



Gabriel Grenier Ferreira Motta

**Determinação da permeabilidade equivalente
de meios-porosos heterogêneos utilizando
*Deep Learning***

Projeto de Graduação

Projeto de Graduação apresentado ao Departamento de Engenharia
Mecânica da PUC-Rio

Orientador: Márcio Carvalho
Coorientador: Sergio Ribeiro

Rio de Janeiro

Junho de 2022

AGRADECIMENTOS

Primeiramente, gostaria de começar agradecendo à minha família, principal responsável pelo ser humano que sou hoje, aqueles que são a minha base para tudo. Em especial, aos meus queridos pais, Mauro e Vanessa. O meu amor por vocês é imensurável e a gratidão por tudo que vocês me proporcionaram até aqui será eterna. Também agradeço do fundo do meu coração ao meu irmão Henrique, a minha avó Thais, ao meu tio Leonardo, a minha tia Simone e ao meu primo João por serem os familiares que mais estiveram presentes ao longo da minha vida e puderam compartilhar comigo todas as glórias e lamentar todos os pesares vividos até aqui. Obrigado também ao resto da família seja em Teresópolis, Salvador ou Belo Horizonte. E, em especial, muito obrigado Cícera e Olímpia, a “Dadá”, por terem participado significativamente na minha criação, vocês também são da família e amo vocês.

Agradeço a todos os amigos que tive o privilégio de fazer ao longo desses 24 anos de vida. Em especial, àqueles do Colégio Andrews, que compartilharam comigo momentos muito significativos vividos até aqui. Esse tipo de amizade é para sempre e assim espero.

Agradeço ao Prof. Luiz Fernando e ao Laboratório de Engenharia de Fluidos (LEF) e, especialmente, ao Rodrigo, Leozinho, Guilherme, Marcinho e Alexandre. Não só pelos bons momentos vividos e pela amizade como também pela oportunidade de me proporcionar a minha primeira experiência profissional.

Agradeço ao Prof. Márcio, ao Sergio e a todo o Laboratório de Microhidrodinâmica em Meios Porosos (LMMP) por terem me proporcionado este tema de pesquisa e me guiado ao longo deste trabalho. Antes de começar a tese, eu queria ter oportunidade de desenvolver algo desafiador e que me trouxesse muitos ensinamentos. No presente momento, sem dúvida nenhuma, posso afirmar que foi bastante desafiador, aprendi muito e, mais importante, consegui.

Agradeço à SAE Brasil por organizar e estimular o projeto BAJA SAE nas universidades do nosso país. Esse é um projeto pelo qual serei

eternamente grato por ter vivenciado neste período significativo da vida, que é o da graduação. Através desse projeto aprendi a sair da zona de conforto, trabalhar em equipe e a enxergar a beleza da engenharia e, conseqüentemente, ama-la. Por isso, não posso deixar de também agradecer ao Prof. José Alberto Parise e ao Prof. José Paulo, os quais são os principais responsáveis pela existência da Equipe Reptiles de BAJA da PUC-Rio, onde eu considero ser a minha segunda casa. Lá, pude fazer amigos que com certeza sei que levarei para vida toda e sou muito grato pelos bons momentos que viveram comigo, as dificuldades que superamos e a tudo que conquistamos juntos, como equipe. Dito isso, faço questão de nomear alguns deles aqui, para registrar o meu agradecimento. Gostaria de poder nomear todos que passaram por ali e deram seu máximo, mas infelizmente não posso deixar o trabalho com muitas páginas. A começar pelos meus veteranos: Biel, “Caipira”, Carol, Erik, Gi, Henrique, Ju, Luísa, Luciana, Marina, “Milhouse”, Monte Santo, “Shrek”, Vivian e Wang. Aqueles que entraram comigo nessa jornada e vivenciaram comigo a maioria das nossas conquistas: Ana, Bruno, “Dedão”, “Fei”, Lucca e Stélio. E, por último, mas não menos importante, meus calouros: “Bigo”, Davi, Erick, Godoy, Karol, Leo, Luiza, Luig, “Milantinha”, Portari, Rod e Turnes.

Por fim, um agradecimento especial a minha namorada, Luísa, a mesma que já foi mencionada. Sou muito grato pela nossa relação e por tudo que construímos até aqui. Obrigado por todos os ensinamentos, por acreditar mais em mim do que eu mesmo, por toda nossa parceria e pelo nosso amor. Como você disse, tem sido bem melhor assim.

RESUMO

Métodos de média são amplamente utilizados para realizar estimativas de permeabilidade média de reservatórios de petróleo. A Equação de Darcy recebe uma vazão medida, correspondente a um diferencial de pressão aplicado, para obter uma boa aproximação de permeabilidade média. Para meios com estrutura porosa homogênea, é possível obter uma relação entre a permeabilidade e a porosidade do meio. Porém, formações rochosas carstificadas, como carbonatos, apresentam *vugs*, fraturas e outras estruturas cavernosas com variações abruptas de porosidade e permeabilidade locais. Determinar uma boa correlação entre os padrões de estruturas cársticas e o incremento gerado na permeabilidade aumentaria consideravelmente a precisão dos métodos de caracterização de reservatórios heterogêneos. Recentemente, redes neurais convolucionais (CNNs) têm sido usadas para estimar os efeitos das características cársticas na permeabilidade equivalente de um meio poroso de carbonato, com base em imagens das estruturas de macroporosidade da amostra [Dali et. al., 2020]. A metodologia proposta por Dali et. al. consiste em: (i) simular o escoamento através de uma malha 2D construída com base nas imagens de microtomografia de rochas utilizando o modelo Brinkman; (ii) criação de um banco de dados de treinamento a partir das imagens binárias de macroporosidade e o correspondente incremento de permeabilidade simulada em relação à permeabilidade da matriz rochosa; (iii) finalmente perguntando à CNN treinada para estimar o incremento de permeabilidade equivalente de imagens de mídia cárstica porosa não vistas. O presente trabalho reimplementa esta metodologia em imagens de microtomografia bidimensionais obtidas a partir de amostras carbonáticas brasileiras. Além disso, apresenta uma análise de sensibilidade abrangente da arquitetura CNN e dos parâmetros de treinamento com relação à precisão efetiva da previsão de permeabilidade. Finalmente, o estudo atual complementa o estudo anterior com uma avaliação da capacidade da CNN de generalizar os padrões aprendidos a partir de um conjunto de dados de treinamento específico de imagens. A análise avalia quais características da rede permitem prever razoavelmente os incrementos de permeabilidade dentro de um conjunto de dados de teste composto por amostras de rochas não vistas com faixas de permeabilidade distintas das de treinamento.

Palavras-chave: Meios porosos. Meios Porosos Heterogêneos. Porosidade. Permeabilidade. Permeabilidade equivalente. Inteligência computacional. Aprendizado Profundo. Rede Neural Convolucional. CNN. Stokes. Darcy. Brinkman.

ABSTRACT

Averaging methods widely used to perform oil reservoir averaging estimates. The Darcy Equation receives a measurement, corresponding to an applied pressure differential, to obtain a good approximation of mean permeability. For media with a porous structure, it is possible to obtain a relationship between the permeability and porosity of the media. However, karstified rock formations, such as carbonates, present vugs, fractures and other cave-like structures with abrupt variations of local porosity and permeability. To determine a good correlation between the karstic structures patterns and the generated increment in permeability would considerably enhance the accuracy of reservoir characterization methods in heterogeneous reservoirs. Recently, Convolutional Neural Networks (CNNs) have been used for estimating the effects of the Karstic features on the equivalent permeability of a carbonate porous medium, based on images of the sample's macro porosity structures [Dali et. al., 2020]. The methodology proposed by Dali et. al. consists on: (i) simulating the flow through a 2D mesh built based on the rock micro tomography images using Brinkman model; (ii) creating a training database from the macro porosity binary images and the correspondent simulated permeability increment with respect to the rock matrix permeability; (iii) finally inquiring the trained CNN to estimate the equivalent permeability increment of unseen karstic porous media images. The present work re-implements this methodology to bidimensional micro tomography images taken from brazilian carbonate core samples. In addition, it presents a comprehensive sensitivity analysis of the CNN architecture and training parameters with respect to the effective permeability prediction accuracy. Finally, the current study complements the previous study with an evaluation of the CNN capacity to generalize the learned patterns from a specific training dataset of images. The analysis evaluates which network characteristics enable it to reasonably predict the permeability increments within a test dataset composed by unseen rock samples with distinct permeability ranges from the training ones.

Key words: Porous media. Heterogeneous Porous Media. Porosity. Permeability. Equivalent Permeability. Computational Intelligence. Deep Learning. Convolutional Neural Network. CNN. Stokes. Darcy. Brinkman.

Sumário

1. INTRODUÇÃO	10
1.1. Descrição do problema	10
1.2. Motivação.....	10
1.3. Objetivo	11
2. REVISÃO BIBLIOGRÁFICA.....	12
2.1. Meios porosos heterogêneos	12
2.2. Equação de conservação de massa	13
2.3. Equações da conservação da quantidade de movimento	13
2.4. Lei de Darcy	14
2.5. Modelo de Brinkman	14
2.6. Redes Neurais Convolucionais (CNNs)	15
3. METODOLOGIA	19
3.1. Geração dos dados de entrada.....	19
3.1.1. Segmentação das imagens dos meios porosos	19
3.1.2. Formulação numérica do modelo de Brinkman	20
3.2. Desenvolvimento da arquitetura da CNN	22
4. RESULTADOS.....	25
4.1. Tratamento dos dados de entrada	25
4.2. Escolha das topologias ótimas.....	26
4.3. Topologia ótima nos outros grupos restantes	29
4.4. Treinamento especial	30
4.5. Previsões cruzadas	34
5. CONCLUSÃO	40
REFERÊNCIAS BIBLIOGRÁFICAS	42

LISTA DE FIGURAS

Figura 1- Captura micro tomografia binária de uma rocha carbonática, exemplificando um meio poroso heterogêneo.....	12
Figura 2 – Campo receptivo local na imagem de entrada se conectando com o neurônio na camada oculta da rede.	16
Figura 3 - Uma camada convolucional completa, com três mapas de recursos no total.	17
Figura 4 - Camada de agrupamento gerando ativação sobre uma região de 2 x 2 neurônios de uma camada oculta, através do método de Max-Pooling.	17
Figura 5 - Exemplo da arquitetura final de uma CNN que ilustra os conceitos bases de qualquer projeto deste tipo.	18
Figura 6 - Exemplo da segmentação de uma imagem topográfica de um meio poroso.	20
Figura 7 - Exemplo da aplicação de pressão no meio poroso.....	21
Figura 8 - Exemplo do campo de velocidade no meio poroso, decorrente da pressão aplicada.	22
Figura 9 – Exemplos de imagens do grupo “am5”. Em ordem, da esquerda para a direita, tipo c1, tipo c2, tipo c3 e tipo c4.	23
Figura 10 - Exemplos de imagens do grupo “am8”. Em ordem, da esquerda para a direita, tipo c1, tipo c2, tipo c3 e tipo c4.	23
Figura 11 – Gráficos de dispersão entre a permeabilidade equivalente estimada e a teórica de cada topologia testada para o grupo de imagens Am5 e tipos c1 e c2.	28
Figura 12 - Gráficos de distribuição normal em função do erro relativo obtido de cada topologia testada.	28
Figura 13 - Gráficos de dispersão entre o erro relativo obtido e a permeabilidade equivalente teórica de cada topologia testada.....	29
Figura 14 - Gráficos de dispersão entre a permeabilidade equivalente estimada e a teórica de cada topologia testada para os grupos restantes: Am5 e tipos c3 e c4; Am8 e tipos c1 e c2; Am8 e tipos c3 e c4.....	30
Figura 15 – Desempenho do treinamento especial. Gráfico da função de perda do modelo (“ <i>Loss Function</i> ”) à esquerda e a correlação do erro médio do modelo com o seu número de épocas.	32

