



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E AMBIENTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

JOYCE PASCOAL DE OLIVEIRA SILVA

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS DO TIPO PERCEPTRON PARA
PREVISÃO DA CONDUTIVIDADE HIDRÁULICA EM SOLOS NÃO SATURADOS**

FORTALEZA/CE

2020

JOYCE PASCOAL DE OLIVEIRA SILVA

APLICAÇÃO DE REDES NEURAIAS ARTIFICIAIS DO TIPO PERCEPTRON PARA
PREVISÃO DA CONDUTIVIDADE HIDRÁULICA EM SOLOS NÃO SATURADOS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para obtenção do Título de Mestre em Engenharia Civil. Área de concentração: Geotecnia.

Orientador: Prof. Dr. Silvrano A. Dantas Neto

FORTALEZA/CE

2020

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária

S58a

Silva, Joyce Pascoal de Oliveira.

Aplicação de redes neurais artificiais do tipo perceptron para previsão da condutividade hidráulica em solos não saturados / Joyce Pascoal de Oliveira Silva. – 2020.
212 f.: il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Hidráulica e Ambiental, Programa de Pós-Graduação em Engenharia Civil: Geotecnia, Fortaleza, 2020.

Área de concentração: Geotecnia.

Orientação: Prof. Dr. Silvrano Adonias Dantas Neto.

1. Curva de retenção. 2. Sucção matricial. 3. Perceptron multicamadas. 4. Algoritmo de retropropagação do erro. I. Título.

CDD 624.15

JOYCE PASCOAL DE OLIVEIRA SILVA

APLICAÇÃO DE REDES NEURAIIS ARTIFICIAIS DO TIPO PERCEPTRON PARA
PREVISÃO DA CONDUTIVIDADE HIDRÁULICA EM SOLOS NÃO SATURADOS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Ceará, como requisito parcial para obtenção do Título de Mestre em Engenharia Civil. Área de concentração: Geotecnia.

Orientador: Prof. Dr. Silvrano A. Dantas Neto

Aprovada em: 08 / 12 / 2020.

BANCA EXAMINADORA

Prof. Dr. Silvrano Adonias Dantas Neto (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco Chagas da Silva Filho (Examinador Interno)
Universidade Federal do Ceará (UFC)

Prof^a. Dr^a. Márcia Maria dos Anjos Mascarenha (Examinadora Externa)
Universidade Federal de Goiás (UFG)

A Deus.

À minha mãe, minha grande incentivadora.

AGRADECIMENTOS

A Deus por me conceder a graça da vida e por sempre me dar forças e me confortar nos momentos difíceis.

À minha mãe Valeska Pascoal, ao meu irmão José Cláudio e ao meu cunhado Denysleo Lopes por serem minhas inspirações e meu porto seguro.

Às minhas amigas Cíntia Castro e Natália Canuto por todo o carinho, companheirismo, suporte e amizade. Sem dúvidas, pessoas especiais que eu tive o prazer de conhecer no mestrado!

Às minhas amigas Nássara Martins, Laryssa Luma e Joeuda Cândido por sempre se fazerem presentes, apoiando-me e incentivando-me em momentos importantes da minha vida.

À minha alma gêmea Ana Viana pelo carinho, pelas longas conversas, por todo o incentivo, por acreditar em mim e me fazer acreditar também. Muito obrigada pela sua amizade!

Aos meus colegas de curso Marlon Vieira, Yuri Saraiva e Abraham Augusto pela amizade e colaboração, dentro e fora da sala de aula.

Ao Prof. Dr. Silvrano Adonias Dantas Neto pelas orientações, conselhos, disponibilidade, incentivo e ensinamentos.

Aos professores do Programa de Pós-Graduação pelo conhecimento transmitido durante o mestrado em Geotecnia.

Aos professores participantes da banca examinadora pelo tempo dedicado à avaliação deste trabalho e pelas valiosas sugestões.

À Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Ceará.

A todos que direta ou indiretamente contribuíram para a realização deste sonho, muito obrigada!

“Feliz aquele que transfere o que sabe e aprende
o que ensina.”

Cora Coralina

RESUMO

A determinação da condutividade hidráulica em solos não saturados é essencial ao realizar análises de fluxo nesses meios porosos. No entanto, a execução de ensaios de laboratório e de campo para a determinação dessa propriedade hidráulica não é prática corrente no âmbito da geotecnia, por se tratar de procedimentos demorados e dispendiosos. As redes neurais artificiais (RNA) têm sido bastante empregadas em Mecânica dos Solos, permitindo a estimativa de uma forma fácil e simples de fenômenos complexos e multivariados. Desse modo, esta dissertação tem como objetivo apresentar um modelo de estimativa da condutividade hidráulica em solos não saturados desenvolvido a partir de um tipo de RNA conhecido como perceptron multicamadas (MLP). As variáveis de entrada do modelo são: índice de vazios inicial, teor de umidade gravimétrico inicial, percentuais de areia, silte e argila, índice de plasticidade, coeficiente de permeabilidade saturado e sucção matricial. Durante a modelagem, um total de 275 exemplos foram utilizados, dos quais 85% foram empregados na fase de treinamento, e 15% na fase de teste. O modelo proposto possui a arquitetura A: 8-4-2-1 e apresentou coeficiente de correlação de 0,97 após 500 mil iterações em ambas as fases de treinamento e de teste. Os resultados do modelo se ajustaram satisfatoriamente aos dados experimentais utilizados nas fases de treinamento e de teste, e a rede neural proposta foi capaz de representar a influência das variáveis de entrada no comportamento hidráulico de diferentes tipos de solo.

Palavras-chave: Curva de retenção. Sucção matricial. Perceptron multicamadas. Algoritmo de retropropagação do erro.

ABSTRACT

The determination of hydraulic conductivity in unsaturated soils is essential when performing flow analysis in these porous media. However, the execution of laboratory and field tests to determine this hydraulic property is not a current practice in the scope of geotechnics, as these are time-consuming and expensive procedures. Artificial neural networks (ANN) have been widely used in Soil Mechanics, allowing the estimation of complex and multivariate phenomena in an easy and simple way. Thus, this dissertation aims to present a model for estimating hydraulic conductivity in unsaturated soils developed from a type of ANN known as multilayer perceptron (MLP). The model's input variables are: initial void ratio, initial gravimetric water content, sand content, silt content, clay content, plasticity index, saturated permeability coefficient and matric suction. During modeling, a total of 275 examples were used, of which 85% were used in the training phase, and 15% in the testing phase. The proposed model has an A: 8-4-2-1 architecture and presented a correlation coefficient of 0.97 after 500 thousand iterations in both training and testing phases. The results of the model adjusted satisfactorily to the experimental data used in the training and test phases, and the proposed neural network was able to represent the influence of the input variables on the hydraulic behavior of different types of soil.

Keywords: Retention curve. Matric suction. Multilayer perceptron. Error back-propagation algorithm.

LISTA DE FIGURAS

Figura 1 – Subdivisões da zona do solo não saturado (zona vadosa)-----	23
Figura 2 – Fases do solo não saturado -----	23
Figura 3 – Ascensão capilar da água em um tubo -----	25
Figura 4 – Detalhe da superfície de contato no tubo -----	25
Figura 5 – Menisco capilar -----	26
Figura 6 – Componentes da sucção total -----	27
Figura 7 – Curva de dessaturação típica para um solo siltoso -----	29
Figura 8 – Relação entre o teor de água volumétrico (θ), o índice de vazios (e) e o grau de saturação (S) -----	31
Figura 9 – Curva de retenção para areias com diferentes granulometrias -----	31
Figura 10 – Curva de retenção para diferentes tipos de solos -----	32
Figura 11 – Efeito da pressão de consolidação na curva de retenção -----	32
Figura 12 – Efeito da condição de compactação na curva de retenção-----	33
Figura 13 – Histerese da curva de retenção -----	34
Figura 14 – Comparação entre as curvas de condutividade hidráulica de um solo arenoso e de um solo siltoso-----	40
Figura 15 – Comparação entre as curvas de retenção de um solo arenoso e de um solo siltoso -----	40
Figura 16 – Equação de Gardner (1958) para a função de permeabilidade-----	42
Figura 17 – Grau de saturação em função da sucção matricial para diferentes tipos de solo -	43
Figura 18 – Valores de λ para diferentes tipos de solo -----	44
Figura 19 – Arquitetura de uma RNA multicamadas -----	49
Figura 20 – Representação em diagrama de blocos dos três estágios do sistema nervoso ----	50
Figura 21 – Neurônio biológico-----	51
Figura 22 – Mecanismo de produção de pulso elétrico em um neurônio biológico-----	52
Figura 23 – Neurônio artificial-----	53
Figura 24 – Relação entre vk e uk -----	54
Figura 25 – Grafo de fluxo de sinal representativo do neurônio k da camada de saída da rede neural -----	56
Figura 26 – Grafo de fluxo de sinal representativo do neurônio j da camada oculta da rede neural -----	59
Figura 27 – RNA usada para simular os efeitos das variáveis de entrada na permeabilidade	61

Figura 28 – Desempenho da RNA na previsão da permeabilidade em amostras de solo na fase de teste-----	62
Figura 29 – Relação entre a condutividade hidráulica não saturada medida e calculada usando o modelo desenvolvido com RNA no teste-----	64
Figura 30 – Perceptron multicamadas de arquitetura A: 10-10-1 -----	66
Figura 31 – Perceptron multicamadas de arquitetura A: 6-8-1 -----	67
Figura 32 – Comparação entre a condutividade hidráulica saturada medida e calculada pelo modelo A: 10-10-1-----	67
Figura 33 – Comparação entre a condutividade hidráulica saturada medida e calculada pelo modelo A: 6-8-1-----	68
Figura 34 – Relação entre a condutividade hidráulica não saturada medida e calculada usando o modelo A: 6-8-1-----	69
Figura 35 – Etapas de desenvolvimento do modelo de RNA-----	71
Figura 36 – Dispersão apresentada ao relacionar a sucção matricial e a condutividade hidráulica -----	74
Figura 37 – Dispersão apresentada ao relacionar o índice de vazios e a condutividade hidráulica -----	74
Figura 38 – Dispersão apresentada ao relacionar o teor de umidade gravimétrico e a condutividade hidráulica-----	75
Figura 39 – Dispersão apresentada ao relacionar o percentual de argila e a condutividade hidráulica-----	75
Figura 40 – Dispersão apresentada ao relacionar o percentual de silte e a condutividade hidráulica-----	76
Figura 41 – Dispersão apresentada ao relacionar o percentual de areia e a condutividade hidráulica-----	76
Figura 42 – Dispersão apresentada ao relacionar o índice de plasticidade e a condutividade hidráulica-----	77
Figura 43 – Dispersão apresentada ao relacionar o coeficiente de condutividade hidráulica saturado e não saturado-----	77
Figura 44 – Estrutura típica de um MLP considerando a configuração C1-----	78
Figura 45 – Distribuição de frequência do percentual de argila-----	81
Figura 46 – Distribuição de frequência do percentual de silte-----	82
Figura 47 – Distribuição de frequência do percentual de areia-----	82
Figura 48 – Distribuição de frequência do índice de vazios inicial-----	83

Figura 49 – Distribuição de frequência do teor de umidade gravimétrico inicial-----	83
Figura 50 – Distribuição de frequência do índice de plasticidade -----	84
Figura 51 – Distribuição de frequência da permeabilidade saturada -----	84
Figura 52 – Distribuição de frequência do sucção matricial -----	85
Figura 53 – Critério de parada antecipada para otimização da RNA -----	88
Figura 54 – Correlação para as cinco melhores arquiteturas de configuração C1 - Treinamento -----	95
Figura 55 – RMS para as cinco melhores arquiteturas de configuração C1 - Treinamento---	95
Figura 56 – Correlação para as cinco melhores arquiteturas de configuração C1 - Teste ----	96
Figura 57 – RMS para as cinco melhores arquiteturas de configuração C1 - Teste-----	96
Figura 58 – Correlação para as cinco melhores arquiteturas de configuração C2 - Treinamento -----	97
Figura 59 – RMS para as cinco melhores arquiteturas de configuração C2 - Treinamento---	97
Figura 60 – Correlação para as cinco melhores arquiteturas de configuração C2 - Teste ----	98
Figura 61 – RMS para as cinco melhores arquiteturas de configuração C2 - Teste-----	98
Figura 62 – Correlação para as cinco melhores arquiteturas de configuração C3 - Treinamento -----	99
Figura 63 – RMS para as cinco melhores arquiteturas de configuração C3 - Treinamento---	99
Figura 64 – Correlação para as cinco melhores arquiteturas de configuração C3 - Teste ----	100
Figura 65 – RMS para as cinco melhores arquiteturas de configuração C3 - Teste-----	100
Figura 66 – Início do <i>overtraining</i> para a arquitetura A: 6-12-8-1 de configuração C2-----	101
Figura 67 – Início do <i>overtraining</i> para a arquitetura A: 6-6-1 de configuração C3 -----	101
Figura 68 – Evolução do coeficiente de correlação no teste – Configuração C1 -----	102
Figura 69 – Evolução do coeficiente de correlação no teste – Configuração C2 -----	103
Figura 70 – Evolução do coeficiente de correlação no teste – Configuração C3 -----	103
Figura 71 – Comparação entre as funções de condutividade hidráulica para o Ensaio 3 – Arquitetura A: 8-4-2-1 -----	104
Figura 72 – Comparação entre as funções de condutividade hidráulica para o Ensaio 3 – Arquitetura A: 8-10-5-2-1 -----	105
Figura 73 – Comparação entre as funções de condutividade hidráulica para o Ensaio 4 – Arquitetura A: 8-4-2-1 -----	105
Figura 74 – Comparação entre as funções de condutividade hidráulica para o Ensaio 4 – Arquitetura A: 8-10-5-2-1 -----	106

Figura 75 – Comparação entre as funções de condutividade hidráulica para o Ensaio 7 – Arquitetura A: 8-4-2-1 -----	106
Figura 76 – Comparação entre as funções de condutividade hidráulica para o Ensaio 7 – Arquitetura A: 8-10-5-2-1 -----	107
Figura 77 – Comparação entre as funções de condutividade hidráulica para o Ensaio 11 – Arquitetura A: 8-4-2-1 -----	107
Figura 78 – Comparação entre as funções de condutividade hidráulica para o Ensaio 11 – Arquitetura A: 8-10-5-2-1 -----	108
Figura 79 – Comparação entre as funções de condutividade hidráulica para o Ensaio 14 – Arquitetura A: 8-4-2-1 -----	108
Figura 80 – Comparação entre as funções de condutividade hidráulica para o Ensaio 14 – Arquitetura A: 8-10-5-2-1 -----	109
Figura 81 – Comparação entre as saídas calculadas pelo modelo desenvolvido (A: 8-4-2-1) e os dados experimentais no treinamento -----	110
Figura 82 – Comparação entre as saídas calculadas pelo modelo desenvolvido (A: 8-4-2-1) e os dados experimentais no teste -----	111
Figura 83 – Correlação entre as saídas calculadas pelo modelo desenvolvido (A: 8-4-2-1) e os dados experimentais no treinamento e no teste -----	111
Figura 84 – Arquitetura do modelo definitivo de previsão da condutividade hidráulica de solos não saturados (A: 8-4-2-1)-----	113
Figura 85 – Seção transversal da barragem Olho d’Água utilizada na análise de fluxo -----	115
Figura 86 – Comparação entre as funções de condutividade estimadas pelo modelo de RNA (corrigida e não corrigida) e pelo modelo de Van Genuchten (1980) -----	117
Figura 87 – Evolução das poropressões em um ponto próximo ao talude de montante – P (55,6) -----	118
Figura 88 – Evolução das poropressões em um ponto próximo ao dreno – P (113,4) -----	119
Figura 89 – Evolução das poropressões em um ponto na região central do maciço – P (86,12) -----	119
Figura 90 – Análise de fluxo com o uso dos dados obtidos por Araújo (2013)-----	120
Figura 91 – Análise de fluxo com o uso do modelo de RNA proposto (A: 8-4-2-1)-----	120
Figura 92 – Análise de fluxo com o uso do modelo de Van Genuchten (1980) -----	121

LISTA DE TABELAS

Tabela 1 – Equações de ajuste para a curva de retenção -----	36
Tabela 2 – Características do modelo que obteve o melhor desempenho-----	63
Tabela 3 – Critérios de erro na fase de teste -----	63
Tabela 4 – Percentuais de contribuição das variáveis de entrada para o modelo de RNA desenvolvido-----	64
Tabela 5 – Medidas da eficiência dos modelos -----	65
Tabela 6 – Análise da sensibilidade global-----	66
Tabela 7 – Configurações consideradas para as variáveis de entrada -----	73
Tabela 8 – Quantidade de exemplos utilizados por referência para C1 e C2-----	79
Tabela 9 – Quantidade de exemplos utilizados por referência para C3 -----	80
Tabela 10 – Estatísticas dos dados do conjunto experimental-----	81
Tabela 11 – Quantidade de arquiteturas analisadas para cada tipo de configuração das variáveis de entrada -----	89
Tabela 12 – Arquiteturas analisadas para cada tipo de configuração das variáveis de entrada -----	90
Tabela 13 – Resumo das arquiteturas utilizadas no primeiro estágio da fase de validação --	102
Tabela 14 – Quantidade de saídas negativas -----	109
Tabela 15 – Percentual de contribuição das variáveis de entrada-----	112
Tabela 16 – Valores dos pesos sinápticos e bias entre a camada de entrada e a 1ª camada oculta do modelo de previsão desenvolvido-----	114
Tabela 17 – Valores dos pesos sinápticos e bias entre a 1ª camada oculta e a 2ª camada oculta do modelo de previsão desenvolvido-----	114
Tabela 18 – Valores dos pesos sinápticos e bias entre a 2ª camada oculta e a camada de saída do modelo de previsão desenvolvido-----	114
Tabela 19 – Variáveis de entrada consideradas para o modelo de RNA e saídas correspondentes -----	116

SUMÁRIO

1 INTRODUÇÃO	16
1.1 Motivação da pesquisa	16
1.2 Objetivos	18
1.2.1 <i>Objetivo geral</i>	18
1.2.2 <i>Objetivos específicos</i>	18
1.3 Metodologia	18
1.4 Escopo do trabalho	19
2 PROPRIEDADES HIDRÁULICAS DOS SOLOS NÃO SATURADOS	21
2.1 Considerações iniciais	21
2.2 Natureza e composição dos solos não saturados	22
2.3 Sucção	26
2.4 Curva de retenção	28
2.4.1 <i>Fatores que determinam o formato da curva de retenção</i>	29
2.4.2 <i>Equações de ajuste para a curva de retenção</i>	34
2.5 Condutividade hidráulica	37
2.5.1 <i>Fatores que afetam a condutividade hidráulica em solos não saturados</i>	38
2.5.2 <i>Métodos de estimativa da condutividade hidráulica em solos não saturados</i>	41
2.6 Considerações parciais	46
3 REDES NEURAIS ARTIFICIAIS	47
3.1 Conceitos gerais sobre redes neurais artificiais	47
3.2 Neurônio biológico	50
3.3 Neurônio artificial	52
3.4 Perceptron multicamadas	55
3.5 Aplicações das redes neurais artificiais em engenharia	59
3.6 Considerações parciais	70
4 METODOLOGIA DE DESENVOLVIMENTO DO MODELO DE PREVISÃO	71
4.1 Definição das variáveis de entrada	71
4.2 Coleta e tratamento dos dados	79
4.3 Treinamento, teste e validação	86
5 ANÁLISE E DISCUSSÃO DOS RESULTADOS	93
5.1 Treinamento e teste	93
5.2 Definição do modelo	102

5.3 Aplicação prática do modelo de RNA desenvolvido	115
5.3.1 Simulação numérica da condição de fluxo de uma barragem durante o seu enchimento	115
5.4 Considerações parciais	121
6 CONCLUSÕES E SUGESTÕES PARA PESQUISAS FUTURAS	123
6.1 Conclusões	123
6.2 Sugestões para pesquisas futuras	125
REFERÊNCIAS	126
APÊNDICE A – CONJUNTO EXPERIMENTAL UTILIZADO NO DESENVOLVIMENTO DO MODELO DE RNA PARA A CONFIGURAÇÃO C1 ---	140
APÊNDICE B – CONJUNTO EXPERIMENTAL UTILIZADO NO DESENVOLVIMENTO DO MODELO DE RNA PARA A CONFIGURAÇÃO C2 ---	148
APÊNDICE C – CONJUNTO EXPERIMENTAL UTILIZADO NO DESENVOLVIMENTO DO MODELO DE RNA PARA A CONFIGURAÇÃO C3 ---	156
APÊNDICE D – CORRELAÇÃO E RMS PARA TODAS AS ARQUITETURAS ANALISADAS	164
APÊNDICE E – COMPARAÇÃO ENTRE AS FUNÇÕES DE CONDUTIVIDADE HIDRÁULICA MEDIDAS E ESTIMADAS PELOS MODELOS DE RNA E PELO MODELO DE VAN GENUCHTEN (1980)	193
APÊNDICE F – PARÂMETROS DO MODELO DE VAN GENUCHTEN (1980) PARA CINCO SOLOS DO CONJUNTO EXPERIMENTAL	211

1 INTRODUÇÃO

Este capítulo apresenta considerações iniciais necessárias à compreensão da relevância da pesquisa, bem como lista os seus principais objetivos. Além disso, a metodologia do trabalho é descrita de forma sucinta, e a sua estrutura é apresentada para fornecer um melhor entendimento de como este estudo foi desenvolvido.

1.1 Motivação da pesquisa

Inúmeras situações em engenharia geotécnica envolvem a análise de fluxo transiente em meios não saturados. Podem ser citados como exemplos de ocorrências que necessitam de tal investigação: o colapso de uma barragem após o primeiro enchimento, devido à construção do aterro com baixa energia de compactação e baixa umidade; a ruptura com deslizamento de terra de um talude natural, ocasionada por variações nas tensões resultantes de mudanças nos valores das poropressões e das sucções matriciais; o rebaixamento rápido em barragens para a análise de estabilidade dos taludes de montante; e o rebaixamento do lençol freático para a execução de escavações (SILVA FILHO, 2004; LLANQUE AYALA, 2018; LÔBO NETO; SILVA FILHO; LOPES, 2018; GERSCOVICH; VARGAS JR.; CAMPOS, 1997).

As análises de fluxo em solos não saturados, porém, exigem o conhecimento de suas propriedades hidráulicas, como a função que relaciona as variáveis sucção, permeabilidade e teor de umidade (COSTA, 2017).

Hillel (1982) aponta que a melhor forma de obtenção do coeficiente de permeabilidade ocorre por meio do uso de medidas experimentais. Todavia, na prática, tais métodos não são muito utilizados, devido ao alto custo, à alta complexidade do procedimento experimental e à elevada demanda de tempo, envolvidos na execução dos ensaios (GERSCOVICH, 2001). Além disso, a qualidade das amostras empregadas em testes de laboratório é duvidosa, uma vez que, durante a coleta, pode haver amolgamento, acarretando a presença de trincas ou fissuras capazes de diminuir a representatividade do material coletado, alterando, assim, os resultados dos ensaios (MACHADO; ZUQUETTE, 2004).

Inúmeros modelos matemáticos constitutivos, envolvendo relações diretas ou indiretas com a curva de retenção de umidade, foram desenvolvidos como uma alternativa para a determinação da condutividade hidráulica em solos não saturados. Dentre essas metodologias,

as seguintes podem ser destacadas: Gardner (1958); Brooks e Corey (1964); Van Genuchten (1980) e Fredlund, Xing e Huang (1994).

No entanto, algumas metodologias possuem parâmetros de difícil obtenção (STERCK, 2011). Tem-se também como outra desvantagem desses modelos constitutivos a acurácia questionável da curva de condutividade resultante, uma vez que sua validação depende das medições diretas do padrão de fluxo e da obtenção das permeabilidades correspondentes.

Van Genuchten, Leij e Yates (1991) desenvolveram um método que utiliza uma abordagem de otimização não linear de mínimos quadrados para estimar os parâmetros do modelo de Van Genuchten (1980). Contudo, esse método pode não fornecer parâmetros que representem o comportamento hidráulico do material, como mostrado adiante neste trabalho.

Tendo em vista o contexto apresentado, esta dissertação busca elaborar, mediante a utilização de redes neurais artificiais (RNA), um modelo de previsão do coeficiente de condutividade hidráulica em função da sucção matricial e de outros parâmetros físicos do solo, cujas obtenções podem ser facilmente realizadas.

Diversas aplicações de RNA podem ser encontradas na literatura científica no âmbito da engenharia civil. Lorenzi (2009), por exemplo, combina resultados de ensaios de velocidade de propagação do pulso ultrassônico com técnicas de RNA para verificar a viabilidade de desenvolver modelos capazes de estimar a resistência à compressão do concreto; Martínez Carvajal (2006) utiliza RNA para reproduzir o comportamento constitutivo de areias limpas submetidas a carregamentos do tipo monotônico-drenado; Araújo (2015) desenvolveu um modelo para previsão de recalques em fundações profundas; e Leite (2019) aplica RNA na previsão do comportamento cisalhante das discontinuidades rochosas com e sem preenchimento em diferentes condições de contorno.

As RNA, portanto, constituem uma forte ferramenta computacional e têm sido usadas em diferentes ramos da ciência. Segundo Lorenzi (2009), devido ao modo de funcionamento, as RNA não necessitam de um modelo matemático que relacione os dados de entrada com os dados de saída, podendo ser aplicadas em casos com elevada não linearidade, o que as torna bastante úteis para criar modelos não lineares complexos e com altos níveis de incertezas.

Além disso, Boukerche e Notare (2002) afirmam que o uso de tais ferramentas na construção de metodologias de análise de fenômenos complexos é uma boa escolha, considerando três fatores inerentes às RNA: a capacidade intrínseca de aprendizagem, a habilidade de criação de limites de decisão altamente não lineares e a não parametrização.

1.2 Objetivos

1.2.1 Objetivo geral

Esta pesquisa tem por objetivo geral aplicar a ferramenta Rede Neural Artificial (RNA) no estabelecimento de um modelo que permita a estimativa da função de condutividade hidráulica de solos não saturados.

1.2.2 Objetivos específicos

Como objetivos específicos deste trabalho, podem ser citados:

- a) Estudar o mecanismo de condutividade hidráulica em solos não saturados, bem como os modelos constitutivos de obtenção da curva de permeabilidade;
- b) Analisar as propriedades/características do solo que interferem nesse fenômeno;
- c) Avaliar o conjunto de entrada que exerce mais influência na obtenção da curva de condutividade, por meio das correlações entre valores calculados e medidos;
- d) Comparar as previsões realizadas utilizando as RNA com os dados experimentais e com os resultados do modelo de Van Genuchten (1980);
- e) Realizar análise de fluxo transiente utilizando os dados obtidos pelo modelo neuronal desenvolvido, a fim de verificar a sensibilidade dos resultados dessa simulação.

1.3 Metodologia

Inicialmente, foi realizada uma revisão bibliográfica para um melhor entendimento das propriedades hidráulicas dos solos não saturados, bem como dos fatores que governam o comportamento do fluxo de água nesses meios porosos. Além disso, foram abordados também conceitos relacionados às redes neurais artificiais, possibilitando a aplicação de tal ferramenta na previsão da curva de condutividade hidráulica.

Posteriormente, foi feita uma coleta de dados (originados de ensaios de caracterização e de permeabilidade), os quais passaram por um processo de tratamento e, então, foram separados em dois conjuntos: treinamento e teste. Foram, também, propostas três configurações distintas para os dados de entrada (C1, C2 e C3), as quais se diferenciam entre si pelas variáveis consideradas.

Com o auxílio do programa QNET 2000, na fase de treinamento, os dados foram utilizados para treinar a rede, por meio da minimização dos erros resultantes da diferença entre a saída gerada e o valor real obtido na coleta de dados. Já, na fase de teste, a capacidade de generalização da rede foi analisada, submetendo-a a estímulos aos quais não tinha sido ainda apresentada.

Para cada configuração proposta, os conjuntos de treinamento e de teste foram monitorados com base no coeficiente de correlação e na raiz do erro quadrático médio. Dessa forma, as cinco melhores arquiteturas de cada configuração, com uma, duas e três camadas ocultas, foram selecionadas, a fim de empregá-las na estimativa das funções de condutividade de cinco solos do conjunto de exemplos coletados e compará-las com as funções obtidas pelo modelo de Van Genuchten (1980) e pelos dados experimentais.

Diante disso, o desempenho na previsão da função de condutividade desses cinco solos, o número de exemplos que resultaram em valores negativos nas fases de treinamento e de teste e a menor quantidade de parâmetros da rede neural foram os critérios estabelecidos para a escolha do modelo final.

Por último, após a seleção da arquitetura definitiva, com o auxílio do *software* Slide, tal modelo foi empregado em uma análise de fluxo transiente de uma barragem na condição de enchimento.

1.4 Escopo do trabalho

A estrutura deste trabalho encontra-se dividida em 6 capítulos. O primeiro capítulo refere-se à Introdução, na qual os seguintes tópicos são elencados: motivação da pesquisa, objetivos gerais e específicos, metodologia e escopo do trabalho.

Em seguida, no segundo capítulo, é apresentada a revisão bibliográfica, na qual é feita a fundamentação teórica de todo o trabalho, abordando os temas: natureza, constituição e ocorrência dos solos não saturados; sucção; curva de retenção e condutividade hidráulica.

O terceiro capítulo apresenta assuntos importantes necessários também ao embasamento teórico desta pesquisa no que se refere às redes neurais artificiais (RNA), como definições gerais, mecanismo de funcionamento e elementos básicos constituintes. Além disso, aplicações de tal ferramenta na engenharia são mencionadas ainda nesse capítulo, indicando características e performance de determinados modelos de estimativa do coeficiente de condutividade hidráulica.

O quarto capítulo traz a metodologia adotada, na qual são apresentadas, de forma detalhada, as etapas de desenvolvimento do modelo, ou seja, a definição das variáveis de entrada, o levantamento, a análise e o tratamento dos dados e as fases de treinamento, teste e validação.

No quinto capítulo, é realizada a apresentação dos resultados obtidos com a utilização de redes neurais artificiais, bem como dos parâmetros fornecidos pelo modelo definitivo. Além disso, é feita também uma comparação entre as funções de condutividade hidráulica determinadas a partir do modelo de Van Genuchten (1980), do modelo de RNA escolhido e dos dados experimentais.

