



**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**PREVISÃO DO COEFICIENTE DE PERMEABILIDADE DE SISTEMAS
SOLO INTERNAMENTE INSTÁVEL-FILTRO GEOTÊXTIL
UTILIZANDO REDES NEURAIS ARTIFICIAIS (RNA)**

KATHERINE MIRELLA FLORES BELLIDO

**ORIENTADOR:ENNIO MARQUES PALMEIRA, Ph.D.
CORIENTADOR: FRANCISCO JUNIOR EVANGELISTA, Ph.D.**

**DISSERTAÇÃO DE MESTRADO EM GEOTECNIA
PUBLICAÇÃO G.DM-426/2025**

BRASÍLIA/DF:17/SETEMBRO/2025

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL

**PREVISÃO DO COEFICIENTE DE PERMEABILIDADE DE SISTEMAS
SOLO INTERNAMENTE INSTÁVEL-FILTRO GEOTÊXTIL
UTILIZANDO REDES NEURAIS ARTIFICIAIS (RNA)**

KATHERINE MIRELLA FLORES BELLIDO

**DISSERTAÇÃO DE MESTRADO SUBMETIDA AO DEPARTAMENTO DE
ENGENHARIA CIVIL E AMBIENTAL DA UNIVERSIDADE DE BRASÍLIA COMO
PARTE DOS REQUISITOS NECESSÁRIOS PARA OBTENÇÃO DO GRAU DE
MESTRA EM GEOTECNIA.**

APROVADOR POR:

**ENNIO MARQUES PALMEIRA, Ph.D. (ENC/UnB)
(ORIENTADOR)**

**FRANCISCO EVANGELISTA JUNIOR, Ph.D. (ENC/UnB).
(COORIENTADOR)**

**MARIA DAS GRAÇAS GARDONI ALMEIDA, D.Sc. (UFMG)
(EXAMINADOR EXTERNO)**

**GREGÓRIO LUIS SILVA ARAÚJO, D.Sc. (ENC/UnB).
(EXAMINADOR INTERNO)**

DATA: BRASÍLIA/DF, 2025, 17 de setembro de 2025.

FICHA CATALOGRÁFICA

FLORES, K.M.B.

Previsão do coeficiente de permeabilidade de sistemas solo internamente instável-filtro geotêxtil utilizando redes neurais artificiais (RNA)

, 2025, xiii, 155p, 210x297 mm (ENC/FT/UnB, Mestre, Geotecnia, 2025)

Dissertação de Mestrado – Programa de Pós-Graduação em Geotecnia Universidade de

- | | |
|-------------------|----------------------------------|
| 1. Permeabilidade | 2. Redes Neural Artificial (RNA) |
| 3. Geotêxtil | 4. Contato com solos instáveis |
| I. ENC/FT/UNB | II. MESTRE |

REFERÊNCIA BIBLIOGRÁFICA

FLORES, K.M.B (2025). Previsão do coeficiente de permeabilidade de sistemas solo internamente instável-filtro geotêxtil utilizando redes neurais artificiais (RNA). Publicação G.DM-426/2025, Dissertação de Mestrado. Departamento de Engenharia Civil e ambiental, Universidade de Brasília, Brasília, DF, 155p.

CESSÃO DE DIREITOS

NOME DO AUTORA: Katherine Mirella Flores Bellido

TÍTULO DA DISSERTAÇÃO DE MESTRADO: Previsão do coeficiente de permeabilidade de sistemas solo internamente instável-filtro geotêxtil utilizando redes neurais artificiais (RNA)

GRAU/ANO: Mestre /2025

É concebida à Universidade de Brasília a permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicas e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação do mestrado pode ser reproduzida sem a autorização por escrito do autor.

Katherine Mirella Flores Bellido
QE 19 conjunto L, CEP: 71050-123 –
Brasília/DF-Brasil
E-mail: katherine.mirella.florres@gmail.com

DEDICATÓRIA

Para mi familia

AGRADECIMENTOS

A realização deste trabalho é resultado do apoio e do incentivo de muitas pessoas. Gostaria de expressar minha profunda gratidão a todos que, direta ou indiretamente, contribuíram para esta jornada.

Em primeiro lugar, agradeço a Deus por me conceder a força, a sabedoria necessária para chegar até aqui e por colocar pessoas maravilhosas no meu caminho.

Essa conquista é dedicada à minha família. Aos meus pais, César Hugo e Mirella, e à minha irmã Greta e sobrinha Arianna por todo o amor incondicional, força e por serem meu porto seguro.

Agradeço imensamente aos meus orientadores. Ao Professor Ennio Palmeira, por sua orientação e ensinamentos, por ser uma fonte de inspiração e por nossas incríveis conversas e anedotas. E ao meu coorientador, Professor Francisco Evangelista por seu apoio, paciência e conhecimentos que foram fundamentais. Sem vocês dois, a elaboração deste trabalho não teria sido possível.

Meu reconhecimento se estende ao Programa de Pós-Graduação em Geotecnia da Universidade de Brasília e à CNPq, que forneceram o suporte fundamental para a execução desta pesquisa. Agradeço também a todos os professores do departamento por seu empenho em fomentar o ensino e a pesquisa, todos vocês foram fonte de inspiração.

Aos amigos que o programa me deu Ágatha, Carlos, Maria Clara, Felipe e Rafael meu sincero obrigado por compartilharem as alegrias e os desafios durante todo esse tempo. e por serem uma fonte de apoio inestimável. Meu agradecimento se estende a Marcelo, Cristian, Ana Luiza, Aninha, Flávia, Sarinha, Mateus e Xande, que se tornaram minha família no Brasil e me apoiaram incansavelmente durante toda essa caminhada.

Por fim, meu carinho e gratidão aos meus tios, Gessilvada e Ailton, que me acolheram com tanto amor e me deram a força que eu precisava.

Muito obrigadas a todos vocês.

ABSTRACT

The use of geotextile filters in geotechnical engineering and environmental protection works has increased in recent decades due to the advantages in project execution and environmental preservation, reducing the use of natural materials such as sands and gravels. However, concerns about their long-term performance, such as reduced permeability and clogging, persist. The behaviour of a geotextile filter is influenced by various conditions, especially soil type, particularly in internally unstable soils, where suffusion can compromise filter performance. Therefore, it is necessary to seek alternative methods for predicting filter behaviour under such conditions. This dissertation proposes the use of Artificial Neural Network (ANN) to predict the permeability of soil-geotextile systems based on 352 research results. A Multilayer Perceptron (MLP) architecture was used to configure the model, and the Backpropagation (BP) algorithm was adopted. In addition, multiple linear regression (MR) and ANN predictions for the permeability coefficient of internally unstable-soil systems were compared. The accuracy of the ANN and MR methods was compared using statistical tools. The results obtained show that these techniques can satisfactorily predict the permeability coefficient of internally unstable-geotextile filter systems.

KEYWORDS: Artificial Neural Network (ANN), Geotextile, Internally Unstable Soils, Multiple Linear Regression (MR)

RESUMO

O uso de filtros geotêxteis em atividades de engenharia geotécnica e proteção ambiental tem sido crescente nas últimas décadas devido às vantagens na execução de empreendimentos e na preservação ambiental, reduzindo o uso de materiais naturais como areia e brita. No entanto, preocupações sobre seu desempenho a longo prazo, como a redução de permeabilidade e colmatação, persistem. O comportamento de um filtro geotêxtil pode ser influenciado por diversas condições, especialmente o tipo de solo, sobretudo em solos internamente instáveis, onde a suflação pode comprometer o seu desempenho. Portanto, é necessário buscar métodos alternativos de previsão de comportamento sob tais condições. Esta dissertação investigou o uso de Rede Neural Artificial (RNA) para prever a permeabilidade do sistema solo-geotêxtil com base em 352 resultados de ensaios de laboratório obtidos por diferentes autores. Foi utilizada uma arquitetura de *Perceptron Multicamada* (PMC) para configurar o modelo e adotou-se o algoritmo de Retropropagação (RP). Além disso, previsões por regressão linear múltipla (RM) e RNA para a permeabilidade de sistemas solo internamente instável-geotêxtil foram comparadas. As acurárias dos métodos RNA e RM foram avaliadas por meio de técnicas estatísticas. Os resultados obtidos mostram que tais técnicas podem ser utilizadas para prever satisfatoriamente o coeficiente de permeabilidade de sistemas solo internamente instável-filtro geotêxtil.

PALAVRAS-CHAVE: Rede Neural Artificial (RNA), Geotêxtil, Solos internamente instáveis, Regressão Múltipla (RM)

LISTA DE FIGURAS

Figura 2.1:Tipo de Geotêxtil: (a) Tecido (GT) e (b) Não Tecido (GNT) (Freitas,2003).....	7
Figura 2.2-Filtro Granular vs. Filtro Geotêxtil (Modificado de Palmeira, 2023).	7
Figura 2.3: Ensaios diretos e indiretos para determinação de abertura de infiltração do geotêxtil (Palmeira, 2003)	13
Figura 2.4- Representação da permissividade (Palmeira, 2003).....	14
Figura 2.5: Representação da Transmissividade (Adaptado de Palmeira & Gardoni, 2002)..	15
Figura 2.6- Mecanismo de colmatação física: (a) Bloqueamento; (b)Cegamento; e (c) Obstrução interna (Adaptado de Markiewicz <i>et al.</i> , 2022).	17
Figura 2.7: Curvas granulométricas típicas de solos internamente instável (Adaptado de Chang e Zhang, 2013).	18
Figura 2.8: Tipos de Aprendizagem.....	21
Figura 2.9: Funcionamento básico da Aprendizagem Supervisionada (Adaptada de Escovedo & Koshiyama, 2020)	23
Figura 2.10: Exemplificação de RNA.....	26
Figura 2.11: Exemplos dos Elementos principais da RNA: (a) Arquitetura de rede; (b) algoritmo de aprendizagem; (c) função de ativação.....	27
Figura 2.12: Representação esquemática de um neurônio artificial (Villamil González 2023).	27
Figura 2.13: Arquiteturas de Redes Neurais Artificiais (Braga et al.,2007)	30
Figura 2.14: (a)RNA monocamada e (b) RNA multicamada (MLP) (Adaptado de Villamall,2024)	32
Figura 2.15: Algoritmo de Retropropagação ou <i>Back-propagation</i> (Adaptado de Braga et al.,2007).....	37
Figura 2.16:Equação e Gráfico da Função Sígnioide.....	38
Figura 2.17 — Gráfico e Equação da Função <i>Tanh</i>	39
Figura 2.18: Equação e Gráfico da Função ReLU	39
Figura 2.19: Distribuição do uso de diferentes técnicas de IA na engenharia geotécnica em nove áreas de aplicação (Adaptado de Baghani et al.,2022)	43
Figura 3.1: Metodologia Geral adotada em este estudo.	47
Figura 3.2: Passos para desenvolvimento do modelo RNA adotado neste estudo.....	48
Figura 3.3 :Ilustração de 3 iteração do algoritmo de otimização bayesiano (modificado de	

Brochu et al., 2010)	59
Figura 3.4 — Gráfico dos valores reais versus os valores previstos	64
Figura 3.5: Técnica de Importância de Atribuição por Permutação (PFI) (Modificado de Carvalho, 2025).....	67
Figura 3.6: Exemplificação gráfica do <i>overfitting</i> , <i>underfitting</i> e <i>justfitting</i>	68
Figura 3.7: Esquema do Treinamento de uma Rede Neural Artificial.....	69
Figura 3.8: Divisão da base de dados em conjuntos de treinamento, validação e teste.	69
Figura 3.9: Método da Parada Antecipada com conjunto de validação (Adaptado de Haykin, 1999).....	70
Figura 4.1 :Distribuição de dados presentes e ausentes nas variáveis do conjunto de dados ..	75
Figura 4.2– Matriz de Coeficiente de correlação de Pearson considerando 16 parâmetros de entrada	92
Figura 4.3: Influência dos parâmetros de entrada segundo o coeficiente de Pearson (ρ_r).....	93
Figura 4.4– Matriz do Coeficiente de correlação de Pearson dos fatores de influência e dos resultados laboratoriais de permeabilidade do sistema solo/geotêxtil do Modelo 1	96
Figura 4.5: Influência dos parâmetros de entrada segundo o coeficiente de Pearson (ρ_r) para o Modelo 1	97
Figura 4.6– Coeficiente de correlação de Pearson dos fatores de influência e dos resultados laboratoriais de permeabilidade do sistema solo/geotêxtil do Modelo 2 – Solos com concavidade para cima	100
Figura 4.7: Influência dos parâmetros de entrada segundo o coeficiente de Pearson (ρ_r) para o Modelo 2	101
Figura 4.8– Coeficiente de correlação de Pearson dos fatores de influência e dos resultados laboratoriais de permeabilidade do sistema solo/geotêxtil – Solos <i>Gap-Gradded</i>	103
Figura 4.9: Influência dos parâmetros de entrada segundo o coeficiente de Pearson (ρ_r) para o Modelo 3	104
Figura 4.10: Valores Observados e Previstos pelo Modelo RNA- Para todos os tipos de solos na fase de treinamento e na fase de teste.....	108
Figura 4.11: Gráfico de correlação dos valores reais e previstos da permeabilidade final do sistema (k_{sys-o}) em RNA com modelo de 3 camadas ocultas e 10 neurônios de entrada: (a) Fase de treinamento e (b) Fase de teste.	110
Figura 4.12: Comparação entre Valores Observados e Previstos pelo Modelo RNA - Solos com concavidade para cima na fase de treinamento e na fase de teste	111
Figura 4.13: Gráfico de correlação dos valores reais e previstos da permeabilidade final do	

sistema (k_{sys}) em RNA com Modelo 2 de 3 camadas ocultas e 9 neurônios de entrada: (a) Fase de treinamento e (b) Fase de teste.....	112
Figura 4.14: Comparação entre Valores Observados e Previstos pelo Modelo RNA - Solos descontínuos na fase de treinamento e na fase de teste.....	114
Figura 4.15: Gráfico de correlação dos valores reais e previstos da permeabilidade final do sistema (k_{sys}) em RNA com Modelo de 3 camadas ocultas e 9 neurônios de entrada: (a) Fase de treinamento e (b) Fase de teste.....	115
Figura 4.16: Importância dos Parâmetros de Entrada no Modelo 1 de Rede Neural (Análise de ΔMSE)- Todos os solos.....	116
Figura 4.17: Importância dos Parâmetros de Entrada no Modelo 2 de Rede Neural (Análise de ΔMSE)- Solos com concavidade para cima (Solos CC).	117
Figura 4.18: Importância dos Parâmetros de Entrada no Modelo 3 de Rede Neural (Análise de ΔMSE)- Solos Descontínuos (Solos GG)	118
Figura 4.19: Valores reais, previstos e residuais para Modelo 1 (Todos os solos) de 3 camadas ocultas e 10 parâmetros de entrada: (a) Fase de Treinamento e (b) Fase de Teste	122
Figura 4.20: Valores reais, previstos e residuais para Modelo 2 (Solos CC) de 3 camadas ocultas e 9 parâmetros de entrada: (a) Fase de Treinamento e (b) Fase de Teste	122
Figura 4.21: Valores reais, previstos e residuais para Modelo 3 (Solos GG) de 2 camadas ocultas e 9 parâmetros de entrada: (a) Fase de Treinamento e (b) Fase de Teste	123
Figura 4.22: Histograma dos valores absolutos para o Modelo 1: (a) Fase de Treinamento, 5 de 179 dados (b) Fase de Teste, 2 de 45 dados	124
Figura 4.23: Histograma dos valores absolutos para o Modelo 2: (a) Fase de Treinamento, 5 dados de 119 (b) Fase de Teste, 1 de 30.....	125
Figura 4.24: Histograma dos valores absolutos para o Modelo 3 (Solos GG): (a) Fase de Treinamento, 3 de 60, (b) Fase de Teste, 2 de 15.	126
Figura 4.25: Gráfico de dispersão mostrando a relação entre previsões e resíduos (erros) do Modelo 1 (Todos os Solos): (a) Valores de Treinamento, 5 de 179 (b) Valores de Teste, 2 de 45.4.26.....	127
Figura 4.27: Gráfico de dispersão mostrando a relação entre previsões e resíduos (erros) do Modelo 2 (Solos com Concavidade para Cima):): (a) Valores de Treinamento, 5 de 119 (b) Valores de Teste, 1 de 45.	128
Figura 4.28: Gráfico de dispersão mostrando a relação entre previsões e resíduos (erros) do Modelo 3 (Solos Descontínuos): (a) Valores de Treinamento, 2 de 60 (b) Valores de Teste, 2 de 15.	129

Figura 4.29: k_{sys} previsto versus k_{sys} medido – Para todos os solos com concavidade para cima (Modificado de Palmeira et al., 2025)	133
Figura 4.30: k_{sys} previsto versus k_{sys} medido – Para todos os solos com concavidade para cima com $k_{sys-o} < 2,00 \times 10^{-3}$ cm/s (Modificado de Palmeira et al., 2025)	134
Figura 4.31: k_{sys} previsto versus k_{sys} medido – Para os solos descontínuos (Modificado de Palmeira et al., 2025).....	135
Figura 4.32: Valores previstos pelo modelo e os valores medidos para os dois tipos de solos (Modelo 1) com a metodologia RNA.....	137
Figura 4.33– Comparação entre os valores previstos pelo modelo e os valores medidos- solos com concavidade para cima	138
Figura 4.34:Comparação entre os valores previstos pelo modelo e os valores medidos- solos descontínuos.	139

LISTA DE TABELAS

Tabela 2.1-Principais Funções do Geossintéticos (Adaptado de Palmeira, 2018).....	5
Tabela 2.2-Avaliação da criticidade e severidade (Modificado de Carroll, 1983, Palmeira, 2018).....	10
Tabela 2.3: Fatores que influem no comportamento do filtro geotêxtil (Adaptado de Rollin & Lombard, 1988).....	15
Tabela 2.4: Outros critérios para verificação do potencial de instabilidade do solo (Modificado de Palmeira 2018).....	20
Tabela 2.5: Tipos de algoritmos de aprendizagem supervisionada (Modificado de Al-Atroush, 2024).....	22
Tabela 2.6: Tipos de aprendizagem não supervisionada (Adaptado de Géron, 2019; Al-Atroush, 2024).....	24
Tabela 2.7: Tipos de aprendizagem reforçada (Modificada de Géron, 2019; Al-Atroush, 2024)	
.....	25
Tabela 2.8: Critério para Selecionar o Número de Neurônios na Camada Oculta (modificado de Park,2011)	35
Tabela 2.9: Seleção de parâmetros de entrada e saída para modelos de IA em diferentes áreas da engenharia geotécnica (Liu et al., 2024)	40
Tabela 3.1: Quantidades de dador por trabalho.....	50
Tabela 3.2 — Parâmetros iniciais de interesse.....	51
Tabela 3.3 — Quantidade de dados iniciais por parâmetros	51
Tabela 3.4 — Quantidade de dados finais por parâmetros	53
Tabela 3.5 — Modelos a serem desenvolvidos.....	54
Tabela 3.6 — Faixas de valores para interpretação do coeficiente de correlação de Pearson (Schober et al.,2018).	55
Tabela 3.7: Hiperparâmetro otimizados e seus espaços de busca	57
Tabela 4.1 :Dados estatísticos dos parâmetros de entrada	76
Tabela 4.2 : Dados estatísticos dos parâmetros de entrada considerando os solos descontínuos e com concavidade para cima.....	80
Tabela 4.3: Dados estatísticos dos parâmetros de saída considerando os solos mal graduados e com concavidade para cima	80
Tabela 4.4 — Dados estatísticos dos parâmetros de entrada considerando os solos com	

concavidade para cima	85
Tabela 4.5: Dados estatísticos do parâmetro de saída considerando os solos mal graduados e com concavidade para cima	85
Tabela 4.6: Dados estatísticos dos parâmetros de entrada considerando os solos mal graduados (<i>gap graded</i>)	88
Tabela 4.7 — Dados estatísticos do parâmetro de saída considerando os solos descontínuos (<i>gap gradded</i>)	88
Tabela 4.8: Faixas de Correlação de Pearson para os 16 parâmetros de entrada em relação a permeabilidade final do sistema k_{sys}	93
Tabela 4.9: Faixas de Correlação de Pearson para os 10 parâmetros de entrada em relação a permeabilidade final do sistema k_{sys} (Modelo 1)	97
Tabela 4.10: Faixas de Correlação de Pearson para os 10 parâmetros de entrada em relação a permeabilidade final do sistema k_{sys} (Modelo 2)	101
Tabela 4.11: Faixas de Correlação de Pearson para os 9 parâmetros de entrada em relação a permeabilidade final do sistema k_{sys} (Modelo 3)	104
Tabela 4.12: Arquitetura Ótima para cada modelo de treinamento de RNA	107
Tabela 4.13: Número de dados para as fases de treinamento/ teste por modelo.....	108
Tabela 4.14: Métricas de avaliação de regressão do modelo preditivos de k_{sys} do conjunto de Modelo 1	110
Tabela 4.15: Métricas de avaliação de regressão do modelo preditivos de k_{sys} do conjunto de Modelo 2	113
Tabela 4.16: Métricas de avaliação de regressão do modelo preditivo de k_{sys} do conjunto de Modelo 3	115
Tabela 4.17 –Faixa de aceitação dos erros residuais estabelecidos por análise estatística.	120
Tabela 4.18: Faixas de Aceitação dos Erros Residuais para a Fase de Treinamento.....	120
Tabela 4.19: Faixas de Aceitação dos Erros Residuais para a Fase de Teste	120
Tabela 4.20: Análise de sensibilidade usando RNA para a fase de treinamento	130
Tabela 4.21: Análise de sensibilidade usando RNA para a fase de teste4.22	130
Tabela 4.23: Resumo da comparação entre os modelos de MR e RNA	140

LISTA DE SIMBOLOS, NOMENCLATURA E ABREVIACÕES

ABNT	ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS
IA	Inteligência Artificial
RNA	Redes Neurais Artificiais]
BOA	Algoritmo de Otimização Bayesiano
BP	Algoritmo de <i>Back-Propagation</i>
CA	Área de contato
CV	Coeficiente de Variação
DE	Algoritmo de Evolução Diferencial
GCE	Geocélula
GDP	Tubulação de Drenagem
GGR	Geogrelha
GM	Geomembrana
GMA	Geomanta
GN	Georede
GTX-K	Geotêxtil Tricotado
GTX-NW	Geotêxtil Não Tecido
GTX-W	Geotêxtil Tecido
HPO	Otimização de Hiperparâmetros
MAE	Erro Absoluto Médio
MAPE	Erro Percentual Absoluto Médio
ML	<i>Machine Learning</i>
MLP	<i>Multi-Layer Perceptron</i>
MSE	Erro Quadrático Médio
PP	Polipropileno
PCM	Perceptron multicamadas
R	Correlação
ReLU	Função Unitária Retificada
RF	<i>Random Forest</i>
RMSE	Raiz do Erro Quadrático Médio
SVM	Support Vector Machine

C_c	Coeficiente de Curvatura
C_u	Coeficiente de Uniformidade
d_{10}	Diâmetro da partícula do solo base para 10% passando
d_{15}	Diâmetro da partícula do solo base para 15% passando
d_{30}	Diâmetro da partícula do solo base para 30% passando
d_{50}	Diâmetro da partícula do solo base para 50% passando ou Diâmetro médio do solo [mm]
d_{60}	Diâmetro da partícula do solo base para 60% passando
d_{85}	Diâmetro da partícula do solo base para 85% passando
FOS	Filtration Opening Size
i_{sys}	System (soil + geotextile) gradient used in the test
k_{sys0}	Coeficiente de permeabilidade inicial do Sistema solo-geotextil
k_{sys}	Coeficiente de permeabilidade (após o ensaio) do Sistema solo-geotextil
LS	Espesura do solo em contato[mm]
M_A	Gramatura do geotêxtil [g/cm^2]
t_{GT}	Espessura do Geotêxtil [mm]
σ_v	Tensão normal vertical no topo do solo base durante o ensaio de infiltração [kPa]
ρ_r	Coeficiente de Correlação de Pearson
f	Função de ativação da RNA
i, j, k	Nó ou neurônio do RNA
l	Camada de RNA
θ_o	Bias de RNA
X_i	Valor de entrada da RNA
X_{norm}	Valor de ANN input normalised value

$\hat{y}_{l,j}$	Valor de saída da RNA
y_i	Valor atual
E	Modelo de predição de Erro de RNA
w_{ij}	Pesos de Sinapse da RNA
d	BP desired response
e	BP error sinal
ξ	BP error energy
ξ_{av}	BP average error energy
t	BP iteration
N	BP total de iterações
m	BP number of input values
η	BP learning rate
μ	BP momentum coefficient
Δw_{ji}	BP synaptic weight correction
δ_j	BP local gradient for hidden neuron j
δ_k	BP local gradient for output neuron k

SUMÁRIO

1	INTRODUÇÃO	1
1.1	OBJETIVOS.....	2
1.2	ESTRUTURAÇÃO DA DISSERTAÇÃO	3
2	REVISÃO BIBLIOGRÁFICA.....	5
2.1	FUNÇÕES E APLICAÇÕES DE GEOSSINTÉTICOS.....	5
2.2	FILTRO GEOTÊXTIL.....	6
2.2.1	PROPRIEDADES DO GEOTÊXTIL	10
2.2.1.1	PROPRIEDADES FÍSICAS	11
2.2.1.2	PROPRIEDADES HIDRÁULICAS	12
2.3	FATORES QUE INFLUENCIAM O COMPORTAMENTO DO GEOTÊXTIL	15
2.4	FILTRO GEOTÊXTIL EM SOLOS INTERNAMENTE INSTÁVEIS	17
2.5	APRENDIZAGEM DE MÁQUINA (ML).....	21
2.5.1	TIPOS DE APRENDIZAGEM.....	21
2.5.1.1	APRENDIZAGEM SUPERVISIONADA.....	22
2.5.1.2	APRENDIZAGEM NÃO SUPERVISIONADA	24
2.5.1.3	APRENDIZAGEM REFORÇADA	25
2.6	NEURAL ARTIFICIAL (RNA).....	25
2.6.1	ARQUITETURA DA REDE NEURAL.....	30
2.6.2	PERCEPTRON DE MÚLTIPLAS CAMADAS – MLP	32
2.6.3	ALGORITMO DE TREINAMENTO – BACKPROPAGATION (BP).....	35
2.7	RNA APLICADO À ENGENHARIA GEOTÉCNICA	39
2.8	REGRESSÃO MULTIVARIADA (RM)	44
2.8.1	APLICADA À ENGENHARIA GEOTÉCNICA	45

3	METODOLOGIA	46
3.1	BANCO DE DADOS.....	49
3.1.1	NORMALIZAÇÃO	54
3.1.2	CORRELAÇÃO DE DADOS – COEFICIENTE DE PEARSON (ρ_r).....	54
3.2	CONFIGURAÇÃO DO MODELO RNA.....	55
3.2.1	ARQUITETURA DA REDE NEURAL (RNA).....	56
3.2.2	ALGORITMO DE OTIMIZAÇÃO BAYESIANA	57
3.2.3	MÉTRICAS DE VALIDAÇÃO DE MODELO	63
3.2.4	LIMITAÇÕES E PROBLEMAS	67
4	RESULTADOS.....	74
4.1	ANÁLISE DOS DADOS	74
4.1.1	INTERPRETAÇÃO DE DADOS	74
4.1.2	CORRELAÇÃO DE DADOS - PEARSON (ρ_r).....	90
4.2	ANÁLISES DO MODELO RNA	105
4.2.1	ARQUITETURA RNA	105
4.2.2	FASE DE TREINAMENTO/TESTE E AVALIAÇÃO DO MODELO RNA	107
4.3	ANÁLISES DO MODELO RM	131
4.4	COMPARAÇÃO DO MODELO DE RNA E O MODELO RM	137
5	CONCLUSÕES.....	141
5.1	CONCLUSÕES GERAIS	141
5.2	LIMITAÇÕES DO MODELO.....	142
5.3	SUGESTÕES PARA PESQUISAS FUTURAS.....	143
6	REFERÊNCIAS BIBLIOGRÁFICAS	144

1 INTRODUÇÃO

O uso de filtros geotêxteis em atividades de engenharia geotécnica e proteção ambiental tem sido crescente ao longo das últimas décadas devido às várias vantagens que sua utilização apresenta. Isso ocorre tanto durante a execução de um empreendimento, com maior facilidade no transporte e instalação, quanto nos aspectos ambientais, ao evitar ou reduzir o uso de materiais naturais como areia e brita, pois favorece a conservação do meio ambiente. Assim, tais filtros oferecem vantagens econômicas e ambientais, pois, segundo Frischknecht et al. (2012), um filtro geotêxtil reduz o impacto ambiental, em mais de 80% em comparação com os filtros de areia. No entanto, a sua aplicação em projetos maiores e complexos ainda apresenta certos obstáculos, por isso é importante entender melhor o seu desempenho a longo prazo sob condições que possam causar um mau desempenho (Palmeira, 2018).

De forma geral, o sistema solo/filtro geotêxtil, na sua condição estável, deve atender aos critérios de retenção, permeabilidade, anticolmatação e sobrevivência e durabilidade. Ao garantir os cumprimentos desses critérios e a boa execução, a probabilidade de o filtro geotêxtil apresentar problemas no seu desempenho ao longo da sua vida útil é muito baixa (Palmeira, 2018; Khan et al., 2022;). Com o aumento da utilização de geotêxteis, inúmeros estudos foram realizados para entender a interação entre o solo, fluidos e filtros geotêxteis e garantir os critérios mencionado acima. Porém, certos aspectos ainda exigem investigações abrangentes para compreender melhor o desempenho desses filtros. Um estudo realizado por Qureshi et al. (1990) apresenta resultados nos quais se obteve redução significativa do coeficiente de permeabilidade do sistema solo/geotêxtil, para um solo internamente instável. Esse estudo também sugere que as reduções foram causadas pela impregnação dos vazios do geotêxtil por partículas do solo em contato.

Outro estudo, realizado por Koerner & Koerner (2015), apresentou as possíveis falhas que levaram a um comportamento inadequado do sistema solo/geotêxtil. Entre essas falhas, encontra-se o contato entre o filtro com solos atípicos, especialmente solos internamente instáveis, os quais são solos de graduação ampla que se caracterizam por ter uma curva granulométrica com concavidade voltada para cima ou solos descontínuos (*gap grapped*). Esses tipos de solos podem sofrer sufusão, com consequências danosas para o desempenho do filtro, reduzindo a permeabilidade do sistema solo/geotêxtil (Chang & Zhang, 2013; Koerner & Koerner, 2015; Palmeira, 2018)

Diante do exposto, a procura por métodos alternativos para prever o comportamento do sistema solo-geotêxtil sob tais condições se torna importante para a engenharia geotécnica. Com o crescente uso de ferramentas avançadas computacionais, o uso de inteligência artificial (IA) vem se tornando bem-sucedido nos diferentes setores da engenharia geotécnica, devido a sua eficácia na análise de previsões de relações não lineares. Trata-se de uma solução para elaboração de modelos de previsão mais precisos em comparação com o uso de métodos tradicionais. Entre os métodos de IA utilizados, as Redes Neurais Artificiais (RNA) parecem ser as mais amplamente utilizadas e preferidas, de modo que compreendem 52% dos estudos revisados (Baghbani et al., 2022). Por outro lado, o uso de análises de regressão multivariada vem apresentado, também, previsões acuradas devido a sua capacidade de aproximar e expressar de forma matemática a relação entre os parâmetros envolvidos, uma vez que é capaz de gerar modelos de fácil interpretação em problemas geotécnicos nos quais existem relações mais complexas entre as variáveis envolvidas.

A presente dissertação visa utilizar os métodos apresentados acima para estimar a permeabilidade de um conjunto solo/geotêxtil e correlacionar as propriedades do solo, a ser estudado (internamente instável), e as propriedades do filtro, com a finalidade de obter uma previsão mais acurada do desempenho do geotêxtil.

1.1 OBJETIVOS

O principal objetivo desta dissertação é avaliar a eficácia de métodos alternativos, como Rede Neural Artificial (RNA) e Métodos de Regressão Multivariada (MRM), para prever o comportamento filtrante de geotêxtil em contato com solos internamente instáveis. A avaliação desse comportamento será realizada por meio do coeficiente de permeabilidade do conjunto solo/geotêxtil, de forma que esse parâmetro é crucial para compreender a interação entre estes materiais e seu impacto no desempenho do filtro geotêxtil.

Para atingir o objetivo principal da dissertação, os seguintes objetivos específicos foram desenvolvidos:

- Identificar os fatores que influenciam o comportamento filtrante do geotêxtil nos ensaios de laboratório compilados na literatura;
- Realizar análises estatísticas com base no banco de dados de ensaios de filtração

para correlacionar as propriedades do filtro com as propriedades do solo;

- Elaborar modelos baseados nos parâmetros de entrada, no número de camadas ocultas e na arquitetura ideal para redes neurais;
- Avaliar o desempenho dos modelos RNA no comportamento de geotêxteis, a fim de comparar os valores previstos com dados reais (os resultados dos ensaios laboratoriais);
- Comparar os resultados do modelo RNA com os resultados obtido por modelos estatísticos.

1.2 ESTRUTURAÇÃO DA DISSERTAÇÃO

O estudo está dividido em cinco capítulos. Nesse sentido, o Capítulo 1 apresenta, de forma concisa, as considerações iniciais da pesquisa, a justificativa e o objetivo do trabalho. Então, o Capítulo 2 é dedicado à revisão da literatura, assim, destaca as principais características e aplicações do filtro geotéxtil, seu comportamento com o solo, além de definir e explorar os conceitos fundamentais de Redes Neurais Artificiais (RNA) aplicados à engenharia civil e geotecnia.

Além disso, o Capítulo 3 descreve em detalhe a metodologia e as técnicas utilizadas para desenvolver, implementar, processar e avaliar o modelo de Redes Neurais Artificiais (RNA), que é destinado a prever a resistência na interface. Este capítulo expõe, passo a passo, desenvolver um modelo de RNA, incluindo a seleção de parâmetros de entrada e definindo a arquitetura adequada.

O Capítulo 4 apresenta os resultados da metodologia aplicada para a previsão do comportamento filtrante do solo/geotêxtil. Os dados coletados são analisados e correlacionados, e as características dos modelos implementados são descritas detalhadamente, acompanhadas de suas respectivas avaliações de desempenho. Os modelos finais são comparados com os resultados experimentais obtidos em laboratório, a fim de determinar sua acurácia. No final, o modelo com o melhor desempenho, em termos de acurácia na previsão do comportamento filtrante (k), foi identificado e selecionado.

Finalmente, o Capítulo 5 oferece uma síntese abrangente dos achados do estudo, de

modo que destaca as principais conclusões. Além disso, discute as limitações da pesquisa e sugere direções para estudos futuros.

As referências bibliográficas utilizadas no estudo estão listadas após o último capítulo.

2 REVISÃO BIBLIOGRÁFICA

2.1 FUNÇÕES E APLICAÇÕES DE GEOSSINTÉTICOS

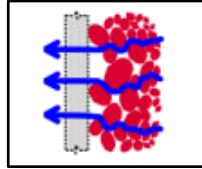
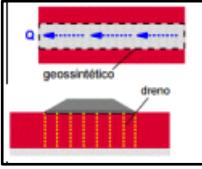
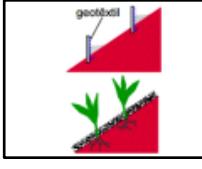
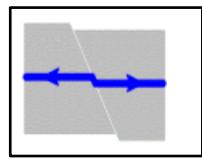
De acordo com a Sociedade Internacional de Geossintéticos (IGS, 2024), os geossintéticos são materiais poliméricos, naturais ou sintéticos, utilizados como materiais em obras de construção civil e geotécnicos., em contato com solos, rochas ou outros materiais geotécnicos. O uso desses materiais tem apresentado um aumento significativo nas últimas décadas, devido a uma série de fatores, entre os quais se destacam as vantagens técnicas, econômicas e ambientais que oferecem.

Do ponto de vista técnico, os geossintéticos se destacam pela agilidade e simplicidade de aplicação, além da ampla variedade de produtos disponíveis para diferentes finalidades. No aspecto econômico, esses materiais são valorizados por seu baixo custo, enquanto, sob a ótica ambiental, apresentam um impacto ambiental reduzido, tornando-se uma alternativa mais sustentável. Com todos esses benefícios, os geossintéticos se consolidaram como uma excelente opção em comparação com as metodologias e aos materiais tradicionais de construção civil.

Este material geotécnico têm a capacidade de substituir, parcial ou totalmente, recursos naturais em obras civis e geotécnicas. Suas características, como resistência à corrosão, flexibilidade, facilidade de transporte, armazenamento e instalação, além de sua durabilidade, reforçam sua adoção em uma ampla gama de aplicações. Na Tabela 2.1, apresenta-se de forma resumida suas principais funções.

Tabela 2.1-Principais Funções do Geossintético (Adaptado de Palmeira, 2018)

Função	Finalidade	Exemplo	Geossintético
Separação	Separar materiais geotécnicos diferentes com o objetivo de garantir a funcionalidade de cada material.		<ul style="list-style-type: none">• Geomembrana• Geotêxtil• Geocomposto
Barreira	O geossintético atua como uma barreira relativamente impermeável a fluidos e gases.		<ul style="list-style-type: none">• Geotêxtil• Geomembranas• Geocompostos• Geocompostos argilosos(GCL's)

Função	Finalidade	Exemplo	Geossintético
Filtração	Permitir simultaneamente o livre escoamento do fluido assim como bloquear a passagem de partículas de solo (agindo como um filtro granular)		<ul style="list-style-type: none"> • Geotêxtil • Geocomposto
Drenagem	Coletar e conduzir o fluido por meio do geossintético.		<ul style="list-style-type: none"> • Geotêxtil • Georredes • Geocomposto • Geotubos
Controle de Erosão	Controlar a erosão superficial de diversas estruturas devido a estar expostos a agentes como chuvas, fluxo superficial e transporte sedimentar.		<ul style="list-style-type: none"> • Georredes; • Mantas Geotêxtil; • Geotêxtil; • Geomembrana; • Geocélulas
Reforço	Aumentar a Resistência e/ou diminuir os recalques, melhorando o comportamento mecânico do solo.		<ul style="list-style-type: none"> • Geogrelha; • Geotêxtil; • Geocomposto • Geocélulas

Entre suas principais aplicações estão reservatórios e barragens, depósitos de resíduos líquidos, depósitos de resíduos sólidos, canais, obras rodoviárias e ferroviárias, fundações, obras de controle de erosão, estruturas subterrâneas como tuneis e sistemas de drenagem (NBR ISO 10318, 2013).

Destaca-se que esta pesquisa tem como foco principal a análise do comportamento filtrante do geotêxtil, sendo que, nos próximos capítulos, haverá uma ênfase maior neste material e na sua função.

2.2 FILTRO GEOTÊXTIL

O geotêxtil é um geossintético plano e permeável de natureza têxtil. Ele pode ser classificado como geotêxtil tecido ou não tecido, e é manufaturado a partir de diversos polímeros, predominantemente polietileno, poliamida (nylon), poliéster (polietileno tereftalato) e polipropileno (Freitas, 2003).

A fabricação de geotêxteis tecidos (GT) consiste no entrelaçamento de fios em direções ortogonais, formando uma estrutura planar contínua. Já os geotêxteis não tecidos (GTN) são

produzidos pela distribuição aleatória de fibras sobre uma superfície rolante, em que a espessura é controlada pela velocidade que ela roda. No processo de fabricação do GTN, as fibras sofrem um processo de ligação, que pode ocorrer de forma mecânica (como agulhamento), térmica (fusão das fibras) ou química (utilização de ligantes) (Freitas, 2003).

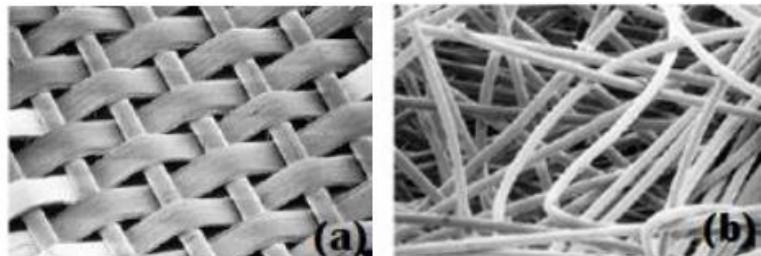


Figura 2.1:Tipo de Geotêxtil: (a) Tecido (GT) e (b) Não Tecido (GNT) (Freitas,2003)

Esse elemento é comumente utilizado em obras geotécnicas como substituição do filtro granular (Figura 1). Essa substituição traz várias vantagens em relação a um filtro granular. Entre essas vantagens, apresentam-se facilidade na fase construtiva da obra, pois possuem facilidade, rapidez e baixo custo na instalação; menor ocupação de volume e redução de uso material granular e, por consequência, menor impacto ambiental; maior confiabilidade no uso devido a repetibilidade e uniformidade das propriedades do material.



Figura 2.2-Filtro Granular vs. Filtro Geotêxtil (Modificado de Palmeira, 2023).

Tanto o filtro geotêxtil como o granular têm como objetivo reter o solo e permitir a passagem da água ao mesmo tempo e de forma equilibrada. Assim, as abordagens de projeto para os filtros geotêxteis geralmente devem considerar critérios geométricos e hidráulicos. O primeiro define os valores limites para os diâmetros dos poros do geotêxtil para impedir o transporte de partículas menores por eles. O segundo define um valor limite para o gradiente hidráulico no qual o transporte das partículas do solo começa (Koerner, 2016).

A elaboração de um projeto adequado com uma correta seleção de filtros depende das condições de contorno, da criticidade da aplicação e das características geotécnicas do solo

base (sobretudo da distribuição do tamanho dos grãos, estabilidade interna e permeabilidade). As condições de contorno estão intimamente relacionadas aos gradientes hidráulicos aplicados, às condições de fluxo e ao comportamento do sistema solo-geotêxtil. Infelizmente, os critérios de projeto de filtro comumente usados não consideram todos esses fatores, mas muitas vezes são resultado de um compromisso necessário entre requisitos (Giroud, 2010; Moraci, 2010).

Outro ponto de observação é o tipo de geotêxtil que vai ser utilizado, pois, segundo Palmeira (2018), os geotêxteis não tecidos apresentam melhor desempenho em relação com o geotêxtil tecido. Entre essas vantagens, encontram-se: menor susceptibilidade a danos mecânicos, maior estabilidade com relação as dimensões das aberturas do filtro e menor impacto na funcionalidade do filtro caso ele fosse danificado.

Para garantir o funcionamento adequado do filtro vários autores propuseram critérios para garantir um adequado comportamento do filtro, mas de forma geral um geotêxtil seja ele tecido ou não tecido, deve atender aos seguintes critérios (Bathia & Smith, 1996):

- Critério de Retenção: Esse critério deve garantir que as aberturas de filtro sejam suficientemente pequenas para impedir a erosão das partículas de solo, a fim de evitar a erosão interna (*piping*)
- Critério de Permeabilidade: Visa assegurar que o filtro manterá o valor de coeficiente de permeabilidade maior que o solo em contato e que seja compatível com as condições de fluxo da obra;
- Critério de Anticolmatação: Deve garantir que o filtro não sofrerá algum tipo de mecanismo de colmatação que reduza a sua permeabilidade.
- Critério de sobrevivência e durabilidade: Garantir que o filtro possua as propriedades mecânicas e de resistência à degradação adequadas durante toda a vida útil da obra (Palmeira, 2018; Khan et al., 2022).

Em relação a esses critérios, Palmeira (2020) enfatiza que os primeiros três critérios se relacionam mais com as propriedades do geotêxtil e o último aspecto com as condições a que o geotêxtil é submetido. Quanto à capacidade de retenção do geotêxtil, Palmeira (2018) compila alguns dos critérios encontrados na literatura, destacando o elaborado por Lafleur (1999).

Segundo esse autor, os solos com $C_u > 6$ com curva granulométrica com concavidade voltada para cima, assim como os solos descontínuos com $C_u > 6$, podem apresentar problemas de retenção pelo geotêxtil. Em solos não coesivos, os solos descontínuos e a solos com curvas granulométrica com concavidade para cima, apresentam risco significativo de migração de finos.

O critério de permeabilidade visa garantir que a permeabilidade inicial do filtro seja igual ou superior a do solo, a fim de permitir o livre fluxo da água, de modo a cumprir a sua função de filtração. Dentre os critérios relevantes, Carroll (1983) e Christopher e Holtz (1985) propõem que, sob condições hidráulicas e de solos críticas e severas, a permeabilidade do geotêxtil deve atender à condição $k_{GT} > 10k_s$. Os autores Christopher e Holtz (1985) também recomendam a adoção de $k_{GT} > 100k_s$ em cenários com potencial de ocorrência de colmatação biológica. O departamento de transporte do Reino Unido (1993) também contribui com os seguintes critérios: para geotêxteis (tecido ou não tecido) com espessura (t_{GT}) inferior a 2 mm, a condição atendida é $k_{GT} > 10k_s$; para geotêxteis não tecidos com t_{GT} superior a 2 mm, o critério é $k_{GT} > 100k_s$.

O critério de anticolmatação, por sua vez, tem como objetivo prevenir a ocorrência de mecanismos de redução de permeabilidade, como cegamento, bloqueamento e obstrução dos poros do geotêxtil. Esse critério será detalhado nos próximos itens. Em situações críticas ou severas, Christopher e Holtz (1985) enfatizam a importância da realização de ensaios de infiltração que utilizem o solo de contato com o geotêxtil e simulem as condições de campo a que o filtro será exposto. A Tabela 2.2 apresenta as situações consideradas severas ou críticas para a aplicação destes critérios.

Tabela 2.2-Avaliação da criticidade e severidade (Modificado de Carroll, 1983, Palmeira, 2018)

Situação Crítica		
Situação	Condição Crítica	Condição Não Crítica
Risco de perder a vida ou danos estruturais devido à falha do dreno.	Alto	Nenhum
Custo de preparo vs. Custo de instalação do dreno	Muito maior	Igual ou menor
Evidência de colmatação do dreno antes de uma falha catastrófica	Nenhuma	Sim
Situação Severa		
Situação	Condição Severa	Condição Não Severa
Solo a ser drenado	Solos descontínuos, sujeitos a <i>piping</i>	Solos bem graduados ou uniformes
Gradiente Hidráulico	Alto	Baixo
Condições de fluxo	Dinâmico ou cíclico	Fluxo Permanente

Por fim, considerando os critérios de sobrevivência e durabilidade, o geotêxtil deve possuir propriedades mecânicas adequadas, abrangendo resistência à tração, deformação sob carga e resistência ao punctionamento. Adicionalmente, deve apresentar durabilidade à degradação induzida por radiação ultravioleta e agentes químicos presentes no ambiente, de modo a garantir a integridade do material durante as fases de instalação, execução e ao longo da vida útil da obra (Christopher & Fischer, 1992).

2.2.1 PROPRIEDADES DO GEOTÊXTIL

Em função do tipo de projeto, o geotêxtil deve apresentar características específicas que assegurem seu desempenho adequado para a finalidade proposta. Dessa forma, as propriedades do material funcionam como critérios determinantes na seleção de um geotêxtil, o qual deve responder de maneira eficaz às diversas condições e solicitações a que será submetido.

Para isso, nos últimos anos, diversos tipos de ensaios laboratoriais foram realizados com o objetivo de estudar e compreender de forma mais detalhada o comportamento e o desempenho dos filtros geotêxteis, além de quantificar as propriedades mais relevantes (Palmeira, 2020). Esses ensaios podem ser classificados tanto pela propriedade avaliada quanto pelos critérios de garantia. Nesse contexto, Villar (2014) os categorizou em quatro grupos principais:

- I) Ensaios para determinação das propriedades físicas: incluem ensaios de filtração de

- solo/geotêxtil, ensaios de índice físicos (Christopher & Holtz, 1985; Melo, 2018)
- II) Ensaios para determinação das propriedades mecânicas: ensaios de resistência à tração, deformação e resistência à agentes químicos;
 - III) Ensaios para determinação das propriedades hidráulicas: compreendem a análise da distribuição granulométrica do solo de contato, ensaio de peneiramento e análise de imagem;
 - IV) Ensaios de desempenho: englobam o ensaio de filtração de longa duração, o Ensaio de Razão de Gradientes (ASTM D5101) e o Ensaio de Condutividade Hidráulica (ASTM D5567).

Em relação aos critérios de anticolmatação, os ensaios a serem conduzidos englobam ensaios de infiltração, a avaliação dos índices físicos do geotêxtil e os ensaios de desempenho previamente mencionados. No que concerne aos ensaios índice, o objetivo é determinar as propriedades filtrantes do geotêxtil, independente das características do solo base e das condições da obra, a fim de avaliar a abertura de infiltração (FOS) e a distribuição de constrições (Christopher & Holtz, 1985; Melo, 2018).

Considerando que este estudo se concentra na análise do desempenho do geotêxtil, uma maior atenção será dedicada aos ensaios que avaliam essa característica, dentre os quais se destacam o ensaio de peneiramento, o ensaio de razão entre gradientes, o ensaio de condutividade hidráulica e o Ensaio do Ponto de Bolha (*Bubble Point Test*). Dessa forma, nos itens subsequentes, serão apresentadas as principais propriedades físicas e hidráulicas do geotêxtil que exercem influência sobre o desempenho do material.

2.2.1.1 PROPRIEDADES FÍSICAS

As grandezas como a espessura, porosidade, massa por unidade de área (gramatura) e o diâmetro das fibras ou filamentos são consideradas como as propriedades físicas do geossintéticos (Palmeira, 2018). A seguir, apresenta-se uma breve descrição dessas propriedades:

- Gramatura (M_A): Também conhecida como massa por unidade de área, a gramatura é um parâmetro relevante para avaliar a uniformidade e a qualidade do geossintético. Ela expressa a quantidade de material por unidade de área, sendo medida em g/m^2 (Moreira,

2009). Segundo Koerner (2005), a maioria dos geotêxteis apresenta valores de gramatura entre 150 e 750 g/m²;

- Espessura (t_{GT}): Representa a distância entre as superfícies inferior e superior do geossintético, expressa em milímetros (mm) sob uma pressão específica. A espessura nominal é obtida ao se aplicar uma pressão de 2 kPa, com valores típicos para geotêxteis que variam entre 0,25 mm e 7,5 mm. A relação entre espessura e pressão permite avaliar a compressibilidade do material (Lopes & Lopes, 2010);
- Porosidade (n): Define-se como a razão entre o volume de vazios e o volume total do geossintético. A porosidade pode ser calculada em função da gramatura (M_A), da massa específica das fibras (ρ_f) e da espessura (t_{GT}), conforme a Eq. (2.1).

$$n = 1 - \frac{M_A}{\rho_f t_{GT}} \quad \text{Eq. (2.1)}$$

- Constrição (D_c): Corresponde ao diâmetro equivalente da menor abertura no canal de fluxo em um geotêxtil, é equivalente ao diâmetro da maior partícula que consegue atravessar a espessura do material. Partículas do solo podem ser retidas nesses canais de fluxo quando a constrição é menor que o diâmetro da partícula. Em geotêxteis não tecidos, a capacidade de retenção de partículas é particularmente sensível à tensão vertical (σ_v) aplicada no material.

2.2.1.2 PROPRIEDADES HIDRÁULICAS

As propriedades hidráulicas desempenham um papel crucial na avaliação do desempenho de um filtro, seja ele granulares ou sintéticos. Como este estudo se concentra no desempenho filtrante do geotêxtil, essas propriedades serão analisadas detalhadamente.

Entre as características hidráulicas relevantes, destacam-se a distribuição e a dimensão das aberturas, a permeabilidade normal ao plano (k_n) e a permeabilidade ao longo do plano (k_p).

- Abertura de filtração (O_f): Embora diversos autores classifiquem essa característica como uma propriedade física dos geossintéticos, seu impacto significativo no

comportamento hidráulico e sua função definidora no potencial de filtração a tornam um parâmetro primordial para o dimensionamento de filtros geotêxteis (Rigo et al., 1990). Portanto, nesta dissertação, ela será abordada como uma propriedade hidráulica do geotêxtil.

Essa propriedade é fundamental, pois o filtro geotêxtil deve desempenhar duas funções simultaneamente: permitir o fluxo de fluido através de seu plano, em contato com o solo, e impedir a passagem de partículas sólidas que possam obstruir seus poros. A determinação da abertura de filtração é realizada por meio de diferentes ensaios, classificados em métodos indiretos e diretos, conforme ilustrado na Figura 2.3

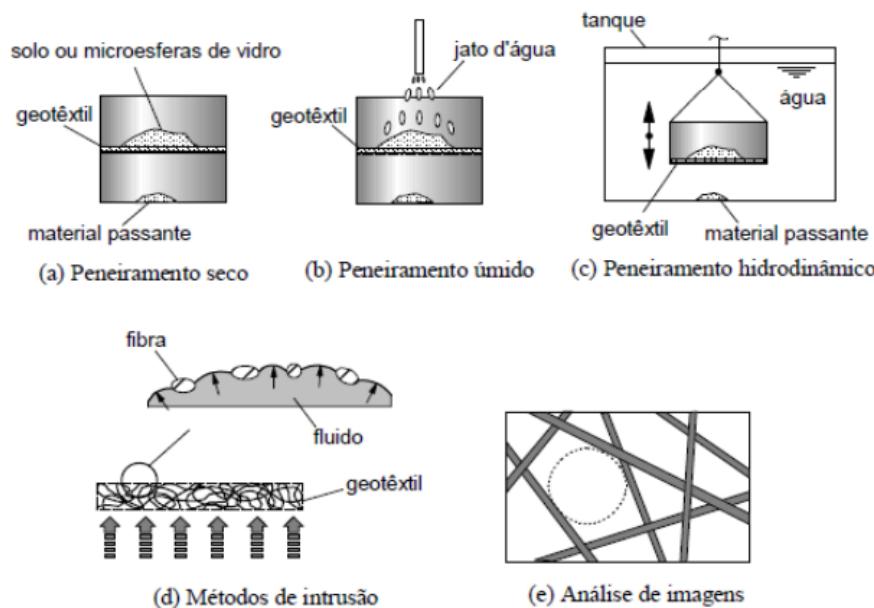


Figura 2.3: Ensaio direto e indireto para determinação de abertura de infiltração do geotêxtil (Palmeira, 2003)

Entre os ensaios indiretos, apresentam-se os métodos de peneiramento (a, b e c) e as análises de imagem (d). Já entre os ensaios diretos, destaca-se o ensaio de capilaridade (Ponto de Bolha) (Melo, 2018).

A abertura de filtração é frequentemente representada pela dimensão equivalente de abertura O_n , que corresponde à maior dimensão de abertura que retém n% das partículas. Geralmente, adota-se o valor de 95% para n, e o diâmetro de abertura é medido em milímetros (mm) (Carneiro, 2009; Lopes & Lopes, 2010);

- Permeabilidade normal ao plano (k_n) e Permissividade (Ψ): A permeabilidade normal

ao plano é uma propriedade intrínseca do geotêxtil que caracteriza a passagem do fluxo de fluido perpendicularmente ao plano do geotêxtil. Essa propriedade depende das características físicas do geotêxtil, como a distribuição e a dimensão das aberturas. (Carneiro, 2009; Lopes & Lopes, 2010). No caso de geotêxtil, Moraes Filho (2018) considera que é mais interessante trabalhar com a permissividade (ψ), um parâmetro mais relevante, pois representa a relação da permeabilidade normal ao plano e a espessura do geotêxtil, conforme a Eq. (2.2) e como é ilustrado na Figura 2.4 :

$$\psi = \frac{k_n}{t_{GT}} \quad \text{Eq. (2.2)}$$

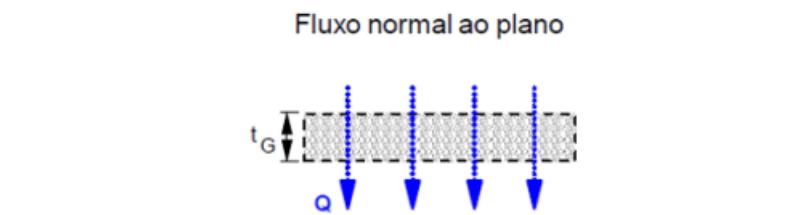


Figura 2.4- Representação da permissividade (Palmeira, 2003)

É importante ressaltar que, para dois geotêxteis com estrutura e porosidade semelhantes, o valor da permeabilidade normal ao plano (k_n) será o mesmo. Consequentemente, se esses materiais apresentarem espessuras distintas, suas permissividades serão diferentes (Gourc, 1982).

