seja, não consegue generalizar. Algumas formas de evitar o *overfitting* é utilizando mais dados de treino, adicionando técnicas de regularização e camadas de *dropout*. Já o *underfitting* ocorre quando o modelo não consegue performar bem nem dos dados de treino, ou seja, não consegue otimizar o treinamento. Um dos maiores desafios ao elaborar um modelo de aprendizado de máquina é encontrar o ponto ideal entre a capacidade de generalização sobre dados novos e a otimização sobre os dados de treino, evitando ao máximo tanto o *overfitting* quanto o *underfitting* (CHOLLET, 2017).

2.5.3 Funções de erro

Uma função de erro (*loss function*) determina o quão diferente está o resultado esperado do resultado obtido pela rede neural para cada amostra de treinamento. É sobre ela que é realizado o cálculo da derivada para o ajuste dos pesos durante o treinamento. Também é através dela que obtém-se muitas das métricas de avaliação do desempenho de um modelo treinado (HEATON, 2015). Por isso, a escolha de uma função de erro adequada para o problema é muito importante para que obtenha-se resultados positivos.

As funções de erro mais utilizadas para problemas de regressão são o erro quadrático médio (MSE - *Mean Squared Error*), e o erro absoluto médio (MAE - *Mean Absolute Error*). Também existe uma variação da MSE chamada de raiz do erro quadrático médio (RMSE - *Root Mean Squared Error*), onde é aplicada raiz quadrada sobre o resultado (CHAI; DRAXLER, 2014). Ambas são representadas pelas equações 1 e 2, sendo n o número de amostras, \hat{y} o valor esperado e y o valor calculado pelo modelo.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (2)$$

Enquanto a função MAE dá o mesmo peso para todos os erros, a função MSE penaliza variações muito grandes, dando maior peso para erros com valores absolutos maiores (CHAI; DRAXLER, 2014). Dessa forma, a MAE se torna mais adequada quando os erros estão distribuídos de forma uniforme, enquanto a MSE se torna mais adequada para distribuição normal com a presença de alguns *outliers* (CHAI; DRAXLER, 2014).

Como alternativa para as duas funções, também existe a função de erro de Huber demonstrada na equação 3. Essa função é um híbrido das duas anteriores, ativando o comportamento da função quadrática e da função absoluta de acordo com o parâmetro δ . É considerada uma função mais robusta, sendo menos propensa e sensível à ruído nos dados (ALQAHTANI et al., 2020; HOLLAND; WELSCH, 1977).

$$L_{\delta}(a) = \begin{cases} \frac{1}{2}a^2 & |a| \leq \delta \\ \delta(|a| - \frac{1}{2}\delta) & |a| > \delta \end{cases} \quad (3)$$

2.5.4 Funções de ativação

Funções de ativação são utilizadas em redes neurais artificiais para transformar um valor de entrada em um valor de saída que é propagado para a próxima camada. São necessárias para evitar que o sinal de saída tenha um formato linear e para que seja possível mapear e treinar o modelo com problemas mais complexos (SHARMA, 2020). Dependendo do tipo de problema que espera-se resolver, podem ser utilizadas diferentes funções de ativação. Inclusive, cada camada da rede neural pode utilizar uma função de ativação diferente.

2.5.4.1 Sigmoid

É uma função não linear que transforma o valor para um intervalo entre 0 e 1, garantindo um valor pequeno e positivo. É geralmente utilizada quando o objetivo é obter uma probabilidade de uma entrada pertencer à uma determinada categoria em classificações binárias (SHARMA, 2020).

Esse tipo de função pode causar um problema chamado de gradiente de fuga, quando o gradiente vai se tornando tão pequeno e insignificante que acaba por não atualizar os pesos, fazendo com que a rede inteira não seja treinada.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

2.5.4.2 Tangente hiperbólica (*tanh*)

Muito semelhante à função *sigmoid*, mas gerando valores no intervalo entre -1 e 1, ou seja, permitindo valores negativos (HEATON, 2015). Tem a vantagem de seu gradiente não ser restrito a variar em apenas uma direção (positiva) (SHARMA, 2020). Assim como a função *sigmoid*, tem o mesmo problema de gradiente de fuga.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

2.5.4.3 Unidade linear retificada (ReLU)

Uma das funções mais utilizadas nas redes neurais, foi proposta por Nair e Hinton (2010) e resolve o problema de gradiente de fuga. Uma de suas maiores vantagens é o fato de nem todos os neurônios serem ativados simultaneamente. O neurônio será desativado apenas quando a saída da função for zero. Por esse fato, também consegue ser mais eficiente que as demais funções (SHARMA, 2020; NWANKPA et al., 2018).

Um dos problemas dessa função é que neurônios tendem a morrer durante o treinamento, fazendo com que os pesos não sejam atualizados e prejudiquem o treinamento (NWANKPA et al., 2018).

Também existem duas variações simples da função ReLU: a ReLU Vazada (LReLU) proposta por Maas, Hannun e Ng (2013) para resolver o problema de morte dos neurônios e a ReLU Parametrizada (PReLU) proposta por He et al. (2015). A única diferença entre elas é o valor de α , que assume 0 na ReLU, 0,01 na LReLU e um valor parametrizado na PReLU.

$$ReLU(x) = \begin{cases} x & x \geq 0 \\ \alpha x & x < 0 \end{cases} \quad (6)$$

2.5.4.4 Unidade linear exponencial (ELU)

Mais uma variação da função ReLU, proposta por Clevert, Unterthiner e Hochreiter (2016). Também utiliza um valor parametrizado para a inclinação dos valores negativos de x , com a diferença de usar uma curva logarítmica (SHARMA, 2020).

$$ELU(x) = \begin{cases} x & x \geq 0 \\ \alpha(\exp(x) - 1) & x < 0 \end{cases} \quad (7)$$

2.5.4.5 Unidade linear exponencial em escala (SELU)

Variação da função ELU, foi introduzida por Klambauer et al. (2017) com propriedades auto normalizantes, visto que a média e variância convergem para zero. Essa função consegue evitar os problemas de gradiente de fuga e gradiente explosivo (NWANKPA et al., 2018).

$$SELU(x) = \lambda \begin{cases} x & x \geq 0 \\ \alpha(\exp(x) - \alpha) & x < 0 \end{cases} \quad (8)$$

Sendo $\alpha \approx 1,6733$ e $\lambda \approx 1,0507$.

2.5.4.6 *Swish*

Proposta por Ramachandran, Zoph e Le (2017), é uma combinação entre as funções *sigmoid* e ReLU. Assim como a ReLU, possui limite superior aberto e limite inferior fechado, mas contém uma curva suave e não é monotômica. Sua suavidade faz com que a função gere melhores resultados de otimização e generalização quando utilizada em redes profundas (RAMACHANDRAN; ZOPH; LE, 2017; NWANKPA et al., 2018).