No sexto capítulo, são indicadas sugestões para trabalhos futuros e apresentadas as conclusões originadas desta pesquisa, destacando os principais resultados alcançados.

Por fim, são apresentadas as referências bibliográficas e os apêndices citados ao longo do texto.

Os Apêndices A, B e C apresentam os exemplos dos conjuntos de treinamento e de teste utilizados no desenvolvimento do modelo de previsão para as configurações C1, C2 e C3, respectivamente.

O Apêndice D mostra a correlação e a raiz do erro quadrático médio (RMS) de todas as arquiteturas avaliadas, tanto na fase de treinamento como na fase de teste.

No Apêndice E, são realizadas comparações entre as funções de condutividade hidráulica medidas, relativas a cinco solos do conjunto de exemplos utilizado na modelagem, e estimadas utilizando o modelo de Van Genuchten (1980) e as quinze melhores arquiteturas com uma, duas e três camadas intermediárias.

No Apêndice F, podem ser encontrados os parâmetros de Van Genuchten (1980) previstos com o auxílio do *software* RETC e empregados para determinar a curva de condutividade hidráulica utilizando o modelo elaborado por esse autor para cinco solos do conjunto experimental.

2 PROPRIEDADES HIDRÁULICAS DOS SOLOS NÃO SATURADOS

Neste capítulo, aspectos importantes relacionados ao tema da pesquisa são discutidos, fornecendo um embasamento teórico para auxiliar o desenvolvimento da metodologia, da análise dos resultados e das considerações finais deste trabalho. Desse modo, temas associados à mecânica dos solos não saturados são abordados, como natureza, constituição e ocorrência desses materiais. Determinados conceitos gerais sobre tal assunto são também apresentados e, posteriormente, explicações relacionadas à sucção, à curva de retenção e à condutividade hidráulica são realizadas.

2.1 Considerações iniciais

Embora a mecânica dos solos não saturados tenha demorado a ser desenvolvida, o reconhecimento da importância de entender como tais materiais se comportam existe desde os primórdios da mecânica clássica. Tal importância deve-se ao fato de esses solos constituírem uma grande categoria, fazendo parte de diversas situações em geotecnia, e de não serem compreendidos pelos fundamentos da mecânica dos solos saturados (FREDLUND; RAHARDJO; FREDLUND, 2012; CONCIANI; BURGOS; BEZERRA, 2015).

Solos não saturados, com frequência, são encontrados em ambientes sujeitos a mudanças diárias nas condições térmicas. Assim, as ocorrências desses materiais são significativas em grande parcela do território terrestre, como em climas áridos, semiáridos e tropicais (FREDLUND; RAHARDJO; FREDLUND, 2012; SALES *et al.*, 2015). Nessas regiões, em geral, o lençol freático é profundo e o solo próximo à superfície está submetido a poropressões negativas e a uma possível redução do grau de saturação, pois a quantidade de água que evapora tende a exceder a que precipita, sendo a temperatura uma variável que desempenha importante papel em tais processos físicos (RIOS FILHO, 2006).

Sérios problemas em engenharia geotécnica estão ligados à alta variação das poropressões negativas (RIOS FILHO, 2006; FREDLUND; RAHARDJO; FREDLUND, 2012). Essas elevadas alterações normalmente acontecem em solos expansivos, colapsíveis e residuais, considerados solos problemáticos. Argilas altamente plásticas, por exemplo, podem sofrer expansão, devido à entrada de água entre as estruturas mineralógicas das partículas; assim, o caráter expansivo está relacionado ao tipo de mineral-argila que as constitui. Alguns siltes, por sua vez, apresentam uma diminuição de volume ao serem submetidos à presença de água, por causa do aumento das poropressões. Antes do contato com a água, as poropressões

negativas elevam as forças entre as partículas, atuando como um confinamento interno. Após o umedecimento, ocorre uma redução na sucção e na resistência ao cisalhamento; possibilitando, dessa maneira, ocorrências de acidentes geotécnicos, tais como deslizamento de taludes ou colapso de fundações.

2.2 Natureza e composição dos solos não saturados

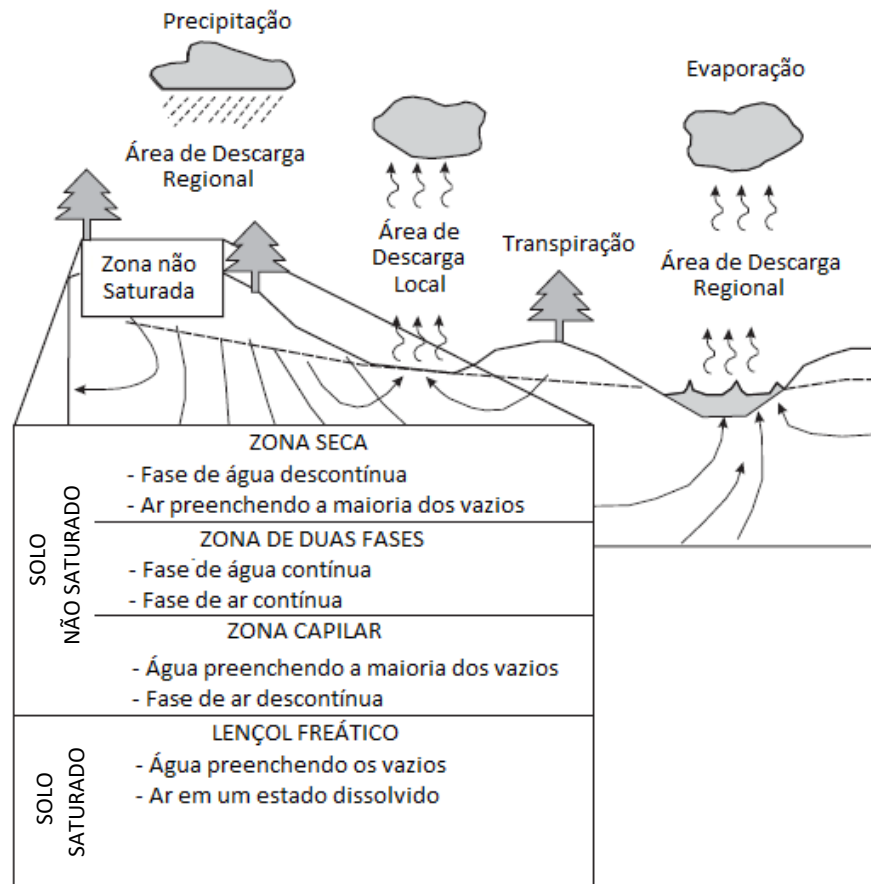
A condição climática é um fator relevante que controla a profundidade do lençol freático e, por conseguinte, determina a espessura da zona vadosa, cuja localização se encontra limitada pela superfície do solo e pela linha freática, onde as poropressões são nulas (FREDLUND; RAHARDJO; FREDLUND, 2012). Apesar de compreender a franja capilar saturada imediatamente acima do lençol freático, o termo “zona do solo não saturado” passou a ser bastante utilizado, em geotecnia, para englobar toda a faixa submetida a poropressões negativas em substituição ao termo “zona vadosa”. Nessa área, o grau de saturação pode variar de 100% (nas proximidades da linha freática) a zero (próximo à superfície do solo). Tais mudanças refletem alterações na sucção, originando subdivisões na zona não saturada, como pode ser visualizado na Figura 1 (STEPHENS, 1995).

Conforme ilustrado na Figura 1, inicialmente, a maioria dos vazios é preenchida por água e a fase do ar é descontínua (região capilar). À proporção que o solo se aproxima da superfície, o teor de água diminui até atingir a zona seca, onde a fase da água se torna descontínua e a fase do ar se torna contínua (ALMEIDA, 2018).

Um solo não saturado pode ser definido como um sistema particulado composto por três fases distintas: sólidos (partículas minerais), ar e água (LAMBE; WHITMAN, 2004). É essencial, todavia, reconhecer a existência de uma quarta fase, representada pela interação entre as fases líquida e gasosa, conhecida como interface ar-água ou película contrátil (Figura 2) (FREDLUND; MORGENSTERN, 1977; BURGOS; CONCIANI, 2015). Em um meio poroso, observa-se que, sob a influência de um gradiente de tensão, o ar e a água fluem, enquanto as partículas sólidas e a película contrátil atingem o equilíbrio.


A película contrátil pode ser comparada a uma fina membrana elástica, que envolve os vazios, separando o ar da água e determinando a relação volumétrica entre ambos os fluidos (FREDLUND; RAHARDJO; FREDLUND, 2012; BURGOS; CONCIANI, 2015). Essa membrana é fundamental para a compreensão do comportamento dos solos não saturados, pois mudanças no estado de tensão da interface podem ocasionar alterações do volume, do teor de água e da resistência ao cisalhamento do solo.

Figura 1 – Subdivisões da zona do solo não saturado (zona vadosa)



Fonte: adaptada de Fredlund, Rahardjo e Fredlund (2012).

Figura 2 – Fases do solo não saturado



Fonte: adaptada de Fredlund e Morgenstern (1977).

A formação dessa película elástica, na superfície da água em contato com o ar, ocorre porque as forças de atração entre as moléculas do líquido são maiores que as forças exercidas pelo ar. Outro fato que também contribui para esse processo é a atração de tais moléculas para o interior da água, tendendo a minimizar a área da superfície (AZEVEDO NETTO; FERNÁNDEZ Y FERNÁNDEZ, 2018).


A energia máxima que um fluido é capaz de suportar sem se partir é definida por Lu e Likos (2004) como tensão superficial. Segundo os autores, a tensão superficial se origina, na interface ar-água, por consequência do desequilíbrio entre as forças intermoleculares, atuando sobre as moléculas que constituem a fase líquida.

A tensão superficial é responsável pelo efeito contrátil da membrana e pela origem de um fenômeno físico denominado de capilaridade (FOX *et al.*, 2018). A ascensão capilar que ocorre em solos, principalmente de grãos finos, é análoga à que ocorre em tubos de pequenos diâmetros em contato com uma superfície livre de água, nos quais esse fluido sobe e se mantém indefinidamente, visto que o peso da coluna de água é sustentado pela força de contato entre o líquido e a parede do tubo, que forma um ângulo de molhamento α (Figuras 3 e 4) (TERZAGHI, 1943). Desse modo, se uma massa de solo for exposta à água a partir de sua base, o líquido subirá acima do nível desse fluido até uma certa altura, ocupando os vazios do solo (TERZAGHI; PECK; MESRI, 1996).

A força atuante na interface ar-água-partículas sólidas (tensão superficial) depende da intensidade das forças de coesão entre as moléculas de água e de adesão entre as moléculas de água e os grãos de solo (MACHADO; VILAR, 2015). Devido à força resultante dos fenômenos de adesão e de coesão e à não resistência da água ao cisalhamento, a película contrátil procura posicionar-se de forma perpendicular à força resultante. Isso estimula a formação de uma curvatura na membrana elástica, conhecida como menisco capilar, ocasionando a ascensão da água e exercendo uma força de aproximação entre os grãos, que é responsável pelo aumento da resistência do solo, segundo se pode visualizar na Figura 5.


A fim de equilibrar as forças do sistema, como resposta à ação da tensão superficial e da membrana contrátil, a pressão da água será sempre menor que a pressão atmosférica, o que diminui a sua energia interna (MACHADO; VILAR, 2015). Essa diferença de pressão ($u_a - u_w$) é conhecida como sucção mátrica (ou matricial) e representa o estado de energia da água nos solos não saturados.

Figura 3 – Ascensão capilar da água em um tubo




Fonte: Leme (2009).

Figura 4 – Detalhe da superfície de contato no tubo



Fonte: Machado e Vilar (2015).

Figura 5 – Menisco capilar



Fonte: Souza Pinto (2006).

2.3 Sucção

A afinidade que um solo não saturado tem por água é representada pela sucção, a qual é função principalmente da mineralogia, da umidade e da densidade do solo, como também da composição da água (MARINHO, 2005).

Essa afinidade, referida à pressão da água intersticial resultante de condições físicas e químicas, é responsável pela absorção ou pela perda de umidade, de acordo com as circunstâncias ambientais, aumentando ou reduzindo o grau de saturação, respectivamente (MARINHO 1997). Tal variável de estado, portanto, possui grande relevância para o entendimento do solo com poropressões negativas, devendo ser considerada nos estudos de resistência ao cisalhamento e podendo ser usada para avaliar a capacidade do solo de reter água.

A sucção, também chamada de sucção total, é definida por Krahn e Fredlund (1972), do ponto de vista da termodinâmica, como a sucção equivalente obtida por meio da medição da pressão parcial de vapor de água em equilíbrio com a água do solo em relação à pressão parcial de vapor de água em equilíbrio com a água pura e livre.

A sucção total é formada por duas parcelas: o potencial matricial e o potencial osmótico (Equação 1) (LEME, 2009). O primeiro componente está associado ao fenômeno da capilaridade, sendo descrito como a tensão negativa da água devido à tensão superficial, isto é, diferença entre as pressões do ar e da água ($u_a - u_w$). Já o segundo componente relaciona-se à concentração de sais do sistema solo-água e é definido como sendo a diferença entre a pressão de vapor em equilíbrio com a água pura e a pressão de vapor em equilíbrio com uma solução cuja composição é idêntica à da água do solo.

$$\psi = (u_a - u_w) + \pi \quad (1)$$

Onde:

ψ = sucção total (kPa);


$(u_a - u_w)$ = sucção matricial (kPa);

π = sucção osmótica (kPa).

A Figura 6 mostra a atuação de cada parcela da sucção. Nessa ilustração, o componente matricial corresponde à diferença de pressão através de uma membrana permeável à água e a solutos em um sistema em equilíbrio (GEORGETTI, 2010). O componente osmótico, por sua vez, corresponde à diferença de pressão em uma membrana que permite somente o fluxo entre a solução do solo e a água pura.

Alterações na sucção osmótica são menos significativas, em contrapartida, variações na sucção matricial podem ser mais desastrosas para efeitos de projetos de engenharia geotécnica (FREDLUND; RAHARDJO; FREDLUND, 2012). Foi comprovado que apenas a sucção mátrica afeta substancialmente o comportamento de solos não saturados; sendo, sozinha, suficiente para descrevê-lo (EDIL; MOTAN; TOHA, 1981; FREDLUND; MORGENSTERN, 1977).

Figura 6 – Componentes da sucção total



Fonte: adaptada de Hillel (2004).

2.4 Curva de retenção

A curva de retenção, ou curva característica solo-água (SWCC), é um modelo constitutivo que relaciona as variáveis sucção e teor de água do solo; sendo, pois, essencial para resolução de problemas envolvendo solos não saturados (SREEDEEP; SINGH, 2008; AYALA, 2018).

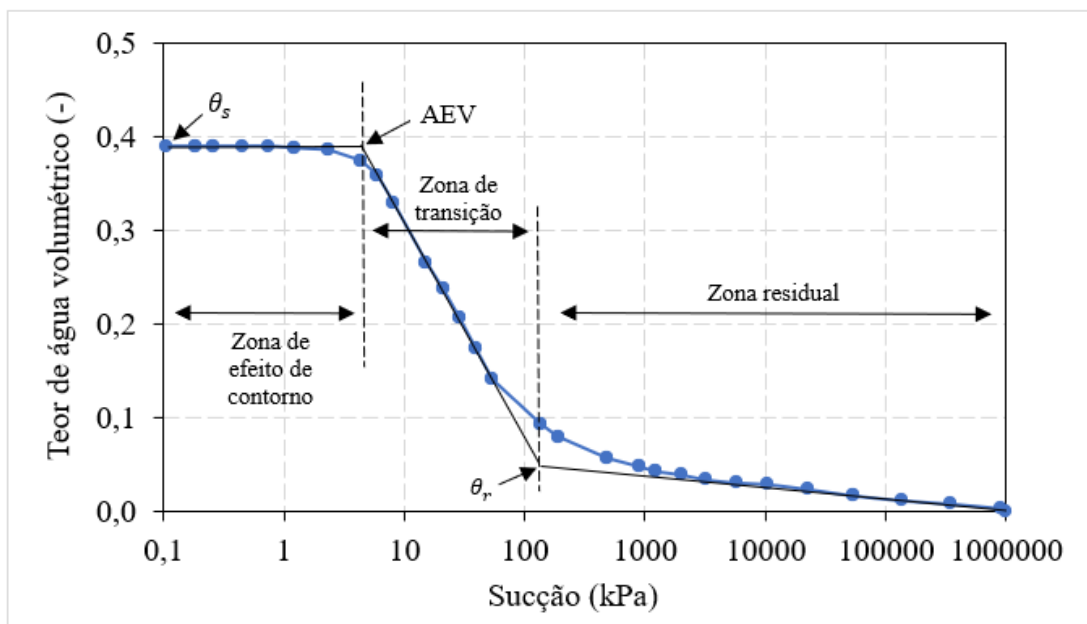
Tal curva exerce papel crucial na determinação das funções de propriedade desses materiais, constituindo a informação primordial requerida em análises de percolação, resistência ao cisalhamento, mudanças de volume, fluxo de ar e fluxo de calor (FREDLUND; WILSON; FREDLUND, 2002; FREDLUND; RAHARDJO; FREDLUND, 2012). Logo, essa curva precisa ser adequadamente medida ou estimada e interpretada.

A obtenção da curva de retenção pode ocorrer tanto por meio de procedimentos de secagem (dessorção) como de umedecimento (adsorção) das amostras de solo em ensaios de laboratório, os quais originam ramos de formatos semelhantes, porém, não coincidentes (AYALA, 2018). A Figura 7 mostra uma curva típica de secagem para um solo siltoso, na qual se observa a divisão do comportamento do solo não saturado em três zonas distintas: zona de efeito de contorno, em que podem ser aplicados os princípios da mecânica do solo saturado; zona de transição, na qual as propriedades do solo se tornam não lineares e, portanto, podem-se aplicar as teorias da mecânica do solo não saturado e zona residual, em que a diminuição do teor de água é mínima com o aumento da sucção. Essas três regiões são delimitadas por dois pontos importantes ao longo da curva característica: o valor de entrada de ar (AEV) e o teor de água residual (θ_r), a partir do qual se iniciam as condições residuais (VANAPALLI *et al.*, 1996; MORALES, 2008).

Com base na Figura 7, verifica-se que as variáveis teor de umidade volumétrico (θ) e sucção ($u_a - u_w$) são inversamente proporcionais e, para pequenos valores de sucção (abaixo de 10 kPa) impostos a um solo saturado, inicialmente, não haverá saída de água. Nesse caso, a quantidade de água em termos de volume é conhecida como teor de água volumétrico saturado (θ_s) e equivale, numericamente, à porosidade (VANAPALLI *et al.*, 1996; MORALES, 2008). Quando um valor crítico de sucção é atingido, o fluxo começa a ocorrer; drenando a água, a princípio, dos poros de maior tamanho. Essa sucção crítica é denominada de valor de entrada de ar $(u_a - u_w)_{aev}$. Já, o teor de água volumétrico residual (θ_r), representa o ponto além do qual a fase líquida se torna descontínua, tornando-se progressivamente mais difícil de remover a água dos vazios.

A obtenção do AEV e do θ_r pode ser realizada traçando retas que interceptam pontos estratégicos pertencentes à curva de retenção (VANAPALLI; SILLERS; FREDLUND, 1998). A interseção da reta que contém o θ_s e é paralela ao eixo horizontal com a reta tangente ao ponto de inflexão da zona de transição fornece o AEV. O θ_r , por sua vez, resulta do encontro da reta tangente a esse ponto de inflexão com outra que passa, nas condições residuais, pelo ponto no qual a sucção equivale a um valor da ordem de 10^6 kPa para um teor de umidade igual a zero (Figura 7).

Figura 7 – Curva de dessaturação típica para um solo siltoso



Fonte: adaptada de Fredlund e Xing (1994).

2.4.1 Fatores que determinam o formato da curva de retenção

Determinados solos possuem curva de retenção diferente da apresentada na Figura 7. A mineralogia, a granulometria, o histórico de tensão, a condição de compactação e a histerese são fatores que influenciam no formato dessa curva (ZHOU; YU, 2005; VANAPALLI; FREDLUND; BABOUR, 1996).

A mineralogia do solo interfere na sua capacidade de reter água (GITIRANA JUNIOR; MARINHO; SOTO, 2015). Em materiais muito plásticos, por exemplo, ocorre um fenômeno denominado de adsorção da água por forças de natureza eletroquímicas, que concorre com a capilaridade.

Devido aos efeitos capilares e eletroquímicos (mineralogia), determinados solos, ao perderem água, sofrem também uma redução de volume. Se o volume de água perdido for igual

à alteração de volume total, o solo permanecerá saturado, precisando de sucções mais elevadas para iniciar a dessaturação (GITIRANA JUNIOR; MARINHO; SOTO, 2015). Tal fato normalmente ocorre em solos mais argilosos e evidencia a necessidade da medição da variação de volume durante o processo de perda de umidade, a fim de se obter a curva característica.

A Figura 8 ilustra possíveis trajetórias de secagem em um gráfico que relaciona teoricamente o teor de umidade volumétrico, o índice de vazios e o grau de saturação. A seta paralela à linha vermelha tracejada indica que não houve dessaturação. As setas vertical e transversal representam a redução do grau de saturação sem e com mudança de volume, respectivamente.

Ao analisar a Figura 8, percebe-se, portanto, que existem três caminhos possíveis para o procedimento de secagem. No primeiro caminho, o solo pode manter a saturação constante, reduzindo o volume. A segunda possibilidade é caracterizada pela constância do volume, porém, com a diminuição da saturação. Por fim, na terceira trajetória, o grau de saturação e o volume sofrem redução, simultaneamente.


De forma geral, os efeitos da distribuição granulométrica em areias, conforme pode ser visto na Figura 9, resultam em uma curva mais íngreme quanto mais uniforme for o solo (GALLAGE; UCHIMURA, 2010). Com o aumento da sucção, os maiores vazios são os primeiros a serem drenados. Em areias com grande porcentagem de partículas finas, maiores valores de sucção precisam ser aplicados para que a água comece a sair dos vazios. Normalmente, nas areias descontínuas ou bimodais, mais de um trecho de dessaturação pode ser verificado (GITIRANA JUNIOR; MARINHO; SOTO, 2015).

Ao comparar areias, siltes e argilas, nota-se que as areias possuem uma variação mais acentuada do teor de umidade com o aumento da sucção, por causa da presença de poros maiores nesse tipo de solo; em contrapartida, as argilas possuem uma relação mais gradual, devido aos menores diâmetros dos vazios e, portanto, a uma maior superfície específica. Geralmente, um índice de plasticidade maior acarreta maiores valores de θ_s e AEV, conforme Figura 10 (VANAPALLI; FREDLUND; BARBOUR, 1996; LEME, 2009; GALLAGE; UCHIMURA, 2010; GITIRANA JUNIOR; MARINHO; SOTO, 2015).

As influências do histórico de tensões e das condições de compactação são apresentadas nas Figuras 11 e 12. Na Figura 11, é possível perceber que o efeito da consolidação ocasiona um aumento nos valores de sucção necessários para drenar a água, em virtude da redução da compressibilidade do solo, ou seja, redução do volume de vazios. Já, na Figura 12, observa-se que, caso o solo seja compactado com uma umidade menor que a umidade ótima, a

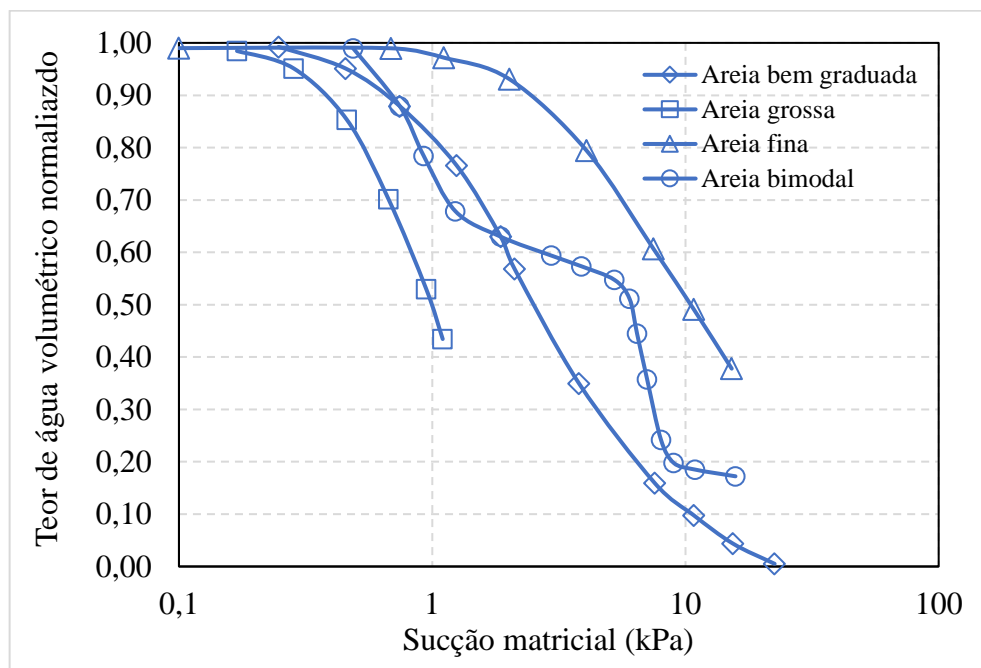
curva de retenção exibirá valores menores de sucção, pois o solo provavelmente não atingiu a sua máxima densidade seca (GITIRANA JUNIOR; MARINHO; SOTO, 2015).

Figura 8 – Relação entre o teor de água volumétrico (θ), o índice de vazios (e) e o grau de saturação (S)



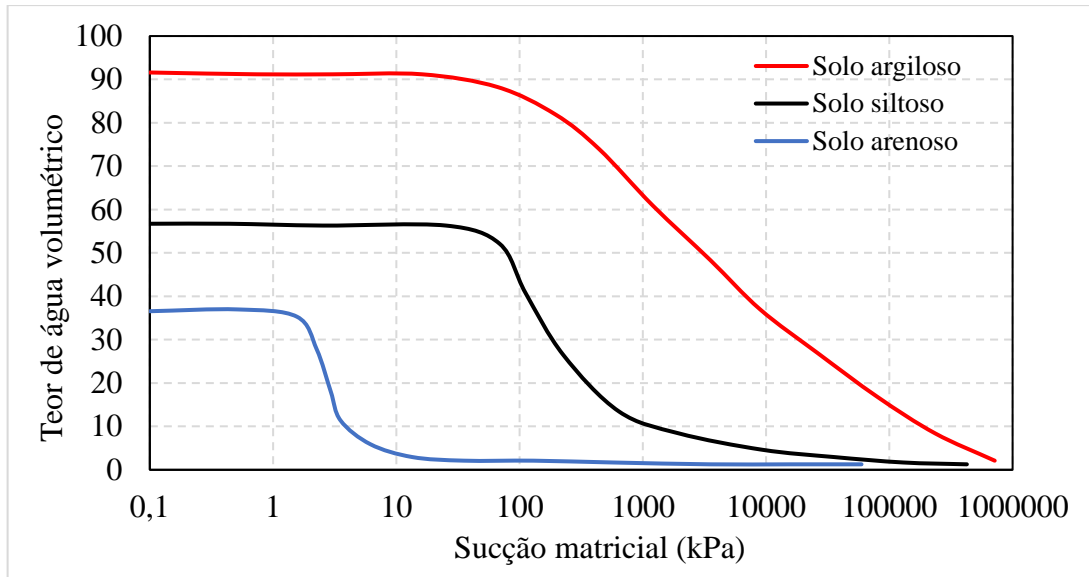
Fonte: Gitirana Junior, Marinho e Soto (2015).

Figura 9 – Curva de retenção para areias com diferentes granulometrias



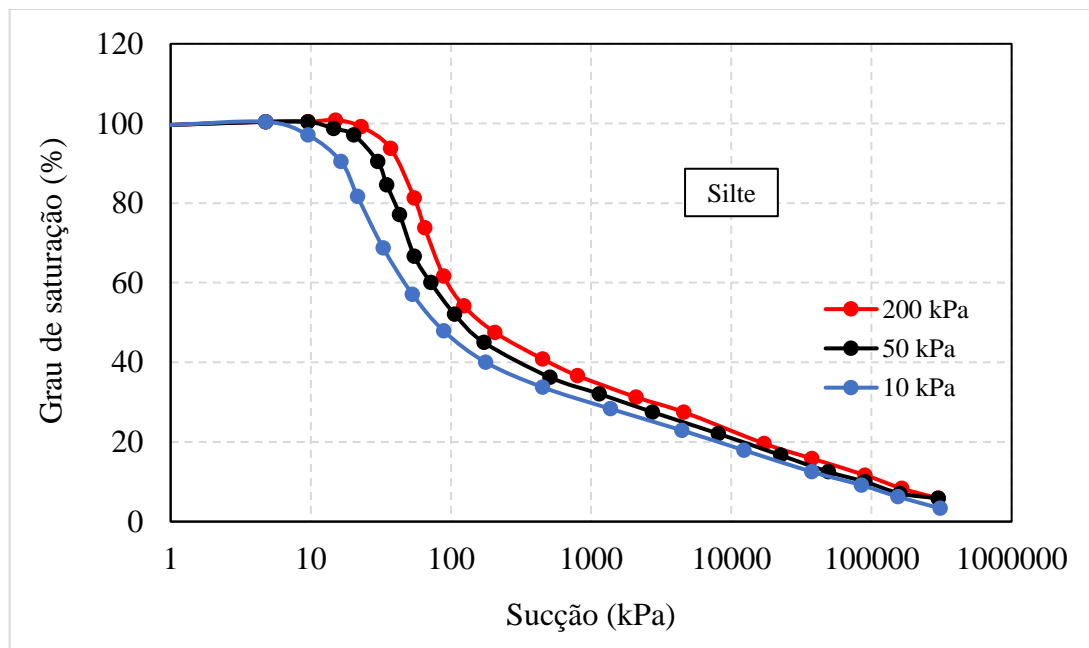
Fonte: Gitirana Junior, Marinho e Soto (2015).