- Permeabilidade ao longo do plano (k_p) e Transmissividade (θ): Essa propriedade descreve as condições de escoamento no plano do geotêxtil e é geralmente expressa como transmissividade (θ). A transmissividade relaciona a permeabilidade ao longo do plano (k_p) e a espessura do geotêxtil sob uma determinada tensão normal de confinamento, sendo depende do gradiente hidráulico (i) atuante. A transmissividade é descrita pela Eq. (2.3) e é apresentada na Figura 2.5

$$\theta = k_p \cdot t_{GT} \quad \text{Eq. (2.3)}$$

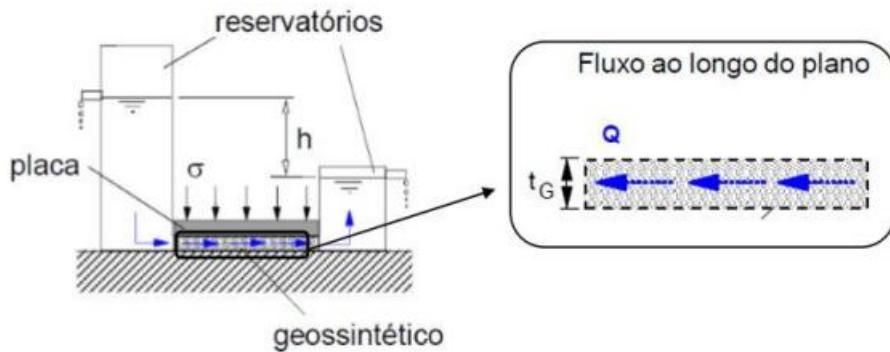


Figura 2.5: Representação da Transmissividade (Adaptado de Palmeira & Gardoni, 2002).

2.3 FATORES QUE INFLUENCIAM O COMPORTAMENTO DO GEOTÉXTIL

Como foi mencionado, o comportamento do filtro geotêxtil é influenciado por diversos fatores, como o tipo de solo base, tipo de fluido, tipo de geotêxtil, estrutura do meio filtrante e solicitações externas. E, conforme Giroud (1996) e Rollin e Lombard (1988), os fatores que influenciam o desempenho de filtração dos geotêxteis podem ser classificados em categorias principais, as quais estão apresentadas de forma resumidas na Tabela 2.3.

Tabela 2.3: Fatores que influem no comportamento do filtro geotêxtil (Adaptado de Rollin & Lombard, 1988)

Propriedades do Solo	Propriedades do Geotêxtil	Condições hidromecânicas
<ul style="list-style-type: none"> • Coeficiente de uniformidade (C_u) • Coeficiente de curvatura (C_c) • Distribuição granulométrica • Forma das partículas e dureza dos grãos • Estado de compactação e grau de saturação 	<ul style="list-style-type: none"> • Tamanho de abertura de filtração (FOS) ou tamanho de abertura aparente (AOS); • Gramatura (M_A); • Porosidade (n); • Espessura do tecido (t_{GT}); • Diâmetro das fibras (d_f); • Tipo de Geotêxtil 	<ul style="list-style-type: none"> • Gradiente hidráulico (i); • Estado de tensão vertical (σ_v); • Contato solo-filtro (contínuo ou não); • Tipo do Fluido

Notas: $C_u = d_{60}/d_{10}$ e $C_c = (d_{30})^2/(d_{60} \cdot d_{10})$

Por outro lado, Palmeira (2023) apresenta os fatores físicos que influem no comportamento filtrante. Esses estão relacionados com a impregnação do geotêxtil e ao estado de tensão a que

são submetidos (confinamento e tração). O confinamento e a presença de partículas de solo na estrutura do geotêxtil influenciam o seu comportamento. Esse tipo de obstrução interna por partículas no filtro pode ocorrer durante o espalhamento da camada de solos e compactação deles sobre o geotêxtil e/ou devido às partículas trazidas pelas forças de percolação durante o fluxo (Palmeira, 2018; 2023).

Cabe destacar que o nível de impregnação ou obstrução interna depende das características do solo base e do geotêxtil. As partículas nos vazios do geotêxtil podem diminuir a sua compressibilidade, sua permeabilidade e gerar condições para obstruções adicionais devido a alteração das aberturas iniciais do geotêxtil. Um estudo realizado por Qureshi et al. (1990) apresenta resultados nos quais se obtiveram reduções significativas do coeficiente de permeabilidade do sistema solo-geotêxtil no caso de solos internamente instáveis, e sugerem que as reduções foram causadas pela impregnação dos vazios do geotêxtil por partículas de solo. A influência de outros fatores como solicitações de tráfegos sobre o geotêxtil, contato entre solo e filtro e mecanismos de colmatação física, química e biológica interferem no comportamento filtrante do geotêxtil.

Prever a ocorrência de colmatação do filtro sob certas condições é difícil, e segundo Palmeira (2023), existem três causas para colmatação física (apresentadas na Figura 2.6): bloqueamento, obstrução interna, e cegamento. O bloqueamento (Figura 2.6a) é um mecanismo que ocorre quando partículas se localizam na entrada dos poros do geotêxtil, sendo a sua ocorrência pouco provável em geotêxteis não tecidos, isso devido à variabilidade de formas, tamanhos e número de poros que este tipo de geotêxtil apresenta. Já o cegamento (Figura 2.6b) acontece quando as partículas finas são retidas na superfície do geotêxtil e se acumulam, criando uma camada fina e de baixa permeabilidade. Esse mecanismo acontece comumente em filtros em contato com solos internamente instáveis. E, por último, a obstrução interna pode ocorrer devido à impregnação excessiva dos poros do geotêxtil (não tecido) por intrusão de partículas do solo base (Figura 2.6 c). Outros mecanismos de colmatação envolvem a formação de filmes bacterianos (colmatação biológica) ou a precipitação de produtos químicos (colmatação química) (Markiewicz et al., 2022; Palmeira, 2023).

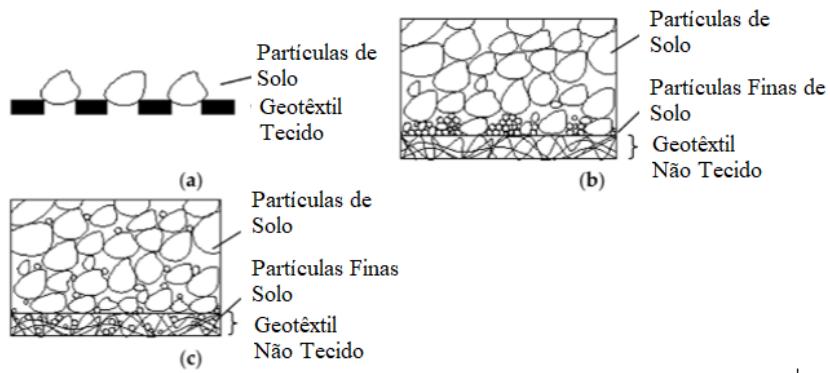


Figura 2.6- Mecanismo de colmatação física: (a) Bloqueamento; (b) Cegamento; e (c) Obstrução interna (Adaptado de Markiewicz *et al.*, 2022).

2.4 FILTRO GEOTÊXTIL EM SOLOS INTERNAMENTE INSTÁVEIS

Solos internamente instáveis são um desafio para filtros, seja granulares ou geotêxteis, devido a serem solos susceptíveis ao fenômeno de sufusão, no qual as partículas menores do solo são transportadas pela água através dos vazios entre grãos maiores. Assim, o tamanho das partículas capazes de atravessarem o geotêxtil é um aspecto essencial a sua especificação para uma obra (Khan *et al.*, 2022). Chang e Zhang (2013) realizaram a identificação de estabilidade interna do solo baseados em 131 solos. Eles adotaram três métodos de identificação: (a) Perda de fração de finos, (b) variação da permeabilidade, e (c) *piping*.

No primeiro método, considera-se que o solo é instável se ocorrer perda contínua de finos, autores como Kenney e Lau (1985), Lafleur *et al.* (1989), Wan & Fell (2008), Chang & Zhang (2011), entre outros, seguiram esse método. De acordo com Kenney & Lau (1985) e Wan & Fell (2008), a fração de perda de finos pode ser feita medindo a distribuição granulométrica após a realização do teste. No segundo método, uma amostra considera-se instável se existir uma mudança brusca na permeabilidade do sistema durante o processo de teste, autores como Sun (1989), Liu (2005) e Kaoser *et al.* (2006) se basearam nesse método. No terceiro método, adotado por Adel *et al.* (1988), os solos instáveis são aqueles que apresentam *piping* sob gradientes hidráulicos menores.

Os dois primeiros métodos se complementam entre si, pois uma perda significativa de finos causa uma mudança repentina na permeabilidade da amostra e uma mudança nas curvas granulométricas. No entanto, as condições hidráulicas nos ensaios foram mais severas que a que se esperam na realidade (Chang & Zang, 2013).

Assim, a estabilidade interna é influenciada significativamente pela granulometria dos solos e pela característica da curva granulométrica. Os solos com granulometria descontínua (*gap-graded*) apresentados na curva C e D da Figura 2.7 os bem graduados, com a curva granulométrica voltada para cima (curva B) e altos valores de coeficiente de uniformidade (Cu) se apresentam como solos com alta possibilidade de instabilidade interna. Na Figura 2.7, apresentam-se as curvas granulométricas típicas de solos internamente instáveis (Chang & Zhang, 2013; Palmeira, 2018).

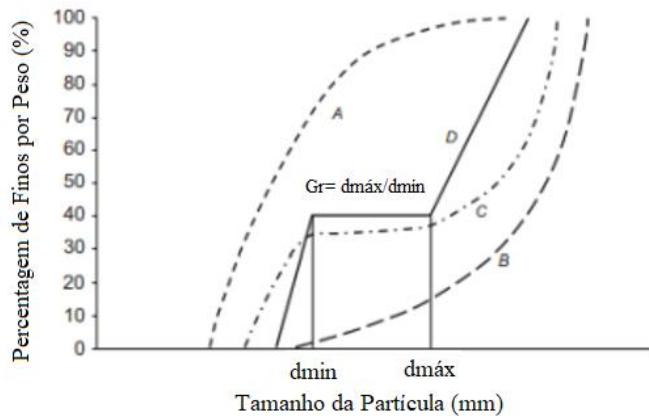


Figura 2.7: Curvas granulométricas típicas de solos internamente instável (Adaptado de Chang e Zhang, 2013).

Em relação aos solos bem graduados, sua estabilidade interna é determinada pela capacidade de suas partículas grossas em reter a perda de suas partículas de tamanho médio, o que, por conseguinte, impede a perda de suas partículas finas. Dessa forma, o teor de finos exerce uma influência significativa na estabilidade interna de um solo amplamente graduado (Bendahmane et al., 2008; Wan & Fell, 2008). Em contraste, um solo com graduação descontínua caracteriza-se por apresentar uma ampla graduação na qual uma faixa de tamanhos é significativamente sub-representada (como o solo C na Figura 2.7) ou completamente ausente (como o solo D na Figura 2.7). Essa parte ausente frequentemente é areia ou silte. Assim, a estabilidade interna de um solo com graduação descontínua reside na capacidade das partículas grossas poder impedir a perda das partículas finas. Caso a fração mais fina consiga preencher totalmente os poros formados pela fração mais grossa, o solo geralmente tende ser internamente estável. O teor de finos, ao igual ao do solo bem graduado, tem uma influência significativa na estabilidade interna de solos com graduação descontínua (Chang & Zhang, 2013).

A estabilidade interna dos solos descontínuos pela razão de descontinuidade (G_r) é ilustrada na

Figura 2.7. Essa razão é definida como a proporção entre o tamanho máximo (d_{\max}) e o tamanho mínimo (d_{\min}) das partículas na porção severamente sub-representada da curva de distribuição granulométrica. Uma elevada razão de descontinuidade indica que a fração grossa não atua eficazmente como filtro para a fração mais fina, o que facilita a erosão das partículas finas mesmo sob baixos gradientes hidráulicos.

A literatura apresenta diversos critérios conservadores para avaliar a suscetibilidade de um solo internamente instável (Kenney & Lau, 1985; Lafleur, 1999). Moraci et al. (2014) realizaram um estudo ao avaliar e comparar os diferentes métodos para determinar a instabilidade de um solo, de modo que chegaram à conclusão de que o método de Kenney & Lau (1985) apresentou previsões satisfatórias.

Segundo Istomina (1957), o coeficiente de uniformidade (C_u) de um solo pode indicar sua estabilidade interna. Esse coeficiente, calculado pela razão entre o diâmetro da partícula com 60% mais fino em peso (d_{60}) e o diâmetro da partícula com 10% mais fino em peso (d_{10}), ou seja, $C_u = d_{60}/d_{10}$, avalia se as partículas finas podem percolar pelos poros formados pela fração grossa do solo. De acordo com o critério, solos com $C_u < 10$ são considerados internamente estáveis, enquanto aqueles com $C_u > 20$ são provavelmente internamente instáveis. Essa análise é aplicável a cascalhos arenosos.

Kezdi (1969) propôs um critério geométrico, baseado no conceito de filtro de Terzaghi (1939), para avaliar a estabilidade interna. O solo é dividido em frações mais fina e mais grossa em um ponto arbitrário da curva granulométrica (tamanho de partícula d) na curva de distribuição granulométrica. O solo é dividido em frações mais fina e mais grossa em um ponto arbitrário da curva granulométrica (tamanho de partícula d_n). A fração mais grossa atua como filtro para a mais fina. O critério estabelece que o solo é internamente estável se a relação máxima ($d_{15c}/d_{85f})_{\max} \leq 4$). Sherard (1979) defendeu essa abordagem, propondo uma modificação do critério para $(d_{15c}/d_{85f})_{\max} \leq 5$), em que partículas com tamanho inferior a um dado valor d (constituindo uma fração de massa F) tenderiam a erodir se a fração de massa H de partículas com tamanho entre d e $4d$ fosse insuficiente. A razão H/F pode ser obtida da curva granulométrica considerando a porção mais fina do solo, com $F \leq 20\%$ para solos bem graduados ($C_u > 3$) e $F \leq 30\%$ para solos mal graduados ($C_u \leq 3$).

Segundo esse critério, um solo é considerado internamente instável se a razão mínima (H/F)_{min} for superior a 1,3. Posteriormente, em 1986, Kenney & Lau revisaram esse limite para $(H/F)_{min}>1.0$.

A Tabela 2.4 apresenta um resumo de outros critérios para identificar a instabilidade interna dos solos.

Tabela 2.4: Outros critérios para verificação do potencial de instabilidade do solo (Modificado de Palmeira 2018)

Referência	Condição
Bathia & Huang (1995)	Solos com $C_c>7$
Cristopher & Holtz (1985)	Solos com $C_u>20$ e curva granulométrica com concavidade voltada para cima
Lafleur (1999)	Solos com $C_u>6$ e curva granulométrica com concavidade voltada para cima

Devido ao desafio que apresentam esses tipos de solos, muitos autores têm investigado o comportamento do geotêxtil em contato com solos internamente instáveis, sob diferentes condições, por meio de diferentes tipos de ensaios, diferentes condições hidráulicas, tipos de geotêxtil, diversos tamanhos de corpo de prova etc. Em geral, observa-se que a redução das aberturas dos poros do geotêxtil aumenta sua capacidade de retenção de partículas, prevenindo fenômenos como o *piping*. Contudo, essa diminuição pode gerar incertezas quanto ao potencial de colmatação do filtro, especialmente em contato com solos internamente instáveis. Partículas finas e móveis podem não atravessar o filtro conforme projetado, o que resulta na impregnação ou cegamento progressivo do geotêxtil (Palmeira & Trejos Galvis, 2018).

Com base na literatura existente (Bhatia & Huang, 1995; Lafleur, 1999; Palmeira & Gardoni, 2000; Lee et al., 2002; Palmeira et al., 2005; Hong & Wu, 2011; Du et al., 2022; Odabasi et al., 2023; Santos, 2023), o desempenho de filtros geotêxteis em solos internamente instáveis pode ser significativamente comprometido ao longo da vida útil da obra. Os principais resultados dessas investigações são apresentados em termos da razão entre os coeficientes de permeabilidade finais (k_{sys}) e iniciais (k_{sys-0}) do sistema (solo e geotêxtil) em ensaios de filtração. É importante ressaltar que a dispersão observada para os resultados experimentais decorre das diferentes técnicas utilizadas para a medição das aberturas do geotêxtil (FOS), dos distintos gradientes hidráulicos (i) e da variedade de equipamentos e metodologias

experimentais adotadas por diferentes autores.

2.5 APRENDIZAGEM DE MÁQUINA (ML)

De forma geral, o aprendizado de máquina usa as informações disponíveis para encontrar a solução de um problema. Como mencionado anteriormente, considerando que cada problema tem características diferentes, é necessário estabelecer o melhor algoritmo que se adapte melhor à solução desejada. Nesse sentido, o ML é comumente categorizado em três tipos de análises que se baseiam na regra de aprendizado (Abraham, 2005).

2.5.1 TIPOS DE APRENDIZAGEM

Os algoritmos de aprendizagem são divididos em três grupos principais: a aprendizagem supervisionada, aprendizagem não supervisionada e aprendizagem reforçada. A supervisionada é utilizada para elaborar modelos preditivos, pois corresponde a um tipo de treinamento em que as informações de entrada e saída são conhecidas, sendo possível realizar uma previsão mais acurada. Por outro lado, a não supervisionada desenvolve modelos descritivos. Esses modelos precisam de interpretação humana, devido ao fato de que se baseiam só nos dados de entrada sem ter conhecimento do resultado esperado (Lantz, 2013).

O tipo de algoritmo a ser utilizado depende do tipo de análise que o problema esteja precisando resolver e das informações disponíveis. A Figura 2.8 apresenta algumas das técnicas de aprendizagem supervisionada que se usa no ML.

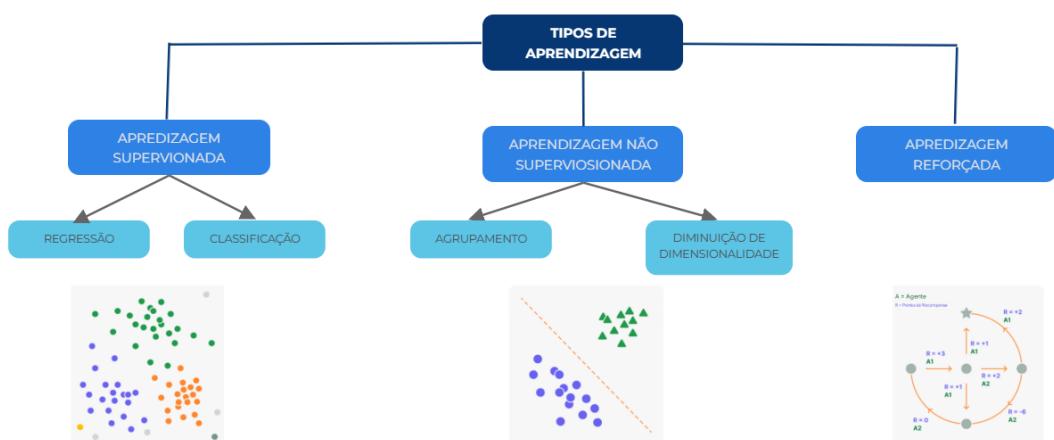


Figura 2.8: Tipos de Aprendizagem

2.5.1.1 APRENDIZAGEM SUPERVISIONADA

No aprendizado supervisionado, tanto os dados de entrada quanto os de saída (resposta desejada) são conhecidos, o que permite estabelecer a precisão da análise (com base no erro de comparação). Esse tipo de aprendizado é conhecido como aprendizado supervisionado por um professor (Haykin, 1999), em que o conhecimento é representado por uma entrada e um exemplo de saída (resultado). O aprendizado supervisionado pode ser dividido em dois tipos de tarefas: a primeira corresponde à Classificação, na qual o algoritmo atua como um filtro para definir a saída desejada; a segunda tarefa é a Predição, em que um valor alvo é gerado a partir de um conjunto de dados de entrada, também conhecidos como preditores, que são treinados por meio de exemplos (Géron, 2019). Então, a estatística de regressão estabelece uma relação entre as variáveis independentes (preditores) e o resultado previsto.

Existem diferentes tipos de algoritmos de aprendizado supervisionado. A seguir, descreve-se brevemente alguns dos mais comumente utilizados.

Tabela 2.5: Tipos de algoritmos de aprendizagem supervisionada (Modificado de Al-Atroush, 2024)

Tipo de Algoritmo	Descrição
Árvore de Decisão	A árvore de decisão é um método popular para classificação e regressão. Ela organiza as decisões como uma árvore, onde cada ponto de decisão (nó interno) usa uma característica dos dados. Cada escolha leva a um ramo, e o ponto final (nó folha) indica a previsão: a classe (para classificação) ou o valor previsto (para regressão) (Hastie et al., 2009).
<i>Naïve Bayes</i> (NB)	Este algoritmo de classificação utiliza o teorema de Bayes, uma abordagem probabilística para prever resultados. Ele considera cada dado independente ("naive"), o que simplifica os cálculos e torna o algoritmo mais eficiente, especialmente em grandes conjuntos de dados (Ray, 2019).
Regressão Linear	A regressão linear é um algoritmo simples e amplamente usado para modelar a relação entre uma variável dependente e uma ou mais variáveis independentes em dados contínuos (James et al, 2013)
Regressão Logística	Algoritmo amplamente utilizado em análises de classificação. A variável de resposta adota valores binários (Bishop, 2006)
<i>K- Nearest neighbor</i> (KNN)	O algoritmo <i>K-Nearest Neighbors</i> (KNN) é um método não paramétrico que classifica dados com base na proximidade e semelhança com outros dados já existentes (Ray, 2019).
Máquinas de Vetores de Suporte (SVM)	Algoritmo é usado para classificação e regressão. Ele cria linhas (hiperplanos) para separar os dados em diferentes categorias (Cortes & Vapnik, 1995).
<i>Random Forest</i> (RF)	Um algoritmo usado para classificação e regressão que combina várias árvores de decisão para aumentar a acurácia e a estabilidade. Ele cria várias amostras aleatórias dos dados, construindo uma "floresta" de árvores. Cada árvore faz uma previsão, e a média dessas previsões define o resultado final do modelo (Breiman, 2001).

Tipo de Algoritmo	Descrição
Redes Neurais Artificiais (RNA)	Inspirada no cérebro humano (Fausett, 1994), a Rede Neural Artificial (RNA) usa neurônios artificiais organizados em camadas, com camadas ocultas entre a entrada e a saída. Ela realiza uma regressão não linear, onde cada valor da camada anterior é ponderado, determinando sua importância para a saída (Haykin, 1999).

De maneira geral, é necessário seguir alguns passos padrões para resolver problemas com a Aprendizagem Supervisionada. A Figura 2.9 mostra passo a passo de como funciona a estrutura básica da Aprendizagem Supervisionada.

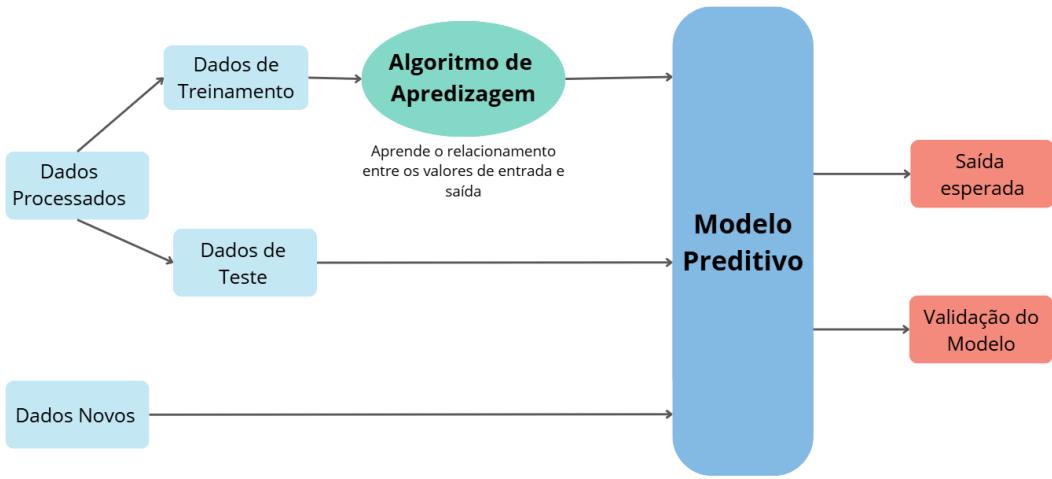


Figura 2.9: Funcionamento básico da Aprendizagem Supervisionada
(Adaptada de Escovedo & Koshiyama, 2020)

Utilizando a Figura 2.9 como exemplo, é possível visualizar que uma das primeiras partes da Aprendizagem Supervisionada, é o processamento dos dados, logo após, é necessário separar os dados em dados de treino e dados de teste, fazendo assim, com que seja possível construir um modelo e assim, executar a validação e a predição. Na literatura, essa separação é denominada de método *holdout*. Esse método, *holdout*, é uma técnica simples e comum que avalia o desempenho dos modelos de ML. Divide os dados em dois subconjuntos: um para treinar seu modelo e outro para testá-lo. O conjunto de treinamento é usado para ajustar os parâmetros do modelo, enquanto o conjunto de teste é usado para avaliar o quanto bem o modelo prevê dados não vistos. A ideia é simular como seu modelo se comportaria em um cenário real, onde você precisa fazer previsões sobre novos dados.

Para este presente trabalho, foi necessário utilizar a Aprendizagem Supervisionada. Então,

foram utilizados os seguintes passos:

- Fazer um tratamento dos dados, de modo a retirar todos os dados que podem atrapalhar o treinamento do algoritmo (removendo *outliers*). Os dados precisam ser representativos;
- Determinar a estrutura da função de aprendizagem correspondente ao algoritmo utilizado, no caso deste trabalho: o algoritmo de Retropropagação (*Backpropagation*);
- Executar o algoritmo escolhido no conjunto de dados de treino e no conjunto de dados de teste para avaliar a acurácia;
- Utilizar uma validação para os resultados (um exemplo é o *k fold cross-validation*, que foi utilizado neste trabalho e visa avaliar a capacidade de generalização dos modelos);
- Verificar a acurácia da aprendizagem em cada um dos conjuntos de dados por meio de métricas estatísticas.

2.5.1.2 APRENDIZAGEM NÃO SUPERVISIONADA

Ao contrário do tipo de aprendizado anterior, neste método, não há valores de saída predefinidos, de modo que os resultados são gerados com base na análise dos dados de entrada. Os algoritmos implementados aprendem a partir dos dados existentes de forma independente, ou seja, sem a necessidade de um “instrutor”, e ao encontrar padrões no conjunto de dados e classificar os dados de acordo com esses padrões (Mahesh, 2020; Samreen et al., 2023). Assim como no aprendizado supervisionado, existem diferentes algoritmos de tarefa e de desempenho, conforme apresentado na Tabela 2.6.

Tabela 2.6: Tipos de aprendizagem não supervisionada (Adaptado de Géron, 2019; Al-Atroush, 2024).

Tipo de Algoritmo	Descrição	Exemplos
Agrupamento (<i>Clustering</i>)	Permite a formação de grupos de dados com características semelhantes. Existem diferentes formas de agrupamento (Cohn & Holm, 2021; IBM, 2023b)	K-means, Análise Hierárquica (HCA)
Detecção de Anomalias	Técnica para encontrar relações interessantes entre diferentes elementos em um conjunto de dados (Kabir & Luo, 2020; Prasad et al., 2022).	One-class SVM, Isolation Forest
Visualização e Redução de dimensão	Utiliza Redes Neurais para representar os dados de forma simplificada e, a partir dessa representação, reconstruir os dados originais.	Análise de Componentes Principais (PCA)

Tipo de Algoritmo	Descrição	Exemplos
	<p>Visualização: Permite encontrar e mostrar valores específicos dentro de um grupo (cluster).</p> <p>Redução de Dimensionalidade: Diminui a quantidade de informação a ser analisada, combinando ou reduzindo parâmetros com características parecidas (Lever et al., 2017; DeepAI, 2023a)</p>	

2.5.1.3 APRENDIZAGEM REFORÇADA

Esse algoritmo é baseado em classes de recompensas positivas ou negativas. Ele utiliza um valor X como um agente no meio dos dados (ambiente) para encontrar diferentes ações e aprender com cada resultado, até identificar a saída mais bem-sucedida com base nas recompensas mais favoráveis (Géron, 2019). A Tabela 2.7 apresenta diferentes tipos de aprendizado por reforço, no qual uma decisão final é tomada com base no aprendizado acumulado.

Tabela 2.7: Tipos de aprendizagem reforçada (Modificada de Géron, 2019; Al-Atroush, 2024)

Tipo de Algoritmo	Descrição	Exemplos
<i>Q-Learning</i>	Permite que um agente aprenda as melhores ações em um ambiente por tentativa e erro, sem conhecer as regras. Ele aprende uma função Q, que estima a recompensa futura ao fazer uma ação em um estado. O objetivo é que o agente melhore essa função Q explorando o ambiente até encontrar as melhores ações Jang et al. (2019)	Robótica e Automação Jogos Finanças
<i>Deep Q-Networks (DQN)</i>	Combina aprendizado profundo com Q-Learning, usando uma rede neural para estimar o valor de cada ação possível em cada situação. Essa rede neural aprende a prever recompensas futuras com base nas experiências do agente, guardadas para treinar a rede. O agente escolhe as ações que provavelmente darão mais recompensa, segundo o que a rede neural aprendeu. Roderick et al. (2017)	Robótica e Automação Jogos Finanças Controle e Otimização
<i>Actor-Critic</i>	Utiliza duas redes neurais, onde o ator aprende a política, ou seja, a probabilidade de cada ação e o crítico , avalia o quão boas são as ações do ator. O ator decide as ações, o crítico as avalia, e essa avaliação ajuda o ator a melhorar suas escolhas Flet-Berliac et al. (2021).	Robótica e Automação Jogos Finanças Controle e Otimização

2.6 NEURAL ARTIFICIAL (RNA)

As Redes Neurais Artificiais (RNAs), também conhecidas como *Artificial Neural Networks* (ANN), são um tipo de inteligência artificial (AI) que usa técnicas computacionais baseadas na estrutura de neurônios biológicos para resolver problemas complexos (não lineares), por isso,

vem sendo a técnica mais utilizada na ML, pois ajudam resolver problemas do mundo real. Sua popularidade radica em como processam a informação para modelar relações complexas e não lineares entre parâmetros (Baghbani et al., 2022b).

Por meio da experiência, essas redes artificiais adquirem conhecimento e se tornam sistemas adaptativos, de modo a permitir a absorção e aplicação de informações ao longo do tempo. Isso é possível por meio uso de algoritmos de aprendizagem. Esses algoritmos operam com dados e resultados existentes para antecipar uma resposta desejada, fundamentando-se na experiência acumulada para realizar suas previsões (Abraham, 2005).

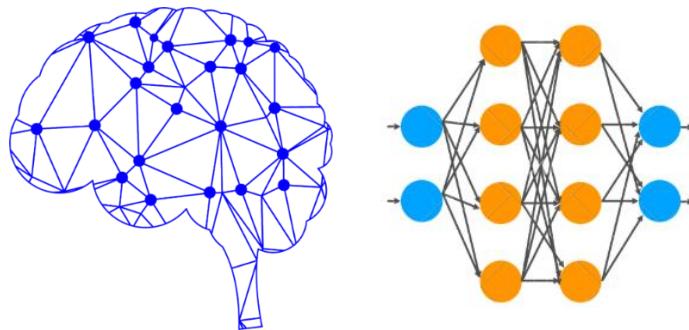


Figura 2.10: Exemplificação de RNA.

Assim, de forma geral as RNAs são estruturas compostas por elementos identificados como neurônios, que armazenam informações e são conectadas entre si por meio de *links* (conhecidos como pesos), que atuam como sinapses. Essas conexões geram sinais ativados por uma função, até que o sinal de saída (neurônio de saída) apresente o resultado desejado (Fausett, 1994; Jain et al., 1996; Haykin, 1999; Abraham, 2005).

De acordo com Fausett (1994), uma RNA tem três elementos principais: a arquitetura da rede, a regra de aprendizagem e a função de ativação (Figura 2.11). A arquitetura da rede, estabelece o número de neurônios, as conexões presentes entre eles e das disposições deles; já a regra de aprendizagem define o algoritmo que será utilizado para analisar o problema; e, por último, há a função de ativação.

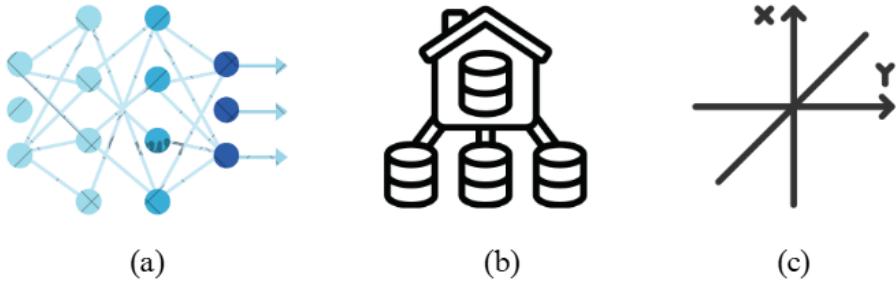


Figura 2.11: Exemplos dos Elementos principais da RNA: (a) Arquitetura de rede; (b) algoritmo de aprendizagem; (c) função de ativação

De forma geral, o modelo artificial de um neurônio de RNA é apresentado na Figura 2.12 esse neurônio típico inclui um sinal adicional $bias (\theta_o)$, o qual favorece a possibilidade de ativação do neurônio. A conexão dos neurônios (sinapses) é realizada pelos pesos (w), o qual amplifica cada um dos sinais recebidos. Já A função de ativação ($f(I_j)$) modela a forma que um neurônio responde ao nível de excitação, limitando e definindo a saída da rede.

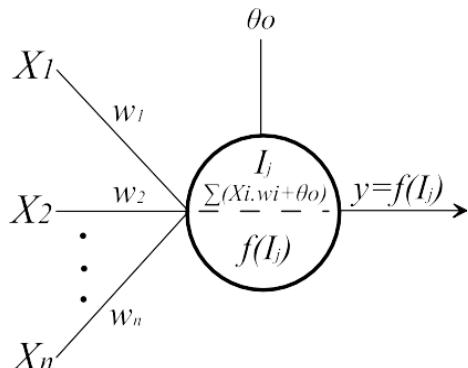


Figura 2.12: Representação esquemática de um neurônio artificial (Villamil González 2023).

Na Figura 2.12, apresenta-se as entradas (X_1, X_2, \dots, X_n), os pesos sinápticos correspondentes (w_1, w_2, \dots, w_n), o bias (θ_o), a função de combinação linear ($I_j = \sum(X_i \cdot w_i + \theta_o)$) e a função de ativação ($y = f(I_j)$) que produz a saída do neurônio.

As Redes Neurais Artificiais (RNAs) podem ser classificadas de diversas maneiras, considerando sua arquitetura, o tipo de algoritmo de aprendizado, a direção da análise dos dados e a sua aplicação (Charytoniuk, 2000).

Quanto à sua aplicação, as RNAs se dividem principalmente em duas categorias: classificação e aproximação de função (previsão). A primeira é usada para reconhecer padrões de dados e/ou

classifica em categorias predefinidas. E a segunda, a rede, é treinada para aprender e generalizar relações não lineares complexas entre certos parâmetros de entrada e saída, a fim de tornar possível a previsão de parâmetros de saída para determinados dados de entrada. Esta última é muito utilizada na engenharia geotécnica (Baghbani et al., 2022b).

Em relação à sua arquitetura, as RNAs se classificam fundamentalmente em monocamadas e multicamadas. Essa distinção se baseia no número de camadas existentes entre a camada de entrada e a camada de saída da rede (Charytoniuk, 2000). Os RNAs monocamada possuem apenas de uma camada de neurônios de saída que recebem diretamente os sinais de entrada. Cada neurônio de saída recebe sinais de todos os neurônios de entrada. Assim, a saída de cada neurônio é calculada aplicando uma função de ativação à soma ponderada de todas as entradas. Esse tipo de redes aprende apenas relações lineares entre as entradas e as saídas. Por outro lado, o desempenho de uma RNA multicamada é caracterizado pela presença de uma a mais camadas intermediárias, também chamada de camadas ocultas (*hidden layers*).

Embora as RNAs multicamadas geralmente apresentem uma capacidade de modelagem superior às monocamadas, o desempenho global de uma rede neural é intrinsecamente dependente de diversos fatores :

- **Qualidade e quantidade dos dados de treinamento:** A eficácia da aprendizagem está diretamente ligada à riqueza e à quantidade de dados fornecidos;
- **Arquitetura da rede:** O número e a organização das conexões entre os neurônios definem a capacidade da rede;
- **Intensidade das conexões (pesos):** A força das sinapses neurais, representada pelos pesos, determina a influência de cada sinal;
- **Algoritmos de aprendizagem:** O método de ajuste dos pesos durante o treinamento afeta a convergência e a qualidade do modelo.

Entre as RNAs multicamadas, o Perceptron Multicamada (MLP) se destaca por seu alto poder computacional (Braga et al., 2007). Um MLP é composto por neurônios interconectados em um sistema organizado em pelo menos três camadas: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (Siddique & Adeli, 2013; Goodfellow et al., 2016). Os neurônios da camada de entrada atuam como meros transmissores do vetor de entrada para as camadas

subsequentes, isto é, não realizam cálculos próprios. Nas camadas ocultas e de saída, cada neurônio executa uma transformação não linear simples sobre a soma ponderada de suas entradas, utilizando uma função de ativação como ReLU, tanh ou sigmoid. Essa não linearidade permite ao MLP a capacidade de aproximar funções complexas (Gardner & Dorling, 1998).

De acordo com Gardner & Dorling (1998), o MLP aprende essa função de mapeamento de forma supervisionada, ao utilizar um conjunto de dados de treinamento com pares de entrada e saída desejada. Em problemas de regressão, o objetivo do treinamento é aproximar a função f de tal modo que o valor previsto $f(x_i, h)$ seja o mais próximo possível do valor alvo y_i . A diferença entre o valor previsto e o valor alvo constitui o sinal de erro. Durante o treinamento, esse sinal de erro é utilizado para determinar como os pesos (h) da rede devem ser modificados, com vistas a minimizar o erro global do MLP.

O treinamento de redes MLP geralmente envolve processos iterativos baseados em gradientes (Rumelhart, Hinton, Willians, 1986), como o Descida de Gradiente Estocástico (SGD) ou métodos Quasi-Newton (como o Broyden-Fletcher-Goldfarb-Shanno L-BFGS). O objetivo é minimizar a função de erro global. Embora o SGD seja simples de implementar, sua otimização e treinamento podem ser desafiadores em cenários com dados esparsos ou de baixa dimensionalidade, comuns em computação de alto desempenho (HPC). Nesses casos, o L-BFGS emerge como uma alternativa altamente competitiva e, por vezes, superior ao SGD (Ngiam et al., 2011).

É importante notar que o treinamento do MLP não garante a convergência para mínimo global e é sensível à escolha dos hiperparâmetros (Goodfellow et al., 2016). Esses hiperparâmetros incluem a função de ativação, o número de camadas ocultas, o número de neurônios por camada (*hidden layer*) o otimizador (método iterativo baseado em gradientes) e o número máximo de iterações (Goodfellow et al. 2016).

Desde os anos 80, as redes neurais têm sido aplicadas na engenharia civil (Chou & Pham, 2013; Chou et al., 2016). Nos últimos tempos, a engenharia geotécnica tem adotado os métodos computacionais em resposta à heterogeneidade em solos e rochas e ao seu comportamento com matérias geotécnicos. Segundo Baghbani et al (2022), essa heterogeneidade resulta em considerável incerteza de suas propriedades mecânicas, o que dificulta a previsão do

comportamento desses materiais. Nesse contexto, há a mecânica computacional principalmente computadores e métodos numéricos para simular, analisar e prever o comportamento mecânico de materiais geológicos. As técnicas computacionais modernas possibilitam lidar com muitos problemas complexos de engenharia, levando em consideração muitas das propriedades típicas dos materiais geotécnicos, como o comportamento acoplado da água nos poros e dos materiais sólidos, o comportamento elastoplástico não linear e os processos de transporte.

2.6.1 ARQUITETURA DA REDE NEURAL

Os autores Jain et al (1996) e Braga et al. (2007) comentam que é crucial delimitar o tipo de problema tratável pela rede. Sua definição abrange características como o número de camadas, a quantidade de neurônios por camada, o tipo de conexão entre os nós e a tipologia geral da rede. Essas características, em conjunto, determinam a dimensão da rede e a forma como seus neurônios se. A Figura 2.13 ilustra algumas arquiteturas de RNAs.

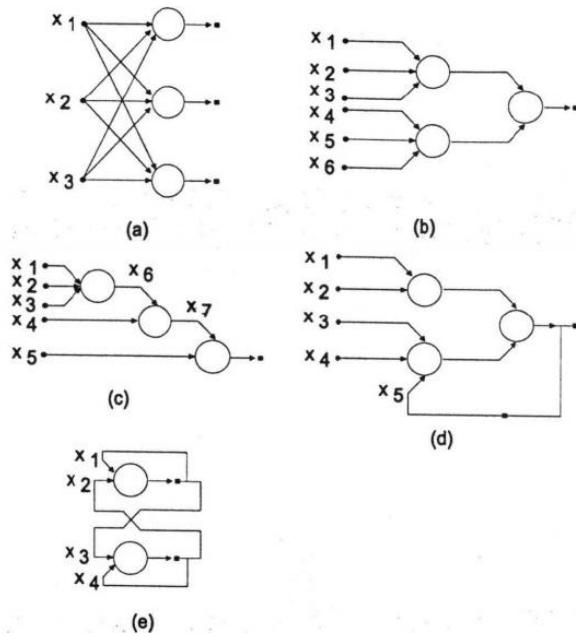


Figura 2.13: Arquiteturas de Redes Neurais Artificiais (Braga et al.,2007)

Quanto ao número de Camadas, as RNAs são classificadas em monocamadas e multicamadas:

- **As Redes Monocamadas:** Se caracterizam pela conexão direta entre a camada de entrada e a camada de saída, sem a presença de camadas intermediárias. Essa arquitetura limita sua capacidade de resolução a problemas linearmente separáveis. Esse tipo de redes são presentadas na Figura 2.13a e Figura 2.13e,
- **As Redes Multicamadas** incorporam uma ou mais camadas intermediárias (*hidden layers*)

layers) (Figura 2.13b, Figura 2.13c e Figura 2.13d). A introdução dessas camadas permite que a rede modele relações complexas e não lineares, tornando-as adequadas para uma vasta gama de aplicações, incluindo visão computacional, processamento de linguagem natural e reconhecimento de padrões. Contudo, o emprego de um número excessivo de camadas ocultas não é recomendado. Isso se deve ao fenômeno da dissipação do gradiente durante o treinamento: à medida que o erro medido na saída é propagado para camadas anteriores, sua acurácia diminui progressivamente (Braga et al., 2007). Apenas a camada de saída possui uma noção precisa do erro cometido pela rede; a última camada oculta recebe apenas uma estimativa desse erro, e a penúltima camada, uma estimativa da estimativa

No que diz respeito ao tipo de conexão entre os neurônios (ou nós). A arquitetura das RNAs pode ser categorizada em *feedforward* (alimentação direta) e recorrente (*ou feedback*):

- **As Redes *Feedforward*** processam a informação de maneira unidirecional, onde a saída de um neurônio não serve como entrada para outros neurônios na mesma camada ou em camadas precedentes. O fluxo de informação ocorre em uma única direção, da entrada para a saída, sem a formação de ciclos ou realimentação (Figura 2.13a, Figura 2.13b e Figura 2.13c)
- **As Redes *Feedbacks ou Recorrente*:** se distinguem pela sua capacidade de “memória”, uma vez que permitem que informações de entradas passadas influenciem o processamento de entradas subsequentes. Essa característica as torna adequadas para lidar com dados sequenciais, como séries temporais e texto, em que a ordem dos elementos é fundamental. As redes recorrentes apresentam um comportamento que busca simular de forma mais realista a dinâmica temporal dos dados e são apresentadas (Figura 2.13d e Figura 2.13e)

O processamento em uma RNA é iniciado na camada de entrada, que contém os valores iniciais definidos em n neurônios (X_i). A informação então flui sequencialmente através das camadas ocultas, mediada por conexões, também conhecidas como pesos sinápticos (w_i). Cada neurônio recebe um sinal ponderado e o transmite para o neurônio da camada seguinte (X_{i+1}). Em cada camada, a informação precedente é transformada em um valor numérico por meio da aplicação de uma função de ativação (f). Esse processo iterativo continua até a camada de saída, em que o valor final do modelo (y) é obtido. Para evitar a ocorrência de saídas nulas em cada neurônio,

um valor conhecido como “bias” (θ_0) pode ser incorporado entre as transformações de cada camada (Haykin, 1999; Shahin et al., 2009). A Eq. (2.4) resume o processo descrito

$$y = f(\sum_{i=1}^n X_i w_i + \theta_0) \quad \text{Eq. (2.4)}$$

2.6.2 PERCEPTRON DE MÚLTIPLAS CAMADAS – MLP

Como mencionado anteriormente, as redes monocamada (Figura 2.13a) são utilizadas para resolver problemas linearmente separáveis, já as redes *perceptron* de múltiplas camadas MLP (Figura 2.13b) são utilizados para problemas não linearmente separáveis e complexos. Segundo Braga et al. (2007), a acurácia obtida e a implementação da função objetivo é influenciada pelo número de nós utilizados nas camadas ocultas.

Assim, no caso de RNA's com mais de uma camada intermediaria, o processo realizado em cada nó é definido pela combinação dos processos realizados pelos nós da camada anterior que estão conectados a ele, tornando o processo de uma MLP dependente em cada camada.

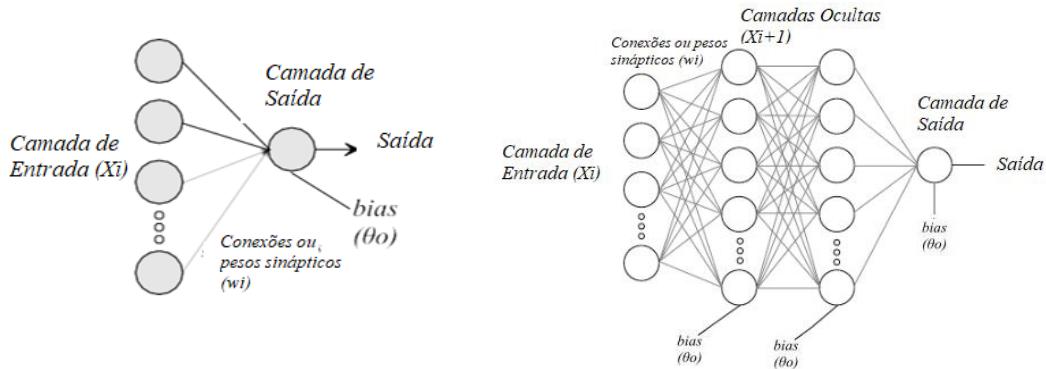


Figura 2.14: (a)RNA monocamada e (b) RNA multicamada (MLP) (Adaptado de Villamall,2024)

A definição da arquitetura de uma Rede Neural Artificial (RNA) envolve diversos parâmetros de projeto, como o número de neurônios na camada de entrada, o número de camadas ocultas, a quantidade de neurônios em cada camada oculta e o número de neurônios na camada de saída. A determinação desses parâmetros frequentemente se baseia em múltiplas execuções do sistema, empregando o método de tentativa e erro. Embora não exista uma estrutura unificada para a seleção da arquitetura ótima e de seus parâmetros (Chung & Kusiak, 1994; Kusiak &

Lee, 1996), pesquisas têm contribuído para a definição do número de camadas ocultas, do número de neurônios por camada e da taxa de aprendizado, entre outros aspectos.

A seleção de parâmetros de entrada adequados para uma RNA é um dos processos mais desafiadores e pode ser influenciada pelos seguintes critérios (Park, 2011):

- **Interdependências e redundâncias entre os parâmetros:** a presença de variáveis altamente correlacionadas ou que fornecem informações semelhantes pode prejudicar o desempenho e a interpretação da rede;
- **Necessidade de otimização da complexidade:** Em alguns casos, a omissão de certos parâmetros pode ser benéfica para reduzir o número total de entradas, simplificando a topologia da rede e diminuindo a complexidade computacional do problema.
- **Ausência de conhecimento prévio dos dados:** frequentemente, as RNAs são aplicadas em problemas em que as relações subjacentes entre as variáveis de entrada e saída não são bem compreendidas, o que dificulta a identificação *a priori* dos parâmetros mais relevantes.

Já o número de camadas ocultas, o número de neurônios nas camadas ocultas e o número de neurônios na camada de saída são encontrados usando várias execuções repetidas do sistema com base no método de tentativa e erro. Não há uma estrutura clara para selecionar a arquitetura ótima da RNA e seus parâmetros (Chung & Kusiak, 1994; Kusiak & Lee, 1996). No entanto, alguns trabalhos de pesquisa contribuíram para determinar o número de camadas ocultas, o número de neurônios em cada camada, a seleção do parâmetro da taxa de aprendizado e outros.

Como mencionado anteriormente, a definição do número de camadas ocultas requer de cuidado, pois um número excessivo de camadas intermediárias pode comprometer a acurácia do erro durante o treinamento. Em relação a essa questão, autores como os de Cybenko (1989), Hertz et al. (1991) e Funahashi (1989) investigaram o número de camadas necessárias para a implementação eficaz de uma RNA. Suas conclusões apontam que um *Perceptron Multicamada* (MLP) com apenas uma camada oculta é capaz de aproximar qualquer função contínua. A utilização de duas à três camadas ocultas, por sua vez, demonstram-se suficiente para aproximar virtualmente qualquer função matemática.

É importante destacar que determinar o número de camadas ocultas e o número de neurônios em cada camada oculta é uma tarefa considerável. O número de camadas ocultas geralmente é um passo crítico. O número de camadas ocultas necessário depende da complexidade da relação entre os parâmetros de entrada e o valor de saída. A maioria dos problemas requer apenas uma camada oculta e, se a relação entre as entradas e a saída for linear, a rede não precisa de nenhuma camada oculta adicional. É improvável que qualquer problema prático exija mais de duas camadas ocultas. Cybenko (1989) e Bounds et al. (1988) sugeriram que uma camada oculta é suficiente para classificar padrões de entrada em diferentes grupos.

Chester (1990) argumentou que uma rede com duas camadas ocultas deveria ter um desempenho melhor do que uma rede com uma camada oculta. Mais de uma camada oculta pode ser útil em certas arquiteturas, como correlação em cascata (Fahlman & Lebiere, 1990) e outras.

Uma explicação simples para o porquê de redes maiores às vezes proporcionarem treinamento aprimorado e menor erro de generalização é que os graus de liberdade extras podem auxiliar na convergência; ou seja, a adição de parâmetros extras pode diminuir a chance de ficar preso em mínimos locais ou em “platôs”. Os métodos de treinamento mais comumente usados para redes de retropropagação são baseados no gradiente descendente, ou seja, o erro é reduzido até que um mínimo seja alcançado, seja um mínimo global ou local. No entanto, não há uma teoria clara para dizer quantas unidades ocultas são necessárias para aproximar qualquer função dada. Se apenas uma entrada estiver disponível, não se observa nenhuma vantagem em usar mais de uma camada oculta. Mas as coisas ficam muito mais complicadas quando duas ou mais entradas são fornecidas. A regra prática para decidir o número de camadas ocultas é normalmente começar com uma camada intermediária (Lawrence, 1994). Se a rede com uma camada oculta não treinar bem, tente aumentar o número de neurônios. Adicionar mais camadas ocultas deve ser a última opção.

Ademais, além da determinação do número de camadas ocultas, a definição do número de nós ou neurônios nas camadas intermediárias é um aspecto crucial. Embora não haja uma padronização universal para essa quantidade, Braga et al. (2007) observam que o número ideal de nós por camada está intrinsecamente ligado à distribuição dos padrões presentes nos conjuntos de treinamento e validação da rede. Entretanto, abordagens mais recentes têm

ganhado destaque, como a definição do número de neurônios em função da quantidade de unidades de entrada (*input*) e de saída (*output*).

Segundo Park (2011), a escolha do tamanho da camada oculta é dependente do problema. Por exemplo, qualquer rede que requeira compressão de dados deve ter uma camada oculta menor que a camada de entrada (Swingler, 1996). Uma abordagem conservadora é selecionar um número entre o número de neurônios de entrada e o número de neurônios de saída. Uma boa regra prática é começar com um número de neurônios ocultos igual à metade do número de neurônios de entrada e, então, adicionar neurônios se o erro de treinamento permanecer acima da tolerância de erro de treinamento, ou reduzir neurônios se o erro de treinamento cair rapidamente para a tolerância de erro de treinamento. A Tabela 2.8 apresenta de forma resumida os critérios para definição do número de neurônios por camada oculta.

Tabela 2.8: Critério para Selecionar o Número de Neurônios na Camada Oculta
(modificado de Park,2011)

Fórmula	Autor
$h = 2i + 1$	Hecht-Nelson (1987)
$h = \frac{(i + o)}{2}$ faixa $10N - i - o \leq h \leq 2N - i - o$	Lawrence & Fredrickson (1988)
$P h = i \log_2 P$	Marchandani & Cao (1989)

Notas: h = número de neurônios ocultos, i = número de neurônios de entrada o = número de neurônios de saída, P= número de padrões de treinamento

Um número inadequado de neurônios por camada pode acarretar problemas significativos no modelo, como *overfitting* e *underfitting*. O *overfitting* está relacionado à capacidade excessiva da rede de memorizar os dados de treinamento, incluindo ruídos e variações específicas, o que compromete sua capacidade de generalização para novos dados. Por outro lado, o *underfitting* geralmente está associado a uma convergência inadequada da rede, frequentemente afetada por um número excessivo de neurônios em relação ao número de conexões disponíveis (ou seja, uma arquitetura com mais neurônios do que conexões significativas).

2.6.3 ALGORITMO DE TREINAMENTO – BACKPROPAGATION (BP)

Como mencionado anteriormente, a RNA utiliza aprendizado supervisionado, o que permite à

rede controlar os resultados obtidos a partir de dados de saída conhecidos. Nesse processo de aprendizado, a rede ajusta iterativamente os pesos e o viés (parâmetros de ajuste) até alcançar o resultado com o menor erro possível, de modo que esse ajuste é realizado por meio de algoritmos de treinamento.