Figura 16 – Gráfico de dispersão entre a permeabilidade equivalente teórica e a estimada pela Topologia 2b (esquerda) e a dispersão do erro relativo de cada previsão com a permeabilidade equivalente teórica, para o grupo de imagens da amostra Am8 e tipos c3 e c4.....	33
Figura 17 – Uso do modelo treinado com a Topologia 2, a partir de imagens do subgrupo da amostra Am5 e tipos c1 e c2, para prever as permeabilidades equivalentes de imagens do subgrupo da amostra Am5 e tipos c3 e c4.....	34
Figura 18 - Uso do modelo treinado com a Topologia 2, a partir de imagens do subgrupo da amostra Am5 e tipos c3 e c4, para prever as permeabilidades equivalentes de imagens do subgrupo da amostra Am8 e tipos c1 e c2.....	36
Figura 19 - Uso do modelo treinado com a Topologia 2b, a partir de imagens do subgrupo da amostra Am8 e tipos c3 e c4, para prever as permeabilidades equivalentes de imagens dos demais subgrupos.....	37
Figura 20 - Uso do modelo treinado com a Topologia 2b, a partir de imagens do subgrupo da amostra Am8 e tipos c3 e c4, para prever as permeabilidades equivalentes de imagens do subgrupo da amostra Am8 e tipos c1 e c2.....	38
Figura 21 - Uso do modelo treinado com a Topologia 2b, a partir de imagens do subgrupo da amostra Am8 e tipos c3 e c4, para prever as permeabilidades equivalentes de imagens do subgrupo da amostra Am5 e tipos c3 e c4.....	38

LISTA DE TABELAS

Tabela 1 – Diferentes topologias do modelo da rede que serão analisadas. ...	24
Tabela 2 - Tratamento dos dados de entrada.	25
Tabela 3 – Desempenho das topologias testadas para a subdivisão do grupo Am5 com tipos c1 e c2.	27
Tabela 4 - Desempenho da topologia ótima para os diferentes grupos restantes.....	30
Tabela 5 – Diferentes topologias do modelo da rede que serão analisadas para o treinamento especial.	31
Tabela 6 - Desempenho das topologias testadas para a subdivisão do grupo Am8 com tipos c3 e c4.	32

1. INTRODUÇÃO

1.1. Descrição do problema

A permeabilidade de um meio poroso é a propriedade mais importante na caracterização dos reservatórios de petróleo e gás em relação à capacidade de escoamento dos fluidos. A permeabilidade de um meio poroso é uma função da porosidade efetiva do meio e da conectividade e forma dos seus poros. Dito isso, em um meio poroso homogêneo, com poros de tamanhos semelhantes, dispersão bem distribuída e uma matriz porosa conectada uniformemente, quanto maior a sua porosidade necessariamente maior será a permeabilidade desse meio.

Entretanto, em alguns tipos de rocha, como as rochas carbonáticas, a geometria dos seus poros pode apresentar grandes variações de escala. Um meio poroso que apresenta de cavernas ou *vugs* bem maiores do que os poros da matriz rochosa recebe o nome de meio poroso carstificado (*karst topography*) [1]. Sendo assim, devido a sua heterogeneidade, é normalmente definida uma permeabilidade equivalente para representar os efeitos dessas macro-porosidades. No entanto, dependendo da heterogeneidade na distribuição dos macroporos, determinar a permeabilidade equivalente desses reservatórios pode ser uma tarefa bastante complexa.

1.2. Motivação

O cenário de produção brasileira de óleo e gás aponta uma importância cada vez maior da produção dos campos do pré-sal, que são reservatórios carbonáticos.

Um grande desafio dos reservatórios carbonáticos é, justamente, o aumento da eficiência de varredura, normalmente aplicando diversas técnicas chamadas de recuperação avançada de óleo, do inglês *Enhanced Oil-Recovery*, ou EOR. A alta heterogeneidade dessas rochas [2] que, em sua maioria, constituem a camada do pré-sal brasileiro, é um fator que intensifica a criação de caminhos preferenciais de escoamento para o fluido injetado, deixando bolsões de óleo para trás durante a produção. Somam-se a isso, inúmeras outras particularidades da cadeia de produção de petróleo e gás

como, por exemplo, as diferentes composições de poços explorados, seja pela quantidade de óleo, gás natural, ou até mesmo de água.

Em suma, é extremamente complexo definir padrões no escoamento em um reservatório de petróleo. O conhecimento da permeabilidade das diferentes regiões de um reservatório é de fundamental importância na definição da melhor estratégia de produção. Tendo isso em vista, determinar de forma rápida e precisa a permeabilidade de um meio poroso carstificado é extremamente valioso para a indústria. Assim como em outras áreas do conhecimento, combinar mecânica dos fluidos com inteligência computacional vem se mostrando uma ferramenta muito poderosa e será tendência nos próximos anos [3].

1.3. Objetivo

O presente trabalho visa combinar os métodos já utilizados no estudo da mecânica dos fluidos em meios porosos heterogêneos com a utilização de algoritmos de inteligência computacional para estimativa da permeabilidade em meios carstificados. Métodos de Inteligência Computacional têm sido cada vez mais utilizados para solucionar problemas de engenharia, principalmente substituindo técnicas tradicionais de maior custo computacional, como os diferentes métodos de dinâmica dos fluidos computacional (CFD), por exemplo.

A partir da implementação de técnicas de aprendizado profundo (“Deep Learning”) torna-se possível entender a relação dos parâmetros de entrada do modelo com as respostas dadas pelo mesmo. Visa-se, então, desenvolver uma Rede Neural Convolucional (CNN), a qual irá receber uma grande quantidade de imagens de entrada e as respectivas permeabilidades equivalentes simuladas como alvo, mapeando a correlação de vários aspectos dessa imagem com a magnitude do alvo. Por fim, espera-se que essa rede seja capaz de inferir a permeabilidade efetiva dos meios porosos analisados, provenientes de imagens nunca antes vistas pela rede, com um alto índice de confiabilidade.

2. REVISÃO BIBLIOGRÁFICA

2.1. Meios porosos heterogêneos

Os meios porosos carstificados apresentam grande heterogeneidade na escala geométrica dos seus poros. Um exemplo são as rochas carbonáticas, que apresentam grandes variações na escala dos seus poros ao longo do reservatório. Os poros de maior tamanho, que podem ser cavernas, vugs e fraturas, recebem o nome de carstes (*karst*) [4]. Sendo assim, alguns autores costumam tratar um meio poroso heterogêneo como a combinação de uma matriz rochosa homogênea com poros na escala micrométrica e uma rede de poros maiores, de diversas geometrias, tamanhos e conexões [5].

A Figura 1 apresenta uma imagem binária de micro tomografia de rocha carbonática. Pode-se observar a presença de diferentes estruturas de poros e interconexões, representados em preto, e os espaços brancos ao redor representam a matriz rochosa, que possui poros em escalas muito menores, não visíveis na resolução da imagem.




Figura 1- Captura micro tomografia binária de uma rocha carbonática, exemplificando um meio poroso heterogêneo.

Uma importante propriedade do meio poroso é a porosidade, que é a razão entre o volume dos poros pelo volume total da amostra [6], como apresentado na eq. 2-1. Também pode ser entendida como a parcela de volume da rocha capaz de conter fluido.

$$\phi = \frac{V_{poros}}{V_{total}} \quad (2-1)$$

Em meios carstificados, a porosidade total da amostra é uma combinação da porosidade da matriz rochosa (poros pequenos) e dos macroporos. Para a simulação dos processos de recuperação em reservatórios carbonáticos, é importante saber o efeito dos macroporos na permeabilidade equivalente da amostra. Esse aumento de permeabilidade está diretamente relacionado com o tamanho, forma e interconectividade dos macroporos.

2.2. Equação de conservação de massa

Uma vez entendidas as propriedades de um meio poroso heterogêneo, é necessário compreender as equações que regem o escoamento de fluidos nos espaços porosos. Segundo Fox [7], a equação diferencial da conservação de massa pode ser escrita como demonstrado na eq. 2-2.

$$\nabla \cdot (\rho \vec{V}) + \frac{\partial \rho}{\partial t} = 0 \quad (2-2)$$

No entanto, para fluidos incompressíveis, onde a sua densidade não varia com a pressão, a equação da continuidade é simplificada para:

$$\nabla \cdot \vec{V} = 0 \quad (2-3)$$

2.3. Equações da conservação da quantidade de movimento

Ainda de acordo com Fox [7], a forma diferencial da equação da conservação da quantidade de movimento é obtida através da aplicação da segunda lei de Newton em um volume de controle infinitesimal de fluido e, para fluidos incompressíveis, é conhecida como a equação de Cauchy. Para um fluido Newtoniano, as tensões podem ser expressas em termos de gradientes da velocidade e das propriedades dos fluidos. Portanto, quando essa equação de conservação de quantidade de movimento é aplicada ao escoamento

incompressível com viscosidade constante, obtêm-se as equações de Navier-Stokes, que podem ser escritas na forma vetorial (eq. 2-4).

$$\rho \left(\frac{\partial \vec{V}}{\partial t} + \vec{V}(\nabla \cdot \vec{V}) \right) = \rho g - \nabla P + \mu \nabla^2 \vec{V} \quad (2-4)$$

E, para escoamentos em baixo número de Reynolds, e onde a inércia pode ser desprezada, a equação de Navier-Stokes é simplificada para a equação de Stokes (eq. 2-5).

$$\rho g + \mu \nabla^2 \vec{V} = \nabla P \quad (2-5)$$

2.4. Lei de Darcy

Ao se tratar de escoamentos em micro poros, deve-se partir da premissa de que simular o escoamento na escala microscópica, ou seja, em cada poro, não é viável. Portanto, opta-se por fazer uso de métodos de transmissibilidade média, sendo a mais amplamente utilizada para este tipo de aplicação, a Lei de Darcy, de acordo com Oliveira [2].