Figura 10 – Curva de retenção para diferentes tipos de solos



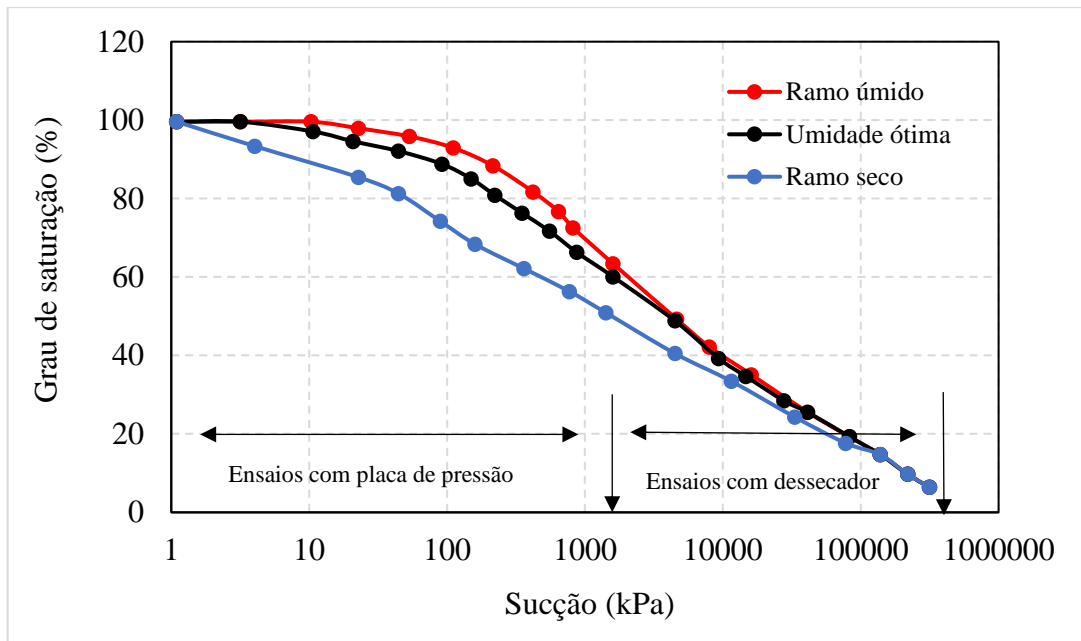
Fonte: adaptada de Fredlund e Xing (1994).

Figura 11 – Efeito da pressão de consolidação na curva de retenção



Fonte: Gitirana Junior, Marinho e Soto (2015).

Figura 12 – Efeito da condição de compactação na curva de retenção



Fonte: Gitirana Junior, Marinho e Soto (2015).

O fenômeno da histerese associado à curva de retenção indica que, embora tendam a ter formatos semelhantes, os ramos de secagem e de umedecimento não coincidem. Isso ocorre uma vez que as grandezas referentes ao umedecimento são menores que as associadas à secagem, considerando ambas as variáveis (sucção e teor de umidade) (Figura 13). Tal fato sugere que para uma determinada sucção pode haver dois valores diferentes de teor de umidade, bem como um determinado teor de umidade pode corresponder a sucções distintas, dependendo do caminho utilizado na obtenção da curva característica (BASHIR; SHARMA; STEFANIAK, 2015; AYALA, 2018).

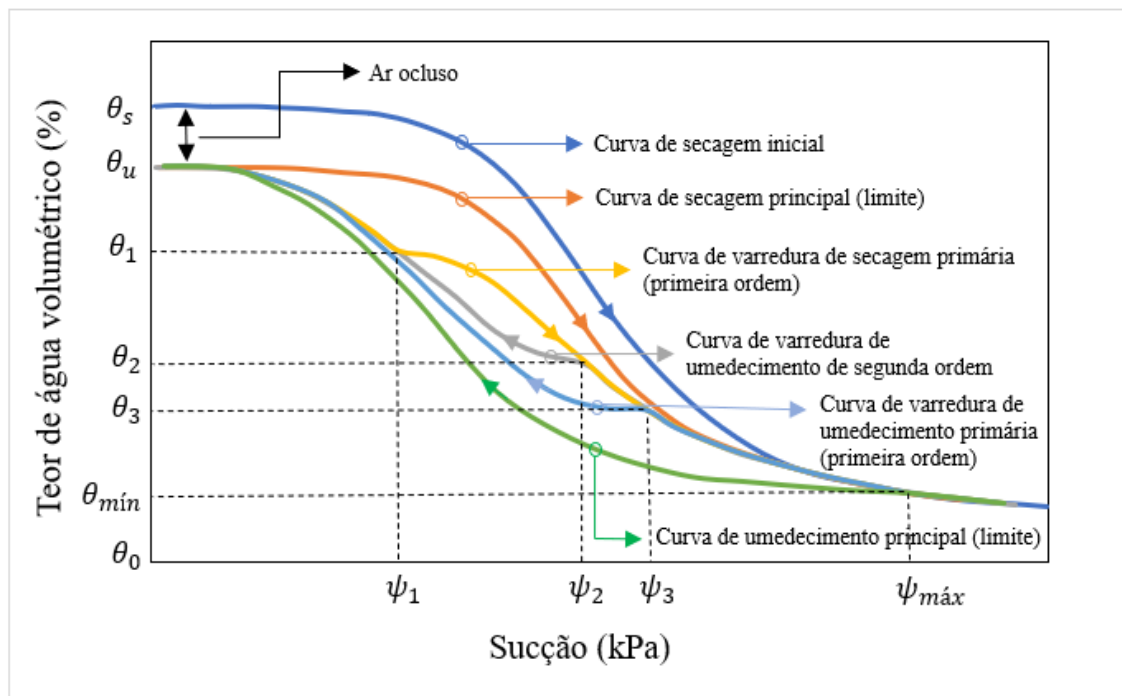
As trajetórias de secagem e de umedecimento formam limites extremos, havendo infinitas curvas intermediárias que se ligam a esses dois ramos delimitadores; cuja diferença pode ser substancial em termos de sucção (FREDLUND; RAHARDJO; FREDLUND, 2012; AYALA, 2018). Um determinado valor de teor de umidade poderá corresponder, por exemplo, a uma de sucção de 10 kPa ou de 100 kPa, dependendo do ramo ao qual se refere (Figura 13).

Desse modo, é fundamental que certos cuidados sejam tomados ao utilizar a curva de retenção em problemas de geotecnia (FREDLUND; RAHARDJO; FREDLUND, 2012). O engenheiro deve tomar uma decisão sobre o processo a ser simulado (secagem ou umedecimento) e, então, usar o resultado para estimá-la.

Fatores impulsionadores do fenômeno da histerese são: geometria não uniforme dos poros individuais interconectados por pequenos canais; influência do ângulo de contato solo-

água, o qual sofre alteração de acordo com o avanço ou recuo do menisco, por causa da rugosidade da superfície das partículas do solo; ocorrência de ar confinado nos vazios, diminuindo o teor de umidade no processo de umedecimento; histórico de dessorção e de adsorção do solo e liberação progressiva do ar dissolvido na água (PRESA, 1982).

Figura 13 – Histerese da curva de retenção



Fonte: adaptada de Fredlund, Rahardjo e Fredlund (2012).

2.4.2 Equações de ajuste para a curva de retenção

Várias equações empíricas foram propostas a fim de melhor ajustar os dados adquiridos em ensaios de laboratório para a curva de retenção e podem ser classificadas como equações de dois, três ou quatro parâmetros, os quais estão ligados ao valor de entrada de ar e à taxa de dessaturação (FREDLUND; RAHARDJO; FREDLUND, 2012).

As curvas de retenção nas zonas de baixas e de altas sucções são assintóticas a uma linha horizontal, configurando dificuldades que precisam ser consideradas no desenvolvimento das equações (FREDLUND; RAHARDJO; FREDLUND, 2012). A primeira situação significa que o módulo de armazenamento de água (m_w) aproxima-se de zero nessa região, o que não é verídico e provoca instabilidade na modelagem de fluxo transiente em solos não saturados. No segundo caso, o equívoco ocorre quando a sucção tende ao infinito para teores de umidade superiores ao residual.

Em virtude disso, certas equações não fornecem uma função contínua para a curva, porém, oferecem uma representação razoável para determinada faixa de sucção. Brooks e Corey (1964), por exemplo, propuseram uma equação para sucções entre o valor de entrada de ar e as condições residuais. Fredlund e Xing (1994) conseguiram solucionar a segunda dificuldade aplicando um fator de correção, o qual direciona a equação da curva para um valor de sucção de 10^6 kPa correspondente a um teor de água igual a zero. Esse valor foi suportado tanto experimentalmente para uma variedade de solos como pelas considerações termodinâmicas (CRONEY; COLEMAN, 1961; RICHARDS, 1965).

Van Genuchten (1980), por sua vez, desenvolveu uma função contínua para a curva característica. No entanto, na tentativa de obter uma expressão de forma fechada para a curva de condutividade hidráulica, relacionou os parâmetros m e n de sua equação de duas formas diferentes: uma baseada na teoria de Mualem (1976) e outra baseada na teoria de Burdine (1953), diminuindo a flexibilidade da função, isto é, reduzindo a representatividade dos dados experimentais. Dessa forma, torna-se mais vantajoso deixar tais parâmetros sem uma relação fixa, obtendo um ajuste mais preciso aos dados de laboratório.

Diversos estudos em uma variedade de amostras de solo foram realizados com o propósito de determinar a adequação dos modelos aos dados experimentais. A pesquisa de Sillers, Fredlund e Zakerzadeh (2001), por exemplo, sugere que as equações de três parâmetros são mais flexíveis em relação à habilidade de ajuste dos dados experimentais em uma ampla faixa de sucção do solo. Os autores apontam ainda que expressões com parâmetros independentes e que possuam significado físico são preferíveis, pois essas equações fornecem um melhor ajuste e são capazes de correlacionar seus parâmetros às propriedades do solo. Outra conclusão obtida por Sillers, Fredlund e Zakerzadeh (2001) é que, quando as sucções precisam ser modeladas além das condições residuais, as equações mais vantajosas são aquelas com fator de correção que garante que a sucção atinja o valor de 10^6 kPa correspondente a um teor de água igual a zero, embora todos os modelos tenham produzido resultados satisfatórios ao limitar o ajuste a uma certa faixa de sucção do solo.

A Tabela 1 ilustra as expressões de ajuste para a curva de retenção referentes aos modelos dos seguintes autores: Gardner (1958), Brooks e Corey (1964), Van Genuchten (1980) e Fredlund e Xing (1994).

Tabela 1 – Equações de ajuste para a curva de retenção (Continua)

Autor	Equação	Parâmetros
Gardner (1958)	$\Theta_d = \frac{1}{1 + a_g \psi^{n_g}}$ <p>Onde:</p> $\Theta_d = \frac{w(\psi)}{w_s}$	<p>a_g = parâmetro de ajuste que é função do AEV;</p> <p>n_g = parâmetro de ajuste que é função da taxa de dessaturação além do AEV.</p>
Brooks e Corey (1964)	<p>Para $\psi \leq \psi_{aev}$:</p> $w(\psi) = w_s \text{ ou } \Theta_n = 1$ <p>Para $\psi > \psi_{aev}$:</p> $\Theta_n = \left[\frac{\psi}{\psi_{aev}} \right]^{-\lambda_{bc}}$ <p>Onde:</p> $\Theta_n = \frac{w(\psi) - w_r}{w_s - w_r}$	<p>ψ_{aev} = valor de entrada de ar do solo;</p> <p>λ_{bc} = índice de distribuição do tamanho dos poros;</p> <p>w_r = teor de água residual.</p>
Van Genuchten (1980)	$\Theta_n = \frac{1}{[1 + (a_{vg} \psi)^{n_{vg}}]^{m_{vg}}}$ <p>Onde:</p> $\Theta_n = \frac{w(\psi) - w_r}{w_s - w_r}$	<p>a_{vg} = parâmetro de ajuste relacionado principalmente ao inverso do AEV;</p> <p>n_{vg} = parâmetro de ajuste relacionado principalmente à taxa de dessaturação do solo além do AEV;</p> <p>m_{vg} = parâmetro de ajuste relacionado principalmente às condições residuais.</p>

Tabela 1 – Equações de ajuste para a curva de retenção (Conclusão)

Autor	Equação	Parâmetros
Fredlund e Xing (1994)	$w(\psi) = C(\psi) \frac{w_s}{\left\{ \ln \left[e + \left(\frac{\psi}{a_f} \right)^{n_f} \right] \right\}^{m_f}}$ <p>Onde:</p> $C(\psi) = 1 - \frac{\ln \left(1 + \psi / \psi_r \right)}{\ln \left[1 + \left(10^6 / \psi_r \right) \right]}$ $\Theta_d = \frac{w(\psi)}{w_s}$	<p>a_f = parâmetro de ajuste que é relacionado principalmente ao AEV;</p> <p>n_f = parâmetro de ajuste que é relacionado principalmente à taxa de dessaturação do solo além do AEV;</p> <p>m_f = parâmetro de ajuste que é relacionado principalmente ao teor de umidade residual;</p> <p>$C(\psi)$ = fator de correção que é relacionado principalmente à sucção correspondente ao teor de umidade residual.</p>

Fonte: Elaborada pela autora (2020).

2.5 Condutividade hidráulica

Para fins de elaboração de projetos de engenharia, em muitas situações, necessita-se do conhecimento da direção e da taxa de escoamento através do meio poroso, bem como da distribuição das poropressões e das cargas hidráulicas dentro do regime de fluxo considerado. Esse comportamento pode ser obtido por meio de análises de percolação (GERSCOVICH, 2011; FREDLUND; RAHARDJO; FREDLUND, 2012; OLIVEIRA, 2014; BORA, 2015; MODESTO, 2019; MOREIRA; AZEVEDO; SANTOS, 2019).

Essas investigações são relevantes, por exemplo, nos estudos de estabilidade de taludes, de controle de contaminação das águas subterrâneas ou de projetos de barragens de terra e podem ser classificadas em dois tipos: análises de fluxo em estado estacionário e análises de fluxo em estado transiente (MACHADO JÚNIOR; NOGUEIRA, 2000; FILIZOLA (2002); GERSCOVICH, 2011; BORA, 2015; MOREIRA; AZEVEDO; SANTOS, 2019). Nas análises transientes, a carga hidráulica e, provavelmente, o coeficiente de permeabilidade mudam em relação ao tempo, como consequência das variações das condições de contorno. Nas análises estacionárias, de forma contrária, a carga hidráulica e o coeficiente de permeabilidade

permanecem constantes em função do tempo, em qualquer ponto da massa de solo (GERSCOVICH, 2011; OLIVEIRA, 2014).

Ao realizar tais análises, portanto, é necessário o conhecimento do coeficiente de permeabilidade (k_w), responsável por regular a taxa de fluxo de água (GERSCOVICH, 2011; FREDLUND; RAHARDJO; FREDLUND, 2012). Em solos não saturados, o k_w assume a forma de uma função matemática, variando bastante com o grau de saturação ou o estado de tensões, em especial, quando a sucção é alterada além do AEV.

2.5.1 Fatores que afetam a condutividade hidráulica em solos não saturados

O coeficiente de permeabilidade é uma medida da facilidade com que a água pode escoar nos espaços vazios do solo disponíveis para vazão e depende tanto das propriedades do fluido como das propriedades do meio poroso (GERSCOVICH, 2011; MACHADO JÚNIOR; NOGUEIRA, 2000).

Em solos não saturados, a água apenas flui através da parcela dos vazios que contém esse líquido (GERSCOVICH, 2011; FREDLUND; RAHARDJO; FREDLUND, 2012). À proporção que o grau de saturação diminui, há também uma diminuição no coeficiente de permeabilidade, uma vez que a área da seção transversal com água é reduzida. Adicionalmente, existe um aumento da tortuosidade do caminho percorrido pela água, fazendo com que o coeficiente de permeabilidade tenha uma redução muito maior que o grau de saturação.

Constatou-se, portanto, que o coeficiente de permeabilidade é função de duas quaisquer das três propriedades volume-massa, sendo afetado de forma significativa por alterações combinadas entre o índice de vazios, o grau de saturação e o teor de água gravimétrico, segundo mostram as Equações 2, 3 e 4 (FREDLUND; RAHARDJO; FREDLUND, 2012; BICALHO; MACHADO; GERSCOVICH, 2015).

$$k_w = k_w(S, e) \quad (2)$$

$$k_w = k_w(S, w) \quad (3)$$

$$k_w = k_w(w, e) \quad (4)$$

Onde:

e = índice de vazios;

S = grau de saturação;

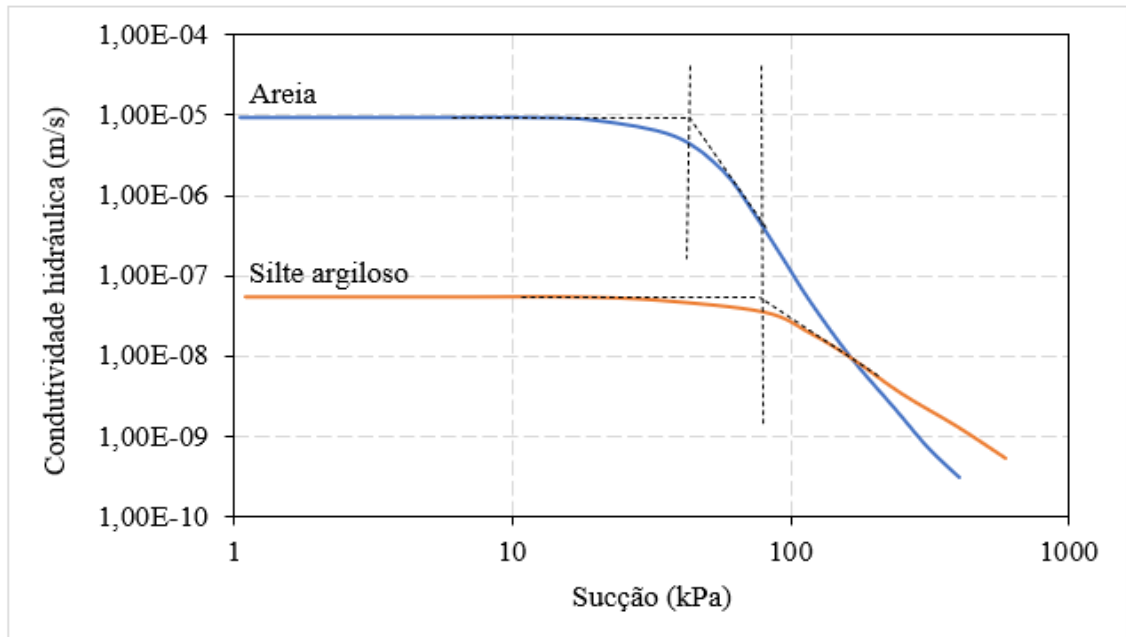
w = teor de água gravimétrico.

A granulometria e a plasticidade são outros fatores que também afetam o coeficiente de permeabilidade (GERSCOVICH, 2011; FREDLUND; RAHARDJO; FREDLUND, 2012). Solos com partículas grossas e com uma distribuição granulométrica mais uniforme tendem a ter elevados valores de permeabilidade, devido à existência de vazios com grandes diâmetros. Em contrapartida, em solos finos, como argilas de alta plasticidade, os vazios menores, juntamente com a elevada superfície específica e a composição química e mineralógica são responsáveis por uma maior retenção de água, a qual não encontra facilidade de transitar nos poros, conferindo a esses materiais uma baixa permeabilidade.

É importante salientar, no entanto, que solos com poros maiores são mais suscetíveis à perda de umidade devido à aplicação da sucção, acarretando acentuadas reduções ao coeficiente de condutividade hidráulica (BICALHO; MACHADO; GERSCOVICH, 2015). Por outro lado, solos finos estão menos sujeitos a variações bruscas da condutividade hidráulica, em virtude de as partículas sólidas conseguirem reter água, mesmo para elevados valores de sucção.

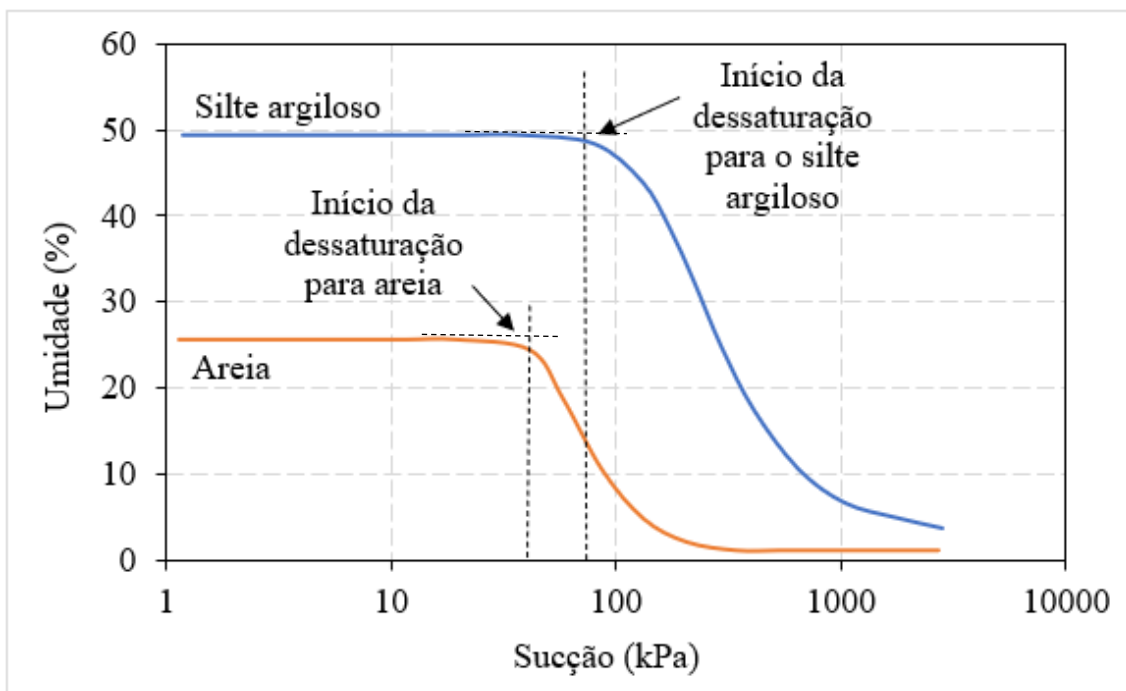
A Figura 14 ilustra uma comparação entre as curvas de condutividade hidráulica de um solo arenoso e de um solo siltoso. A Figura 15, por sua vez, mostra as suas respectivas curvas de retenção. Realizando-se uma análise de ambas as figuras, é possível observar que, independentemente do tipo de solo, a permeabilidade permanece relativamente constante até o AEV, ou seja, o ponto de início da dessaturação, a partir do qual esse coeficiente começa a decrescer, de forma rápida, com os acréscimos de sucção matricial. Após o AEV, verifica-se que a taxa de redução da condutividade hidráulica do solo arenoso é maior que a do solo siltoso. Em razão disso, há um ponto de interseção entre essas duas curvas, além do qual a condutividade hidráulica do solo arenoso é menor que a do solo siltoso.

Figura 14 – Comparação entre as curvas de condutividade hidráulica de um solo arenoso e de um solo siltoso



Fonte: adaptada de Bicalho, Machado e Gerscovich (2015).

Figura 15 – Comparação entre as curvas de retenção de um solo arenoso e de um solo siltoso



Fonte: adaptada de Bicalho, Machado e Gerscovich (2015).

2.5.2 Métodos de estimativa da condutividade hidráulica em solos não saturados

A aplicabilidade das leis de fluxo na resolução de problemas de geotecnia necessita das propriedades hidráulicas dos solos (GERSCOVICH, 2011; FREDLUND; RAHARDJO; FREDLUND, 2012). Embora os procedimentos teóricos para o cálculo da função de permeabilidade não transmitam resultados tão confiáveis quanto a realização de ensaios laboratoriais, a execução demorada e dispendiosa das medições experimentais diretas, em campo ou em laboratório, torna mais viável a utilização de técnicas de previsão da condutividade hidráulica em solos não saturados.

Esses procedimentos de estimativa realizam uma associação entre o início da dessaturação e a redução do k_w , baseando-se na SWCC e no coeficiente de permeabilidade saturado (k_s) (FREDLUND; RAHARDJO; FREDLUND, 2012). A um solo saturado é atribuído o maior k_w , que começa a diminuir quando a sucção supera o AEV, ou seja, o grau de saturação passa a ser menor que 100%. Após as condições residuais, o fluxo de água líquida cessa, predominando o fluxo de vapor.

Gardner (1958) propôs a seguinte relação matemática entre a permeabilidade hidráulica de solos não saturados e a sucção matricial:

$$k_w(u_a - u_w) = \frac{k_s}{1 + a_g \left\{ \frac{u_a - u_w}{\rho_w g} \right\}^{n_g}} \quad (5)$$

Onde:

g = aceleração da gravidade;

ρ_w = densidade da água;

n_g = parâmetro de ajuste relacionado à taxa de dessaturação do solo;

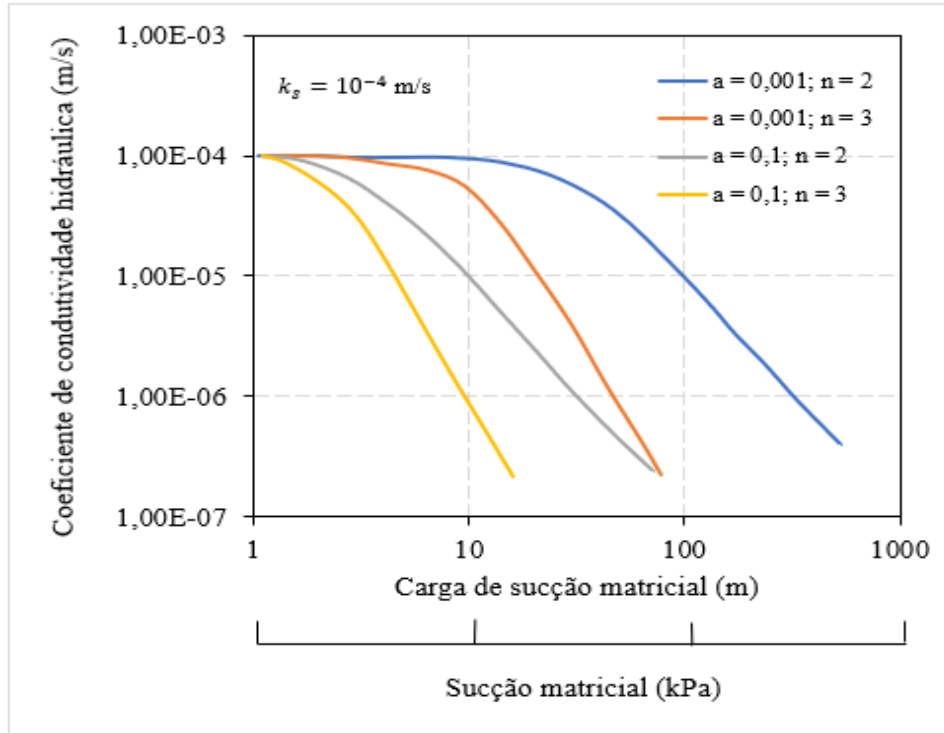
a_g = parâmetro de ajuste relacionado ao inverso do AEV.

A Equação 5 fornece uma função contínua que se estende da zona próxima às condições saturadas àquela de altas sucções matriciais. Essa expressão, contudo, não atende aos requisitos de uma função de estimativa, pois os seus parâmetros são resultantes de uma análise de regressão de dados experimentais, não podendo ser usada sem que seja possível determiná-los previamente (FREDLUND; RAHARDJO; FREDLUND, 2012). Curvas típicas para diferentes valores de n_g e a_g podem ser visualizadas na Figura 16.

Gardner (1958) desenvolveu, portanto, uma relação entre a condutividade hidráulica em solos não saturados e alguns parâmetros do solo, como o coeficiente de permeabilidade saturado (k_s), a sucção matricial ($u_a - u_w$), o entendimento do valor de entrada

de ar, cujo inverso está associado ao a_g , e o entendimento da taxa de dessaturação do solo, representada por n_g . Os dois últimos parâmetros (a_g e n_g) estão, assim, relacionados à SWCC.

Figura 16 – Equação de Gardner (1958) para a função de permeabilidade



Fonte: adaptada de Fredlund, Rahardjo e Fredlund (2012).

Brooks e Corey (1964) elaboraram um modelo empírico dividido em duas partes, as quais envolvem a identificação do coeficiente de permeabilidade abaixo e acima do AEV. Na região saturada, abaixo do AEV ($u_a - u_w \leq (u_a - u_w)_b$), o k_w é igual ao k_s :

$$k_w = k_s \quad (6)$$

Acima do AEV ($u_a - u_w > (u_a - u_w)_b$), a função é dada por:

$$k_w = k_s \left\{ \frac{(u_a - u_w)_b}{u_a - u_w} \right\}^{2+3\lambda} \quad (7)$$

Onde:

$(u_a - u_w)_b$ = sucção matricial de entrada de ar;

λ = índice de distribuição do tamanho dos poros.

O parâmetro λ é obtido a partir da SWCC. Esse índice é definido como a inclinação negativa do grau efetivo de saturação (S_e) versus a sucção matricial ($u_a - u_w$), sendo o grau efetivo de saturação (S_e) expresso de acordo com a seguinte equação:

$$S_e = \frac{S - S_r}{1 - S_r} \quad (8)$$

Onde:

S_r = grau de saturação residual;

S = qualquer valor de grau de saturação;

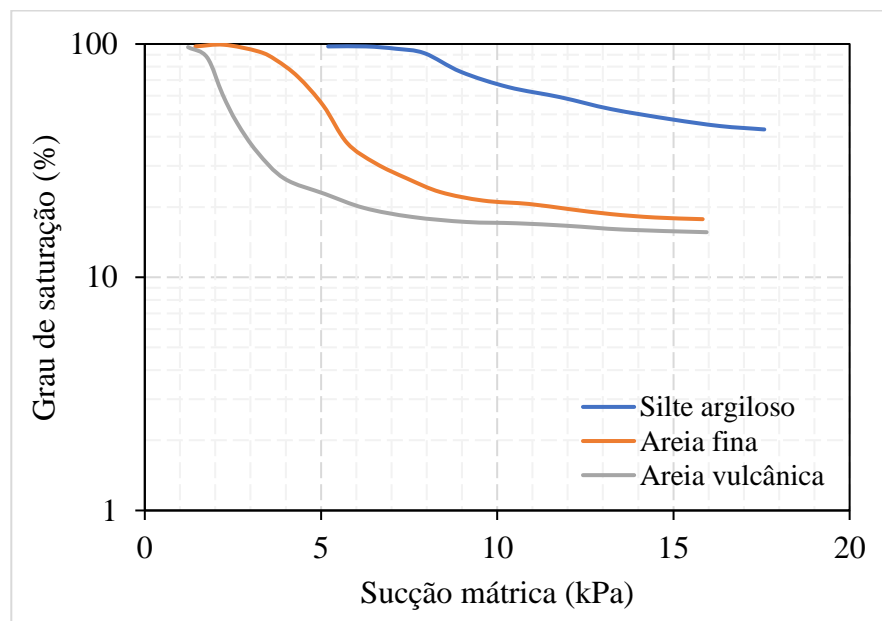
S_e = grau efetivo de saturação.