Existem diferentes arquiteturas de redes neurais, classificadas segundo o tipo de algoritmo de treinamento empregado, ou seja, de acordo com a maneira como os pesos e o viés são ajustados. No caso de redes neurais multicamadas, o algoritmo de Retropropagação (*Backpropagation* – BP) tem sido amplamente utilizado em problemas de engenharia (Riedmiller & Braun, 1993). Desenvolvido em 1986 por David Rumelhart, Geoffrey Hinton e Ronald Williams, esse algoritmo se baseia no método de descida de gradiente de primeira ordem. O método de descida de gradiente é um algoritmo de otimização utilizado para encontrar o mínimo de uma função, nesse caso, a função de erro (a diferença entre o valor previsto e o valor real). Assim, o algoritmo ajusta os parâmetros do modelo, como os pesos e o viés, de forma a reduzir esse erro. O gradiente indica a taxa de variação da função de erro em relação aos parâmetros do modelo, informando se o erro aumenta ou diminui (Basheer & Hajmeer, 2000; Soleimanbeigi & Hataf, 2006).

De forma resumida, a retropropagação opera em duas fases principais, apresentado na Figura 2.15, percorrendo a rede em sentidos opostos: *forward* (para frente) e *backward* (para trás). Na primeira fase, denominada *forward*, realiza-se uma análise inicial dos dados de entrada até a camada de saída, definindo-se os valores iniciais dos pesos sinápticos e do viés. Na segunda fase, chamada *backward*, calcula-se a diferença entre o valor previsto e o valor real, ou seja, o erro (E). Esse erro é, então, retropropagado para cada camada da rede, ajustando-se os pesos e o viés das camadas com base no erro encontrado na saída, utilizando-se o gradiente da função de erro.

Esses ajustes são realizados em cada camada, da saída para a entrada, o que permite que a rede aprenda e melhore suas previsões. Além disso, esses processos iterativos de avanço e retrocesso são chamados de épocas, durante as quais o algoritmo é ajustado para reduzir o erro. A cada época, a rede ajusta os pesos e o viés para minimizar o erro (E) e aproximar ao máximo o valor obtido pela rede (\hat{y}_i) do valor real (y_i) (Camarena-Martinez et al., 2021).

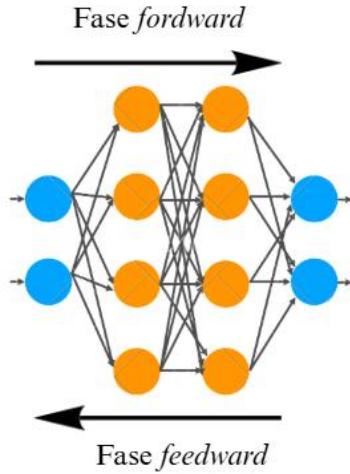


Figura 2.15: Algoritmo de Retropropagação ou *Back-propagation* (Adaptado de Braga et al., 2007).

O Erro é representado pela Eq. (2.5) onde \hat{y}_i é o valor obtido pelo modelo (valor previsto), y_i , valor real obtido por meio de resultados de ensaios; e n os números de neurônios.

$$E = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad \text{Eq. (2.5)}$$

O algoritmo de treinamento inicia atribuindo valores aleatórios aos pesos e ao viés. A cada iteração, o valor anterior do peso sináptico é ajustado incremento variável, que pode ser positivo ou negativo e é determinado pela regra delta (Zupan & Gasteiger, 1993; Abraham, 2005). A Eq. (2.6) apresenta esse ajuste do peso:

$$w_{ji}^l(t) = w_{ji}^l(t-1) + \Delta w_{ji}^l(t); \Delta w_{ji}^l(t) = \eta \frac{\partial E}{\partial w_{ij}} + \mu \Delta w_{ji}^{l(\text{previo})} \quad \text{Eq. (2.6)}$$

Nessa equação, t é cada iteração, j e i são os neurônios (ou os nós) de cada camada l , w é o peso sináptico, E é a média dos erros quadráticos totais, η é a taxa de aprendizado e μ é o coeficiente de momento.

A taxa de aprendizado (η) define a magnitude do passo durante o ajuste do peso; um valor alto pode causar oscilações e uma convergência lenta, enquanto uma taxa muito baixa exige várias iterações. Em relação ao coeficiente de momento (μ), ele modifica o valor da iteração anterior para diminuir o erro do valor atual; se o valor for baixo, o treinamento se torna lento. Assim, um valor adequado de η e μ garante um treinamento apropriado e um aprendizado rápido. Esse

mesmo procedimento é utilizado para o parâmetro de viés (Abraham, 2005)

Embora o uso do algoritmo BP apresente bons resultados no RNA, tem algumas limitações as quais serão detalhadas na seção 0 deste trabalho.

A função de ativação constitui outro conceito fundamental em redes neurais. Essas funções, aplicadas no interior dos neurônios, introduzem propriedades não lineares ao sistema, conferindo-lhe a capacidade de aprendizado a partir de intrincados padrões de dados (Azoor et al, 2022). Sua relevância na estimativa dos resultados se acentua progressivamente ao longo das épocas de treinamento. Tal importância reside no fato de que a função de ativação modula a soma ponderada de todos os sinais de entrada de um neurônio, determinando a intensidade de sua ativação (Basheer & Hajmeer, 2000). Uma variedade de funções de ativação está disponível, incluindo a sigmoidal, a hiperbólica (ou tangencial) e a ReLU (*Rectified Linear Unit* – Unidade Linear Retificada).

Embora as duas primeiras funções sejam amplamente aplicáveis, elas não apresentam simetria em relação ao eixo central das coordenadas (eixo zero). Glorot et al. (2011) sugerem que a função ReLU é preferível por ser unilateralmente antissimétrica, o que resulta em uma resposta nula para uma entrada real oposta.

A função sigmoide também conhecido como função logística executa a transformação na entrada x , de modo a gerar um valor de saída entre 0 e 1. Na Figura 2.16, apresenta-se a equação e o gráfico que descreve esta função.

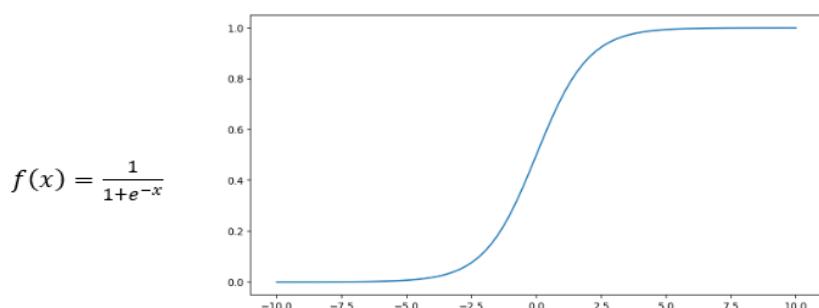


Figura 2.16:Equação e Gráfico da Função Sigmoidal

Já a função $tanh$ (tangente hiperbólica) transforma a entrada x para gerar um valor de saída entre -1 e 1. Apresenta-se, na Figura 2.17 a equação e o gráfico que descreve esta função.

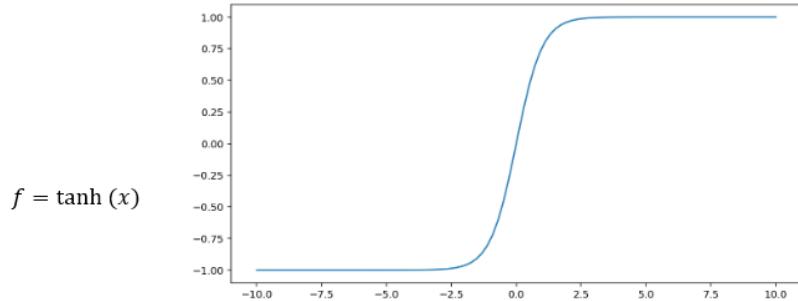


Figura 2.17 — Gráfico e Equação da Função *Tanh*

Por último, a função de ativação ReLU (unidade linear retificada) transforma a saída usando o seguinte algoritmo:

- Se o valor de entrada x for menos que 0, retornará ao valor de 0;
- Se o valor de entrada x for maior ou igual a 0, retorne ao valor de entrada.

Na Figura 2.18, apresenta-se a equação e o gráfico que definem a função ReLU.

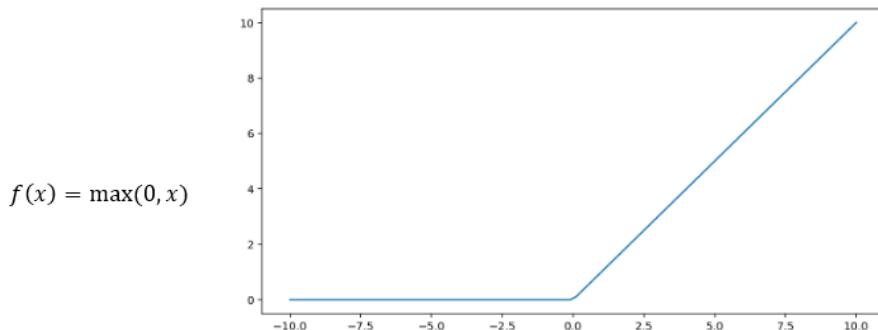


Figura 2.18: Equação e Gráfico da Função ReLU

Neste estudo, a função de ativação “ReLU” (Unidade Linear Retificada) foi escolhida em ambas as camadas ocultas, pois é atualmente considerada a função de ativação que produz as melhores soluções, porque é menos suscetível ao problema de gradiente nulo na fase de treinamento da rede. Uma vantagem do ReLU é que ele pode convergir em um curto período em comparação com as funções Sigmoid ou *Tanh*. A equação para o ReLU pode ser vista na Figura 2.18

2.7 RNA APLICADO À ENGENHARIA GEOTÉCNICA

Esta seção apresenta uma breve compilação de artigos que abordam a aplicação da IA na Engenharia Civil, especificamente as Redes Neurais Artificiais (RNA). Assim, será destacado

seu uso na Engenharia Geotécnica e no comportamento de geossintéticos.

A inteligência artificial aprimora os métodos computacionais na engenharia geotécnica, oferecendo vantagens sobre os métodos convencionais como Método de Elementos Finitos, Método dos Elementos de Contorno e o Método de Elementos Discretos. As vantagens aumentam a acurácia e eficiência dos cálculos, complementando e otimizando as abordagens tradicionais. Pois, ao lidar com relações não lineares, os métodos de cálculos convencionais exigem premissa simplificadoras e vários ajustes manuais dos parâmetros utilizados resultando em valores menos precisos.

Em contrapartida os algoritmos de IA e ML processam dados multidimensionais complexos, extraem características de forma automática e constroem modelos não lineares de alta precisão. Por exemplo, segundo (Shao et al. 2023), os algoritmos como Maquinas de Vetores de Suporte (SMV) e as Redes Neurais Aritficiais (ANN), sobressaem na previsão de capacidade de carga de fundação e na análises de estabilidades de taludes, melhorando a acurácia das previsões.

No caso a engenharia geotécnica, a maioria de propriedades dos materiais exibem características altamente não lineares, assim a coleta de dados de análise geotécnico, seja por meio de ensaios laboratoriais ou na literatura requer de muito tempo e investimento financeiro. Portanto a identificação de parâmetros de entradas que impactam significativamente na modelagem de IA se torna essencial. Os autores Liu et al.(2024) apresentaram um resumo dos parâmetros de entrada muito utilizados nas áreas de engenharia geotécnica baseado em resultados de uma revisão bibliográfica, os quais serviram como orientação inicial para a seleção dos principais parâmetros de entrada durante a coleta de dados. Este resumo dos parâmetros de entradas, encontram-se na Tabela 2.9.

Tabela 2.9: Seleção de parâmetros de entrada e saída para modelos de IA em diferentes áreas da engenharia geotécnica (Liu et al., 2024)

Área de pesquisa	Parâmetros de entrada comumente usados	Parâmetros previstos (saída)
Propriedades Físicas	Propriedades fundamentais de amostras geotécnicas brutas, dados experimentais históricos, condições, imagens de microscopia de materiais geotécnicos, localização geográfica e informações estratigráficas das amostras	Distribuição granulométrica, forma das partículas e características geométricas, porosidade ou índice de vazios, saturação ou teor de umidade, e vários tipos de densidade

Área de pesquisa	Parâmetros de entrada comumente usados	Parâmetros previstos (saída)
Resistência	Distribuição granulométrica de amostras geotécnicas, dados experimentais históricos (tensão-deformação) e condições ambientais como temperatura, umidade e pressão	As resistências máximas de materiais geotécnicos, resistência à tração, resistência à compressão e resistência ao cisalhamento
Módulo	Informações microestruturais de amostras geotécnicas, histórico e ciclos de carregamento, e resultados de testes laboratoriais	Módulo de elasticidade, módulo de deformação e coeficiente de Poisson .
Modelo constitutivo baseado em dados	Incluindo histórico de tensão-deformação (como caminhos de carregamento, taxas e dados de diferentes estágios), juntamente com parâmetros para distribuição de trincas e micro trincas	A relação tensão-deformação dos materiais
Propriedade de Compressão	Parâmetros de estado inicial (como porosidade inicial, teor de umidade e índice de compressão), condições de carregamento e condições ambientais (como temperatura, umidade e pressão confinante)	Curva de compressão, módulo de compressão e índice de compressão, porosidade e teor de umidade previstos sob pressões variáveis, e outros parâmetros relevantes
Propriedade de Permeabilidade	Propriedades fundamentais do solo (como distribuição do tamanho das partículas e estrutura dos poros), teor de umidade inicial e grau de saturação, condições ambientais como temperatura e pressão, e condições de carregamento	Coeficiente de permeabilidade, curvas de propriedade de permeabilidade relacionadas à saturação, e outros parâmetros relacionados à permeabilidade (como porosidade efetiva e coeficiente de difusão)
Propriedade de Liquefação	Parâmetros sísmicos, características tipo de solo e tamanho das partículas, condições do lençol freático, parâmetros de estado do solo e eventos de liquefação	Potencial de liquefação e deformações do solo induzidas pela liquefação, como subsidência e fissuras

Assim, a IA tem atraído interesse em diversos campos profissionais devido a sua versatilidade, simplicidade de aplicação e capacidade de resolver problemas complexos a partir de resultados de dados existentes. Um dos primeiros autores a compilar registros de publicações sobre IA na Engenharia Civil foi Sriram, em 1984, que apresentou uma série de títulos relacionados à arquitetura, engenharia civil e geologia, que utilizavam a metodologia de Sistemas Especialistas Baseados em Conhecimento (KBES). Posteriormente, outros autores publicaram pesquisas de ponta, que compilavam a aplicação da IA na engenharia civil, o que evidenciou um grande interesse na análise e resolução de problemas (Reich, 1997; Adeli, 2001; Lu et al., 2012; Shahin, 2013; Salehi & Burgueño, 2018; Dede et al., 2019; Huang & Fu, 2019; Lagaros & Plevris, 2022).

Reich (1997), desenvolveu um trabalho em que propos um processo de sete etapas para a implementação bem-sucedida de soluções de ML. Através de exemplos em engenharia civil, demonstrou que, embora o ML tenha um potencial imenso ainda a ser explorado, seu sucesso é intrinsecamente ligado à adesão cuidadosa e ao tratamento das complexidades inerentes a cada

fase desse processo proposto.

O trabalho desenvolvido por Lu et al. (2012) explora uma gama de métodos e teorias de IA desenvolvidos para aplicações em engenharia civil. Isso inclui desde técnicas amplamente conhecidas como computação evolutiva, redes neurais, sistemas fuzzy e sistemas especialistas. Ao final, o artigo também identifica as principais tendências de pesquisa, fornecendo uma visão abrangente do progresso da inteligência artificial no contexto da engenharia civil.

Shanin, em 2013 realizou um estudo que revisa de forma abrangente o uso, vantagens, desafios e potencial da Inteligência Artificial em diversas subáreas da engenharia civil, com ênfase na engenharia geotécnica. O trabalho concentra-se em três técnicas de IA tidas como as mais eficazes para essa área: Redes Neurais Artificiais (ANNs), Programação Genética (GP) e Regressão Polinomial Evolutiva (EPR), com as ANNs sendo a mais empregada.

Em 2019, os autores Dede et al. (2019), apresentaram um estudo que se concentra nas aplicações da Inteligência Artificial (IA) na engenharia civil, destacando seu papel crescente e potencial. Reuniu artigos de revisão que abordam técnicas como Redes Neurais Artificiais (ANN), sistemas fuzzy, sistemas especialistas e inteligência de enxame também foram incluídos.

Uma pesquisa realizada por Lagaros & Plevris, 2022 na base de dados Scopus, em junho de 2022, utilizando termos como "inteligência artificial" e "engenharia civil", revelou mais de 14.000 artigos publicados desde 2000. Esse crescimento acelerado indica que o uso da IA na engenharia civil está em ascensão e trará inovações significativas nos próximos e revelou mais de 14.000 artigos publicados desde 2000.

As primeiras pesquisas publicadas sobre o uso de RNAs na área de engenharia geotécnica foram apresentadas nos primeiros anos da década dos 90. Trabalhos como “Uso de RNAs para determinação de coeficiente de condutividade hidráulica em solos não saturados” por Gribb & Gribb, em 1994, entre outros (Lee & Sterling, 1992; Kaseko & Ritchie, 1993; Pachepsky et al., 1996; Schaap & Bouten, 1996) apresentaram resultados interessantes e deram um bom impulso para o uso do RNA em mais problemas geotécnicos.

Baghbani et al. (2022), também, realizam uma revisão de artigos, publicações e trabalhos de

aplicação IA nessa área da engenharia. A Figura 2.19 apresenta o número de estudos realizados usando os métodos de IA em nove campos da engenharia geotécnica

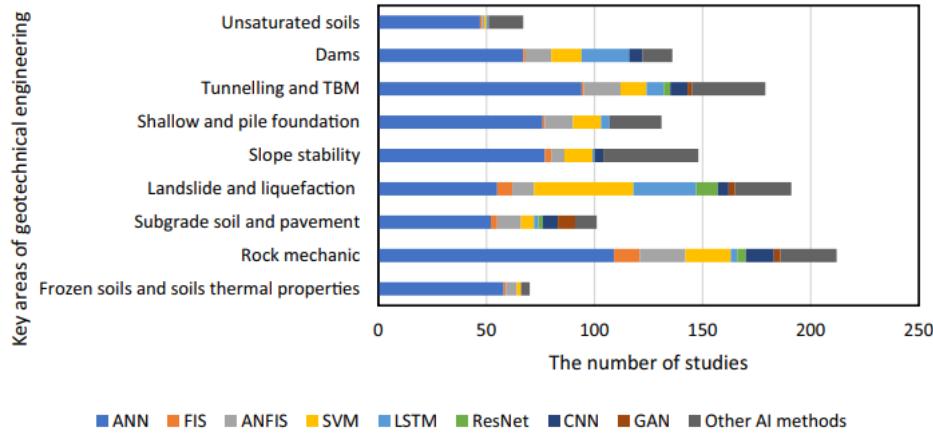


Figura 2.19: Distribuição do uso de diferentes técnicas de IA na engenharia geotécnica em nove áreas de aplicação (Adaptado de Baghani et al., 2022)

Além de apresentar o número de estudos realizados por cada campo, foi realizada uma comparação entre as técnicas de IA usadas nas publicações, de modo que se destacou o uso da técnica de redes neurais.

Na literatura, foram examinados trabalhos que empregaram o método de Redes Neurais Artificiais como uma ferramenta de análise em geossintéticos:

O artigo desenvolvido por Sardehaei e Mehjardi (2017) apresenta um modelo de rede neural de tipo *backpropagation* para prever a resistência à tração retida em geotêxteis não tecidos após a instalação. Usando dados de 34 testes de campo, a rede neural previu com acurácia a resistência, superando um modelo de regressão. O estudo revela que os danos de instalação do geotêxtil aumentam após a compactação, especialmente em condições de menor resistência inicial, maior estresse aplicado e condições específicas do material de enchimento e do subleito.

Silva et al. (2021) realizaram um estudo na previsão da resistência à tração e eficácia erosional de geotêxteis naturais utilizando Redes Neurais Artificiais (ANN, do inglês *Artificial Neural Network*). Claro, este estudo se concentrou na previsão da resistência e eficácia erosional de geotêxteis naturais usando Redes Neurais Artificiais (RNAs). Três tipos de fibras naturais — coco, abacá e aguapé — foram usados como geotêxteis. Foram desenvolvidos modelos para

entender como essas fibras influenciam a resistência e a capacidade de reduzir a erosão. Os modelos de RNA demonstraram uma excelente capacidade de previsão, com correlações altas e erros baixos.

Outro estudo realizado por Chao et al. (2021) avalia a resistência ao cisalhamento pico entre a interface solo-geocomposto (GDL) em estruturas de engenharia. Com base em uma grande base de dados de 316 testes diretos de cisalhamento solo-GDL, diferentes modelos de aprendizado de máquina foram utilizados para prever essa resistência. Os modelos BPANN, SVM, ELM, otimizados por PSO, GA e método exaustivo, foram comparados, o que revelou que o BPANN otimizado por PSO teve a melhor acurácia preditiva. O estudo identificou a influência de vários parâmetros e destacou a pressão normal como o fator de maior impacto. Uma equação empírica foi desenvolvida para estimar essa resistência, de modo a fornecer uma ferramenta útil para engenheiros geotécnicos com pouco conhecimento em técnicas de aprendizado de máquina.

Os autores Tanga et al. (2023), também, investigaram a aplicação da regressão Random Forest (um algoritmo de Machine Learning) para prever o ângulo de atrito em interfaces geomembrana-areia. O estudo incluiu 495 interfaces de geomembranas lisas e rugosas em contato com areia, utilizando dados de diversas fontes nacionais e internacionais. Os resultados principais revelaram uma forte correlação entre os ângulos de atrito laboratoriais e as estimativas da Random Forest, com coeficientes de determinação (R^2) de 0,93 para o conjunto de treinamento e 0,92 para o conjunto de teste, confirmando a alta eficiência da técnica empregada.

Assim, observa-se um crescente uso e potencial da Inteligência Artificial (IA) e de seus estudos derivados na engenharia civil, especialmente no campo geotécnico, o que tem possibilitado análises cada vez mais precisas e fundamentadas. Contudo, ainda há uma lacuna significativa de pesquisas específicas que explorem a aplicação da IA no desempenho dos geotêxteis. A escassez de artigos, dissertações e teses que utilizam abordagens de *machine learning* para investigar os parâmetros que influenciam a função filtrante desses materiais evidencia essa necessidade. Diante disso, existe uma necessidade de desenvolver pesquisas nesta área, o que constitui o objetivo central da presente dissertação.

2.8 REGRESSÃO MULTIVARIADA (RM)

Esta ferramenta aborda um conjunto de métodos e técnicas estatísticas utilizadas para compreender melhor as variáveis que influenciam o problema a ser analisado. Essa avaliação das variáveis é feita por meio da análise de um conjunto de dados (Santos, 2019 apud Mingoti, 2013).

2.8.1 APLICADA À ENGENHARIA GEOTÉCNICA

A análise multivariada é frequentemente utilizada em estudos de engenharia geotécnica, em que é necessário compreender as interações entre diferentes propriedades do solo, como resistência, permeabilidade, densidade, entre outras. Essa análise pode ser aplicada em diferentes contextos, como projetos de fundações, estabilidade de taludes, comportamento de aterros, entre outros.

Existem várias técnicas de análise multivariada que podem ser aplicadas na geotecnia. De forma geral, as técnicas são divididas em dois tipos: técnicas de interdependência e técnicas de dependência. A primeira é baseada na interrelação entre várias variáveis, com a finalidade de analisar a existência de correlações entre elas. Já a outra determina modelos em que uma ou mais variáveis são dependentes de outras variáveis.

Entre essas técnicas, destaca-se componentes principais e regressão linear múltipla, pois foram técnicas adotadas em inúmeros trabalhos aplicadas à geotecnia (Gardoni, 2000; Bera et al., 2005; Marrapu & Jakka, 2027; Palmeira et al., 2024; Santos et al., 2025). A análise de componentes principais explica a estrutura de variâncias e covariâncias dos dados por meio de combinações lineares. Essa análise permite uma redução das variáveis independentes originais que não se correlacionam com a variável dependente, para obter variáveis conhecidas como componentes principais. (Pearson, 1901). Cabe destacar que esse tipo de análise é caracterizado mais por servir como um passo intermediário para realizar outras análises, como regressões, agrupamentos etc.

Por outro lado, a análise de regressão múltipla é uma técnica estatística usada para entender a relação entre uma variável dependente (ou critério) e diversas variáveis independentes (ou preditoras). Seu objetivo é usar os valores conhecidos das variáveis independentes para prever os valores da variável dependente escolhida. Cada variável independente é ponderada durante o processo de análise de regressão para garantir uma previsão eficaz baseada no conjunto delas.

Esses pesos representam a contribuição relativa de cada variável independente para a previsão total, mas interpretar sua influência pode ser desafiador quando há correlação entre as variáveis independentes. A combinação ponderada das variáveis independentes forma a variável estatística de regressão, também chamada de equação ou modelo de regressão. Esse modelo representa uma variável estatística fundamental nas técnicas multivariadas.

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_p x_p + \epsilon \quad \text{Eq. (2.7)}$$

Onde Y é a variável dependente ou variável que se deseja prever; β_p , variáveis independentes; β_0 , intercepto; β_p , coeficiente de regressão parciais; e ϵ , variável de erro.

A regressão múltipla será abordada no item 5.3 e servirá como metodologia de comparação com a rede neural (rna), a fim de avaliar os diferentes métodos para prever o comportamento filtrante do geotêxtil

3 METODOLOGIA

Neste capítulo, detalha-se a metodologia adotada para avaliar o uso de Redes Neurais Artificiais (RNA) como ferramenta de previsão do desempenho filtrante de geotêxteis, especificamente em termos de permeabilidade do sistema solo/geotêxtil. A Figura 3.1 ilustra as três etapas gerais, que compreendem a definição de um banco de dados, desenvolvimento de um modelo treinado e a validação desse modelo treinado.

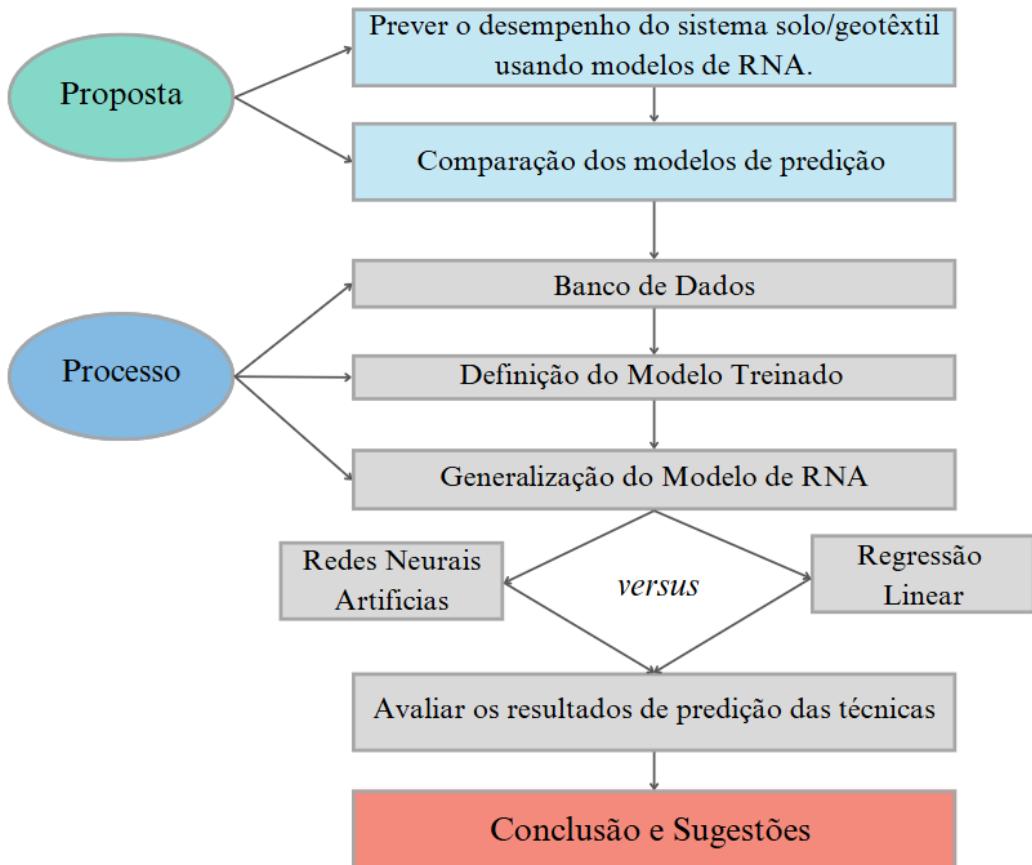


Figura 3.1: Metodologia Geral adotada em este estudo.

De forma mais específica, a primeira etapa, dedicada à formação do banco de dados, inicia-se com a coleta de dados, seguida por análises preliminares e um pré-processamento dados para a seleção dos parâmetros de interesse (parâmetros de entrada e saída). Essas etapas iniciais, relacionadas aos dados fornecidos, são realizadas de maneira iterativa, conforme detalhado no item 4.2, dada a influência da qualidade e da quantidade dos dados na modelagem da RNA. Somente após a definição de um banco de dados consistente, a etapa seguinte é iniciada.

Na segunda etapa, voltada à definição do modelo treinado, e após a conclusão da primeira, inicia-se o treinamento do modelo. Isso envolve a definição da função de perda, do otimizador para os parâmetros do modelo e do método de inicialização desses parâmetros. Em seguida, a validação cruzada é empregada na fase de otimização de hiperparâmetros, com o modelo sendo treinado em múltiplas partições (utilizou-se a validação cruzada k -fold). Paralelamente, aplicam-se técnicas de regularização para mitigar o *overfitting* durante a fase de treinamento do modelo.

Na terceira etapa, após a obtenção do modelo treinado, ou seja, um modelo baseado em uma rede neural artificial que aprendeu a partir dos dados ao ajustar iterativamente os pesos das conexões entre os neurônios para minimizar os erros nas previsões, avalia-se seu desempenho final utilizando um conjunto de dados específico (conjunto de validação). Essa validação é conduzida por meio de análises gráficas e de resíduos, e é complementada por uma avaliação da importância dos parâmetros. Esta avaliação tem como objetivo identificar quais variáveis de entrada mais influenciam nas decisões do modelo, permitindo maior entendimento e a possível eliminação de variáveis irrelevantes. Entre os métodos utilizados, destacam-se abordagens como a permutação de variáveis.

É importante ressaltar que essa metodologia possui um caráter iterativo. Isto é, caso não se alcance uma acurácia considerada aceitável durante o desenvolvimento, diversas variáveis podem ser modificadas, o que exige a repetição de toda a metodologia para garantir a obtenção de um modelo ótimo.

Os passos para o desenvolvimento do modelo de RNA são apresentados graficamente na Figura 3.2

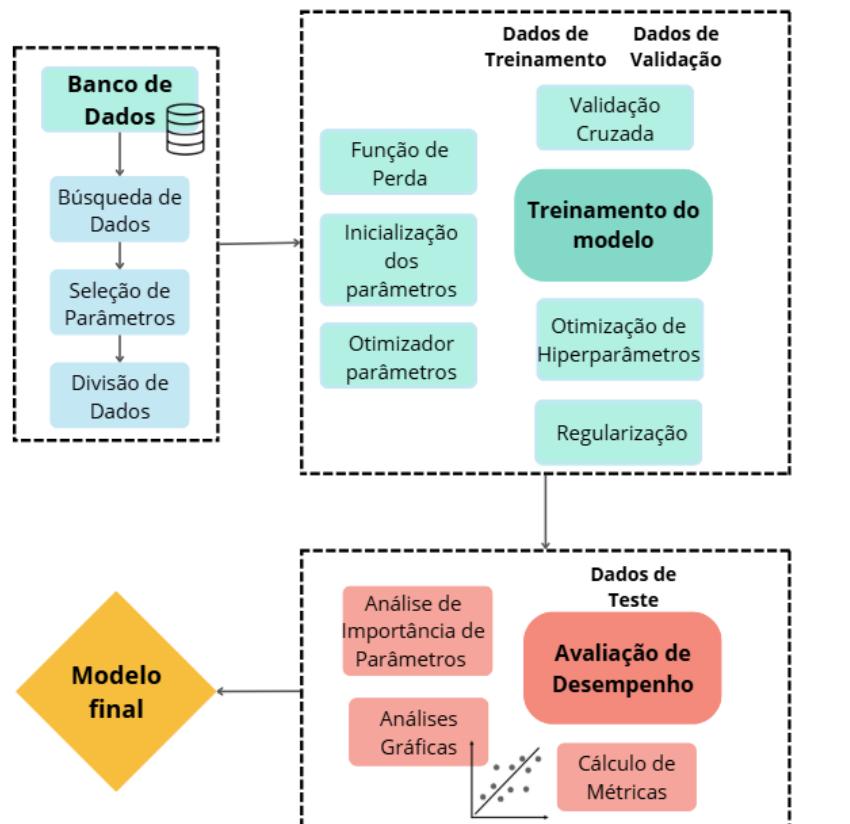


Figura 3.2: Passos para desenvolvimento do modelo RNA adotado neste estudo.

3.1 BANCO DE DADOS

FF Os dados de entrada (*input*) e os valores de permeabilidade final do sistema foram definidos com base nos resultados obtidos em investigações anteriores conduzidas por diversos autores, totalizando uma coleta de 352 amostras.

Conforme mencionado anteriormente, as Redes Neurais Artificiais (RNAs) representam uma abordagem eficaz fundamentada no aprendizado de dados de entrada e saída (Shabin, 2013; Al-Atroush, 2024). É crucial destacar a influência do número de variáveis de entrada no tempo de processamento da rede: um maior número de variáveis implica em uma rede de maior dimensão e, consequentemente, em um tempo de análise mais extenso para a resolução do problema (Lachtermacher & Fuller, 1994). Contudo, Shanin et al. (2000) sugerem que um número elevado de variáveis pode, paradoxalmente, aprimorar o desempenho da rede. Nesse contexto, o presente trabalho empregará uma RNA para prever o desempenho filtrante do sistema solo/geotêxtil, quantificado pela sua permeabilidade.

A primeira etapa desta pesquisa consistiu na busca e coleta de dados, especificamente dados e resultados de ensaios laboratoriais destinados à avaliação da permeabilidade do sistema solo/geotêxtil. Essas informações foram extraídas de publicações como artigos de periódicos internacionais, teses, dissertações e acervos pessoais de dados. Através das informações compiladas, foi possível identificar e estabelecer os parâmetros de entrada relevantes e os respectivos valores de saída. Ao final dessa etapa, foram reunidos um total de 352 dados para o treinamento e a validação do modelo de RNA. A Tabela 3.1 detalha os trabalhos consultados e o número de dados obtidos de cada fonte.

Tabela 3.1: Quantidades de dador por trabalho

Nome do Trabalho/Paper	Autor/ Ano	Pais	Número de dados coletados
Evaluation of geotextile/soil filtration characteristics using the hydraulic conductivity ratio analysis	Williams & Abouzakhm (1989)	USA	10
Geotextile filter performance with fine grained soils	Lawson (1990)	Reino Unido	4
Long term filtration behaviour of non-woven geotextiles.	Qureshi et al (1990)	USA	30
Laboratory measurement of geotextile filtration characteristics	Williams & Luettich (1990)	USA	5
Correlation between long term flow testing and current geotextile filtration design practice. Proceedings of Geosynthetics	Wayne & Koerner (1993)	USA	8
Geotextile Filters for Internally Stable/Unstable Soils	Bhatia & Huang (1996)	USA	26
Avaliação da aplicabilidade de ensaios de laboratório e critérios de filtros para a utilização de geotêxteis em solos do Distrito Federal.	Gardoni (1995)	Brasil	3
A study on the behaviour of soil-geotextile systems in filtration tests	Palmeira et al. (1996)	Brasil	5
Acervo Pessoal	Gardoni & Palmeira (1999)	Brasil	1
Selection of geotextiles to filter broadly graded cohesionless soils	Lafleur (1999)	Canadá	9
Clogging phenomena of the residual soil-geotextile filter system.	Lee et al. (2002)	Korea e USA	3
Comportamento do filtro drenante de geotêxteis em barragens de rejeitos de mineração	Beirigo (2005)	Brasil	5
Soil-geotextile filter interaction under high stress levels in the gradient ratio test	Palmeira et al. (2005) & Gardoni (2000)	Brasil	22
Filter Performance and Design for Highway Drains	Lee & Bourdeau (2006)	USA	12
Filtration behaviour of soil-nonwoven geotextile combinations subjected to various loads	Hong & Wu (2011)	Taiwan	19
Changes of Permeability of Nonwoven Geotextiles due to Clogging and Cyclic Water Flow in Laboratory Conditions	Miszkowska et al. (2017)	Polonia	6
Filtration Performance of Nonwoven Geotextile Filtering Fine-Grained Soil under Normal Compressive Stresses	Du et al. (2022)	China	4
Influence of physical clogging on filtration performance of soil-geotextile interaction.	Markiewicz et al. (2022)	Polonia	16

Nome do Trabalho/Paper	Autor/ Ano	País	Número de dados coletados
Long-term hydraulic performance of geotextiles filtering recycled materials	Odabasi et al. (2022)	Turquia	75
Comportamento de Filtros geotêxteis em solos internamente instáveis sob confinamento	Carvalho (2023)- Dellane	Brasil	81
Acervo Pessoal	Gardoni (2023)	Brasil	8
Total de Dados			352

Os parâmetros de entrada foram selecionados com base nas informações extraídas dos trabalhos listados na Tabela 3.1, a fim de identificar os fatores que podem influenciar no desempenho filtrante do geotêxtil. Inicialmente, foram definidos 16 parâmetros de entrada, detalhados na Tabela 3.2.

Tabela 3.2 — Parâmetros iniciais de interesse

Tipo de parâmetros/ Variáveis	Parâmetros
Parâmetros de Entrada (<i>Input</i>)/Independentes	Tipo de Geotêxtil (WG/NWG); d_{10} ; d_{15} ; d_{30} ; d_{50} ; d_{60} ; d_{85} ; C_c ; C_u ; T_{GT} ; M_A ; FOS; LS; i_{sys} ; σ_v , k_{sys-o}
Parâmetros de Saída (<i>Output</i>)/Dependentes	k_{sys}

WG=*Woven geotextile*, WG=*Nonwoven geotextile*, d_{xx} =Diâmetro de partícula do solo base para xx% de passagem, C_c , C_u =coef. de curvatura C_u =coef. de uniformidade, T_{GT} =espessura do geotêxtil, M_A =gramatura do geotêxtil, FOS= abertura de filtração do geotêxtil, LS=espessura do corpo de prova; i_{sys} = gradiente hidráulico do sistema (solo-geotêxtil), σ_v =tensão vertical, k_{sys-o} = Coeficiente de permeabilidade inicial do sistema solo-geotêxtil, k_{sys} = Coeficiente e permeabilidade final do sistema solo- geotêxtil.

A Tabela 3.3 por sua vez, detalha a quantidade de dados coletados para cada um dos parâmetros de entrada e saída estabelecidos.

Tabela 3.3 — Quantidade de dados iniciais por parâmetros

Símbolo	Parâmetros	# Dados	Símbolo	Parâmetros	# Dados
Parâmetros de Entrada (Inputs)					
d_{10}	Diâmetro da partícula de solo correspondente a 10% do material mais fino (mm)	335	t_{GT}	Espessura do geotêxtil (mm) (g/cm^3)	345
d_{15}	Diâmetro da partícula de solo correspondente a 15% do material mais fino (mm)	355	M_A	Gramatura do geotêxtil (g/m^2)	348

Símbolo	Parâmetros	# Dados	Símbolo	Parâmetros	# Dados
Parâmetros de Entrada (Inputs)					
d_{30}	Diâmetro da partícula de solo correspondente a 30% do material mais fino (mm)	341	FOS	Abertura de filtração do geotêxtil (mm)	347
d_{50}	Diâmetro da partícula de solo correspondente a 50% do material mais fino (mm)	341	Ls	Espessura do corpo de prova (cm)	333
d_{60}	Diâmetro da partícula de solo correspondente a 60% do material mais fino (mm)	341	i	Gradiente hidráulico do sistema solo/geotêxtil	312
d_{85}	Diâmetro da partícula de solo correspondente a 85% do material mais fino (mm)	341	σ_v	Tensão vertical (kPa)	341
d_{gap}	Diâmetro da lacuna ou do espaçamento entre partículas (mm)	56	k_{sys-o}	Coeficiente de permeabilidade inicial do sistema solo- geotêxtil	287
C_c	Coeficiente de curvatura	335	WG/NW G	Tipo de Geotêxtil (Tecido/Não Tecido)	352
C_u	Coeficiente de uniformidade	335			
Parâmetro de Saída (Output)					
k_{sys}	Coeficiente de permeabilidade final do sistema solo- geotêxtil			303	

Para prevenir o sobreajuste (*overfitting*) durante o treinamento da rede, o conjunto de dados foi depurado, removendo-se valores discrepantes (outliers) e amostras com dados faltantes relevantes, especialmente para k_{sys-o} e k_{sys} . A ausência desses dados comprometeria a avaliação do desempenho do filtro geotêxtil, pois impossibilitaria determinar se ocorreu colmatação e, consequentemente, analisar sua eficácia. Dessa forma, foram consideradas principalmente 287 amostras úteis para as análises, as quais abrangearam os dois tipos de geotêxteis (224 amostras de geotêxtil não tecido e 63 de geotêxtil tecido). Inicialmente, realizou-se uma análise estatística foi realizada uma análise estatística exploratória, avaliando-se os valores mínimo, máximo, média, desvio padrão, covariância e assimetria, com o objetivo de verificar a influência de todos os parâmetros listados na Tabela 3.2 sobre o desempenho do filtro geotêxtil, cujos resultados são apresentados no subitem 0 deste trabalho.

Após essa análise, constatou-se que o tipo de geotêxtil exercia pouca influência no desempenho. Consequentemente, o presente estudo focou na análise de geotêxteis não tecidos, de modo a constituir um banco de dados de 224 amostras. A Tabela 3.4 apresenta a quantidade de dados

coletados para os parâmetros de entrada e saída finais que serão utilizados nesta pesquisa.

Tabela 3.4 — Quantidade de dados finais por parâmetros

Símb	Parâmetros	# Dados	Símbolo	Parâmetros	# Dados
Parâmetros de Entrada (Inputs)					
d_{10}	Diâmetro da partícula de solo correspondente a 10% do material mais fino (mm)	224	t_{GT}	Espessura do geotêxtil (mm)	224
d_{15}	Diâmetro da partícula de solo correspondente a 15% do material mais fino (mm)	224	M_A	Gramatura do geotêxtil (g/m ²)	224
d_{30}	Diâmetro da partícula de solo correspondente a 30% do material mais fino (mm)	224	FOS	Abertura de filtração do geotêxtil (mm)	224
d_{50}	Diâmetro da partícula de solo correspondente a 50% do material mais fino (mm)	224	L_s	Espessura do corpo de prova (cm)	224
d_{60}	Diâmetro da partícula de solo correspondente a 60% do material mais fino (mm)	224	i	Gradiente hidráulico do sistema solo/geotêxtil	224
d_{85}	Diâmetro da partícula de solo correspondente a 85% do material mais fino (mm)	224	σ_v	Tensão vertical (kPa)	224
d_{gap}	Diâmetro da lacuna ou do espaçamento entre partículas (mm)	224	k_{sys-o}	Coeficiente de permeabilidade inicial do sistema solo- geotêxtil	224
C_c	Coeficiente de curvatura	224			
C_u	Coeficiente de uniformidade	224			
Parâmetro de Saída (Output)					
k_{sys}	Coeficiente de permeabilidade final do sistema solo-geotêxtil	224			

Depois da definição do banco de dados final, foram propostos três modelos distintos, baseados nos tipos de solos a serem analisados, conforme o resumo apresentado na Tabela

3.5.

Tabela 3.5 — Modelos a serem desenvolvidos

Modelo	Tipo de solo	Número de Dados
1	Solos com concavidade para cima e solos descontínuos	224
2	Solos com concavidade para cima	149
3	Solos descontínuos	75

3.1.1 NORMALIZAÇÃO

A normalização de dados foi aplicada no conjunto de dados, pois este método ajuda a definir parâmetros mais uniformes, o que diminui a probabilidade de que valores menores sejam sobrepostos e evita a saturação de informação nos nós da rede (James et al., 2021). Neste estudo, foi utilizada a normalização mínima e máxima, a qual é expressa pela Eq. (3.1), onde X_{norm} é o valor normalizado de X_i , e $X_{mín}$ e $X_{máx}$ são os valores mínimo e máximo de X_i , respectivamente, no banco de dados:

$$X_{norm} = \frac{X_i - X_{mín}}{X_{máx} - X_{mín}} \quad \text{Eq. (3.1)}$$

3.1.2 CORRELAÇÃO DE DADOS – COEFICIENTE DE PEARSON (ρ_r)

O coeficiente de correlação de Pearson foi empregado para analisar a relação linear entre os parâmetros de entrada e a variável de saída. Esse coeficiente, uma medida estatística que varia de -1 a +1, permite quantificar a intensidade e a direção da relação linear monotônica entre duas variáveis contínuas e aleatórias. Valores próximos de +1 indicam uma forte correlação positiva, enquanto valores próximos de -1 indicam uma forte correlação negativa. Valores próximos de zero sugerem uma fraca ou nenhuma correlação linear entre as variáveis analisadas (Mukaka, 2012).

O cálculo do coeficiente de correlação de Pearson entre duas variáveis é realizado por meio da Eq. (3.2), na qual $cov(x, y)$ é a covariância entre dois variáveis e σ_x e σ_y são os desvios padrão de cada variável. Além disso, para auxiliar na interpretação dos resultados obtidos, a Tabela 3.6 apresenta as faixas de correlação e seus respectivos significados.

$$\rho_r(x, y) = \frac{cov(x, y)}{\sigma_x \sigma_y} \quad \text{Eq. (3.2)}$$

É importante ressaltar que a interpretação do coeficiente de Pearson pode variar dependendo do contexto de cada estudo a que ele é aplicado. Essa interpretação é subjetiva e, portanto, deve ser justificada claramente as faixas de correlação a serem utilizadas. Portanto, neste estudo, serão adotadas as faixas apresentadas na Tabela 3.6.

Tabela 3.6 — Faixas de valores para interpretação do coeficiente de correlação de Pearson (Schober et al., 2018).

Faixas de Correlação	Interpretação
0.00 – 0.10	Correlação Inexistente
0.10 – 0.39	Correlação Fraca
0.40 – 0.69	Correlação Moderada
0.70 – 0.89	Correlação Forte
0.90 – 1.00	Correlação Muito Forte

3.2 CONFIGURAÇÃO DO MODELO RNA

Neste estudo, a análise da Rede Neural Artificial (RNA) foi realizada utilizando uma rede *Perceptron Multicamadas* (MLP) *feedforward*, treinada com o algoritmo de aprendizagem de retropropagação (*backpropagation* - BP). Para a otimização da rede, o algoritmo de otimização bayesiano (BOA) foi adotado no modelo.

Para o desenvolvimento da metodologia de RNA, os algoritmos de aprendizado de máquina serão implementados e executados utilizando o módulo de Aprendizado de Máquina do *software* Tyche (Tyche, 2023), desenvolvido no Laboratório de Modelagem Computacional Inteligência Artificial (LAMCIA) da Universidade de Brasília. O *software* também incluirá a otimização de hiperparâmetros (HPO).

Todos os modelos foram treinados com paralelização em uma GPU básica NVIDIA GeForce MX110 de 2 GB de memória dedicada, com auxílio do CUDA, uma plataforma criada pela NVIDIA que facilita a computação em paralelo. Os códigos serão programados em linguagem Python®, os quais foram aplicados com sucesso em outros estudos para fins de previsão

(Chaves et al.,2023; Evangelista Junior; Almeida, 2021; V. P. Silva et al., 2023).

3.2.1 ARQUITETURA DA REDE NEURAL (RNA)

Segundo Abraham (2005), uma rede MLP é dividida em três partes: camada de entrada, camadas intermediárias ou ocultas e camada de saída. Nesse sentido, os dados foram processados através de uma Rede Neural Artificial (RNA) *feedforward* totalmente conectada, conhecida como arquitetura *Perceptron Multicamadas* (MLP). A camada de entrada e cada camada oculta do MLP foram construídas sequencialmente com uma transformação linear (em que se aplicou pesos e bias), uma camada de normalização em lote e uma função de ativação ReLU (Unidade Linear Retificada). Em razão dessa escolha de função de ativação, a inicialização dos pesos das camadas lineares foi feita com a Inicialização de Kaiming He, enquanto os bias foram inicializados com zero. Nas camadas de normalização em lote, os pesos foram inicializados com 1 e os bias com 0. O treinamento foi realizado com a variante AMSGrad do otimizador Adam até a convergência.

Os critérios de convergência foram tanto o número máximo de épocas quanto o número de épocas de paciência na técnica de parada antecipada (*early stopping*). Para os conjuntos de dados utilizados , todos os modelos definiram 10.000 como o número máximo de épocas e 200 como paciência. Esses altos valores de épocas máximas foram utilizados para garantir a convergência durante o treinamento, uma vez que a implementação da parada antecipada preveniu o *overfitting* e interrompeu o treinamento muito antes do máximo de épocas estabelecido.

O conjunto de dados foi separado em 80% para treinamento e 20% para teste. A função de perda utilizada foi o Mean Squared Error (MSE), por ser o usual para modelos de regressão. O otimizador usado para treinar as redes foi um otimizador baseado em gradiente chamado AMSGrad, uma variação do otimizador Adam que propõe melhor convergência. A função de ativação empregada nas camadas ocultas foi a Rectified Linear Unit (ReLU), por ser a recomendação padrão para otimizadores baseados em gradiente, dado seu formato quase linear. Foi utilizada validação-cruzada k-fold com $k = 5$ e os hiperparâmetros dos modelos foram otimizados utilizando Otimização Bayesiana (OB). Essa técnica, com base em um modelo surrogado probabilístico, calcula a cada iteração qual o melhor próximo ponto da função objetivo a ser avaliado, assim, performa bem em problemas em que a função objetivo é custosa.

A função objetivo em questão foi a média do MSE dos 5 *folds* de validação. Os hiperparâmetros otimizados e seus intervalos de busca (rango) estão definidos na Tabela 3.7

Tabela 3.7: Hiperparâmetro otimizados e seus espaços de busca

Hiperparâmetro	Rango
Taxa de aprendizado (α)	$[10^{-4}, 10^{-1}]$
Decaimento de peso (λ)	$[10^{-9}, 1]$
Camadas Ocultas	$[1, 4]$
Neurônios em cada camada oculta	$[10, 1000]$

Foram empregadas 3 técnicas de regularização, a fim de evitar o *overfitting* e de garantir boa generalização dos modelos. São elas:

- *Early Stopping*: ela consiste em parar o treinamento do modelo quando o erro do conjunto de validação não está mais baixando após um dado número de iterações consecutivas, de modo a evitar, assim, treinamento excessivo;
- Decaimento de peso: a técnica penaliza pesos grandes com base no quadrado da norma L2 e em um hiperparâmetro lambda, que controla o quanto os pesos grandes são penalizados;
- *Batch Normalization*: um método de reparametrização que acelera e estabiliza o treinamento, o que melhora performance do modelo. Ela normaliza os *inputs* de cada camada para média 0 e variância 1. Em seguida, para manter a capacidade de representação do modelo, aprende parâmetros de escala e deslocamento do resultado.

Graças a essa divisão de dados, foi possível determinar os valores ótimos de pesos sinápticos e vieses que minimizam o erro na previsão do modelo. A fase de teste, por sua vez, avalia o desempenho do modelo com base nos parâmetros finais obtidos durante a fase de treinamento.

3.2.2 ALGORITMO DE OTIMIZAÇÃO BAYESIANA

Em aprendizado de máquina, um hiperparâmetro é um parâmetro cujo valor precisa ser definido antes do treinamento do modelo, dessa forma, é raro encontrar algoritmos que não os utilizem. Para algoritmos como XGBoost, *Random Forest* (RF) e outros métodos de *Machine Learning* (ML) comparativos, diversos hiperparâmetros impactam significativamente a acurácia preditiva. Portanto, o ajuste adequado desses hiperparâmetros, processo conhecido como

otimização de hiperparâmetros, é crucial.

Cada vez mais, essa otimização é realizada por métodos automatizados que buscam os melhores hiperparâmetros de forma eficiente, utilizando estratégias de busca informada. Esses métodos dispensam operações manuais adicionais após a configuração inicial. A Otimização Bayesiana (OB) se destaca como a principal escolha para otimizar funções objetivo (Snoek et al., 2012; Ghahramani, 2015; Xia et al., 2017). Ela opera através da construção de um modelo probabilístico (substituto) da função objetivo com base em avaliações anteriores, buscando o ponto que minimiza essa função. Recentemente, a BO tem sido amplamente adotada para o ajuste de hiperparâmetros em aprendizado de máquina.

A Otimização Bayesiana (BO) tem suas raízes nos trabalhos de Kushner (1964), Močkus (1975) e Zhilinskas (1975). Jones et al. (1998) realizaram uma das primeiras aplicações significativas da BO, ao desenvolverem um algoritmo de otimização global eficiente para problemas de engenharia em que o número de avaliações da função objetivo é severamente limitado por tempo ou custo.

Em modelos de ML, o ajuste de hiperparâmetros pode ser formulado como um problema de otimização de função caixa-preta, desconhecida e sem derivadas, o que impede o uso de técnicas tradicionais, como o método de Newton ou o gradiente descendente (Wu et al., 2019). Os métodos Bayesianos são particularmente eficazes nesse cenário, pois incorporam uma estrutura probabilística à informação obtida através das avaliações da função (Betrò & Rotondi, 1991).

De acordo com Turner et al. (2021), a Otimização Bayesiana (OB) é um algoritmo de otimização de caixa-preta que se fundamenta na construção de um modelo probabilístico substituto da função objetivo, fornecendo, também, uma medida de incerteza. Este modelo substituto é implementado por meio de Processos Gaussianos (GP), que empregam uma função de aquisição para determinar o ponto mais promissor a ser avaliado na próxima iteração. Em geral, esse algoritmo demonstra eficácia em problemas onde as avaliações da função objetivo são trabalhosas, direcionando o tempo computacional de forma estratégica para identificação de parâmetros ótimos (Snoek et al., 2012).

Para aplicação OB, o usuário precisa definir os intervalos do espaço de busca e estabelecer um critério de parada, o qual pode ser determinado por um número máximo de interações ou pela convergência. Esses requisitos demandam um conhecimento prévio do problema ou da execução de múltiplos testes de configuração para definir o espaço de busca de maneira adequada. Essa definição cuidadosa visa evitar otimizações ineficientes em espaços de busca excessivamente amplos ou a exclusão do ponto ótimo em espaços restritos (Nguyen, 2019). Não obstante essas exigências iniciais, uma vez que os intervalos são definidos de forma razoável e um critério de parada é estabelecido (seja por número de iterações suficiente ou por convergência satisfatória), o algoritmo se torna capaz de encontrar soluções ótimas de maneira automática. Na Figura 3.3 é mostrado geralmente como o algoritmo BO funciona.