Proposta por Henry Darcy em 1856, a mesma estabelece a relação entre a vazão que atravessa um meio poroso homogêneo e o gradiente de pressão que atua sobre o mesmo meio. Sendo assim, como mostrado pela eq. 2-6, estabelece a proporcionalidade direta da vazão (Q) com o gradiente de pressão (∇P) e a proporcionalidade indireta da vazão com a viscosidade do fluido (μ), ambas correlacionadas com a constante de permeabilidade do meio (k). Em suma, essa constante deve ser entendida como a medida da capacidade de um meio poroso de transmitir o escoamento de um fluido [8].

$$\frac{Q}{A} = -\frac{k}{\mu} \nabla P \quad (2-6)$$

2.5. Modelo de Brinkman

O modelo de Brinkman que combina as equações de Darcy e Stokes através de uma única equação diferencial é bastante utilizado para modelar rochas em que a escala de tamanho de poros varia de poros micrométricos até

grandes falhas e cavernas por onde o fluido escoar livremente em baixas velocidades, como visto em Oliveira [2], é apresentada na Eq.(2-7).

$$\nabla P = -\frac{\mu}{k}\vec{V} + \mu^*\nabla^2\vec{V} \quad (2-7)$$

Na matriz rochosa, contendo poros pequenos, onde o escoamento obedece a Lei de Darcy (eq. 2-6), a viscosidade (μ^*) é definida de forma a zerar o termo de Stokes. Já no espaço constituído pelos poros macroscópicos, onde o escoamento obedece à equação de Stokes (eq. 2-5), a permeabilidade (k) é definida de forma a zerar o termo de Darcy. Dito isso, pode-se entender o modelo de Brinkman como uma única equação capaz de representar o escoamento do fluido em dois domínios diferentes.

Usando a equação de Brinkman e o modelo de elementos finitos, Dali [9] solucionou o sistema de equações diferenciais que descreve um fluxo bidimensional através de um meio poroso com macroporos. O objetivo da sua análise foi avaliar uma permeabilidade equivalente em função da área e estrutura dos macroporos, dando como entrada cortes 2D de imagens tomográficas de diferentes tipos de rochas. Entretanto, estas simulações numéricas do escoamento apresentam um alto custo computacional, tornando a determinação da permeabilidade equivalente de meios heterogêneos por essa metodologia bastante custosa.

2.6. Redes Neurais Convolucionais (CNNs)

De acordo com Nielsen [10], redes neurais convolucionais podem ser descritas como algoritmos de “*Deep Learning*” (em português, “Aprendizado Profundo”) que possuem arquiteturas particularmente ideais para se resolver problemas de identificação de imagens. Tais arquiteturas fazem uso de três conceitos bases: campos receptivos locais, pesos e vieses compartilhados e camadas de agrupamento. A seguir, para melhor entendimento e contextualização do problema, estão descritas breves explicações acerca destes três conceitos.

Nielsen [10] define campos receptivos locais como uma região na imagem de entrada de tamanho pré-definido, ou seja, uma pequena janela nos

pixels de entrada. Essa janela tem como principal função estabelecer a conexão com um neurônio da camada oculta que pertence à arquitetura da rede. Logo abaixo, a Figura 2 ilustra esse processo. Note que os neurônios de entrada correspondem a uma imagem de 28 x 28 pixels (ou uma matriz 28 x 28), totalizando 784 pixels, e o campo receptivo local corresponde a uma região de 5 x 5 pixels, totalizando 25 neurônios de entrada. Tais valores não necessariamente se aplicam ao problema aqui estudado e estão sendo utilizados somente para um melhor entendimento da teoria.




Figura 2 – Campo receptivo local na imagem de entrada se conectando com o neurônio na camada oculta da rede.

É importante frisar que o uso de um campo receptivo local desse tamanho não é obrigatório e é um parâmetro da rede facilmente ajustável, pois é definido empiricamente, assim como a maioria dos demais parâmetros deste tipo de problema. Entretanto, para uma imagem de entrada de 28 x 28 pixels, e caso sejam utilizados campos receptivos locais de 5 x 5 pixels, tem-se como resultado uma camada oculta de 24 x 24 pixels. E, para cada conexão feita com um pixel na camada oculta, tem-se um peso correspondente e o mesmo aprende um viés que também está relacionado à conexão realizada.

Dito isso, ainda de acordo com Nielsen [10], esses pesos e vieses compartilhados podem ser definidos como um filtro. Entretanto, ao se tratar de identificação de imagens, faz-se necessário a presença de múltiplos mapas de recursos, os quais são definidos por um conjunto de pesos compartilhados e um único viés compartilhado. Na Figura 3, é possível observar três mapas de recursos e, com essa configuração, a rede é capaz de detectar três diferentes recursos. Logicamente, cada recurso é detectável em toda a imagem de entrada ao invés de somente em um campo receptivo local.




Figura 3 - Uma camada convolucional completa, com três mapas de recursos no total.

Por fim, para se definir os conceitos básicos que formam a teoria da arquitetura por trás de CNNs, além das camadas convolucionais, existem as camadas de agrupamento, as quais, segundo Nielsen [10], são utilizadas para simplificar as informações na saída da camada convolucional. Continuando com a arquitetura exemplo da rede utilizada nas imagens anteriores, uma camada de agrupamento pode ter uma unidade resumindo uma região de 2 x 2 neurônios de uma camada oculta, por exemplo, como exemplificado na Figura 4. Com isso, em uma camada oculta de 24 x 24 neurônios, após o agrupamento, o resultado é o de uma camada de 12 x 12 neurônios.




Figura 4 - Camada de agrupamento gerando ativação sobre uma região de 2 x 2 neurônios de uma camada oculta, através do método de Max-Pooling.

Esses são os três conceitos bases que se deve ter em mente para se arquitetar uma CNN. Como já foi comentado, a quantidade de camadas ocultas e de camadas de agrupamento varia de acordo com os objetivos de cada problema e, conseqüentemente, muitos dos parâmetros são determinados empiricamente. Sendo assim, é de escopo deste projeto a determinação desses mesmos parâmetros, de modo que no final seja construída uma rede

capaz de determinar a permeabilidade equivalente de meios porosos heterogêneos com certo grau de confiabilidade satisfatório, a partir da entrada de imagens topográficas desses meios, cuja arquitetura está exemplificada pela Figura 5.




Figura 5 - Exemplo da arquitetura final de uma CNN que ilustra os conceitos bases de qualquer projeto deste tipo.

Dito isso, pode-se identificar três tipos de camadas diferentes na arquitetura da Figura 5. Uma camada de entrada, a qual é responsável por receber dados brutos em sua entrada; camadas escondidas, responsáveis por receber dados de outra camada e passar adiante para camadas diferentes (seja outra camada escondida ou uma camada de saída); e uma camada de saída, a qual é responsável pela predição do modelo.

Segundo Brownlee [11], as camadas escondidas de um único modelo costumam fazer uso de uma mesma função de ativação. E, de acordo com o autor, para redes do tipo CNN, esta deve ser a função de ativação Linear Retificada (ReLU). Devido a sua eficácia, praticidade e simplicidade de implementação. Já para as camadas de saída, em redes do tipo CNN, Brownlee [11] recomenda o uso da função de ativação Linear, por se tratar de um problema de regressão.

3. METODOLOGIA

3.1. Geração dos dados de entrada

Como é observado em Nielsen [10], para se treinar a CNN idealizada, é preciso gerar um conjunto de dados contendo um grande número de imagens das diferentes rochas analisadas e as suas respectivas permeabilidades equivalentes. Uma base de imagens foi disponibilizada a partir de microtomografias de dois plugues de rocha carbonática pelo Laboratório de Micro Hidrodinâmica em Meios Porosos (LMMP), da PUC-Rio. As imagens foram obtidas durante o trabalho de Dali [9], e são o resultado de um processamento digital de todo o plugue que o divide em fatias 2D. Sendo assim, dividiu-se a geração dos dados de entradas em duas etapas, descritas a seguir.

3.1.1. Segmentação das imagens dos meios porosos

Primeiramente, partiu-se da necessidade de uma identificação dos macroporos presentes nas imagens da microtomografia das rochas analisadas. Então, foi feita a segmentação das imagens dos meios porosos, utilizando a biblioteca OpenCV da linguagem Python, com a qual um código foi desenvolvido para a obtenção das imagens binárias.

Com isso, foi possível identificar os contornos presentes nas imagens, como ilustrado na Figura 6. Posteriormente, diferentes domínios para a geração de malhas bidimensionais são identificados utilizando a biblioteca de código aberto pyGmsh, também da linguagem Python. Segundo a metodologia apresentada por Dali [9], nos domínios discretizados que compõem a malha foi aplicado o modelo de Brinkman (eq. 2-7). Isso significa que no domínio que representa a matriz rochosa o escoamento segue a Lei de Darcy (eq. 2-6), enquanto no domínio que representa os macroporos, o obedece à equação de Stokes (eq. 2-5), como mencionado anteriormente.




Figura 6 - Exemplo da segmentação de uma imagem topográfica de um meio poroso.

3.1.2. Formulação numérica do modelo de Brinkman

Com as imagens do meio devidamente segmentadas, ou seja, com as suas bordas e todos os poros ali presentes corretamente demarcados, utilizou-se a biblioteca numérica de código aberto Dolfin, desenvolvida pelo projeto FEniCS [12] para implementar a solução do modelo de Brinkman (eq. 2-7). Essa biblioteca possui funções que permitem a implementação da solução numérica do modelo de Brinkman utilizando método de elementos finitos. Seguindo a forma como a biblioteca Dolfin interpreta o problema, o modelo apresentado anteriormente em equações diferenciais parciais precisa ser convertido para a formulação fraca ou integral. Por meio do seu pacote de funções Python, essa plataforma é de fácil utilização e apresenta bom desempenho para o estudo de mecânica dos fluidos em geometrias complexas, por ser pré-compilada.

Entretanto, por não ser o foco do problema a ser resolvido, o presente trabalho não irá se aprofundar na metodologia matemática dessa implementação numérica. Sendo assim, as equações necessárias para esta etapa foram obtidas do trabalho de Dali [9], que desenvolveu tal metodologia.

Uma vez feitas todas as adaptações necessárias para o problema atual, pôde-se enfim aplicar o modelo de Brinkman no meio poroso analisado. Sendo assim, foi definido um gradiente de pressão imposto e a permeabilidade da matriz rochosa, para que velocidades muito altas não surgissem respeitando a janela de operação do modelo de regime laminar.

Feito isso, finalmente, tem-se o modelo de Brinkman de maneira que o mesmo possa ser simulado sobre uma malha gerada a partir de qualquer imagem de um meio poroso, já segmentada. Na Figura 7 e na Figura 8, pode-se observar o exemplo de comportamento do campo de pressão devido a imposição de uma diferença de pressão aplicada nas extremidades do domínio e, em consequência, o mapa das velocidades no meio, respectivamente. As imagens mostram o escoamento simulado no meio poroso apresentado na imagem segmentada da Figura 6, e com uma pressão aplicada de baixo para cima, como observado na Figura 7.