De acordo com Ramachandran, Zoph e Le (2017), as principais vantagens da função *swish* são sua simplicidade e alta acurácia, visto que não sofre do problema de gradiente de fuga e mesmo assim consegue uma boa propagação de informação durante o treinamento.

$$swish(x) = x \cdot \sigma(x) = \frac{x}{1 + e^{-x}} \quad (9)$$

2.5.5 Métricas

Além das funções de erro, que também são utilizadas como métricas de desempenho, existem outras medidas frequentemente utilizadas em problemas de regressão para medir a acurácia do modelo. Essas métricas não influenciam o treinamento e são utilizadas para medir a performance do modelo. O coeficiente de determinação (R^2) é uma métrica normalmente utilizada para determinar a capacidade preditiva de algoritmos de regressão. Pode ser interpretado como o percentual de variância das variáveis dependentes que podem ser "explicadas" pelo modelo. Quanto mais perto de 1 (100%) o valor do R^2 , melhor é a capacidade preditiva do modelo sobre as variáveis dependentes (EROFEEV et al., 2019; NAGELKERKE, 1991). É definido pela equação 10, sendo \hat{y}_i os valores reais, y_i os valores previstos pelo modelo e \bar{y} a média dos valores de y :

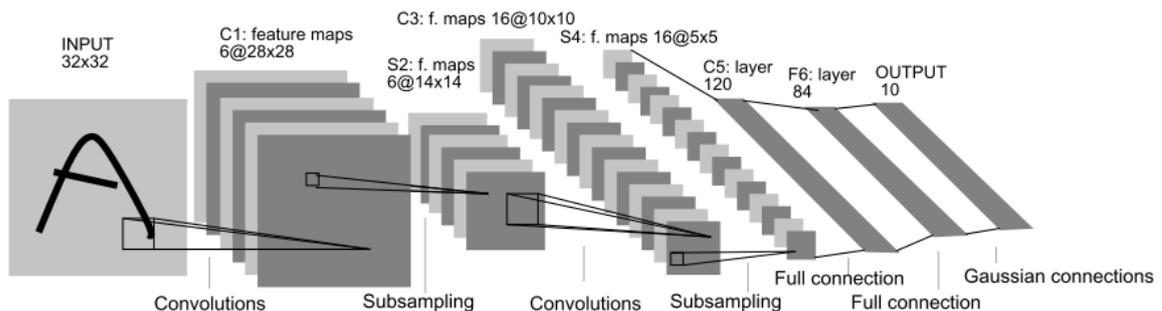
$$R^2 = 1 - \frac{\sum_i (\hat{y}_i - y_i)^2}{\sum_i (\hat{y}_i - \bar{y})^2}, \quad (10)$$

2.6 Redes neurais convolucionais

Redes neurais convolucionais (CNN - *Convolutional Neural Networks*) (LECUN et al., 1998) são projetadas para processar dados de entrada no formato de múltiplos vetores, representando uma dependência de espaço ou proximidade entre cada valor de entrada. Esses vetores podem ser de uma dimensão para dados temporais, como sinais e sequências, duas dimensões para imagens e espectrogramas de áudio, ou então três dimensões para vídeo e imagens volumétricas (LECUN; BENGIO; HINTON, 2015). Sua estrutura é muito semelhante às redes neurais artificiais, com a diferença que usam operações matemáticas de convolução ao invés de multiplicação simples de matrizes em no mínimo uma de suas camadas (GOODFELLOW; BENGIO; COURVILLE, 2016).

Além da camada de convolução, também podem contar com camadas de ativação e *pooling*. Juntas, as camadas transformam os dados de entrada, inferindo quais características são determinantes para o problema através do processo de treinamento. Para isso, também utilizam as mesmas técnicas convencionalmente utilizadas em redes neurais artificiais: descida de gradiente e *backpropagation*. A Figura 8 demonstra o modelo de rede neural convolucional proposto por LeCun et al. (1998) para classificação de dígitos escritos à mão, sendo um dos percursos desse tipo de rede.

Figura 8 – CNN proposta por LeCun et al. (1998)



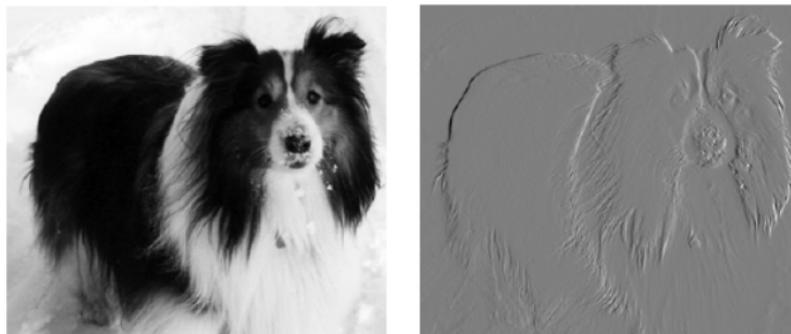
Fonte: (LECUN et al., 1998).

2.6.1 Camada de convolução

Na camada de convolução é realizada operação de convolução sobre a estrutura de entrada, realizando cálculos com estruturas multidimensionais conhecidas como filtros ou *kernels* (AGGARWAL, 2018). Esses filtros são estruturas menores do que a entrada e vão sendo aplicados sobre seções de mesmo tamanho e deslocados até que seja aplicado sobre toda a entrada.

A camada de convolução tem o objetivo de destacar, de certa forma, as características que influenciam no resultado final da rede. Na classificação de imagens de animais, por exemplo, os filtros poderiam ser ajustados para destacar características como as patas ou o rabo do animal. Os valores dos filtros são ajustados durante o processo de descida de gradiente e *backpropagation*, ou seja, a rede é capaz de identificar sozinha quais as características mais relevantes para o problema que está resolvendo. Essas características podem ser semelhantes às características que o cérebro humano identifica, ou então completamente diferentes. (AGGARWAL, 2018; HEATON, 2015). Na Figura 9, é exibida imagem de um cachorro antes e depois de aplicar a operação de convolução.

Figura 9 – Imagem de um cachorro antes e depois da convolução



Fonte: (GOODFELLOW; BENGIO; COURVILLE, 2016).

2.6.2 Camada de ativação

Na camada de ativação, muito semelhante às camadas de ativação em redes neurais tradicionais, é aplicada uma função de ativação sobre a entrada. Essa operação não afeta a dimensionalidade da entrada, sendo um mapeamento um-para-um. Em redes convolucionais, é mais comum o uso de funções de ativação abertas, como ReLU ou semelhantes (AGGARWAL, 2018).

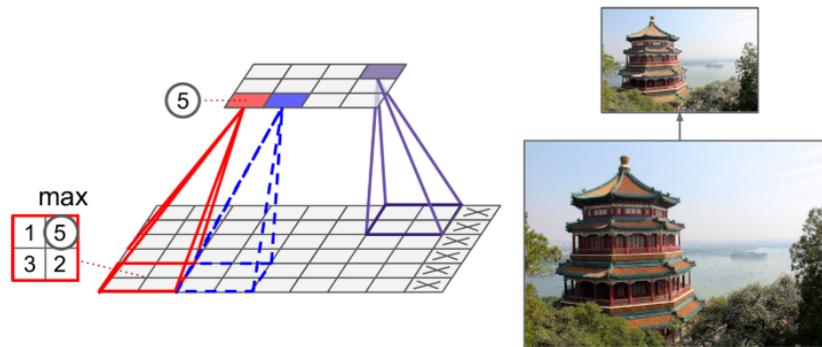
2.6.3 Camada de *pooling*

A camada de *pooling* reduz a dimensionalidade da entrada de acordo com alguma função. É semelhante à convolução por efetuar operações em frações da entrada, com a diferença que não possuem filtros, então não são afetadas durante o treinamento, e na saída geram dados reduzidos. Além de reduzir o *overfitting*, visto que descartam informações não relevantes que poderiam afetar a saída, também diminuem o tempo de treinamento pois diminuem a quantidade de dados a serem processados (AGGARWAL, 2018).

O tipo de *pooling* mais utilizado é o *max pooling*, onde para cada janela é retornado apenas

o maior valor, conforme Figura 10. Existem outros, como *average pooling*, que retornam a média de cada janela, mas não são tão utilizados como o *max pooling*. Como as camadas de convolução destacam características importantes da entrada, faz mais sentido justamente pegar o maior valor ao invés da média (CHOLLET, 2017).