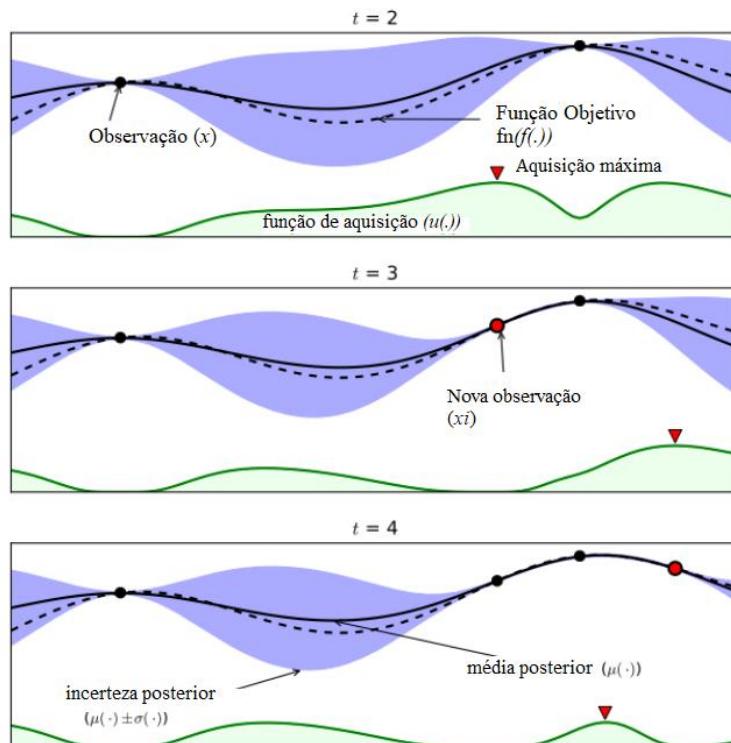


Figura 3.3 :Ilustração de 3 iteração do algoritmo de otimização bayesiano (modificado de Brochu et al., 2010)

Na Figura 3.3, a parte inferior dos gráficos exibe a função de aquisição, enquanto a parte superior ilustra uma aproximação da função objetivo por meio de Processos Gaussianos (GP). A figura inicia na iteração 2, a figura demostra duas avaliações da função, representadas pelos pontos pretos. Com base nessas observações iniciais, são calculadas a média e o desvio padrão do GP, que resultam em uma aproximação da função objetivo e fornecem a área azul que indica a incerteza da distribuição posterior. Subsequente, ao utilizar a regressão GP, avalia-se a função

de aquisição, e seu ponto máximo é selecionado como o próximo ponto a ser avaliado. Essa nova avaliação gera uma nova observação, a qual será incluída em uma nova aproximação GP, reiniciando o processo iterativo. Dessa forma, mesmo que a nova observação não corresponda a um mínimo local, ela adiciona informações ao GP, de modo a contribuir para a busca pelo mínimo nas próximas iterações.

Em outras palavras, a Otimização Bayesiana opera em um ciclo iterativo para encontrar o mínimo de uma função objetivo desconhecida e dispendiosa de avaliar. Inicialmente, ela constrói um modelo substituto probabilístico, tipicamente um Processo Gaussiano, que não apenas estima o valor da função objetivo em diferentes pontos, mas também quantifica a incerteza associada a essas estimativas. Em seguida, uma função de aquisição é empregada para guiar a seleção do próximo ponto a ser avaliado na função objetivo real. Essa função crucial equilibra a necessidade de explorar regiões do espaço de busca com alta incerteza (onde o mínimo pode estar escondido) com a exploração de áreas onde o modelo substituto prevê valores baixos (próximos ao mínimo). Após a avaliação da função objetivo no ponto escolhido, o modelo substituto é atualizado com essa nova informação, refinando suas estimativas e reduzindo a incerteza. Esse processo de seleção de ponto via função de aquisição e atualização do modelo substituto é repetido iterativamente até que um critério de parada predefinido seja atingido, como um número máximo de avaliações da função objetivo ou a detecção de convergência nos resultados obtidos.

Assim como em outros problemas de otimização, a solução desejada é o mínimo de uma função $f(x)$ em algum conjunto limitado X . A otimização bayesiana, especificamente, constrói um modelo probabilístico para $f(x)$ com a finalidade de utilizar toda a informação fornecida pelas avaliações anteriores da função. Por isso, o custo computacional, de determinar o próximo ponto a ser avaliado é justificável devido ao custo de realizar cada avaliação (Snoek et al., 2012).

Os Processos Gaussianos (PGs) são uma coleção de variáveis aleatórias, qualquer número finito das quais possui uma distribuição Gaussiana conjunta, e são completamente especificados por funções de média e covariância. A função de média $m(x)$, representada pela Eq. (3.3), e a função de covariância $C(x,x')$, pela Eq. (3.4), de um processo real $f(x)$ são definidas, de acordo com William & Rassmussen (1996) e Bishop (2006), como:

$$m(x) = \mathbb{E}[f(x)] \quad \text{Eq. (3.3)}$$

$$C(x, x') = \mathbb{E}[(f(x) - m(x))(f(x') - m(x'))] \quad \text{Eq. (3.4)}$$

E o Processo Gaussiano, é descrito pela Eq. (3.5), onde a função de média $m(x)$ é considerada nula, para simplificar o modelo:

$$f(x) \sim GP(m(x), C(x, x')) \quad \text{Eq. (3.5)}$$

Para aplicar PG ao problema de regressão, precisa-se considerar o ruído aleatório (ϵ_n) nos valores alvos observados. O processo de ruído é considerado ao adotar uma distribuição Gaussiana e ser baseado em um hiperparâmetro (β_G) que representa a precisão do ruído, para, assim, prever variáveis alvo para novas entradas, dado um conjunto de dados de treinamento. Supondo que o conjunto de treinamento seja dado por alvos $y_N = (y_1, \dots, y_N)^T$ que correspondem aos valores de entrada x_1, \dots, x_n , com o objetivo de prever y_N dado x_{N+1} , para isso, precisa-se avaliar a distribuição preditiva $p(y_{N+1} | y_N)$, dado por uma Gaussiana com média e covariância, representadas pela Eq. (3.6) e Eq. (3.7) respectivamente.

$$m(x_{N+1}) = k^T C_N^{-1} y \quad \text{Eq. (3.6)}$$

$$\sigma^2(x_{N+1}) = c - k^T C_N^{-1} k \quad \text{Eq. (3.7)}$$

Onde o vetor k tem elementos $k(x_n, x_{N+1})$ para $n=1, \dots, N$, o escalar $c = k(x_n, x_{N+1}) + \beta_G$ e C_N é a matriz de covariância $N \times NC(x_n, x_m) = k(x_n, x_m) + \beta_G^{-1} \delta_{nm}$ para $n, m = 1, \dots, N$. Onde δ_{nm} é um delta de Kronecker, que é 1 se $n=m$ e 0 caso contrário. Já $k(x_n, x_m)$ é uma função kernel para regressão GP, que pode assumir muitas formas.

A partir dos Processos Gaussianos e a Regressão de Processos Gaussiano definidos, é possível entender como as técnicas quantificam as incertezas de áreas não observadas com base em observações anteriores, de modo a fornecer uma distribuição de probabilidade Bayesiana. Essas técnicas combinam informações sobre a função desconhecida com informações da amostra para obter informações posteriores da distribuição da função com a fórmula de Bayes. A localização do valor ótimo é deduzida com base na informação posterior (Betrò, 1991). Embora esse valor ótimo seja baseado em uma função de aquisição e não na função original, devido ao fato de que a função de aquisição $a(x)$ é conhecida, portanto, ela fornece o próximo ponto a ser avaliada

na função original.

Brochu et al. (2010) comentam que função de aquisição conhecida é a de Melhoria Esperada. Essa função de melhoria $I(x)$ é dada pela Eq. (3.8):

$$I(x) = \max(0, f_{N+1}(x) - f^*) \quad \text{Eq. (3.8)}$$

Onde $f_{N+1}(x)$ é a avaliação de um determinado ponto x e f^* é o melhor valor conhecido até esse momento. Desse modo, ao escolher um próximo ponto x para ser avaliado, ele retorna a diferença entre sua avaliação $f(x)$ e $f^*(x) > f^*$, caso contrário, retorna zero. O novo ponto de consulta x é encontrado maximizando a melhoria esperada (Eq. (3.9))

$$x = \operatorname{argmax} \mathbb{E}[\max(0, f_{N+1}(x) - f^*) | \mathcal{D}_N] \quad \text{Eq. (3.9)}$$

Onde \mathcal{D}_N é a distribuição a priori. A probabilidade de melhoria I em uma distribuição posterior normalmente descrita por $\mu(x)$ e $\sigma^2(x)$ que pode ser computada a partir da equação de densidade de probabilidade normal (Eq. (3.10))

$$\phi = \frac{1}{\sqrt{2\pi\sigma(x)}} \exp\left(-\frac{(\mu(x) - f(x) - EI)^2}{2\sigma^2(x)}\right) \quad \text{Eq. (3.10)}$$

A integral da Eq. (3.10) é a Melhoria Esperada, expressada pela Eq. (3.11) a seguir:

$$EI = \int_{I=0}^{I=\infty} \frac{1}{\sqrt{2\pi\sigma(x)}} \exp\left(-\frac{(\mu(x) - f(x) - EI)^2}{2\sigma^2(x)}\right) dI \quad \text{Eq. (3.11)}$$

Os autores Jones et al.(1998), comentam que a função EI (Eq. (3.11)) pode ser avaliada de forma analítica o que resulta na Eq. (3.12) e Eq. (3.13):

$$EI(x) = \begin{cases} (\mu(x) - f^*)\Phi(Z) + \sigma(x)\phi(Z) & \text{se } \sigma(x) > 0 \\ 0 & \text{se } \sigma(x) = 0 \end{cases} \quad \text{Eq. (3.12)}$$

$$Z = \frac{\mu(x) - f^*}{\sigma(x)} \quad \text{Eq. (3.13)}$$

Onde ϕ e Φ , são a função de densidade de probabilidade e a função de distribuição acumulativa de distribuição normal padrão, respectivamente.

Como já mencionado, esse processo é iterativo até que o modelo converja, ou seja, encontre o melhor valor de acurácia, logo, varia-se os hiperparâmetros da rede. Assim, para este estudo, foram definidos como hiperparâmetros da rede:

- Número de neurônios;
- Tipo de função de ativação;
- Taxa de aprendizado;
- Coeficiente de momento.

Para todos os casos de treinamento, foi definido um parâmetro de parada antecipada, com um valor máximo de 3000 iterações (épocas).

Os dados de entrada foram divididos na proporção de 80 e 20 para as fases de treinamento e teste, respectivamente. Na fase de treinamento, os dados foram organizados em subconjuntos de estimativa e validação, utilizando o método de validação cruzada (*k-fold*), com um valor de *k* igual a 5 (20% dos dados em cada subgrupo). Assim, o modelo foi treinado no subconjunto de estimativa e testado no subconjunto de validação, por meio de diferentes combinações de hiperparâmetros, até identificar o modelo com o menor erro.

Graças a essa divisão de dados, foi possível determinar os valores ótimos de pesos sinápticos e vieses que minimizam o erro na previsão do modelo. A fase de teste, por sua vez, avalia o desempenho do modelo com base nos parâmetros finais obtidos durante a fase de treinamento.

3.2.3 MÉTRICAS DE VALIDAÇÃO DE MODELO

Após a definição do modelo de Rede Neural Artificial (RNA) para prever o desempenho filtrante do sistema geotêxtil/solo, a acurácia foi avaliada ao comparar-se os valores reais com os valores previstos. Essa avaliação é feita de maneira visual, por meio de um gráfico que compara os valores previstos pelo modelo desenvolvido com os valores reais obtidos a partir

da coleta de dados, como apresenta-se na Figura 3.4. Com esse gráfico, é possível estabelecer uma linha de regressão para os dados. Essa linha, por sua vez, funciona como um limite entre os dois conjuntos de valores.

Assim, valores mais próximos da linha de regressão são interpretados como o que apresentam menor diferença entre si, ou seja, um erro menor, o que indica que o modelo possui um bom desempenho de previsão. Destaca-se que um modelo perfeito é alcançado quando a linha de regressão apresenta uma inclinação de 45 graus a partir da intercepção dos eixos do gráfico, ou seja, valor previsto é igual a valor real.

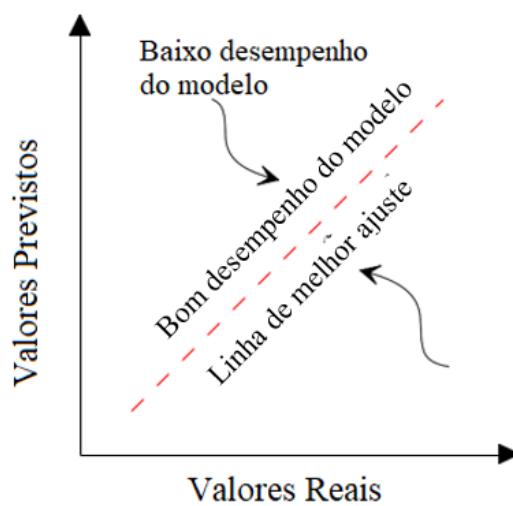


Figura 3.4 — Gráfico dos valores reais versus os valores previstos

(Adaptado de Villamil, 2023)

Para avaliação do desempenho de previsão do modelo foram utilizados três métricas estatísticas. Essas três são as mais usadas para avaliar este o desempenho de uma RNA. São elas:

- **Coeficiente de determinação R- quadrado (R^2):** permite avaliar a qualidade do ajuste de um modelo de regressão entre um valor real e o valor obtido pela RNA. Este coeficiente varia entre 0 e 1. Assim, quanto maior o R^2 , o modelo se ajusta melhor ao dado. No entanto, ele não indica a acurácia preditiva do modelo e deve ser interpretado em conjunto com outras métricas como o Erro quadrático médio (Waqas et al., 2023). Este coeficiente é representado pela Eq. (3.14)

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad \text{Eq. (3.14)}$$

Onde y_i é o valor observado (valor real); \hat{y}_i , valor estimado pelo modelo (valor previsto); e \bar{y} , média dos valores observados.

- **Raiz do Erro Quadrático Médio (The Root Mean Squared Error – RMSE):** permite estabelecer o erro quadrático entre os valores previsto e os valores observados (reais) em relação ao valor médio dos dados. Essa métrica estatística indica quão próximo os dados estão da linha de melhor ajuste.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad \text{Eq. (3.15)}$$

- Erro Percentual Médio Absoluto (*Mean Absolute Percentage Error – MAPE*): mede a acurácia do modelo de previsão em termos percentuais. Essa métrica é calculada pela média das diferenças absolutas entre os valores reais e os valores previstos, dividido pelos valores reais, e depois multiplicada por 100. Essa métrica é expressa pela Eq. (3.16)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(y_i - \hat{y}_i)}{y_i} * 100 \right| \quad \text{Eq. (3.16)}$$

O coeficiente de determinação (R^2) mede a proporção da variância na variável dependente que é explicada pelas variáveis independentes. Em outras palavras, ele fornece uma medida de quanto o modelo se ajusta aos dados. Assim, um valor de R^2 próximo de 1 indica um bom desempenho do modelo, ou seja, o modelo pode prever com precisão a variável dependente (*output*) com base nas variáveis independentes (*inputs*).

Por outro lado, os valores médios de erro (RMSE e MAPE) fornecem informações sobre a proximidade entre o valor calculado pelo modelo e o valor real. Quando os valores de erro estão próximos de 0, isso indica que os valores obtidos pelo modelo são semelhantes aos valores reais, sugerindo que o modelo se ajusta bem aos dados. Portanto, a análise conjunta dessas quatro métricas permite uma avaliação completa do modelo. Quando o valor de R^2 está próximo de 1 e os valores médios de erro estão próximos de 0, o modelo demonstra um ótimo desempenho e pode prever com precisão os valores da variável dependente (*output*).

Além das três métricas apresentadas acima, Altroush et al. (2024) comentam que, para os modelos de IA, eles podem ser avaliados complementarmente com as seguintes ferramentas tanto visuais como estatísticas:

- **Erro Quadrático Médio (*Mean Squared Error – MSE*):** permite estabelecer o erro quadrático entre os valores previsto e os valores observados (reais) em relação ao valor médio dos dados. Essa métrica estatística quantifica a magnitude média dos erros e indica quão próximo os dados estão da linha de melhor ajuste (Dodge, 2008). Esse erro é calculado por meio da Eq. (3.17).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{Eq. (3.17)}$$

- **Histograma de erros:** é crucial para visualizar a distribuição dos erros de predição, identificando padrões ou vieses nos erros cometidos pelo modelo. Um histograma assimétrico pode indicar subestimação ou superestimação do modelo, entretanto, requer de dados suficientes para ser significativo e sua interpretação pode ser subjetiva e menos precisa (Nassar et al., 2023)
- **Gráfico de correlação de valores previsto *versus* valores previsto:** esse gráfico fornece uma avaliação visual da predição preditiva do modelo, pois um alto grau de correlação linear sugere que as previsões do modelo estão próximas dos valores reais, o que indica um bom desempenho do modelo. É importante mencionar que esse método não quantifica o grau de erro ou de acurácia, e é menos eficaz para modelos que apresentam relações não lineares, de forma que podem ser enganosos em casos de *overfitting* ou *underfitting* (Walter et al., 2015).

Com o modelo finalmente ajustado, emprega-se uma técnica denominada Importância de Atribuição por Permutação (PFI), para identificar quais atributos exercem maior impacto nas previsões da variável esperada. Autores como Breiman (2001) e Fisher et al. (2019) comentam que o algoritmo PFI quantifica a importância de um atributo ao avaliar o efeito de perturbações aleatórias em seus valores sobre o desempenho do modelo. Uma diminuição significativa no desempenho do modelo com as perturbações indica a importância desse atributo. Enquanto, se o desempenho do modelo não se vê afetado, então, esse modelo é irrelevante para as previsões.

Em problemas de regressão, o desempenho do modelo é comumente avaliado pela métrica estatística Erro Quadrático Médio (MSE).

A Figura 3.5 ilustra o funcionamento do PFI, em que as instâncias de uma única coluna de atributo são embaralhadas aleatoriamente, e a variação no erro do modelo antes e depois dessa permutação (ΔMSE) é medida. Esse processo é repetido por N vezes, e a importância do atributo é determinada pela média dos valores ΔMSE das N repetições.

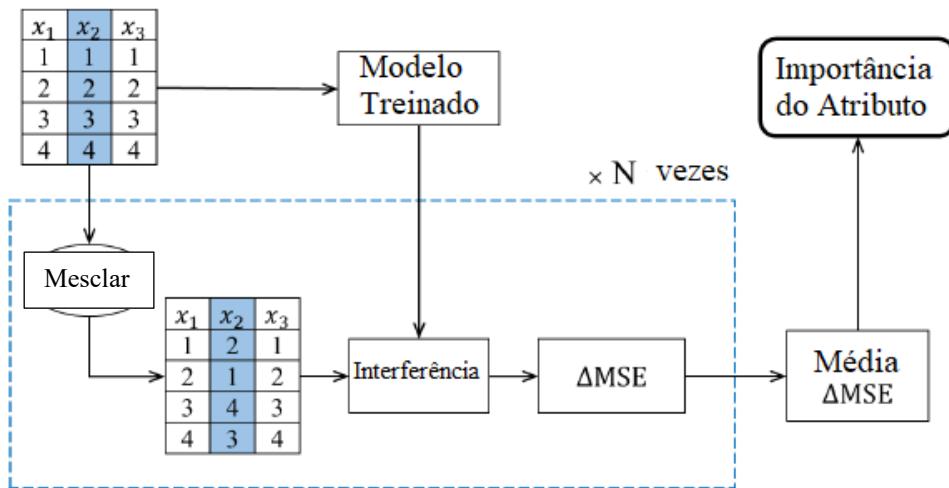


Figura 3.5: Técnica de Importância de Atribuição por Permutação (PFI) (Modificado de Carvalho, 2025)

3.2.4 LIMITAÇÕES E PROBLEMAS

Os modelos preditivos de RNA podem apresentar dois problemas principais: *overfitting* e *underfitting*, tal como é exemplificado na Figura 3.6a e Figura 3.6b, respectivamente.

O *overfitting* (Figura 3.6a) ocorre quando, para uma determinada amostra de treinamento, o modelo demonstra um bom desempenho. No entanto, ao utilizar dados de teste, o desempenho é comprometido. Isso se deve ao fato de que o modelo aprendeu as relações específicas existentes durante o treinamento e, ao receber informações dos dados de teste, aplica essas regras memorizadas, o que gerou erros (*overfitting*).

Em contrapartida, o *underfitting* (Figura 3.6b) é o processo oposto, o desempenho da rede é insatisfatório na fase de treinamento, pois o modelo não consegue ajustar adequadamente as relações entre as variáveis (devido aos poucos dados ou à inadequação do modelo). Esse fenômeno cria situações em que o modelo pode melhorar suportando uma maior quantidade de

dados de treinos que os inicialmente fornecidos (Li et al., 2021) Portanto, um modelo que apresenta esse tipo de problema não deve ser utilizado, assim, é necessário buscar outras funções de ativação ou algoritmos (Haykin, 1999; Shahin et al., 2008; Géron, 2019)

Na Figura 3.6, ilustra-se ambos os problemas de *overfitting* e *underfitting*. Assim, conforme apresentado por Pothuganti (2023), para evitar esses dois problemas, deve-se realizar diversos testes com a finalidade de atingir um equilíbrio chamado de *justifitting* (Figura 3.6c). Quando é atingido a etapa de *justifitting*, o modelo é capaz de realizar deteções complexas, que permitem a adaptação precisa ao contato com novos dados (dados de teste).

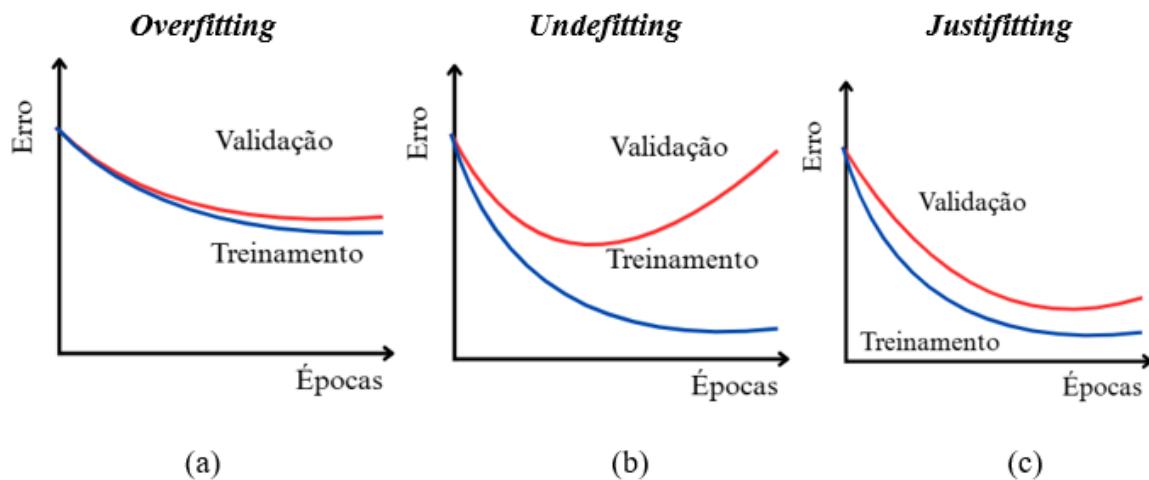


Figura 3.6: Exemplificação gráfica do *overfitting*, *underfitting* e *justifitting*.

Como mencionado anteriormente, o desenvolvimento de um modelo precisa ser verificado quanto a erros de generalização. Para isso, existem diversos métodos para evitar ou contornar a ocorrência de *overfitting* ou *underfitting*, entre esses métodos, destaca-se o aumento de dados, divisão de dados entre teste, treino e validação, paragem antecipada (*Early Stopping*) ou remoção do número de camadas

Em relação à divisão de dados, o processo de análise de RNA é baseado principalmente em duas fases: a fase de treinamento e validação. Na fase de treinamento, a rede ajusta seus pesos através do uso do algoritmo de treinamento, como apresentado na Figura 3.7, onde a saída do RNA é comparada com a saída desejada (alvo) e, então, o resíduo é utilizado para ajustar os pesos sinápticos de acordo com o algoritmo de treinamento. Por outro lado, a fase de teste, que envolve a verificação ou validação do modelo, ou seja, a rede, calcula a saída com base nos valores de entrada e nos pesos ajustados da fase de treinamento.

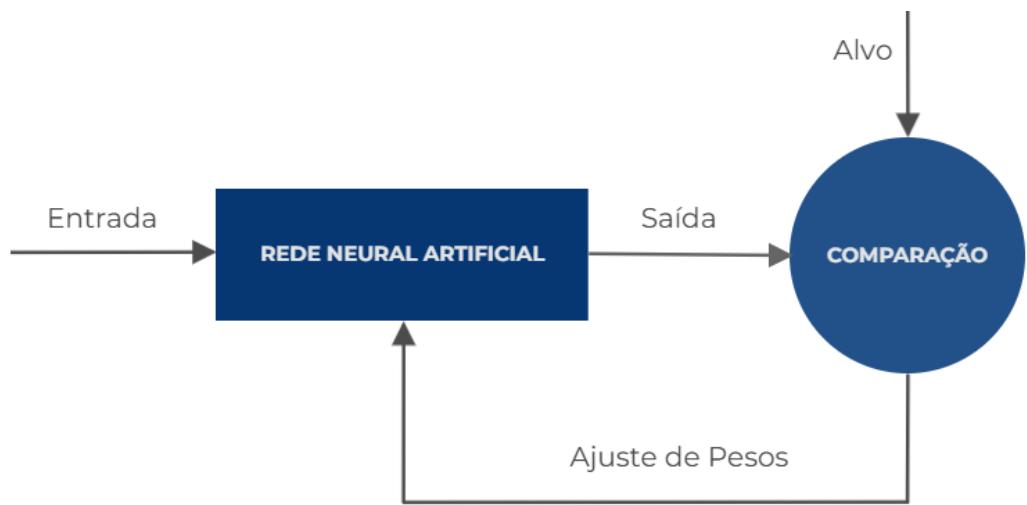


Figura 3.7: Esquema do Treinamento de uma Rede Neural Artificial

Para realizar a análise, os dados são divididos em conjuntos de treinamento e validação. Uma divisão comumente utilizada é de 70/30% ou 80/20%, respectivamente (Jeremiah et al., 2021), embora seja crucial verificar o tamanho do banco de dados para determinar a proporção mais adequada (Géron, 2019). Com vistas a projetar uma RNA com bom poder de generalização, a fase de treinamento pode ser subdividida em estimação e teste (Figura 3.8), um procedimento conhecido como validação cruzada na estatística.

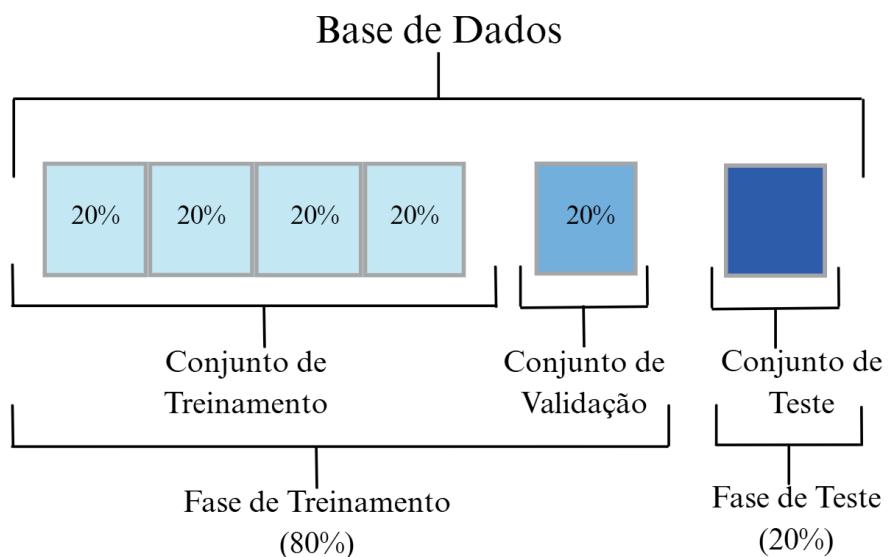


Figura 3.8: Divisão da base de dados em conjuntos de treinamento, validação e teste.

Dessa forma, um conjunto de teste pode ser utilizado durante o treinamento para determinar o momento ideal de interrupção. Esse método, denominado Parada Antecipada (*Early Stopping*), consiste em testar a rede com os dados de validação após cada época. Caso não se observem melhorias significativas, ou o Erro Quadrático Médio (MSE) comece a aumentar, o processo é interrompido, conforme ilustrado na Figura 3.9. Assim, nessa etapa, define-se o número de épocas (*epochs*) durante as quais o modelo será treinado até a sua interrupção (Haykin, 1999; Silva et al., 2016).

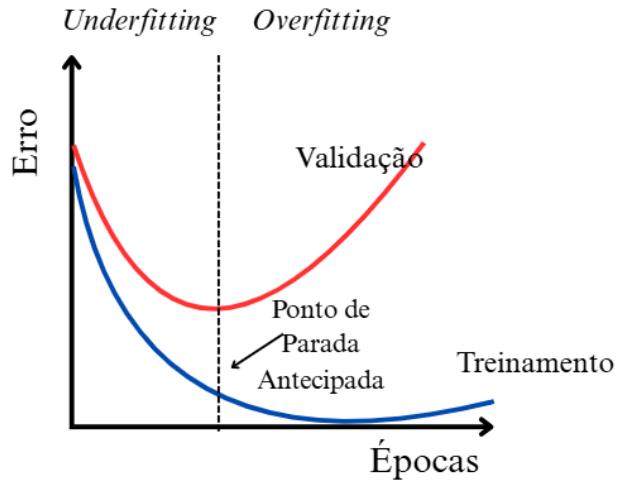


Figura 3.9: Método da Parada Antecipada com conjunto de validação (Adaptado de Haykin, 1999).

Ressalta-se que, entre os problemas existentes no treinamento de redes MLP, encontra-se (Haykin, 1999):

- **Definição dos parâmetros de entrada:** a sensibilidade do modelo a variações nos parâmetros de entrada implica que pequenas alterações podem induzir divergências significativas tanto na fase de treinamento quanto na capacidade de generalização da rede neural. A seleção e o ajuste criteriosos desses parâmetros são, portanto, etapas cruciais no desenvolvimento de modelos robustos.
- **Dimensionamento das entradas (Feature Scaling):** a magnitude (quantidade) das variáveis de entrada influencia diretamente a escala efetiva dos pesos na camada de entrada da rede. Essa disparidade de escalas pode impactar a qualidade da solução final e a eficiência do processo de otimização. Inicialmente, recomenda-se a padronização das entradas, de forma a garantir que todas as *features* contribuam equitativamente durante a aplicação de técnicas de regularização. Essa normalização também estabelece

um intervalo significativo para a inicialização aleatória dos pesos, facilitando a exploração do espaço de busca e potencialmente acelerando a convergência do treinamento.

- **Número neurônios e de camadas ocultas:** em linhas gerais, arquiteturas de redes neurais com um número elevado de neurônios ocultos tendem a apresentar melhor capacidade de aproximação de funções complexas do que aquelas com poucas unidades. Uma quantidade subdimensionada de unidades ocultas pode restringir a flexibilidade do modelo, de forma a limitar sua habilidade de capturar as não linearidades inerentes aos dados. Por outro lado, embora um número excessivo de unidades ocultas aumente a capacidade representacional da rede, o risco de *overfitting* pode ser mitigado através da aplicação de técnicas de regularização adequadas. Nesses casos, os pesos associados às unidades redundantes podem ser efetivamente penalizados, tendendo a valores próximos de zero durante o processo de treinamento. Empiricamente, o número ideal de unidades ocultas geralmente se situa em uma faixa que varia entre 5 e 100 — comumente, escalonando-se em proporção ao número de variáveis de entrada e ao volume do conjunto de dados de treinamento. Uma prática comum e eficaz consiste em definir uma arquitetura com um número relativamente grande de unidades ocultas e, subsequentemente, empregar métodos de regularização robustos durante o treinamento para controlar a complexidade do modelo e evitar o *overfitting*.
- **Multiplicidade de Mínimos Locais:** a função de erro associada a redes neurais profundas tipicamente exibe uma natureza não convexa, caracterizada pela presença de múltiplos mínimos locais. Consequentemente, a solução otimizada resultante do processo de treinamento demonstra uma sensibilidade significativa à inicialização dos pesos sinápticos. Para mitigar essa dependência, recomenda-se a avaliação de um conjunto diversificado de configurações iniciais aleatórias, em que se seleciona a arquitetura que apresentar o menor erro de generalização, possivelmente incorporando um termo de penalização para regularização. Uma estratégia robusta para a obtenção da predição final consiste em empregar a média das previsões geradas por um *ensemble* (conjunto) de redes independentemente treinadas (Ripley, 1996). Essa abordagem é preferível à média dos pesos individuais das redes, dado que a não linearidade intrínseca

ao modelo pode resultar em um desempenho subótimo da solução média dos pesos. Adicionalmente, a técnica de *bagging* emerge como uma alternativa eficaz, ao computar a média das previsões de modelos treinados em versões aleatoriamente perturbadas do conjunto de dados de treinamento, promovendo a robustez e a estabilidade das previsões.

Outra maneira de controlar a probabilidade de *overfitting* no modelo é realizar a regularização de hiperparâmetros. Em ML, os parâmetros de entrada utilizados durante o treinamento controlam parte do aprendizado, análise e o resultado a ser previsto. No entanto, certos parâmetros do algoritmo permanecem constantes durante a fase de treinamento. Esses parâmetros são conhecidos como hiperparâmetros, que podem ser otimizados para reduzir o esforço e melhorar o desempenho do algoritmo aplicado (Hutter et al., 2019). A otimização permite encontrar o(s) parâmetro(s) que ajudam a minimizar uma função desejada (Das & Suganthan, 2011). De acordo com Bilal et al. (2020) alguns hiperparâmetros comumente empregados em modelos de Redes Neurais Artificiais (RNAs) são:

- Número de camadas
- Função de ativação;
- Função de perda;
- Algoritmo de Otimização
- Número de épocas

Desta forma, o algoritmo de otimização tem como objetivo ajustar os valores dos parâmetros de um modelo, de modo de minimizar sua função de perda. O otimizador Adam, que significa “*adaptive moment estimation*”, combina as melhores características dos algoritmos AdaGrad (*Adaptive Gradient Descent*) e RMSProp (*Root Mean Square*), o que resulta em um método de otimização eficaz para lidar com gradientes esparsos em problemas ruidosos (Brownlee, 2021). Segundo Kingma & Ba (2014), o algoritmo Adam é uma escolha popular entre os cientistas de dados, sendo utilizado na etapa de retropropagação. Esse algoritmo calcula taxas de aprendizado adaptativas individuais para diferentes parâmetros, baseando-se em estimativas dos primeiros e segundos momentos dos gradientes. O algoritmo rastreia uma média móvel exponencialmente ponderada (*Exponentially Weighted Moving Averages* -EWMA) tanto do gradiente quanto dos gradientes quadrados. As etapas desse algoritmo são apresentadas nas equações a seguir:

$$v \leftarrow \gamma_2 v + (1 - \gamma_2)(\nabla_{\theta} J(\theta))^2 \quad \text{Eq. (3.19)}$$

$$m \leftarrow \gamma_1 m + (1 - \gamma_1)\nabla_{\theta} J(\theta) \quad \text{Eq. (3.18)}$$

$$v \leftarrow \gamma_2 v + (1 - \gamma_2)(\nabla_{\theta} J(\theta))^2 \quad \text{Eq. (3.19)}$$

$$\hat{m} \leftarrow \frac{m}{1 - \gamma_1 t} \quad \text{Eq. (3.20)}$$

$$\hat{v} \leftarrow \frac{m}{1 - \gamma_2 t} \quad \text{Eq. (3.21)}$$

$$\theta \leftarrow \theta - \alpha \frac{\hat{m}}{\sqrt{\hat{v} + \delta}} \quad \text{Eq. (3.22)}$$

Onde γ_1 e γ_2 representam as taxas de decaimento exponencial para as estimativas de momento; m e v são as estimativas enviesadas do primeiro e segundo momento; $\nabla_{\theta} J(\theta)$ é o gradiente da função de perda $J(\theta)$, em relação aos parâmetros θ . Por outro lado, \hat{m} e \hat{v} são as estimativas de primeiro e segundo momentos com correção de viés; δ , é uma pequena constante adicionada para garantir a estabilidade numérica; e α é a taxa de aprendizado.

Em contrapartida, Reddi et al. (2019) observaram que o algoritmo Adam nem sempre converge para a solução ótima e propuseram AMSGrad (*Adaptive Moment Estimation with improved convergence guarantees*), uma variante de Adam com convergência garantida. Essa variante introduz uma nova média móvel exponencial, que considera o máximo de todas as estimativas do segundo momento até o instante atual, normalizando a média móvel do gradiente.

4 RESULTADOS

Este capítulo apresenta e analisa os resultados obtidos após a aplicação da metodologia de Rede Neural Artificial (RNA) para prever o desempenho filtrante dos sistemas solo/geotêxtil. Primeiramente, realiza-se uma interpretação e correlação dos dados coletados. Em seguida, faz-se uma descrição das características dos modelos implementados, a qual é seguida da avaliação da eficiência obtida para cada modelo, a fim de identificar qual apresenta a melhor performance.

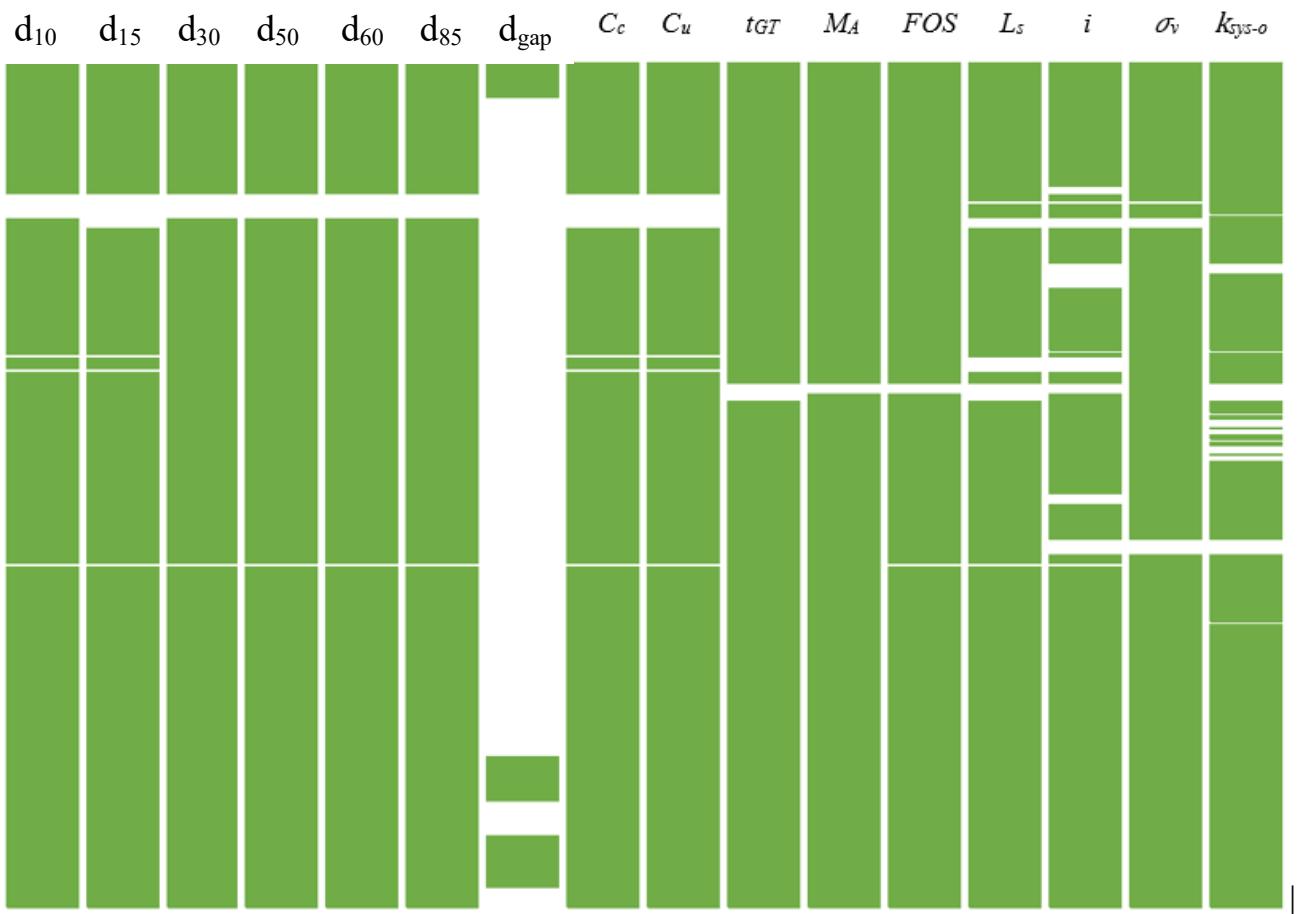
4.1 ANÁLISE DOS DADOS

4.1.1 INTERPRETAÇÃO DE DADOS

Como apresentado no Capítulo 4, foram coletadas 352 amostras de 19 publicações bibliográficas e 2 acervos pessoais de pesquisadores. Esses dados foram selecionados ao se considerar fatores de influência similares, sendo que, inicialmente, foram estabelecidos 16 parâmetros. A Figura 4.1 apresenta uma visualização da distribuição dos dados presentes e ausentes no conjunto de dados coletados. Cada coluna representa uma variável diferente e os espaços em branco indicam dados ausentes para cada parâmetro. É possível observar que o diâmetro de intervalo (d_{gap}) apresenta a menor quantidade de informações reportadas, o que se deve ao fato de ser um parâmetro característico do tipo de solo a ser analisado.

Por outro lado, a maioria das variáveis apresenta uma quantidade significativa de dados presentes. No entanto, deve-se atentar-se aos dados ausentes na variável de permeabilidade inicial do sistema solo/geotêxtil (k_{sys-o}), pois a ausência desses dados compromete o uso na análise desta pesquisa.

Figura 4.1 :Distribuição de dados presentes e ausentes nas variáveis do conjunto de dados



A Tabela 4.1 apresenta os dados estatísticos dos parâmetros de influência utilizados após a limpeza dos dados de *outliers* ou valores atípicos (que resultaram em 287 amostras úteis). Para cada parâmetro, são calculados os valores máximo, mínimo e médio, juntamente com a distribuição dos dados, medida pelo desvio padrão, coeficiente de variação e coeficiente de assimetria. O desvio padrão mensura o desvio dos dados em relação ao valor médio, de modo que um valor menor indica uma concentração mais estreita em torno da média. Por outro lado, o coeficiente de variação indica o nível de homogeneidade dos dados, com uma porcentagem mais alta sugerindo maior heterogeneidade. O coeficiente de assimetria indica a simetria da distribuição dos dados, de forma que um valor mais alto indica uma assimetria mais significativa, e o sinal representa sua direção (positivo: à direita, negativo: à esquerda). Para o parâmetro “Tipo Geotêxtil”, é apresentada a quantidade de cada teste realizado.

Tabela 4.1 :Dados estatísticos dos parâmetros de entrada

Simb.	Parâmetro	Mín.	Máx.	Média	Desvio Padrão σ	Coef. de Variância CV	Assimetria
Variável de Entrada (Inputs)							
d_{10}	Diâmetro da partícula de solo correspondente a 10% do material mais fino (mm)	0,001	0,489	0,083	0,144	173,826 %	2,056
d_{15}	Diâmetro da partícula de solo correspondente a 15% do material mais fino (mm)	0,002	0,748	0,139	0,201	147,877 %	1,807
d_{30}	Diâmetro da partícula de solo correspondente a 30% do material mais fino (mm)	0,003	1,849	0,423	0,571	134,742 %	1,487
d_{50}	Diâmetro da partícula de solo correspondente a 50% do material mais fino (mm)	0,004	5,986	1,112	1,726	154,859 %	1,811
d_{60}	Diâmetro da partícula de solo correspondente a 60% do material mais fino (mm)	0,006	8,635	1,607	2,586	160,28%	1,808
d_{85}	Diâmetro da partícula de solo correspondente a 85% do material mais fino (mm)	0,034	16,833	3,350	5,449	162,370 %	1,735
d_{gap}	Diâmetro da partícula de solo correspondente a 10% do material mais fino (mm)	0,008	0,023	0,013	0,005	41,276%	0,737
C_c	Coeficiente de curvatura	0,106	19,079	3,588	3,970	110,459 %	1,603
C_u	Coeficiente de uniformidade	1,725	106,965	35,400	28,191	79,502%	0,535
t_{GT}	Espessura de geotêxtil (mm)	0,330	5,600	2,058	1,115	54,085%	0,791
M_A	Gramatura do geotêxtil (g/m^2)	95	627	254,515	126,978	49,806%	1,257
FOS	Abertura de filtração do geotêxtil (mm)	0,03	0,6	0,184	0,144	78,412%	1,783
L_s .	Espessura do corpo de prova (cm)	1,5	16	7,205	3,565	49,400%	0,561
i_{sys}	Gradiente hidráulico	1	20	5,365	5,151		1,280
σ_v	Tensão vertical (kPa)	0,961	2012,4	149,966	434,526		3,676

Simb.	Parâmetro	Mín.	Máx.	Média	Desvio Padrão σ	Coef. de Variância CV	Assimetria
Variável de Entrada (Inputs)							
k_{sys-o}	Coeficiente de permeabilidade inicial do sistema solo- geotêxtil (cm/s)	$4,27 \times 10^{-7}$	$6,10 \times 10^{-1}$	$9,56 \times 10^{-3}$	0,057	591,377 %	9,300
Variável de Saída (Output)							
k_{sys}	Coeficiente de permeabilidade final do sistema solo- geotêxtil (cm/s)	$2,80 \times 10^{-7}$	$4,20 \times 10^{-2}$	$7,00 \times 10^{-3}$	0,039	557,840 %	8,728

A Tabela 4.1 de dados estatísticos apresenta uma análise descritiva de diversas variáveis de entrada (propriedades do solo, do geotêxtil e condições do ensaio) e da variável de saída (coeficiente de permeabilidade final do sistema solo-geotêxtil – k_{sys}). A análise dos parâmetros revela uma alta variabilidade geral nos dados, evidenciada pelos elevados coeficientes de variância (CV), que são maiores que 100%, observados para a maioria das variáveis de entrada e para a variável de saída. Essa dispersão significativa sugere que o conjunto de dados abrange uma ampla gama de cenários e condições experimentais, o que é crucial para o desenvolvimento de modelos preditivos robustos com boa capacidade de generalização.

A assimetria das distribuições também é uma característica notável. A maioria das variáveis de entrada, especialmente os diâmetros das partículas do solo (d_{10} a d_{85}) e os coeficientes de curvatura (C_c) e uniformidade (C_u), apresentam uma assimetria positiva considerável. Isso indica que as distribuições dessas variáveis tendem a ter uma cauda mais longa, estendendo-se para valores mais altos, com a maioria dos dados concentrados em valores abaixo da média. Essa assimetria pode influenciar o desempenho de modelos estatísticos que assumem distribuições simétricas, de modo que podem exigir transformações de dados para melhor adequação.

Em relação aos parâmetros do solo, a análise dos diâmetros das partículas (d_{10} a d_{85}) reflete a esperada progressão no tamanho das partículas correspondentes a frações crescentes do solo mais fino. Observa-se que esses diâmetros podem variar em ordens de grandeza (potências de 10), mesmo dentro de uma mesma curva granulométrica, evidenciando a ampla distribuição de tamanhos presentes em algumas amostras. A alta variabilidade ($CV > 130\%$) nesses parâmetros

demonstra a diversidade das granulometrias dos solos investigados. A assimetria positiva acentuada sugere que, embora haja uma predominância de partículas menores, algumas amostras apresentam proporções significativas de partículas maiores. O parâmetro d_{gap} , específico para solos com granulometria descontínua, exibe uma variabilidade menor, o que pode ser atribuído à sua natureza mais restrita a um tipo específico de solo. Os coeficientes de forma da curva granulométrica (C_c e C_u) também apresentam variabilidade considerável, indicando uma ampla gama de formas de distribuição de partículas entre os solos estudados.

Por outro lado, os parâmetros do geotêxtil em comparação com os parâmetros do solo, e as propriedades do geotêxtil (espessura – t_{GT} , gramatura – M_A e abertura de filtração – FOS) mostram uma variabilidade geralmente menor (CVs entre 49% e 78%). Isso sugere uma gama menos extensa de geotêxteis utilizados nos testes em comparação com a diversidade dos solos. No entanto, a abertura de filtração (FOS) ainda apresenta uma variabilidade considerável. A assimetria positiva para esses parâmetros indica uma tendência para valores menores de espessura, gramatura e abertura, com alguns geotêxteis que apresentam valores significativamente maiores.

Já os parâmetros relacionados com as condições do ensaio, as condições de teste revelam uma ampla gama de configurações experimentais. A espessura do corpo de prova (L_s) apresenta uma variabilidade moderada. O gradiente hidráulico (i) e, especialmente, a tensão vertical (σ_v) mostram uma dispersão muito alta, o que indica que os testes foram realizados sob uma variedade de condições de fluxo e confinamento. A permeabilidade inicial do sistema solo-geotêxtil (k_{sys-o}) exibe a maior variabilidade de todas as variáveis de entrada, abrangendo várias ordens de magnitude. Essa extrema variabilidade reflete a sensibilidade da permeabilidade inicial às características do solo e do geotêxtil.

A variável de saída (k_{sys}), coeficiente de permeabilidade final do sistema solo-geotêxtil, também apresenta uma variabilidade muito alta, comparável à da permeabilidade inicial. Isso demonstra que o resultado da permeabilidade do sistema varia significativamente entre os diferentes ensaios, provavelmente em resposta à combinação das diversas propriedades do solo, do geotêxtil e das condições do ensaio. A alta assimetria positiva para k_{sys} sugere que a maioria dos sistemas tende a apresentar uma permeabilidade final baixa, com alguns casos isolados de permeabilidade final significativamente maior.

A análise estatística detalhada desses dados ressalta a complexidade do comportamento de sistemas solo-geotêxtil em solos internamente instáveis. A alta variabilidade e a assimetria das distribuições das variáveis de entrada e saída implicam que modelos preditivos simples podem não ser suficientes para capturar as relações subjacentes.

A extrema variabilidade observada em k_{sys-o} e k_{sys} sugere a necessidade de considerar transformações de dados, ou modelos, que sejam robustos a essa ampla gama de valores. Em última análise, uma compreensão aprofundada dessas características estatísticas é fundamental para a seleção e o desenvolvimento de modelos preditivos eficazes para o desempenho de filtros geotêxteis em solos internamente instáveis.

Para o desenvolvimento do modelo de Rede Neural Artificial (RNA), conforme detalhado ao longo deste capítulo, foram considerados apenas geotêxteis do tipo não tecido, os quais totalizaram 224 amostras que abrangem dois tipos de solos classificados como internamente instáveis. Assim, foram analisados estatisticamente os 3 modelos desenvolvidos.

Nesse sentido, a Tabela 4.2 e a Tabela 4.3, apresentam as análises estatísticas dos parâmetros de entrada e do parâmetro de saída, respectivamente, para o Modelo 1 (que considera os dois tipos de solo).

Tabela 4.2 : Dados estatísticos dos parâmetros de entrada considerando os solos descontínuos e com concavidade para cima

Sím	Min	Máx	Média	Desvio Padrão	Assimetria	Mediana	Q1	Q3	IQR	# Outlier inf	Outliers inf (%)	# Outlier sup	Outliers sup(%)
d_{10}	0,001	0,489	0,059	0,123	2,793	0,015	0,006	0,0405	0,035	0	0	33	14,73
d_{15}	0,002	0,748	0,103	0,176	2,494	0,039	0,007	0,0842	0,077	0	0	38	16,96
d_{30}	0,008	1,849	0,284	0,510	2,089	0,053	0,015	0,17	0,155	0	0	42	18,75
C_u	2,616	106,965	31,553	28,214	0,838	19,333	8,840	55,268	46,428	0	0	0	0
t_{GT}	0,51	5,6	2,268	0,920	0,388	2,3	1,9	2,6	0,7	12	5,36	23	10,27
FOS	0,03	0,5	0,147	0,0916	3,007	0,13	0,117	0,143	0,026	18	8,04	33	14,73
i	1	20	5,181	5,492	1,376	2,5	1	10	9	0	0	0	0
σ_v	0,961	2012,436	149,966	434,526	3,676	7,271	3,63	51,484	47,854	0	0	31	13,84
k_{sys-o}	$7,86 \times 10^{-7}$	0,61	0,010	0,0627	8,466	$5,00 \times 10^{-4}$	$7,60 \times 10^{-5}$	$2,16 \times 10^{-3}$	$2,08 \times 10^{-3}$	0	0	32	14,29

Tabela 4.3: Dados estatísticos dos parâmetros de saída considerando os solos mal graduados e com concavidade para cima

Sím	Min	Máx	Média	Desvio Padrão	Assimetria	Mediana	Q1	Q3	IQR	# Outlier inf	Outliers inf (%)	#Outlier sup	Outliers sup(%)
k_{sys}	$2,76 \times 10^{-7}$	0,097	$1,87 \times 10^{-3}$	$8,81 \times 10^{-3}$	8,528	$1,55 \times 10^{-4}$	$2,97 \times 10^{-5}$	$7,83 \times 10^{-4}$	$7,54 \times 10^{-4}$	0	0	33	14,73

As informações estatísticas obtidas dos diferentes estudos apresentados revelam o uso de vários tipos de solos com altas porcentagem de finos (silte e argila) e pequenas porções de areias (areia fina e média) em relação às propriedades do solo. Os solos finos variam entre argila e silte com um tamanho médio de 0,06 mm (conforme relatado por Mello, 2001), a areia fina e, com um tamanho de 0,10 mm (de acordo com Vangla & Gali, 2016), e uma areia média, de 1,85 mm.

Os solos apresentam também pequenas porções de areias (finas e média) com 16,52%, 22,77% e 40,18% respectivamente A distribuição dos dados é heterogênea, com uma tendência de os valores serem inferiores à média (assimetria entre 2,09 e 2,79). Segundo os autores Kenney & Lau (1985), solos com fração mais fina (30%) podem apresentar comportamentos instáveis, sendo que os solos estudados apresentam uma porcentagem maior de 50% de finos, de modo que são solos com alto potencial de apresentar instabilidade. Portanto, para a definição de um solo instável, precisam ser analisados outros parâmetros, como o coeficiente de uniformidade (C_u).

Pode-se observar que o coeficiente de uniformidade (C_u) varia entre 2,62 e 106,97. Este valor máximo explica a dispersão significativa dos dados com um desvio padrão de 28,21 e uma assimetria de 0,84, que pode ser confirmado pela divergência da média de 31,55 com a mediana de 19,33.

Por outro lado, esses dados estatísticos confirmam que a maioria das amostras podem ser considerados solos instáveis, pois, segundo Lafleur (1999), solos com $C_u > 6$ com curva granulométrica com concavidade para cima atendem ao critério de serem considerados solos instáveis. Assim, 79,91% dos dados totais cumprem esses critérios. Christopher & Holtz (1985) consideram que os solos que apresentam $C_u > 20$ com concavidade para cima são considerados como solos instáveis, de forma que 54,91% das amostras apresentam essa condição.

A faixa de tensão aplicada nos testes é ampla, pois varia de 1 kPa a valores significativos de 2012 kPa, com a maioria dos valores se concentrando em uma faixa muito inferior à média. Isso se deve principalmente aos ensaios onde não se aplicam tensão vertical, mas é considerada a tensão vertical proveniente da força de percolação devido ao fluxo da água através do sistema.