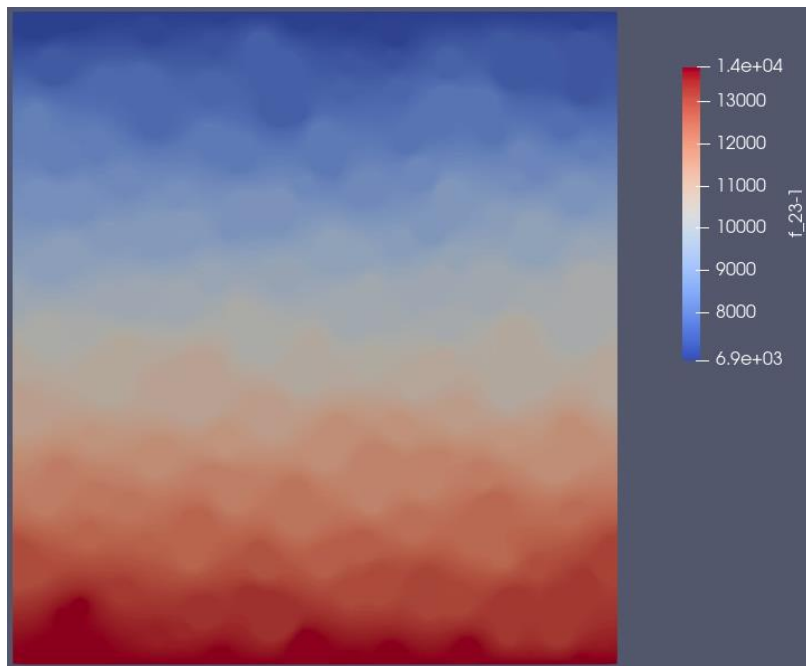


Figura 7 - Exemplo da aplicação de pressão no meio poroso.




Figura 8 - Exemplo do campo de velocidade no meio poroso, decorrente da pressão aplicada.

Ao observar a Figura 8, notam-se as baixas velocidades alcançadas na matriz rochosa (azul escuro) a partir da pressão aplicada. Já as velocidades atingidas nos macro poros do meio são significativamente maiores do que as encontradas na matriz rochosa, como esperado. Cerca de até 100 vezes mais. A permeabilidade equivalente do meio poroso pode ser calculada a partir dos resultados da simulação do escoamento e a utilização da Lei de Darcy.

3.2. Desenvolvimento da arquitetura da CNN

Uma vez desenvolvido todo o processo da geração dos dados de entrada do problema, foi possível, enfim, idealizar a arquitetura da CNN almejada. Para tal, foi preciso ter em mente as premissas deste campo de estudo descritas na seção 2.6.

Antes de começar a planejar o treinamento da rede, para que seja possível, enfim, construir sua arquitetura desejada, é preciso definir os dados de entrada do modelo. Como já foi mencionado, o modelo será alimentado por imagens tomográficas de meios porosos heterogêneos. Todavia, é importante frisar que essas imagens foram divididas em dois grandes grupos, cada um correspondente a uma amostra de rocha carbonática, denominadas por “am5” e “am8”, cada grupo possui uma determinada faixa de macroporosidade e

estrutura dos macroporos. Sendo que esse dois grupos foram subdivididos em quatro tipos, os quais estão relacionados a faixa de valor da macroporosidade. A Figura 9 e Figura 10 exemplificam os diferentes tipos de imagens que foram utilizadas para este estudo. Nestas imagens, a região preta representa os macroporos e a região branca, a matriz porosa, que possui permeabilidade conhecida.



Figura 9 – Exemplos de imagens do grupo “am5”. Em ordem, da esquerda para a direita, tipo c1, tipo c2, tipo c3 e tipo c4.



Figura 10 - Exemplos de imagens do grupo “am8”. Em ordem, da esquerda para a direita, tipo c1, tipo c2, tipo c3 e tipo c4.

Tendo em vista essas subdivisões e tudo o que foi comentado na seção 2.6, decidiu-se por agrupar as subdivisões mais semelhantes dos diferentes grupos. Sendo assim, têm-se quatro conjuntos de subdivisões para cada grupo de imagens. São eles: 1) tipo c1 e c2 do grupo am5; 2) tipo c3 e c4 do grupo am5; 3) tipo c1 e c2 do grupo am8; 4) tipo c3 e c4 do grupo am8. Essa divisão é decorrente da proximidade dos diferentes tipos de cada grupo de imagens, pois se entende que uma rede treinada com imagens do tipo c1 do grupo am5 seria capaz de prever a permeabilidade equivalente de imagens do tipo c2 do mesmo grupo - com um alto índice de confiabilidade - e vice versa.

Com isso, definiu-se uma matriz de testes, exposta na Tabela 1, para que fosse possível encontrar uma arquitetura ótima da rede neural desejada a partir da variação empírica de alguns parâmetros de um modelo sequencial de rede. Sendo assim, de acordo com a documentação oficial do TensorFlow [13],

e tendo em vista o que já foi dito na seção 2.6, entendeu-se que analisar a influência dos parâmetros de treinamento - *Batch Size*, *Split Size* e *Epochs* - seria fundamental para o andamento do trabalho. De acordo com [13], os mesmo podem ser definidos como o número de amostras por iteração do modelo, a proporção pela qual o conjunto de dados de entrada é dividido em dados de treinamento e dados de teste e, por fim, o número inteiro total de iterações do modelo, respectivamente. Os parâmetros que configuram a arquitetura da rede – *Kernel Size*, *Stride* e *Pool Size* – foram revistos na seção 2.6.

Tabela 1 – Diferentes topologias do modelo da rede que serão analisadas.

Model Topology	Kernel size	Stride	Pool size	Batch size	Split size	Epochs
1	256	(5; 5)	(2; 2)	10	0.15	10
	128	(3; 3)	(2; 2)			
	64	(3; 3)	(2; 2)			
2	256	(5; 5)	(2; 2)	10	0.15	20
	128	(3; 3)	(2; 2)			
	64	(3; 3)	(2; 2)			
3	256	(5; 5)	(2; 2)	50	0.15	20
	128	(3; 3)	(2; 2)			
	64	(3; 3)	(2; 2)			
4	256	(7; 7)	(2; 2)	10	0.15	20
	128	(5; 5)	(2; 2)			
	64	(5; 5)	(2; 2)			
5	384	(5; 5)	(2; 2)	10	0.15	20
	192	(3; 3)	(2; 2)			
	96	(3; 3)	(2; 2)			
6	512	(5; 5)	(2; 2)	10	0.15	20
	256	(3; 3)	(2; 2)			
	128	(3; 3)	(2; 2)			
	64	(3; 3)	(2; 2)			

4. RESULTADOS

4.1. Tratamento dos dados de entrada

A base de dados cedida pelo LMMP para a condução dos testes é constituída por 24075 dados de entrada, sendo cada um o par formado por uma imagem tomográfica bidimensional de um meio poroso e a respectiva permeabilidade equivalente determinada numericamente pela solução do escoamento usando o modelo de Brinkman. Tendo em vista a grande quantidade de dados de entrada, entendeu-se como necessário a exclusão daqueles que destoassem de forma significativa da média de seus grupos. Com isso, a quantidade de *outliers* determinados para cada grupo de testes – estabelecidos com base no que foi descrito na Seção 3.2 – pode ser observada na Tabela 2. Nota-se que foram excluídos ao todo 1031 pares de dados do conjunto inicial, restando um total de 23044 pares de dados para continuar o estudo.

Tabela 2 - Tratamento dos dados de entrada.

Amostra	Tipos		Qtd. de dados	1º Quartil	3º Quartil	Qtd. de <i>Outliers</i>	Menor Permeabilidade Equivalente (-)	Maior Permeabilidade Equivalente (-)	Faixa dos valores (-)
5	1	2	6319	1.05	1.10	224	1.02	1.17	0.15
	3	4	5492	1.40	1.83	142	1.22	2.47	1.25
8	1	2	6342	1.29	1.53	491	1.14	1.88	0.74
	3	4	5922	5.21	35.84	174	1.43	81.63	80.20

Ainda na Tabela 2, é possível observar características importantes de cada subdivisão das imagens. Como, por exemplo, o menor e maior valor de permeabilidade equivalente de cada grupo, a diferença entre esses dois valores e os valores limites do primeiro e terceiro quartil, o que possibilita um melhor entendimento de como as imagens estão distribuídas em seus respectivos grupos. Adotou-se, então, como premissa que os testes com base na matriz da Tabela 1, seriam feitos exclusivamente para a subdivisão da amostra Am5 e tipos c1 e c2, que possui a menor faixa de permeabilidade equivalente assumida, minimizando os dados gerados. Todavia, caso o desempenho da rede na predição das permeabilidades das demais subdivisões seja muito aquém do esperado, uma nova configuração de rede deve ser buscada.

4.2. Escolha das topologias ótimas

O desempenho das topologias estabelecidas na matriz de testes, definida na Seção 3.2, pode ser observado na Tabela 3, logo abaixo. A partir destes valores, pode-se concluir que a topologia de melhor desempenho foi a Topologia 2, a qual apresentou o menor desvio padrão, tanto para os dados de treinamento quanto para os dados de teste. Seguida pela Topologia 6 que também apresentou um desempenho bastante satisfatório, embora possua um desvio padrão maior para os dados de treinamento do que a Topologia 5, pois o que vale mesmo é o desempenho para os dados de teste. Todavia, é importante ressaltar que a Topologia 6 demorou cerca de 4 h a mais para terminar o seu treinamento e prever os resultados do que a topologia de melhor desempenho, o que decorre do maior número de camadas de convolução em sua arquitetura.

O desempenho ruim da Topologia 1 é facilmente justificado pela quantidade de épocas de apenas 10 unidades em sua arquitetura. Note que, apenas esse parâmetro foi responsável por tamanha diferença entre essa e a Topologia 2, a de melhor desempenho. Já a Topologia 3 obteve um desempenho longe do desejado exclusivamente pelo valor de *batch size* de sua arquitetura, que é o único parâmetro que a diferencia da topologia de melhor resultado. Por fim, o desempenho abaixo do desejado da Topologia 4 decorre do aumento na camada de *Stride*, visto que valores grandes neste parâmetro acabam por simplificar demais algumas características das imagens de entrada e, conseqüentemente, dificulta o aprendizado da rede, assim como visto na seção 2.6.

Tabela 3 – Desempenho das topologias testadas para a subdivisão do grupo Am5 com tipos c1 e c2.