A partir da Equação 8, pode-se perceber que o grau efetivo de saturação, descrito por Brooks e Corey (1964), normaliza o teor de umidade entre as condições saturadas ($S = 1$) e residuais, pois os autores apoiaram-se na premissa de que o fluxo de água líquida ocorreria entre essas duas circunstâncias, diminuindo à proporção que maiores valores de sucção eram impostos ao solo.

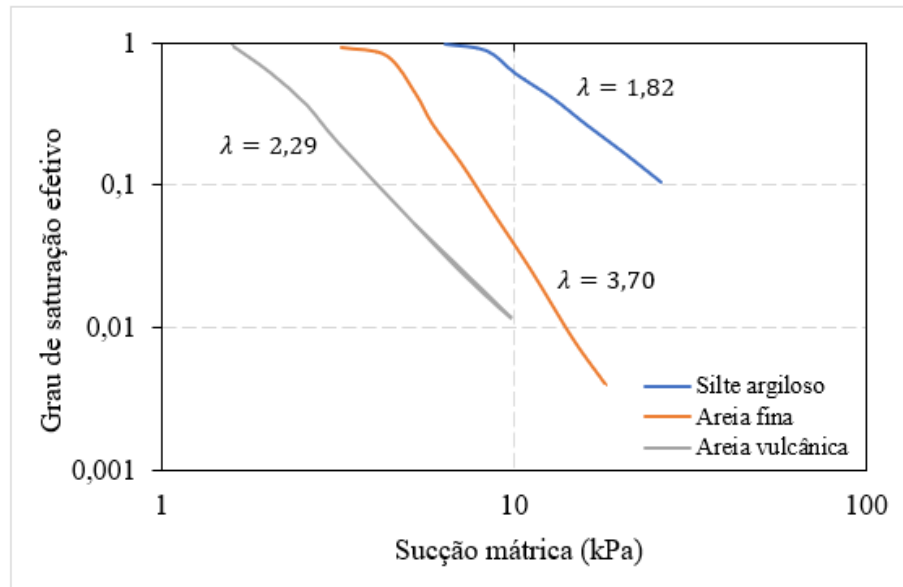
As Figuras 17 e 18 apresentam exemplos de ajustes do modelo para diferentes tipos de materiais. Como pode ser visto na Figura 18, solos com uma distribuição de tamanho dos poros mais uniforme possuem valores maiores para o índice λ .

Dessa forma, o modelo de Brooks e Corey (1964) fornece uma estimativa da função de condutividade hidráulica com base no coeficiente de permeabilidade saturado (k_s), na sucção matricial ($u_a - u_w$), na compreensão do valor de entrada de ar $(u_a - u_w)_b$ a partir da SWCC, e na distribuição do tamanho dos poros (λ), obtida por intermédio da curva que relaciona o grau efetivo de saturação (S_e) com a sucção mátrica.

Figura 17 – Grau de saturação em função da sucção matricial para diferentes tipos de solo



Fonte: adaptada de Fredlund, Rahardjo e Fredlund (2012).

Figura 18 – Valores de λ para diferentes tipos de solo

Fonte: adaptada de Fredlund, Rahardjo e Fredlund (2012).

Van Genuchten (1980) constatou que, caso sua função de três parâmetros para a SWCC pudesse ser reduzida para uma de dois parâmetros, uma curva de forma fechada poderia ser obtida para o coeficiente de permeabilidade. Amparado nas diferentes metodologias de integração elaboradas por Burdine (1953) e por Mualem (1976) e com o objetivo de possibilitar a realização de tais procedimentos de integração, Van Genuchten (1980) relacionou os parâmetros de ajuste m_{vg} e n_{vg} de duas maneiras distintas, de acordo com as Equações 9 e 10. Essas relações deram origem a duas funções de condutividade hidráulica: uma baseada nas teorias de Burdine (1953) e outra alicerçada nas idealizações de Mualem (1976), comumente, referidas como expressões de Van Genuchten (1980) – Burdine (1953) e de Van Genuchten (1980) – Mualem (1976), segundo as Equações 11 e 12, respectivamente.

$$m_{vb} = 1 - \frac{2}{n_{vb}} \quad (9)$$

$$m_{vm} = 1 - \frac{1}{n_{vm}} \quad (10)$$

$$k_r(\psi) = \frac{k_w(\psi)}{k_s} = \frac{1 - (a_{vb}\psi)^{n_{vb}-2} [1 + (a_{vb}\psi)^{n_{vb}}]^{-m_{vb}}}{[1 + (a_{vb}\psi)^{n_{vb}}]^{2n_{vb}}} \quad (11)$$

$$k_r(\psi) = \frac{k_w(\psi)}{k_s} = \frac{\{1 - (a_{vm}\psi)^{n_{vm}-1} [1 + (a_{vm}\psi)^{n_{vm}}]^{-m_{vm}}\}^2}{[1 + (a_{vm}\psi)^{n_{vm}}]^{0,5}} \quad (12)$$

Onde:

k_r = coeficiente relativo de permeabilidade;

m_{vb} , n_{vb} e a_{vb} = parâmetros de ajuste do modelo de Van Genuchten (1980) – Burdine (1953);

m_{vm} , n_{vm} e a_{vm} = parâmetros de ajuste do modelo de Van Genuchten (1980) – Mualem (1976).

Contudo, os resultados fornecidos da avaliação da razoabilidade dessas relações, usando análise de regressão de melhor ajuste das informações de curvas de retenção recuperadas de um banco de dados, apontaram que tais associações não são representativas da maioria dos dados experimentais (FREDLUND; RAHARDJO; FREDLUND, 2012).

Logo, os modelos de Van Genuchten (1980) – Burdine (1953) e de Van Genuchten (1980) – Mualem (1976), com a finalidade de estimar a condutividade hidráulica em solos não saturados, consideram os seguintes fatores: coeficiente de permeabilidade saturado (k_s), sucção total (ψ) e os parâmetros de ajuste (a , m e n), relacionados à SWCC.

Fredlund, Xing e Huang (1994) empregaram a equação de Fredlund e Xing (1994) para a SWCC em conjunto com o modelo físico de Childs e Collis – George (1950), a fim de calcular a função de condutividade hidráulica a partir da execução de uma integração numérica ao longo da curva de retenção. Esse procedimento considerou insignificantes as alterações de volume da estrutura do solo e manteve a independência dos parâmetros de ajuste m_f , n_f e a_f da SWCC. A expressão elaborada pode ser definida de acordo com a Equação 13.

$$k_r(\psi) = \int_{\psi}^{\psi_r} \frac{\theta(y) - \theta(\psi)}{y^2} \theta'(y) dy / \int_{\psi_{aev}}^{\psi_r} \frac{\theta(y) - \theta_s}{y^2} \theta'(y) dy \quad (13)$$

Onde:

ψ_r = sucção total residual;

ψ_{aev} = sucção total de entrada de ar;

y = variável de integração, representando a sucção.

O termo θ' da Equação 13 corresponde à derivada da função de Fredlund e Xing (1994) que descreve a SWCC em toda a faixa de sucção, ou seja, de 0 à 10^6 kPa (Equação 14).

$$\theta = C(\psi) \frac{\theta_s}{\{\ln[e + (\psi/a_f)^{n_f}]\}^{m_f}} \quad (14)$$

Onde:

a_f = parâmetro relacionado ao AEV;

n_f = parâmetro que controla a inclinação do ponto de inflexção;

m_f = parâmetro relacionado ao teor de água residual;

e = número de Néper (2,71828);

$C(\psi)$ = função de correção, definida como:

$$C(\psi) = 1 - \frac{\ln(1+\psi/\psi_r)}{\ln(1+10^6/\psi_r)} \quad (15)$$

Para evitar dificuldades associadas à realização da integração além do AEV, é conveniente fazê-la em escala logarítmica, preferindo-se a seguinte variação da Equação 13:

$$k_r(\psi) = \int_{\ln(\psi)}^b \frac{\theta(e^y) - \theta(\psi)}{e^y} \theta'(e^y) dy / \int_{\ln(\psi_{aev})}^b \frac{\theta(e^y) - \theta_s}{e^y} \theta'(e^y) dy \quad (16)$$

b = limite superior de integração, igual a $\ln(10^6)$;

y = variável de integração, representando o logaritmo da sucção total;

e = número de Néper (2,71828).

Dessa forma, a sucção total (ψ) e o coeficiente de permeabilidade saturado (k_s), juntamente com o valor de entrada de ar (ψ_{aev}), o valor que representa o início das condições residuais (ψ_r) e a SWCC (θ') fornecem uma previsão da função de condutividade hidráulica por meio do modelo de Fredlund, Xing e Huang (1994).

2.6 Considerações parciais

A princípio, considerações gerais sobre mecânica dos solos não saturados foram abordadas, salientando definições básicas e temáticas como natureza, composição e ocorrência desses materiais, com o intuito estabelecer um entendimento inicial sobre o assunto.

Em seguida, uma breve explicação sobre a sucção foi realizada. Foram também discutidos assuntos relacionados à curva característica solo-água (SWCC) ou curva de retenção, como fatores que a influenciam e metodologias de previsão.

A necessidade de determinação do coeficiente de permeabilidade em solos não saturados, essencial em análises de fluxo, foi, então, evidenciada. Ressaltou-se, entretanto, que a obtenção direta desse parâmetro é demorada e dispendiosa. Dessa forma, em substituição aos métodos experimentais, técnicas de estimativa de tal coeficiente foram destacadas.

3 REDES NEURAIIS ARTIFICIAIS

Neste capítulo, são apresentadas algumas definições gerais relevantes à compreensão das redes neurais artificiais (RNA), bem como as descrições dos seus elementos básicos e o seu mecanismo de funcionamento. Em seguida, aplicações dessa ferramenta na engenharia são mencionadas, indicando características e performances de determinados modelos de estimativa do coeficiente de condutividade hidráulica.

3.1 Conceitos gerais sobre redes neurais artificiais

Mesmo havendo semelhanças quanto às funcionalidades do computador digital convencional e do cérebro humano, a percepção de que este processa informações de forma diferente daquele impulsionou estudos no âmbito das redes neurais artificiais (RNA), comumente referidas apenas como redes neurais (HAYKIN, 2001). O cérebro pode ser comparado a um computador com elevado desempenho, isto é, a um sistema de processamento de informação altamente complexo, não linear e paralelo, que executa rapidamente várias operações ao mesmo tempo. Na fase de desenvolvimento dos neurônios, o cérebro possui uma característica essencial, responsável pela adaptação do sistema nervoso ao meio ambiente, denominada de plasticidade. Essa qualidade é atribuída também às RNA, usadas para reproduzir determinada tarefa ou função de interesse realizada pelo cérebro.

Haykin (2001) conceitua RNA como um processador maciçamente e paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso, assemelhando-se ao cérebro em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente por intermédio de um processo de aprendizagem e as forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O modo como uma RNA é estruturada e as capacidades de aprender, generalizar e se adaptar conferem a essa ferramenta um enorme poder computacional que oferece as seguintes propriedades (HAYKIN, 2001):

- a) Não-linearidade: uma RNA é dita não-linear quando é composta por conexões de neurônios não-lineares, o que é muito importante principalmente se o mecanismo físico responsável pela geração do sinal de entrada também o é;
- b) Mapeamento de entrada-saída: construído para um problema considerado, durante o processo de aprendizagem supervisionada, a partir da aplicação de um

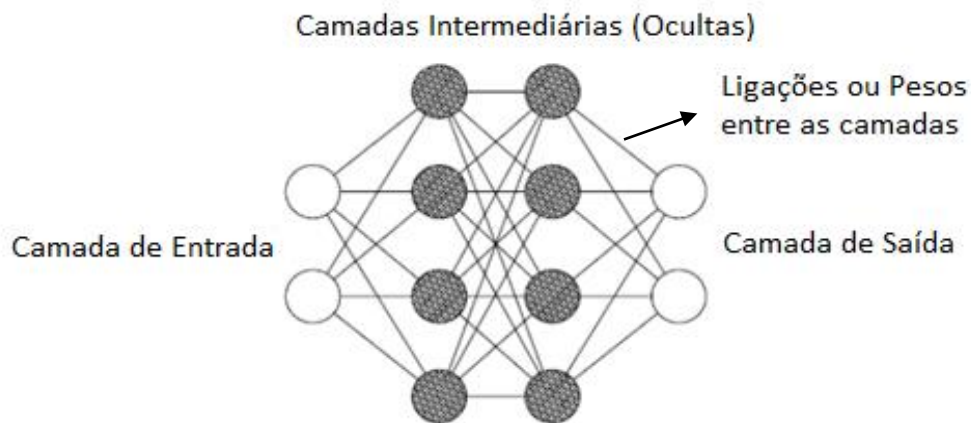
conjunto de treinamento rotulado, consistindo de sinais de entrada e de sinais de saída correspondentes, os quais são usados pela RNA para modificar os seus pesos sinápticos a fim de minimizar a diferença entre a resposta desejada e a resposta real da rede;

- c) Adaptabilidade: capacidade de modificar os pesos sinápticos em resposta às mudanças ambientais. Uma rede treinada para operar em um ambiente específico pode, com facilidade, ser retreinada para atender a pequenas alterações ambientais; além de, ao operar em um ambiente onde as estatísticas variam com o tempo (não-estacionário), poder ser projetada para modificar seus pesos sinápticos em tempo real. Para que a rede tenha uma boa performance em situações como essa, as constantes de tempo principais do sistema devem ser grandes o suficiente para ignorar perturbações irrelevantes e, ao mesmo tempo, pequenas o suficiente para considerar mudanças significativas no ambiente;
- d) Resposta a evidências: no contexto de classificação de padrões, um projeto de uma RNA pode oferecer tanto informações sobre qual padrão particular selecionar quanto sobre a confiança na decisão tomada, o que é interessante ao se rejeitar padrões ambíguos, caso estejam presentes;
- e) Informação contextual: cada neurônio é bastante influenciado pela ação de todos os outros neurônios da rede neural; tratando-se, pois, com naturalidade a informação contextual;
- f) Tolerância a falhas: o desempenho de uma RNA reduz lentamente em condições de operação adversas, ao invés de apresentar, a princípio, falha catastrófica. Devido à natureza distribuída da informação armazenada, o dano deve ser extenso para que a resposta global da rede seja degradada seriamente;
- g) Implementação em VLSI: o fornecimento de um meio de capturar comportamentos complexos de forma hierárquica é um dos benefícios da tecnologia *Very Large Scale Integration* (VLSI), cuja implementação torna-se adequada a uma RNA, devido a sua estrutura maciçamente paralela, fazendo-a ser potencialmente rápida em certas tarefas;
- h) Uniformidade de análise e projeto: universalidade das redes neurais como processadores de informação, visto que há uma padronização relativa à notação utilizada em todos os domínios que as envolvem;

- i) Analogia neurobiológica: a motivação do projeto de uma RNA é atribuída à analogia com o cérebro humano, o qual comprova que o processamento paralelo tolerante a falhas é rápido, poderoso e possível fisicamente.

Da perspectiva da matemática, uma rede neural é um agrupamento de neurônios, também chamados de nós computacionais, organizados em camadas consecutivas, com uma camada de entrada, uma ou mais camadas intermediárias (ocultas) e uma camada de saída, como pode ser visto na Figura 19. A quantidade de neurônios nas camadas de entrada e de saída é respaldada nos dados disponíveis e no tipo de problema, ao passo que o número de camadas e nós intermediários é definido durante o processo de pesquisa da estrutura que melhor representa o fenômeno em questão (SILVEIRA, 2014).

Figura 19 – Arquitetura de uma RNA multicamadas



Fonte: adaptada de Haykin (2001).

Uma das atividades mais importantes e difíceis na concepção de um modelo utilizando RNA é o estabelecimento de uma arquitetura adequada. A dificuldade reside em definir o número ótimo de camadas ocultas e de nós em cada uma delas, em razão de não existir uma teoria unificada para realização desse procedimento (NEJAD; JAKSA; MCCABE, 2009). Logo, a determinação da arquitetura ideal é dada por um processo de tentativa e erro.

Uma grande vantagem das redes neurais é a competência de fornecer respostas adequadas para um conjunto de dados diferente daquele imposto na etapa de treinamento. Tal habilidade demonstra que a aptidão dessa ferramenta transcende o mapeamento entrada-saída. No entanto, a adoção de muitos neurônios pode provocar a memorização de padrões de treinamento pela rede neural em substituição à extração de características gerais das variáveis de entrada, o que interfere na capacidade de generalização do conhecimento. Em contrapartida, ao admitir um número pequeno de nós computacionais, pode haver uma demora excessiva no

rastreamento de uma arquitetura com desempenho ótimo (BRAGA; CARVALHO; LUDEMIR, 2000).


A maneira pela qual os neurônios estão estruturados está diretamente relacionada ao critério estatístico orientador da modificação dos pesos sinápticos no processo de aprendizagem (HAYKIN, 2001). Segundo Braga, Carvalho e Ludemir (2000), a aprendizagem supervisionada é a mais comum no treinamento, a qual ajusta pesos sinápticos e bias encontrando uma ligação entre os pares de entradas e de saídas correspondentes fornecidos por um supervisor externo (professor). A alteração desses parâmetros da rede permite a aquisição da compreensão do evento em análise (SANTOS JR, 2006).

Tal método de aprendizagem é empregado em situações em que as variáveis de entrada e de saída são conhecidas para um caso real; possibilitando, assim, a comparação da resposta originada pela rede neural com a resposta desejada, relativa ao caso real. Desse confronto deriva um sinal de erro acionador de um mecanismo de controle que aplica uma sequência de ajustes corretivos aos pesos sinápticos, com o objetivo de diminuir a diferença entre esses valores até que o sistema encontre uma solução apropriada para os parâmetros livres da rede neural (KOVÁCS, 2002; SANTOS JR, 2006).

3.2 Neurônio biológico

A representação do sistema nervoso humano pode ser realizada considerando-o composto por três estágios. Como mostrado na Figura 20, no primeiro estágio, os receptores convertem estímulos do ambiente externo em pulsos elétricos, por meio dos quais a informação é transmitida para a rede neural. O cérebro (rede neural), no segundo estágio, recebe a informação e toma decisões apropriadas. Já os atuadores, no terceiro estágio, convertem os impulsos elétricos em respostas discerníveis (HAYKIN, 2001).

Figura 20 – Representação em diagrama de blocos dos três estágios do sistema nervoso

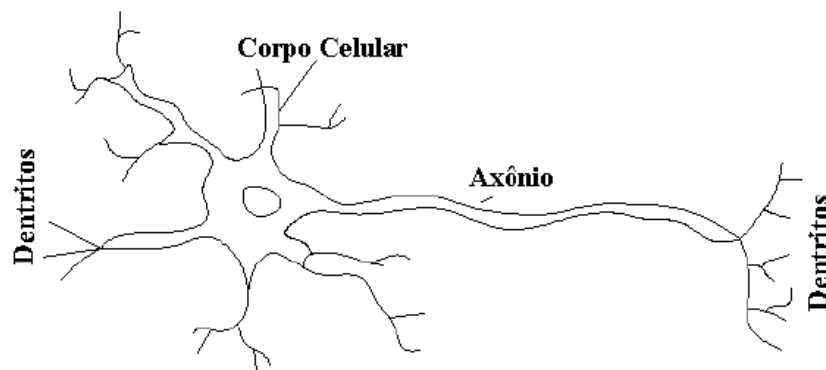


Fonte: Haykin (2001).

O cérebro é constituído por neurônios, que possuem uma diversidade de formas e tamanhos. A estrutura individual dos neurônios, bem como a tipologia de suas conexões e o seu comportamento conjunto formam o alicerce para o estudo das RNA (BRAGA; CARVALHO; LUDEMIR, 2000).

Um dos tipos mais comuns de neurônios corticais é a célula piramidal, apresentada na Figura 21. Essa célula é constituída por corpo celular, axônios (linhas de transmissão) e dendritos (zonas receptoras). Os dendritos recebem pulsos elétricos e os transmitem para o corpo celular, o qual os processa e, muitas vezes, codifica-os em uma série de pulsos breves de tensão ou potenciais de ação. Por sua vez, os axônios propagam esses pulsos elétricos e os transmitem as demais células nervosas com as quais se encontram conectados (ARAÚJO, 2015). Os dendritos e os axônios podem ser diferenciados segundo suas morfologias. Enquanto os primeiros são curtos, de superfície irregular e com muitas ramificações; os segundos possuem filamento longo, liso e com poucas ramificações, conforme visualizado na Figura 21.

Figura 21 – Neurônio biológico



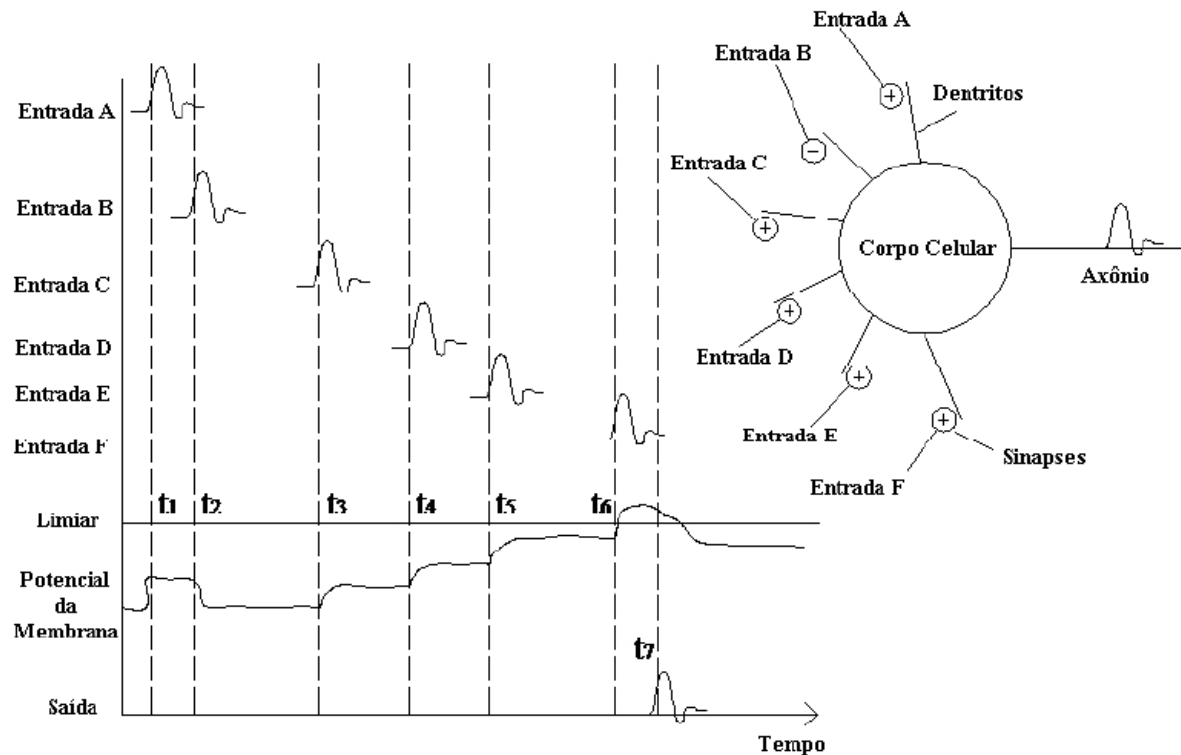
Fonte: adaptada de Haykin (2001).

No sistema nervoso humano, a interação entre os neurônios é mediada pelas sinapses, unidades estruturais e funcionais elementares que representam o nível mais fundamental de organização estrutural do cérebro, cuja atuação depende de íons e moléculas. Em sinapses químicas, a princípio, um sinal elétrico pré-sináptico é convertido em um sinal químico, ou seja, uma substância é liberada e propagada via junção sináptica dos neurônios. Posteriormente, no processo pós-sináptico, esse sinal químico é convertido, outra vez, em um sinal elétrico (HAYKIN, 2001).

Considera-se que a sinapse seja capaz de impor ao neurônio receptor ou uma inibição ou uma excitação. Um potencial designado de potencial elétrico de repouso da membrana é atribuído ao neurônio quando o corpo celular se encontra em estado de equilíbrio. À proporção que os dendritos são estimulados por outras células mediante sinapses, tal

potencial vai sofrendo variações, aumentando ou diminuindo em concordância com o tipo de estímulo produzido (excitatório ou inibitório). Quando o potencial da membrana atinge determinado limiar, resultante do acúmulo das contribuições de cada estímulo em intervalos de tempo diferentes, um pulso elétrico é, então, originado e transmitido para outros neurônios (ARAÚJO, 2015). A Figura 22 ilustra esse mecanismo.

Figura 22 – Mecanismo de produção de pulso elétrico em um neurônio biológico

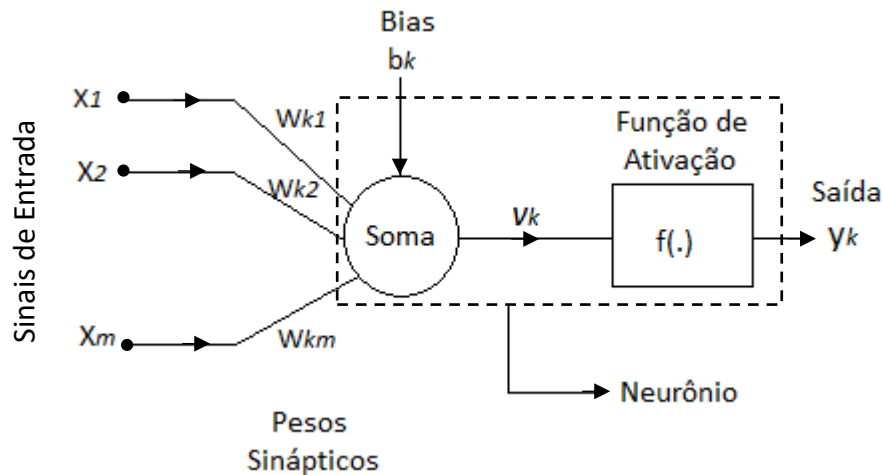


Fonte: Kovács (2002).

3.3 Neurônio artificial

O neurônio artificial é a unidade básica de processamento de dados de uma rede neural, cujo projeto baseia-se no modelo representado pelo diagrama de blocos da Figura 23 (HAYKIN, 2001).

Figura 23 – Neurônio artificial



Fonte: Haykin (2001).

A partir da Figura 23, podem ser identificados elementos fundamentais desse modelo, os quais são apresentados e descritos a seguir (HAYKIN, 2001):

- a) Conjunto de sinapses ou elos de conexão: são caracterizados por uma força própria, denominada de peso sináptico (w_{kj}), o qual pode estar compreendido em um intervalo que abrange valores positivos e negativos. Possuem a finalidade de armazenar informação, sendo modificados, durante o processo de aprendizagem, para alcançar os objetivos de projeto desejados;
- b) Combinador linear ou somador: soma os sinais de entrada ponderados pelas respectivas sinapses do neurônio;
- c) Função de ativação ($\varphi(\cdot)$): aplicada à saída do combinador linear para restringir a amplitude do sinal de saída do neurônio a um valor finito. Os três tipos básicos de funções de ativação, mais comumente utilizados, são: limiar, linear por partes e sigmoide. Em alguns casos, é desejável, que as funções limiar e sigmoide sejam estendidas a valores negativos; passando, então, a serem chamadas de função sinal e função tangente hiperbólica;
- d) Bias (b_k): parâmetro externo que pode ser comparado ao limiar do neurônio biológico e possui o efeito de aumentar ou diminuir a entrada da função de ativação, caso seja positivo ou negativo, respectivamente. Essa característica proporciona maior estabilidade à rede, aprimora sua capacidade de generalização e permite a consideração de um valor não relacionado aos fatores elencados pelos parâmetros de entrada (SANTOS JR, 2006).

Um neurônio k pode ser representado, matematicamente, por meio do seguinte par de equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (17)$$

$$y_k = \varphi(u_k + b_k) \quad (18)$$

Onde:

x_j = sinal de entrada correspondente à sinapse j ;

w_{kj} = peso sináptico do neurônio k , na sinapse j ;

u_k = saída do combinador linear do neurônio k ;

b_k = bias do neurônio k ;

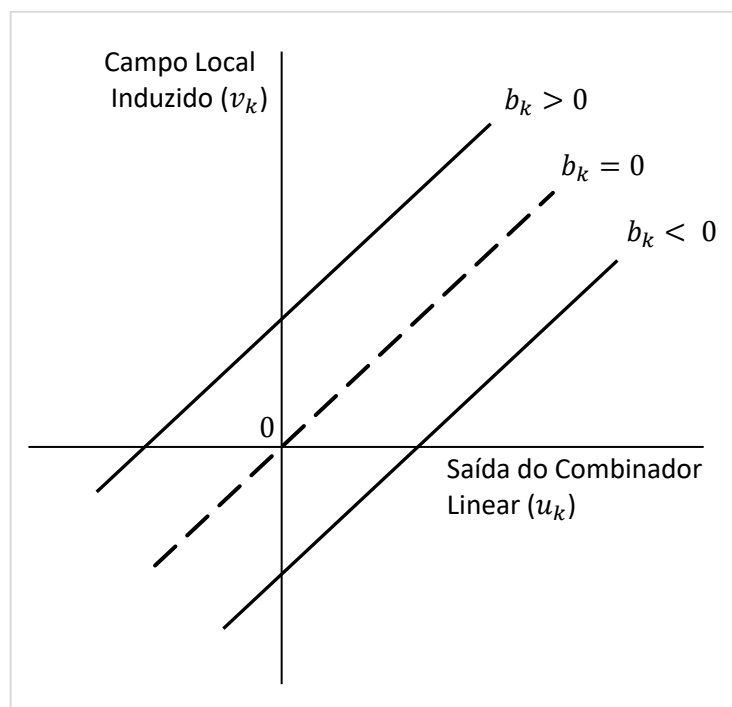
$\varphi(\cdot)$ = função de ativação;

y_k = sinal de saída do neurônio k .