Os dados exibem uma tendência altamente dispersa, o que significa que os valores da tensão vertical variam drasticamente. O Intervalo Interquartil (IQR), com um valor de 47,854 kPa, é

considerável e evidencia a alta dispersão da metade central dos dados. Este fato, somado à discrepância significativa entre a média (149,97 kPa) e a mediana (7,27 kPa), sugere uma distribuição assimétrica. Considera-se como valor central típico dos dados a mediana (7,27 kPa), já que é menos sensível a *outliers*.

Com relação à assimetria (3,676), é muito alta e positiva, o que indica uma distribuição extremamente assimétrica à direita. Isso significa que há uma longa cauda de valores altos que puxam a média para cima. Há um número considerável de *outliers* superiores (13,84%), o que indica a presença de valores de tensão vertical muito acima da faixa típica.

A abertura de filtração do geotêxtil (FOS) varia entre 0,03 mm e 0,5 mm, de modo que a maioria dos valores se concentra em torno de 0,13 mm a 0,147mm. Assim, observa-se uma tendência a aberturas do geotêxtil menores, o que pode ser devido ao fato de o tipo de solo em contato apresentar uma granulometria mais fina. O desvio padrão de 0,092 mm indica uma dispersão moderada dos dados em relação à média 0,147 mm. Isso significa que os valores da abertura de filtração do geotêxtil variam, mas não de forma extrema. O IQR de 0,026 mm também indica uma dispersão moderada dos 50% dos dados, concentrando-se em uma faixa estreita. A média de 0,147 mm e a mediana de 0,13 mm são próximas, o que confirma uma distribuição relativamente simétrica, embora a assimetria indique o contrário.

A assimetria (3,007) é alta e positiva, o que indica que a distribuição dos dados é fortemente assimétrica à direita. Isso sugere a presença de alguns valores significativamente maiores que a média, aproximadamente 37% dos dados totais dos parâmetros de entrada FOS.

Com relação aos *outliers*, destaca-se uma quantidade considerável tanto inferiores (8,04%) quanto superiores (14,73%). Isso indica que existem valores de abertura de filtração do geotêxtil que se desviam significativamente da faixa típica.

De acordo com os resultados, a espessura do geotêxtil está dentro dos valores nominais comumente usados na indústria, variando de 0,5 a 5,6 mm. Com um desvio padrão de 0,920mm, os dados indicam uma dispersão moderada em relação à média (2,268mm), com a maioria dos valores se concentrado em torno de 2,3mm. A assimetria de 0,388 é positiva, próxima de zero, o que confirma uma distribuição relativamente simétrica dos dados, com uma leve tendência

para os valores altos. Observam-se *outliers* tanto inferiores (5,35%) quanto superiores (10,27%), o que indica diferentes tipos de geotêxteis utilizados nos testes realizados por diferentes autores.

Com relação às condições em que o geotêxtil é submetido, os gradientes hidráulicos variam de 1 a 20, de modo que a maioria dos valores se concentra em uma faixa mais baixa. O desvio padrão (5,49) é relativamente alto em comparação com a média (5,18), indicando uma dispersão moderada dos dados. Isso significa que os valores do gradiente hidráulico variam consideravelmente.

O IQR de 9 também reforça essa moderada dispersão, uma vez que mostra que os 50% dos dados têm uma faixa de variação considerável. A distribuição de dados não é perfeitamente simétrica, devido ao fato de que a média (5,18) é significativamente diferente da mediana de 2,5. Não há *outliers* presentes, tanto inferiores quanto superiores. Isso sugere que os dados, apesar da dispersão, estão dentro de uma faixa considerada normal para o gradiente hidráulico. A ausência de *outliers* pode indicar que os testes foram feitos com maior controle. Pode-se entender que a variabilidade dos valores de gradiente hidráulicos é devido aos diferentes tamanhos de corpos de prova e cargas hidráulicas totais utilizadas nos testes realizados por diferentes autores.

Em relação à permeabilidade inicial do sistema solo/geotêxtil, ou seja, a permeabilidade no início do ensaio, os valores variam entre $7,96 \times 10^{-7}$ cm/s e 0,61 cm/s, de forma que a maioria dos valores se concentra em uma faixa muito inferior à média. Essa faixa de valores apresenta uma dispersão alta dos dados, pois apresenta um desvio padrão de 0,063cm/s em comparação com a média de 0,010cm/s. Essa dispersão dos dados é confirmada pelo valor do IQR de $2,08 \times 10^{-3}$ cm/s, que reforça a variabilidade dos 50% dos dados.

A diferença da média (0,010 cm/s) com a mediana é considerável ($5,00 \times 10^{-4}$ cm/s), sugerindo a influência por valores extremos. A assimetria é muito alta e positiva (8,47), o que significa a presença de valores altos. Há um número considerável de *outliers* superiores (14,29%), o que indica a presença de valores de permeabilidade inicial muito acima da faixa típica. A grande variação dos valores de permeabilidade pode ser devido à grande variedade de solos e geotêxteis utilizados nos testes.

As Tabela 4.4 e Tabela 4.5 apresentam as análises estatísticas dos parâmetros de entrada e do parâmetro de saída, respectivamente, para o Modelo 2 (solos com concavidade para cima)

Tabela 4.4 — Dados estatísticos dos parâmetros de entrada considerando os solos com concavidade para cima

Sím	Min	Máx	Média	Desvio Padrão	Assimetria	Mediana	Q1	Q3	IQR	# Outlier inf	Outliers inf (%)	#Outlier sup	Outliers sup(%)
d_{10}	0,001	0,489	0,084	0,144	2,100	0,022	0,006	0,068	0,062	0	0	26	17,45
d_{15}	0,005	0,748	0,140	0,203	1,942	0,065	0,010	0,141	0,131	0	0	17	11,41
d_{30}	0,015	1,849	0,399	0,577	1,579	0,142	0,028	0,45	0,422	0	0	23	15,444
C_u	2,627	106,965	21,389	23,965	1,988	9,505	8,840	19,333	10,493	0	0	34	22,82
t_{GR}	0,51	5,6	2,322	0,946	0,243	2,3	1,59	2,65	1,06	0	0	2	1,34
FOS	0,06	0,5	0,166	0,105	2,526	0,13	0,117	0,158	0,041	0	0	12	8,053
i	1	20	5,198	5,730	1,575	2,5	1	5	4	0	0	16	10,74
σ_v	0,971	2012,436	213,146	521,496	2,857	7,271	3,516	101,643	98,127	0	0	20	13,42
k_{sys-o}	$7,86 \times 10^{-7}$	0,61	0,014	0,077	6,869	$3,33 \times 10^{-4}$	$4,07 \times 10^{-5}$	$2,03 \times 10^{-3}$	$1,99 \times 10^{-3}$	0	0	20	13,42

Tabela 4.5: Dados estatísticos do parâmetro de saída considerando os solos mal graduados e com concavidade para cima

Sím	Min	Máx	Média	Desvio Padrão	Assimetria	Mediana	Q1	Q3	IQR	# Outlier inf	Outliers inf (%)	#Outlier sup	Outliers sup(%)
k_{sys}	$2,76 \times 10^{-7}$	0,097	$2,64 \times 10^{-3}$	0,011	6,942	$1,76 \times 10^{-4}$	$1,28 \times 10^{-5}$	$1,17 \times 10^{-3}$	$1,16 \times 10^{-3}$	0	0	17	11,41

De acordo com Tabela 4.4, os valores médios dos diâmetros das partículas correspondentes a 10%, 15% e 30% do material mais fino (d_{10} , d_{15} e d_{30}), respectivamente 0,084 mm, 0,140 mm e 0,399 mm, indicam uma composição granulométrica que tende a partículas finas, alinhando-se com a descrição de solos com alta porcentagem de siltes e argilas. A dispersão desses dados, avaliada pelo desvio padrão (0,144 mm para d_{10} , 0,203 mm para d_{15} e 0,577 mm para D_{30}), aumenta progressivamente com o tamanho da partícula. A assimetria positiva observada (2,100 para d_{10} , 1,942 para d_{15} e 1,579 para d_{30}) sugere que a distribuição dos tamanhos de partícula tende a concentrar-se em valores inferiores à média, com uma cauda alongada para valores maiores.

O coeficiente de uniformidade (C_u) apresenta uma média de 21,389 e uma mediana de 9,505, o que revela uma distribuição assimétrica, corroborada pela assimetria calculada de 1,988. A ampla faixa de variação do C_u (2,627 a 106,965) indica a inclusão de solos com diferentes graus de uniformidade, que abrange desde solos bem graduados até solos com uma distribuição granulométrica mais extensa. A presença de uma porcentagem significativa de *outliers* superiores (22,82%) enfatiza a existência de amostras com uma grande variedade de tamanhos de partículas.

A tensão vertical (σ_v) aplicada nos testes varia consideravelmente, de 0,97 kPa a 2012,4 kPa. A média de 149,97 kPa é significativamente maior que a mediana de 7,27 kPa, o que indica uma forte influência de valores extremos e de uma distribuição altamente assimétrica à direita, com uma assimetria de 2,857. A alta dispersão, evidenciada pelo desvio padrão de 521,496 kPa e pelo intervalo interquartil (IQR) de 98,127 kPa, confirma a heterogeneidade das condições de confinamento aplicadas. A presença de *outliers* superiores (13,42%) destaca a ocorrência de testes sob tensões verticais muito elevadas.

A abertura de filtração do geotêxtil (FOS) varia entre 0,03 mm e 0,6 mm, com uma tendência para valores menores, conforme indicado pela média de 0,166 mm e pela mediana de 0,13 mm. A dispersão dos dados, com um desvio padrão de 0,105 mm, é moderada e a assimetria positiva de 2,526 sugere uma distribuição com uma concentração de valores menores e uma cauda alongada para valores maiores. A presença de *outliers* inferiores (8,04%) e superiores (10,74%) indica desvios significativos da faixa típica de abertura de filtração.

Por outro lado, a espessura do geotêxtil (t_{GT}) apresenta uma faixa de variação de 0,51 mm a 5,6 mm, com uma média de 2,322 mm e uma mediana de 2,3 mm, o que sugere uma distribuição relativamente simétrica, confirmada pela baixa assimetria de 0,243. A presença de *outliers* inferiores (5,35%) e superiores (1,34%) reflete a variedade de geotêxteis utilizados nos testes. O gradiente hidráulico (i) varia de 1 a 20, com uma tendência para valores mais baixos, conforme a média de 5,198 e a mediana de 2,5. A dispersão dos dados é alta, com um desvio padrão de 5,730. A assimetria positiva de 1,575 indica uma distribuição com uma cauda longa para valores mais altos. A ausência de *outliers* inferiores e superiores sugere uma maior consistência nas condições de fluxo aplicadas.

A permeabilidade inicial do sistema solo/geotêxtil (k_{sys-o}) exibe uma ampla faixa de variação, de $7,86 \times 10^{-7}$ cm/s a 0,61 cm/s, com uma concentração de valores inferiores à média de 0,014 cm/s e à mediana de $3,33 \times 10^{-4}$ cm/s. A alta dispersão, com um desvio padrão de 0,077 cm/s, e a assimetria muito alta e positiva, de 6,869, indicam a influência de valores extremos. A presença de uma porcentagem considerável de *outliers* superiores (13,42%) enfatiza a grande variabilidade na permeabilidade inicial dos sistemas testados.

Finalmente, o coeficiente de permeabilidade final do sistema solo-geotêxtil (k_{sys}) apresenta uma faixa de variação de $2,76 \times 10^{-7}$ cm/s a 0,097 cm/s, com uma tendência para valores baixos, evidenciada pela média de $2,64 \times 10^{-3}$ cm/s e pela mediana de $1,76 \times 10^{-4}$ cm/s. A dispersão dos dados é alta, com um desvio padrão de 0,011 cm/s. A assimetria positiva de 6,942 sugere uma distribuição com uma cauda longa para valores mais altos. A presença de *outliers* superiores (11,41%) indica alguns casos com permeabilidade final significativamente maior que a maioria.

As análises estatísticas dos parâmetros de entrada e do parâmetro de saída para o Modelo 3 (solos descontínuos) são apresentados na Tabela 4.6 e

Tabela 4.7, respectivamente.

Tabela 4.6: Dados estatísticos dos parâmetros de entrada considerando os solos mal graduados (*gap graded*)

Sím	Min	Máx.	Média	Desvio Padrão	Assimetria	Mediana	Q1	Q3	IQR	# Outlier inf.	Outlier inf. (%)	#Outlier sup.	Outlier sup.(%)
d_{10}	0,002	0,045	0,010	0,009	2,094	0,005	0,005	0,011	0,006	0	0	11	14,67
d_{15}	0,002	0,257	0,029	0,053	2,754	0,006	0,006	0,014	0,009	0	0	14	18,67
d_{gap}	0,008	1,008	0,056	0,196	4,728	0,011	0,008	0,0159	0,008	0	0	7	9,33
C_u	2,616	76,712	51,746	25,081	-0,461	55,268	27,070	76,712	49,642	0	0	0	0
t_{GT}	0,55	4,2	2,16	0,862	0,715	1,9	1,9	2,1	0,2	9	12	18	24
FOS	0,03	0,13	0,110	0,031	-1,449	0,13	0,1	0,13	0,03	5	6,67	0	0
i_{sys}	1	20	5,147	5,021	0,772	1	1	10	9	0	0	0	0
σ_v	0,961	105,461	24,449	32,676	1,713	5,461	3,707	27,883	24,176	0	0	10	13,33
$k_{\text{sys-}o}$	$2,13 \times 10^{-5}$	0,0226	$2,38 \times 10^{-3}$	$3,90 \times 10^{-3}$	2,888	$8,31 \times 10^{-4}$	$1,46 \times 10^{-4}$	0,00243	$2,284 \times 10^{-3}$	0	0	11	14,67

Tabela 4.7 — Dados estatísticos do parâmetro de saída considerando os solos descontínuos (*gap gradded*)

Sím	Min	Máx	Média	Desvio Padrão	Assimetria	Mediana	Q1	Q3	IQR	# Outlier inf	Outlier inf (%)	#Outlier sup.	Outliers sup (%)
k_{sys}	$1,98 \times 10^{-5}$	$3,09 \times 10^{-3}$	$3,38 \times 10^{-4}$	$5,93 \times 10^{-4}$	3,074	$1,27 \times 10^{-4}$	$4,85 \times 10^{-5}$	$2,51 \times 10^{-4}$	$2,03 \times 10^{-4}$	0	0	11	14,67

De acordo com a Tabela 4.6, os valores médios dos diâmetros das partículas correspondentes a 10% e 15% do material mais fino (d_{10} e d_{15}), respectivamente 0,010 mm e 0,029 mm, indicam a presença de partículas finas nos solos mal graduados. O diâmetro da lacuna (d_{gap}) apresenta uma média de 0,056 mm. A dispersão desses dados, avaliada pelo desvio padrão (0,009 mm para d_{10} , 0,053 mm para d_{15} e 0,196 mm para d_{gap}), varia entre os parâmetros. A assimetria positiva observada (2,09 para d_{10} , 2,75 para d_{15} e 4,72 para d_{gap}) sugere uma concentração dos tamanhos de partícula em valores inferiores à média, com uma cauda alongada para valores maiores.

O coeficiente de uniformidade (C_u) apresenta uma média elevada de 51,746 e uma mediana de 27,070, o que revela uma distribuição assimétrica, corroborada pela assimetria negativa de -0,461. A ampla faixa de variação do C_u (2,62 a 76,71) indica a inclusão de solos com diferentes graus de uniformidade. A presença de uma porcentagem significativa de *outliers* superiores (24,00%) enfatiza a existência de amostras com uma grande variedade de tamanhos de partículas.

Já a espessura do geotêxtil (t_{GT}) apresenta uma faixa de variação de 0,5 mm a 4,2 mm, com uma média de 2,16 mm e uma mediana de 1,9 mm. A assimetria positiva de 0,72 sugere uma distribuição levemente inclinada para valores maiores. Observa-se uma presença considerável de *outliers* inferiores (12,00%) e superiores (18,00%), que refletem a variedade de geotêxteis utilizados.

A abertura de filtração do geotêxtil (FOS) varia entre 0,03 mm e 0,13 mm, com uma tendência para valores menores, conforme indicado pela média de 0,11 mm e pela mediana de 0,13 mm. A dispersão dos dados, com um desvio padrão de 0,03 mm, é moderada. A assimetria negativa de -1,45 sugere uma distribuição com uma concentração de valores maiores e uma cauda alongada para valores menores. A presença de *outliers* inferiores (6,67%) é notável.

Igualmente aos outros modelos, o gradiente hidráulico (i) varia de 1 a 20, com uma média de 5,15 e uma mediana de 1. A dispersão dos dados é alta, com um desvio padrão de 5,02. A assimetria positiva de 0,77 indica uma distribuição com uma cauda longa para valores mais altos. Não se observam *outliers* para este parâmetro.

A tensão vertical (σ_v) aplicada nos testes varia consideravelmente, de 0,96 kPa a 105,46 kPa. A média de 24,45 kPa é significativamente maior que a mediana de 5,46 kPa, o que indica uma forte influência de valores extremos e uma distribuição assimétrica à direita, com uma assimetria de 1,713. A alta dispersão, evidenciada pelo desvio padrão de 32,68 kPa e pelo IQR de 24,176 kPa, confirma a heterogeneidade das condições de confinamento aplicadas. A presença de *outliers* superiores (13,33%) destaca a ocorrência de testes sob tensões verticais mais elevadas.

Por outro lado, a permeabilidade inicial do sistema solo/geotêxtil (k_{sys-o}) exibe uma ampla faixa de variação, de $2,13 \times 10^{-5}$ cm/s a 0,0226 cm/s, com uma concentração de valores inferiores à média de $3,903 \times 10^{-3}$ cm/s e à mediana de $8,31 \times 10^{-4}$ cm/s. A alta dispersão, com um desvio padrão de $3,903 \times 10^{-3}$ cm/s, e a assimetria muito alta e positiva de 2,888 indicam a influência de valores extremos. A presença de *outliers* superiores (14,67%) enfatiza a grande variabilidade na permeabilidade inicial dos sistemas testados.

Finalmente, o coeficiente de permeabilidade final do sistema solo-geotêxtil (k_{sys}), conforme a Tabela 4.7, apresenta uma faixa de variação de $1,98 \times 10^{-5}$ cm/s a $3,09 \times 10^{-3}$ cm/s, com uma tendência para valores baixos, evidenciada pela média de $3,38 \times 10^{-4}$ cm/s e pela mediana de $1,27 \times 10^{-4}$ cm/s. A dispersão dos dados é alta, com um desvio padrão de $5,93 \times 10^{-4}$ cm/s. A assimetria positiva de 3,074 sugere uma distribuição com uma cauda longa para valores mais altos. A presença de *outliers* superiores (14,67%) indica alguns casos com permeabilidades finais significativamente maiores que a maioria.

4.1.2 CORRELAÇÃO DE DADOS - PEARSON (ρ_r)

O coeficiente de Pearson é uma ferramenta estatística comumente utilizada para estabelecer ou compreender correlações lineares monotônicas estatisticamente significativas entre duas variáveis. De acordo com Schober et al. (2018), a matriz define se essa relação é diretamente proporcional (correlação direta, valor positivo) ou inversamente proporcional (correlação inversa, valor negativo). Neste estudo, o coeficiente de Pearson será empregado para estabelecer a correlação linear entre os parâmetros de entrada e os resultados da permeabilidade final do sistema solo-geotêxtil (k_{sys-o}).

Contudo, é importante destacar que o coeficiente de Pearson mede apenas relações lineares entre

variáveis. Em casos onde a associação é não linear, esse coeficiente pode não refletir adequadamente a verdadeira relação entre os parâmetros. Além disso, a existência de correlação não implica, necessariamente, em uma relação de causa e efeito (causalidade) entre as variáveis analisadas.

Dessa forma, a análise estatística deve ser complementada com a compreensão do comportamento físico do sistema, por meio de ensaios laboratoriais, que possibilitam avaliar os mecanismos envolvidos. No caso da permeabilidade do sistema solo-geotêxtil (k_{sys-o}), esta depende intrinsecamente de fatores como o FOS (que caracteriza o tipo de geotêxtil, seja não tecido – NW – ou tecido – W), da espessura do geotêxtil (t_{GT}) – que, por sua vez, é influenciada pelo tipo de geotêxtil e pelo próprio FOS – e das tensões confinantes, as quais afetam tanto a espessura quanto o comportamento do geotêxtil. Esses fatores mostram que a interpretação estatística isolada não é suficiente para capturar a complexidade do comportamento hidráulico do sistema, sendo indispensável a avaliação experimental.

Apesar da existência de diferentes faixas de classificação de correlação de Pearson, este estudo adotará a faixa apresentada na Tabela 3.6 , na qual valores próximos de zero indicam uma correlação fraca, e valores próximos de um indicam uma correlação forte.

A Figura 4.2 e a Figura 4.3 ilustram a correlação entre 16 parâmetros e a permeabilidade final do sistema solo-geotêxtil, com base nos dados compilados da literatura. Essa análise preliminar auxilia na definição dos parâmetros que serão incorporados aos diferentes modelos a serem desenvolvidos, cuja classificação das faixas de correlação para cada um dos 16 parâmetros de entrada é apresentada na

Tabela 4.8.

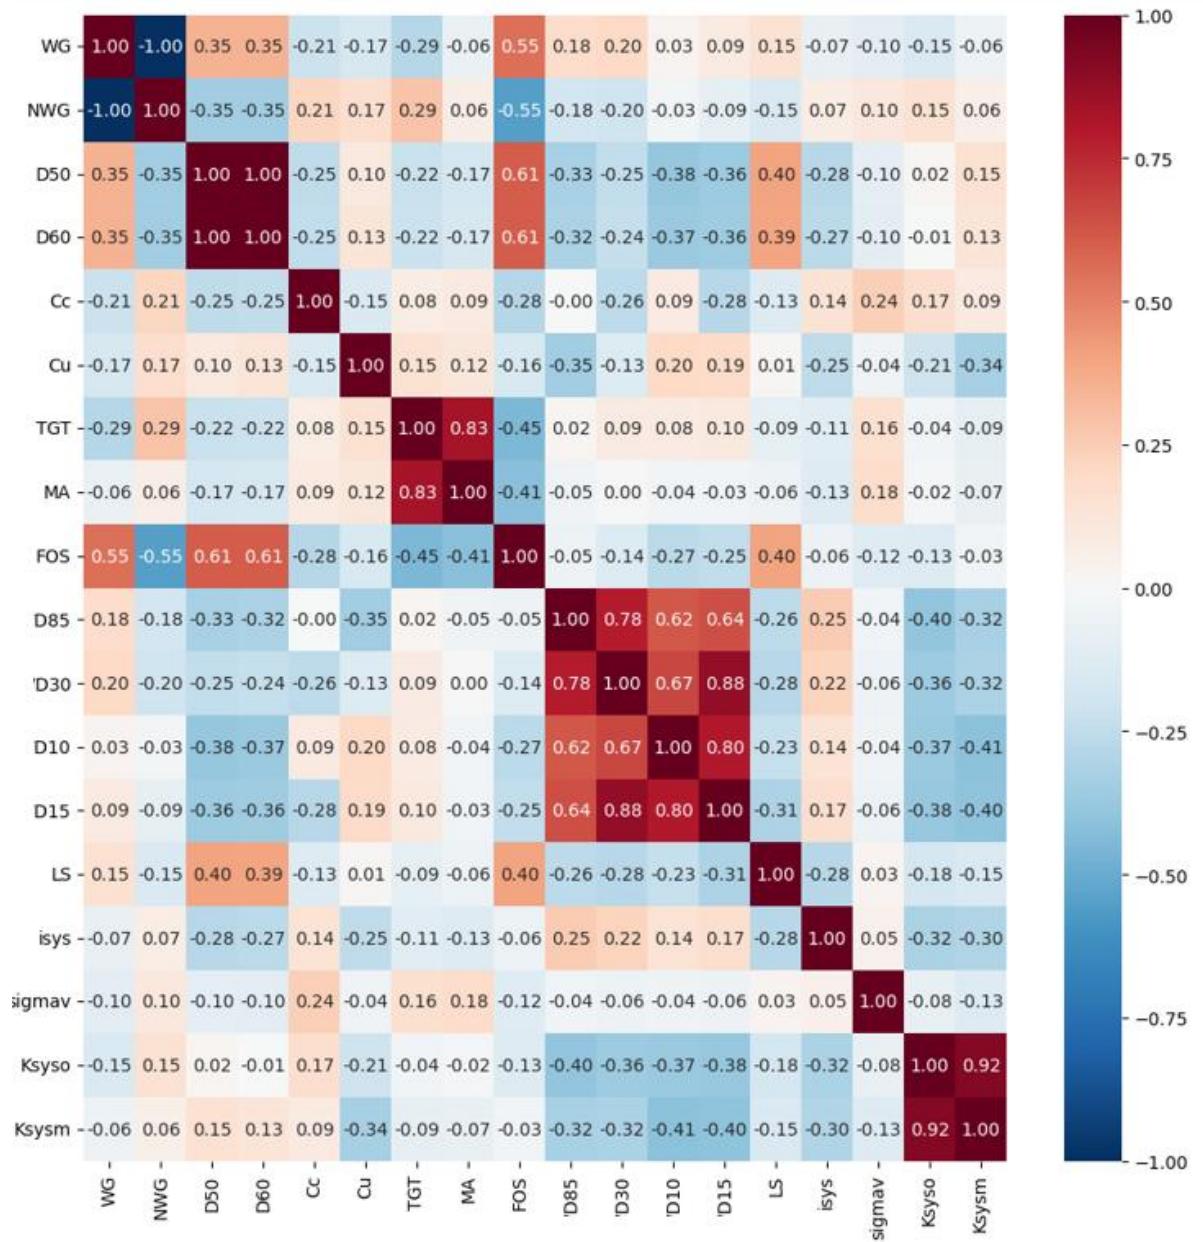


Figura 4.2– Matriz de Coeficiente de correlação de Pearson considerando 16 parâmetros de entrada

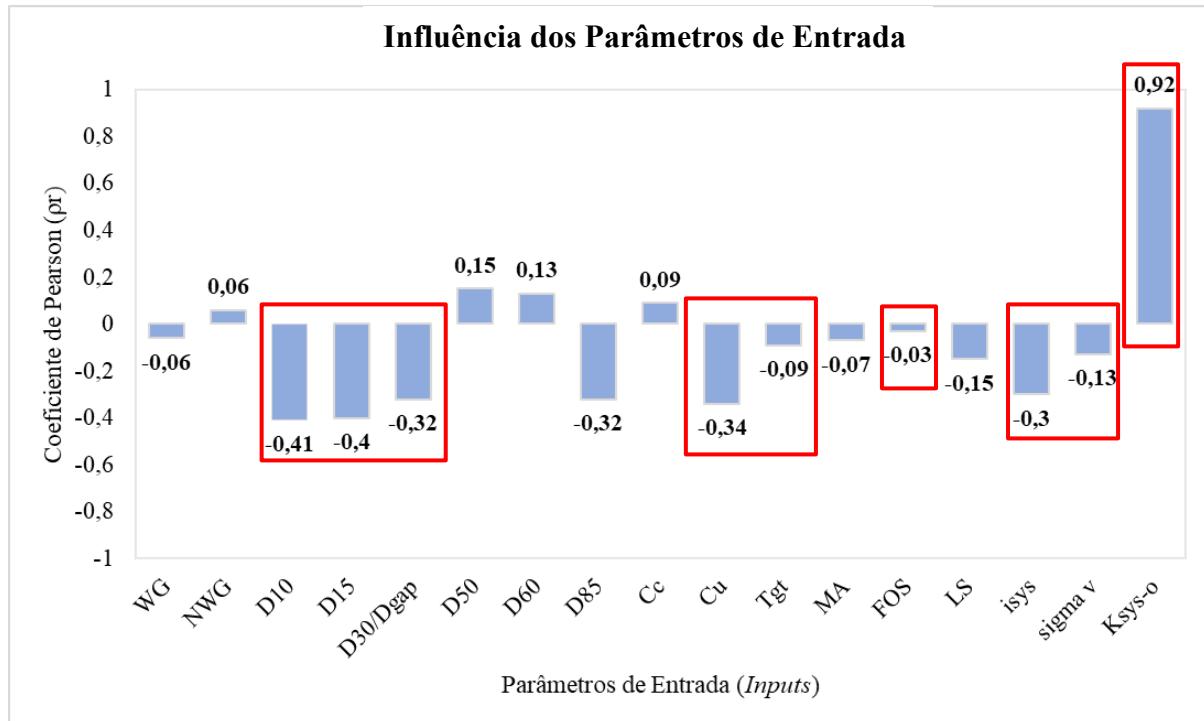


Figura 4.3: Influência dos parâmetros de entrada segundo o coeficiente de Pearson (ρ_r)

Tabela 4.8: Faixas de Correlação de Pearson para os 16 parâmetros de entrada em relação a permeabilidade final do sistema k_{sys}

Faixas de Correlação	Interpretação	Parâmetros
0.00 – 0.10	Correlação Inexistente	Tipo de Geotêxtil, C _c , tGT, M _A , FOS
0.10 – 0.39	Correlação Fraca	d _{gap} , d ₃₀ , d ₅₀ , d ₆₀ , d ₈₅ , C _u , L _S , i _{sys} , σ_v
0.40 – 0.69	Correlação Moderada	d ₁₀ , d ₁₅
0.70 – 0.89	Correlação Forte	-
0.90 – 1.00	Correlação Muito Forte	k _{sys-o}

Baseados nos resultados apresentados na Figura 4.3 e na Tabela 4.8, observa-se que tipo de geotêxtil tem uma correlação muito baixa com a permeabilidade final do sistema (ρ_r de -0,06 para WG e ρ_r de 0,06 para NWG). Em relação às propriedades do solo C_c, apresenta uma correlação inexistente com $\rho_r=0,09$. Já os parâmetros de d₃₀, d_{gap}, d₅₀, d₆₀, d₈₅ e C_u apresentam uma correlação fraca (com $\rho_r=0,32$, $\rho_r=0,15$, $\rho_r=0,13$, $\rho_r=-0,34$, respectivamente) e os parâmetros d₁₀ e d₁₅ apresentam uma relação moderada (com $\rho_r=-0,41$, $\rho_r=-0,40$, respectivamente).

Por outro lado, a matriz de correlação apresentada Figura 4.2 revela uma forte associação entre os diferentes diâmetros característicos das partículas do solo, indicando que os diâmetros se influenciam mutuamente. Observa-se, por exemplo, que há correlação muito forte entre d₃₀ e d₅₀ ($\rho_r = 0,78$), d₃₀ e d₆₀ ($\rho_r = 0,67$), bem como entre d₁₅ e d₃₀ ($\rho_r = 0,88$) e d₁₀ e d₁₅ ($\rho_r = 0,80$). Esses valores elevados de correlação sugerem que, à medida que o valor de um diâmetro aumenta, os demais também tendem a aumentar, refletindo uma progressão granulométrica consistente nas amostras analisadas.

De acordo com Palmeira et al. (2024), deve ser dada uma atenção aos diâmetros das partículas do solo que são tradicionalmente associados a diferentes aspectos do comportamento de filtros geotêxteis em solos internamente instáveis, como d₁₀ e d₁₅ e d₃₀. Este último é considerado um diâmetro de partícula do solo indicativo apropriado em critérios de retenção para solos não coesivos internamente instáveis (Lafleur et al., 1989; Lafleur, 1999; Khan et al., 2022). Isso também se aplica ao d_{gap} para solos com granulometria descontínua, onde d_{gap} é o tamanho mínimo da lacuna granulométrica (Lafleur, 1999). Assim, apesar do d₃₀ e d_{gap} terem uma correlação fraca, ela dever ser levada em conta como um parâmetro de influência.

Em relação às propriedades do geotêxtil, os parâmetros t_{GT}, M_A e FOS apresentaram uma correlação muito baixa (com $\rho_r=0,09$, $\rho_r=0,07$ e $\rho_r=-0,03$, respectivamente) com a permeabilidade final do sistema. Isso sugere que variações lineares nessas propriedades não estão fortemente associadas aos valores da permeabilidade final. Entretanto, Santos (2023), comenta que os geotêxteis não tecidos espessos com pequena abertura de filtração tendem a exibir um desempenho de filtração insatisfatório. Embora esses parâmetros apresentem baixo correlação de pearson, esses estudos indicam que o FOS influencia o resultado da permeabilidade tanto quanto a espessura do geotêxtil (Gardoni, 2000).

Os parâmetros relacionados às condições do ensaio, como L_S, i_{sys}, σ_v , presentaram uma correlação fraca com a permeabilidade final ($\rho_r=-0,15$, $\rho_r=-0,30$, $\rho_r=-0,13$, respectivamente). No entanto, autores como Gardoni (2000) e Melo (2018) já comprovaram a influência do confinamento no comportamento filtrante de geotêxteis não tecidos.

A permeabilidade inicial do sistema (k_{sys-0}) demonstra uma correlação positiva muito forte ($\rho_r = 0.92$) com a permeabilidade final, o que indica que é o fator mais linearmente relacionado ao

desempenho final do sistema.

Na Figura 4.4 e na Figura 4.5 apresentam-se a correlação entre os 10 parâmetros selecionados a partir da análise prévia e a permeabilidade final do sistema solo-geotêxtil. Essa análise preliminar foi fundamental para a redução dos parâmetros de entrada que serão incorporados aos diferentes modelos a serem desenvolvidos.

Destaca-se que, embora o parâmetro FOS apresente correlação muito baixa com a variável de interesse, ele será mantido na modelagem em razão de sua relevância para o comportamento filtrante do geotêxtil, conforme evidenciado em estudos como o de Gardoni (2000).

Assim, reforça-se a importância de complementar a análise estatística preliminar com o entendimento do comportamento físico dos materiais, dada a complexidade envolvida na interação solo-geotêxtil e as limitações da análise estatística isolada para capturar todos os fatores relevantes.

A classificação das faixas de correlação para cada um desses 10 parâmetros é detalhada na Tabela 4.9.

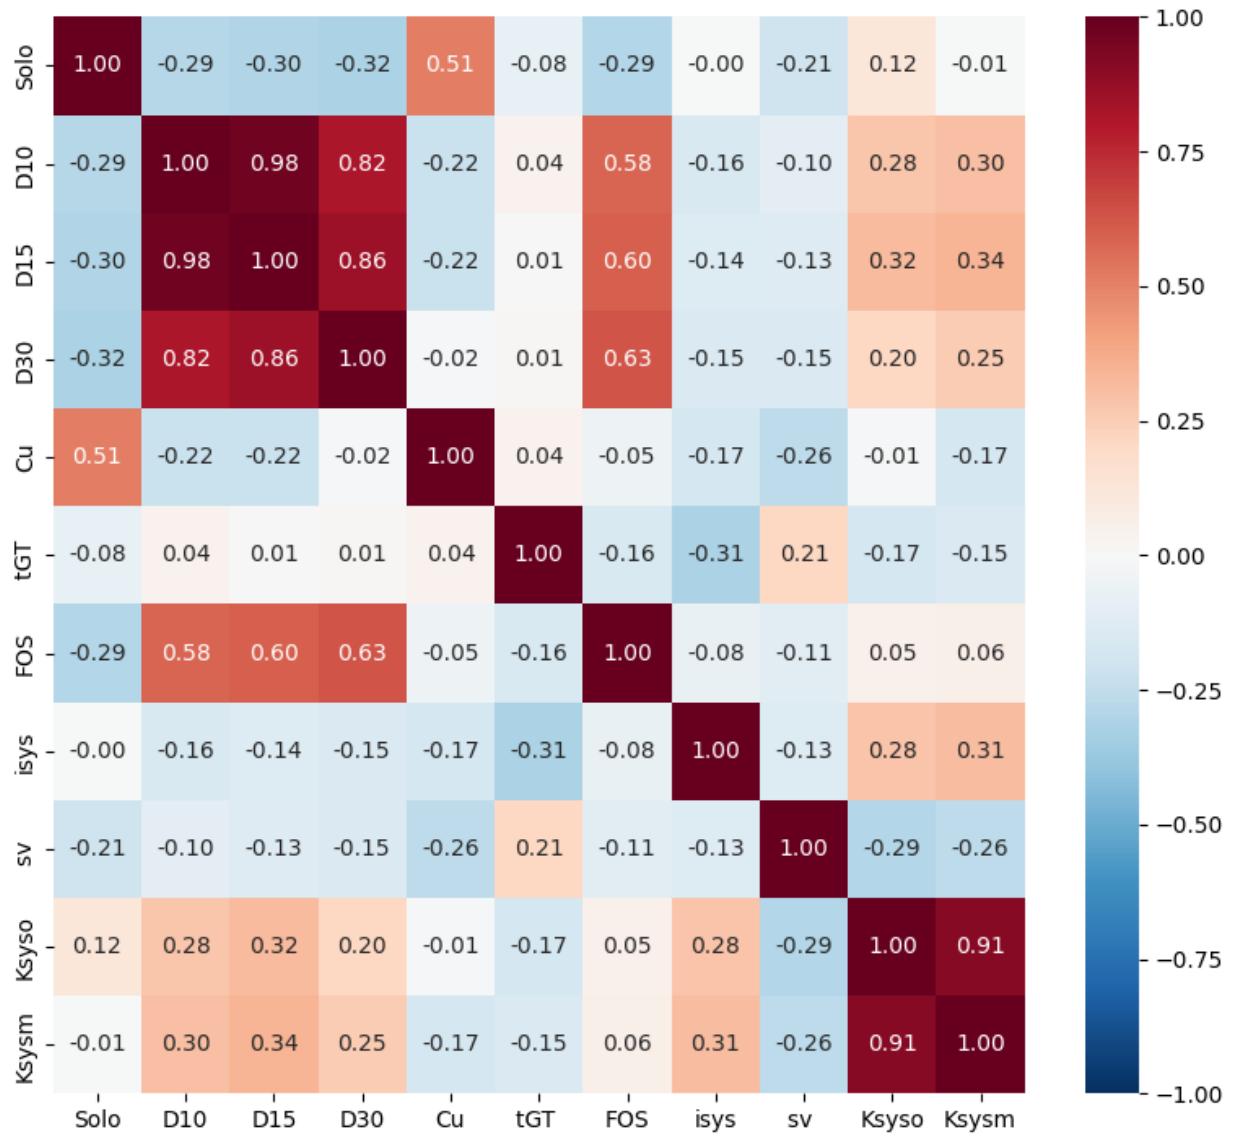


Figura 4.4—Matriz do Coeficiente de correlação de Pearson dos fatores de influência e dos resultados laboratoriais de permeabilidade do sistema solo/geotêxtil do Modelo 1

Influência dos Parâmetros- Todos os solos

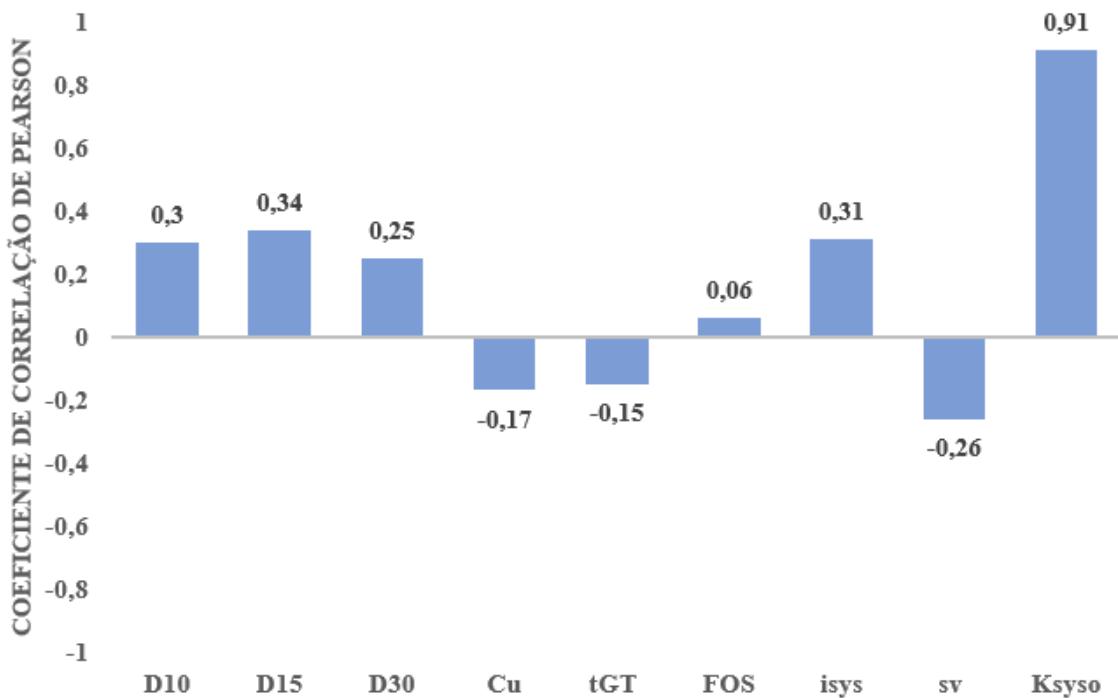


Figura 4.5: Influência dos parâmetros de entrada segundo o coeficiente de Pearson (ρ_r) para o Modelo 1

Tabela 4.9: Faixas de Correlação de Pearson para os 10 parâmetros de entrada em relação a permeabilidade final do sistema k_{sys} (Modelo 1)

Faixas de Correlação	Interpretação	Parâmetros
0.00 – 0.10	Correlação Inexistente	FOS
0.10 – 0.39	Correlação Fraca	$d_{10}, d_{15}, d_{30}, C_u, t_{GT}, LS, i_{sys}, \sigma_v$
0.40 – 0.69	Correlação Moderada	-
0.70 – 0.89	Correlação Forte	-
0.90 – 1.00	Correlação Muito Forte	k_{sys-o}

A influência dos parâmetros de entrada na permeabilidade final do sistema solo-geotêxtil (k_{sys}) para o Modelo 1, que engloba todos os tipos de solos analisados, foi avaliada por meio do coeficiente de correlação de Pearson (ρ_r), conforme ilustrado na Figura 4.5 e categorizado na Tabela 4.9.

A análise da Figura 4.5 revela que a permeabilidade inicial do sistema (k_{sys0}) apresenta a correlação positiva mais forte com a permeabilidade final ($\rho_r = 0.91$), o que indica que sistemas com maior permeabilidade inicial tendem a manter uma maior permeabilidade ao final do teste.

Observou-se que os diâmetros das partículas do solo (d_{10} e d_{15} e d_{30}) possuem correlações positivas fracas com k_{sys} ($\rho_r = 0.30, 0.34$ e 0.25 , respectivamente). Tal resultado sugere que solos com partículas mais finas tendem a apresentar uma permeabilidade final ligeiramente menor.

Por outro lado, o coeficiente de uniformidade do solo (C_u) ($\rho_r = -0.17$), a espessura do geotêxtil (t_{GT}) ($\rho_r = -0.15$) e a tensão vertical (σ_v) ($\rho_r = -0.26$) demonstraram correlações negativas fracas com k_{sys} . Essa tendência indica que valores maiores para esses parâmetros estão associados a uma permeabilidade final ligeiramente reduzida.

O gradiente hidráulico do sistema (i_{sys}) exibe uma correlação positiva fraca com k_{sys} ($\rho_r = 0.31$), o que sugere que gradientes hidráulicos mais elevados podem estar relacionados a uma permeabilidade final ligeiramente maior.

Notavelmente, o tamanho de abertura de filtração do geotêxtil (FOS) demonstra uma correlação positiva praticamente inexistente com k_{sys} ($\rho_r = 0.06$). Isso aponta que, para o conjunto de dados total, tal propriedade do geotêxtil não possui uma influência linear significativa na permeabilidade final do sistema. A Tabela 4.9., que categoriza a força dessas correlações, confirma que FOS apresenta uma correlação inexistente e d_{10} , d_{15} , d_{30} , C_u , t_{GT} , i_{sys} e σ_v apresentam correlações fracas. Destaca-se que a permeabilidade inicial do sistema (k_{sys0}) exibe uma correlação muito forte com a permeabilidade final.

Em suma, para o Modelo 1, que considera todos os solos em conjunto, a permeabilidade inicial do sistema emerge como o fator preditivo mais importante da permeabilidade final. As características granulométricas do solo e o gradiente hidráulico mostram uma influência positiva modesta, enquanto as propriedades do geotêxtil (com exceção do FOS) e a tensão vertical exibem uma influência negativa discreta. Por outro lado, segundo o valor de correlação de Pearson, a abertura de filtração do geotêxtil não manifesta uma relação linear expressiva com

a permeabilidade final no total dos dados analisados. Esta análise sugere que o comportamento da massa de solo e as condições iniciais do sistema podem ser mais determinantes para a permeabilidade final do que as propriedades intrínsecas do geotêxtil, quando se consideram diferentes tipos de solos em conjunto.

No caso do Modelo 2, esse modelo considera o tipo de solos com concavidade para cima. Na Figura 4.6 e na Figura 4.7 apresentam-se a correlação entre os 10 parâmetros selecionados a partir da análise prévia e a permeabilidade final do sistema solo-geotêxtil. A classificação das faixas de correlação para cada um desses 10 parâmetros é detalhada na Tabela 4.10

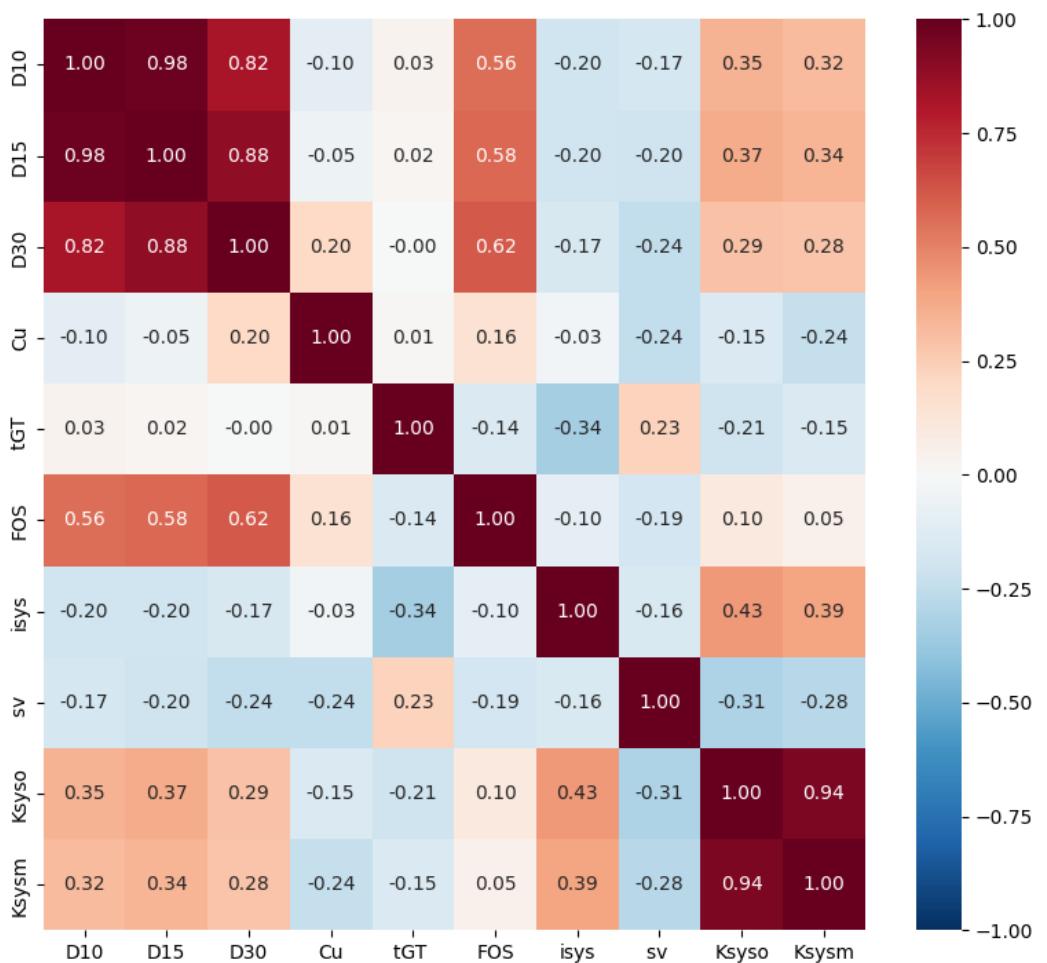


Figura 4.6– Coeficiente de correlação de Pearson dos fatores de influência e dos resultados laboratoriais de permeabilidade do sistema solo/geotêxtil do Modelo 2 – Solos com concavidade para cima

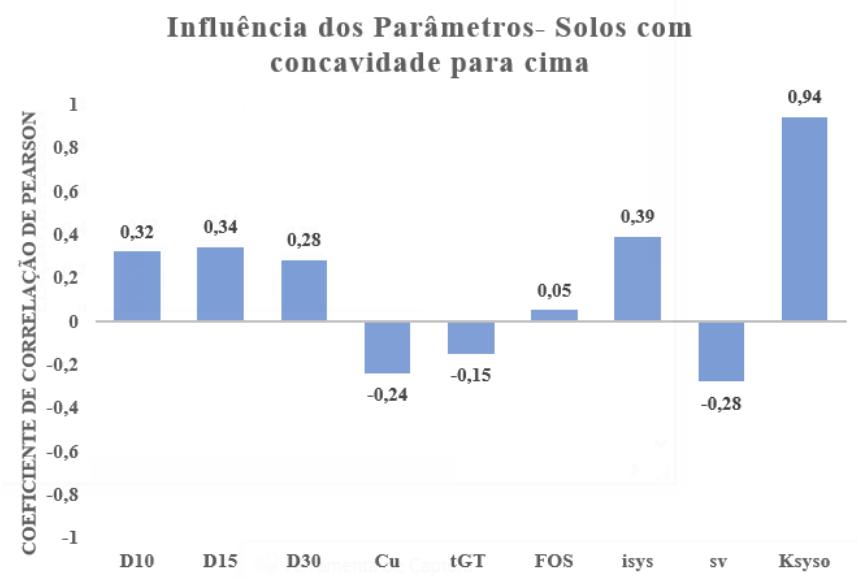


Figura 4.7: Influência dos parâmetros de entrada segundo o coeficiente de Pearson (ρ_r) para o Modelo 2

Tabela 4.10: Faixas de Correlação de Pearson para os 10 parâmetros de entrada em relação a permeabilidade final do sistema k_{sys} (Modelo 2)

Faixas de Correlação	Interpretação	Parâmetros
0.00 – 0.10	Correlação Inexistente	FOS
0.10 – 0.39	Correlação Fraca	$d_{10}, d_{15}, d_{30}, C_u, t_{GT}, L_s, i_{sys}, \sigma_v$
0.40 – 0.69	Correlação Moderada	i_{sys}
0.70 – 0.89	Correlação Forte	-
0.90 – 1.00	Correlação Muito Forte	k_{sys-o}

A influência dos parâmetros de entrada na permeabilidade final do sistema solo-geotêxtil (k_{sys}) para o Modelo 2, que considera especificamente os solos com concavidade para cima, foi avaliada por meio do coeficiente de correlação de Pearson (ρ_r), conforme apresentado na Figura 4.6 e categorizado na Tabela 4.10

A análise da Figura 4.6 revela que a permeabilidade inicial do sistema (k_{syso}) demonstra uma correlação positiva muito forte com a permeabilidade final ($\rho_r = 0.94$), o que indica uma relação ainda mais acentuada do que quando todos os tipos de solo são considerados. Isso sugere que a condição inicial de permeabilidade é um forte indicador do desempenho final para esse tipo de solo.

Os diâmetros das partículas do solo (d_{10}, d_{15} e d_{30}) exibem correlações positivas fracas com k_{sys} ($\rho_r = 0.32, 0.34$ e 0.28 , respectivamente), o que indica que solos com partículas mais finas tendem a apresentar uma permeabilidade final ligeiramente menor. A força dessas correlações é ligeiramente maior em comparação com a análise que inclui todos os solos.

O coeficiente de uniformidade do solo (C_u) ($\rho_r = -0.24$) e a tensão vertical (σ_v) ($\rho_r = -0.28$) mostram correlações negativas fracas com k_{sys} , de modo que essas são correlações um pouco mais fortes do que na análise geral. Isso sugere que, para solos com concavidade para cima, um maior coeficiente de uniformidade e uma maior tensão vertical podem estar mais associados a uma redução na permeabilidade final.

O gradiente hidráulico do sistema (i_{sys}) apresenta uma correlação positiva moderada com k_{sys} ($\rho_r = 0.39$), o que indica uma influência mais significativa do que quando todos os solos são considerados. Isso sugere que, para solos com concavidade para cima, gradientes hidráulicos mais elevados tendem a favorecer uma maior permeabilidade final.

Similarmente à análise geral, o tamanho de abertura de filtração do geotêxtil (FOS) demonstra uma correlação positiva praticamente inexistente com k_{sys} ($\rho_r = 0.05$). Isso sugere que essa propriedade do geotêxtil tem uma influência linear mínima na permeabilidade final, mesmo considerando apenas solos com concavidade para cima.

A Tabela 4.10, que categoriza a força dessas correlações para o Modelo 2, confirma que FOS apresenta uma correlação inexistente, d_{10} , d_{15} , d_{30} , C_u e σ_v apresentam correlações fracas, i_{sys} apresenta uma correlação moderada, e k_{sys-o} exibe uma correlação muito forte com a permeabilidade final do sistema.

Em resumo, ao analisar especificamente os solos com concavidade para cima, a permeabilidade inicial do sistema (k_{sys-o}) emerge como o fator mais determinante da permeabilidade final. O gradiente hidráulico (i_{sys}) também demonstra uma influência mais relevante do que na análise geral. As características granulométricas do solo e as condições de confinamento (C_u e σ_v) apresentam uma influência fraca, ligeiramente mais pronunciada do que na análise com todos os solos. A abertura de filtração do geotêxtil (FOS), no entanto, continua a não mostrar uma correlação linear significativa com a permeabilidade final para este tipo de solo. Essa análise enfatiza a importância da condição inicial do sistema e das condições de fluxo para o desempenho da permeabilidade final em solos com concavidade para cima.

Finalmente o Modelo 3 similarmente ao Modelo 2, considera a separação dos dois tipos de solos. Na Figura 4.8 e na Figura 4.9 apresentam-se a correlação entre os 10 parâmetros. A classificação das faixas de correlação para cada um desses 10 parâmetros é detalhada na Tabela 4.11.