Topologia	Treinamento			Teste		
	Erro médio (%)	Erro máximo (%)	Desvio Padrão (%)	Erro médio (%)	Erro máximo (%)	Desvio Padrão (%)
1	2.458	5.709	1.034	2.430	7.200	1.040
2	0.821	3.548	0.630	0.826	4.010	0.635
3	1.473	5.813	1.158	1.430	6.260	1.110
4	3.156	6.389	1.093	3.190	6.450	1.030
5	1.609	3.814	0.771	1.610	4.450	0.755
6	0.985	4.927	0.777	0.964	4.360	0.729

Para uma melhor visualização, tem-se da Figura 11 à Figura 13 a correlação dos resultados de cada conjunto de grupos testado logo abaixo de cada tabela. Na Figura 11 é possível observar a dispersão da permeabilidade equivalente estimada com a teórica, na Figura 12 observa-se a distribuição normal dos resultados em função do erro relativo obtido e, por último, na Figura 13 é possível observar a dispersão entre o erro relativo em módulo com a permeabilidade equivalente teórica.

É interessante notar que as topologias de melhor desempenho (Topologias 2 e 6) apresentaram erros relativos significativamente maiores para as permeabilidades equivalentes mais altas, em torno de 1.15 [-], ainda que, no geral, ambas apresentem um erro médio em torno de 1.0 %, o que é excelente e pode ser interpretado como extremamente confiável. Já as demais topologias apresentaram uma dispersão muito mais significativa em seus resultados, tanto para permeabilidades equivalentes mais baixas, em torno de 1.0 [-], quanto para as de maior valor, refletindo em um erro médio consideravelmente maior.

É importante ressaltar que, nos gráficos de dispersão dispostos na Figura 11, entre a permeabilidade equivalente teórica e a prevista pela

configuração da rede neural testada a reta traçada ao longo do gráfico possui uma inclinação equivalente a 45°, pois indica o valor que a permeabilidade equivalente prevista pela rede deveria ter, ou seja, igual à permeabilidade teórica.

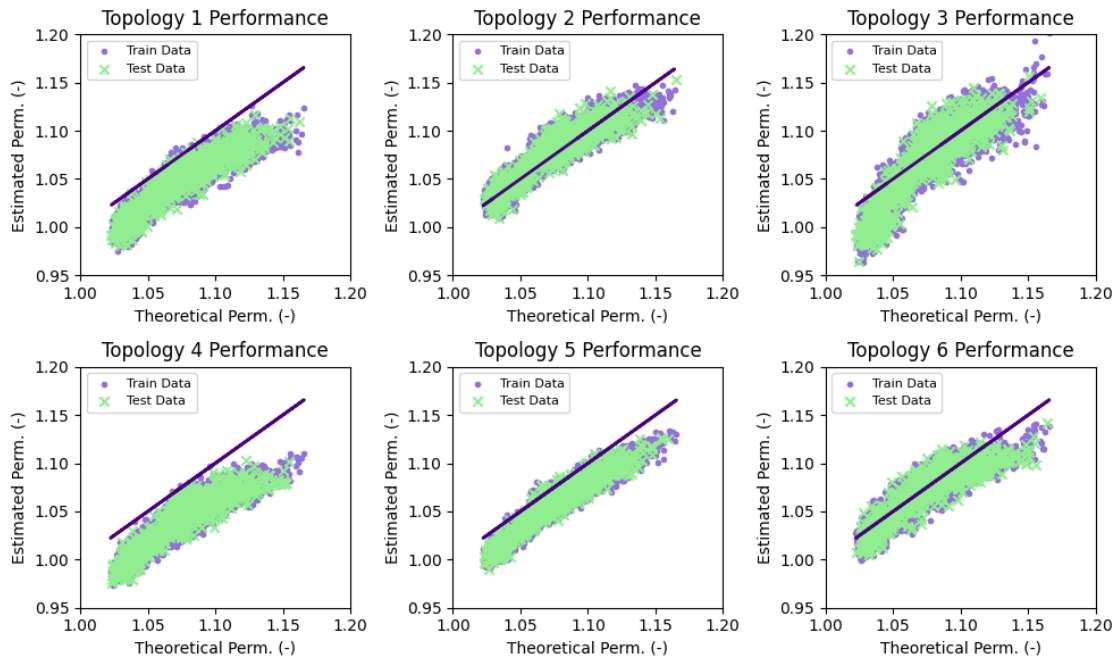


Figura 11 – Gráficos de dispersão entre a permeabilidade equivalente estimada e a teórica de cada topologia testada para o grupo de imagens Am5 e tipos c1 e c2.

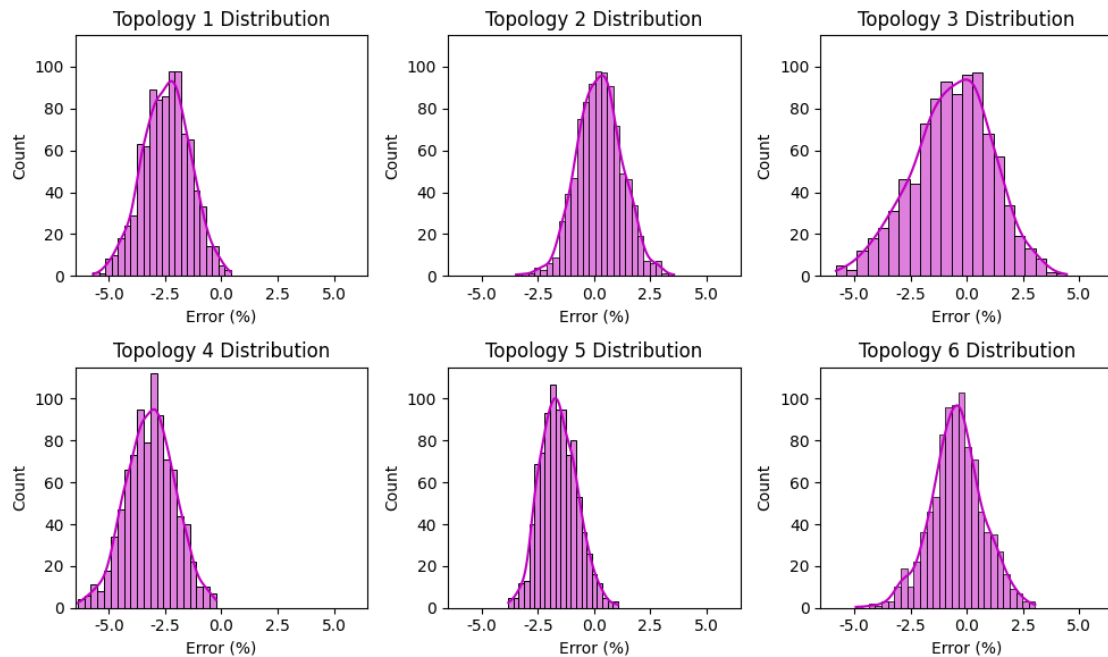


Figura 12 - Gráficos de distribuição normal em função do erro relativo obtido de cada topologia testada.

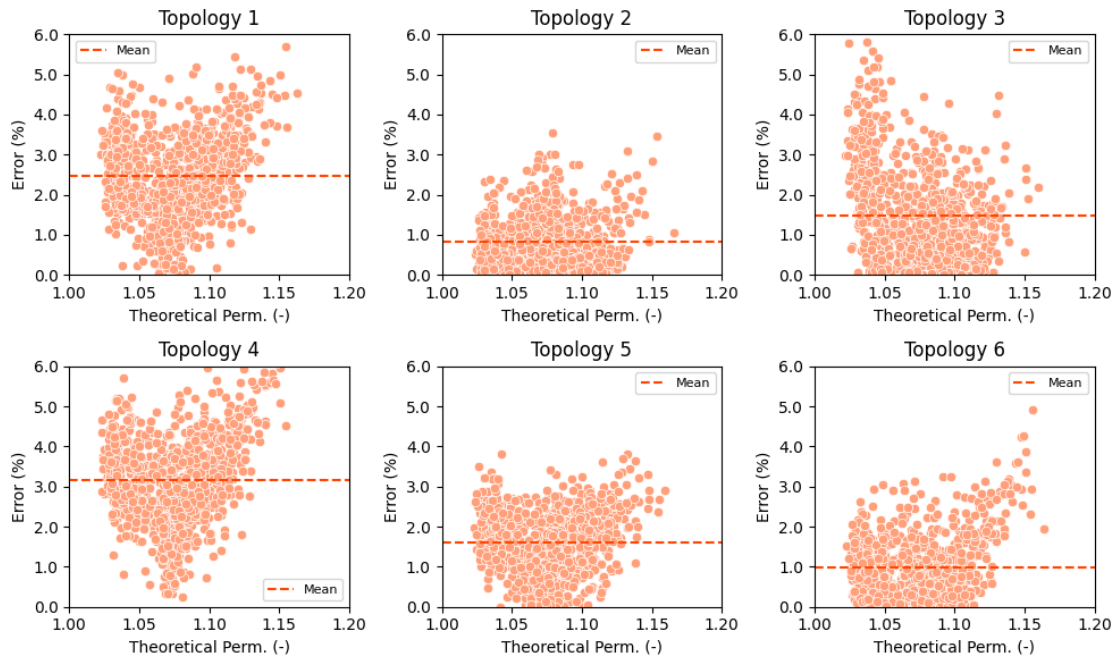


Figura 13 - Gráficos de dispersão entre o erro relativo obtido e a permeabilidade equivalente teórica de cada topologia testada.

4.3. Topologia ótima nos outros grupos restantes

Uma vez estabelecido a Topologia 2 como a topologia ótima, partiu, então, para testá-la nos demais grupos não estudados. Sendo eles o grupo Am5 com tipos c3 e c4, o grupo Am8 com os tipos c1 e c2 e o grupo Am8 com os tipos c3 e c4. O desempenho dos modelos está disposto na Tabela 4.

A partir destes resultados, foi possível observar que a rede desempenhou de forma satisfatória para o primeiro e o segundo grupo de imagens, onde em ambos os casos foi apresentado um desvio padrão em torno de 2.00 %. É importante ressaltar que nestes dois casos as permeabilidades equivalentes ainda podem ser consideradas baixas, embora relativamente mais altas do que quando comparadas com o grupo Am5 e tipos c1 e c2. Mesmo no grupo de imagens Am5 e tipos c3 e c4, onde as permeabilidades atingem valores na ordem de 2.00 [-], a rede acabou desempenhando melhor do que quando treinada para imagens do grupo Am8 e tipos c1 e c2. Logo, pode-se concluir que, de maneira geral, o aprendizado foi melhor para imagens Am5.

Tabela 4 - Desempenho da topologia ótima para os diferentes grupos restantes.