A soma do bias (b_k) com a saída do combinador linear (u_k) é conhecida como potencial de ativação ou campo local induzido (v_k), segundo Equação 19. A relação entre os dois últimos termos é modificada, dependendo do valor do bias, conforme a Figura 24, onde se pode verificar que o gráfico v_k em função de u_k não passa mais pela origem.

$$v_k = u_k + b_k \quad (19)$$

Figura 24 – Relação entre v_k e u_k



Fonte: adaptada de Haykin (2001).

3.4 Perceptron multicamadas

O perceptron multicamadas, uma importante classe de RNA, é composto por, no mínimo, três camadas alimentadas adiante (acíclicas), isto é, a propagação dos sinais de entrada ocorre unicamente para frente, em direção aos neurônios de saída (HAYKIN, 2001).

A primeira camada constitui a camada de entrada, formada pelas unidades sensoriais, que fornecem os sinais de entrada. Em seguida, pode haver uma ou mais camadas intermediárias (ou ocultas), cuja função é intervir entre a entrada e a saída, de maneira útil, tornando a RNA capaz de aprender tarefas complexas ao extrair estatísticas de elevada ordem e informações mais significantes dos vetores de entrada. Por último, está a camada de saída, responsável por fornecer respostas para os estímulos impostos pelo ambiente externo (HAYKIN, 2001).

Outras características distintivas desse tipo de rede neural são o fato de cada neurônio incluir uma função de ativação não-linear suave, diferenciável em qualquer ponto, e o alto grau de conectividade exibido, determinado pelas sinapses (HAYKIN, 2001).

O perceptron multicamadas tem sido amplamente aplicado na resolução de problemas difíceis, por meio do paradigma de aprendizagem supervisionada, na qual um conhecimento prévio é apresentado à rede, fornecendo-a uma resposta desejada para determinado vetor de treinamento e a orientando na alteração de seus pesos sinápticos (HAYKIN, 2001).

A regra utilizada para a mudança dos parâmetros, baseada na aprendizagem por correção de erro, é denominada de algoritmo de retropropagação do erro (*error back-propagation*), que consiste em dois passos através das camadas da rede: um passo para frente, a propagação, e um passo para trás, a retropropagação. Na propagação, todos os pesos sinápticos são fixos. Em contrapartida, na retropropagação, esses pesos são ajustados de acordo com um sinal de erro, o qual é propagado no sentido contrário ao das conexões entre os neurônios (HAYKIN, 2001).

O sinal de erro de um neurônio k pertencente à última camada da rede, como o ilustrado pelo grafo de fluxo de sinal da Figura 25, é dado por (HAYKIN, 2001):

$$e_k(i) = d_k(i) - y_k(i) \quad (20)$$

Quando existem vários nós computacionais de saída, para os quais os sinais de erro podem ser calculados diretamente, a energia total do erro resulta da soma dos valores instantâneos das energias de todos esses neurônios, conforme Equação 21 (HAYKIN, 2001).

$$E(i) = \frac{1}{2} \sum_{k \in C} e_k^2(i) \quad (21)$$

Onde:

i = i -ésimo exemplo do conjunto de treinamento, apresentado à rede neural;

C = conjunto de todos os neurônios da camada de saída;


$e_k(i)$ = sinal de erro na saída do neurônio k ;

$d_k(i)$ = resposta desejada para o neurônio k ;

$y_k(i)$ = sinal funcional de saída do neurônio k ;

$E(i)$ = valor instantâneo da energia total do erro.

Figura 25 – Grafo de fluxo de sinal representativo do neurônio k da camada de saída da rede neural



Fonte: adaptada de Haykin (2001).

Para um certo conjunto de padrões de entrada, na metodologia de treinamento em lote, o desempenho de aprendizagem é avaliado pela função de custo $E_{med}(n)$, a qual é calculada a partir de $E(i)$, segundo a Equação 22. Em tal método, os pesos sinápticos são fixos para todos os exemplos, sofrendo alteração somente na mudança de uma época para outra (HAYKIN, 2001).

$$E_{med}(n) = \frac{1}{N} \sum_{i=1}^N E(i) \quad (22)$$

Onde:

$E_{med}(n)$ = energia média do erro ou erro quadrático médio;

n = passo de tempo discreto (época), correspondente a cada alteração do conjunto de pesos sinápticos;

N = número total de exemplos contidos no conjunto de treinamento.

O treinamento tem como objetivo fazer variar os parâmetros livres da rede, a cada etapa do processo, minimizando ao máximo e de forma incremental $E_{med}(n)$, até que o sistema atinja um estado estável. Desse modo, os ajustes sucessivos do vetor de pesos sinápticos do neurônio de saída k são feitos de maneira iterativa, de acordo com a Equação 23, percorrendo a superfície de erro $E_{med}(\{w_{kj}(n)\})$ no sentido oposto ao do gradiente do erro quadrático médio, cuja definição encontra-se na Equação 24 (HAYKIN, 2001).

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} + \{\Delta w_{kj}(n)\} \quad (23)$$

$$\nabla E_{med}(n) = \frac{\partial E_{med}(n)}{\partial w_{kj}(n)} \quad (24)$$

Onde:

$\{w_{kj}(n)\}$ = vetor de peso sináptico do neurônio k , conectado à saída do neurônio j ;

$\{\Delta w_{kj}(n)\}$ = ajuste do vetor de peso sináptico $\{w_{kj}(n)\}$;

$\nabla E_{med}(n)$ = gradiente do erro quadrático médio.

O ajuste do vetor de peso sináptico pode, então, ser escrito com base na seguinte expressão:

$$\{w_{kj}(n+1)\} = \{w_{kj}(n)\} - \eta \nabla E_{med}(n) \quad (25)$$

Onde:

η = taxa de aprendizagem.

Percebe-se, portanto, que a correção dos pesos sinápticos aplicada pelo algoritmo de retropropagação é proporcional à derivada parcial $\partial E_{med}(n)/\partial w_{kj}(n)$. Desenvolvendo-se a Equação 24, obtém-se, para o ajuste $\Delta w_{kj}(n)$, a Equação 26, conhecida como regra delta (HAYKIN, 2001).

$$\Delta w_{kj}(n) = \eta \delta_k(n) y_j(n) \quad (26)$$

Sendo:

$$\delta_k(n) = e_k(n) \varphi'_k(v_k(n)) \quad (27)$$

Onde:

$\delta_k(n)$ = gradiente local do neurônio de saída k ;

$y_j(n)$ = sinal de entrada do neurônio k , correspondente à saída do neurônio j .

Para o neurônio j , que pertence a uma camada intermediária da rede neural, como o apresentado na Figura 26, e para o qual não há uma resposta alvo especificada, a correção do peso sináptico $\Delta w_{ji}(n)$ atribuída a $w_{ji}(n)$ é definida pela Equação 28 (HAYKIN, 2001).

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (28)$$

Sendo:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (29)$$

Onde:

$\delta_j(n)$ = gradiente local do neurônio j ;


$y_i(n)$ = sinal de entrada do neurônio j , correspondente à saída do neurônio i .

A taxa de aprendizagem η diz respeito à velocidade com a qual os pesos sinápticos são modificados, compreendendo valores entre 0 e 1. O método da descida mais íngreme, fornecido pelo algoritmo em estudo, faz uso desse fator para percorrer a superfície do erro em direção a um ponto de mínimo. Valores baixos da taxa de aprendizagem refletem uma trajetória mais suave, ou seja, necessitam de um maior tempo para convergência. Por outro lado, valores mais altos representam grandes modificações nos pesos sinápticos entre iterações consecutivas, o que resulta em um processo de aprendizagem mais rápido. Precauções devem ser tomadas, neste último caso, pois a rede neural pode tornar-se oscilatória ao se elevar demais esse parâmetro (SILVEIRA, 2014).

Uma maneira de aumentar a taxa de aprendizagem de forma a afastar o perigo de instabilidade é incluir a constante de momento α , responsável por acelerar a descida em direções com declividade constante e capaz de evitar que a fase de aprendizagem termine em um mínimo local da superfície de erro. O acréscimo desse termo é mostrado na Equação 30, denominada de regra delta generalizada, a qual engloba a Equação 26 como um caso especial em que α é igual a 0.

$$\Delta w_{kj}(n) = \alpha \Delta w_{kj}(n-1) + \eta \delta_k(n) y_j(n) \quad (30)$$

Figura 26 – Grafo de fluxo de sinal representativo do neurônio j da camada oculta da rede neural



Fonte: adaptada de Haykin (2001).

3.5 Aplicações das redes neurais artificiais em engenharia

As RNA constituem uma ferramenta interessante que tem sido usada com êxito para auxiliar ou facilitar o exame de diversas situações importantes em diferentes ramos da engenharia. Trabalhos que aplicam essa técnica no âmbito da geotecnia foram desenvolvidos nas últimas décadas e são elencados a seguir de acordo com os seus respectivos assuntos.

- a) Capacidade de carga e recalque de fundações: Hanna, Morcoux e Helmy (2004); Shahin, Jaksa e Maier (2005); Das e Basudhar (2006); Shahin (2010); Amâncio (2013); Dantas Neto *et al.* (2014); Silveira (2014); Araújo (2015); Araújo, Dantas Neto e Anjos (2016); Liu *et al.* (2020); Pham *et al.* (2020); Rabiei e Choobbasti (2020); Wengang *et al.* (2020);
- b) Propriedades ou parâmetros geotécnicos dos solos e seu comportamento: Park (2011); Park e Lee (2011); Ismeik e Al-Rawi (2014); Tizpa *et al.* (2014); Javdanian, Jafarian e Haddad (2015); Dantas Neto *et al.* (2017); Sharma *et al.* (2017); Benbouras *et al.* (2018); Cui e Jing (2019); Mota (2019); Alam, Mondal e Shiuly (2020); Alsharari, Olenko e Abuel-Naga (2020); Hanandeh, Ardah e Abu-Farsakh (2020); Zhang *et al.* (2020);
- c) Estabilidade de taludes: Mayoraz e Vulliet (2002); Goh e Kulhawy (2003); Ferentinou e Sakellariou (2007); Cho (2009); Choobbasti, Farrokhzad e Barari (2009); Kaunda *et al.* (2010); Li *et al.* (2018); Qian *et al.* (2019); Tinoco *et al.*

- (2019); Ahour, Hataf e Azar (2020); Gao *et al.* (2020); Li, Lim e Fatty (2020); Marrapu e Jakka (2020); Wang, Moayedi e Kok Foong (2020);
- d) Liquefação do solo: Goh (2002); Baziar e Ghorbani (2005); Kim e Kim (2006); Hanna, Ural e Saygili (2007); Farrokhzad; Choobbasti e Barari (2010); Kumar, Venkatesh e Kumar (2012); Baziar e Saeedi Azizkandi (2013); Venkatesh, Kumar e Tiwari (2013); Rezaei e Choobbasti (2014); Abbaszadeh Shahri (2016); Xue e Liu (2017);
- e) Túneis ou aberturas subterrâneas: Benardos e Kaliampakos (2004); Yoo e Kim (2007); Javad e Narges (2010); Lai *et al.* (2015); Koopialipoor *et al.* (2019); Abolhosseini, Hashemi e Ajalloeian (2020); Hasanpour *et al.* (2020); Kovacevic, Bacic e Gavin (2020); Zhou *et al.* (2020).

A utilização de tal recurso é vantajosa, pois as RNA são capazes de aprender extraindo características a partir da imposição de um conjunto de exemplos e, posteriormente, generalizar a informação aprendida, originando respostas a problemas semelhantes aos dos exemplos apresentados (BOCANEGRA, 2002). As formas de aquisição, processamento e distribuição do conhecimento bem como sua capacidade adaptativa fazem com que as redes neurais tenham uma atuação bem sucedida, agindo em prol da resolução de problemas complexos, os quais podem estar ligados a inúmeras áreas da ciência (SILVA; SALES JÚNIOR, 2017).


Como uma forma de Inteligência Artificial (IA), as redes neurais tentam capturar relações funcionais sutis entre dados de um conjunto de referência, mesmo que o seu significado físico seja difícil de explicar. A incorporação da vivência do profissional por meio dos padrões impostos bem como a habilidade de aprender com a experiência conferem a essa ferramenta certa superioridade em comparação aos métodos empíricos e estatísticos mais tradicionais, os quais necessitam de um conhecimento prévio sobre a natureza da interação entre os dados (SILVEIRA, 2014). As RNA são, portanto, um recurso de modelagem adequado no que concerne ao comportamento complexo da maioria dos materiais de engenharia, que, por sua essência, exibem extrema variabilidade (SHAHIN; JAKSA; MAIER, 2008).

Desse modo, algumas pesquisas empregaram RNA na determinação das propriedades hidráulicas dos solos não saturados, em virtude da importância e da dificuldade de obtenção desses parâmetros.

Akbulut (2005), por exemplo, teve como objetivo elaborar um modelo de RNA para estimar a condutividade hidráulica de solos granulares, a fim de usá-lo em conjunto com testes de laboratório e de campo. Dessa forma, 95 ensaios foram realizados em diferentes meios

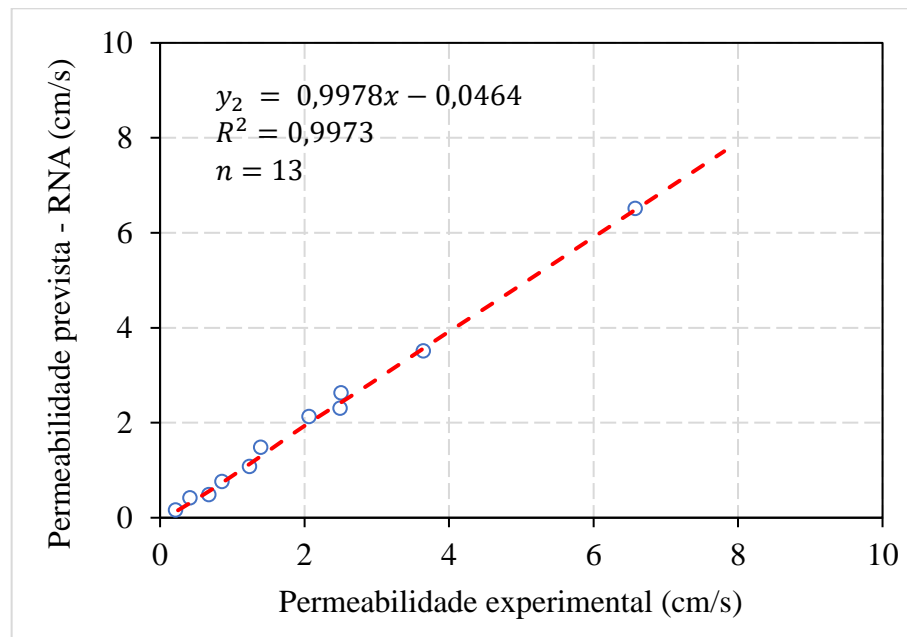
porosos granulares heterogêneos, dos quais 82 (86%) foram direcionados para treinar o sistema, e o restante (14%) foi usado na etapa de teste. Os parâmetros de entrada escolhidos para executar a modelagem foram: percentual de grãos finos (FC), de areia (SC) e de pedregulho (GC), diâmetros dos grãos da massa total de solo d_{10} e d_{50} e índice de vazios (e). A arquitetura projetada possui apenas uma camada oculta com doze neurônios de função de ativação sigmoide logarítmica (Figura 27). Com a finalidade de encontrar os pesos adequados, as iterações ocorreram, no treinamento, até que a soma do erro quadrático entre os valores calculados e medidos atingisse um número aceitável; que, nesse caso, foi estabelecido como igual a 0,17, alcançado com menos de 1000 épocas. O desempenho da rede neural foi comparado com os dados experimentais, obtendo um coeficiente de determinação (R^2) de 0,9993, no treinamento, e de 0,9973, no teste (Figura 28). O autor observou, portanto, que os resultados foram encorajadores e o modelo desenvolvido simulou bem a condutividade hidráulica.

Figura 27 – RNA usada para simular os efeitos das variáveis de entrada na permeabilidade



Fonte: adaptada de Akbulut (2005).

Figura 28 – Desempenho da RNA na previsão da permeabilidade em amostras de solo na fase de teste



Fonte: adaptada de Akbulut (2005).

Al-Sulaiman e Aboukarima (2016) criaram um modelo de previsão da condutividade hidráulica não saturada, com o auxílio de RNA, baseado em algumas propriedades químicas e físicas de solos agrícolas. As variáveis de entrada consideradas foram condutividade elétrica (EC), taxa de adsorção de sódio (SAR), teor de água inicial, teores de areia, silte e argila, densidade aparente e percentual de matéria orgânica. Em relação à variável de saída, apenas o coeficiente de condutividade hidráulica não saturado foi observado.

O conjunto de dados usados nos processos de treinamento e de teste consiste, respectivamente, de nove e três exemplos, cujas variáveis foram medidas em laboratório. O algoritmo de retropropagação do erro orientou a alteração dos pesos sinápticos. A arquitetura que obteve o melhor desempenho foi a A: 8-8-14-1. A Tabela 2 mostra uma descrição mais detalhada desse modelo.

Durante a fase de teste, os resultados obtidos para as formas de avaliação do erro entre o valor calculado pela rede neural e o valor medido são mostrados na Tabela 3. Esses critérios incluem o erro absoluto médio (MAE), a raiz do erro quadrático médio (RMSE) e o erro relativo médio (MRE). Os pequenos valores alcançados para tais parâmetros sugerem que o modelo escolhido foi preciso na previsão da permeabilidade de solos agrícolas não saturados.

Das oito variáveis de entrada definidas, as que apresentaram os maiores percentuais de contribuição foram o teor de argila, o teor de água inicial e a densidade aparente, com,

respectivamente, 22,2%, 20,63 % e 19,12%; enquanto as demais variáveis obtiveram percentuais de contribuição inferiores a 14%, de acordo com a Tabela 4.

A Figura 29 ilustra a relação, na fase de teste, entre o coeficiente de condutividade hidráulica não saturado medido e estimado usando o modelo desenvolvido. Nessa figura, pode-se perceber uma alta correlação representada por um coeficiente de determinação (R^2) de 0,9979.

Tabela 2 – Características do modelo que obteve o melhor desempenho

Definições da RNA	Valores
Número de camadas	4
Número de nós na camada de entrada	8
Número de nós na primeira camada oculta	8
Função de transferência	Sigmoide
Número de nós na segunda camada oculta	14
Função de transferência	Sigmoide
Iterações	10.000
Erro no treinamento	0,001277
Taxa de aprendizagem	0,095193
Fator de momento	0,8

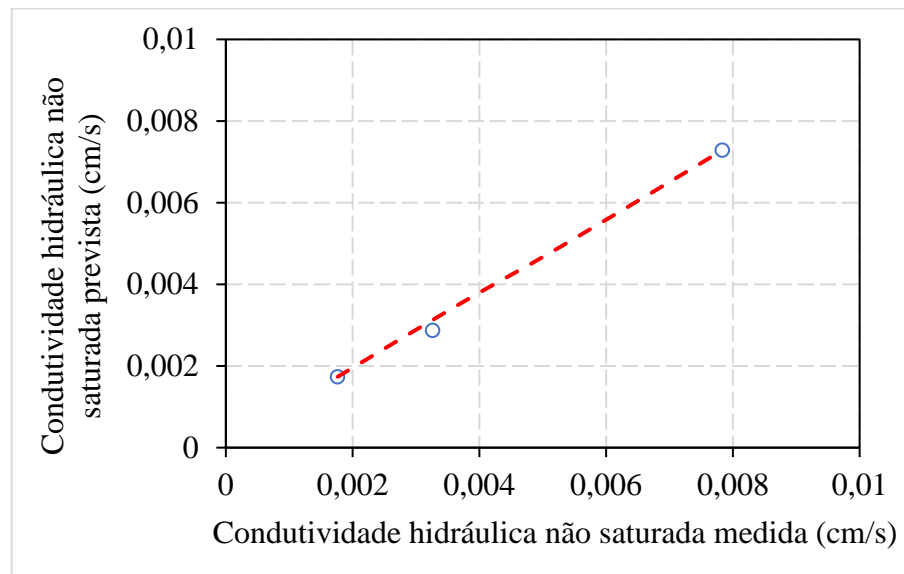
Fonte: adaptada de Al-Sulaiman e Aboukarima (2016).

Tabela 3 – Critérios de erro na fase de teste

Critério de erro	Unidade	Valor
RMSE	cm/s	0,000333251
MAE	cm/s	0,000284699
MRE	%	4,184
R^2	-	0,9979

Fonte: adaptada de Al-Sulaiman e Aboukarima (2016).

Figura 29 – Relação entre a condutividade hidráulica não saturada medida e calculada usando o modelo desenvolvido com RNA no teste



Fonte: adaptada de Al-Sulaiman e Aboukarima (2016).

Tabela 4 – Percentuais de contribuição das variáveis de entrada para o modelo de RNA desenvolvido

Variáveis de entrada	Contribuição (%)
Areia	2,50
Silte	13,06
Argila	22,02
EC	6,88
SAR	3,17
Matéria orgânica	12,62
Teor de água inicial	20,63
Densidade aparente	19,12

Fonte: adaptada de Al-Sulaiman e Aboukarima (2016).

Kruk *et al.* (2017) determinaram a permeabilidade hidráulica saturada com o uso de perceptrons multicamadas (MLP), a partir de dois diferentes conjuntos de dados de entrada. O primeiro é composto por dez parâmetros que são: diâmetros característicos d_{10} , d_{50} , d_{60} e d_{90} ; frações de areia (S), silte (Si) e argila (C); porosidade total (n); densidade aparente (BD) e teor de matéria orgânica (OMC), dos quais os seis com maior influência na obtenção da condutividade saturada foram usados para compor o segundo conjunto de dados de entrada.

Dos 56 exemplos resultantes de ensaios de laboratório em diferentes solos, 50% foram usados na fase de treinamento; 25% na fase de teste; e os outros 25% na fase de validação.

As melhores arquiteturas foram A: 10-10-1 (Figura 30), cujas funções de ativação das camadas oculta e de saída foram linear e exponencial, e A: 6-8-1, com ambas as camadas com função exponencial (Figura 31). Uma análise do desempenho desses modelos foi realizada por meio dos parâmetros: erro médio do prognóstico (MEP); raiz do erro médio quadrático (RMSE); erro médio percentual (MPE); eficiência do modelo (ME) e coeficiente de correlação (r), que são apresentados na Tabela 5. Embasados nesses valores, Kruk *et al.* (2017) concluíram que ambos os modelos atingiram resultados satisfatórios para os dados considerados. As Figuras 32 e 33 mostram gráficos comparativos entre a condutividade hidráulica prevista e a calculada pelos perceptrons.

As variáveis que mais influenciaram no cálculo da propriedade em estudo, após a realização de uma análise de sensibilidade global, foram os teores de argila (37,7%) e de areia (13,5%), os diâmetros d_{60} (17,1%) e d_{90} (6%), a densidade aparente (5,9%) e a porosidade total (5,7%), como ilustra a Tabela 6.

Tabela 5 – Medidas da eficiência dos modelos

Modelo de RNA	Medidas da eficiência				
	MEP ($m. d^{-1}$)	RMSE ($m. d^{-1}$)	MPE (%)	ME (-)	r (-)
MLP 10-10-1	0,036	0,104	35,900	0,998	0,989
MLP 6-8-1	0,079	0,208	54,800	0,912	0,955

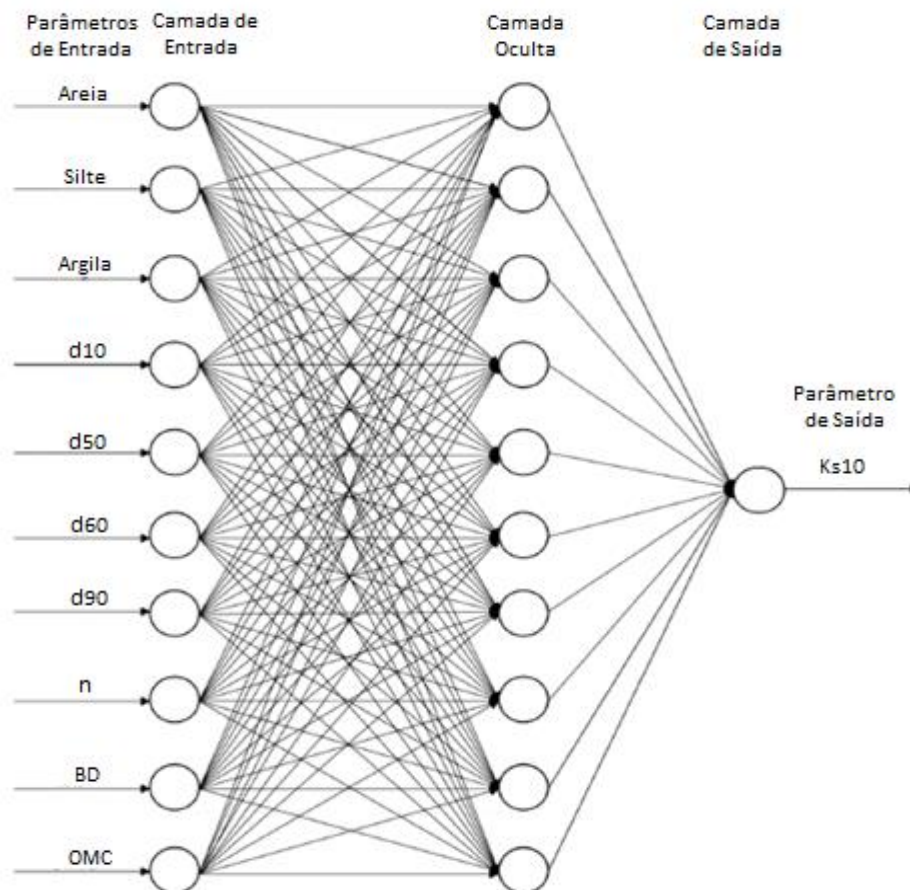
Fonte: adaptada de Kruk *et al.* (2017).

Tabela 6 – Análise da sensibilidade global

Parâmetros	Sensitividade relativa (-)	Influência absoluta (%)
Teor de argila (<i>C</i>)	608,600	37,7
Diâmetro d_{60}	275,204	17,1
Teor de areia (<i>S</i>)	218,437	13,5
Diâmetro d_{90}	96,538	6,0
Densidade aparente (<i>BD</i>)	95,570	5,9
Porosidade total (<i>n</i>)	91,979	5,7
Diâmetro d_{50}	77,717	4,8
Teor de silte (<i>Si</i>)	77,562	4,8
Diâmetro d_{10}	36,622	2,3
Teor de matéria orgânica (<i>OMC</i>)	34,370	2,1

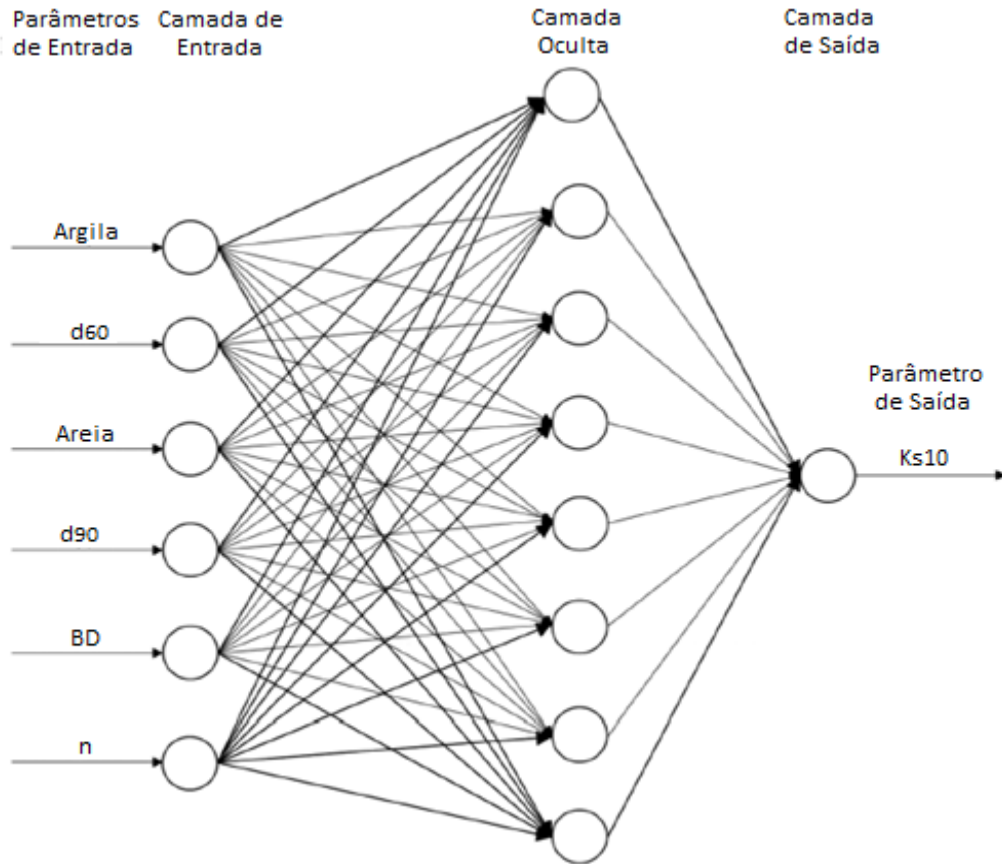
Fonte: adaptada de Kruk *et al.* (2017).

Figura 30 – Perceptron multicamadas de arquitetura A: 10-10-1




Fonte: adaptada de Kruk *et al.* (2017).

Figura 31 – Perceptron multicamadas de arquitetura A: 6-8-1




Fonte: adaptada de Kruk *et al.* (2017).

Figura 32 – Comparação entre a condutividade hidráulica saturada medida e calculada pelo modelo A: 10-10-1



Fonte: adaptada de Kruk *et al.* (2017).

Figura 33 – Comparação entre a condutividade hidráulica saturada medida e calculada pelo modelo A: 6-8-1




Fonte: adaptada de Kruk *et al.* (2017).

Sihag (2018) determinou a eficácia das RNA na estimativa da condutividade hidráulica não saturada, com o uso do algoritmo de retropropagação do erro. O solo selecionado para esse estudo é considerado como arenoso, pois a areia é o componente principal. Todavia, esse material possui também, em sua composição, cinzas volantes e cinzas de casca de arroz, as quais representam impurezas. Ensaios de laboratório foram feitos em amostras, resultando em um total de 46 dados, dos quais 70% foram usados no treinamento, e 30% escolhidos aleatoriamente para a fase de teste.