Figura 10 – *Max pooling*



Fonte: (GÉRON, 2019).

2.6.4 Camada densa

Camadas densas são utilizadas no final das redes convolucionais e seu comportamento é igual à redes neurais artificiais. Após as operações espaciais da rede convolucional, é aplicado uma camada de achatamento (*flatten*) para transformar os dados multidimensionais em apenas uma dimensão, como esperado pelas camadas densas (AGGARWAL, 2018).

2.6.5 Camada de *dropout*

A camada de *dropout* (HINTON et al., 2012) é aplicada sobre outra camada densa e consiste em desativar, ou derrubar, aleatoriamente algum percentual de neurônios da camada durante o treinamento. O percentual de *dropout* geralmente fica entre 20% e 50%. Essa técnica é utilizada para reduzir o *overfitting*, visto que ajuda a rede a se adaptar à ruídos nos dados de entrada, evitando que fique "viciada" em dados "perfeitos", o que geralmente não é o caso em dados reais (CHOLLET, 2017).

3 TRABALHOS RELACIONADOS

Para embasar este trabalho e identificar aspectos do estado da arte na identificação de propriedades de rochas com uso de IA foi realizada uma pesquisa não sistemática em periódicos qualificados, com uso dos termos de pesquisa ligados à temática geral tratada. Foram utilizados termos como "porosidade", "permeabilidade", "rochas carbonáticas", "redes convolucionais", "aprendizado de máquina" e "aprendizado profundo", filtrando trabalhos tanto em português

como inglês desenvolvidos nos últimos 5 anos. A partir dos resultados da busca, foram selecionados os trabalhos de maior relevância com maior quantidade de citações.

A grande maioria dos trabalhos relacionados que identificam propriedades de rochas utilizando aprendizado de máquina, utilizam um *dataset* de imagens tridimensionais em escala de cinza, coletadas a partir da técnica de microtomografia computadorizada de raios-x. São dados diferentes dos utilizados neste trabalho, mas estes trabalhos foram mantidos para efeito comparativo.

No trabalho de Sudakov, Burnaev e Koroteev (2019), foi realizado um estudo sobre diferentes técnicas de aprendizado de máquina para prever a permeabilidade a partir das rochas digitais (imagens em 3D). Ao fim, concluíram que as redes convolucionais 3D trazem os melhores resultados com um erro médio absoluto de 3,37%, visto que conseguem identificar características complexas sem perder a dependência de espaço em todas as três dimensões. Esse trabalho acabou servindo como ponto de partida e influenciando diversos outros trabalhos com temáticas semelhantes.

Bordignon et al. (2019) utilizaram dados sintéticos (conjunto de esferas) para treino de uma rede neural convolucional 3D com o objetivo de prever as distribuições de tamanho de grão e porosidade de forma ágil. No pré-processamento das imagens, foi utilizada uma técnica de segmentação simples de *thresholding*. Em seguida, o modelo treinado foi aplicado sobre amostras reais de arenito Berea. A solução convergiu para um erro baixo, mas não foi descrito o valor exato. A principal contribuição do trabalho foi o fato de usar dados sintéticos para realizar o treinamento, evitando a necessidade de coleta e anotação de imagens.

Já no estudo de Alqahtani et al. (2020), foi treinado um modelo de rede convolucional para prever porosidade, área de superfície específica e média de tamanho dos poros. Foram utilizados dados reais de três tipos de arenito em formato 3D e convertidos para fatias em 2D. A média final de erro obtida foi consideravelmente baixa, com *Hubber loss* de 2,8%, MSE de 4,5% e MAE de 5,4%. O R^2 obtido foi de 0,96 para porosidade, 0,92 para área de superfície específica e 0,71 para média de tamanho de poros. Os bons resultados demonstraram o potencial de uso de redes convolucionais sobre esse tipo de tarefa. Uma limitação desse trabalho é que dependeu da aplicação de técnicas de segmentação em seu processo para que fossem obtidos bons resultados. Além disso, também não foi realizada a predição da permeabilidade, sendo indicado como trabalho futuro.

Tembely e AlSumaiti (2019) usaram uma combinação de técnicas numéricas tradicionais com técnicas de aprendizado de máquina para prever a permeabilidade a partir de milhares de imagens em 3D. Obtiveram o melhor resultado através de uma rede neural profunda com um R^2 de 0,9156, mas não conseguiram bons resultados ao utilizar redes neurais convolucionais, tanto diretamente a partir das imagens como também utilizando propriedades físicas das rochas. Por fim, ressalta a agilidade de predição da rede em comparação a modelos tradicionais de identificação da permeabilidade de rochas.

Wu, Yin e Xiao (2018) propuseram um modelo de rede neural convolucional para prever a

permeabilidade das rochas. Utilizaram um *dataset* de imagens 2D geradas artificialmente em conjunto com dados físicos de rochas e, assim como Bordignon et al. (2019), aplicaram o modelo sobre imagens reais. Foi obtido um R^2 de 0,926315 e MSE de 0,000470. O principal foco do trabalho, de acordo com os autores, é servir como prova de conceito para adoção de técnicas de reconhecimento de imagens a partir de redes convolucionais na predição da permeabilidade de rochas reais, se provando efetivo nesse aspecto.

Enquanto isso, Araya-Polo et al. (2018) buscaram prever a permeabilidade com uma rede convolucional e imagens em 2D coletadas a partir de Microscopia Eletrônica de Varredura (SEM), uma outra técnica de coleta de imagens que produz imagens em maiores resoluções se comparado à microtomografia de raios-x, sendo obtido um erro médio de 11,69% (MSE) e um R^2 de 0,7967 sobre os dados de teste. É destacado a falta de uma arquitetura completa que utiliza imagens coletadas com essa tecnologia.

De forma geral, observa-se uma tendência ao uso de arquiteturas convolucionais, a partir e seus bons resultados e adequação às necessidades de tratamento dos dados de rochas. Também é perceptível o crescimento e potencial de uso dessas redes para tarefas de regressão, algo que não é tão comum em relação à tarefas de classificação e está trazendo bons resultados. Além disso, o fato das redes convolucionais conseguirem identificar propriedades de forma prática e rápida relacionam muito bem com as necessidades atuais de geologia em busca da melhor identificação de rochas. Apesar deste trabalho ser focado na aplicação dessa arquitetura em rochas carbonáticas, encontradas principalmente em poços de petróleo, seu uso pode ser facilmente estendido para contemplar diferentes casos de uso, conforme a necessidade da área.