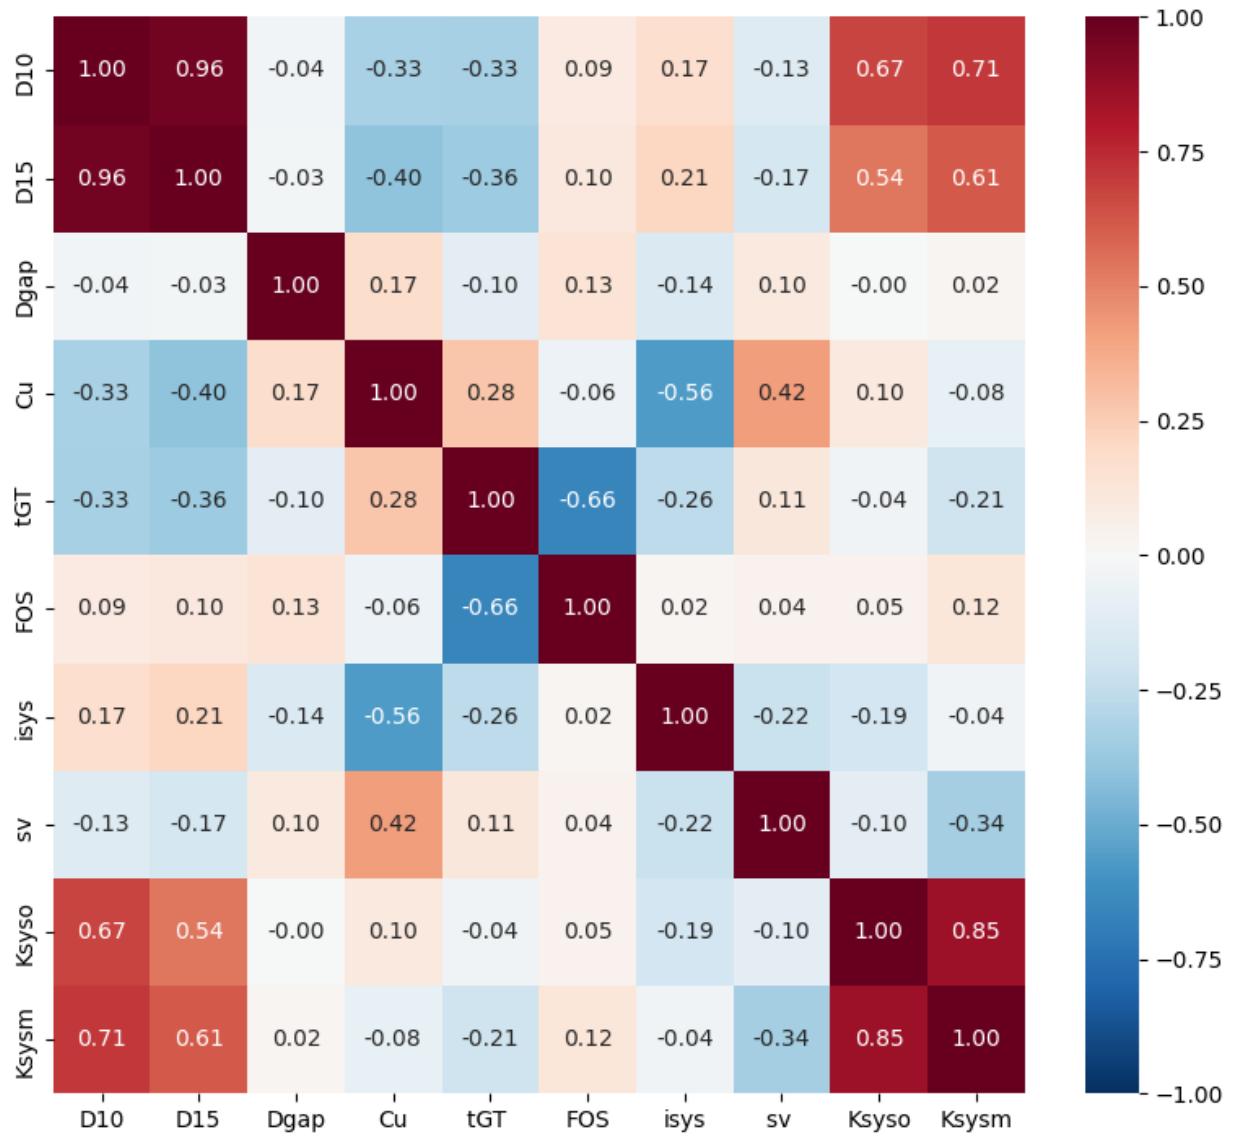


Figura 4.8– Coeficiente de correlação de Pearson dos fatores de influência e dos resultados laboratoriais de permeabilidade do sistema solo/geotêxtil – Solos *Gap-Graded*

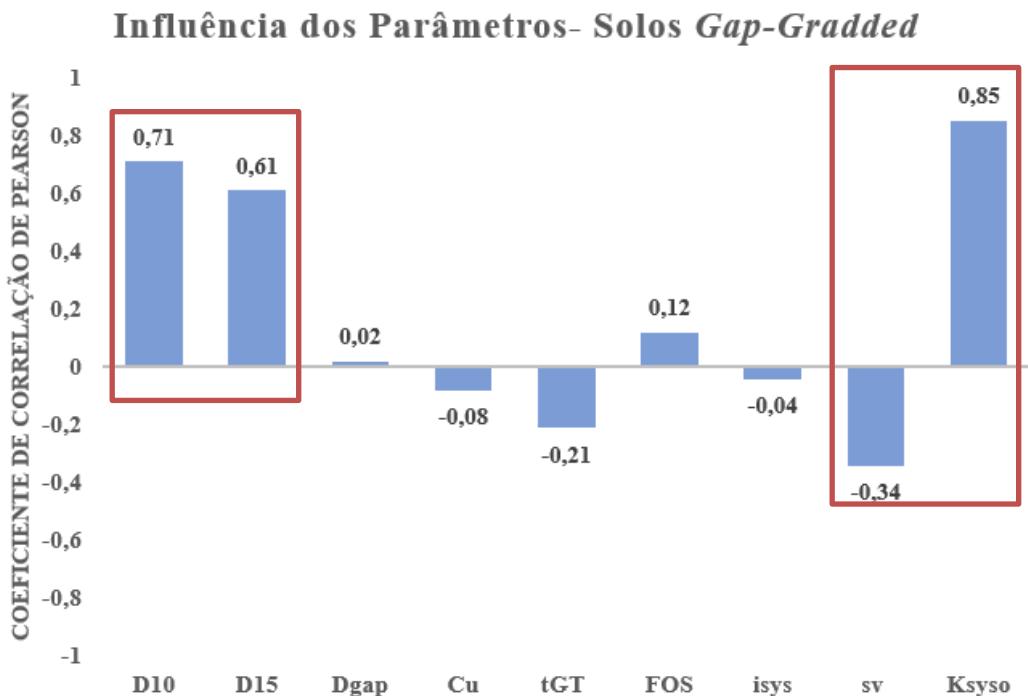


Figura 4.9: Influência dos parâmetros de entrada segundo o coeficiente de Pearson (ρ_r) para o Modelo 3

Tabela 4.11: Faixas de Correlação de Pearson para os 9 parâmetros de entrada em relação a permeabilidade final do sistema k_{sys} (Modelo 3)

Faixas de Correlação	Interpretação	Parâmetros
0.00 – 0.10	Correlação Inexistente	d_{gap}, C_u, i_{sys}
0.10 – 0.39	Correlação Fraca	t_{GT}, FOS, σ_v
0.40 – 0.69	Correlação Moderada	d_{15}
0.70 – 0.89	Correlação Forte	d_{10}
0.90 – 1.00	Correlação Muito Forte	k_{sys-o}

A influência dos parâmetros de entrada na permeabilidade final do sistema solo-geotêxtil (k_{sys}) para o Modelo 3, que considera especificamente os solos com granulometria descontínua (*gap-graded*), foi avaliada em função do coeficiente de correlação de Pearson (ρ_r), conforme apresentado na Figura 4.8 e categorizado na Tabela 4.11

A análise da Figura 4.8 revela que a permeabilidade inicial do sistema (k_{sys-o}) demonstra uma correlação positiva e muito forte com a permeabilidade final ($\rho_r = 0.85$), mantendo-se como um dos principais fatores de influência. No entanto, para esse tipo de solo, as características

granulométricas da fração fina ganham maior relevância. O diâmetro das partículas correspondente a 10% do material mais fino (d_{10}) apresenta uma forte correlação positiva com k_{sys} ($\rho_r = 0,71$), o que indica que, em solos *gap-graded*, um menor d_{10} está significativamente associado a uma menor permeabilidade final. O diâmetro das partículas correspondente a 15% do material mais fino (d_{15}) também exibe uma correlação positiva moderada à forte com k_{sys} ($\rho_r = 0.61$).

Em contraste, o tamanho da lacuna granulométrica (d_{gap}) ($\rho_r = 0,02$) e o gradiente hidráulico do sistema (i_{sys}) ($\rho_r = -0.04$) mostram correlações lineares praticamente inexistentes com a permeabilidade final.

A espessura do geotêxtil (t_{GT}) ($\rho_r = -0.21$) e a tensão vertical (σ_v) ($\rho_r = -0.34$) apresentam correlações negativas fracas com k_{sys} , o que sugere uma leve tendência de que valores maiores desses parâmetros estejam associados a uma menor permeabilidade final. O tamanho de abertura de filtração do geotêxtil (FOS) exibe uma correlação positiva fraca com k_{sys} ($\rho_r = 0.12$).

A Tabela 4.11, que categoriza a força dessas correlações para o Modelo 3, confirma que d_{gap} e i_{sys} apresentam correlações inexistentes, t_{GT} , FOS e σ_v apresentam correlações fracas, d_{15} apresenta uma correlação moderada, d_{10} apresenta uma correlação forte, e k_{sys-o} apresenta uma correlação muito forte com a permeabilidade final do sistema.

Em resumo, para solos com granulometria descontínua, a permeabilidade inicial do sistema (k_{sys-o}) continua sendo um fator importante. No entanto, o tamanho das partículas mais finas do solo (D_{10} e D_{15}) emerge como um preditor mais relevante da permeabilidade final do que para os outros tipos de solos analisados. As propriedades do geotêxtil e as condições de fluxo e confinamento exibem influências lineares mais fracas para este tipo de solo. Essa análise destaca a maior sensibilidade da permeabilidade final de sistemas com solos *gap-graded* às características granulométricas da fração fina do solo.

4.2 ANÁLISES DO MODELO RNA

4.2.1 ARQUITETURA RNA

A definição da arquitetura da rede neural é uma fase preliminar à fase de treinamento da rede. Portanto, com o algoritmo de otimização de hiperparâmetro OB é possível achar a arquitetura

ideal para os dados de treinamento. Assim, a definição da estrutura da rede é importante, pois estabelece o número de camadas intermediárias assim como número de neurônios que compõe cada camada. Neste trabalho, a metodologia adotada para RNA é o *Perceptron Multicamadas* (MLP), uma vez que, segundo Haykin (1999), a arquitetura para esse tipo de análise deve ter pelo menos uma camada oculta. Com relação ao número de neurônios para cada camada oculta, ele é influenciado pelos parâmetros de entrada e de saída.

Como mencionado no item 3.2, o conjunto de dados foi separado em 80% para treinamento e 20% para teste. A função de perda utilizada foi o *Mean Squared Error* (MSE), por ser o usual para modelos de regressão. O otimizador usado para treinar as redes foi um otimizador baseado em gradiente chamado AMSGrad, uma variação do otimizador Adam que propõe melhor convergência. A função de ativação empregada nas camadas ocultas foi a *Rectified Linear Unit* (*ReLU*), por ser a recomendação padrão para otimizadores baseados em gradiente, dado seu formato quase linear. Foi utilizada validação-cruzada *k-fold* com $k = 5$ e os hiperparâmetros dos modelos foram otimizados utilizando Otimização Bayesiana (OB). Essa técnica, com base em um modelo surrogado probabilístico, calcula a cada iteração qual o melhor próximo ponto da função objetivo a ser avaliado, assim performando bem em problemas em que a função objetivo é custosa. A função objetivo em questão foi a média do MSE dos 5 *folds* de validação. Os hiperparâmetros otimizados e seus intervalos estão definidos na Tabela 3.7, em que é estabelecido um espaço de busca para camadas ocultas entre de 1 a 4, com número de neurônios de 10 a 1000.

Para os conjuntos de dados utilizados, todos os modelos definiram 10.000 como o número máximo de épocas e 200 como paciência. Esses altos valores de épocas máximas foram utilizados para garantir a convergência durante o treinamento, uma vez que a implementação da parada antecipada preveniu o *overfitting* e interrompeu o treinamento muito antes do máximo de épocas estabelecido.

Com relação aos parâmetros, o tipo de solo foi considerado como uma variável nominal e os parâmetros que apresentam menor influência, observada na matriz de correlação inicial (Tabela 4.8) foram desconsiderados. Isso resultou em um total de dez parâmetros de entrada para o modelo 1, e 9 parâmetros de entrada para o modelo 2 e 3.

Ao realizar a validação cruzada *k-fold* com parada antecipada, cada dobra terá seu treinamento interrompido em um número diferente de épocas. Portanto, após realizar a otimização de hiperparâmetros, se todo o conjunto de treinamento estiver sendo usado e não houver um conjunto de validação separado, não é intuitivo em quantas épocas o treinamento deve ser interrompido. Motivado por esse problema, todos os modelos desenvolvidos neste trabalho atuam como um *ensemble* de cinco modelos, utilizando os conjuntos de treinamento e validação de cada dobra da validação cruzada.

Assim, o treinamento é interrompido com base em cada conjunto de validação, e a inferência é realizada calculando a média das previsões fornecidas por cada modelo. A partir disso, foram obtidos os seguintes modelos de treinamento RNA apresentados na Tabela 4.12

Tabela 4.12: Arquitetura Ótima para cada modelo de treinamento de RNA

Modelo	Tipo de Solo	Nº. Inputs	Camadas Ocultas	Neurônios na Camada 1	Neurônios na Camada 2	Neurônios na Camada 3	Nº. Output
1	Solos com concavidade para cima e solos descontínuos	9	3	554	136	186	1
2	Solos com concavidade para cima	9	3	890	850	209	1
3	Solos descontínuos	14	2	557	835	-	1

Notas: CC: solos com concavidade para cima., CG = solos *grap graded* ou solos descontínuos

4.2.2 FASE DE TREINAMENTO/TESTE E AVALIAÇÃO DO MODELO RNA

As fases de treinamento e teste foram realizadas para cada arquitetura definida na Tabela 4.12, então, foi utilizada uma distribuição aleatória de 80% e 20 % dos dados, respectivamente. Assim, a Tabela 4.13 apresenta de forma resumida a quantidade de dados utilizados para a fase de treinamento como a fase de teste para cada modelo

Tabela 4.13: Número de dados para as fases de treinamento/ teste por modelo.

Modelo	Tipo de Solo	#Dados de Treinamento	#Dados de Teste
1	Solos com concavidade para cima e solos descontínuos	179	45
2	Solos com concavidade para cima	119	30
3	Solos descontínuos	60	75

Notas: CC: solos com concavidade para cima .. CG = solos *grad graded* ou solos descontínuos

Na Figura 4.10 apresenta-se o gráfico de comparação dos valores reais e previstos para o Modelo 1 na fase de treinamento como de teste, onde a linha central no gráfico representa uma linha de regressão, que ilustra a relação entre os dois conjuntos de dados. Quanto mais próximos os pontos de dados da linha de tendência, mais precisas são as previsões do modelo.

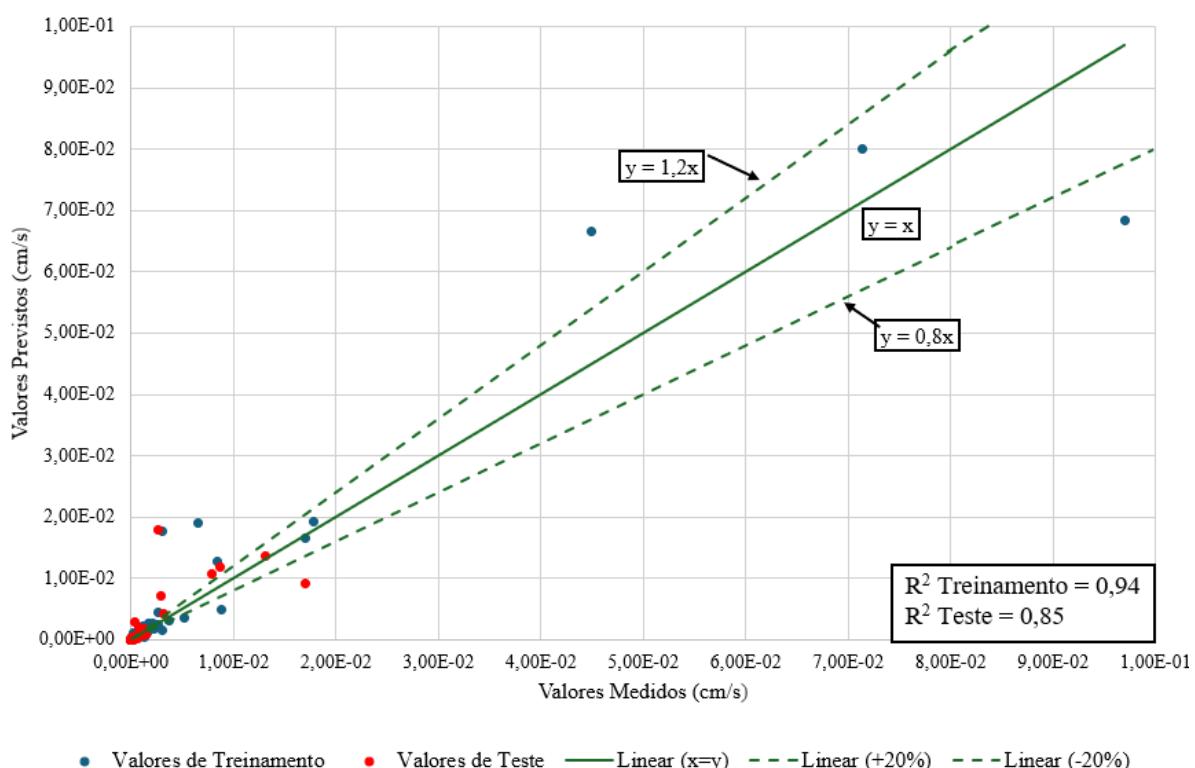


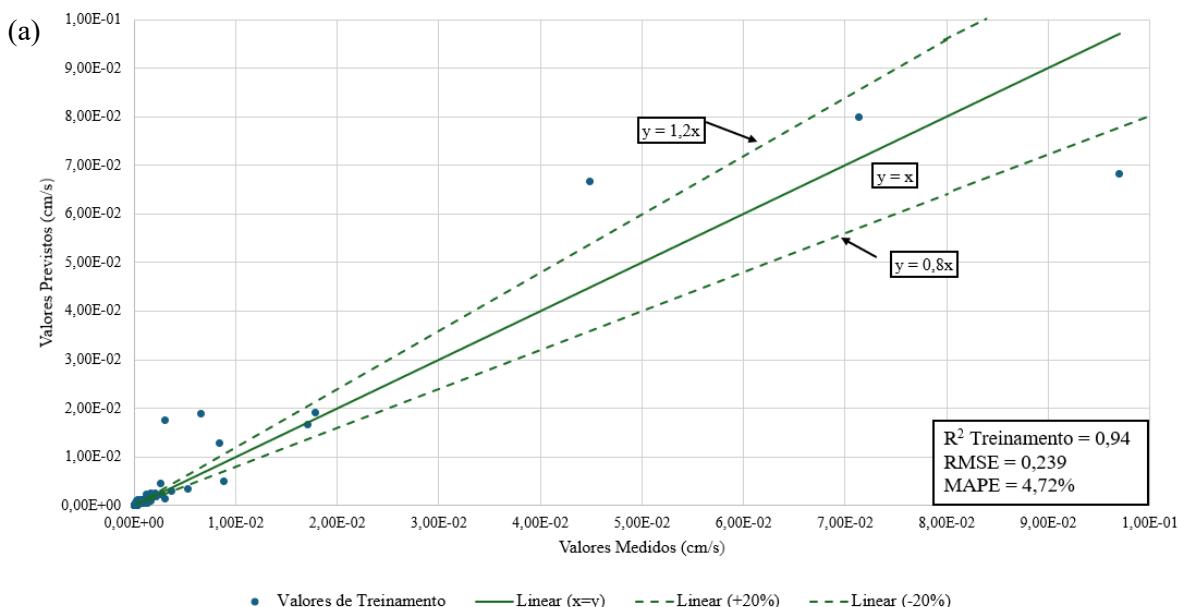
Figura 4.10: Valores Observados e Previstos pelo Modelo RNA- Para todos os tipos de solos na fase de treinamento e na fase de teste.

A Figura 4.10 exibe a relação entre os valores observados (reais) e os valores previstos pelo

modelo de rede neural. O eixo X representa os valores observados, enquanto o eixo Y representa os valores previstos. Os pontos azuis representam os dados de treinamento, e os pontos vermelhos representam os dados de teste. A linha diagonal ($x = y$) representa a relação ideal entre os valores observados e os valores previstos. Assim, quanto mais próximos os pontos estiverem da linha diagonal ($y = x$), melhor o desempenho do modelo. Por outro lado, as linhas tracejadas (+/- 20%) apresentam um intervalo de 20% em torno da linha de regressão, oferecendo uma referência visual para avaliar a acurácia das previsões.

Com relação ao coeficiente de determinação (R^2) em cada fase, obteve-se $R^2=0,94$ na fase de treinamento, o que indica que o modelo explica 94% de variabilidade nos dados de treinamento. Já na fase de teste, foi obtido um $R^2= 0,85$, explicando 85% da variabilidade nos dados de teste. Com base nos valores de R^2 , tanto para os dados de treinamento quanto para os dados de teste, apresenta-se um bom ajuste do modelo com uma boa generalização para os dados não vistos. É possível notar que os valores de R^2 obtidos durante a fase de teste não exibem uma diferença significativa em comparação com aqueles obtidos na fase de treinamento, o que sugere que o modelo não está sofrendo sobreajuste (*overfitting*) (Haykin, 1999; Nunes da Silva et al., 2016).

A Figura 4.11(a) e a Figura 4.11 (b) apresentam de forma individual o desempenho da RNA, na fase de treinamento e de teste, respectivamente, para o Modelo 1.



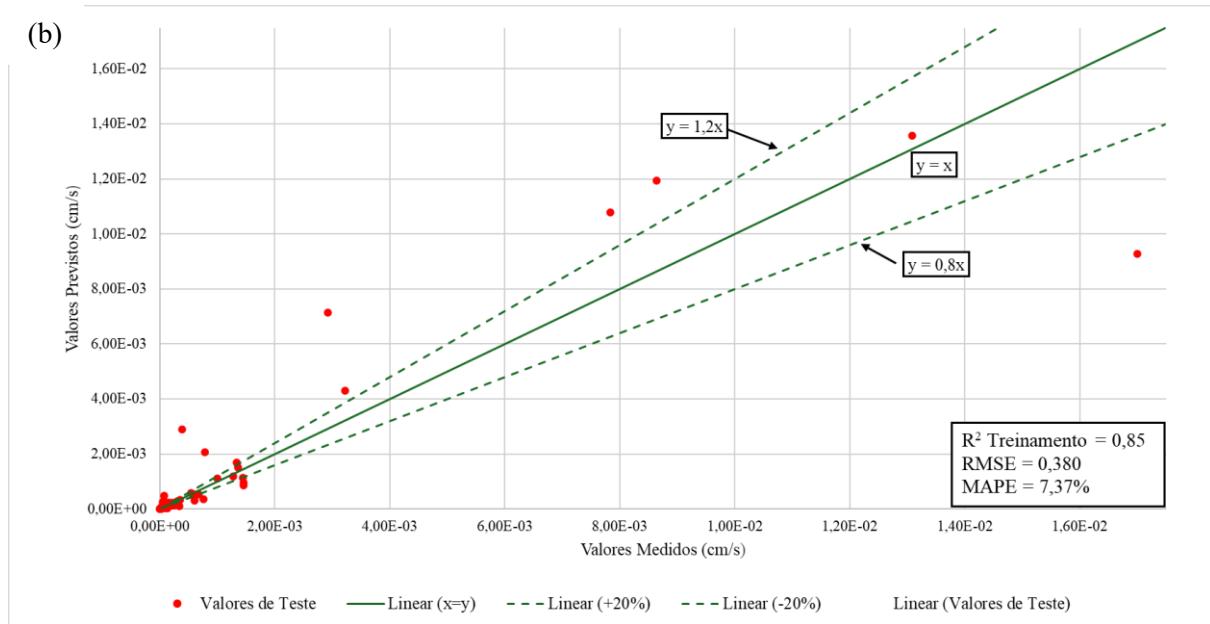


Figura 4.11: Gráfico de correlação dos valores reais e previstos da permeabilidade final do sistema (k_{sys-o}) em RNA com modelo de 3 camadas ocultas e 10 neurônios de entrada:
(a) Fase de treinamento e (b) Fase de teste.

A Tabela 4.14 apresenta um resumo das métricas obtidas na fase de treinamento e teste para o Modelo 1

Tabela 4.14: Métricas de avaliação de regressão do modelo preditivos de k_{sys} do conjunto de Modelo 1

Métricas de Desempenho	Fase de Treinamento	Fase de teste
R²	0,94	0,85
RMSE	0,234	0,380
MAPE%	4,72	7,43

Conforme as informações observadas na Figura 4.11 e Tabela 4.14, os gráficos de correlação e das métricas de desempenho revelam que o modelo de RNA com 3 camadas ocultas e 10 neurônios de entrada demonstra um bom ajuste aos dados de treinamento, com alta correlação entre os valores reais e previstos (R^2 de 0,94, RMSE de 0,239 e MAPE de 4,72%). Ao ser avaliado em dados não vistos na fase de teste, o modelo apresenta uma capacidade razoável de generalização, embora com um desempenho ligeiramente inferior, evidenciado por uma maior dispersão dos pontos em relação à linha de igualdade e métricas ligeiramente piores (R^2 de 0,85, RMSE de 0,380 e MAPE de 7,37%). Essa pequena diferença no desempenho entre as fases sugere um leve indício de *overfitting*. No

geral, o modelo captura a tendência positiva dos dados e oferece um desempenho preditivo aceitável, cuja adequação final dependerá dos requisitos específicos da aplicação.

O Modelo 2 analisa o solo com concavidade para cima (CC), considerando um total de 149 amostras, as quais foram divididas em 119 amostras para a fase de treinamento e 30 amostras para a fase de teste. A Figura 4.12 exibe a relação entre os valores observados (reais) e os valores previstos pelo modelo 2 de rede neural nas duas fases.

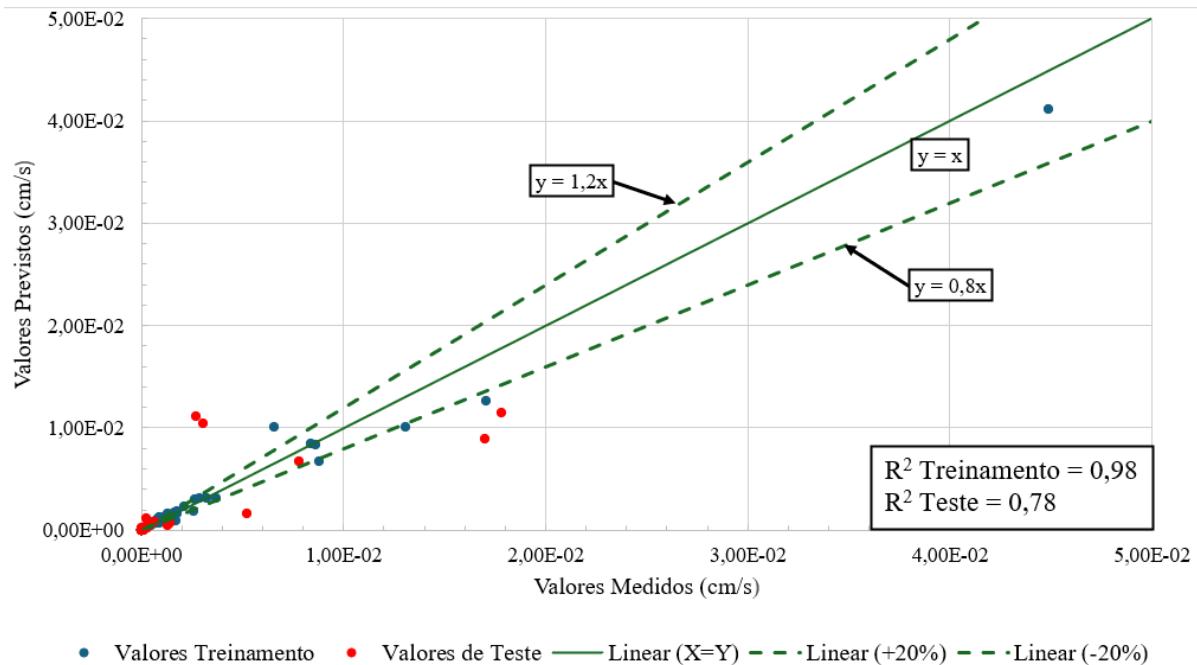


Figura 4.12: Comparaçao entre Valores Observados e Previstos pelo Modelo RNA - Solos com concavidade para cima na fase de treinamento e na fase de teste

A Figura 4.13(a) e Figura 4.13(b) apresentam de forma individual o desempenho da RNA, na fase de treinamento e de teste respectivamente, para o Modelo 2.

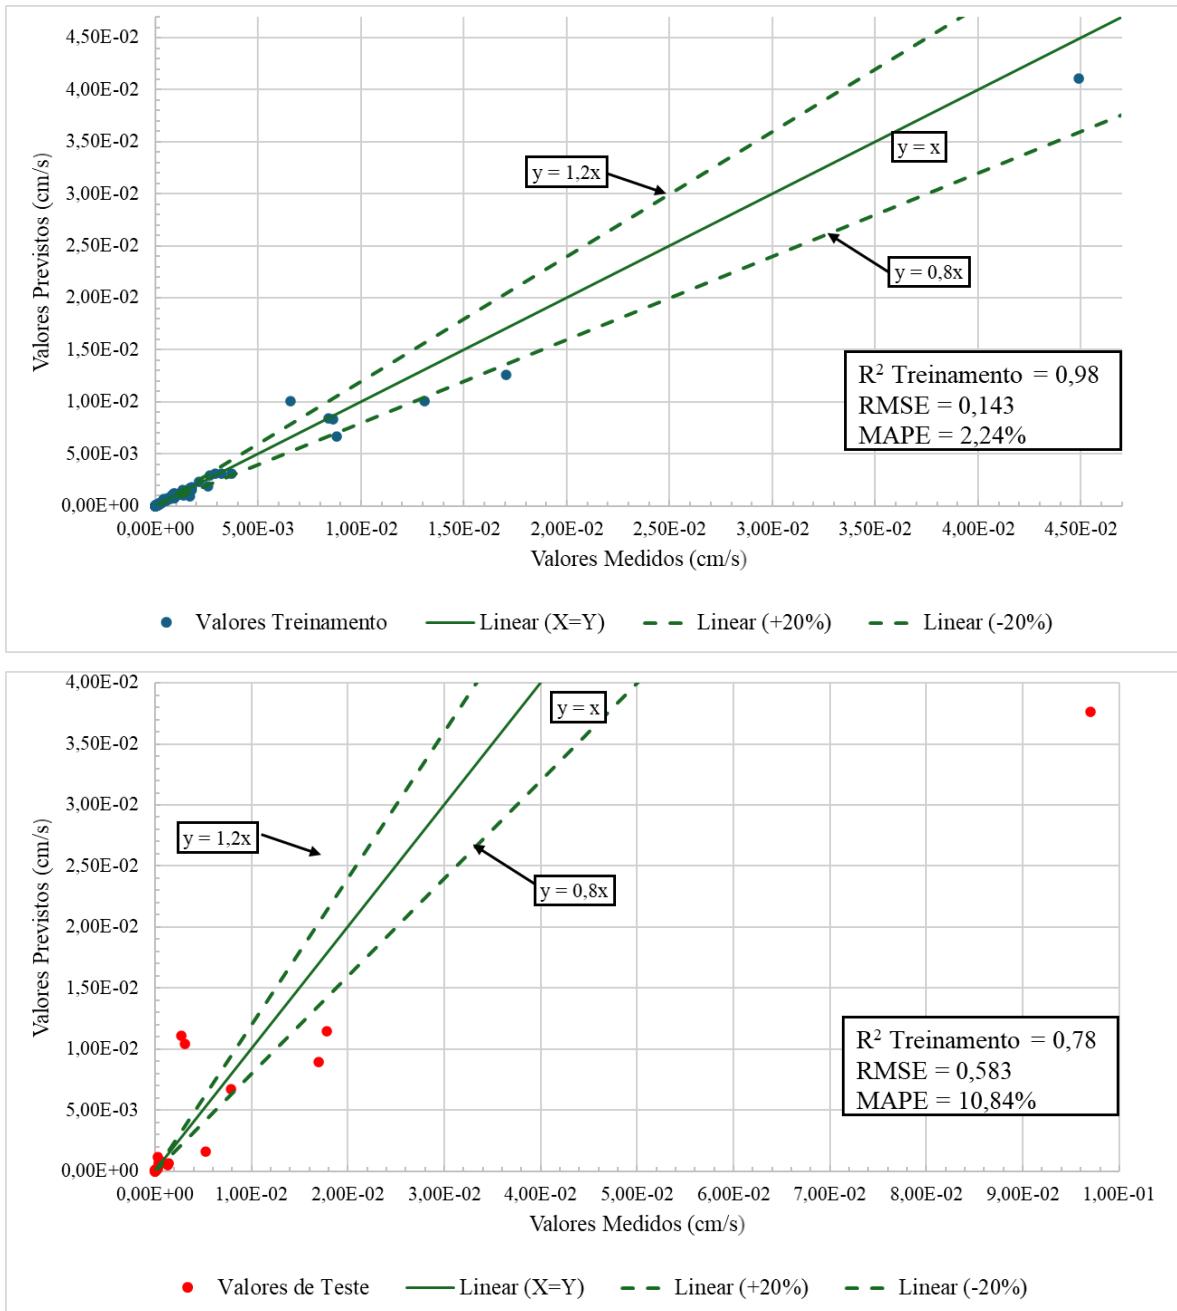


Figura 4.13: Gráfico de correlação dos valores reais e previstos da permeabilidade final do sistema (k_{sys}) em RNA com Modelo 2 de 3 camadas ocultas e 9 neurônios de entrada:
(a) Fase de treinamento e (b) Fase de teste.

A

Tabela 4.15 apresenta um resumo das métricas obtidas na fase de treinamento e teste para o Modelo 2.

Tabela 4.15: Métricas de avaliação de regressão do modelo preditivos de k_{sys} do conjunto de Modelo 2

Métricas de Desempenho	Fase de Treinamento	Fase de teste
R ²	0,98	0,78
RMSE	0,143	0,583
MAPE%	2,24	10,84

O Modelo 2 alcançou um ajuste ótimo aos dados de treinamento, conforme evidenciado por um coeficiente de determinação muito alto (R^2 de 0,98) e erros notavelmente baixos (RMSE de 0,143 e MAPE% de 2,24%), o que demonstra um excelente aprendizado dos padrões presentes nesses dados. Ao ser avaliado em dados não vistos na fase de teste, o modelo ainda apresenta uma capacidade razoável de explicar a variabilidade (R^2 de 0,78), embora com um aumento nos erros (RMSE para 0,583 e MAPE% para 10,84%). Essa diferença nas métricas, entre as fases de treinamento e teste, pode indicar uma oportunidade para otimizar a capacidade de generalização do modelo para dados futuros.

Já o Modelo 3 analisa os solos descontínuos, considerando um total de 75 amostras, divididas em 60 e 15 amostras, para a fase de treinamento e teste, respectivamente. A Figura 4.14 apresenta a comparação entre os valores observados e previstos para o modelo 3, tanto para a fase de treinamento como de teste.

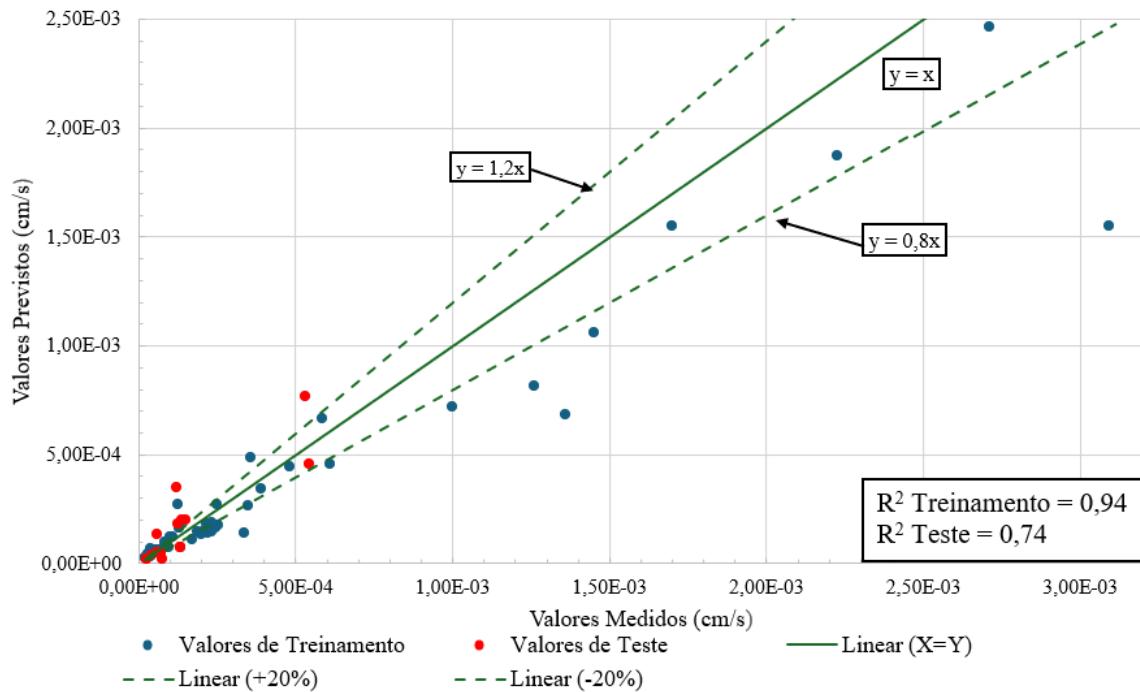
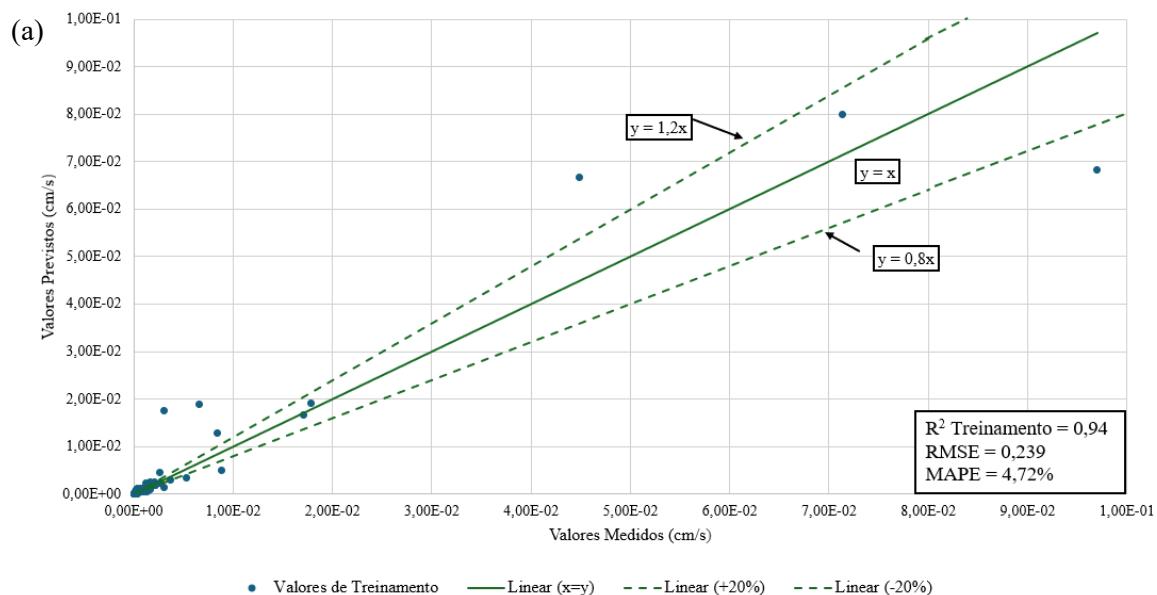


Figura 4.14: Comparação entre Valores Observados e Previstos pelo Modelo RNA - Solos descontínuos na fase de treinamento e na fase de teste.

A Figura 4.15(a) e a Figura 4.15(b) apresentam de forma individual o desempenho da RNA, na fase de treinamento e de teste, respectivamente, para o Modelo 3.



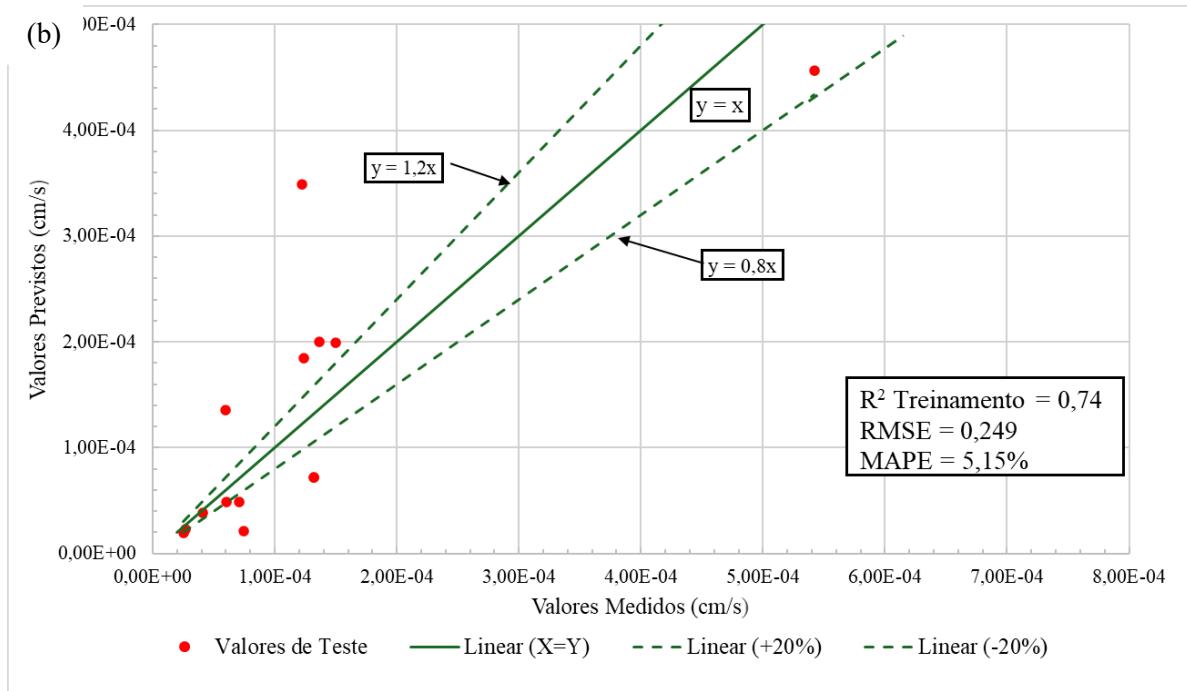


Figura 4.15: Gráfico de correlação dos valores reais e previstos da permeabilidade final (k_{sys}) em RNA com Modelo de 3 camadas ocultas e 9 neurônios de entrada:
(a) Fase de treinamento e (b) Fase de teste.

A Tabela 4.16 apresenta um resumo das métricas obtidas na fase de treinamento e teste para o Modelo 3

Tabela 4.16: Métricas de avaliação de regressão do modelo preditivo de k_{sys} do conjunto de Modelo 3

Métricas de Desempenho	Fase de Treinamento	Fase de teste
R²	0,94	0,74
RMSE	0,142	0,249
MAPE%	3,24	5,15

Os resultados de desempenho do Modelo 3 revelam um bom ajuste aos dados de treinamento, com um elevado coeficiente de determinação (R^2 de 0,94) e erros relativamente baixos (RMSE de 0,142 e MAPE% de 3,24%). Ao ser avaliado em dados não vistos na fase de teste, o modelo demonstra uma capacidade de generalização razoável, com uma pequena redução no R^2 para 0,74 e um aumento moderado nos erros (RMSE para 0,249 e MAPE% para 5,15%). Essa menor disparidade entre as métricas de treinamento e teste, quando comparado ao Modelo 2, sugere um menor grau de *overfitting* e uma melhor capacidade de aplicar o aprendizado a novos dados.

Em termos gerais, o Modelo 3 apresenta um desempenho sólido, e sua adequação para a aplicação dependerá da análise comparativa com outros modelos e da avaliação se as métricas de desempenho na fase de teste atendem aos requisitos específicos do problema.

As Figura 4.16 à Figura 4.18 apresentam os gráficos de Importância de Atributos por Permutação (PFI) avaliadas com $N = 30$ permutações, dos Modelos 1, 2 e 3, respectivamente. Esses gráficos permitem identificar a relevância de cada variável de entrada no desempenho de cada modelo. Por meio da avaliação do aumento da média do Erro Quadrático Médio (MSE), resultante da permutação aleatória dos valores de cada atributo, é possível quantificar sua influência na acurácia das previsões. Atributos com maiores aumentos no MSE após a permutação são considerados mais importantes para o modelo.

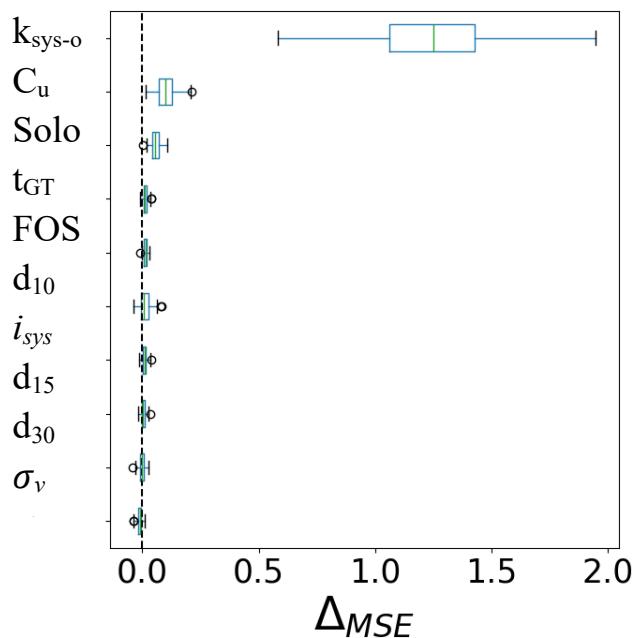


Figura 4.16: Importância dos Parâmetros de Entrada no Modelo 1 de Rede Neural (Análise de $\Delta M S E$)- Todos os solos

Analizando a Figura 4.16, a permeabilidade inicial do sistema ($k_{sys\text{-}o}$) apresenta o maior $\Delta M S E$, o que indica que é o parâmetro mais importante para o modelo e que a remoção desse parâmetro causa o maior aumento no erro de previsão.

Com relação ao coeficiente de uniformidade (C_u), esse parâmetro também tem um $\Delta M S E$

relativamente alto, o que sugere que é um parâmetro importante para o modelo. O parâmetro nominal do tipo de solo (Tecido – GW e Não Tecido- NWG) apresenta um ΔMSE moderado, indicando que tem alguma importância para o modelo. Já o resto dos parâmetros, como Espessura do Geotextil (t_{GT}), Abertura de Filtração (FOS), D_{10} , Gradiente Hidráulico (i_{sys}), D_{15} , D_{30} , Tensão Vertical (σ_v), apresentam valores baixos, próximos de zero, o que indica que têm pouca importância para o modelo e a remoção desses parâmetros não afetaria significativamente o erro de previsão.

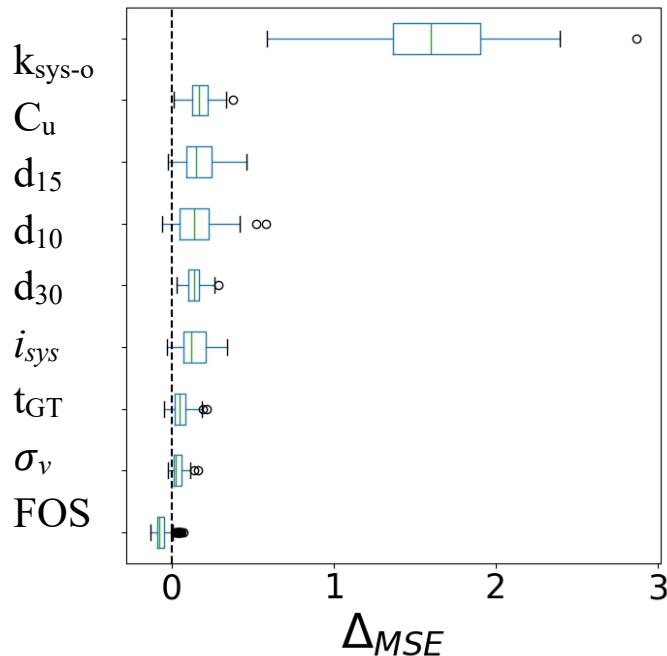


Figura 4.17: Importância dos Parâmetros de Entrada no Modelo 2 de Rede Neural (Análise de ΔMSE)- Solos com concavidade para cima (Solos CC).

Na Figura 4.17, há a análise da Importância de Atributos por Permutação (PFI) para o Modelo 2 de RNA, aplicado a solos com concavidade para cima (Solos CC). O parâmetro $k_{\text{sys-}o}$ é o fator de maior importância para o desempenho preditivo do modelo, seguido por C_u , que também demonstra uma influência significativa, embora menor. Os parâmetros d_{15} e d_{10} contribuem para a acurácia do modelo, mas em menor grau que $k_{\text{sys-}o}$ e C_u , enquanto D_{30} apresenta uma influência ainda mais reduzida. Surpreendentemente, os parâmetros i_{sys} , t_{GT} , σ_v e FOS exibem uma importância nula, com a permutação de seus valores a resultar em variações mínimas ou até mesmo negativas no erro do modelo, o que sugere sua irrelevância para as previsões em Solos CC. Essa avaliação destaca a dominância de $k_{\text{sys-}o}$ e C_u na determinação da saída do Modelo 2 para esse tipo específico de solo.

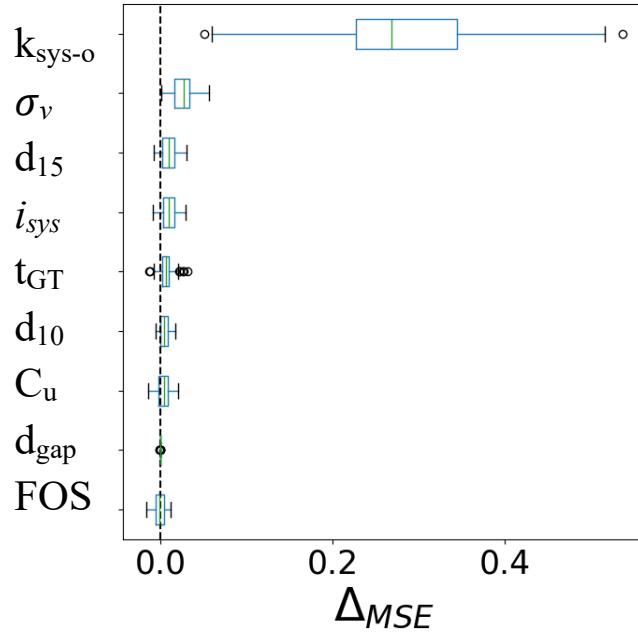


Figura 4.18: Importância dos Parâmetros de Entrada no Modelo 3 de Rede Neural (Análise de Δ_{MSE})- Solos Descontínuos (Solos GG)

A análise de Importância de Atributos por Permutação (PFI) para o Modelo 3, aplicado a solos descontínuos (Solos GG), revela que k_{sys-o} é o parâmetro de entrada mais crucial para o desempenho preditivo. A tensão vertical (σ_v) também se destaca como um atributo importante, mas de menor influência. Além disso, D_{15} e i_{sys} apresentam uma contribuição moderada para o modelo. Em contraste, os parâmetros t_{GT} , d_{10} , C_u , d_{gap} e FOS demonstram ter pouca ou nenhuma relevância para as previsões realizadas pelo Modelo 3 em Solos GG, de modo a enfatizar a dominância de k_{sys-o} e σ_v na determinação da saída para esse tipo específico de solo.

A avaliação dos três modelos por meio da importância de atributos permite relacionar a influência de certos parâmetros. O k_{sys-o} demonstra ser um fator chave no desempenho do filtro geotêxtil, independentemente do tipo de solo. O parâmetro C_u apresenta importância nos Modelos 1 e 2, mas sua influência é limitada no Modelo 3. Inversamente, a tensão vertical (σ_v) exibe baixa relevância nos Modelos 1 e 2, mas emerge como o segundo parâmetro mais importante no Modelo 3.

A análise revelou que o tipo de solo (atributo "Solo") exerce uma influência considerável no modelo, destacando sua relevância para o desempenho do filtro. Diante disso, optou-se por realizar uma divisão dos dados com base nos tipos de solo. Essa segmentação permitiu uma compreensão mais aprofundada da importância dos parâmetros, independentemente da

categoria geral do solo. Os parâmetros d_{10} e d_{15} apresentam influência moderada nos Modelos 2 e 3 (que representam diferentes categorias de solo resultantes dessa divisão), sugerindo que as características granulométricas impactam o desempenho em ambos o tipo de solo. Já o parâmetro d_{gap} mostrou-se relevante especificamente para o Modelo 3, o que era esperado por se tratar de um descriptor de solos descontínuos. Curiosamente, os parâmetros correspondentes às características do geotêxtil (t_{GT} e FOS) se mostraram irrelevantes nesses modelos.

A menor relevância de t_{GT} e FOS no PFI pode ser atribuída à diferença de unidades e as escalas em relação à permeabilidade, o que pode gerar variações pequenas na saída do modelo durante a permutação. Outros fatores que podem contribuir para essa baixa relevância incluem a redundância de informação com outras variáveis, a presença de relações não lineares não capturadas pelo PFI, e a limitada variação desses parâmetros nos dados. Embora a normalização dos dados possa atenuar o efeito das diferentes unidades, a baixa relevância no PFI sugere que a influência direta de t_{GT} e FOS, na permeabilidade final, pode ser menos evidente no modelo treinado, apesar de sua importância física no processo de colmatação. Em outras palavras, embora esses parâmetros exibam baixa influência, a inclusão desses parâmetros na análise auxilia a capturar a complexidade dos dados utilizados, pois estão diretamente correlacionados com o tipo de geotêxtil e são importantes para a construção do modelo.

Para validar a acurácia dos resultados do modelo, os valores residuais foram calculados ao se encontrar a diferença entre os valores previstos e os reais. As Figura 4.19 à Figura 4.21, mostram a distribuição dos valores medidos em laboratório, bem como os valores residuais (diferença entre medidos e previstos) obtidos para cada modelo. Assim, é possível validar a acurácia dos resultados do modelo. As linhas horizontais representam a variação na permeabilidade final do sistema solo – geotêxtil. Para a definição das faixas de variabilidade, foi considerada a faixa de distribuição normal de média + 2 desvios padrão.

Neste trabalho, para determinar tais critérios estatísticos, baseou-se em Kuperman et al. (2003). Segundo os autores, para um determinado grau de confiança, a “região de aceitação” se encontra delimitada no eixo das abscissas da distribuição por “ $\mu - eo$ ” e “ $\mu + eo$ ”, em que:

- μ = a média dos dados do estudo;

- $eo = Pr \cdot Sd$ (Sd é o desvio padrão e Pr é um valor que depende do grau de confiança adotado e do número de dados do estudo em questão).

Os graus de confiança e as “regiões de aceitação” correlacionadas foram, então, associados às regiões em que a acurácia do modelo se considera aceitável, conforme mostrado na Tabela 4.17. Salienta-se que os dados foram analisados estatisticamente de maneira separada, por cada modelo de RNA.

Tabela 4.17 –Faixa de aceitação dos erros residuais estabelecidos por análise estatística.

Faixa de Aceitação	Grau de Confiança (%)	Pr	Limites de Aceitação
Adotada	95,45	2,00	$\mu +/- 2,00 Sd$

Notas:

μ = a média dos dados de monitoramento do instrumento;

Sd = desvio padrão dos dados;

Pr = valor que depende do grau de confiança adotado e do número de dados do estudo em questão (tabela *t-Student*).

A Tabela 4.18 e

Tabela 4.19 apresentam as faixas de aceitação adotadas neste trabalho tanto na fase treinamento como de teste, respectivamente.