As variáveis de entrada foram: teores de areia (S), de cinzas volantes (F_a) e de cinzas de casca de arroz (R_{ha}), sucção (S_h), densidade aparente (B_d) e teor de umidade (M_c); enquanto a única variável de saída é a condutividade hidráulica não saturada (K_u). O modelo pré-determinado para análise de sua eficácia possui apenas uma camada oculta com oito neurônios (A: 6-8-1), cuja performance pode ser considerada adequada, com coeficiente de correlação (CC) de 0,8662 e raiz do erro quadrático médio (RMSE) de 4,5907 cm/h, na fase de teste. Segundo mostrado na Figura 34, uma semelhança entre os valores de K_u medidos e fornecidos por esse modelo pode ser verificada.

Figura 34 – Relação entre a condutividade hidráulica não saturada medida e calculada usando o modelo A: 6-8-1



Fonte: adaptada de Sihag (2018).

Totola (2020), por sua vez, avaliou o desempenho do uso de RNA na estimativa da curva de retenção (limite superior de secagem) para a faixa de sucção de 0 a 1500 kPa a partir de um banco de dados de solos de ambiente tropical e subtropical brasileiros, compostos em sua maioria por Planossolos, Latossolos e Argissolos. Duas diferentes topologias foram propostas: Pontual e Pseudocontínua. Além disso, fatores que influenciam a capacidade de previsão das RNA foram analisados, como geometria e estrutura das redes e adição dos parâmetros de entrada em uma estrutura hierárquica. Os parâmetros de entrada considerados incluíram distribuição granulométrica, densidade do solo e dos sólidos, porosidade total e teor de matéria orgânica. Os critérios de desempenho utilizados para avaliar a performance das RNA foram coeficiente de determinação (R^2) e raiz do erro quadrático médio (RMSE). Com base nesses critérios, Totola (2020) observou que a topologia pseudocontínua superou o desempenho da topologia pontual, bem como os valores de RMSE diminuíram de 0,048 para 0,029 cm^3/cm^3 quando mais preditores foram utilizados. O autor verificou ainda que o uso da mineralogia da argila é recomendado para a diminuição dos erros das estimativas no trecho seco da curva de retenção, pois as partículas do tamanho da argila são predominantes nos finos para solos tropicais.

3.6 Considerações parciais

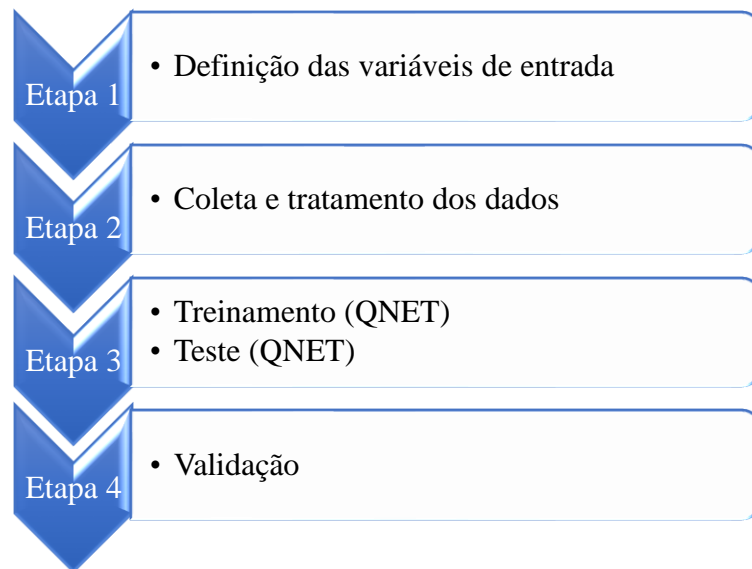
Inicialmente, explicações de conceitos relativos às redes neurais artificiais (RNA) foram apresentadas, listando algumas propriedades e vantagens desse recurso. Em seguida, o mecanismo de atuação de um neurônio biológico e seus componentes foram abordados, a fim de se fazer uma analogia com o modelo neuronal artificial básico. A metodologia de funcionamento de um tipo de RNA, os perceptrons multicamadas, foi então apresentada.

Por último, aplicações dessa ferramenta na engenharia foram citadas, tratando-se mais detalhadamente aquelas cujo objetivo refere-se à estimativa do coeficiente de condutividade hidráulica. Em tais pesquisas, verificou-se a obtenção de resultados satisfatórios, embasando, assim, o uso das RNA nesta dissertação.

4 METODOLOGIA DE DESENVOLVIMENTO DO MODELO DE PREVISÃO

A apresentação da metodologia empregada na concepção do modelo de previsão da condutividade hidráulica mediante redes neurais artificiais é realizada neste capítulo. Para tanto, as etapas de desenvolvimento dessa ferramenta são: definição das variáveis de entrada; levantamento e tratamento dos dados; treinamento e teste, utilizando diferentes arquiteturas, e posterior validação do modelo, conforme pode ser visualizado no fluxograma da Figura 35.

Figura 35 – Etapas de desenvolvimento do modelo de RNA



Fonte: Autora (2020).

4.1 Definição das variáveis de entrada

A determinação da função de permeabilidade é de extrema importância ao se estudar situações complexas que envolvem a percolação de água em meios porosos não saturados. As características dos solos são fatores relevantes que possuem influência na facilidade de escoamento do fluido nos vazios desses materiais. As variáveis de entrada do modelo neuronal desenvolvido neste trabalho foram definidas com base em estudos anteriores, apresentados no Capítulo 2, os quais forneceram subsídios para a identificação dos parâmetros que governam tal comportamento do solo.

Em virtude da dificuldade de obtenção do coeficiente de permeabilidade em solos não saturados (k_w), que constitui a saída do modelo proposto; a escolha do tipo de informação para compor o conjunto de sinais de entrada considerou ainda a simplicidade de determinação

de tais variáveis por meio de ensaios de laboratório ou de campo, as quais são apresentadas a seguir:

- a) Índice de vazios inicial (e_o), adimensional;
- b) Teor de umidade gravimétrico inicial (w_o) ou teor de umidade volumétrico variando com a sucção matricial (θ), em %;
- c) Fração de argila (C), em %;
- d) Fração de silte (M), em %;
- e) Fração de areia (S), em %;
- f) Índice de plasticidade (IP), em %;
- g) Coeficiente de permeabilidade saturado (k_{sat}), em cm/s;
- h) Sucção matricial ($u_a - u_w$), em kPa.

O teor de umidade gravimétrico e o índice de vazios foram escolhidos como variáveis de entrada, pois mudanças combinadas nesses dois parâmetros resultam em alterações no coeficiente de permeabilidade não saturado (FREDLUND; RAHARDJO; FREDLUND, 2012). Quanto menor o índice de vazios e o volume de água presente no solo, menor a área de seção transversal disponível para vazão e mais tortuoso o caminho percorrido pelo líquido.

Essa escolha pode também ser respaldada nos trabalhos de Al-Sulaima e Aboukarima (2016) e Akbulut (2005). Os primeiros autores realizaram uma modelagem com o auxílio de RNA para determinação do coeficiente de condutividade hidráulica, por meio da qual um percentual de contribuição de 20,63% para o teor de umidade inicial foi alcançado. Akbulut (2005), por sua vez, obteve resultados satisfatórios ao utilizar o índice de vazios como variável de entrada na previsão desse coeficiente.

Os percentuais de areia, silte e argila foram considerados por representarem a granulometria do material. Solos mais bem graduados possuem uma menor permeabilidade, pois as partículas de pequenos diâmetros preenchem os espaços vazios. Em contrapartida, solos mais uniformes possuem poros maiores, disponíveis para serem ocupados por água. Quando há uma parcela grande de partículas finas com plasticidade elevada, contudo, ocorre uma maior retenção da água, tornando mais difícil o seu escoamento (FREDLUND; RAHARDJO; FREDLUND, 2012).

As pesquisas de Akbulut (2005), Al-Sulaima e Aboukarima (2016) e Kruk *et al.* (2017), apresentadas no Capítulo 3, validaram o uso das frações de areia, silte e argila na estimativa do coeficiente de condutividade hidráulica, mediante RNA. Al-Sulaima e

Aboukarima (2016) e Kruk *et al.* (2017) obtiveram, respectivamente, contribuições de 37,76% e 56%, relativos à soma dos percentuais das três frações de solo.

No que se refere às sucções matriciais, valores crescentes de sucção aplicados a solos saturados causam uma diminuição da condutividade hidráulica. O coeficiente de permeabilidade saturado, por sua vez, representa o maior valor para a condutividade hidráulica e corresponde à condição saturada do solo (FREDLUND; RAHARDJO; FREDLUND, 2012).

Diversos modelos de previsão da condutividade hidráulica baseiam-se nesses dois parâmetros do solo, como os de Gardner (1958) e Brooks e Corey (1964). Além dessas técnicas, Sihag (2018) considerou a sucção como uma das variáveis de entrada de um modelo de RNA, com o objetivo de determinar a eficácia dessa ferramenta na estimativa da condutividade hidráulica em solos não saturados, obtendo, assim, um desempenho adequado.

Com o propósito de encontrar um modelo simplificado com o menor número de parâmetros envolvidos e que fosse capaz de oferecer um desempenho satisfatório na representação do fenômeno em estudo, três configurações de variáveis de entrada (C1, C2 e C3) foram empregadas no desenvolvimento da melhor arquitetura. De acordo com a Tabela 7, percebe-se que a diferença entre as conformações C1 e C2 reside apenas no fato de esta não possuir o teor de umidade inicial e nem o índice de vazios inicial; posto que, ao contrário do que se considera em C1, esses parâmetros variam com a sucção para um mesmo ensaio.

É importante ressaltar que a configuração C3 leva em conta dois aspectos relevantes: a redução da umidade com o aumento da sucção e a permeabilidade saturada como parte da variável de saída, correspondendo à condição de sucção igual a zero. Devido a isso, houve um menor número de exemplos para C3, pois a relação entre o teor de umidade e a sucção foi adquirida por meio da curva de retenção e um dos trabalhos utilizados para compor o conjunto de treinamento e de teste não apresentou essa informação.

Tabela 7 – Configurações consideradas para as variáveis de entrada

Configuração	Quantidade de variáveis de entrada	Variáveis de entrada consideradas
C1	8	$e_0, w_0, C, M, S, IP, k_{sat}, (u_a - u_w)$
C2	6	$C, M, S, IP, k_{sat}, (u_a - u_w)$
C3	6	$\theta^*, C, M, S, IP, (u_a - u_w)$


θ^* = teor de umidade volumétrico variando com a sucção matricial.

Fonte: Autora (2020).

Mesmo que todos os parâmetros escolhidos tenham influência sobre a condutividade hidráulica do solo, essas variáveis não são capazes, isoladamente, de representar


tal comportamento em sua totalidade. As Figuras 36 a 43, por exemplo, ilustram a elevada dispersão obtida, correlacionando cada variável de entrada com a permeabilidade do solo, a partir dos dados do conjunto experimental; mostrando, pois, a complexidade desse fenômeno, o qual é influenciado pela ação conjunta de uma variedade de fatores.

Figura 36 – Dispersão apresentada ao relacionar a sucção matricial e a condutividade hidráulica




Fonte: Autora (2020).

Figura 37 – Dispersão apresentada ao relacionar o índice de vazios e a condutividade hidráulica




Fonte: Autora (2020).

Figura 38 – Dispersão apresentada ao relacionar o teor de umidade gravimétrico e a condutividade hidráulica




Fonte: Autora (2020).

Figura 39 – Dispersão apresentada ao relacionar o percentual de argila e a condutividade hidráulica




Fonte: Autora (2020).

Figura 40 – Dispersão apresentada ao relacionar o percentual de silte e a condutividade hidráulica




Fonte: Autora (2020).

Figura 41 – Dispersão apresentada ao relacionar o percentual de areia e a condutividade hidráulica




Fonte: Autora (2020).

Figura 42 – Dispersão apresentada ao relacionar o índice de plasticidade e a condutividade hidráulica



Fonte: Autora (2020).

Figura 43 – Dispersão apresentada ao relacionar o coeficiente de condutividade hidráulica saturado e não saturado



Fonte: Autora (2020).

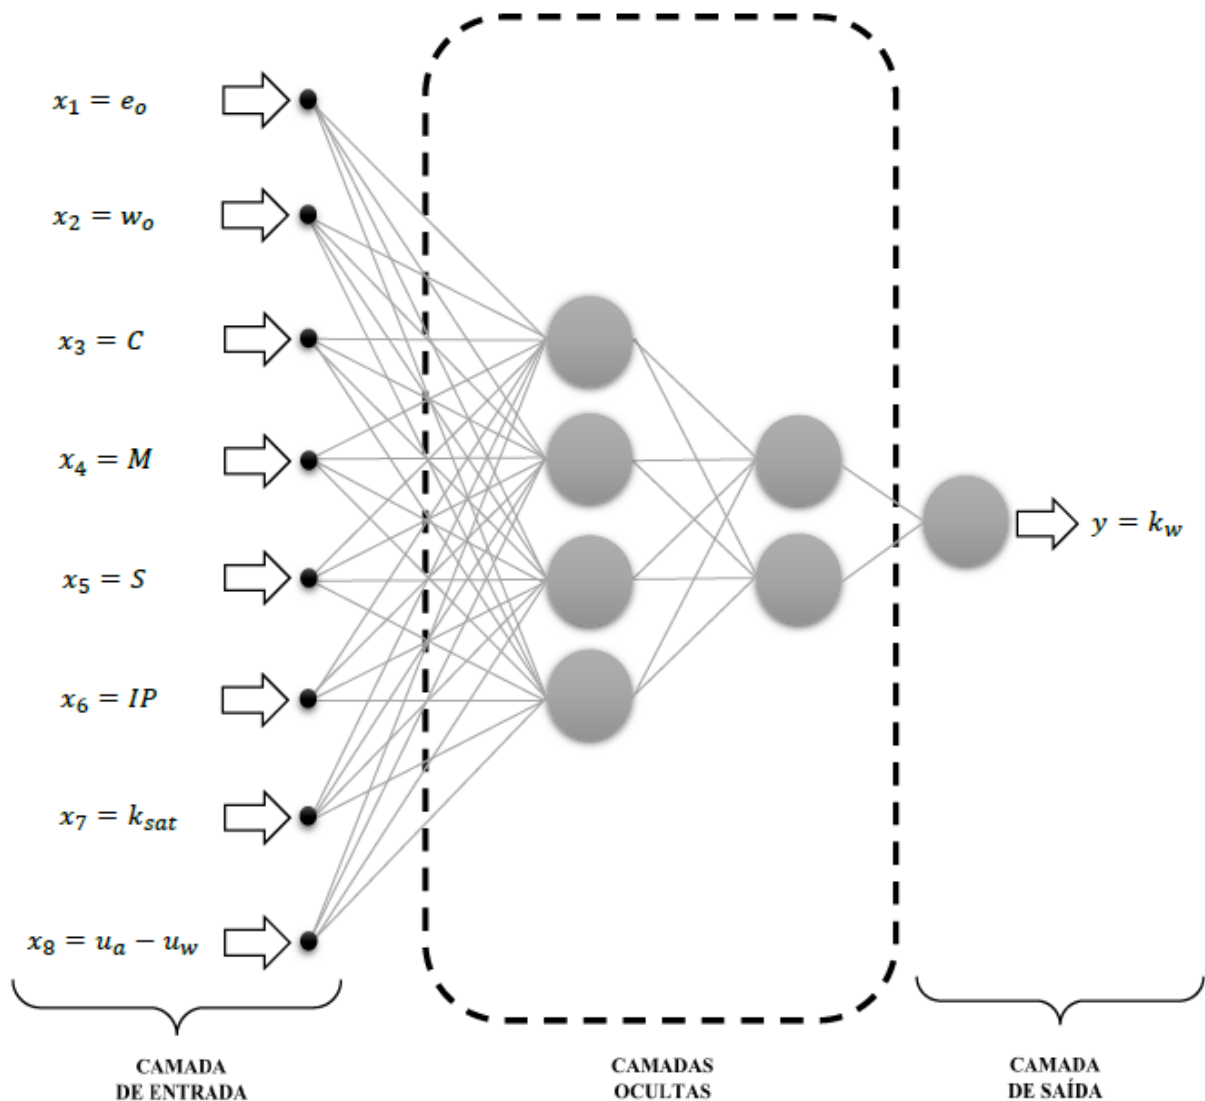
Dessa forma, a Equação 31 apresenta, de maneira generalizada, a RNA proposta nesta pesquisa, evidenciando a relação de dependência entre as variáveis de entrada e a de saída. A Figura 44, por sua vez, ilustra a estrutura típica de um perceptron multicamadas (MLP), tipo de rede neural empregada nesta dissertação, e as conexões entre essas variáveis, considerando a configuração C1.

$$k_w = f(e_o, w_o \text{ ou } \theta, C, M, S, IP, k_{sat}, u_a - u_w) \quad (31)$$

Onde:

f = função que representa a arquitetura, os pesos sinápticos e os bias de todos os neurônios da RNA.

Figura 44 – Estrutura típica de um MLP considerando a configuração C1



Fonte: Autora (2020).

4.2 Coleta e tratamento dos dados

Para a elaboração dos modelos de previsão procedeu-se, posteriormente, ao levantamento dos dados, a fim de compor o conjunto de padrões representativos da tarefa em questão. Essa busca ocorreu por meio de pesquisa na literatura científica, da qual resultou em mais de duzentos exemplos, obtidos experimentalmente por São Mateus e Vilar (1994); Conciani, Carneiro e Machado (1997); Gerscovich, Vargas Jr e Campos (1997); Gerscovich e Guedes (2004); Machado, Carvalho e Matta (2004); Lisboa (2006); Silva e Coutinho (2007); Mendes (2008); Fernandes e Vilar (2011). As Tabelas 8 e 9 apresentam a quantidade de exemplos, os tipos de solo conforme o Sistema Unificado de Classificação dos Solos (SUCS) e os ensaios relativos a cada referência, cujos resultados experimentais utilizados no desenvolvimento do modelo são mostrados nos Apêndices A, B e C.

Tabela 8 – Quantidade de exemplos utilizados por referência para C1 e C2

Configuração	Referência	Ensaio	Tipo de solo (SUCS)	Número de exemplos
C1 e C2	São Mateus e Vilar (1994)	1	SM	18
	Conciani, Carneiro e Machado (1997)	2	SC	12
	Gerscovich, Vargas Jr. e Campos (1997)	3	SM	28
	Gerscovich e Guedes (2004)	4	SM	7
	Machado, Carvalho e Matta (2004)	5	CH	40
	Silva e Coutinho (2007)	6	SC	22
	Fernandes e Vilar (2011)	7	SC	4
	Lisboa (2006)	8	MH	8
		9	SM	6
		10	CL	10
		11	MH	30
	Mendes (2008)	12	SM	30
		13	ML	30
		14	ML	30
			Total	275

Fonte: Autora (2020).

Tabela 9 – Quantidade de exemplos utilizados por referência para C3

Configuração	Referência	Ensaio	Tipo de solo (SUCS)	Número de exemplos
C3	São Mateus e Vilar (1994)	1	SM	19
	Conciani, Carneiro e Machado (1997)	2	SC	13
	Gerscovich, Vargas Jr. e Campos (1997)	3	SM	29
	Gerscovich e Guedes (2004)	4	SM	8
	Silva e Coutinho (2007)	5	SC	23
	Fernandes e Vilar (2011)	6	SC	5
		7	MH	9
	Lisboa (2006)	8	SM	7
		9	CL	11
		10	MH	31
	Mendes (2008)	11	SM	31
		12	ML	31
		13	ML	31
	Total			248

Fonte: Autora (2020).

Segundo Araújo (2015), o êxito de um modelo de previsão utilizando RNA depende de um grupo de entrada-saída amplo, abrangente e confiável. Caso os exemplos não representem com proximidade o fenômeno em estudo, as estimativas podem ser equivocadas. Mota (2019) ressalta a importância de se utilizar um vasto banco de dados para um bom funcionamento de uma RNA, pois, assim, há uma melhor generalização e se pode evitar o *overtraining*.

Desse modo, o banco de dados criado foi obtido dos resultados de testes em diferentes tipos de solos sob condições de contorno diversas, gerando um total de 275 padrões para C1 e C2, resultantes de 14 ensaios, e de 248 padrões para C3, resultantes de 13 ensaios (Tabelas 8 e 9).

As estatísticas dos dados são apresentadas na Tabela 10 e as suas distribuições de frequência são mostradas nas Figuras 45 a 52. Ao analisar as Figuras 45, 46 e 47, pode-se perceber a existência predominante de solos arenosos, todavia, fazem-se presentes também os siltosos e os argilosos, com índice de plasticidade variando desde zero (solos não plásticos) até 40% (solos muito plásticos), segundo visualizado na Figura 50. As Figuras 48 e 49 mostram uma concentração maior do índice de vazios inicial em valores elevados, em torno de 1,20, e do teor de umidade gravimétrico inicial entre os valores de 18% e 24%. Já, as Figuras 51 e 52


apresentam, respectivamente, uma maior frequência dos dados em torno das faixas de valores da ordem de 10^5 e 10^4 cm/s, para o coeficiente de permeabilidade saturado, e de 0,01 a 80 kPa, para a sucção matricial.

Tabela 10 – Estatísticas dos dados do conjunto experimental

Valor	e_o	w_o (%)	θ (%)	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	$u_a - u_w$ (kPa)	k_w (cm/s)
Mínimo	0,39	12,00	8,45	5,50	5,00	12,00	0,00	3,77E-05	0,01	1,30E-15
Máximo	1,41	46,00	55,00	52,00	48,00	64,00	40,00	4,60E-03	802,30	1,39E-03
Amplitude	1,02	34,00	46,55	46,50	43,00	52,00	40,00	4,56E-03	802,29	1,39E-03
Média	1,13	25,15	34,37	20,67	28,92	50,42	14,54	9,34E-04	85,40	6,62E-05
Desvio padrão	0,19	10,98	12,34	12,50	13,30	12,85	11,90	1,09E-03	147,81	1,70E-04
Coefficiente de variação (%)	17	44	36	60	46	25	82	116	173	257


Fonte: Autora (2020).

Figura 45 – Distribuição de frequência do percentual de argila




Fonte: Autora (2020).

Figura 46 – Distribuição de frequência do percentual de silte




Fonte: Autora (2020).

Figura 47 – Distribuição de frequência do percentual de areia




Fonte: Autora (2020).

Figura 48 – Distribuição de frequência do índice de vazios inicial




Fonte: Autora (2020).

Figura 49 – Distribuição de frequência do teor de umidade gravimétrico inicial




Fonte: Autora (2020).

Figura 50 – Distribuição de frequência do índice de plasticidade




Fonte: Autora (2020).

Figura 51 – Distribuição de frequência da permeabilidade saturada



Fonte: Autora (2020).

Figura 52 – Distribuição de frequência do sucção matricial



Fonte: Autora (2020).

A partir da Tabela 10 verifica-se que a maior variabilidade dos dados em relação à média da população é atribuída à sucção mátrica, a qual possui o mais alto coeficiente de variação de 173%. Por outro lado, o índice de vazios inicial apresentou um coeficiente de variação de 17%, configurando a menor dispersão em relação aos outros parâmetros, possuindo, assim, uma maior homogeneidade em termos de valores.

Embora algumas variáveis tenham apresentado uma concentração mais elevada próximo às suas médias, significando uma tendência natural dos solos ou uma amostragem defeituosa, estabeleceu-se a premissa de que o banco de dados era representativo da população, sendo capaz de generalizar situações reais semelhantes.

Limitações relativas à construção do banco de dados bem como à aplicação do modelo são listadas a seguir:

- a) A base de dados limitou-se às informações encontradas na literatura;
- b) Como os solos considerados são brasileiros, os dados coletados podem não representar claramente solos de outros países;
- c) Não foi possível verificar a veracidade das informações levantadas;
- d) O modelo desenvolvido pode não prever precisamente valores fora do intervalo referente aos dados utilizados para compor o conjunto de exemplos do fenômeno em estudo.

4.3 Treinamento, teste e validação

O desenvolvimento propriamente dito do modelo de RNA ocorreu por meio da análise de uma série de arquiteturas, a fim de identificar aquela capaz de representar o comportamento do solo no que diz respeito à condutividade hidráulica após as etapas de treinamento, teste e validação.

O *software* utilizado para a realização da modelagem foi o QNET 2000, pacote comercial que faz uso de redes neuronais de várias camadas alimentadas adiante (perceptrons multicamadas) submetidas ao treinamento supervisionado baseado na aprendizagem por correção de erro (HAYKIN, 2001). Esse programa foi escolhido por ter sido usado com êxito por autores como Silveira (2014); Araújo, Dantas Neto e Souza Filho (2015); Araújo, Dantas Neto e Anjos (2016); Dantas Neto *et al.* (2017) e Leite *et al.* (2019).

Para a construção do modelo, com o auxílio do QNET 2000, houve a divisão aleatória do padrões de entrada da seguinte maneira: 85% dos exemplos foram destinados à etapa de treinamento, e 15% designados para a etapa de teste. A separação dos dados nessa proporção foi fundamentada em trabalhos com frações aproximadas como os de Akbulut (2005); Samui (2012); Silveira (2014); Tizpa *et al.* (2014); Araújo (2015) e Mota (2019).

No decorrer da fase de treinamento, os fatores de ponderação sináptica foram alterados conforme o algoritmo de retropropagação do erro, apresentado no Capítulo 3, com o propósito de minimizar a função de custo, a partir das informações existentes no conjunto de treinamento. Assim, a rede neural é capaz de aprender o comportamento do fenômeno estudado, representado pelos dados impostos ao modelo. Para isso, com o objetivo de possibilitar uma convergência adequada, foram utilizadas as configurações padrões do *software* representadas por uma constante de momento (α) de 0,8 e uma taxa de aprendizagem (η) variando entre os valores 0,001 e 0,3, conforme os trabalhos similares de Amâncio (2013); Dantas Neto *et al.* (2014); Dantas Neto, Indraratna e Oliveira (2016); Leite (2019) e Mota (2019).

A constante de momento relaciona-se com a estabilidade do algoritmo de retropropagação e a taxa de aprendizagem é adotada dessa maneira, pois o programa otimiza os valores tornando a fase de treinamento mais rápida e diminuindo o risco de não convergência numérica. Haykin (2001) afirma que o uso da constante de momento juntamente com a taxa de aprendizagem traz benefícios para o processo de modelagem, pois evita oscilações da rede, possibilitando o alcance, após um baixo número de épocas, de um mínimo local da superfície de erro, de um mínimo global da superfície de erro ou de uma arquitetura com boa capacidade de generalização.

Com base ainda nos autores Amâncio (2013); Dantas Neto *et al.* (2014); Dantas Neto, Indraratna e Oliveira (2016); Leite (2019) e Mota (2019), a função de ativação selecionada para todos os neurônios das redes analisadas foi a sigmoide (Equação 32).

$$f(v_k) = \frac{1}{1+e^{-v_k}} \quad (32)$$

Como a função sigmoide é descrita dentro de um intervalo entre 0 e 1, é essencial a execução da normalização dos dados utilizados, que consiste em modificar todas as variáveis de entrada e de saída do conjunto experimental, conforme a Equação 33, de modo a transformá-las em valores pertencentes ao intervalo fechado compreendido entre 0,15 e 0,85. Tal procedimento foi realizado automaticamente pelo próprio *software*, permitindo, portanto, a compatibilidade entre o valor calculado pela rede e valor de referência imposto. Além disso, a normalização possibilitou também o cálculo do sinal de erro e dos gradientes locais necessários para otimizar os parâmetros livres, segundo o algoritmo de retropropagação padrão. A Tabela 10 mostra os valores máximos e mínimos, disponíveis no banco de dados, usados para normalizar todas as variáveis de entrada e de saída nas fases de treinamento e de teste.

$$\frac{x_{nor}-0,15}{0,85-0,15} = \frac{x-x_{mín}}{x_{máx}-x_{mín}} \quad (33)$$

Onde:

x_{nor} = variável resultante da normalização;

x = variável a ser normalizada;

$x_{mín}$ = valor mínimo da variável a ser normalizada;

$x_{máx}$ = valor máximo da variável a ser normalizada.

A etapa de teste avalia a capacidade da RNA de generalizar o conhecimento adquirido, oferecendo respostas satisfatórias a estímulos não submetidos previamente ao perceptron. Esse procedimento é de extrema importância, pois estabelece a qualidade do modelo ao verificar o seu desempenho por meio da comparação entre a saída da rede e a saída alvo, a partir de dados que não foram utilizados para alterar os fatores de ponderação sináptica (ARAÚJO, 2015).

Ambas as fases necessitam de monitoramento para identificar a ocorrência de *overtraining*, que ocorre quando a medida do erro calculado diminui no treinamento, porém, aumenta no teste, após um determinado número de iterações (KRÖSE; SMAGT, 1996). Esse treinamento excessivo ocasiona uma falta de aptidão para generalizar o conhecimento, fazendo com que a RNA apenas memorize os exemplos existentes, em vez de executar corretamente o

mapeamento entrada-saída. A identificação do *overtraining* pode ocorrer ao analisar, por exemplo, as variações nas funções da raiz do erro quadrático médio (RMS), definido pela Equação 34, tanto no treinamento como no teste (DANTAS NETO *et al.*, 2017). Meulenkamp e Grima (1999) mencionam que, embora o algoritmo de aprendizagem alcance a convergência e não haja aumento na função de erro, ainda assim pode ocorrer o *overtraining* se muitas iterações forem usadas para treinar a rede neural.

$$RMS = \sqrt{\sum \frac{(d_k - y_k)^2}{n}} \quad (34)$$

Onde:

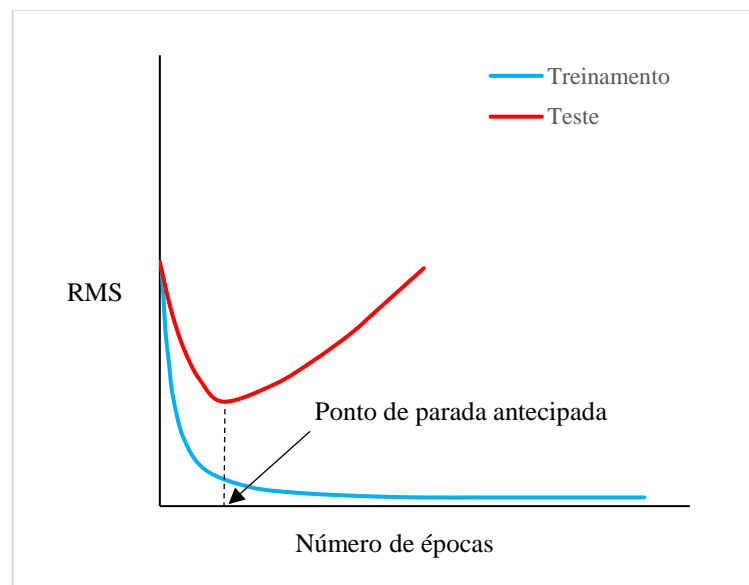
d_k = saída desejada, pertencente ao banco de dados;

y_k = saída calculada pela RNA;

n = número de exemplos.