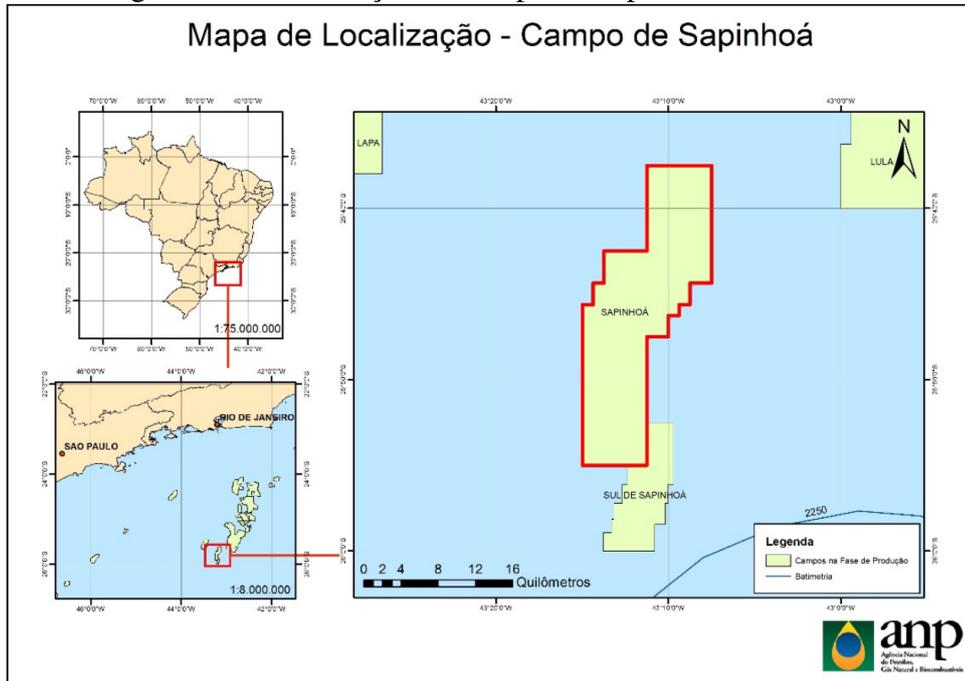
4 MATERIAIS E MÉTODOS

A proposta deste trabalho consiste realizar experimentos com uma rede neural convolucional bidimensional, capaz de identificar a porosidade e a permeabilidade de rochas a partir de imagens. Nas próximas seções será descrito em mais detalhe o *dataset* utilizado para treino e validação, a estrutura da rede elaborada e todas as etapas de pré processamento realizadas.

4.1 Dataset

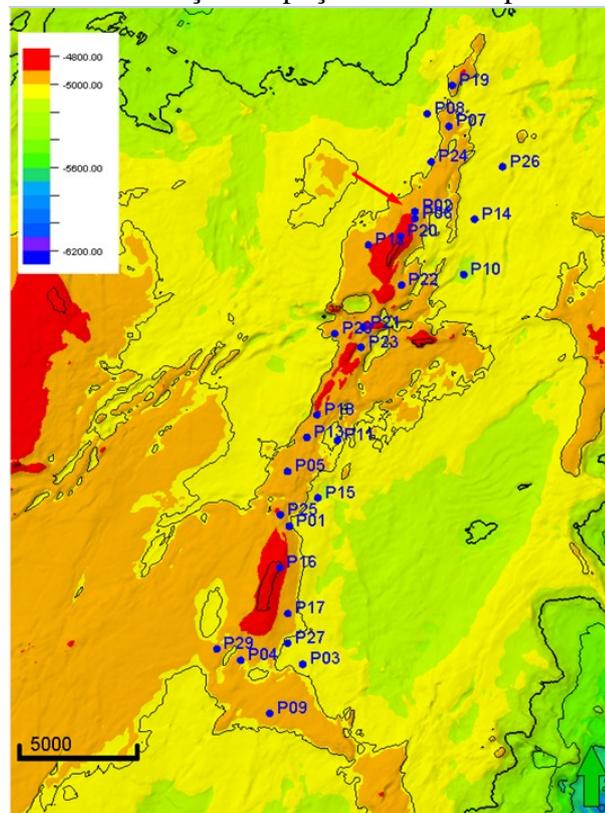
O *dataset* consiste em imagens de lâminas petrográficas obtidas a partir de amostras de rochas coletadas em diferentes profundidades durante a perfuração do poço P02 do campo de Sapinhoá da Petrobras, localizado no pré-sal brasileiro. Conforme pode ser visualizado na Figura 11, o campo de Sapinhoá possui uma área total de 233 km^2 , sendo localizado na porção central da Bacia de Santos a aproximadamente 360 km de distância da costa do estado de São Paulo e 290 km de distância da cidade do Rio de Janeiro (ANP, 2017). A localização do poço P02 dentro do campo de Sapinhoá, assim como sua profundidade, pode ser visualizado na Figura 12.

Figura 11 – Localização do campo de Sapinhoá da Petrobrás



Fonte: (ANP, 2017)

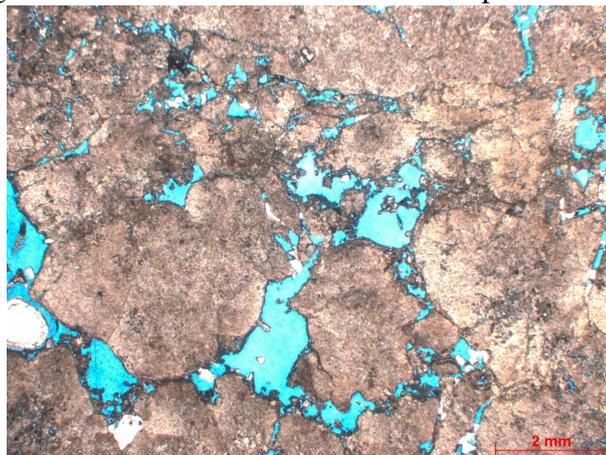
Figura 12 – Localização do poço P02 no campo de Sapinhoá



Fonte: Projeto Sapinhoá.

As amostras de rochas coletadas durante a perfuração do poço foram então cortadas em formato de lâmina e posteriormente fotografadas à luz natural com equipamentos especiais. As lâminas foram providenciadas pela Petrobras, enquanto que o trabalho de análise e fotografia das amostras foi realizado pelo grupo de pesquisa do projeto Sapinhoá. Na Figura 13 pode ser observada uma dessas lâminas, onde os poros podem ser distinguidos dos minerais através de suas cores mais azuladas.

Figura 13 – Imagem de amostra de rocha coletada em profundidade de 4987,05 m



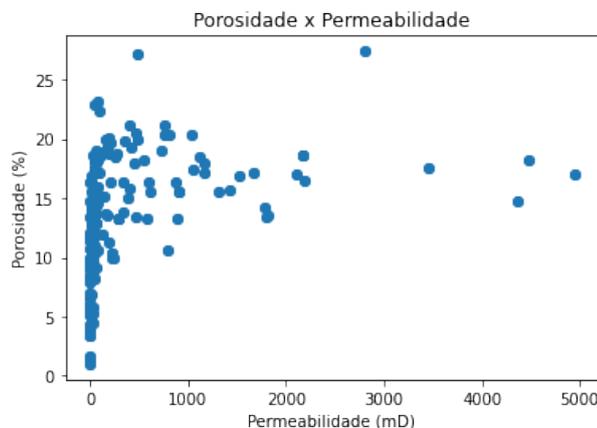
Fonte: Projeto Sapinhoá.

Quanto aos *labels*, para cada uma das imagens foram disponibilizados os dados de porosidade e permeabilidade obtidos através do uso de equipamentos laboratoriais e análise por parte dos especialistas da Geologia. A Figura 14 mostra uma comparação entre a porosidade e a permeabilidade de cada amostra de rocha do *dataset*. A partir dela, é possível perceber que os dados de permeabilidade estão levemente desbalanceados, com poucas amostras tendo permeabilidade acima de 2000 mD. Já os dados de porosidade estão distribuídos de forma mais uniforme, tendo bastante amostras tanto de baixa como de alta porosidade. Outra informação que pode ser extraída da Figura 14 é falta de relação direta entre porosidade e permeabilidade. Uma alta porosidade não significa que a rocha terá uma boa permeabilidade. Existem amostras com alta porosidade e baixa permeabilidade, pois os poros podem não estar conectados entre si.