Amostra	Tipos		Topologia	Treinamento			Teste		
				Erro médio (%)	Erro máximo (%)	Desvio Padrão (%)	Erro médio (%)	Erro máximo (%)	Desvio Padrão (%)
5	3	4	2	2.35	13.7	1.96	2.54	58.11	2.84
8	1	2	2	3.24	16.00	2.36	3.23	15.60	2.22
8	3	4	2	92.00	582.00	88.60	97.50	555.50	93.89

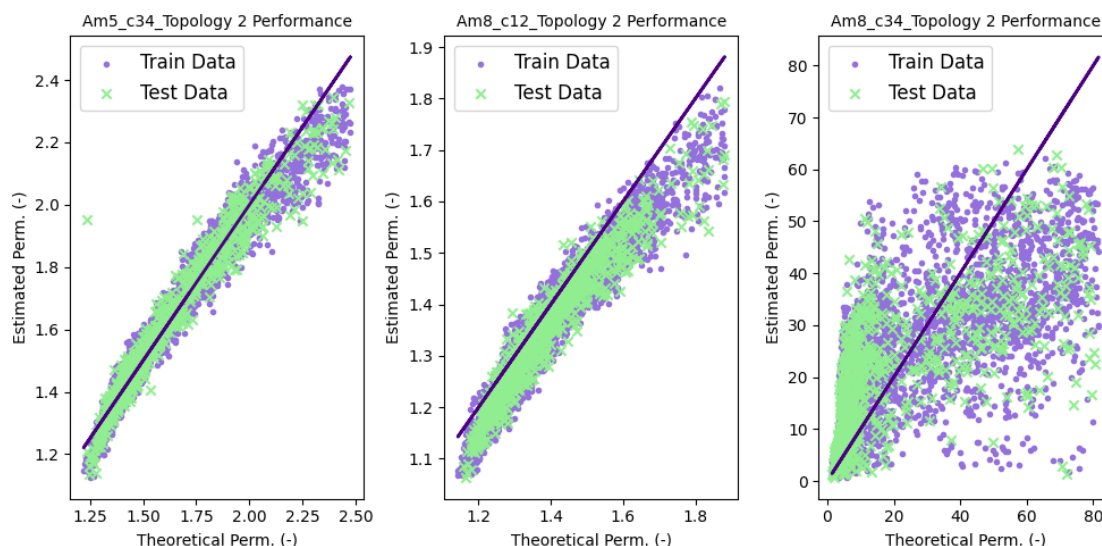


Figura 14 - Gráficos de dispersão entre a permeabilidade equivalente estimada e a teórica de cada topologia testada para os grupos restantes: Am5 e tipos c3 e c4; Am8 e tipos c1 e c2; Am8 e tipos c3 e c4.

Entretanto, o aprendizado da rede para o grupo de imagens Am8 e tipos c3 e c4 pode ser considerado insatisfatório, visto os valores dos parâmetros métricos expostos na Tabela 5. Isso é melhor compreendido ao se analisar a dispersão dos dados pela Figura 14. Na imagem, nota-se que neste grupo de imagens, há imagens com permeabilidades equivalentes até mesmo na ordem de 80.0 [-], ao mesmo tempo em que há imagens com permeabilidades cerca de oitenta vezes menores do que isso. Dito isso, pode-se concluir que a faixa de permeabilidades assumida (Tabela 2) impacta diretamente o aprendizado da rede, ou seja, quanto maior ela for, mais o grupo necessitará de um treinamento mais robusto.

4.4. Treinamento especial

Tendo em vista a faixa de valores assumidos para o grupo da amostra Am8 e tipos c3 e c4 ser equivalente a 80.20 [-], como mostrado na Tabela 2, pode-se entender que este conjunto acaba sendo bem generalizado. Com isso,

ao visar desenvolver uma arquitetura CNN capaz de prever a permeabilidade equivalente desse grupo de imagens, acredita-se que, no final, se terá uma rede neural capaz de prever a permeabilidade equivalente de qualquer imagem. Dessa forma, adotando a mesma metodologia das seções anteriores, foi esquematizada uma nova matriz de testes, exposta logo abaixo na Tabela 5. Levou-se em consideração a arquitetura de melhor desempenho vista anteriormente, a Topologia 2.

Tabela 5 – Diferentes topologias do modelo da rede que serão analisadas para o treinamento especial.

Model Topology	Kernel size	Stride	Pool size	Batch size	Split size	Epochs
2	256	(5; 5)	(2; 2)	10	0.15	20
	128	(3; 3)	(2; 2)			
	64	(3; 3)	(2; 2)			
2a	256	(5; 5)	(2; 2)	10	0.15	100
	128	(3; 3)	(2; 2)			
	64	(3; 3)	(2; 2)			
2b	256	(5; 5)	(2; 2)	10	0.15	500
	128	(3; 3)	(2; 2)			
	64	(3; 3)	(2; 2)			

Para a definição dos parâmetros das topologias, também se levou em consideração que, tendo em vista que desta vez as permeabilidades equivalentes de todas as imagens do conjunto analisado são significativamente mais dispersas, a rede neural demandará muito mais esforço em seu aprendizado. Com isso, adotou-se a tática de um aumento gradual no número de épocas, como é possível perceber na Tabela 5, visando à minimização da função de perda (“*Loss function*”) do modelo, a qual é uma simples “*Mean Square Error*”, muito utilizada neste tipo de problema.

Sendo assim, na Figura 15, é possível observar o desempenho do modelo e como o aprendizado da rede neural cresce à medida que a mesma é exposta a um maior número de épocas. Note que, quanto maior o número de épocas, menor é a função de perda do modelo. E, assim como nas seções anteriores, pode-se observar o desempenho de cada topologia com base em mais parâmetros métricos através da Tabela 6.




Figura 15 – Desempenho do treinamento especial. Gráfico da função de perda do modelo (“Loss Function”) à esquerda e a correlação do erro médio do modelo com o seu número de épocas.

Tabela 6 - Desempenho das topologias testadas para a subdivisão do grupo Am8 com tipos c3 e c4.

Topologia	Treinamento			Teste		
	Erro médio (%)	Erro máximo (%)	Desvio Padrão (%)	Erro médio (%)	Erro máximo (%)	Desvio Padrão (%)
2	92.00	582.00	88.60	97.50	555.50	93.89
2a	38.29	380.94	41.30	40.57	438.07	47.95
2b	15.20	216.00	20.10	21.38	260.60	28.48

Vale a pena mencionar que ao longo dos treinamentos fez-se uso da técnica de *early stopping*, tendo como meta a minimização da função de perda do modelo para um intervalo máximo de 50 épocas, ou seja, caso seu desempenho não melhore neste intervalo, o treinamento é interrompido. Com isso, o modelo foi interrompido na época número 496, podendo concluir que com os demais parâmetros de sua arquitetura, o mesmo não apresentaria um melhor desempenho em um maior número de épocas. Na Figura 16, está a dispersão entre a permeabilidade equivalente teórica e a estimada pela topologia de melhor desempenho desta seção de treinamentos, a Topologia 2b.




Figura 16 – Gráfico de dispersão entre a permeabilidade equivalente teórica e a estimada pela Topologia 2b (esquerda) e a dispersão do erro relativo de cada previsão com a permeabilidade equivalente teórica, para o grupo de imagens da amostra Am8 e tipos c3 e c4.

Ao observar a figura acima nota-se que o desempenho final desse treinamento não pode ser considerado satisfatório, sobretudo por causa de 75% dos dados utilizados para o treinamento desta rede neural se encontrar abaixo de permeabilidades equivalentes teóricas iguais a 35.84 [-], assim como descrito pela Tabela 2.

É preciso, também, ressaltar a importância de analisar o desempenho do modelo pelo erro relativo, ao invés do erro absoluto, pois ao observar a Figura 16, pode-se concluir precipitadamente que o mesmo apresentou um melhor desempenho para as imagens cuja permeabilidade equivalente possui um valor consideravelmente maior. Todavia, isso não poderia ser mais falso, pois o mesmo erro absoluto é relativamente mais significativo para faixas de permeabilidade menores, o que é justamente o que deve ser observado na Figura 16. Sendo assim, mesmo com imagens de permeabilidade equivalente mais baixa e com erros relativos consideravelmente altos em sua previsão, há também imagens de permeabilidade equivalente baixa com erros relativos pequenos em suas previsões.

Dessa maneira, pode-se concluir que o treinamento realizado não conseguiu entregar uma rede neural capaz de generalizar diferentes imagens com as mais variadas permeabilidades equivalentes com o índice de confiabilidade almejado.

4.5. Previsões cruzadas

Como próximo passo do trabalho, optou-se por testar a capacidade dos modelos treinados com imagens nunca antes vistas de subgrupos diferentes daquele utilizado para o conjunto de treinamento. Para isso, foram utilizados os três modelos analisados nas seções anteriores.

O primeiro modelo é característico por ter sido treinado com o subgrupo de imagens cuja faixa de permeabilidade equivalente é a menor dos grupos (Tabela 2), sendo esse a combinação de imagens da amostra Am5 com os tipos c1 e c2, o qual apresentou um excelente desempenho, a partir da configuração imposta pela Topologia 2 (Tabela 1). Tanto para o conjunto de imagens utilizado em seu treinamento, quanto para a parcela dos dados do mesmo subgrupo utilizada para os seus testes. Sendo assim, para testar ainda mais o seu desempenho, escolheu-se o subgrupo formado por imagens da amostra Am5 e tipos c3 e c4. O qual se caracteriza por possuir imagens com permeabilidades equivalentes ligeiramente maiores, nunca antes vistas pelo modelo original. Dito isso, os resultados das previsões podem ser vistos na Figura 17, logo abaixo.

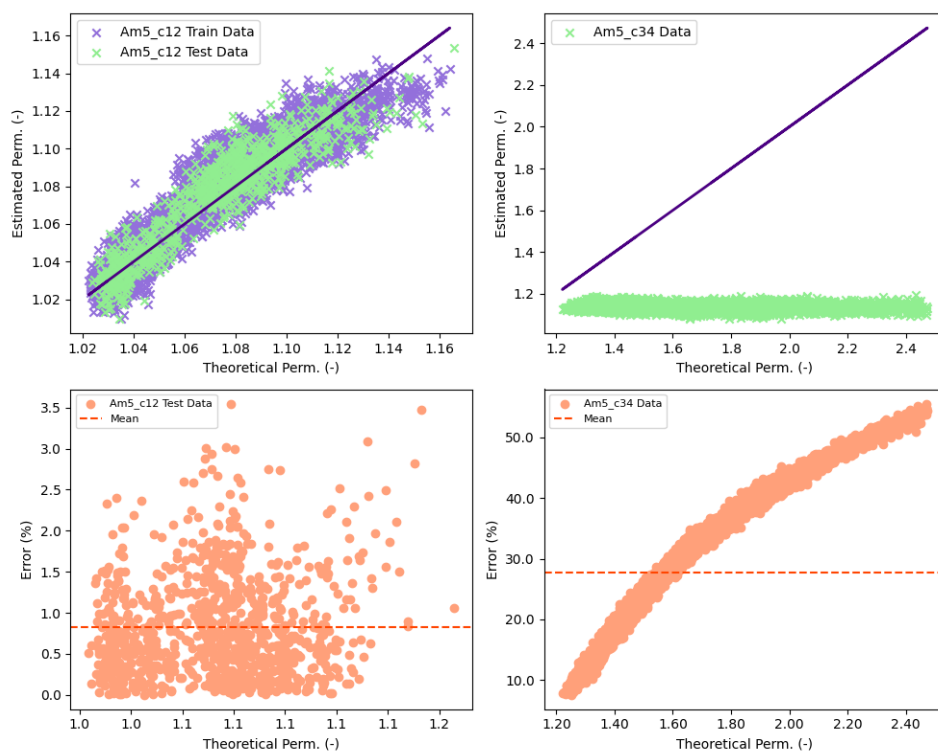


Figura 17 – Uso do modelo treinado com a Topologia 2, a partir de imagens do subgrupo da amostra Am5 e tipos c1 e c2, para prever as permeabilidades equivalentes de imagens do subgrupo da amostra Am5 e tipos c3 e c4.