A Figura 53 mostra a curva da raiz do erro quadrático médio (RMS) *versus* o número de épocas para o treinamento e para o teste. A partir do ponto de mínimo da curva de teste, no qual se inicia o *overtraining*, o que a rede aprende é considerado apenas ruído contido no conjunto de dados de entrada; sugerindo, então, que esse ponto possa ser usado como critério de parada do treinamento (HAYKIN, 2001).

Figura 53 – Critério de parada antecipada para otimização da RNA



Fonte: adaptada de Haykin (2009).

Além do RMS, o coeficiente de correlação (R), descrito pela Equação 35, também foi usado para aferir a qualidade do ajuste do modelo. Dessa maneira, a melhor arquitetura foi estipulada como sendo aquela com maior R^2 (coeficiente de determinação), no teste, sem a verificação de *overtraining*.

$$R = \left(\frac{Cov(X,Y)}{DP(X)DP(Y)} \right) \quad (35)$$

Onde:

$Cov(X, Y)$ = covariância entre duas variáveis aleatórias X e Y;

$DP(X)$ = desvio padrão de X;

$DP(Y)$ = desvio padrão de Y.

Durante a modelagem, diversas arquiteturas foram analisadas para todos os tipos de configurações dos parâmetros de entrada. Após um número de 500 mil iterações, os processos de treinamento e de teste foram interrompidos. A otimização dos pesos sinápticos ocorreu até 500 mil iterações, pois, segundo Dantas Neto *et al.* (2017), esse número é considerado suficiente para definir a convergência do algoritmo de treinamento ou o início do *overtraining*.

A Tabela 11 mostra a quantidade de arquiteturas analisadas por configuração das variáveis de entrada. A Tabela 12, por sua vez, apresenta todas as arquiteturas avaliadas, sendo A: X-Y-Z o código que representa um modelo constituído por uma camada de entrada com X estímulos, uma camada oculta com Y nós computacionais e uma camada de saída com Z neurônios.

Tabela 11 – Quantidade de arquiteturas analisadas para cada tipo de configuração das variáveis de entrada

Configuração das variáveis de entrada	Quantidade de arquiteturas analisadas
C1	20
C2	17
C3	18
Total	55

Fonte: Autora (2020).

Tabela 12 – Arquiteturas analisadas para cada tipo de configuração das variáveis de entrada (continua)

Configuração das variáveis de entrada	Arquitetura
C1	A: 8-14-10-10-1
	A: 8-14-10-8-1
	A: 8-14-10-4-1
	A: 8-14-8-4-1
	A: 8-10-5-2-1
	A: 8-14-10-1
	A: 8-14-7-1
	A: 8-12-10-1
	A: 8-12-6-1
	A: 8-10-10-1
	A: 8-10-8-1
	A: 8-10-5-1
	A: 8-8-8-1
	A: 8-8-4-1
	A: 8-4-4-1
	A: 8-4-2-1
	A: 8-12-1
	A: 8-10-1
	A: 8-8-1
	A: 8-4-1
C2	A: 6-14-10-10-1
	A: 6-12-10-8-1
	A: 6-10-8-4-1
	A: 6-10-5-2-1
	A: 6-14-10-1
	A: 6-12-8-1
	A: 6-10-12-1
	A: 6-10-10-1
	A: 6-10-8-1
	A: 6-8-12-1
	A: 6-8-4-1
	A: 6-6-6-1
	A: 6-6-4-1
	A: 6-4-2-1
	A: 6-10-1
A: 6-8-1	
A: 6-6-1	

Tabela 12 – Arquiteturas analisadas para cada tipo de configuração das variáveis de entrada (conclusão)

Configuração das variáveis de entrada	Arquitetura
C3	A: 6-14-10-10-1
	A: 6-14-10-8-1
	A: 6-12-10-8-1
	A: 6-10-8-4-1
	A: 6-10-5-2-1
	A: 6-14-10-1
	A: 6-12-8-1
	A: 6-10-12-1
	A: 6-10-10-1
	A: 6-10-8-1
	A: 6-8-12-1
	A: 6-8-4-1
	A: 6-6-6-1
	A: 6-6-4-1
	A: 6-4-2-1
	A: 6-10-1
A: 6-8-1	
A: 6-6-1	

Fonte: Autora (2020).

Para cada configuração e arquitetura, foram plotados gráficos do coeficiente de correlação *versus* o número de iterações, para a fase de teste. Baseando-se nesses gráficos, foram identificadas as arquiteturas com uma, duas e três camadas ocultas cujas correlações correspondentes a 300 mil iterações possuíram valores máximos, a fim de empregá-las na etapa seguinte: a validação.

A fase de validação foi realizada em duas etapas. Na primeira, as cinco arquiteturas de cada configuração que obtiveram maior coeficiente de correlação no teste foram comparadas com os resultados do método de previsão da condutividade hidráulica de Van Genuchten (1980) e com os resultados de cinco ensaios do conjunto experimental, obtidos nos trabalhos de Gerscovich, Vargas Jr e Campos (1997) (Ensaio 3); Gerscovich e Guedes (2004) (Ensaio 4); Mendes (2008) (Ensaio 11 e 14) e Fernandes e Vilar (2011) (Ensaio 7). Fundamentando-se nessa comparação, a arquitetura com melhor desempenho foi, então, selecionada.

Inicialmente, na primeira etapa da validação, houve a obtenção dos parâmetros do modelo de Van Genuchten (1980) para os dados dos ensaios mencionados anteriormente, com

o auxílio do programa RETC (*Retention Curve*). Esse *software* pode ser empregado para descrever as propriedades hidráulicas dos solos não saturados, ajustando modelos analíticos aos dados de retenção e/ou condutividade observados. A curva de retenção pode ser representada pelas equações de Van Genuchten (1980) ou de Brooks e Corey (1964), enquanto a função de permeabilidade pode ser formulada em termos das teorias estatísticas de distribuição do tamanho dos poros de Mualem (1976) ou de Burdine (1953). O RETC utiliza-se de uma abordagem de otimização de mínimos quadrados não linear para estimar coeficientes desconhecidos de expressões para as curvas de retenção e de permeabilidade, baseando-se em redes neurais artificiais (VAN GENUCHTEN; LEIJ; YATES, 1991).

Em seguida, uma vez que tais parâmetros foram determinados, foi possível identificar os gráficos que representam a condutividade hidráulica em função da sucção matricial referentes ao modelo de Van Genuchten (1980) para os cinco solos dos ensaios supracitados.

Na segunda etapa da validação, realizou-se uma análise de fluxo transiente em uma barragem na condição de enchimento a partir da função de condutividade hidráulica prevista pelo modelo de RNA desenvolvido. Para isso, foi utilizado o programa de modelagem Slide, que permitiu uma investigação completa de tal ocorrência. A realização da simulação numérica teve como objetivo apenas verificar a sensibilidade do resultado da análise de fluxo obtido com o modelo neuronal.

5 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Este capítulo encontra-se estruturado em três etapas, nas quais é realizada uma análise dos resultados obtidos no decorrer do processo de desenvolvimento do modelo de estimativa da função de condutividade hidráulica em solos não saturados. Inicialmente, os resultados da modelagem com a utilização do *software* QNET são examinados. Em seguida, ocorre a seleção da arquitetura de melhor desempenho, que é validada comparando-a com os dados experimentais e com o modelo de Van Genuchten (1980). Por fim, a rede neural selecionada é aplicada em uma simulação numérica de uma barragem na condição de enchimento.

5.1 Treinamento e teste

Com o intuito de elaborar uma ferramenta com a qual fosse possível obter o coeficiente de condutividade hidráulica de solos não saturados a partir de parâmetros de simples determinação, as variáveis de entrada da rede neural foram estabelecidas e, em seguida, um banco de dados foi formado por meio de pesquisa na literatura científica. De posse desses dados, pôde-se dar início ao treinamento e ao teste. Durante essas fases, foram avaliadas 55 arquiteturas, que levaram em consideração três combinações diferentes (C1, C2 e C3) entre os parâmetros de entrada. As Equações 36, 37 e 38 representam, simplificada, as três categorias de modelo sugeridas por esta dissertação.

$$C1 \quad \Rightarrow \quad k_w = f(e_o, w_o, C, M, S, IP, k_{sat}, u_a - u_w) \quad (36)$$

$$C2 \quad \Rightarrow \quad k_w = f(C, M, S, IP, k_{sat}, u_a - u_w) \quad (37)$$

$$C3 \quad \Rightarrow \quad k_w = f(\theta, C, M, S, IP, u_a - u_w) \quad (38)$$

O método de tentativa e erro conduziu a procura pela arquitetura ideal para a rede neural, alterando-se somente a quantidade de camadas intermediárias e/ou o número de nós computacionais ocultos, uma vez que o problema em evidência é responsável por determinar a quantidade de sinais de entrada e de neurônios de saída. Nesta pesquisa, essas quantidades são 8 ou 6 nós de entrada, conforme a configuração considerada (C1, C2 ou C3), e apenas 1 neurônio de saída.

O conjunto de exemplos da tarefa foi, então, separado de forma aleatória em 85% para o treinamento e 15% para o teste. O processo de otimização dos fatores de ponderação sináptica ocorreu até 500 mil iterações, interrompendo-se, em seguida, o treinamento.


As Figuras 54 a 65 mostram o RMS e a correlação para as cinco melhores arquiteturas de cada configuração com uma, duas e três camadas intermediárias e o Apêndice D apresenta esses parâmetros para o restante das estruturas analisadas.

Conforme pode ser visualizado nessas figuras, embora o *overtraining* esteja presente em grande parte das estruturas de configurações C2 e C3 analisadas, tal fenômeno não ocorre para a maioria das estruturas de configuração C1. O início do *overtraining* pode ser claramente observado, por exemplo, nas Figuras 66 e 67; onde o RMS aumenta no teste enquanto continua a diminuir na fase de treinamento para as arquiteturas A: 6-12-8-1 (C2) e A: 6-6-1 (C3), a partir das iterações respectivas de 200 mil e 400 mil. Verifica-se ainda que, para quase todas as arquiteturas exibidas entre as Figuras 54 e 65, as correlações atingiram valores altos (próximos a 0,90) com menos de 200 mil iterações em ambas as etapas.

Os maiores coeficientes de correlação, na fase de teste, para C1, C2 e C3 foram, nessa ordem, 0,97, 0,92 e 0,92. Tendo em vista esses valores, nota-se que não houve vantagem ao reduzir o número de variáveis de entrada de oito para seis e nem ao considerar o teor de umidade variando com a sucção, uma vez que a melhor relação entre o grupo de dados experimentais e o grupo composto pelos sinais de saída das redes neurais foi obtida levando em consideração os parâmetros mostrados na Equação 36.


De modo geral, ao aumentar o número de camadas ocultas de um para dois, os resultados tornaram-se melhores. No entanto, ao realizar o acréscimo de duas para três camadas ocultas, não se perceberam muitos benefícios.

Figura 54 – Correlação para as cinco melhores arquiteturas de configuração C1 - Treinamento




Fonte: Autora (2020).

Figura 55 – RMS para as cinco melhores arquiteturas de configuração C1 - Treinamento




Fonte: Autora (2020).

Figura 56 – Correlação para as cinco melhores arquiteturas de configuração C1 - Teste




Fonte: Autora (2020).

Figura 57 – RMS para as cinco melhores arquiteturas de configuração C1 - Teste




Fonte: Autora (2020).

Figura 58 – Correlação para as cinco melhores arquiteturas de configuração C2 - Treinamento




Fonte: Autora (2020).

Figura 59 – RMS para as cinco melhores arquiteturas de configuração C2 - Treinamento




Fonte: Autora (2020).

Figura 60 – Correlação para as cinco melhores arquiteturas de configuração C2 - Teste




Fonte: Autora (2020).

Figura 61 – RMS para as cinco melhores arquiteturas de configuração C2 - Teste




Fonte: Autora (2020).

Figura 62 – Correlação para as cinco melhores arquiteturas de configuração C3 - Treinamento




Fonte: Autora (2020).

Figura 63 – RMS para as cinco melhores arquiteturas de configuração C3 - Treinamento




Fonte: Autora (2020).

Figura 64 – Correlação para as cinco melhores arquiteturas de configuração C3 - Teste




Fonte: Autora (2020).

Figura 65 – RMS para as cinco melhores arquiteturas de configuração C3 - Teste




Fonte: Autora (2020).

Figura 66 – Início do *overtraining* para a arquitetura A: 6-12-8-1 de configuração C2



Fonte: Autora (2020).

Figura 67 – Início do *overtraining* para a arquitetura A: 6-6-1 de configuração C3



Fonte: Autora (2020).

5.2 Definição do modelo


Curvas que representam a mudança da correlação no teste em função do número de iterações foram plotadas e utilizadas para identificar as cinco arquiteturas com o maior coeficiente de determinação (R^2), com uma, duas e três camadas intermediárias para cada combinação entre as variáveis de entrada (Figuras 68, 69 e 70). Um resumo dessas estruturas é apresentado na Tabela 14, que mostra também o máximo valor atingido para a correlação, juntamente com a raiz do erro quadrático médio e a iteração correspondentes.

Tabela 13 – Resumo das arquiteturas utilizadas no primeiro estágio da fase de validação

Configuração	Arquitetura	Correlação	RMS	Iteração
C1	A: 8-4-1	0,89	0,027	500 mil
	A: 8-4-2-1	0,97	0,016	400 mil
	A: 8-14-10-1	0,96	0,018	500 mil
	A: 8-10-5-2-1	0,97	0,016	450 mil
	A: 8-14-10-10-1	0,96	0,017	300 mil
C2	A: 6-10-1	0,83	0,030	500 mil
	A: 6-4-2-1	0,90	0,024	250 mil
	A: 6-12-8-1	0,90	0,023	200 mil
	A: 6-10-5-2-1	0,92	0,022	500 mil
	A: 6-14-10-10-1	0,91	0,024	350 mil
C3	A: 6-6-1	0,92	0,039	450 mil
	A: 6-8-12-1	0,92	0,057	400 mil
	A: 6-12-8-1	0,92	0,039	100 mil
	A: 6-10-5-2-1	0,92	0,051	50 mil
	A: 6-14-10-10-1	0,92	0,037	300 mil


Fonte: Autora (2020).

Figura 68 – Evolução do coeficiente de correlação no teste – Configuração C1



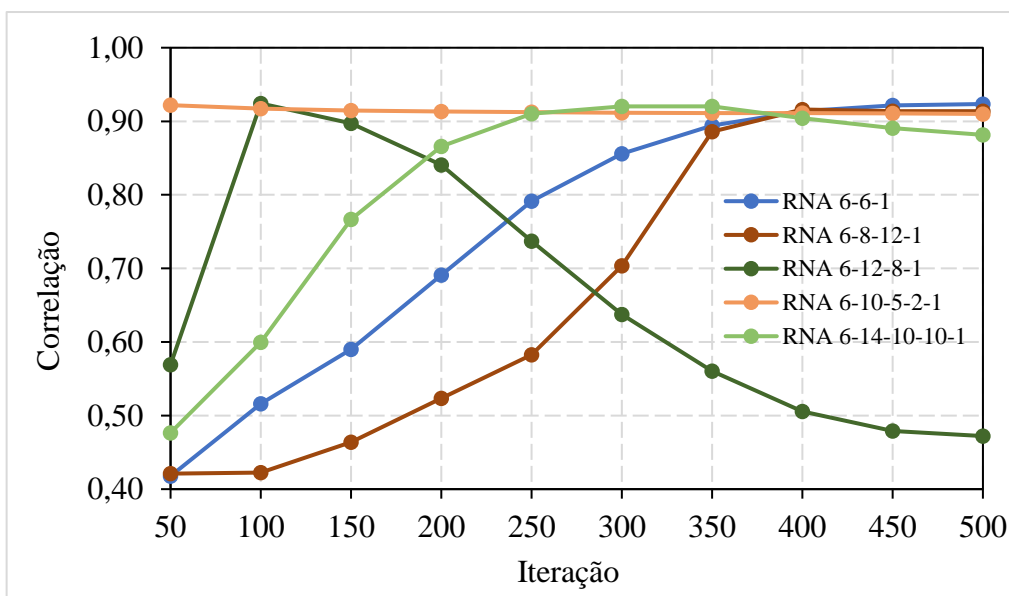
Fonte: Autora (2020).

Figura 69 – Evolução do coeficiente de correlação no teste – Configuração C2



Fonte: Autora (2020).

Figura 70 – Evolução do coeficiente de correlação no teste – Configuração C3




Fonte: Autora (2020).

As quinze arquiteturas apresentadas na Tabela 13 foram empregadas para estimar as funções de condutividade hidráulica de cinco solos do conjunto de exemplos coletados referentes aos ensaios 3, 4, 7, 11 e 14, as quais foram comparadas aos dados experimentais e às funções obtidas pelo modelo de Van Genuchten (1980), conforme mostrado no Apêndice E. É importante salientar que os parâmetros de Van Genuchten (1980) para todos os solos foram previstos com o auxílio do programa RETC (VAN GENUCHTEN; LEIJ; YATES, 1991) e podem ser encontrados no Apêndice F.

Com base nessa comparação, pode-se constatar que, de fato, as duas estruturas com maior correlação (A: 8-4-2-1 e A: 8-10-5-2-1) obtiveram melhor desempenho, representando mais fielmente os dados experimentais, segundo pode ser visualizado nas Figuras 71 a 80. Dentre essas duas arquiteturas, a escolhida como modelo proposto por esta dissertação foi a A: 8-4-2-1, em virtude de dispor da menor quantidade de parâmetros, contando somente com 49 termos. Essa estrutura simplificada é um indicador do aumento da capacidade de generalização da rede neural desenvolvida, que possui, assim, uma maior compreensão do fenômeno em estudo (HAYKIN, 2009; DANTAS NETO *et al.*, 2014; DANTAS NETO *et al.*, 2017).


Ao analisar os gráficos comparativos mostrados entre as Figuras 71 a 80, nota-se que o perceptron multicamadas (MLP) escolhido retratou de forma satisfatória o fenômeno em questão, alcançando resultados semelhantes aos experimentais tanto para baixas como para altas sucções matriciais, tendo inclusive melhor performance que o modelo de Van Genuchten (1980) para a maioria dos ensaios.

Figura 71 – Comparação entre as funções de condutividade hidráulica para o Ensaio 3 – Arquitetura A: 8-4-2-1




Fonte: Autora (2020).

Figura 72 – Comparação entre as funções de condutividade hidráulica para o Ensaio 3 – Arquitetura A: 8-10-5-2-1




Fonte: Autora (2020).

Figura 73 – Comparação entre as funções de condutividade hidráulica para o Ensaio 4 – Arquitetura A: 8-4-2-1




Fonte: Autora (2020).

Figura 74 – Comparação entre as funções de condutividade hidráulica para o Ensaio 4 – Arquitetura A: 8-10-5-2-1




Fonte: Autora (2020).

Figura 75 – Comparação entre as funções de condutividade hidráulica para o Ensaio 7 – Arquitetura A: 8-4-2-1




Fonte: Autora (2020).

Figura 76 – Comparação entre as funções de condutividade hidráulica para o Ensaio 7 – Arquitetura A: 8-10-5-2-1




Fonte: Autora (2020).

Figura 77 – Comparação entre as funções de condutividade hidráulica para o Ensaio 11 – Arquitetura A: 8-4-2-1




Fonte: Autora (2020).

Figura 78 – Comparação entre as funções de condutividade hidráulica para o Ensaio 11 – Arquitetura A: 8-10-5-2-1




Fonte: Autora (2020).

Figura 79 – Comparação entre as funções de condutividade hidráulica para o Ensaio 14 – Arquitetura A: 8-4-2-1



Fonte: Autora (2020).

Figura 80 – Comparação entre as funções de condutividade hidráulica para o Ensaio 14 – Arquitetura A: 8-10-5-2-1



Fonte: Autora (2020).

Outro aspecto determinante na escolha da melhor arquitetura foi a quantidade de exemplos impostos às RNA que resultaram no cálculo de coeficientes de condutividade hidráulica negativos. De acordo com a Tabela 14, verifica-se que a arquitetura A: 8-4-2-1, selecionada como modelo definitivo desta pesquisa, apresenta o menor número de exemplos para os quais esses coeficientes negativos foram obtidos. É importante evidenciar que esses valores negativos estão relacionados ao processo de desnormalização das saídas e ocorreram principalmente para níveis de sucção nos quais os coeficientes de condutividade hidráulica foram muito baixos (próximos a 0,15, considerando o processo de normalização).

Tabela 14 – Quantidade de saídas negativas

Arquitetura	Quantidade de saídas negativas calculadas pelo modelo de RNA
A: 8-4-2-1	20
A: 8-10-5-2-1	39


Fonte: Autora (2020).

O modelo selecionado como aquele que apresentou o melhor desempenho dentre todos os analisados (A: 8-4-2-1) foi, portanto, capaz de reproduzir o comportamento relativo à condutividade hidráulica dos solos avaliados de forma aproximada para o conjunto de dados utilizado na modelagem e para as variáveis de entrada consideradas, com uma correlação de

0,97 e um RMS de 0,016 cm/s obtidos para 400 mil iterações no teste. As Figuras 81 e 82 ilustram a variação desses parâmetros com o aumento do número de iterações tanto para a fase de treinamento como para a fase de teste.


A Figura 83 apresenta, para a variável de saída, a relação aproximada entre o grupo de padrões de treinamento e de teste e os valores calculados utilizando o modelo definitivo (A: 8-4-2-1), considerando o processo de normalização dos dados. A análise desse gráfico mostra que a rede proposta conseguiu prever com um elevado grau de precisão mesmo os coeficientes de condutividade hidráulica mais altos, embora grande parte dos exemplos, cerca de 81%, encontrem-se concentrados na região que compreende o intervalo entre 0,15 ($1,30 \cdot 10^{-15}$ cm/s) e 0,20 ($1,00 \cdot 10^{-4}$ cm/s).

Figura 81 – Comparação entre as saídas calculadas pelo modelo desenvolvido (A: 8-4-2-1) e os dados experimentais no treinamento




Fonte: Autora (2020).

Figura 82 – Comparação entre as saídas calculadas pelo modelo desenvolvido (A: 8-4-2-1) e os dados experimentais no teste



Fonte: Autora (2020).

Figura 83 – Correlação entre as saídas calculadas pelo modelo desenvolvido (A: 8-4-2-1) e os dados experimentais no treinamento e no teste



Fonte: Autora (2020).

O *software* QNET fornece os percentuais de contribuição de cada variável de entrada no cálculo da resposta do perceptron multicamadas. Em geral, a contribuição dos parâmetros ponderados manteve-se em torno de 13% para a arquitetura A: 8-4-2-1, que se enquadra na configuração C1. Respalhando-se nas informações oferecidas pelo programa, pode-se, portanto, afirmar que houve um equilíbrio em relação ao nível de influência das oito variáveis no fenômeno examinado, cada uma atuando de forma relevante na descrição da condutividade hidráulica em solos não saturados.

Conforme ilustrado na Tabela 15, a característica do solo que atingiu o maior percentual de contribuição foi a granulometria com 32,89%, representada pela ação conjunta das frações de areia, silte e argila, que foram, respectivamente, 11,64%, 13,10% e 8,15%. Em seguida, destacam-se o teor de umidade gravimétrico inicial com 16,65% e o índice de plasticidade com 16,50%, ambas as variáveis possuindo percentuais bem parecidos. O índice de vazios inicial contribuiu, por sua vez, com 14,62%, enquanto o coeficiente de permeabilidade saturado contribuiu com 12,29%, valores também significativos. Por fim, de maneira diversa ao que se acreditava no início desta pesquisa, o parâmetro que obteve menor influência sobre a variável de saída foi a sucção matricial, com um percentual de contribuição de 7,05%.

Tabela 15 – Percentual de contribuição das variáveis de entrada

Variáveis de entrada	Contribuição (%)
e_o	14,62
w_o	16,65
C	8,15
M	13,10
S	11,64
IP	16,50
k_{sat}	12,29
$u_a - u_w$	7,05

Fonte: Autora (2020).

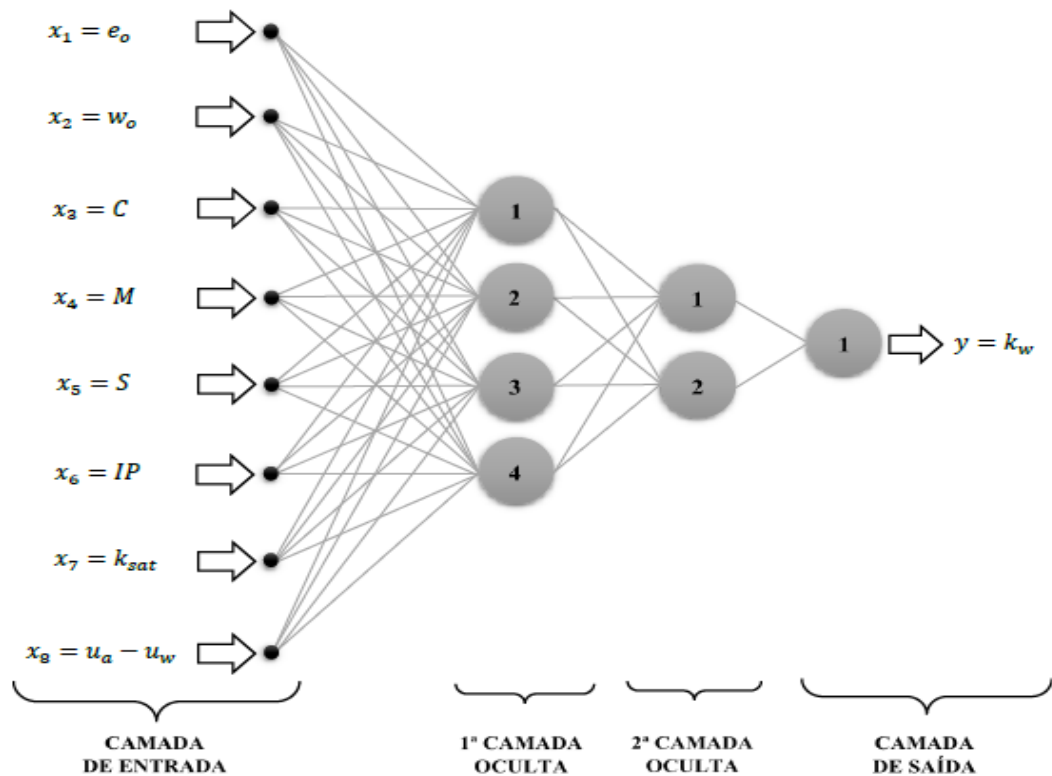
O modelo final proposto por esta dissertação possui, assim, uma arquitetura composta por quatro camadas (A: 8-4-2-1), sendo a primeira constituída por oito sinais de entrada. As duas camadas intermediárias, por sua vez, são compostas por, respectivamente, quatro e dois

nós computacionais, totalizando apenas seis neurônios ocultos. Por último, a camada de saída é formada por um único neurônio, conforme apresentado na Figura 84.

Os parâmetros da arquitetura definitiva, isto é, pesos sinápticos e bias, originados durante o processo de treinamento da modelagem com RNA do tipo MLP, são apresentados nas Tabelas 16, 17 e 18. Tais informações possibilitam a implantação desse modelo em planilhas eletrônicas de cálculo, sendo essencial, para isso, executar previamente os seguintes procedimentos:

- Determinar as variáveis de entrada do modelo, que são: e_o ; w_o ; C ; M ; S ; IP ; k_{sat} e $u_a - u_w$;
- Normalizar essas variáveis segundo a Equação 33 e os valores máximos e mínimos da Tabela 10;
- Empregar as Equações 17 e 18, usando os pesos sinápticos e os bias das Tabelas 16, 17 e 18, para determinar, assim, a resposta do modelo neuronal desenvolvido;
- Transformar a variável de saída normalizada da rede neural em uma variável não normalizada, de acordo com a Equação 33 e os valores máximos e mínimos da Tabela 10.

Figura 84 – Arquitetura do modelo definitivo de previsão da condutividade hidráulica de solos não saturados (A: 8-4-2-1)



Fonte: Autora (2020).

Tabela 16 – Valores dos pesos sinápticos e bias entre a camada de entrada e a 1ª camada oculta do modelo de previsão desenvolvido

		1ª Camada Oculta			
		1	2	3	4
Camada de entrada	e_0	-5,75172	-0,50917	0,31767	3,19656
	w_0	-1,73394	5,20341	-3,26753	-3,77786
	C	-7,87552	-2,96896	0,48882	0,93303
	M	-0,65119	-3,87781	5,21392	0,88540
	S	14,02280	3,37291	-3,98317	-1,22773
	IP	-15,30781	-6,32156	4,24222	-0,64102
	k_{sat}	4,14572	1,81156	-2,68606	0,98919
	$u_a - u_w$	-26,16241	18,84291	-12,92930	-13,23870
	b_k	4,55798	-1,79170	0,91186	-0,00401

Fonte: Autora (2020).

Tabela 17 – Valores dos pesos sinápticos e bias entre a 1ª camada oculta e a 2ª camada oculta do modelo de previsão desenvolvido

		2ª Camada Oculta	
		1	2
1ª Camada Oculta	1	-9,78932	-26,88161
	2	8,81395	19,13131
	3	-1,51715	-9,83015
	4	-9,81690	-6,04726
	b_k	5,70182	11,87000

Fonte: Autora (2020).

Tabela 18 – Valores dos pesos sinápticos e bias entre a 2ª camada oculta e a camada de saída do modelo de previsão desenvolvido

		Camada de saída
		1
2ª Camada Oculta	1	4,98311
	2	-16,15941
	b_k	9,46846

Fonte: Autora (2020).