4.2 Preparação dos dados

Foram utilizadas 183 imagens com resoluções de 1388x1040 e 1384x1036 pixels, cada uma representando uma amostra de rocha coletada em diferente profundidade de perfuração do poço. As 183 imagens foram redimensionadas para uma resolução padrão de 1384x1036 pixels, mantendo a proximidade da resolução original e evitando a perda de informações. Posteriormente, todas as imagens foram espelhadas com objetivo de gerar novas amostras para melhor treinamento da rede, gerando um total de 366 imagens para treinamento, validação e teste. Importante ressaltar que o espelhamento das imagens não afeta a identificação da porosidade ou

Figura 14 – Comparação entre porosidade e permeabilidade de cada amostra de rocha



Fonte: Elaborado pelo autor.

da permeabilidade, ou seja, ambas as propriedades permanecem iguais independente do ângulo de visualização.

A partir das 366 imagens, foi realizada uma divisão aleatória de 70% para treino, 15% para validação e 15% para teste. Enquanto os dados de treino são utilizados para o ajuste dos parâmetros da rede, os dados de validação são utilizados durante o treinamento para medir a qualidade e melhoria das métricas sobre dados novos no decorrer do treinamento. Já os dados de teste são utilizados após o fim do treinamento da rede, como forma de medir a qualidade de generalização do modelo com dados sem nenhuma influência sobre o treinamento.

A próxima etapa foi alterar a escala das imagens, visto que estavam em formato RGB, contendo três valores de 0 a 255 correspondente a cada nível de cor vermelho, verde e azul. Todos os valores foram divididos por 255, resultando em valores entre 0 e 1 e mantendo a mesma relação de distância entre si sem perder informações. O mesmo foi feito para os *labels*: a porosidade foi dividida por 100 para transformar os valores percentuais, de 0 a 100, em valores decimais entre 0 e 1 e a permeabilidade foi dividida por 1000 para converter os valores de mD (0 a 5000) para D (0 a 5). Isso é importante para agilizar o treinamento da rede neural e ajudar a evitar problemas como gradiente de fuga e gradiente explosivo.

4.3 Modelo

O desenvolvimento do modelo foi realizado com a linguagem de programação Python, utilizando o *framework* do Keras (CHOLLET; others, 2015) em conjunto com o TensorFlow (ABADI et al., 2016). Consiste em camadas convolucionais de 128, 64 e 32 neurônios com função de ativação ReLU em conjunto com camadas de *max pooling* e *dropout* (Tabela 1). O modelo foi desenvolvido se baseando na estrutura de modelos encontrados no estado da arte e adaptado de forma que os resultados fossem os melhores possíveis com os dados utilizados. Algumas das alterações realizadas foram a adição de camadas convolucionais, com diferente

quantidade de neurônios, e camadas de *max pooling*. Outros modelos foram experimentados, com diferentes funções de ativação, camadas e número de neurônios, mas nenhuma obteve resultados melhores do que a apresentada.

Além disso, também foram realizados experimentos com técnicas de segmentação utilizando ensino não supervisionado e aplicadas sobre as imagens antes de passar para a rede convolucional, mas não houve diferença perceptível nos resultados e acrescentou um alto custo computacional, aumentando consideravelmente o tempo total de execução. Acredita-se que não houve melhora devido ao fato das imagens já possuírem uma alta diferença de contraste entre poro e mineral. Por esses motivos, a aplicação dessa técnica sobre o modelo não foi continuada, sendo que as imagens foram utilizadas na rede convolucional em sua forma original.

Tabela 1 – Modelo de rede neural convolucional proposto

Camada	Neurônios	Ativação	Filtro
Convolutacional	32	ReLU	3x3
Max Pooling	-	-	2x2
Convolutacional	32	ReLU	3x3
Max Pooling	-	-	2x2
Convolutacional	64	ReLU	3x3
Max Pooling	-	-	2x2
Convolutacional	64	ReLU	3x3
Max Pooling	-	-	2x2
Convolutacional	128	ReLU	3x3
Max Pooling	-	-	2x2
Convolutacional	128	ReLU	3x3
Max Pooling	-	-	2x2
Dropout	-	-	20%
Densa	64	ReLU	-
Densa	32	ReLU	-
Densa	1	Identidade	-
Total de parâmetros:	3.352.993		

Fonte: Elaborado pelo autor

A função de erro utilizada foi a função de Huber em conjunto com o algoritmo de otimização de Adam (KINGMA; BA, 2017). Esse algoritmo é responsável por atualizar os pesos de cada camada da rede através da descida de gradiente estocástico. Uma vantagem do Adam é sua capacidade de adaptar a taxa de aprendizado de acordo com a melhora na acurácia do modelo (KINGMA; BA, 2017).

O modelo foi treinado utilizando ambiente de GPU com 25 GB de memória RAM fornecida pelo Google Colab sobre um máximo de 150 épocas (iterações por todo o conjunto de amostras de treino). Para evitar o esgotamento da memória, foi reduzido o parâmetro *batch size*, que indica o número de amostras de treino que são propagadas pela rede em cada iteração, de 32 para 16. Dessa forma, foram necessárias 16 iterações em cada época para propagar todas as amostras de treino. Também foi utilizada a técnica de *early stopping* para que o modelo

interrompa o treinamento quando não identificar melhora no resultado, com o objetivo de evitar o *overfitting*. O *early stopping* foi configurado para monitorar a função de erro sobre os dados de validação com uma paciência de 20 épocas (épocas seguidas sem melhora na métrica sendo avaliada) e restaurar os pesos da rede ao ser ativado. Assim, garante que o modelo final estará treinado com o melhor resultado possível obtido durante o treinamento.

O mesmo modelo foi treinado duas vezes separadamente para porosidade e permeabilidade, resultando em duas instâncias treinadas para cada uma das propriedades, conforme Figura 15. Foram realizados experimentos utilizando o mesmo modelo para retornar as duas propriedades em conjunto, mas os resultados foram consideravelmente inferiores ao formato proposto.

Figura 15 – Estrutura do modelo proposto



Fonte: Elaborado pelo autor.

5 RESULTADOS

As métricas foram obtidas a partir da média de 5 treinamentos, para que os resultados sejam mais consistentes e confiáveis. As métricas usadas foram o R^2 , MAE, MSE e RMSE.

Para a porosidade, foi obtido um R^2 de 0,8385, MAE de 0,0132, MSE de 0,0004 e RMSE de 0,0209. Para a permeabilidade, foi obtido um R^2 de 0,9826, MAE de 0,0700, MSE de 0,0161 e RMSE de 0,1256. Esses dados estão consolidados na Tabela 2.