Tabela 4.18: Faixas de Aceitação dos Erros Residuais para a Fase de Treinamento

Modelo	Média dos Erro Residual (cm/s)	Desvio Padrão dos Erros Residuais (cm/s)	Limite inferior $\mu - 2,00 Sd$ (cm/s)	Limite superior $\mu + 2,00 Sd$ (cm/s)
1	$-1,67 \times 10^{-4}$	$3,17 \times 10^{-3}$	$-6,50 \times 10^{-3}$	$6,17 \times 10^{-3}$
2	$-9,31 \times 10^{-5}$	$7,27 \times 10^{-4}$	$-1,36 \times 10^{-3}$	$1,55 \times 10^{-3}$
3	$7,84 \times 10^{-5}$	$2,36 \times 10^{-4}$	$-3,93 \times 10^{-4}$	$5,50 \times 10^{-4}$

Tabela 4.19: Faixas de Aceitação dos Erros Residuais para a Fase de Teste

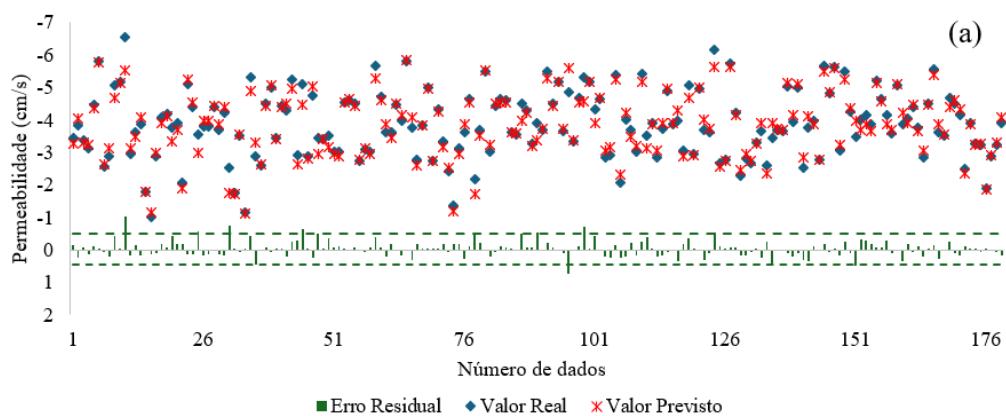
Modelo	Média dos Erro Residual (cm/s)	Desvio Padrão dos Erros Residuais (cm/s)	Limite inferior $\mu - 2,00 Sd$ (cm/s)	Limite superior $\mu + 2,00 Sd$ (cm/s)
1	$-4,70 \times 10^{-4}$	$2,74 \times 10^{-3}$	$-5,95 \times 10^{-3}$	$5,01 \times 10^{-3}$
2	$2,10 \times 10^{-3}$	$1,12 \times 10^{-2}$	$-2,03 \times 10^{-2}$	$2,45 \times 10^{-2}$
3	$2,71 \times 10^{-5}$	$9,64 \times 10^{-5}$	$-1,66 \times 10^{-4}$	$2,20 \times 10^{-4}$

A acurácia dos modelos de RNA propostos neste estudo pode ser avaliada por meio da análise

dos valores residuais, que representam a diferença entre os valores previstos e os medidos. Essa avaliação é detalhada nas Tabela 4.18 e

Tabela 4.19. Para ilustrar visualmente, as Figura 4.19 à Figura 4.21 mostram a distribuição dos valores medidos em laboratório (identificados por pontos azuis), juntamente com os valores previstos (símbolos vermelhos) e seus respectivos resíduos para cada modelo (barras verdes). Nessas representações gráficas, as linhas horizontais delimitam a faixa de aceitação da permeabilidade final do sistema geotêxtil/solo. Vale destacar que o eixo vertical está em escala logarítmica, o que permite uma melhor visualização e interpretação dos dados, especialmente devido à ampla variação dos valores analisados.

As discrepâncias observadas nos valores previstos podem ser atribuídas à significativa variabilidade dos dados de entrada de certos parâmetros, onde o desvio padrão excede a média e os coeficientes de variação ultrapassam 100%. Embora essa heterogeneidade dos dados contribua para um aprendizado mais robusto da rede, o modelo emprega fatores de aproximação internos que modulam a influência de cada parâmetro na correlação com o resultado desejado, o qual, por sua própria natureza, varia entre as amostras.



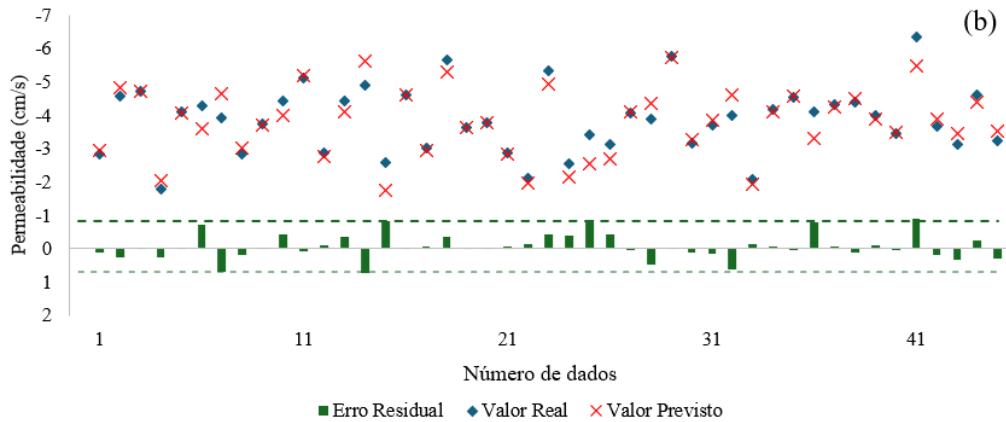


Figura 4.19: Valores reais, previstos e residuais para Modelo 1 (Todos os solos) de 3 camadas ocultas e 10 parâmetros de entrada: (a) Fase de Treinamento e (b) Fase de Teste

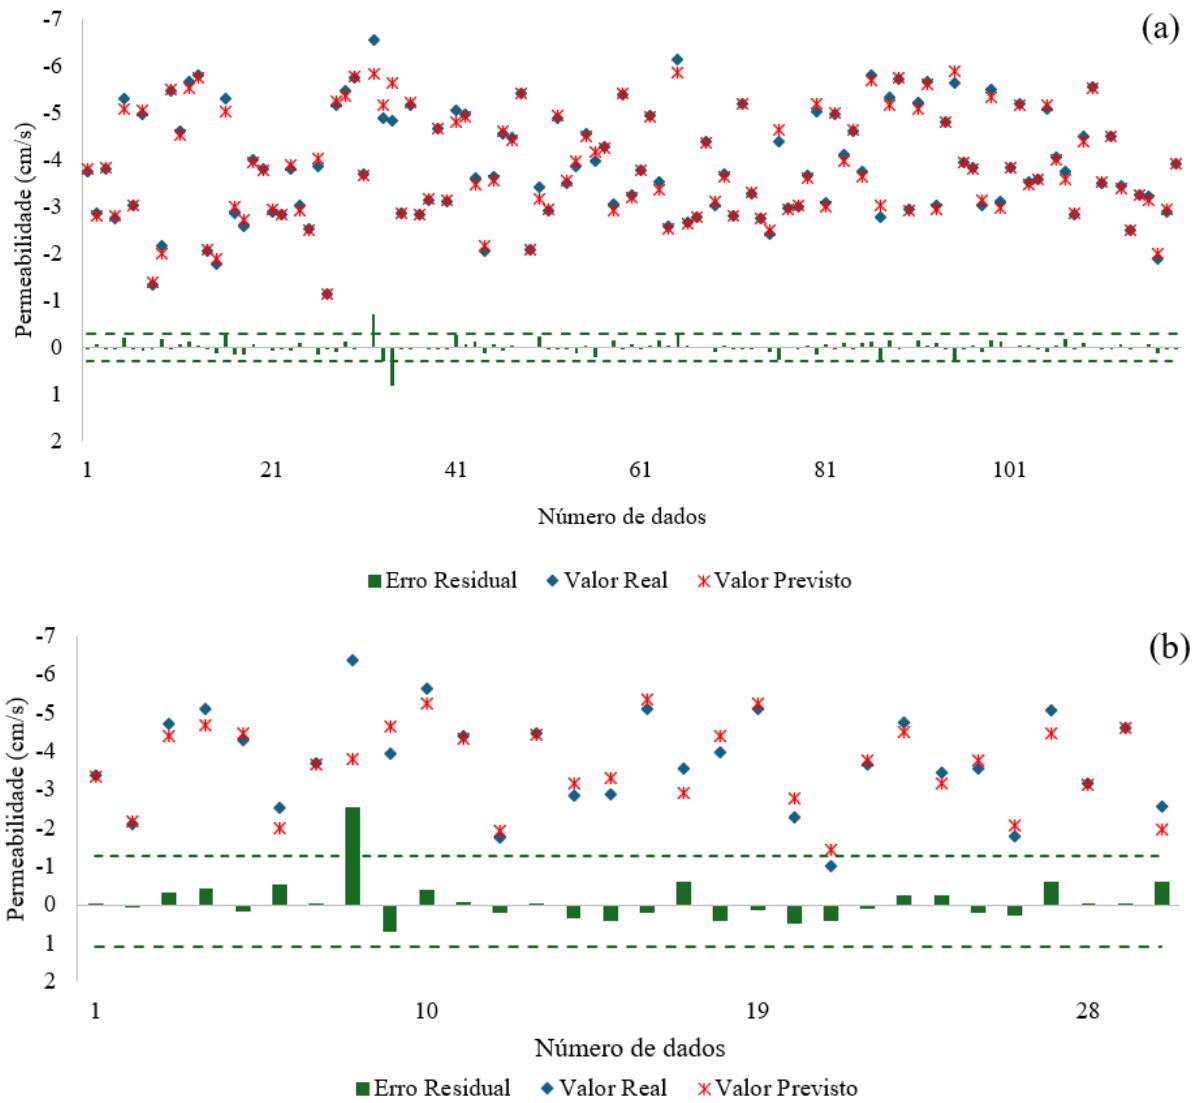


Figura 4.20: Valores reais, previstos e residuais para Modelo 2 (Solos CC) de 3 camadas ocultas e 9 parâmetros de entrada: (a) Fase de Treinamento e (b) Fase de Teste

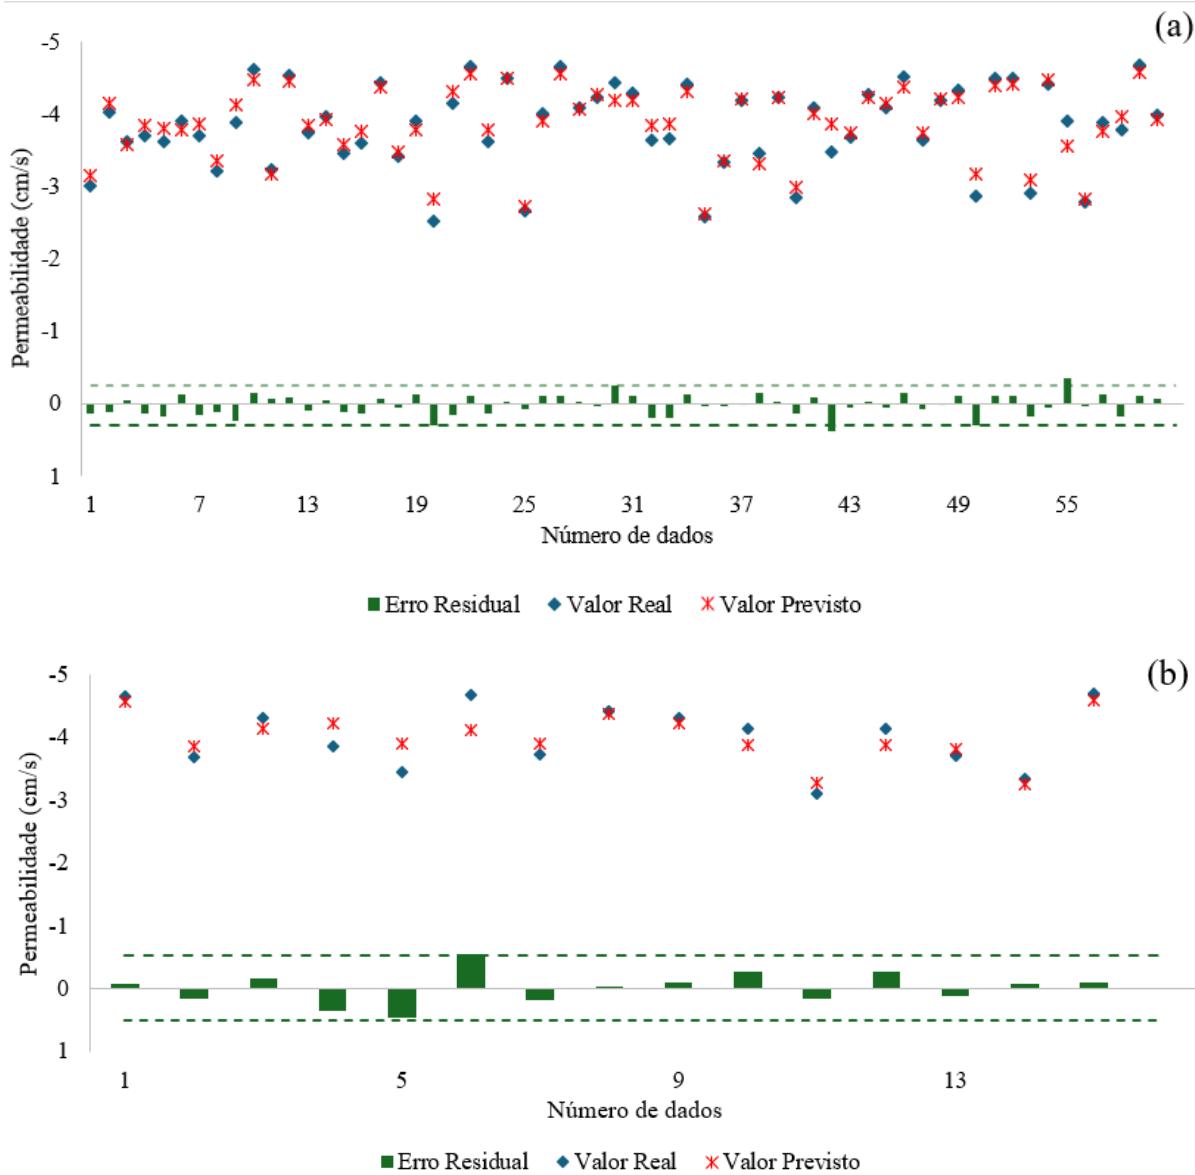


Figura 4.21: Valores reais, previstos e residuais para Modelo 3 (Solos GG) de 2 camadas ocultas e 9 parâmetros de entrada: (a) Fase de Treinamento e (b) Fase de Teste

Os percentuais de dados previstos que foram observados fora da faixa aceitável considerada nas Tabela 4.18 e

Tabela 4.19 foram determinados por meio do cálculo da quantidade de resíduos. Para a fase de treinamento, o percentual de resíduos fora da faixa é de 2,79%, 4,20% e 5,00% para cada modelo, respectivamente. Por outro lado, na fase de teste, os valores foram de 4,44%, 3,33%, e 13,33% para cada modelo, respectivamente.

Os valores de frequência do percentual de resíduos podem ser visualizados nas Figura 4.22 a

Figura 4.24 , que correspondem aos histogramas de frequência dos valores residuais. De maneira geral, pode-se observar que a ocorrência de valores residuais fora da faixa aceitável é mínima, e uma proporção considerável dos desvios dos dados previstos está centrada na faixa de 0 cm/s. Essa concentração sugere que o modelo fornece uma aproximação satisfatória dos resultados.

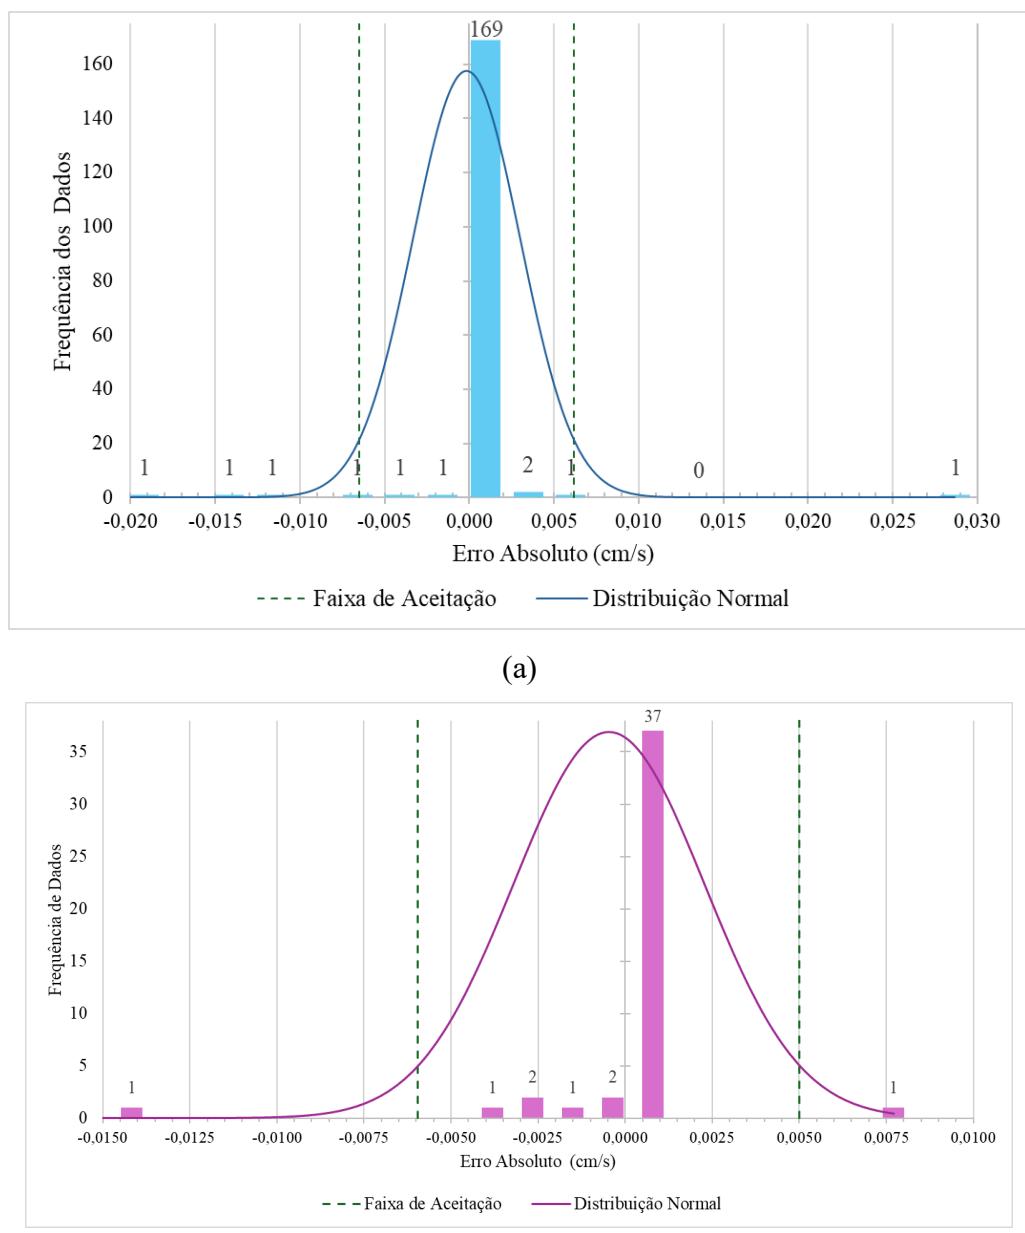
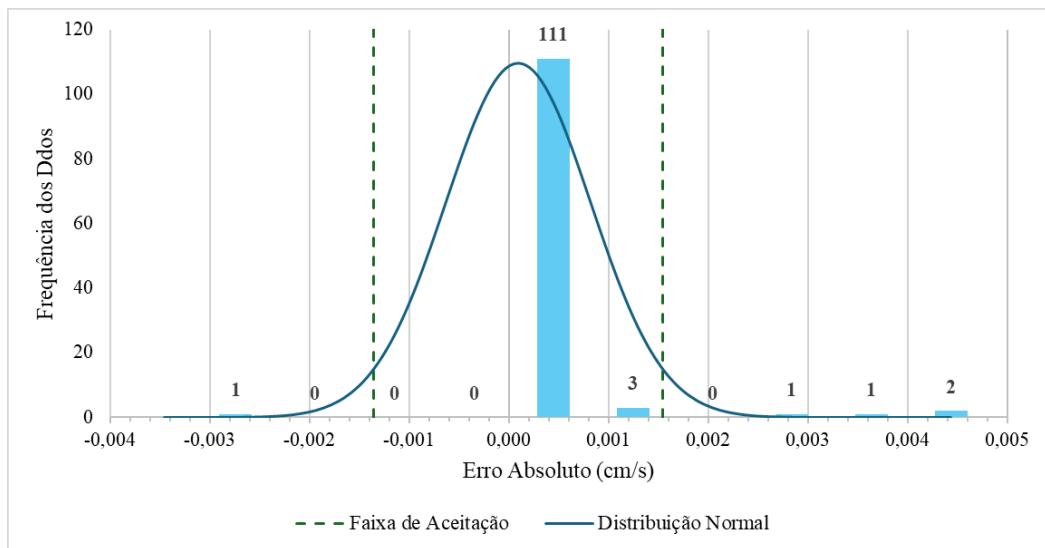
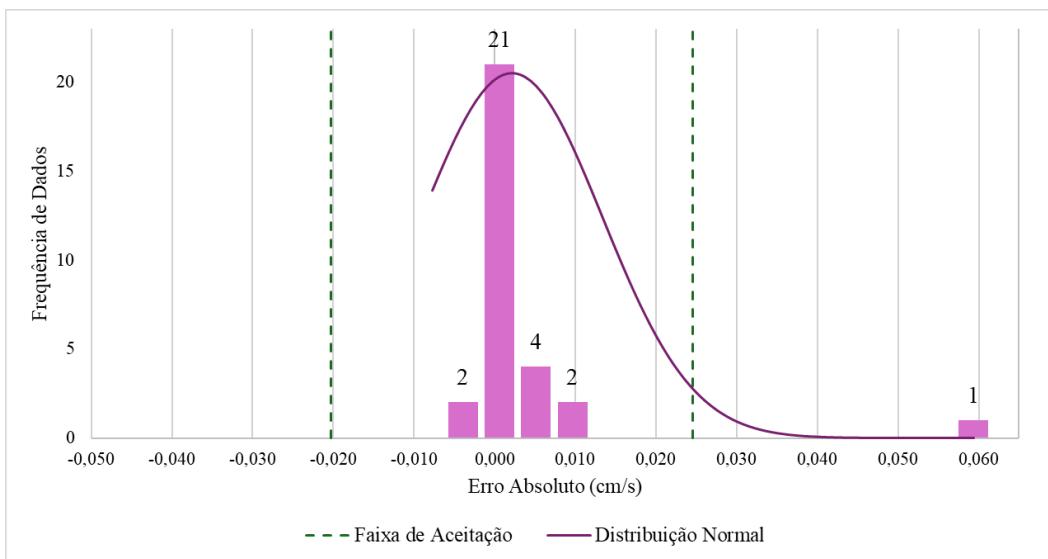


Figura 4.22: Histograma dos valores absolutos para o Modelo 1: (a) Fase de Treinamento, 5 de 179 dados (b) Fase de Teste, 2 de 45 dados

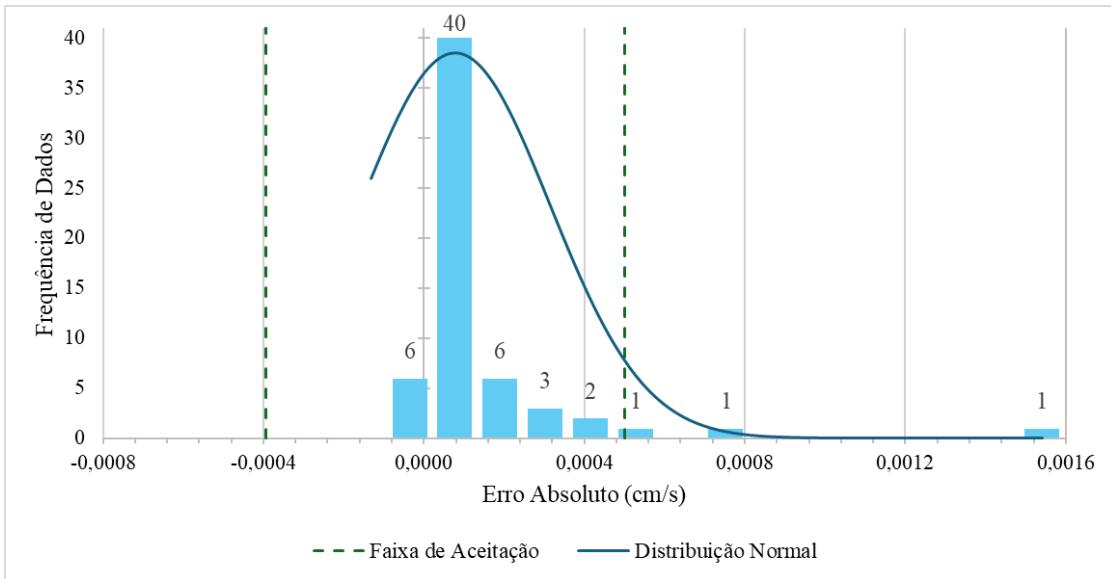


(a)

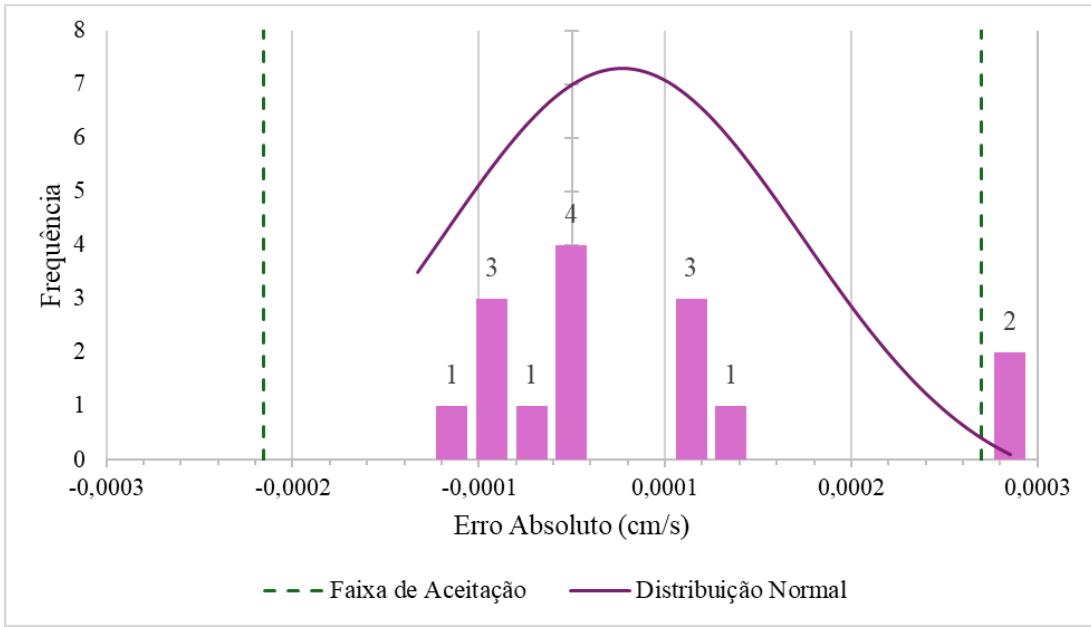


(b)

Figura 4.23: Histograma dos valores absolutos para o Modelo 2: (a) Fase de Treinamento, 5 dados de 119 (b) Fase de Teste, 1 de 30



(a)



(b)

Figura 4.24: Histograma dos valores absolutos para o Modelo 3 (Solos GG): (a) Fase de Treinamento, 3 de 60, (b) Fase de Teste, 2 de 15.

A Figura 4.25 até a Figura 4.28 apresentam outra maneira de analisar os resíduos obtidos pelos modelos de RNA. Esse método avalia a relação entre as previsões dos modelos e os resíduos (erros) das previsões. Os pontos vermelhos apresentam os dados de treinamento e a dispersão dos dados indica a variabilidade dos resíduos em relação às previsões. A linha vertical sólida, conhecida como zero residual, representa o ponto em que os resíduos são nulos, ou seja, o valor previsto é igual ao valor real. Já a linha horizontal tracejada, representa a médias dos valores

previstos, fornecendo uma referência para comparar a distribuição dos resíduos em relação à média das previsões. O Figura 4.25 (a), apresenta a relação entre os valores previsto e os resíduos relativos, ou seja, os resíduos são normalizados em relação aos valores previstos ou reais. Já o Figura 4.25 (b) apresenta os erros absolutos dos dados de teste (diferença entre os valores previstos e reais).

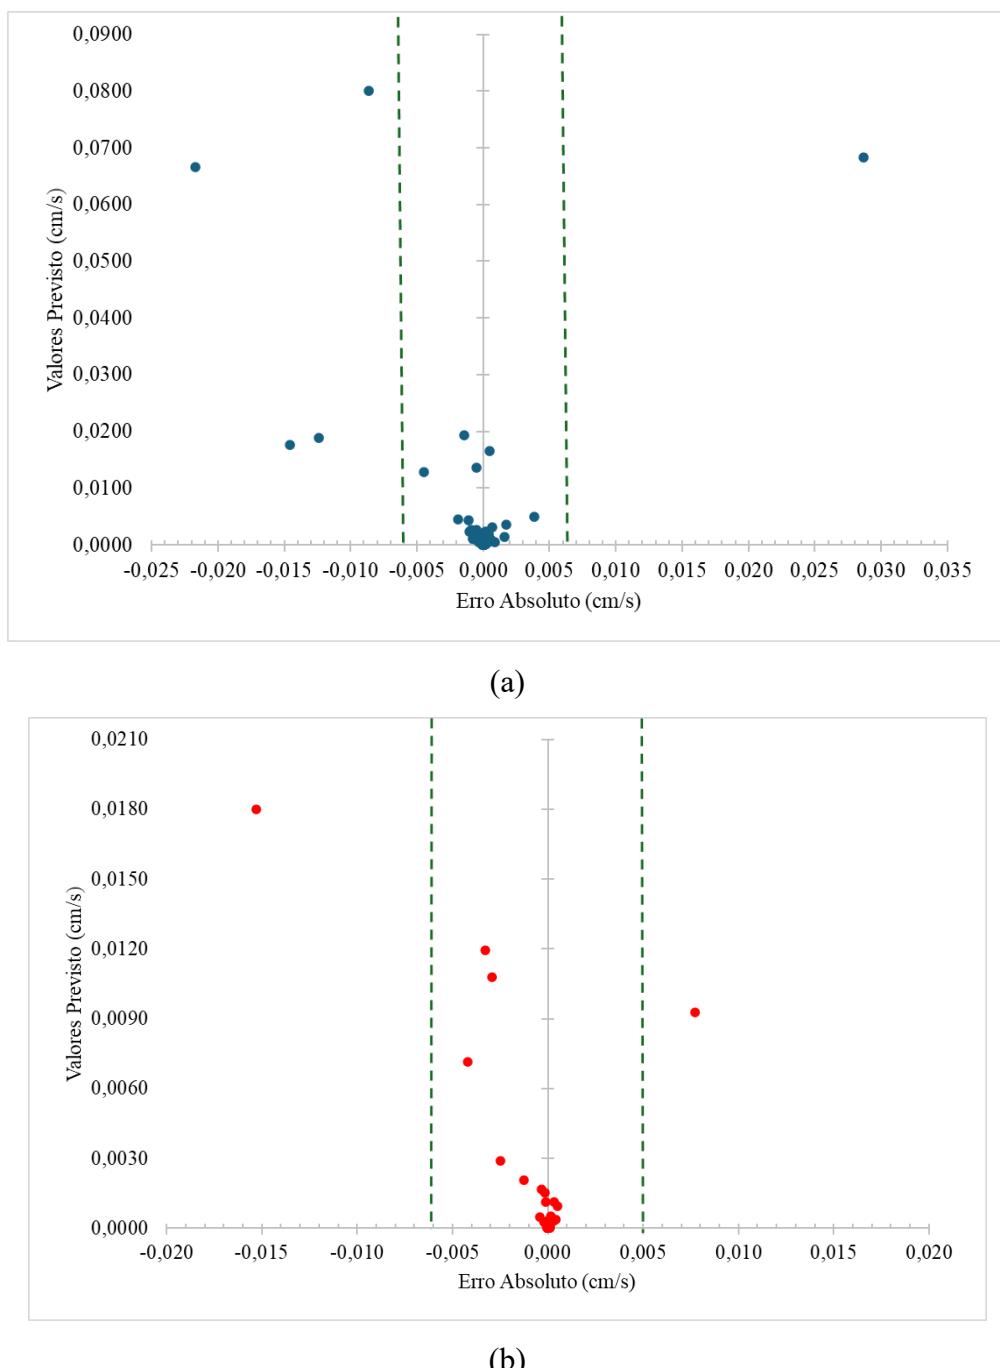
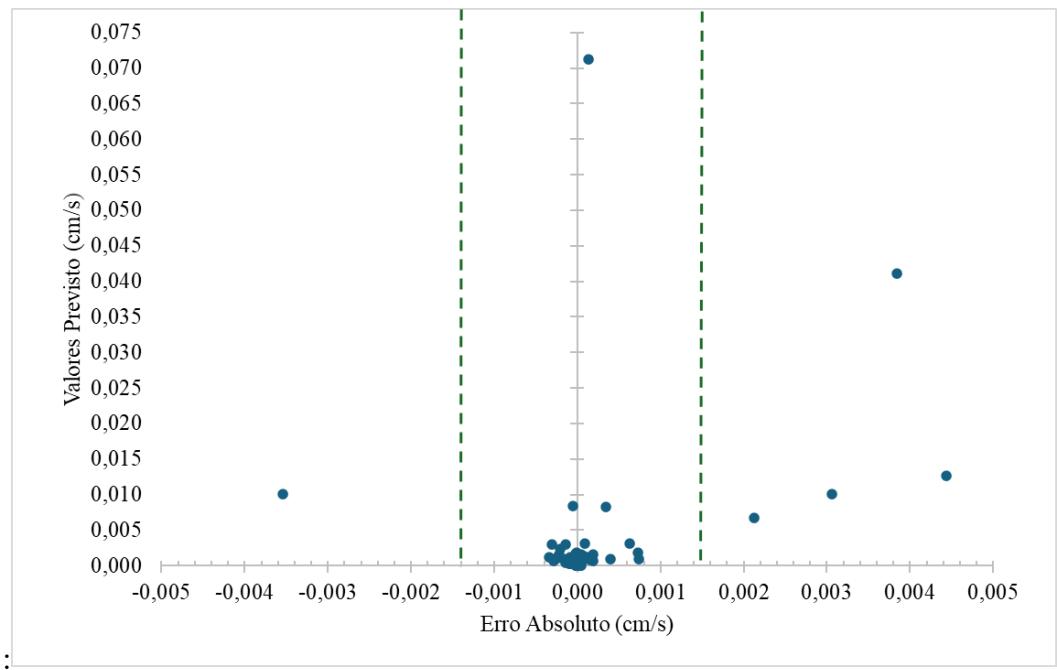
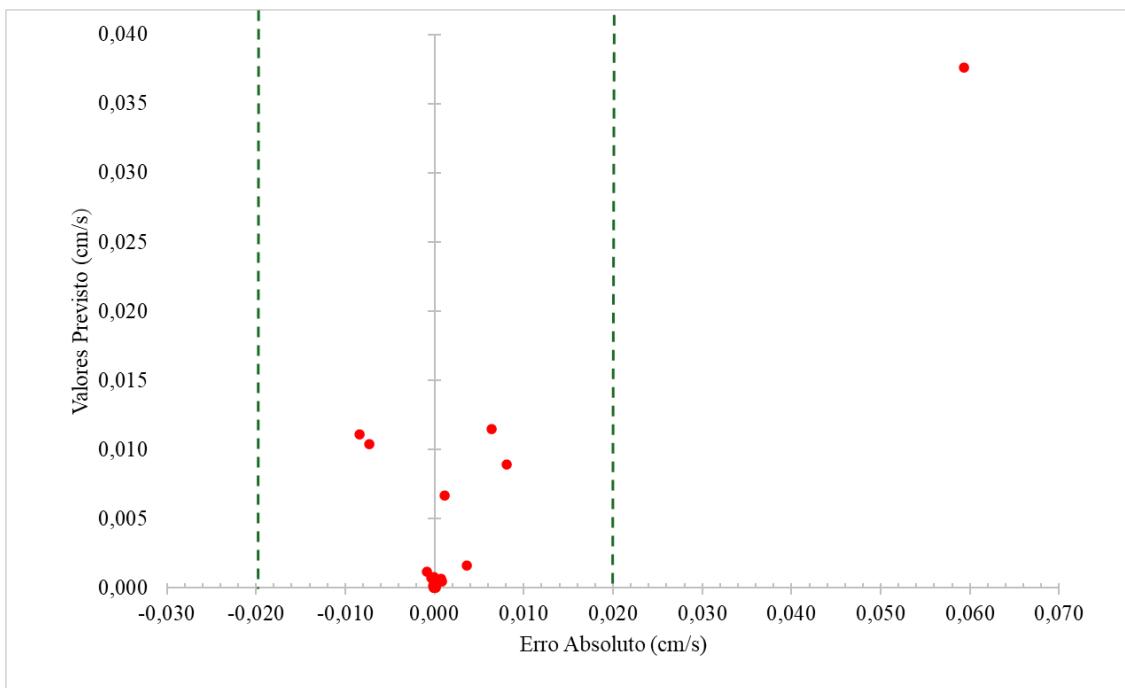


Figura 4.25: Gráfico de dispersão mostrando a relação entre previsões e resíduos (erros) do Modelo 1 (Todos os Solos): (a) Valores de Treinamento, 5 de 179 (b) Valores de Teste, 2 de 45.4.26



(a)



(b)

Figura 4.27: Gráfico de dispersão mostrando a relação entre previsões e resíduos (erros) do Modelo 2 (Solos com Concavidade para Cima): (a) Valores de Treinamento, 5 de 119 (b) Valores de Teste, 1 de 45.

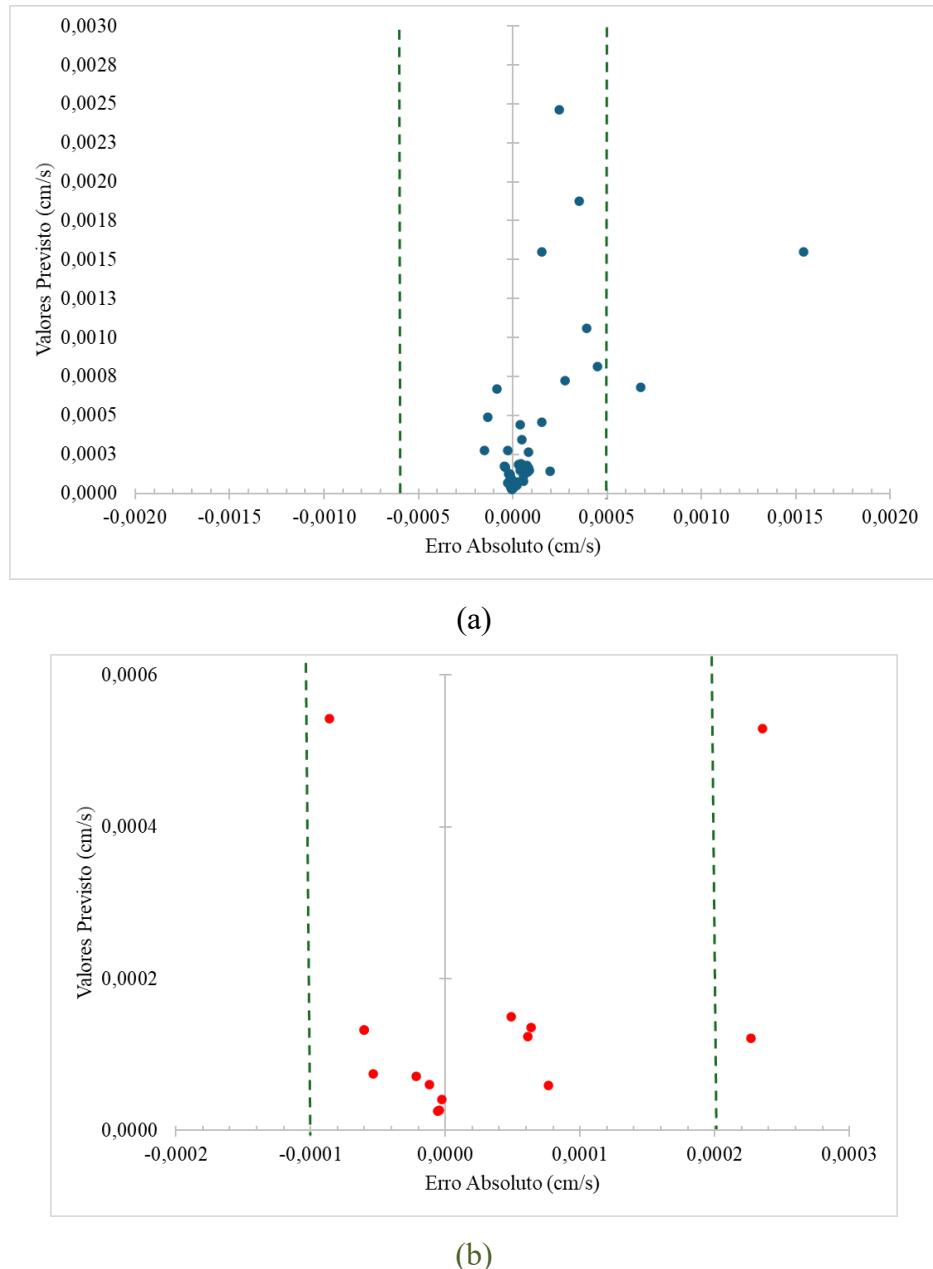


Figura 4.28: Gráfico de dispersão mostrando a relação entre previsões e resíduos (erros) do Modelo 3 (Solos Descontínuos): (a) Valores de Treinamento, 2 de 60 (b) Valores de Teste, 2 de 15.

Analizando a Figura 4.28 (a), observa-se que a maioria dos resíduos está concentrada em torno de zero, o que indica que as previsões são, em geral, precisas. Em relação à distribuição dos resíduos, o histograma apresentado na Figura 4.22(a) é simétrico em torno de zero, sugerindo que a maioria dos resíduos relativos está próxima de zero. Isso significa que a diferença entre os valores previstos pelo modelo e os valores reais é pequena, o que indica um bom desempenho do modelo. Por outro lado, a Figura 4.28 (a) também apresenta resíduos relativamente grandes, o que pode indicar erros de previsão significativos para esses casos.

Adicionalmente, a fim de avaliar o desempenho de cada modelo implementado na previsão dos valores de resistência ao cisalhamento da interface, erros estatísticos como RMSE, MAE e MAPE foram calculados conforme descrito no Capítulo 3. A Tabela 4.20 e a Tabela 4.21 resumem os resultados dos três critérios de avaliação estatística mencionados acima.

Tabela 4.20: Análise de sensibilidade usando RNA para a fase de treinamento

Modelo	Tipo de solo	Quant. de Dados	Parâmetros de Entrada	Número de Camadas Ocultas	Métricas de Desempenho		
					R ²	RMSE	MAPE%
1	CC+GG	179	10	3	0,94	0,239	4,27
2	CC	119	9	3	0,94	0,142	3,24
3	GG	60	9	2	0,98	0,143	2,24

Tabela 4.21: Análise de sensibilidade usando RNA para a fase de teste

Modelo	Tipo de solo	Quant. de Dados	Parâmetros de Entrada	Número de Camadas Ocultas	Métricas de Desempenho		
					R ²	RMSE	MAPE%
1	CC+GG	45	10	3	0,85	0,38	7,43
2	CC	30	9	3	0,78	0,583	10,84
3	GG	15	9	2	0,74	0,249	5,15

As Tabela 4.20 e

Tabela 4.21 apresentam os resultados da análise de sensibilidade utilizando Redes Neurais Artificiais (RNA) nas fases de treinamento e teste, respectivamente. Foram avaliados três modelos distintos, diferenciados pelo tipo de solo considerado (CC+GG: solos com concavidade para cima e *gap-graded* combinados; CC: apenas solos com concavidade para cima; GG: apenas solos *gap-graded*) e pela arquitetura da RNA (número de parâmetros de entrada e número de camadas ocultas).

Na fase de treinamento, todos os modelos demonstraram um bom ajuste aos dados utilizados para o aprendizado, com valores elevados de R² e relativamente baixos de RMSE e MAPE%. O Modelo 3 (apenas solos GG) apresentou o melhor desempenho nesta fase (R² = 0,98, MAPE = 2,24%). Os Modelos 1 (CC+GG) e 2 (apenas solos CC) tiveram desempenhos semelhantes,

com R^2 de 0,94, sendo o Modelo 2 ligeiramente melhor em termos de RMSE e MAPE%.

Na fase de teste, foi avaliada a capacidade de generalização dos modelos para dados não vistos, e percebeu-se que o Modelo 1 (CC+GG) manteve um desempenho razoável ($R^2 = 0,85$, MAPE = 7,43%), o que sugere uma boa capacidade de lidar com novos dados. Já os Modelos 2 (apenas solos CC) e 3 (apenas solos GG) apresentaram uma queda no desempenho em comparação com a fase de treinamento. O Modelo 2 obteve um R^2 de 0,78 e um MAPE de 10,84%, enquanto o Modelo 3 alcançou um R^2 de 0,74 e um MAPE de 5,15%. É importante notar que o Modelo 3 foi testado com um número significativamente menor de amostras (apenas 15), o que pode influenciar as métricas de desempenho.

Em termos comparativos, o Modelo 1 (treinado com ambos os tipos de solo) parece ser o mais robusto em termos de capacidade de generalização, pois mantém um desempenho aceitável tanto no treinamento quanto no teste. Os Modelos 2 e 3, embora excelentes no ajuste aos seus dados de treinamento específicos, mostraram dificuldades em prever a permeabilidade para novos dados, possivelmente devido a *overfitting* ou à menor quantidade de dados de teste para cada tipo de solo.

Em conclusão, a análise de sensibilidade indica que um modelo de RNA treinado com uma variedade maior de tipos de solo (Modelo 1) pode ser mais promissor para prever a permeabilidade final do sistema solo-geotêxtil em diferentes cenários. No entanto, a otimização da arquitetura da RNA e a expansão dos conjuntos de dados de treinamento e teste para cada tipo de solo são etapas importantes para melhorar a acurácia e a confiabilidade das previsões.

4.3 ANÁLISES DO MODELO RM

O uso de regressão múltipla identificou o nível de importância de parâmetros relevantes para avaliar o potencial mau funcionamento do sistema solo-geotêxtil e foi possível elaborar equações para prever valores de limite inferior e estimativas do coeficiente de permeabilidade do sistema solo-geotêxtil para análises preliminares.

Os resultados obtidos indicam que reduções significativas no coeficiente de permeabilidade e na taxa de fluxo do sistema solo-geotêxtil podem ocorrer independentemente do tipo de teste. Frequentemente, essas reduções são atribuídas a um comportamento hidráulico inadequado do

solo, e não ao entupimento do filtro geotêxtil. Essa observação é corroborada pelos resultados das RNAs, onde a análise de Importância de Atributos por Permutação (PFI) revelou que os parâmetros relacionados ao geotêxtil exercearam pouca influência no desempenho do sistema.

Para o desenvolvimento das equações de regressão apresentadas no estudo por RM conduzido por Palmeira et al. (2025), os solos foram separados em dois grupos: solos com curvas granulométricas côncavas para cima e solos com granulometria descontínua, uma vez que diferentes mecanismos de instabilidade interna seriam esperados em massas de solo contínuas e descontínuas. Além disso, a consideração de todos os solos juntos resultou em menor acurácia da regressão. Para solos com granulometria descontínua, o menor diâmetro de partícula da lacuna (d_{gap}) também foi considerado para a condição $d_{gap} > d_{15}$. Com base nessas suposições, as equações resultantes têm as seguintes formas:

Para solo com concavidade para cima, foi encontrada a Eq. (4.1),

$$k_{sys} = A_0 + A_1 k_{sys-o} + A_2 d_{10} + A_3 d_{15} + A_4 d_{30} + A_5 C_u + A_6 i_{sys} + A_7 \sigma_v + A_8 t_{GT} + A_9 FOS \quad \text{Eq. (4.1)}$$

Já para os solos descontínuos foi achada a Eq. (4.2)

$$k_{sys} = A_0 + A_1 k_{sys-o} + A_2 d_{10} + A_3 d_{15} + A_4 d_{30} + A_5 C_u + A_6 i_{sys} + A_7 \sigma_v + A_8 t_{GT} + A_9 FOS \quad \text{Eq. (4.2)}$$

Onde A_0 a A_9 e B_0 a B_9 são os coeficientes de regressão obtidos das análises para solos com curvas granulométricas côncavas para cima e solos com granulometria descontínua, respectivamente, com k_{sys} e k_{sys-o} em cm/s, d_{10} , d_{15} , d_{30} , t_{GT} e FOS em mm e σ_v em kPa.

A comparação entre as previsões obtidas para solos com curvas granulométricas côncavas para cima e os resultados dos testes de filtração (149 testes) é apresentada na Figura 4.29.

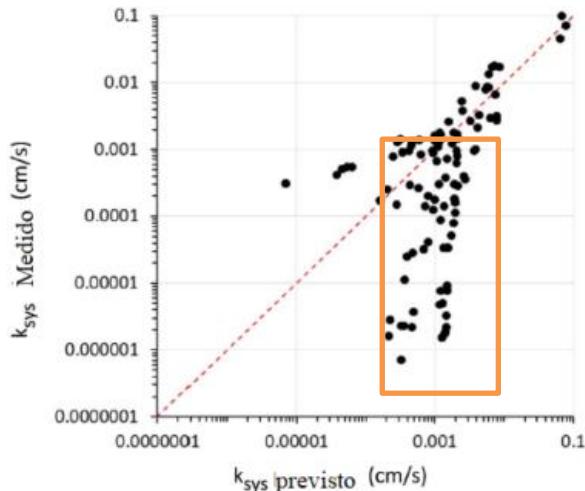


Figura 4.29: k_{sys} previsto versus k_{sys} medido – Para todos os solos com concavidade para cima (Modificado de Palmeira et al., 2025)

Percebe-se distintos padrões de variação entre os valores previstos e medidos para valores de k_{sys} maiores e menores que 2×10^{-3} cm/s, que também correspondem a valores de k_{sys-o} aproximadamente maiores e menores que 2×10^{-3} cm/s. Assim, os autores propuseram a adoção de diferentes equações de regressão para k_{sys-o} maior e menor que 2×10^{-3} cm/s, obtendo o resultado apresentado na Figura 4.30, em que uma melhor concordância entre os valores previstos e medidos pode ser notada. Nesse caso, para os coeficientes A_i , obtidos para solos com concavidade para cima, a Eq. (4.1) se torna:

Para $7,5 \times 10^{-5} \text{ cm/s} < k_{sys-o} < 2 \times 10^{-3} \text{ cm/s}$ com $R^2 = 0,87$, obteve-se a:

$$k_{sys} = -9,19x10^{-5} + 7,58x10^{-1}k_{sys-o} - 9,57x10^{-4}d_{10} + 4,86x10^{-4}d_{15} \quad \text{Eq. (4.3)} \\ + 9,50x10^{-6}d_{30} - 2,71x10^{-7}C_u - 3,72x10^{-6}i_{sys} \\ - 5,11x10^{-9}\sigma_v + 2,73x10^{-5}t_{GT} + 7,40x10^{-5}FOS$$

Para $k_{sys-o} > 2 \times 10^{-3} \text{ cm/s}$ com $R^2 = 0,89$ obteve-se a:

$$k_{sys} = -5,96x10^{-3} + 1,09x10^{-1}k_{sys-o} - 5,62x10^{-2}d_{10} + 8,47x10^{-2}d_{15} \quad \text{Eq. (4.4)} \\ - 1,50x10^{-2}d_{30} + 3,69x10^{-4}C_u + 3,31x10^{-4}i_{sys} \\ - 4,45x10^{-6}\sigma_v - 2,81x10^{-4}t_{GT} - 8,56x10^{-3}FOS$$

Na Figura 4.30 mostra-se que em aproximadamente 90% dos casos o k_{sys} medido ficou na faixa

de k_{sys} previsto/3 a $3k_{sys}$ previsto. Isso significa que em 90% dos casos as previsões pela Eq. (4.3) e Eq. (4.4) subestimariam ou superestimariam o coeficiente de permeabilidade do sistema por um fator de até 3. Em aproximadamente 98% dos casos as previsões subestimariam ou superestimariam as medições por um fator de até 10. Essas faixas de variação do coeficiente de permeabilidade podem ser consideradas bastante satisfatórias para análises preliminares.

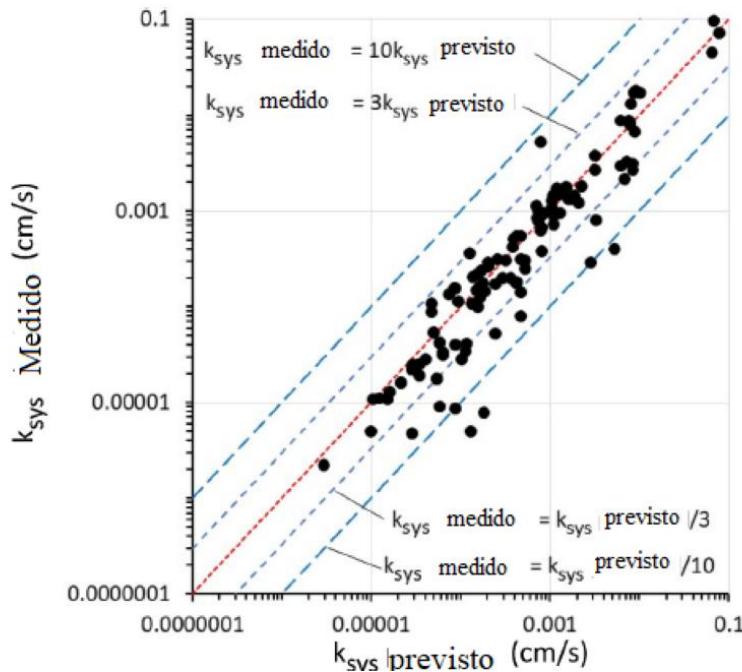


Figura 4.30: k_{sys} previsto versus k_{sys} medido – Para todos os solos com concavidade para cima com $k_{sys-o} < 2,00 \times 10^{-3}$ cm/s (Modificado de Palmeira et al., 2025)

Para solos com granulometria descontínua, as previsões de duas regressões estatísticas diferentes, neste caso, para k_{sys-o} menor ou maior que 5×10^{-4} cm/s, compararam-se melhor com as medições, semelhante ao que foi observado para solos com concavidade para cima. Assim, para solos com granulometria descontínua, para os valores de Bi calculados, a Eq. (4.2) , adota as seguintes formas:

Para $10^{-5} \text{ cm/s} < k_{sys-o} < 5 \times 10^{-4} \text{ cm/s}$ com $R^2 = 0,68$, obteve-se:

$$k_{sys} = 4,92 \times 10^{-5} + 2,10 \times 10^{-1} k_{sys-o} - 2,23 \times 10^{-2} d_{10} + 9,45 \times 10^{-3} d_{15} + 1,01 \times 10^{-5} d_{gap} + 4,56 \times 10^{-7} C_u - 4,69 \times 10^{-6} i_{sys} - 5,89 \times 10^{-7} \sigma_v + 3,95 \times 10^{-6} t_{GT} + 3,38 \times 10^{-4} FOS \quad \text{Eq. (4.5)}$$

Para $k_{sys-o} > 5 \times 10^{-4} \text{ cm/s}$ com $R^2 = 0,82$ obteve-se:

$$\begin{aligned}
k_{sys} = & -1,11 \times 10^{-2} + 1,26 \times 10^{-1} k_{sys-o} + 0,0d_{10} - 7,13 \times 10^{-2} d_{15} - 1,23 \times 10^{-2} d_{gap} \\
& - 2,18 \times 10^{-5} C_u + 3,31 \times 10^{-4} i_{sys} + 3,05 \times 10^{-5} \sigma_v - 1,91 \times 10^{-3} t_{GT} \\
& - 4,22 \times 10^{-2} FOS
\end{aligned} \quad \text{Eq. (4.6)}$$

A Figura 4.31 apresenta os valores medidos e os previstos pelas equações para solos com granulometria descontínua, é possível perceber uma maior dispersão dos dados comparado com os solos de concavidade para cima, sendo comprovado pelo um menor R^2 . Destaca-se que, para este esse tipo de solo, o número de amostras é menor que o outro tipo de solo.