Ao analisar a Figura 17, é possível concluir que o desempenho foi insatisfatório. Todavia, isso já era esperado, uma vez que o treinamento do modelo foi a partir de imagens com permeabilidades equivalentes ligeiramente menores. É importante reparar que a menor permeabilidade equivalente do subgrupo formado por imagens da amostra Am5 e tipos c3 e c4 é maior do que a maior permeabilidade equivalente já vista pelo modelo, o qual foi treinado com imagens do subgrupo formado pela amostra Am5 e tipos c1 e c2. Dito isso, o modelo não sabe o que são imagens com permeabilidades maiores do que 1.16 [-] e, por isso, a previsão desse tipo de dado com uma alta precisão pode ser classificada como muito improvável.

O segundo modelo aqui analisado também tem sua arquitetura descrita pela Topologia 2 (Tabela 1), só que este foi treinado pelo subgrupo de imagens formado pela amostra Am5 e tipos c3 e c4. Dessa vez, para testar ainda mais o desempenho desse modelo, fez-se uso do subgrupo de imagens formado pela amostra Am8 e tipos c1 e c2. Tal escolha se justifica pela interseção das faixas de permeabilidades equivalentes das imagens de ambos os grupos. Sendo assim, visa-se analisar a capacidade do modelo de prever imagens nunca antes vistas, mas que, em tese, ele é capaz de prever. Os resultados das previsões podem ser observados na Figura 18, logo abaixo.

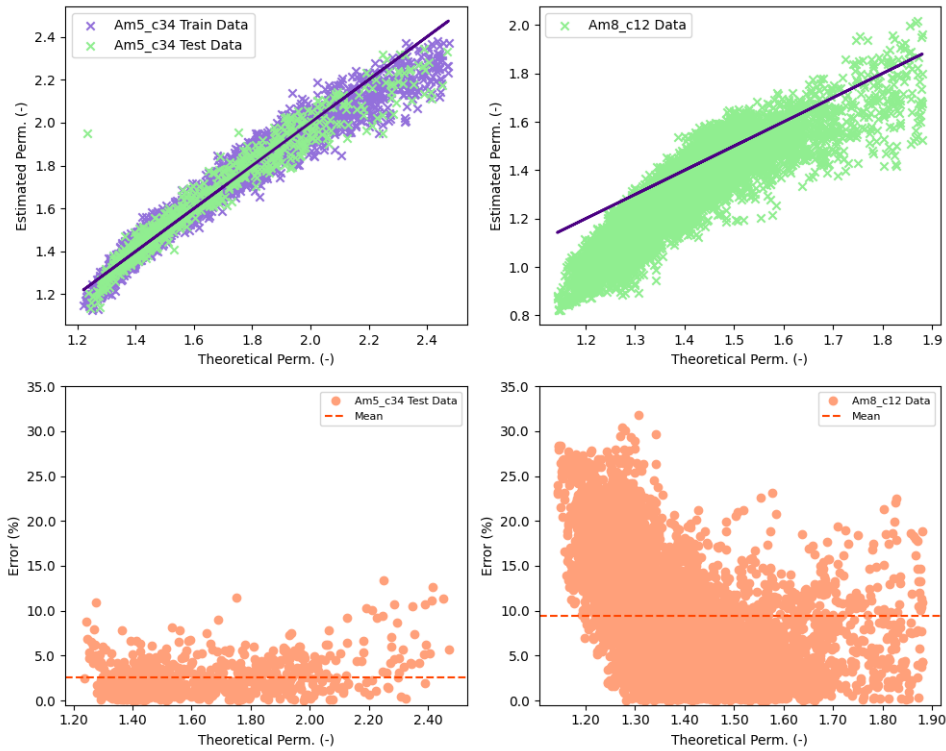


Figura 18 - Uso do modelo treinado com a Topologia 2, a partir de imagens do subgrupo da amostra Am5 e tipos c3 e c4, para prever as permeabilidades equivalentes de imagens do subgrupo da amostra Am8 e tipos c1 e c2.

Ao analisar a Figura 18, é possível observar um maior nível de acerto nas previsões das permeabilidades equivalentes das imagens do subgrupo da amostra Am8 e tipos c1 e c2 para a faixa de valores de permeabilidade que também estão presentes no conjunto de dados utilizados para o treinamento do modelo. Logo, para as imagens cuja permeabilidade é inferior a 1.20 [-], esse que é o menor valor visto durante o treinamento do modelo, é possível perceber que o erro relativo tende a ser bem maior. Entretanto, mesmo sendo possível observar a linearidade do modelo na previsão dos dados, esperava-se um maior índice de acerto para as demais imagens analisadas. Tendo em vista que essas assumem valores de permeabilidade já conhecidos pelo modelo da rede neural.

Por fim, como último modelo, tem-se o treinamento realizado com o subgrupo de imagens com amostra Am8 e tipos c3 e c4, cujo treinamento foi feito utilizando a Topologia 2b (Tabela 6). A escolha por analisar esse modelo se dá pelo fato dele já ter sido treinado com um grupo de imagens que possuem uma faixa de permeabilidade bem maior do que os demais (Tabela 2), ou seja, ao longo de seu treinamento o mesmo foi apresentado a imagens

das mais variadas topografias e, conseqüentemente, permeabilidades equivalentes. Sendo assim, para analisar o seu desempenho, optou-se por utilizar os subgrupos restantes.

É importante ressaltar que os estes subgrupos remanescentes, ou seja, todos com exceção do utilizado para o treinamento do modelo, possuem imagens com permeabilidades equivalentes inferiores e que majoritariamente não tem qualquer relação com as utilizadas para o treinamento do modelo aqui analisado. Com exceção, algumas imagens do subgrupo da amostra Am8 e tipos c1 e c2 e uma boa parcela do subgrupo formado pela amostra Am5 e tipos c3 e c4. Esperou-se, então, que o desempenho da previsão desses dados fosse satisfatório e, por isso, esses também foram analisados separadamente, a fim de mitigar erros propagados. Os resultados das previsões podem ser observados na Figura 19, Figura 20 e Figura 21, para todos os outros subgrupos, exclusivamente para o subgrupo das imagens da amostra Am8 e tipos c1 e c2 e exclusivamente para o subgrupo das imagens da amostra Am5 e tipos c3 e c4, respectivamente.

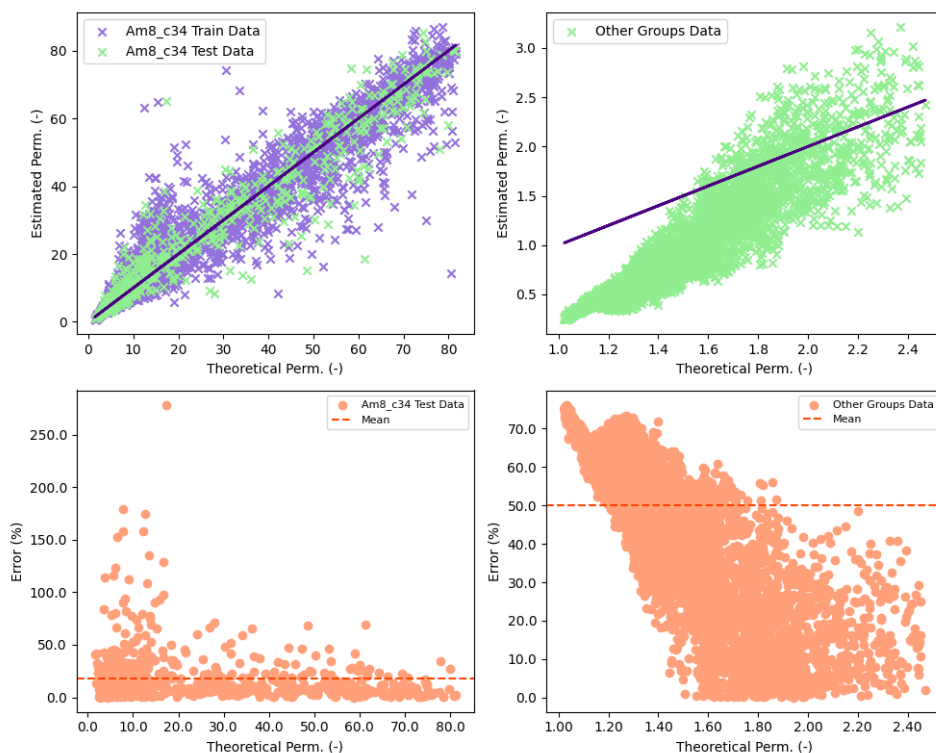


Figura 19 - Uso do modelo treinado com a Topologia 2b, a partir de imagens do subgrupo da amostra Am8 e tipos c3 e c4, para prever as permeabilidades equivalentes de imagens dos demais subgrupos.

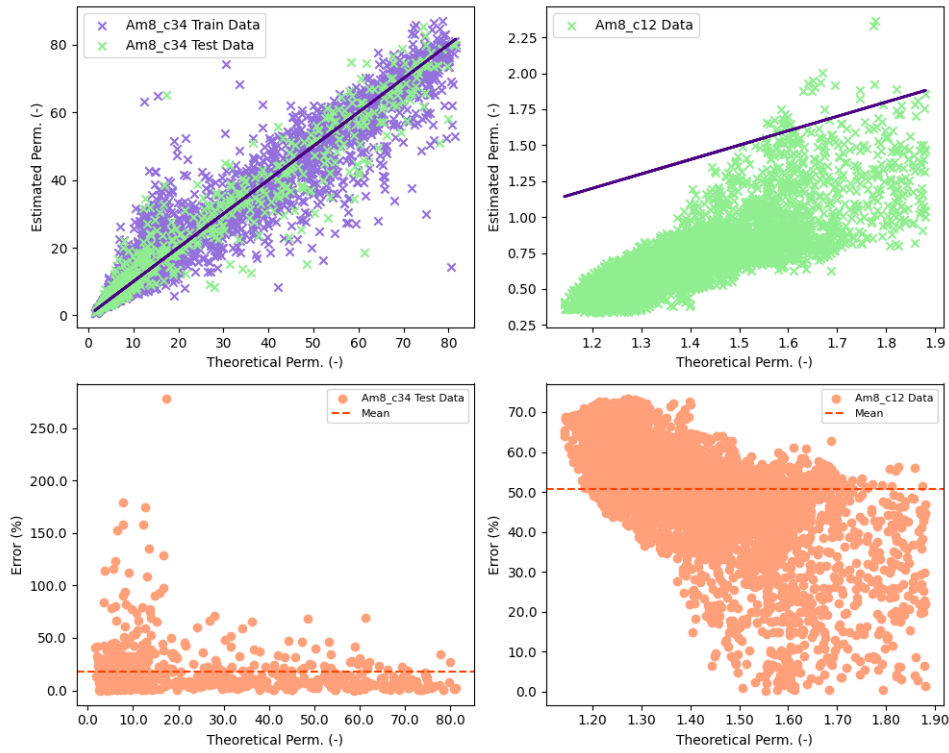


Figura 20 - Uso do modelo treinado com a Topologia 2b, a partir de imagens do subgrupo da amostra Am8 e tipos c3 e c4, para prever as permeabilidades equivalentes de imagens do subgrupo da amostra Am8 e tipos c1 e c2.