Tabela 2 – Métricas obtidas a partir dos treinamentos

Treino	Porosidade				Permeabilidade			
	R^2	MAE	MSE	RMSE	R^2	MAE	MSE	RMSE
1	0,8487	0,0125	0,0004	0,0203	0,9814	0,0772	0,0173	0,1314
2	0,8409	0,0138	0,0004	0,0208	0,9809	0,0661	0,0178	0,1334
3	0,8041	0,0138	0,0005	0,0231	0,9743	0,0722	0,0239	0,1545
4	0,8283	0,0135	0,0005	0,0216	0,9889	0,0618	0,0103	0,1014
5	0,8704	0,0124	0,0004	0,0188	0,9876	0,0727	0,0115	0,1072
Média	0,8385	0,0132	0,0004	0,0209	0,9826	0,0700	0,0161	0,1256

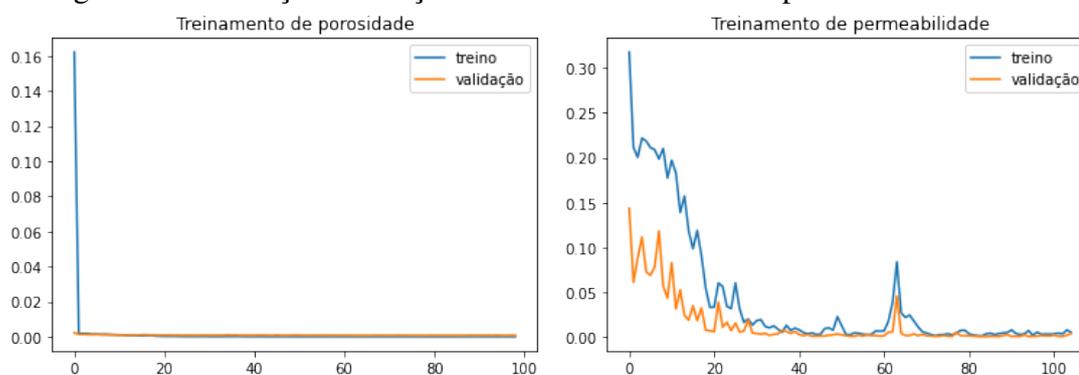
Fonte: Elaborado pelo autor.

Apesar da permeabilidade ser uma propriedade muito mais complexa de ser avaliada em relação à porosidade, o modelo acabou obtendo um coeficiente de determinação superior, mesmo

com os erros sendo maiores. Isso pode ser explicado pelo fato do coeficiente de determinação utilizar a média dos valores de saída no seu cálculo. A permeabilidade possui valores entre 0 D e 5 D, ou seja, a métrica é muito menos penalizada por pequenas diferenças entre o valor real e o valor previsto. Enquanto isso, para a porosidade são valores percentuais entre 0 e 1, resultando em uma maior penalidade em qualquer pequena diferença no valor previsto pelo modelo.

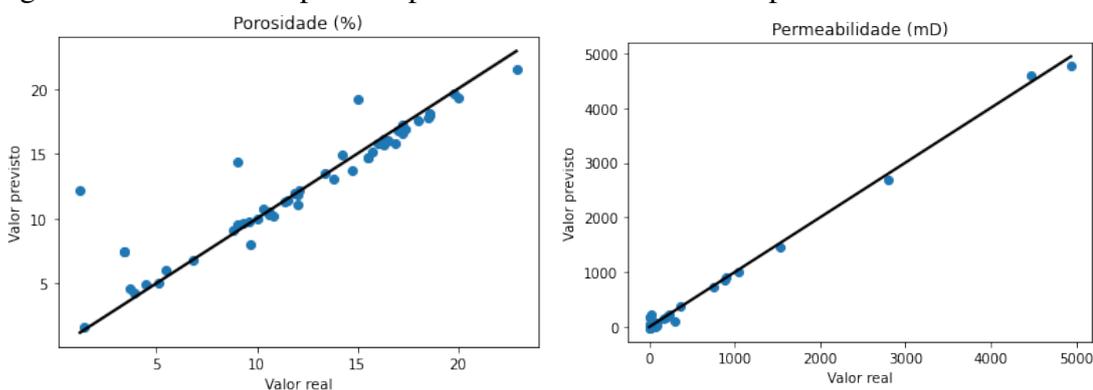
A Figura 16 mostra a evolução da função de erro no decorrer das épocas durante um dos treinamentos de porosidade e de permeabilidade, tanto dos dados de treinamento como dos dados de validação, até a parada devido ao *early stopping*, quando foi detectado que o erro parou de reduzir depois de 20 épocas. A Figura 17 mostra, respectivamente, a porosidade e a permeabilidade prevista pelo modelo nos dados de teste em relação à porosidade real das rochas após um dos treinamentos.

Figura 16 – Evolução da função de erro no decorrer das épocas de treinamento



Fonte: Elaborado pelo autor.

Figura 17 – Porosidade prevista pelo modelo em contraste à porosidade real das rochas

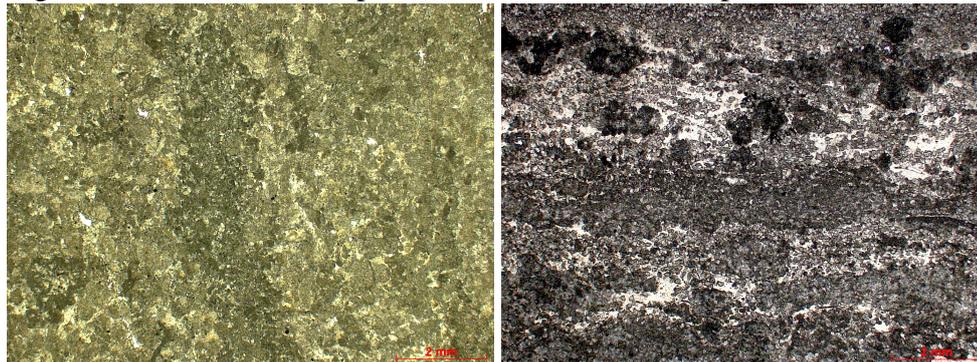


Fonte: Elaborado pelo autor.

Na Figura 17 é possível perceber a presença de alguns pontos fora da curva (*outliers*), principalmente no gráfico referente ao modelo de previsão de porosidade. Os *outliers* mais evidentes foram identificados pela rede com porosidade maior do que a realidade. Algumas dessas amostras podem ser visualizadas na Figura 18, enquanto na Figura 19 podem ser visualizadas

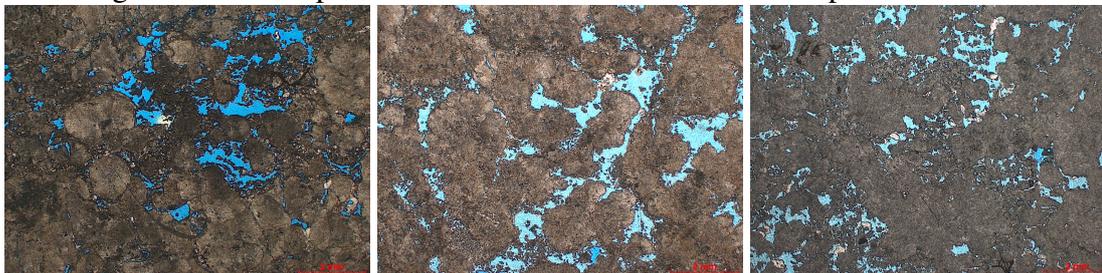
amostras com tonalidade encontrada em maior quantidade no *dataset*. Em comparação às demais amostras, é possível identificar que há uma grande diferença nas tonalidades das cores, principalmente do mineral. Uma possível interpretação é que isso pode ter confundido a rede, que pode ter interpretado partes do mineral como sendo poros. Talvez uma forma de mitigar isso futuramente seja adicionando mais exemplares com tonalidade semelhante, como algum tipo de rocha menos comum que aparece em menor quantidade no *dataset* disponibilizado.

Figura 18 – Amostras com pior resultado no cálculo de porosidade (*outliers*)



Fonte: Projeto Sapinhoá.

Figura 19 – Exemplos de amostras encontradas em maior parte do *dataset*



Fonte: Projeto Sapinhoá.

Quanto ao gráfico de permeabilidade, mesmo os dados estando desbalanceados e a grande maioria das amostras possuírem baixa permeabilidade, a rede conseguiu prever com uma boa acurácia as poucas amostras que continham maior permeabilidade. Isso é muito importante para auxiliar os especialistas no momento da tomada de decisões e na identificação dos poços de petróleo com maior taxa de extração.