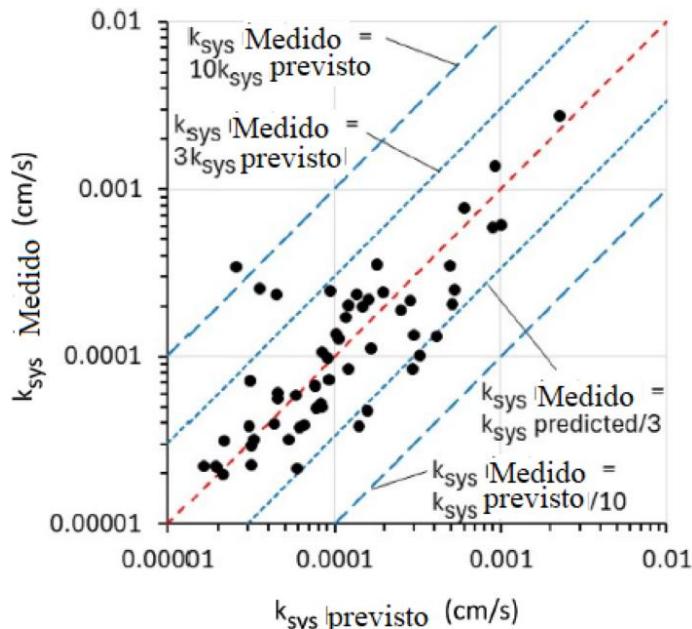


Figura 4.31: k_{sys} previsto versus k_{sys} medido – Para os solos descontínuos (Modificado de Palmeira et al., 2025)

A Figura 4.31 apresenta uma dispersão maior comparado com os solos com concavidade para cima, sendo o que é corroborado pelo menor valor de R^2 obtido para o primeiro tipo de solo. Deve-se também salientar que foram encontrados menos dados experimentais para solos com granulometria descontínua. Em 87% dos casos, a Eq. (4.5) e Eq. (4.6) subestimaram ou superestimaram o k_{sys} medido por um fator de até 3 e, em 98% dos casos, por um fator de até 10.

As equações consideram propriedades do solo e do geotêxtil, além de condições hidráulicas e de confinamento, e foram desenvolvidas separadamente para diferentes tipos de solo para melhorar a acurácia. Os resultados mostram uma concordância razoável entre as previsões e os

dados experimentais, especialmente ao dividir os dados com base na permeabilidade inicial do sistema. Isso indica a utilidade dessas equações para análises preliminares em engenharia geotécnica.

4.4 COMPARAÇÃO DO MODELO DE RNA E O MODELO RM

Com a finalidade de comparar o desempenho dos modelos desenvolvidos por RNA e do modelo obtido pela regressão linear múltipla. A Figura 4.32 apresenta um gráfico de dispersão que compara os valores previstos com os valores medidos do coeficiente de permeabilidade (cm/s), igualmente realizado no item 4.3, utilizando uma escala *log-log* em ambos os eixos para abranger a ampla variação de magnitude dos dados.

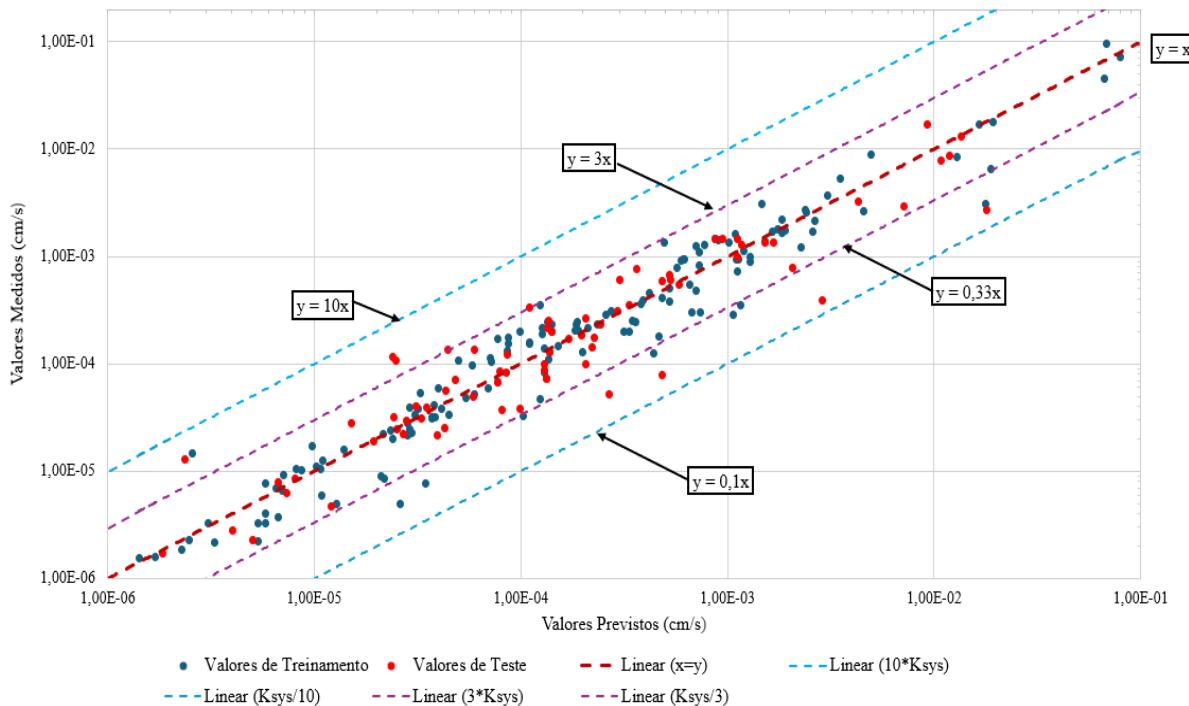


Figura 4.32: Valores previstos pelo modelo e os valores medidos para os dois tipos de solos (Modelo 1) com a metodologia RNA.

Na Figura 4.32, os pontos azuis representam os valores utilizados no treinamento do modelo de previsão, enquanto os pontos vermelhos correspondem aos valores de teste empregados para avaliar a capacidade de generalização do modelo a dados não previamente utilizados. A linha vermelha sólida, que representa a condição de igualdade ($y=x$), demonstra que a maioria dos pontos, tanto de treinamento quanto de teste, agrupa-se em torno dela. Isso indica uma concordância geral razoável entre as previsões do modelo e os valores efetivamente medidos do coeficiente de permeabilidade.

Alguns pontos se situam acima da linha, o que indica que o modelo subestimou o valor real, enquanto outros estão abaixo, sinalizando uma superestimação. As linhas tracejadas em azul (y

$= 0.1x$ e $y = 10x$) e roxo ($y = 0.33x$ e $y = 3x$) definem faixas de erro. A análise, consistente com os dados apresentados na Figura 4.32 do estudo, revela que aproximadamente 94% dos casos se encontram dentro da faixa delimitada pelas linhas roxas (erro de até um fator de 3). Adicionalmente, quase 100% dos casos se situam dentro da faixa mais ampla definida pelas linhas azuis (erro de até uma ordem de magnitude).

A dispersão dos pontos de teste (vermelhos) é similar à dos pontos de treinamento (azuis), o que sugere que o modelo apresenta uma capacidade de generalização aceitável e provavelmente não sofre de *overfitting*, ou seja, não se ajustou excessivamente aos dados de treinamento em detrimento do desempenho em dados novos. A análise visual da escala *log-log* indica que o desempenho do modelo parece relativamente consistente em diferentes ordens de magnitude dos valores de permeabilidade, embora possa haver uma ligeira tendência de maior variabilidade nos valores mais elevados.

Para o modelo 2 desenvolvido neste estudo, a Figura 4.33 mostra que, em aproximadamente 95% dos casos, o k_{sys} medido ficou na faixa de k_{sys} previsto/3 a $3k_{sys}$ previsto. Isso significa que, em 95% dos casos, as previsões pelo Modelo 2 subestimariam ou superestimariam o coeficiente de permeabilidade (ou taxa de fluxo) do sistema por um fator de até 3. Em aproximadamente 99% dos casos, as previsões subestimariam ou superestimariam as medições por um fator de até 10.

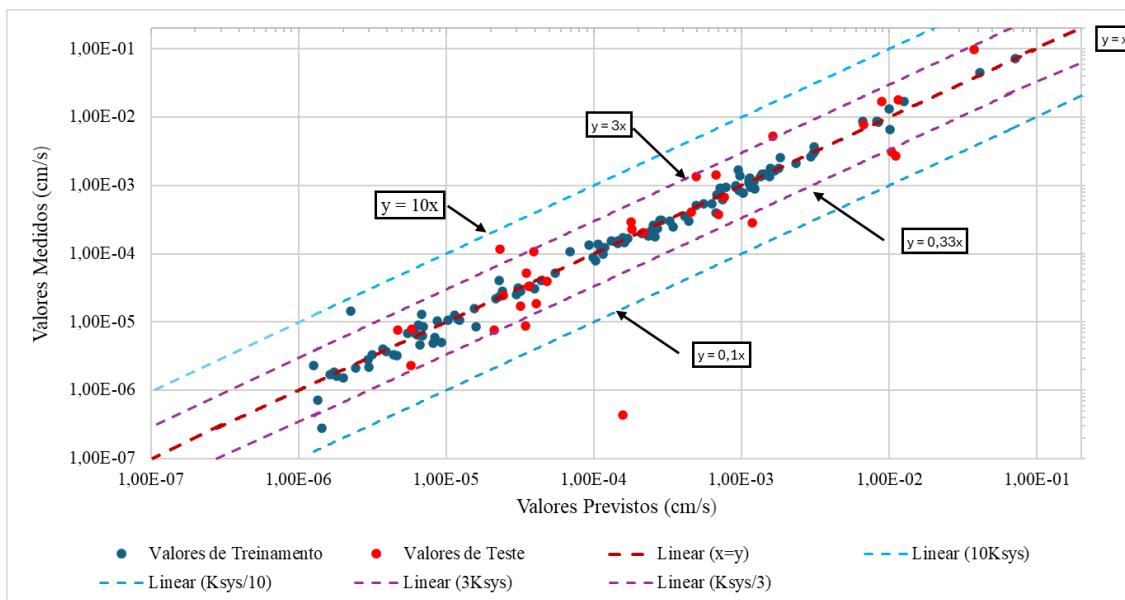


Figura 4.33– Comparaçāo entre os valores previstos pelo modelo e os valores medidos- solos com concavidade para cima

Já com relação ao Modelo 3, a Figura 4.34 mostra que, em aproximadamente 99% dos casos, o k_{sys} medido ficou na faixa de k_{sys} previsto/3 a 3 k_{sys} previsto. Isso significa que, em 99% dos casos, as previsões pelo Modelo 3 subestimariam ou superestimariam o coeficiente de permeabilidade (ou taxa de fluxo) do sistema por um fator de até 3. Em aproximadamente 100% dos casos, as previsões subestimariam ou superestimariam as medições por um fator de até 10.

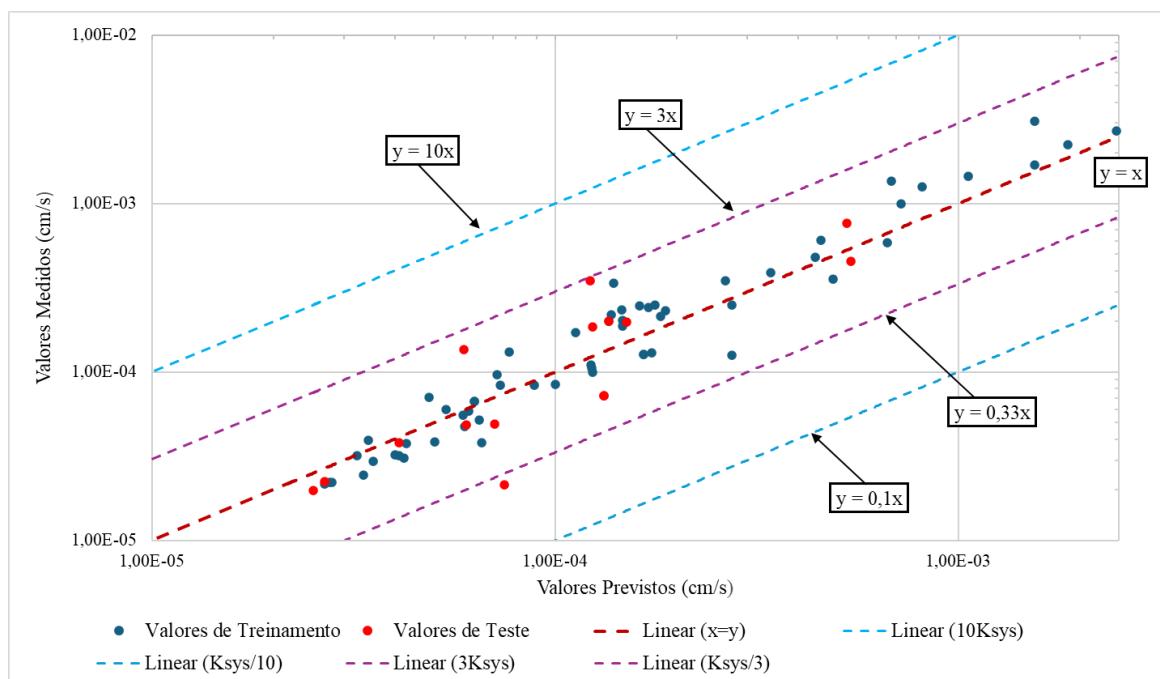


Figura 4.34: Comparação entre os valores previstos pelo modelo e os valores medidos- solos descontínuos.

O desempenho dos modelos de Redes Neurais Artificiais (RNA) foi avaliado quantitativamente por meio da análise da porcentagem de previsões que se encontram dentro de faixas de erro predefinidas em relação aos valores medidos do coeficiente de permeabilidade. Para o Modelo 1, treinado com dados de ambos os tipos de solo (com concavidade para cima e descontínuos), aproximadamente 94% das previsões ficaram dentro de um fator de até 3 dos valores medidos. Além disso, quase 100% das previsões apresentaram um erro de até uma ordem de magnitude (fator de até 10). O Modelo 2, desenvolvido especificamente para solos com concavidade para cima, demonstrou uma ligeira melhoria, com aproximadamente 95% das previsões dentro de um fator de até 3 e 99% dentro de um fator de até 10 dos valores medidos. O Modelo 3, treinado para solos com granulometria descontínua, apresentou o melhor desempenho entre os três modelos, com cerca de 99% das previsões dentro de um fator de até 3 dos valores medidos e 100% das previsões dentro de um fator de até 10.

Essas porcentagens indicam que todos os modelos conseguem prever o coeficiente de permeabilidade com uma acurácia razoável, de modo que a grande maioria das previsões se situa dentro de uma ordem de magnitude dos valores reais. Os modelos treinados especificamente para um tipo de solo (Modelos 2 e 3) tendem a apresentar uma ligeira vantagem em termos de acurácia para o tipo de solo para o qual foram otimizados.

Assim com a finalidade de avaliar o desempenho dos modelos de regressão múltipla (RM) e de rede neural artificial (RNA), desenvolvidos nos itens 4.2 e no item 4.3, foi realizada uma comparação e apresenta-se de forma resumida na Tabela 4.22 . Esta análise se concentrou nos Modelos 2 e 3 para permitir uma avaliação mais detalhada e individualizada de cada tipo de solo.

Tabela 4.22: Resumo da comparação entre os modelos de MR e RNA

Modelo	Faixas	RM	RNA
1 (Solos com concavidade para cima e <i>gap graded</i>)	Entre $k_{sysm}/3$ e $3k_{sysm}$	-	94%
	Entre $k_{sysm}/10$ e $10 k_{sysm}$	-	100%
2 (Solos com concavidade para cima)	Entre $k_{sysm}/3$ e $3k_{sysm}$	90%	95%
	Entre $k_{sysm}/10$ e $10 k_{sysm}$	98%	99%
3 (Solos descontínuos ou <i>grap graded</i>)	Entre $k_{sysm}/3$ e $3k_{sysm}$	87%	99%
	Entre $k_{sysm}/10$ e $10 k_{sysm}$	98%	100%

A Tabela 4.22 revela que os modelos de RNA tendem a prever o comportamento filtrante do sistema solo/geotêxtil com maior precisão. A diferença é pequena no Modelo 2, mas torna-se considerável no Modelo 3, onde a acurácia da RNA é 12% maior (99% contra 87%) na faixa de $k_{sysm}/3$ a $3k_{sysm}$.

É importante notar que os Modelos 2 e 3 superam a acurácia do Modelo 1, o que reforça a hipótese inicial de que a separação dos tipos de solo é uma estratégia eficaz para o desenvolvimento de modelos preditivos, tanto para RNA quanto para regressão múltipla.

Em resumo, embora a metodologia de RNA tenha apresentado os melhores resultados, ambas as abordagens demonstram um excelente desempenho na tarefa de previsão do comportamento filtrante do sistema solo/ geotêxtil.

5 CONCLUSÕES

5.1 CONCLUSÕES GERAIS

O foco deste estudo foi avaliar a eficácia do uso da metodologia RNA para prever o desempenho do sistema solo/geotêxtil em contato com solos internamente instáveis. Uma arquitetura MLP foi escolhida para configurar os modelos de RNA, e o processo de treinamento é supervisionado, o que envolve um algoritmo de treinamento BP acoplado ao algoritmo de otimização BOA.

Os dados de entrada para os modelos implementados foram definidos a partir de testes de laboratório relatados em pesquisas anteriores. Duzentos e vinte e quatro dados (224), incluindo 16 parâmetros de entrada e os resultados da permeabilidade final do sistema solo/geotêxtil (k_{sys}), foram finalmente utilizados. Uma vez que os resultados obtidos nas várias análises realizadas foram avaliados, é possível estabelecer as seguintes conclusões:

- A informação estatística dos dados coletados revela uma ampla distribuição para cada parâmetro, o que permite uma melhor caracterização e análise para diferentes condições de solo, geotêxtil e condições externas.
- Para esse estudo, a análise de correlação dos dados coletados mostrou que as características do solo (d_{10} , d_{15} e C_u) têm a maior correlação com a permeabilidade final do sistema solo-geotêxtil. Em contraste, condições do ensaio como tensão vertical e gradiente hidráulico apresentam uma correlação média, enquanto a espessura do geotêxtil e a abertura de filtração exibiram os menores coeficientes de correlação. É importante destacar que esses resultados refletem o comportamento observado neste conjunto específico de dados e não devem ser generalizados sem cautela. Assim, no contexto deste estudo, esta análise permitiu reforçar que, na maioria dos casos, a diminuição do desempenho do sistema solo-geotêxtil não foi causada apenas pelas propriedades do geotêxtil, mas, sim, pelo comportamento do solo internamente instável sob as condições hidráulicas impostas;
- Três modelos de RNA foram analisados, diferenciados em termos do seu número de entradas (9 ou 10) e do número de camadas ocultas (2 ou 3). Os modelos com mais parâmetros de entrada apresentaram maior acurácia com base na análise de distribuição, valores residuais e critérios estatísticos obtidos pela comparação entre valores previstos e reais.
- Não foi alcançada uma correlação perfeita entre os dados previstos e reais provavelmente

devido à ausência de alguns valores nos parâmetros de entrada durante o treinamento da rede. Essa limitação reflete a complexidade inerente a esses sistemas, que envolvem múltiplas regressões não lineares e muitas variáveis explicativas, tornando inviável a inclusão de todas elas no modelo. Portanto, essa complexidade dificulta a modelagem precisa, exigindo abordagens que conciliem simplificação e representatividade dos dados;

- O Modelo 1 de RNA, com a arquitetura 10-554-136-186-1, apresentou resultados satisfatórios em termos da distribuição dos valores previstos em comparação com a linha de tendência, um menor número de valores residuais fora da faixa aceitável (2,8% para treinamento e 4,4% para teste) e excelente desempenho de previsão de acordo com as métricas estatísticas para ambas as fases.
- O Modelo 2 de RNA, com a arquitetura 9-890-850-209-1, também apresentou resultados satisfatórios com um número de valores residuais fora da faixa aceitável (4,2% para treinamento e 3,3% para teste) e excelente desempenho de previsão de acordo com as métricas estatísticas para ambas as fases;
- Já o Modelo 3 de RNA, apresentou uma arquitetura 9-557-835-1, desenvolveu resultados aceitáveis com um número de valores residuais fora da faixa aceitável, sendo 5,00% para a fase de treinamento e de 13,33% na fase de teste e desempenho moderado de previsão de acordo com as métricas estatísticas para ambas as fases;
- Pode-se concluir que o algoritmo de RNA é um método adequado para prever os valores de desempenho do sistema solo/geotêxtil (k_{sys}) para os dados coletados.
- A análise de regressão múltipla (MR) apresentou resultados preliminares promissores e as equações obtidas permitem quantificar e utilizar esses métodos de forma complementar para compreender os fatores que influenciam o comportamento do sistema solo internamente instável-geotêxtil.

Por fim, ressalta-se que os dados matemáticos isolados não oferecem a sensibilidade necessária para compreender integralmente o funcionamento real do sistema. Sem a observação direta em campo ou em laboratório, tais dados apenas simulam relações numéricas, sem captar a complexidade e as nuances do comportamento físico, o que evidencia a importância fundamental de análises experimentais complementares.

5.2 LIMITAÇÕES DO MODELO

A principal limitação do modelo reside nas propriedades dos materiais sob avaliação. Especificamente, o modelo se concentra unicamente na interação entre solo internamente instável e geotêxtil. Adicionalmente, é necessário dispor da maior quantidade de informação possível sobre os parâmetros de entrada, os quais devem estar dentro das faixas dos dados utilizados nos algoritmos de aprendizagem.

5.3 SUGESTÕES PARA PESQUISAS FUTURAS

As conclusões deste estudo fornecem algumas recomendações para pesquisas futuras sobre o uso de RNA e Regressão Linear Múltipla para avaliar o desempenho filtrante do sistema solo/geotêxtil:

- Complementar a base de dados atual e fornecer mais amostras para treinamento e validação.
- Implementar diferentes algoritmos de treinamento e/ou otimização e outras técnicas de *Machine Learning* (Aprendizado de Máquina), para comparar os resultados obtidos e estabelecer a metodologia mais precisa.
- Iniciar pesquisas com outros solos e geotêxteis, a fim de estabelecer um comportamento geral para diferentes tipos de filtro geossintéticos.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABRAHAM, A. (2005). Artificial Neural Networks. In P.H. Sydenham and R. Thorn (Eds.), Handbook of Measuring System Design (pp. 901-908). John Wiley & Sons.
- ADEL, D. H., BAKKER, K. J., & BRETELER, M. K. (1988). Internal stability of minestone. In: Proceedings of international symposium of modelling soil–water-structure interaction. Balkema, Rotterdam, pp 225–231.
- ADELI, H. (2001). Neural networks in civil engineering: 1989-2000. Computer-Aided Civil and Infrastructure Engineering, vol. 16, no. 2, pp. 126-142.
- AL-ATROUSH, M., ESSAM, A., & HEMDAN, E. E.-D. (2024). Beyond p-y method: A review of artificial intelligence approaches for predicting lateral capacity of drilled shafts in clayey soils. Journal of Rock Mechanics and Geotechnical Engineering.
- ANDERSON, D. & MCNEILL, G. (1992). Artificial Neural Networks Technology: A DACS State-of-the-Art Report. Kaman Sciences Corporation.
- ASTM D5101-Standard Test Method for Measuring the Filtration Compatibility of Soil-Geotextile Systems
- ASTM D5567-Standard Test Method for Hydraulic Conductivity Ratio (HCR) Testing of Soil/Geotextile Systems
- AZOUR, R., DEO, R., SHANNON, B., FU, G., JI, J., & KODIKARA, J. (2022). Predicting pipeline corrosion in heterogeneous soils using numerical modelling and artificial neural networks. Acta Geotechnica, volume 17, páginas 1–14.
- BAGHBANI, A., CHOUDHURY, T., COSTA, S., REINER, J. (2022). Application of artificial intelligence in geotechnical engineering: A state-of-the-art review. Em Earth-Science Reviews, Elsevier B.V., volume 228.
- BASHEER, I. A., HAJMEER, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. J Microbiol Methods. 2000 Dec 1;43(1):3-31.
- BEIRIGO, E.A. (2009). Comportamento filtro-drenante de geotêxteis em barragens de rejeitos de mineração. Dissertação de mestrado.
- BENDAHMANE, F., MAROT, D., & ALEXIS, A. (2008). Experimental parametric Study of Suffusion and Backward Erosion. Journal of Geotechnical and Geoenvironmental Engineering - ASCE, 134(1), 57-67.
- BERA, A. K., GHOSH, A., & GHOSH, A. (2005). Regression model for bearing capacity of a square footing on reinforced pond ash. Geotextiles and Geomembranes, volume 23, número 3, páginas 261–285.
- BETRO, B., & ROTONDI, R. (1991). On Bayesian inference for the inverse Gaussian distribution. Statistics & probability letters, 11(3), 219-224.

BHATIA, G. I. S. & HUANG, S. K. (1995). Geotextile Filters for Internally Stable/Unstable Soils. Em Geosynthetics International, volume 2, número 3.

BHATIA, S. K. & HUANG, Q. (1996). Geotextile filters for internally stable/unstable soils. Geosynthetics International, 3, No. 3, pp. 537–565.

BHATIA, S.K. & SMITH, J.L. (1996). Geotextile Characterization and Pore-Size Distribution: Part I. A Review of Manufacturing Processes. Geosynthetics International, 3, páginas 85–105.

BISHOP, C. M. (2006). Mixture models and the em algorithm. Microsoft Research, Cambridge.

BISHOP, C. M. (2006). Pattern recognition and machine learning. Berlin, Germany: Springer Science+ Business Media, LLC.

BOUNDS, D.G.; LLOYD, P.J.; MATHEW, B.; and WADDELL, G. (1998). A multilayer perceptron network for the diagnosis of low back pain, Proc. of 2nd IEEE Annual Int'l Conf. on Neural Networks, pp. 481-489, San Diego, NJ, USA, June 21-24, 1988

BRAGA, A.P., CARVALHO, A.C.P.L.F., & LUDELMIR, T.B. (2007). Redes neurais artificiais - Teoria e aplicações. 2.ed. Rio de Janeiro: LTC.

BREIMAN, L. (2001). Random forests. Machine learning, v. 45, n. 1, p. 5-32.

BROCHU, E., CORA, V. M., & DE FREITAS, N. (2010). A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. arXiv preprint arXiv:1012.2599.

CAMARENA-MARTINEZ, R., LIZARRAGA-MORALES, R., & BAEZA SERRATO, R. (2021). Classification of Geomembranes as Raw Material for Defects Reduction in the Manufacture of Biodegester Using an Artificial Neuronal Network. Energies, volume 14, número 21, página 7345.

CARNEIRO, J. R. C. Durabilidade de materiais geossintéticos em estruturas de carácter ambiental – A importância da incorporação de aditivos químicos. 2009. 602f. Tese de Doutorado – Universidade do Porto, Portugal, 2009.

CARROLL, R. G., Jr. (1983). Geotextile filter criteria. Engineering Fabrics in Transportation Construction, TRB 916, Washington, D.C., pp. 46-53.

CHANG, D. S. & ZHANG, L. M. (2013). Extended internal stability criteria for soils under seepage. Soils and Foundations, volume 53, número 4, páginas 569–583.

CHAO, Z., FOWMES, G., DASSANAYAKE, S. M. (2021). Comparative Study of Hybrid Artificial Intelligence Approaches for Predicting Peak Shear Strength Along Soil-Geocomposite Drainage Layer Interfaces. International Journal of Geosynthetics and Ground Engineering, volume 7, número 3.

CHARNET, R., FREIRE, C. A. de F., BONVINO, H., CHARNET, E. M. R. (2008). Análise de Modelos de Regressão Linear com Aplicações. UNICAMP.

CHARYTONIUK, W., BOX, E.D., LEE, W.-J., MO-SHING, K.P., VAN OLINDA, P. (2000). Neural-Network-Based Demand Forecasting in Deregulated Environment. *IEEE Transactions on Industry Applications*, volume 36, número 3, páginas 31-44.

CHAVES, J. F. N., EVANGELISTA JUNIOR, F., RÊGO, J. H. da S., VASQUES, L. de P. (2023). Dataset construction and data science analysis of physicochemical characterization of ordinary Portland cement. *Revista IBRACON de Estruturas e Materiais*, volume 16, número 6, páginas 1–13.

CHESTER, D.L. (1990). Why two hidden layers are better than one, Proc. of 4th IEEE Annual Int'l Conf. on Neural Networks, pp. 1.265-1.268, Washington, DC, NJ, USA, Jan. 15-19.

CHOU, J.S., Chong, W.K. and Bui, D.K., 2016. Nature-inspired metaheuristic regression system: programming and implementation for civil engineering applications. *Journal of Computing in Civil Engineering*, 30(5), p.04016007

CHOU, J.S. and Pham, A.D. (2013). Enhanced artificial intelligence for ensemble approach to predicting high performance concrete compressive strength. *Construction and Building Materials*, 49, pp.554-563.

CHRISTOPHER, B.R. & FISHER, G.R. (1992). Geotextile Filtration Principles, Practices and Problems. *Journal of Geotextile and Geomembranes*, Elsevier, 11, 4–6, pp. 337–354.

CHRISTOPHER, B.R. & HOLTZ, R.D. (1985). Geotextile Engineering Manual. Report FHWA-TS-86/203.

CHUNG, Y. & KUSIAK, A. (1994). Grouping parts with a neural network, *Journal of Manufacturing Systems*, Vol.13, No.4, pp. 262-75.

COHN, R., HOLM, E. (2021). Unsupervised Machine Learning Via Transfer Learning and k-Means Clustering to Classify Materials Image Data. *Integr Mater Manuf Innov*, 10, 231–244.

CORTES, C., VAPNIK, V. (1995). Support-vector networks. *Machine Learning*, 20, 273–297.

CYBENKO, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control Signals and Systems*, 2(4), 303-314.

DAS, B.M. (2010). *Principles of Foundation Engineering*, 7th ed. Cengage Learning, USA.

DEDE, T., KANKAL, M., VOSOUGHI, A. R., GRZYWIŃSKI, M., & KRIPKA, M. (2019). Artificial intelligence applications in civil engineering. *Advances in Civil Engineering*, volume 2019.

DEBNATH, P. & DEY, A. K. (2017). Prediction of Laboratory Peak Shear Stress Along the Cohesive Soil–Geosynthetic Interface Using Artificial Neural Network. *Geotechnical and Geological Engineering*, volume 35, número 1, páginas 445–461.

DEEPAI. (2023a). Autoencoder definition. Acesso em: 15 jul. 2024. Disponível em:

<https://deepai.org/machine-learningglossary-and-terms/autoencoder>.

DU, C., XU, C., YANG, Y., WANG, J. (2022). Filtration performance of nonwoven geotextile filtering fine-grained soil under normal compressive stresses. *Applied Sciences* (Switzerland), 12(24), 12638.

ESCOVEDO, T. & KOSHIYAMA, A. S. (2020). *Introdução a Data Science — Algoritmos de Machine Learning e métodos de análise*. São Paulo, Ed. Casa do Código.

EVANGELISTA JUNIOR, F., ALMEIDA, I. F. (2021). Machine learning RBF-based surrogate models for uncertainty quantification of age and time-dependent fracture mechanics. *Engineering Fracture Mechanics*, volume 258, páginas 1–15.

FAHLMAN, S.E. & LEBIERE, C. (1990). The cascade correlation learning architecture, In: *Advances in Neural Information Processing Systems*, H, D.S. Touretzky, (Ed.), Morgan Kaufmann , San Mateo, CA, USA

FAUSSETT, L.V. (1994). *Fundamentals of Neural Networks: Architecture, Algorithms, and Applications*. Prentice Hall, New Jersey.

FISHER, A., RUDIN, C., & DOMINICI, F. (2019). All models are wrong, but many are useful: Learning a variable's importance by studying an entire class of prediction models simultaneously. *Journal of Machine Learning Research*, 20(177), 1-81.

FLET-BERLIAC, Y., FERRET, J., PIETQUIN, O., et al., 2021. Adversarially Guided Actor-Critic. arXiv:2102.04376v1.

FREITAS, R. A. (2003). Comportamento de geotêxteis como filtro em resíduo – Fosfogesso e Lama Vermelha. Dissertação de mestrado. COPPE/UFRJ, Rio de Janeiro.

FUNAHASHI, K. (1989). On the approximate realization of continuous mappings by neural networks. *Neural Networks*, 2(3), 183-192.

GARDNER, M. W. & DORLING, S. R. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14-15), 2627-2636.

GARDONI, M. G. A. (1995). Avaliação da aplicabilidade de ensaios de laboratório e critérios de filtros para a utilização de geotêxteis em solos do Distrito Federal. Universidade de Brasília, Brasília.

GARDONI, M.G.A. (2000). Estudo do Comportamento Dreno-Filtrante de Geossintéticos sob Compressão. Tese de Doutorado, Publicação G.TD-003A/2000, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 313 p.

GÉRON, A. (1999). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. Prentice-Hall.

GHAHRAMANI, Z. (2016). A history of Bayesian neural networks. In NIPS workshop on

Bayesian deep learning.

GIROUD, J. P. (2010). Development of criteria for geotextile and granular filters. In Proceedings of the 9th International Conference on Geosynthetics, páginas 45–65.

GLOROT, X., BORDES, A. & BENGIO, Y. (2011). Deep Sparse Rectifier Neural Networks. Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, in Proceedings of Machine Learning Research 15:315-323.

GRIBB, M. M., & GRIBB, G. W. (1994). Use of neural networks for hydraulic conductivity determination in unsaturated soil. In: Proceedings of the 2nd International Conference on Ground Water Ecology, J.A. Stanford and H.M. Valett (Eds.), Bethesda MD: Amer, Water Resources Assoc., páginas 155–163.

HABIBI, M. J., MOKHTARI, A. R., BAGHBANAN, A., NAMDARI, S. (2014). Prediction of permeability in dual fracture media by multivariate regression analysis. Journal of Petroleum Science and Engineering, volume 120, páginas 194–201.

HADI SALEHI, R. & BURGUEÑO, R. (2018). Emerging artificial intelligence methods in structural engineering. Engineering Structures, volume 171, páginas 170–189.

HASTIE, T. et al. (2024). The elements of statistical learning. Springer, pp 305-324.

HATAF, N. & SOLEIMANBEIGI, A. (2006). Prediction of settlement of shallow foundations on reinforced soils using neural networks. Geosynthetics International, volume 13, páginas 161–170.

HAYKIN, S. (1999). Neural Networks: A Comprehensive Foundation. Prentice-Hall.

HECHT-NELSON, R. (1987). Kolmogorov's mapping neural network existence theorem, Proc. of 1st IEEE Annual Int'l Conf. on Neural Networks, pp. III.11-111.14, San Diego, NJ, USA, June 21-24.

HEATON, J. et al. (2018). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning. Genet Program Evolvable Mach, 19, páginas 305–307. <https://doi.org/10.1007/s10710-017-9314-z>

HERTZ, J., KROGH, A., PALMER, R. G., & HORNER, H. (1991). Introduction to the Theory of Neural Computation. Physics Today, 44(12), 70. <https://doi.org/10.1063/1.2810360>

HONG, Y.S. and WU, C.S., 2011. Filtration behaviour of soil-nonwoven geotextile combinations subjected to various loads. Geosynthetics International, 29(2), pp.102-115.

HUANG, Y., & FU, J. (2019). Review on application of artificial intelligence in civil engineering. Computer Modeling in Engineering & Sciences, volume 121, número 3, páginas 845–875.

IBM. (2023a). What is machine learning?. Acesso em: 17 jul. 2024. Disponível em: <https://www.ibm.com/topics/machinelearning>.

IBM. (2023b). What is unsupervised learning?. Acesso em: 5 jul. 2024. Disponível em: <https://www.ibm.com/topics/unsupervised-learning>.

JAMES, Gareth; WITTEN, Daniela; HASTIE, Trevor; TIBSHIRANI, Robert. (2021) *An Introduction to Statistical Learning: with Applications in R*. 2. ed. New York: Springer,

JAIN, A.K., MAO, J., MOHIUDDIN, K.M. (1996). Artificial neural work approach. In: Dagli, C.H. et al. (Eds.), Proceedings networks: a tutorial. Comput. IEEE March, 31–44.

JAMES, G., WITTEN, D., HASTIE, T., & TIBSHIRANI, R. (2013). An introduction to statistical learning. In: Springer Texts in Statistics (STS, V.103). Springer, pp. 59e127.

JANG, B., KIM, M., HARERIMANA, G., & KIM, J. W. (2019). Q-Learning Algorithms: A Comprehensive Classification and Applications. In IEEE Access, vol. 7, pp. 133653-133667.

JEREMIAH, J., ABBEY, S., BOOTH, C., & KASHYAP, A. (2021). Results of Application of Artificial Neural Networks in Predicting Geo-Mechanical Properties of Stabilised Clays-A Review. Geotechnics, 1, 147-171.

JONES, D. R., SCHONLAU, M., & WELCH, W. J. (1998). Efficient global optimization of expensive black-box functions. Journal of Global optimization, 13(4), 455–492.

KABIR, M. A. & LUO, X. (2020). Unsupervised Learning for Network Flow Based Anomaly Detection in the Era of Deep Learning. 2020 IEEE Sixth International Conference on Big Data Computing Service and Applications (BigDataService), Oxford, UK, pp. 165-168.

KAOSER, S., BARRINGTON, S., ELEKTOROWICZ, M., & AYADAT, T. (2006). The influence of hydraulic gradient and rate of erosion on hydraulic conductivity of sand-bentonite mixtures. Soil & Sediment Contamination, 15(5), 481-496.

KASEKO, M. S., & RITCHIE, S. G. (1993). A neural network-Expert system hybrid approach for tunnel design. In: Transportation Research Part C: Emerging Technologies, volume 1, número 4, páginas 275–291.

KENNEY, T. C. & LAU, D. (1985). Internal stability of granular filters. Em J, volume 22.

KEZDI, A. A. (1969). Increase of Protective Capacity of Flood Control Dikes. Department of Geotechnique. Technical University, Budapest, Hungary. Report no. 1 (in Hungarian).

KHAN, M. W., DAWSON, A. R., MARSHALL, A. M. (2022). Filtration performance of non-woven geotextiles with internally-stable and -unstable soils under dynamic loading. Geotextiles and Geomembranes, volume 50, número 2, páginas 293–311.

KHANLARI, G. R., HEIDARI, M., MOMENI, A. A., ABDILOR, Y. (2012). Prediction of shear strength parameters of soils using artificial neural networks and multivariate regression methods. Engineering Geology, volume 131–132, páginas 11–18.

KOERNER, R. M. (2005). Designing with Geosynthetics, fifth Edition, Prentice-Hall Inc.,

Upper Saddle River, New Jersey, USA, pp 29-157.

KOERNER, R. M. (2016). Geotextiles: From Design to Applications. Woodhead Publishing.

KOERNER, R. M. & KOERNER, G. R. (2015). Lessons learned from geotextile filter failures under challenging field conditions. *Geotextiles and Geomembranes*, volume 43, número 3, páginas 272–281.

KUSHNER, H. J. (1964). On the dynamical equations of conditional probability density functions, with applications to optimal stochastic control theory. *Journal of Mathematical Analysis and Applications*, 8(2), 332-344.

KUSIAK, A. & LEE, H. (1996). Neural computing based design of components for cellular manufacturing. *International Journal of Production Research*, 34(11), 3295-3310.

LACHTERMACHER, G., FULLER, J.D. (1994). Backpropagation in Hydrological Time Series Forecasting. In: Hipel, K.W., McLeod, A.I., Panu, U.S., Singh, V.P. (eds) Stochastic and Statistical Methods in Hydrology and Environmental Engineering. Water Science and Technology Library, vol 10/3. Springer, Dordrecht. https://doi.org/10.1007/978-94-017-3083-9_18

LAFLEUR, J. (1999). Selection of geotextiles to filter broadly graded cohesionless soils. *Geotextiles and Geomembranes*, 17(5-6), pp.299-312.

LAFLEUR, J.; MLYNAREK, J. & ROLLIN, A.L. (1989). Filtration of broadly graded cohesionless soils. *Journal of Geotechnical Engineering*, 115 (12): 1747–1768.

LAGAROS, N. D., & PLEVRIS, V. (2022). Artificial intelligence (AI) applied in civil engineering. *Applied Sciences*, volume 12, número 15, página 7595.

LANTZ, B. (2013). Machine Learning with R: Learn How to Use R to Apply Powerful Machine Learning Methods and Gain an Insight into Real-World Applications. Packt Publishing.

LAWRENCE, J. (1994). Introduction to Neural Networks: Design, Theory, and Applications, 6th ed. Nevada City, CA: California Scientific Software.

LAWRENCE, J. & FREDRICKSON, J. (1998). BrainMaker User's Guide and Reference Manual, 7th Ed., Nevada City, CA: California Scientific Software.

LAWSON, C. R. (1990). Geotextile filter performance with fine grained soils. In 4th Int. Conf. on Geotextiles, Geornembranes and Related Products (pp. 301-6).

LEE, I.M., KIM, J.H. and REDDI, L.N., 2002. Clogging phenomena of the residual soil-geotextile filter system. *Geotechnical Testing Journal*, 25(4), pp.379-390.

LEE, S. and Bourdeau, P.L., 2006. Filter performance and design for highway drains. Joint Transportation Research Program, p.266.

LEITE, A. R. S. (2019). Aplicações de Redes Neurais Artificiais para Previsão do

Comportamento Cisalhante em Descontinuidade de Maciços Rochosos. Dissertação de Mestrado. Universidade Federal do Ceará.

LEVER, J., KRZYWINSKI, M. & ALTMAN, N. (2017). Principal component analysis. *Nat Methods*, 14, 641–642.

LIU, H., SU, H., SUN, L., DIAS-DA-COSTA, D. (2024). State-of-the-art review on the use of AI-enhanced computational mechanics in geotechnical engineering. *Artificial Intelligence Review*, volume 57.

LIU, J. (2005). *Seepage Control of Earth-Rock Dams: Theoretical Basis, Engineering Experiences and Lessons*. China Waterpower Press, Beijing (in Chinese).

M. PINHO-LOPES, A. M. PAULA, M. L. LOPES; Long-term response and design of two geosynthetics: effect of field installation damage. *Geosynthetics International* 1 February 2018; 25 (1): 98–117.

MARCHANDANI, G. & CAO, W. (1989). On hidden nodes for neural nets, *IEEE Trans. on Circuits and Systems*, Vol.36, No.5, pp. 661-664.

MARKIEWICZ, A., KODA, E., KAWALEC, J. (2022). Geosynthetics for Filtration and Stabilisation: A Review. Em *Polymers*, MDPI, volume 14, número 24.

MARRAPU, B., & JAKKA, R. (2017). Assessment of slope stability using multiple regression analysis. *Geomechanics and Engineering*, volume 13, número 2, páginas 237–254.

MELO, D. L. A. (2018). Avaliação da Abertura de Filtração de Geotêxteis Não Tecidos Sob Diferentes Esforços Solicitantes. Dissertação de Mestrado, Publicação no G.DM – 310/18, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 99p.

MINGOTI, S. A. (2005). Análise de Dados Através de Métodos de Estatística Multivariada: Uma Abordagem Aplicada.

MISZKOWSKA, A., LENART, S., & KODA, E. (2017). Changes of permeability of nonwoven geotextiles due to clogging and cyclic water flow in laboratory conditions. *Water*, 9(9), 660.

MOČKUS, J. (1975). Optimization techniques IFIP technical conference. In *Optimization Techniques IFIP Technical Conference*.

MOHAMMADI, M., FATEMI AGHDA, S. M., TALKHABLOU, M., CHESHOMI, A. (2022). Prediction of the shear strength parameters from easily-available soil properties by means of multivariate regression and artificial neural network methods. *Geomechanics and Geoengineering*, volume 17, número 2, páginas 442–454.

MONTOYA BOTERO, E. (2013). *Modelo de Alerta de Escorregamentos Deflagrados por Chuvas usando Redes Neurais Artificiais*. Dissertação de Mestrado. Universidade de Brasília.

MORAES FILHO, I.P. (2018). Avaliação da abertura de filtração de geotêxteis sob diferentes condições de solicitação mecânica. Dissertação de Mestrado, Publicação G.DM-297/2018,

Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 122 p.

MORACI, N. (2010). Geotextile filter: Design, characterization and factors affecting clogging and blinding limit states. In Proceedings of the 9th International Conference on Geosynthetics, páginas 413–435.

MORACI, N., MANDAGLIO, M. C., IELO, D. (2014). Analysis of the internal stability of granular soils using different methods. Canadian Geotechnical Journal, volume 51, número 9, páginas 1063–1072.

MUKAKA, M. M. (2012). A guide to appropriate use of correlation coefficient in medical research. Malawi medical journal, 24(3), 69-71.

NASSAR, M., ALI, A. M., EL SHAFFA, W., SALEEB, A. A., ABD EL-SAMIE, F. E., AL EISA, H. N., & AHMED, H. E. H. (2023). Hybrid of Distributed Cumulative Histograms and Classification Model for Attack Detection. Comput. Syst. Eng., 45(2), 2235–2247.

NGiam, J., Khosla, A., Kim, M., Nam, J., Lee, H., & Ng, A. (2011). Multimodal Deep Learning. Proceedings of the 28th International Conference on Machine Learning, ICML 2011. 689-696.

NGUYEN, V. (2019). Bayesian optimization for accelerating hyper-parameter tuning. In 2019 IEEE second international conference on artificial intelligence and knowledge engineering (AIKE), pp. 302-305. IEEE.

ODABASI, E., DAYIOGLU, A. Y., DEMIR YETIS, A., AYDILEK, A. H. (2023). Long-term hydraulic performance of geotextiles filtering recycled materials. Geosynthetics International, volume 30, número 2, páginas 137–153.

PACHEPSKY, Ya A., TIMLIN, Dennis, & VARALLYAY, G. Y. (1996). Artificial neural networks to estimate soil water retention from easily measurable data. Soil Science Society of America Journal, volume 60, número 3, páginas 727-733.

PALMEIRA, E. M. (2003). Notas de Aula de Ensaios em Geossintéticos, Propriedades de Filtração, Determinação da Abertura de Filtração de Geotêxteis. Departamento de Engenharia Civil, Universidade de Brasília, Brasília, DF, 39p.

PALMEIRA, E. M. (2018). Geossintéticos em geotecnia e meio ambiente. Oficina de Textos.

PALMEIRA, E. M. (2020). A review on some factors influencing the behaviour of nonwoven geotextile filters. Soils and Rocks, vol. 43, no 3, pp. 351-368.

PALMEIRA, E. M. (2023). Geotextile filters. From idealization to real behaviour. 12th International Conference on Geosynthetics, páginas 1–40.

PALMEIRA, E.M. & GARDONI, M.G., (2002). Drainage and filtration properties of non-woven geotextiles under confinement using different experimental techniques. Geotextiles and Geomembranes 20(2), pp. 97-115.

PALMEIRA, E. M., GARDONI, M. G., BESSA DA LUZ, D. W. (2025). Soil-geotextile filter

interaction under high stress levels in the gradient ratio test. *Geosynthetics International*, volume 4, número 12, páginas 162–175.

PALMEIRA, E. M. & GALVIS, H. (2018). Evaluation of predictions of nonwoven geotextile pore size distribution under confinement. *Geosynthetics International*, volume 25, páginas 1–42.

PALMEIRA, E.M., FANNIN, R.J. and VAID, Y.P., 1997. A study on the behaviour of soil geotextile systems in filtration tests. *Canadian Geotechnical Journal*, 33(6), pp.899-912.

PALMEIRA, E. M. & TREJOS GALVIS, H. L. (2018). Evaluation of predictions of nonwoven geotextile pore size distribution under confinement. *Geosynthetics International*, volume 25, número 2, páginas 230–241.

PALMEIRA, E.M., SOUZA, M.V., SANTOS, D.S.C. & GÓNGORA, I.A.M.G. (2025). Study on the hydraulic properties of internally unstable soil-nonwoven geotextile systems: Boundary values and preliminary estimates. *Geotextiles and Geomembranes*, 53 (2): 588-606.

PARK, H. I. (2011). Study for application of artificial neural networks in geotechnical problems. *Artificial neural networks-application*, 303-336.

PINHO LOPES, M. & LOPES, M. (2010). A Durabilidade dos Geossintéticos. 1^a edição. Porto, Portugal.

PINTO, G. H. da S. (2023). Proposta de modelos de predição da resistência não drenada de rejeitos de bauxita. Dissertação de Mestrado. Universidade Federal de Ouro Preto.

POTHUGANTI, S. (2018). Review on over-fitting and under-fitting problems in Machine Learning and solutions. *International Journal of Advanced Research in Electrical Electronics and Instrumentation Engineering*, 7, 3692-3695.

QURESHI, S., KOGLER, R. M., BHATIA, S. K. (1990). Long-term clogging behaviour of non-woven geotextiles with silty and gap-graded sands. *Em Geotextiles and Geomembranes*, volume 7.

RAY, S. (2019). A Quick Review of Machine Learning Algorithms. In: 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon), Faridabad, India, pp. 35-39, doi: 10.1109/COMITCon.2019.8862451.

REICH, Y. (1997). Machine learning techniques for civil engineering problems. *Computer-Aided Civil and Infrastructure Engineering*, v. 12, n. 4, p. 295-310.

RIEDMILLER, M. and BRAUN, H. (1993) A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. *Proceedings of the IEEE International Conference on Neural Networks*, San Francisco, 28 March-1 April 1993, 586-591.

RODERICK, M., MACGLASHAN, J., & TELLEX, S. (2017). Implementing the Deep Q-Network. arXiv:1711.07478v1.

ROLLIN, A. L. & LOMBARD, G. (1988). Mechanisms Affecting Long-Term Filtration Behavior of Geotextiles. Em Geotextiles and Geomembranes, volume 7.

RUMELHART, D. E., HINTON, G. E., & WILLIAMS, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323, 533-536.

SANTOS, A. E. M. (2021). Classificação de maciços rochosos por meio de técnicas de estatística multivariada e inteligência artificial. Tese de Doutorado. Universidade Federal de Ouro Preto.

SANTOS, D. (2023). Comportamento de filtros geotêxteis em solos internamente instáveis sob confinamento. Dissertação de Mestrado. Universidade de Brasília.

SANTOS, L., RESENDE, C., MARTINS, K., QUEVEDO, R., & LOPEZ, M. (2025). Comparative Analysis of Slope Stability Prediction for Earth Dams Using Response Surface Method, Statistical Models, and ANN. *Geotechnical and Geological Engineering*, volume 43. <https://doi.org/10.1007/s10706-025-03138-7>.

SARDEHAEI, E. A. & MEHRJARDI, G. T. (2020). Winter 2020 Downloaded from jeg. Em *Journal of Engineering Geology*, volume 13, páginas 1–22.

SCHAAP, M. G., & BOUTEN, W. (1996). Modeling water retention curves of sandy soils using neural networks. *Water Resources Research*, volume 32, número 10, páginas 3033-3040.

SCHOBER, P., BOER, C., & SCHWARTE, L. A. (2018). Correlation coefficients: appropriate use and interpretation. *Anesthesia & analgesia*, 126(5), 1763-1768.

SHAHIN, M. A., JAKSA, M. B., & MAIER, H. R. (2000). Predicting the settlement of shallow foundations on cohesionless soils using back-propagation neural networks. Research Report No. R 167, The University of Adelaide, Adelaide.

SHAHIN, M. A. (2013). Artificial intelligence in geotechnical engineering: applications, modeling aspects, and future directions. In: *Metaheuristics in Water, Geotechnical and Transport Engineering*, pp. 169–204.

SIDDIQUE, N., & ADELI, H. (2013). Computational intelligence: synergies of fuzzy logic, neural networks and evolutionary computing. John Wiley & Sons.

SILVA, D. L., JESUS, K. L. M. D., ADINA, E. M., MANGROBANG, D. V., ESCALANTE, M. D., SUSI, N. A. M. (2021). Prediction of Tensile Strength and Erosional Effectiveness of Natural Geotextiles Using Artificial Neural Network. 2021 13th International Conference on Computer and Automation Engineering, ICCAE 2021, páginas 12

SNOEK, J., LAROCHELLE, H., & ADAMS, R. P. (2012). Practical bayesian optimization of machine learning algorithms. *Advances in neural information processing systems*, 25.

STERLING, R. L., & LEE, C. A. (1992). A neural network-Expert system hybrid approach for tunnel design. In: Paper presented at the 33rd U.S. Symposium on Rock Mechanics (USRMS), Santa Fe, New Mexico, June 1992.

SWINGLER, K. (1996). Applying Neural Networks: A Practical Guide. San Francisco: Morgan Kaufmann Publishers.

TANGA, A. T., ARAÚJO, G. L. S., & EVANGELISTA JUNIOR, F. (2025). A comparison between geomembrane-sand tests and machine learning predictions. *Geosynthetics International*, volume 32, número 2, páginas 180–193.

TURNER, R., ERIKSSON, D., MCCOURT, M., KIILI, J., LAAKSONEN, E., XU, Z. and GUYON, I., 2021. Bayesian optimization is superior to random search for machine learning hyperparameter tuning: Analysis of the black-box optimization challenge 2020. In NeurIPS 2020 competition and demonstration track (pp. 3-26). PMLR.

WILLIAMS, C., & RASMUSSEN, C. (1995). Gaussian processes for regression. *Advances in neural information processing systems*, 8.

WILLIAMS, N. D., & ABOUZAKHM, M. A. (1989). Evaluation of geotextile/soil filtration characteristics using the hydraulic conductivity ratio analysis. *Geotextiles and Geomembranes*, volume 8, número 1, páginas 1-26. [https://doi.org/10.1016/0266-1144\(89\)90008-3](https://doi.org/10.1016/0266-1144(89)90008-3)

WILLIAMS, N. D., & LUETTICH, S. M. (1990). Laboratory measurement of geotextile filtration characteristics. In: *Proceedings, 4th International Conference on Geotextiles*. 1990. p. 273-278.

WU, J., CHEN, X.Y., ZHANG, H., XIONG, L.D., LEI, H. & DENG, S.H. (2019). Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*. 17. 26-40. 10.11989/JEST.1674-862X.80904120.