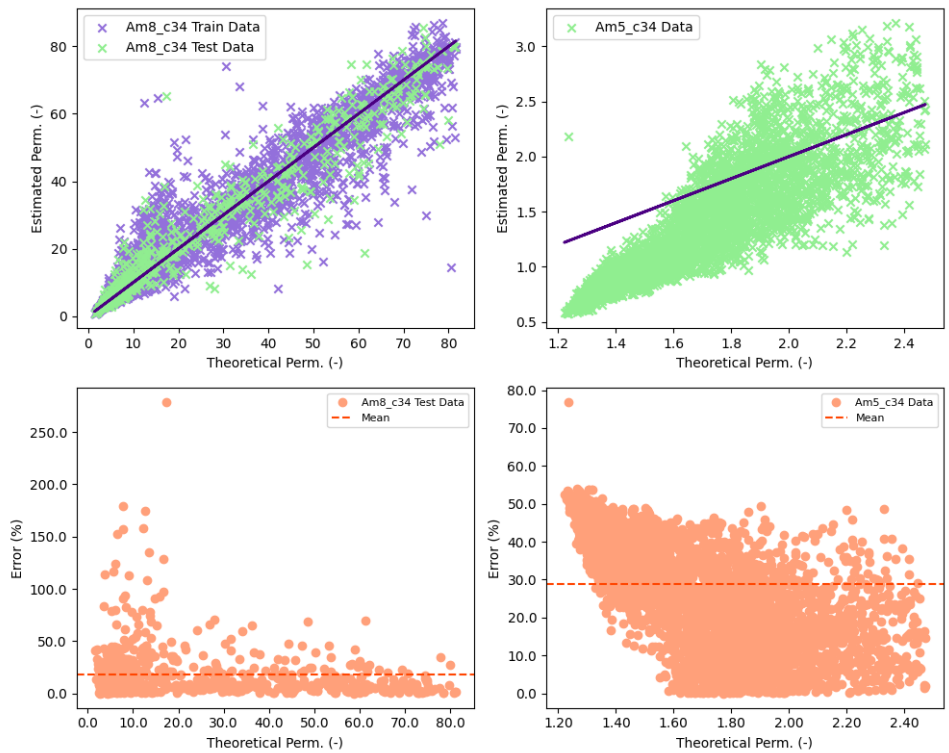


Figura 21 - Uso do modelo treinado com a Topologia 2b, a partir de imagens do subgrupo da amostra Am8 e tipos c3 e c4, para prever as permeabilidades equivalentes de imagens do subgrupo da amostra Am5 e tipos c3 e c4.

Na Figura 19, é possível notar que a previsão para as imagens de permeabilidades equivalentes muito baixas, ou seja, próximas de 1.00 [-] contribuíram significativamente para um fraco desempenho do modelo. E, como essas imagens estão majoritariamente dentro do subgrupo formado pelas imagens da amostra Am5 e tipos c1 e c2, o mesmo foi desconsiderado para as demais análises, enquanto os outros grupos foram analisados exclusivamente.

Dito isso, é interessante notar que a grande maioria das imagens utilizadas para esses testes foi subdimensionada pelo modelo. Pode-se concluir que isso é devido ao treinamento do mesmo ter sido feito com imagens que possuem permeabilidades equivalentes significativamente maiores. Com isso, entende-se que a rede apresenta dificuldade para prever imagens que se concentram numa faixa muito específica de resultados, a qual não foi muito explorada no seu treinamento.

Sendo assim, mesmo notando a linearidade dos valores previstos na Figura 20, é notável que a grande maioria foi estimada abaixo dos valores teóricos, caracterizando um modelo de rede neural subdimensionado. E, na Figura 21, o mesmo fenômeno se repete, embora em menor intensidade. Isso é devido ao fato dos subgrupos compartilharem significativamente mais imagens de permeabilidades equivalentes semelhantes. Entretanto, pode-se observar o mesmo subdimensionamento para as imagens de permeabilidades equivalentes mais baixas e uma dispersão melhor distribuída à medida que os valores de permeabilidade teóricos vão crescendo.

5. CONCLUSÃO

Em suma, o objetivo inicial do trabalho, de construir um modelo de rede neural geral capaz de prever a permeabilidade equivalente de qualquer imagem tomográfica de um meio poroso nunca antes vista com uma alta precisão, não foi atingido. Todavia, a partir das observações feitas ao longo das análises, é possível tirar algumas conclusões interessantes acerca deste tema.

Primeiramente, foi observado na seção 4.5 que, embora um modelo de rede neural fosse capaz de prever as permeabilidades equivalentes com um alto índice de precisão, se o mesmo tiver sido treinado com imagens de permeabilidades que se restringem a uma pequena faixa de valores, o modelo não será capaz de prever novas imagens de permeabilidades que não se assemelham àquelas do treinamento.

Entretanto, é importante ressaltar que caso seja de interesse desenvolver um modelo de rede neural que atue prevendo a permeabilidade equivalente de imagens para uma determinada pequena faixa de valores, foi demonstrado na seção 4.2 que é possível e não demanda muito esforço computacional. Tendo em vista que o treinamento foi realizado com somente 20 épocas, segundo a Topologia 2, da Tabela 1, na seção 3.2.

Em relação às observações feitas na seção 4.4, é possível concluir que quanto maior a faixa de valores assumidos para as imagens utilizadas em um conjunto de treinamento, maior será o esforço computacional demandado para o treinamento da rede neural. Não só isso, mas também, é mais difícil escolher os seus parâmetros, visto que este modelo treinado para o conjunto de dados formados por imagens da amostra Am8 e tipos c3 e c4 não obteve o mesmo índice de confiabilidade do modelo treinado com imagens da amostra Am5 e tipos c1 e c2, da seção 4.2. Nem utilizando a mesma topologia e nem tão pouco com um treinamento cujo número épocas foi consideravelmente maior, fazendo uso da Topologia 2b, da Tabela 5, na seção 4.4.

Por fim, deve-se ressaltar também que o modelo treinado a partir de um conjunto de imagens das mais variadas permeabilidades equivalentes também apresentou o mesmo problema em prever a permeabilidade de imagens nunca

antes vistas cuja permeabilidade não se assemelha às aquelas do treinamento, como foi visto na seção 4.5. Dito isso, recomenda-se para trabalhos futuros que, ao invés de almejar construir um único modelo de rede neural capaz de prever a permeabilidade equivalente de qualquer imagem, buscar desenvolver modelos que atuem em faixas de valores de permeabilidade específicas. Dividindo o grupo de dados de treinamento não exclusivamente pelas características das imagens tomográficas e sim por intervalos de permeabilidades. Acredita-se que dessa maneira o esforço computacional será menor e o produto final será o de diversos modelos, com topologias muito parecidas, senão iguais, capazes de realizar a previsão dos resultados com um alto índice de precisão, como almejado inicialmente neste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Schlumberger the oilfield glossary: Where the oil field meets the dictionary. <https://glossary.oilfield.slb.com/en/terms/k/karst>. Acesso em: 2022-01-09.
- [2] OLIVEIRA, R.; “Finite Element Method Applied to Flow in Heterogeneous Porous Media”; 2014.
- [3] ZAPAROLLI, D.; Produção mais eficaz no pré-sal. Revista Pesquisa FAPESP, ano 21, Ed. 303. <https://revistapesquisa.fapesp.br/producao-mais-eficaz-no-pre-sal/>. Acesso em: 2022-04-18.
- [4] Schlumberger the oilfield glossary: Where the oil field meets the dictionary. <https://glossary.oilfield.slb.com/en/terms/v/vuggy>. Acesso em: 2022-01-09.
- [5] Schlumberger the oilfield glossary: Where the oil field meets the dictionary. https://glossary.oilfield.slb.com/en/terms/p/porous_medium. Acesso em: 2022-01-09.
- [6] Schlumberger the oilfield glossary: Where the oil field meets the dictionary. <https://glossary.oilfield.slb.com/en/terms/p/porosity>. Acesso em: 2022-01-09.
- [7] FOX, R. W.; MCDONALD, A. T.; PRITCHARD, P. J.; Introdução à Mecânica dos Fluidos; 8ª Ed.
- [8] Schlumberger the oilfield glossary: Where the oil field meets the dictionary. <https://glossary.oilfield.slb.com/en/terms/p/permeability>. Acessado: 2022-01-09.
- [9] DALI, M. F.; “Flow in porous media with macropores using Brinkman’s model”; 2019.
- [10] NIELSEN, M. A.; Neural Networks and Deep Learning; Determination Press; 2015.
- [11] BROWNLEE, J.; “Deep Learning With Python”; 2016.
- [12] LOGG, A.; MARDAL, K.; WELLS, Garth N.; “Automated Solution of Differential Equations by the Finite Element Method – The FEniCS Book”; The FEniCS Project; 2011.
- [13] ABADI, M.; AGARWAL, A.; BARHAM, P.; BREVDO, E; CHEN, Z; CITRO, C.; CORRADO, G. S.; DAVIS, A; DEAN, J; DEVIN, M.; GHEMAWAT, S.; GOODFELLOW, I.; HARP, A.; IRVING, G.; ISARD, M.; JOZEFOWICZ, R.; JIA, Y.; KAISER, L.; KUDLUR, M.; LEVENBERG, J.; MANÉ, D.; SCHUSTER, M.; MONGA, R.; MOORE, S.; MURRAY, D.; OLAH, C.; SHLENS, J.; STEINER, B.; SUTSKEVER, I.; TALWAR, K.; TUCKER, P.; VANHOUCHE, V.; VASUDEVAN, V.; VIÉGAS, F.; VINYALS, O.; WARDEN, P.; WATTENBERG, M.; WICKE, M.; YU, Y.; ZHENG, X.; “TensorFlow: Large-scale machine learning on heterogeneous systems”; 2015; Software available from tensorflow.org.