Para efeito de comparação, o trabalho de Alqahtani et al. (2020) obteve um R^2 de 0,96 ao medir a porosidade a partir de imagens já segmentadas e um R^2 de 0,78 a partir das imagens originais em escala de cinza. O trabalho de Wu, Yin e Xiao (2018) obteve um R^2 máximo de 0,878642 e MSE de 0,001076. Já o trabalho de Tembely e AlSumaiti (2019) obteve um R^2 de 0,9156 em sua proposta de rede neural. Apesar de não ser possível fazer uma comparação direta entre os trabalhos pois são *datasets* diferentes, percebe-se que os resultados deste trabalho são positivos e obtiveram resultados semelhantes com trabalhos relacionados considerados como estado da arte na área.

6 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho teve o objetivo de aplicar aprendizado de máquina, mais especificamente redes neurais convolucionais, para prever a porosidade e a permeabilidade de rochas carbonáticas a partir de imagens de amostras coletadas durante perfuração de um poço de petróleo. Após uma introdução do problema e apresentação dos conceitos teóricos por trás do trabalho, foram apresentados trabalhos relacionados, detalhado o *dataset* utilizado e apresentado o modelo com todas as etapas de pré-processamento realizadas. Por fim, foram apresentados os resultados obtidos, com uma breve comparação com alguns trabalhos relacionados, a partir da qual se constata que os resultados são similares aos resultados relatados no estado da arte. É importante ressaltar que não é possível realizar uma comparação direta entre os trabalhos, mas apenas de forma informativa, visto que não usam o mesmo *dataset*. Esta implementação foi uma primeira etapa em direção a um modelo de predição mais completo que possua uma maior precisão e seja capaz de identificar outras propriedades mais complexas do material, que também podem ser importantes para a Geologia.

A partir da pesquisa e dos resultados, foi possível concluir que o uso de redes neurais convolucionais pode ser muito útil na previsão de propriedades de materiais porosos. Destaca-se como diferenciais a possibilidade de identificação rápida, sem custos laboratoriais e viés humano. Por consequência, auxilia os especialistas na identificação dos poços de extração de maior qualidade e que podem trazer mais benefícios ao serem explorados.

Quanto às limitações do trabalho, podem ser destacadas a necessidade de dados anotados para o treinamento, a dependência de coleta e fotografia das lâminas, a sensibilidade à *outliers* e também o fato de possuir poucas imagens, que pode ter prejudicado os resultados.

Um dos maiores desafios encontrado durante o desenvolvimento sem dúvida foi o consumo de memória. Devido à quantidade e resolução das imagens, dependendo da estrutura da rede não era possível realizar o treinamento com a quantidade de memória disponível. Algumas técnicas poderiam ser exploradas para reduzir o consumo de memória, mas nesse momento foi optado por usar as imagens em seu formato original para evitar a perda de informações importantes para o treinamento da rede.

Como trabalhos futuros, podem ser estudadas técnicas para melhorar os resultados obtidos, além de prever características mais complexas das rochas e dos poros, como quantidade de gargantas, tipos de poros ou até mesmo a litologia das rochas. Também pode ser experimentada a aplicação desse modelo em outros tipos de rochas (não carbonáticas).

Algumas técnicas de inteligência artificial que podem ser experimentadas são o uso de *cross validation* e outros métodos de *data augmentation* para geração de novas amostras. Outra possibilidade seria um estudo de técnicas de segmentação que poderiam ser aplicadas antes do treinamento para tentar aprimorar os resultados.

Outro fator que poderia melhorar os resultados é o uso de técnicas mais avançadas de coleta das imagens das rochas em três dimensões, como a microtomografia computadorizada de

raios-x. Essa técnica vem crescendo consideravelmente na indústria petrolífera nos últimos anos (BLUNT et al., 2013; ANDRÄ et al., 2013; BERG; LOPEZ; BERLAND, 2017) pois representa a estrutura da rocha de forma mais completa e fiel à realidade em relação à imagens de duas dimensões. Redes convolucionais tridimensionais e técnicas de segmentação no formato *encoder-decoder* são algumas das possibilidades que podem ser exploradas e aplicadas sobre essas imagens, inclusive como feito nos trabalhos de Alqahtani et al. (2020), Karimpouli e Tahmasebi (2019), Rushood et al. (2020), Wang et al. (2020).

Referências

- ABADI, M. et al. TensorFlow: A System for Large-Scale Machine Learning. In: **12th {USENIX} Symposium on Operating Systems Design and Implementation ({OSDI} 16)**. Savannah, GA: {USENIX} Association, 2016. p. 265–283. ISBN 978-1-931971-33-1. Disponível em: <<https://www.usenix.org/conference/osdi16/technical-sessions/presentation/abadi>>.
- AGGARWAL, C. **Neural Networks and Deep Learning: A Textbook**. Nova Iorque, EUA: Springer, 2018. ISBN 978-3-319-94462-3.
- AKBAR, M. et al. A snapshot of carbonate reservoir evaluation. **Oilfield Review**, v. 12, n. 4, p. 20–21, 2000.
- ALQAHTANI, N. et al. Machine learning for predicting properties of porous media from 2d X-ray images. **Journal of Petroleum Science and Engineering**, v. 184, p. 106514, 2020. ISSN 0920-4105. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0920410519309350>>.
- ANDRÄ, H. et al. Digital rock physics benchmarks—Part I: Imaging and segmentation. **Computers & Geosciences**, v. 50, p. 25–32, 2013. ISSN 0098-3004. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0098300412003147>>.
- ANP. **Sumário Sapinhoá**. 2017. Disponível em: <http://www.anp.gov.br/images/EXPLORACAO\E_PRODUCAO\DE\OLEO\E_GAS/Gestao\Contratos\Fase_Producao\Planos_Desenvolvimento\sumario_sapinhoa.pdf>.
- ARAYA-POLO, M. et al. Deep Learning-Driven Pore-Scale Simulation For Permeability Estimation. In: . European Association of Geoscientists & Engineers, 2018. v. 2018, n. 1, p. 1–14. ISSN 2214-4609. Disponível em: <<http://www.earthdoc.org/publication/publicationdetails/?publication=93919>>.
- AREL, I.; ROSE, D. C.; KARNOWSKI, T. P. Deep Machine Learning - A New Frontier in Artificial Intelligence Research [Research Frontier]. **IEEE Computational Intelligence Magazine**, v. 5, n. 4, p. 13–18, 2010.
- BERG, C. F.; LOPEZ, O.; BERLAND, H. Industrial applications of digital rock technology. **Journal of Petroleum Science and Engineering**, v. 157, p. 131–147, 2017. ISSN 0920-4105. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0920410517305600>>.
- BERRYMAN, J. G.; WANG, H. F. Elastic wave propagation and attenuation in a double-porosity dual-permeability medium. **International Journal of Rock Mechanics**

and Mining Sciences, v. 37, n. 1, p. 63–78, 2000. ISSN 1365-1609. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1365160999000921>>.

BLUNT, M. J. et al. Pore-scale imaging and modelling. **Advances in Water Resources**, v. 51, p. 197–216, 2013. ISSN 0309-1708. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0309170812000528>>.

BORDIGNON, F. et al. Deep Learning for Grain Size and Porosity Distributions Estimation on micro-CT Images. In: **Proceedings of the 16th International Congress of the Brazilian Geophysical Society & Expogef**. [S.l.: s.n.], 2019.

BURYAKOVSKY, L. et al. **Fundamentals of the petrophysics of oil and gas reservoirs**. [S.l.]: John Wiley & Sons, 2012.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. **Geoscientific model development**, Copernicus GmbH, v. 7, n. 3, p. 1247–1250, 2014.

CHOLLET, F. **Deep Learning with Python**. Nova Iorque, EUA: Manning Publications Company, 2017. ISBN 9781617294433.

CHOLLET, F.; others. **Keras**. 2015. Disponível em: <<https://keras.io>>.

CLEVERT, D.-A.; UNTERTHINER, T.; HOCHREITER, S. **Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)**. 2016.

EROFEEV, A. et al. Prediction of Porosity and Permeability Alteration Based on Machine Learning Algorithms. **Transport in Porous Media**, v. 128, n. 2, p. 677–700, 2019. ISSN 1573-1634. Disponível em: <<https://doi.org/10.1007/s11242-019-01265-3>>.

FACELI, K. et al. **Inteligência artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro, Brasil: Grupo Gen - LTC, 2011. ISBN 9788521618805. Disponível em: <<https://integrada.minhabiblioteca.com.br/#/books/978-85-216-2146-1/>>.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2. ed. [S.l.]: O'Reilly Media, 2019. ISBN 9781492032595.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016. Disponível em: <<http://www.deeplearningbook.org>>.

HARBAUGH, J. W. Chapter 7 Carbonate Oil Reservoir Rocks. In: CHILINGAR, G. V.; BISSELL, H. J.; FAIRBRIDGE, R. W. B. T. D. i. S. (Ed.). **Carbonate Rocks Origin, Occurrence and Classification**. Elsevier, 1967. v. 9, p. 349–398. ISBN 0070-4571. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0070457108711154>>.

HE, K. et al. Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. In: **Proceedings of the IEEE International Conference on Computer Vision (ICCV)**. [S.l.: s.n.], 2015.

HEATON, J. **Artificial intelligence for humans**. [S.l.]: Heaton Research, Incorporated, 2015. v. 3. ISBN 978-1505714340.

- HINTON, G. E. et al. **Improving neural networks by preventing co-adaptation of feature detectors**. 2012.
- HOLLAND, P. W.; WELSCH, R. E. Robust regression using iteratively reweighted least-squares. **Communications in Statistics - Theory and Methods**, Taylor & Francis, v. 6, n. 9, p. 813–827, 1 1977. ISSN 0361-0926. Disponível em: <<https://doi.org/10.1080/03610927708827533>>.
- KARIMPOULI, S.; TAHMASEBI, P. Segmentation of digital rock images using deep convolutional autoencoder networks. **Computers & Geosciences**, v. 126, p. 142–150, 2019. ISSN 0098-3004. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0098300418303911>>.
- KINGMA, D. P.; BA, J. **Adam: A Method for Stochastic Optimization**. 2017.
- KLAMBAUER, G. et al. **Self-Normalizing Neural Networks**. 2017.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. ImageNet Classification with Deep Convolutional Neural Networks. **Neural Information Processing Systems**, v. 25, 2012.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, p. 436–444, 2015.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998.
- MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier nonlinearities improve neural network acoustic models. In: **Proc. icml**. [S.l.: s.n.], 2013. v. 30, n. 1, p. 3.
- MITCHELL, T. M. **Machine Learning**. [S.l.]: McGraw-Hill, 1997. ISBN 9780071154673.
- MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of Machine Learning**. 2. ed. Cambridge, EUA: MIT Press, 2018. ISBN 9780262039406. Disponível em: <<https://books.google.com.br/books?id=V2B9DwAAQBAJ>>.
- NAGELKERKE, N. A note on a general definition of the coefficient of determination. **Biometrika**, v. 78, p. 691–692, 1991.
- NAIR, V.; HINTON, G. E. Rectified Linear Units Improve Restricted Boltzmann Machines. In: **ICML**. [s.n.], 2010. p. 807–814. Disponível em: <<https://icml.cc/Conferences/2010/papers/432.pdf>>.
- NIELSEN, M. **Neural Networks and Deep Learning**. Determination Press, 2015. Disponível em: <<http://neuralnetworksanddeeplearning.com/>>.
- NWANKPA, C. et al. **Activation Functions: Comparison of trends in Practice and Research for Deep Learning**. 2018.
- RAMACHANDRAN, P.; ZOPH, B.; LE, Q. V. **Searching for Activation Functions**. 2017.
- RUMELHART, D. E.; HINTON, G.; WILLIAMS, R. J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group, v. 323, n. 6088, p. 533–536, 1986.
- RUSHOOD, I. A. et al. **Segmentation of X-Ray Images of Rocks Using Deep Learning**. Virtual: Society of Petroleum Engineers, 2020. 13 p. Disponível em: <<https://doi.org/10.2118/201282-MS>>.

RUSSELL, S.; NORVIG, P. **Inteligência Artificial**. 3. ed. Rio de Janeiro, Brasil: Elsevier, 2013. ISBN 978853523701. Disponível em: <<https://integrada.minhabiblioteca.com.br/#/books/9788595156104>>.

SCHMIDHUBER, J. Deep learning in neural networks: An overview. **Neural Networks**, Elsevier BV, v. 61, p. 85–117, 1 2015. ISSN 0893-6080. Disponível em: <<http://dx.doi.org/10.1016/j.neunet.2014.09.003>>.

SHARMA, S. Activation functions in neural networks. **Towards Data Science**, v. 4, n. 12, p. 310–316, 2020.

SUDAKOV, O.; BURNAEV, E.; KOROTEEV, D. Driving digital rock towards machine learning: Predicting permeability with gradient boosting and deep neural networks. **Computers & Geosciences**, v. 127, p. 91–98, 2019. ISSN 0098-3004. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0098300418301717>>.

TAHMASEBI, P. et al. Machine learning in geo- and environmental sciences: From small to large scale. **Advances in Water Resources**, v. 142, p. 103619, 2020. ISSN 0309-1708. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0309170820301366>>.

TEMBELY, M.; ALSUMAITI, A. **Deep Learning for a Fast and Accurate Prediction of Complex Carbonate Rock Permeability From 3D Micro-CT Images**. Abu Dhabi, UAE: Society of Petroleum Engineers, 2019. 14 p. Disponível em: <<https://doi.org/10.2118/197457-MS>>.

TEMBELY, M.; ALSUMAITI, A.; ALAMERI, W. A deep learning perspective on predicting permeability in porous media from network modeling to direct simulation. **Computational Geosciences**, v. 24, n. 4, p. 1541–1556, 2020. ISSN 1573-1499. Disponível em: <<https://doi.org/10.1007/s10596-020-09963-4>>.

VALENTÍN, M. B. et al. A deep residual convolutional neural network for automatic lithological facies identification in Brazilian pre-salt oilfield wellbore image logs. **Journal of Petroleum Science and Engineering**, v. 179, p. 474–503, 2019. ISSN 0920-4105. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0920410519303663>>.

WANG, Y. D. et al. Physical Accuracy of Deep Neural Networks for 2D and 3D Multi-Mineral Segmentation of Rock micro-CT Images. 2 2020. Disponível em: <<http://arxiv.org/abs/2002.05322>>.

WASON, R. Deep learning: Evolution and expansion. **Cognitive Systems Research**, v. 52, p. 701–708, 2018. ISSN 1389-0417. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1389041717303546>>.

WU, J.; YIN, X.; XIAO, H. Seeing permeability from images: fast prediction with convolutional neural networks. **Science Bulletin**, v. 63, n. 18, p. 1215–1222, 2018. ISSN 2095-9273. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S2095927318303955>>.