5.3 Aplicação prática do modelo de RNA desenvolvido

A aplicação prática do modelo desenvolvido é realizada a fim de verificar a capacidade de a rede neural prever resultados adequados fora do conjunto de treinamento e de teste, bem como de exemplificar a sua utilização. Com esse objetivo, empregando a função de condutividade hidráulica estimada pelo modelo de RNA, foi executada uma análise de fluxo transiente em uma barragem na condição de enchimento.

5.3.1 Simulação numérica da condição de fluxo de uma barragem durante o seu enchimento

Para a aplicação prática do modelo desenvolvido, é realizada a análise da condição de enchimento da barragem Olho d'Água, localizada no Estado do Ceará, cuja seção transversal encontra-se na Figura 85.

Figura 85 – Seção transversal da barragem Olho d'Água utilizada na análise de fluxo



Fonte: Araújo (2013).

A princípio, a curva de condutividade hidráulica do maciço foi estimada pelo modelo de Van Genuchten (1980) e pelo perceptron de arquitetura A: 8-4-2-1, proposto por esta dissertação. As variáveis de entrada do modelo de RNA estão disponíveis em Araújo (2013), que examinou a estabilidade dos taludes de tal maciço, definindo, por meio de retroanálises, os parâmetros hidráulicos dos materiais constituintes dessa barragem a partir de leituras realizadas em dispositivos de instrumentação instalados.

Destaca-se, no entanto, que foram atribuídos às variáveis teor de umidade gravimétrica inicial e índice de vazios inicial valores correspondentes ao solo do conjunto experimental cujas características se assemelham às do maciço, visto que essas informações não são apresentadas pelo autor. Além disso, em razão de o modelo proposto não incluir como

variável de entrada a parcela de pedregulho, esse percentual foi somado à fração de areia. Desse modo, a Tabela 19 ilustra as variáveis de entrada consideradas e as saídas calculadas correspondentes.

Tabela 19 – Variáveis de entrada consideradas para o modelo de RNA e saídas correspondentes

e_o	w_o (%)	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	$u_a - u_w$ (kPa)	k_w (cm/s)
0,90	12	20	18	62	7,80	4,00E-04	0,5	1,69E-03
0,90	12	20	18	62	7,80	4,00E-04	1,0	1,69E-03
0,90	12	20	18	62	7,80	4,00E-04	5,0	1,69E-03
0,90	12	20	18	62	7,80	4,00E-04	10,0	1,69E-03
0,90	12	20	18	62	7,80	4,00E-04	20,0	1,69E-03
0,90	12	20	18	62	7,80	4,00E-04	30,0	1,40E-03
0,90	12	20	18	62	7,80	4,00E-04	40,0	2,90E-04
0,90	12	20	18	62	7,80	4,00E-04	50,0	3,00E-05
0,90	12	20	18	62	7,80	4,00E-04	100,0	1,00E-05
0,90	12	20	18	62	7,80	4,00E-04	150,0	1,00E-05
0,90	12	20	18	62	7,80	4,00E-04	200,0	1,00E-05

Fonte: Autora (2020).

Figura 86 apresenta a curva da condutividade hidráulica em função da sucção matricial plotada com os valores previstos pelo modelo de RNA, constantes na Tabela 19. Nessa figura, observa-se que o coeficiente de permeabilidade saturado da função prevista não é compatível com aquele resultante das retroanálises de Araújo (2013). Por conseguinte, um fator de correção foi empregado à função de condutividade estimada de modo a ajustá-la ao coeficiente de permeabilidade saturado obtido pelo autor. Dessa forma, ambas as curvas (corrigida e não corrigida) foram utilizadas, a fim de identificar a influência dessa diferença na análise de fluxo da barragem.

A Figura 86 ilustra também as funções de permeabilidade obtidas pelo modelo de Van Genuchten (1980) e pela rede neural após a aplicação do fator de correção. Pode-se perceber que a curva corrigida possui valores mais próximos aos de Van Genuchten (1980).

A correção da curva de condutividade hidráulica prevista pelo perceptron ocorreu segundo a seguinte expressão:

$$k_{wc} = FC k_{wnc} \quad (39)$$

Onde:

k_{wc} = Coeficiente de condutividade hidráulica corrigido;

k_{wnc} = Coeficiente de condutividade hidráulica não corrigido;


FC = Fator de correção, definido como:

$$FC = \frac{k_{sat(m)}}{k_{sat(p)}} \quad (40)$$

$k_{sat(m)}$ = Coeficiente de condutividade hidráulica saturado medido;

$k_{sat(p)}$ = Coeficiente de condutividade hidráulica saturado previsto.

Figura 86 – Comparação entre as funções de condutividade estimadas pelo modelo de RNA (corrigida e não corrigida) e pelo modelo de Van Genuchten (1980)



Fonte: Autora (2020).


Em seguida, de posse das funções de condutividade estimadas, realizou-se a análise de fluxo da barragem na condição de enchimento. Os resultados de tal análise relativos à utilização do modelo proposto por esta dissertação (A: 8-4-2-1) e do modelo de Van Genuchten (1980), para três pontos localizados no interior do maciço, são mostrados nas Figuras 87 a 92. Nessas figuras, são também apresentados os resultados da simulação realizada com os parâmetros hidráulicos obtidos por Araújo (2013), que são utilizados como referência na avaliação do desempenho desses modelos de previsão.

Como se pode visualizar na Figura 87, que mostra a evolução das poropressões para um ponto próximo ao talude de montante, todos os resultados aproximaram-se do de Araújo (2013). Contudo, em relação ao ponto próximo ao dreno (Figura 88) e ao ponto na região central do maciço (Figura 89), os melhores resultados foram, respectivamente, aqueles correspondentes ao modelo de Van Genuchten (1980) e ao modelo de RNA cuja função foi corrigida.

De forma geral, ao analisar ainda as Figuras 87, 88 e 89, verifica-se que a curva de condutividade hidráulica corrigida obteve melhor desempenho que a curva não corrigida; indicando-se, portanto, que a aplicação do fator de correção é necessária, uma vez que levou a resultados mais próximos daqueles obtidos por meio da simulação numérica que empregou os parâmetros hidráulicos de Araújo (2013), tidos como referência.


Além disso, percebe-se também que, para os três pontos, a distribuição das poropressões resultante do modelo de RNA de função corrigida apresentou comportamento semelhante à distribuição das poropressões obtida com o uso dos parâmetros hidráulicos de Araújo (2013), o que sugere que o modelo de RNA desenvolvido, após a correção, é capaz de prever de forma satisfatória funções de condutividade hidráulica de solos fora do conjunto de exemplos do banco de dados coletados.

Figura 87 – Evolução das poropressões em um ponto próximo ao talude de montante – P (55,6)




Fonte: Autora (2020).

Figura 88 – Evolução das poropressões em um ponto próximo ao dreno – P (113,4)




Fonte: Autora (2020).

Figura 89 – Evolução das poropressões em um ponto na região central do maciço – P (86,12)




Fonte: Autora (2020).

Figura 90 – Análise de fluxo com o uso dos dados obtidos por Araújo (2013)




Fonte: Autora (2020).

Figura 91 – Análise de fluxo com o uso do modelo de RNA proposto (A: 8-4-2-1)



Fonte: Autora (2020).

Figura 92 – Análise de fluxo com o uso do modelo de Van Genuchten (1980)



Fonte: Autora (2020).

5.4 Considerações parciais

Os resultados das fases de treinamento e de teste mostraram que, para os três tipos de configuração, as correlações obtidas foram elevadas, com valores próximos a 0,90. Dessa forma, as cinco melhores arquiteturas de cada configuração foram selecionadas, a fim de empregá-las na estimativa das funções de condutividade de cinco solos do conjunto de exemplos coletados e compará-las com os dados experimentais e com as funções obtidas pelo modelo de Van Genuchten (1980).

A escolha do modelo definitivo, proposto por esta dissertação, baseou-se, portanto, nos seguintes critérios: desempenho obtido na previsão da função de condutividade desses cinco solos, número de exemplos que resultaram em valores negativos nas fases de treinamento e de teste e menor quantidade de parâmetros da rede neural. Desse modo, foi selecionada como modelo definitivo a arquitetura A: 8-4-2-1, com correlação de 0,97 e RMS de 0,016 cm/s, correspondentes a 400 mil iterações no teste.

O modelo desenvolvido foi, então, aplicado em uma análise de fluxo da barragem Olho d'água, no estado do Ceará. Nessa análise, após a previsão da função de condutividade hidráulica, verificou-se que o coeficiente de permeabilidade saturado estimado era diferente daquele utilizado como variável de entrada do modelo e obtido por meio de retroanálise por

Araújo (2013). Logo, aplicou-se um fator de correção à curva prevista de modo a ajustá-la ao coeficiente de permeabilidade saturado obtido por esse autor.

Dessa forma, os resultados da análise de fluxo obtidos com a curva de condutividade estimada pelo modelo proposto, após a aplicação do fator de correção, foram satisfatórios, semelhantes aos resultados obtidos por meio da simulação numérica que empregou parâmetros hidráulicos resultantes de retroanálise realizada por Araújo (2013) e tidos como referência. Assim, comprova-se o bom desempenho do modelo de redes neurais artificiais na previsão da função de condutividade hidráulica de solos não saturados, ressaltando-se a necessidade de correção da curva estimada.

6 CONCLUSÕES E SUGESTÕES PARA PESQUISAS FUTURAS

Neste capítulo, são realizadas considerações finais referentes à elaboração do modelo de RNA para previsão da condutividade hidráulica em solos não saturados, apresentando as conclusões obtidas e os resultados adquiridos, a partir do desenvolvimento desta dissertação. Além disso, são indicadas sugestões para trabalhos futuros como forma de complementar esta pesquisa.

6.1 Conclusões

A determinação do coeficiente de condutividade hidráulica em solos não saturados mediante procedimentos laboratoriais costuma ser cara, complexa e demorada. Essas desvantagens, muitas vezes, tornam inviável a realização de ensaios experimentais. Em virtude disso, foram elaboradas técnicas de estimativa da função de condutividade hidráulica nesses solos com base na curva de retenção e no coeficiente de permeabilidade saturado, representando uma alternativa à realização de testes de laboratório. No entanto, algumas dessas metodologias possuem parâmetros de difícil obtenção.

Tendo em vista o contexto abordado, este trabalho busca desenvolver um modelo de previsão da condutividade hidráulica em solos não saturados, utilizando redes neurais artificiais (RNA) do tipo perceptron multicamadas (MLP). A composição do banco de dados para a elaboração do modelo resultou de informações retiradas de ensaios em solos arenosos, siltosos e argilosos, formando, assim, um conjunto de padrões composto por 275 exemplos representativos da tarefa em questão.

Baseando-se nos estudos dos fatores que governam o comportamento hidráulico dos solos não saturados, foram definidas oito variáveis de entrada, que são: índice de vazios inicial, teor de umidade, frações de areia, silte e argila, índice de plasticidade, coeficiente de permeabilidade saturado e sucção matricial.

Com o propósito de encontrar um modelo simplificado com o menor número de parâmetros envolvidos e que fosse capaz de oferecer um desempenho adequado na representação do fenômeno em estudo, três configurações de variáveis de entrada (C1, C2 e C3) foram empregadas no desenvolvimento da melhor arquitetura. A diferença entre as conformações C1 e C2 residiu apenas no fato de esta não possuir o teor de umidade e nem o índice de vazios inicial; posto que, ao contrário do que se considerou em C1, esses parâmetros variam com a sucção para um mesmo ensaio.

A configuração C3, por sua vez, levou em conta dois aspectos relevantes: a redução da umidade com o aumento da sucção mátrica e a permeabilidade saturada como parte da variável de saída, correspondendo à condição de sucção mátrica igual a zero. Devido a isso, houve um menor número de exemplos para C3, que contou com somente 248 padrões, pois a relação entre o teor de umidade e a sucção foi adquirida por meio da curva de retenção e um dos trabalhos utilizados para compor o conjunto experimental não apresentou essa informação

Desse modo, o modelo final, proposto por esta dissertação, possui uma arquitetura com oito nós na camada de entrada, quatro neurônios na primeira camada oculta, dois neurônios na segunda camada oculta e apenas um neurônio de saída (A: 8-4-2-1). Esse modelo obteve, no teste, uma correlação de 0,97 e um RMS de 0,016 cm/s, correspondentes a 400 mil iterações.

Fundamentando-se nas informações fornecidas pelo *software* QNET, observou-se que a característica do solo que obteve o maior percentual de contribuição foi a granulometria com 32,89%, representada pela ação conjunta das frações de areia, silte e argila, que foram, respectivamente, 11,64%, 13,10% e 8,15%. Em seguida, destacam-se também com elevados percentuais de contribuição o teor de umidade gravimétrico inicial (16,65%), o índice de plasticidade (16,50%), o índice de vazios inicial (14,62%) e o coeficiente de permeabilidade saturado (12,29%). Por fim, de maneira diversa ao que se acreditava no início desta pesquisa, o parâmetro que obteve menor influência sobre a variável de saída foi a sucção matricial, com um percentual de contribuição de 7,05%.

A aplicação prática do modelo proposto foi realizada a fim de verificar a capacidade de a rede neural prever resultados adequados fora do conjunto experimental. Dessa forma, esse modelo foi, então, aplicado na análise da condição de enchimento da barragem Olho d'água, no estado do Ceará.

Nessa análise, após a previsão da função de condutividade hidráulica, verificou-se que o coeficiente de permeabilidade saturado previsto era diferente daquele utilizado como variável de entrada do modelo e assumido como real. Por essa razão, empregou-se um fator de correção à função estimada, ajustando-a ao coeficiente de permeabilidade saturado real. Para identificar a influência dessa diferença na análise de fluxo, tanto a função corrigida como a função não corrigida foram utilizadas.

De modo geral, o resultado obtido com a curva de condutividade estimada pelo modelo proposto após a aplicação do fator de correção foi satisfatório, semelhante ao resultado tido como referência. Constata-se, assim, o bom desempenho do modelo neuronal desenvolvido na previsão da função de condutividade hidráulica de solos não saturados, ressaltando-se a necessidade de correção da curva estimada.

O modelo de RNA proposto por esta dissertação pode ser empregado na prática da engenharia geotécnica nos casos em que houver a necessidade de realização de análises de fluxo transiente, uma vez que tais investigações requerem o conhecimento da função de condutividade hidráulica. A implementação desse modelo é efetuada de forma simples e rápida, pois as variáveis de entrada consideradas podem ser facilmente obtidas em ensaios de laboratório.

É importante salientar, no entanto, que a aplicação prática do modelo possui limitações relacionadas à concentração em uma determinada faixa de valores dos dados experimentais utilizados na modelagem correspondentes ao coeficiente de condutividade hidráulica saturado e à sucção matricial. Dessa forma, recomenda-se que o emprego do modelo de RNA desenvolvido seja limitado a solos com coeficiente de permeabilidade saturado acima de 10^{-5} cm/s e com níveis de sucção matricial de até 200 kPa.

6.2 Sugestões para pesquisas futuras

No decorrer do desenvolvimento desta dissertação, foi possível identificar oportunidades de melhoria deste trabalho por meio de pesquisas futuras. Assim, algumas sugestões são apresentadas a seguir:

- a) Inserir no banco de dados solos com percentual de pedregulho, elaborando um modelo mais abrangente;
- b) Incluir no banco de dados mais exemplos de solos de outras regiões brasileiras, como norte e sul, para aumentar a representatividade do conjunto experimental;
- c) Aprimorar o banco de dados, aumentando o número de exemplos e incluindo valores fora do intervalo utilizado neste trabalho;
- d) Comparar a função estimada pelo modelo de RNA desenvolvido com as previstas por outros modelos tradicionais como o de Fredlund *et al.* (1994);
- e) Verificar a sensibilidade do modelo proposto aplicando-o em análises de fluxo em diferentes situações.

REFERÊNCIAS

- ABBASZADEH SHAHRI, A. *Assessment and Prediction of Liquefaction Potential Using Different Artificial Neural Network Models: A Case Study*. **Geotech Geol Eng**, 34, 807–815, 2016.
- ABOLHOSSEINI, H.; HASHEMI, M.; AJALLOEIAN, R. *Evaluation of geotechnical parameters affecting the penetration rate of TBM using neural network (case study)*. **Arab J Geosci**, 13, 183, 2020.
- AHOUR, M.; HATAF, N.; AZAR, E. *A Mathematical Model Based on Artificial Neural Networks to Predict the Stability of Rock Slopes Using the Generalized Hoek–Brown Failure Criterion*. **Geotech Geol Eng**, 38, 587–604, 2020.
- AKBULUT, S. *Artificial Neural Networks for Predicting the Hydraulic Conductivity of Coarse-Grained Soils*. **Eurasian Soil Science**, v. 38, n. 4, 2005, p. 392-398. Translated from *Pochvovedenie*, n. 4, 2005, p. 446–452.
- ALAM, S. K.; MONDAL, A.; SHIULY, A. *Prediction of CBR Value of Fine Grained Soils of Bengal Basin by Genetic Expression Programming, Artificial Neural Network and Krigging Method*. **J Geol Soc India**, 95, 190–196, 2020.
- ALMEIDA, Marcela Moreira da Rocha. **Avaliação de métodos de estimativa da capacidade de carga de fundações diretas em solos não saturados**. Orientador: Francisco Chagas da Silva Filho. 2018. 143 f. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, fev. 2018.
- ALSHARARI, Bandar; OLENKO, Andriy; ABUEL-NAGA, Hossam. *Modeling of electrical resistivity of soil based on geotechnical properties*. **Expert Systems with Applications**, v. 141, p. 112966, 2020.
- AL-SULAIMAN, M. A.; ABOUKARIMA, A. M. *Prediction of Unsaturated Hydraulic Conductivity of Agricultural Soils Using Artificial Neural Network and c#*. **Journal of Agriculture and Ecology Research International**, 5(4): 1-15, 2016.
- AMANCIO, Luciana Barbosa. **Previsão de recalques em fundações profundas utilizando redes neurais artificiais do tipo perceptron**. Orientador: Silvrano Adonias Dantas Neto. 2013. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, ago. 2013.
- ARAÚJO, Carla Beatriz Costa de. **Aplicação das redes neurais artificiais do tipo perceptron na estimativa de recalques em estacas**. Orientador: Silvrano Adonias Dantas Neto. 2015. 227 f. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, abr. 2015.

ARAÚJO, Carla Beatriz Costa de; DANTAS NETO, Silvrano Adonias; ANJOS, Gérson Jacques Miranda dos. Estimativa de recalque em estacas utilizando redes neurais artificiais. *In: XVIII CONGRESSO BRASILEIRO DE MECÂNICA DOS SOLOS E ENGENHARIA GEOTÉCNICA*, 2016, Belo Horizonte/MG. **Anais [...]**. Belo Horizonte/MG: COBRAMSEG, ABMS, 2016.

ARAÚJO, Carla Beatriz Costa de; DANTAS NETO, Silvrano Adonias; SOUZA FILHO, Francisco de Assis. Previsão de vazões para o açude Orós/CE a partir de dados hidrometeorológicos utilizando perceptrons. **Revista Brasileira de Meteorologia**, v. 30, n. 1, 2015.

ARAÚJO, Franklim Rabelo de. **Risco geotécnico: uma abordagem estocástica para análise de estabilidade de taludes da barragem Olho D'Água no estado do Ceará**. Orientador: Silvrano Adonias Dantas Neto. 2013. 128 f. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Hidráulica e Ambiental, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, nov. 2013.

AZEVEDO NETTO, José Martiniano de; FERNÁNDEZ Y FERNÁNDEZ, Miguel. **Manual de Hidráulica**. 9ª ed. São Paulo: Blucher, 2018.

BASHIR, Rashid; SHARMA, Jitendra; STEFANIAK, Natasja. *Effect of hysteresis of soil-water characteristic curves on infiltration under different climatic conditions*. **Canadian Geotechnical Journal**, 2015.

BAZIAR, M. H.; GHORBANI, A. *Evaluation of lateral spreading using artificial neural networks*. **Soil Dynamics and Earthquake Engineering**, v. 25, p. 1-9, 2005.

BAZIAR, M. H.; SAEEDI AZIZKANDI, A. *Evaluation of lateral spreading utilizing artificial neural network and genetic programming*. **International Journal of Civil Engineering**, v. 11, n. 2, p. 100-111, 2013.

BENARDOS, A. G.; KALIAMPAKOS, D. C. *Modelling TBM performance with artificial neural networks*. **Tunnelling and Underground Space Technology**, v. 19, p. 597-605, 2004.

BENBOURAS, Mohammed Amin; MITICHE KETTAB, Ratiba; ZEDIRA, Hamma; DEBICHE, Fatiha; ZAIDI, Narimane. *Comparing nonlinear regression analysis and artificial neural networks to predict geotechnical parameters from standard penetration test*. **Urbanism, Arhitectura and Constructii Journal**, v. 9, n. 3, 2018.

BICALHO, Kátia Vanessa; MACHADO, Sandro Lemos; GERSCOVICH, Denise M. S. Condutividade hidráulica e fluxo em solos não saturados. *In: CARVALHO, José Camapum de et al. (org.). Solos não saturados no contexto geotécnico*. São Paulo: ABMS, 2015. p. 297-326.

BOCANEGRA, Charlie Williams Rengifo. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. Orientador: Antônio Nélon Rodrigues da Silva. 2002. Dissertação (Mestrado em Transportes) – Escola de Engenharia de São Carlos da Universidade de São Paulo, Departamento de Transportes, São Carlos/SP, 2002.

BORA, Celso Felipe. **Análise de estabilidade de uma encosta da Serra do Mar Paranaense:** influências da consideração da poropressão e do fluxo em meio não saturado. Orientador: Alessandro Christopher Morales Kormann. 2015. 152 f. Dissertação (Mestrado em Engenharia de Construção Civil) – Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia de Construção Civil, Área de Concentração em Geotecnia, Curitiba/PR, mai. 2015.

BOUKERCHE, Azzedine; NOTARE, Mirela Sechi M. Annoni. *Behavior-Based Intrusion Detection in Mobile Phone Systems*. **Journal of Parallel and Distributed Computing**, v. 62, n. 9, p. 1476-1490, 2002.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes Neurais Artificiais:** teoria e aplicações. Rio de Janeiro: LTC, 2000.

BROOKS, R. H.; COREY, A. T. *Hydraulics properties of porous media*. Colorado State University. **Hydrology Papers**, n. 3. Fort Collins, CO, 1964.

BURDINE, N. T. *Relative permeability calculations from pore size distribution data*. **Journal of Petroleum Technology**, v. 198, 1953.

BURGOS, Paulo Cesar; CONCIANI, Wilson. Índices físicos, textura, consistência e classificação de solos. *In: CARVALHO, José Camapum de et al. (org.). Solos não saturados no contexto geotécnico*. São Paulo: ABMS, 2015. p. 181-204.

CONCIANI, Wilson; BURGOS, Paulo Cesar; BEZERRA, Raimundo Leidimar. Origem e formação dos solos, perfis de intemperismo. *In: CARVALHO, José Camapum de et al. (org.). Solos não saturados no contexto geotécnico*. São Paulo: ABMS, 2015. p. 21-37.

CONCIANI, W.; CARNEIRO, B. J. I.; MACHADO, S. L. Estimativa da condutividade hidráulica de solos não saturados através do TDR. *In: 3º SIMPÓSIO BRASILEIRO DE SOLOS NÃO SATURADOS*, 1997, Rio de Janeiro/RJ. **Anais [...]**. Rio de Janeiro/RJ: ABMS, 1997. p. 221-229.

COSTA, Mateus Bezerra Alves da. **Modelagem numérica do fluxo transiente em meio poroso não saturado sob a ação de centrifugação**. Orientador: André Luís Brasil Cavalcante. 2017. Dissertação (Mestrado em Geotecnia) – Universidade de Brasília, Faculdade de Tecnologia, Departamento de Engenharia Civil e Ambiental, Brasília, jul. 2017.

CHILDS, E. C.; COLLIS-GEORGE, N. *The permeability of porous materials*. **Proceedings of the Royal Society of London**. Series A. Mathematical and Physical Sciences, v. 201, n. 1066, p. 392-405, 1950.

CHO, Sung Eun. *Probabilistic stability analyses of slopes using the ANN-based response surface*. **Computers and Geotechnics**, v. 36, p. 787-797, 2009.

CHOOBBASTI, A. J.; FARROKHZAD, F.; BARARI, A. *Prediction of slope stability using artificial neural network (case study: Noabad, Mazandaran, Iran)*. **Arab J Geosci**, 2, 311–319, 2009.

CRONEY, D.; COLEMAN, J. D. Pore pressure and suction in soil. In: *Proceedings of the Conference on Pore Pressure and Suction in Soils*. Butterworth, London, 1961. p. 31–37.

CUI, K.; JING, X. *Research on prediction model of geotechnical parameters based on BP neural network*. **Neural Comput & Applic**, 31, 8205–8215, 2019.

DANTAS NETO, Silvrano Adonias; INDRARATNA, Buddhima; OLIVEIRA, David Américo Fortuna; ASSIS, André Pacheco de. *Modelling the Shear Behaviour of Clean Rock Discontinuities Using Artificial Neural Networks*. **Rock Mech Rock Eng**, 50: 1817-1831, 2017.

DANTAS NETO, Silvrano Adonias; INDRARATNA, Buddhima; OLIVEIRA, David Américo Fortuna. *Prediction of the Shear Behaviour of Clean Joints in Soft Rocks using Perceptron*. In: **VII Brazilian Symposium on Rock Mechanics**. Belo Horizonte, Minas Gerais, Brazil, 2016.

DANTAS NETO, S. A.; SILVEIRA, M. V.; AMÂNCIO, L.B.; ANJOS, G.M. *Pile Settlement Modeling with Multilayer Perceptrons*. **Electronic Journal of Geotechnical Engineering**, v. 19, p. 4517-4528, 2014.

DAS, S. K.; BASUDHAR, P. K. *Undrained lateral load capacity of piles in clay using artificial neural network*. **Computers and Geotechnics**, 33(8), 454-459, 2006.

EDIL, T. B.; MOTAN, S. E.; TOHA, F. X. *Mechanical Behavior and Testing Methods of Unsaturated Soils*. **Laboratory Shear Strength of Soil**, ASTM, STP 740, 114-129, 1981.

FARROKHZAD, F.; CHOBBASTI, A. J.; BARARI, A. *Artificial neural network model for prediction of liquefaction potential in soil deposits*. 2010.

FERENTINOU, M. D.; SAKELLARIOU, M. G. *Computational intelligence tools for the prediction of slope performance*. **Computers and Geotechnics**, 34(5), 362-384, 2007.

FERNANDES, M. A.; VILAR, O. M. Medida da condutividade hidráulica em solo não saturado por meio de infiltrômetro de disco. In: VII SIMPÓSIO BRASILEIRO DE SOLOS NÃO SATURADOS, 2011, Pirenópolis/GO. **Anais [...]**. Pirenópolis/GO: ABMS, 2011. p. 47-55.

FILIZOLA, Heloisa Ferreira; FERRACINI, Vera Lúcia; SANS, Luís Marcelo Aguiar; GOMES, Marco Antônio Ferreira; FERREIRA, Celso João Alves. Monitoramento e avaliação do risco de contaminação por pesticidas em água superficial e subterrânea na região de Guaira. **Pesquisa Agropecuária Brasileira**, Brasília/DF, mai. 2002. v.37, n.5, p. 659-667.

FOX, Robert W.; MCDONALD, Alan T.; PRITCHARD, Philip J.; MITCHELL, John W. **Introdução à Mecânica dos Fluidos**. 9ª ed. Rio de Janeiro: LTC, 2018.

FREDLUND, D. G.; MORGENSTERN, N. R. *Stress state variables for unsaturated soils*. **Journal of Geotechnical Engineering Division**, ASCE, 103:447–466, 1977.

FREDLUND, D. G.; RAHARDJO, H.; FREDLUND, M. D. *Unsaturated Soil Mechanics in Engineering Practice*. John Wiley & Sons, New Jersey, 926 p., 2012.

FREDLUND, D. G.; XING, A. *Equations for the Soil-Water Characteristic Curve*. **Canadian Geotechnical Journal**, v. 31, p. 521-532, 1994.

FREDLUND, D. G.; XING, A.; HUANG, S. *Predicting the permeability function for unsaturated soils using the soil water characteristic curve*. **Canadian Geotechnical Journal**, 1994. v. 31, n. 4, p. 533-546, 1994.

FREDLUND, M. D.; WILSON, G. W.; FREDLUND, D. G. *Use of the grain-size distribution for estimation of the soil-water characteristic curve*. **Canadian Geotechnical Journal**, v. 39, n. 5, p. 1103-1117, 2002.

GALLAGE, Chaminda Pathma Kumara; UCHIMURA, Taro. Effects of dry density and grain size distribution on soil-water characteristic curves of sandy soils. **Soils and Foundations**, v. 50, n. 1, p. 161-172, 2010.

GAO, Wei; RAFTARI, Mehdi; RASHID, Ahmad Safuan A.; MU'AZU, Mohammed Abdullahi; JUSOH, Wan Amizah Wan. *A predictive model based on an optimized ANN combined with ICA for predicting the stability of slopes*. **Engineering with Computers**, 36, 325-344, 2020.

GARDNER, W. R. *Some Steady-State of the Unsaturated Moisture Flow Equation with application to Evaporation from Water Table*. **Soil Science**, n. 85, v. 3, 1958. p. 228-232.

GEORGETTI, Giovana Bizão. **Resistência de um solo não saturado a partir de ensaios com teor de umidade constante (CW)**. Orientador: Orencio Monje Vilar. 2010. Dissertação (Mestrado em Geotecnia) – Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos/SP, abr. 2010.

GITIRANA JUNIOR, Gilson de Farias Neves; MARINHO, Fernando Antônio Medeiros; SOTO, Miguel Angel Alfaro. A curva de retenção de água de materiais porosos. In: CARVALHO, José Camapum de *et al.* (org.). **Solos não saturados no contexto geotécnico**. São Paulo: ABMS, 2015. p. 205-229.

GERSCOVICH, D. M. S. Equações para modelagem da curva característica aplicadas a solos brasileiros. In: IV SIMPÓSIO BRASILEIRO DE SOLOS NÃO SATURADOS, 2001, Porto Alegre/RS. **Anais [...]**. Porto Alegre/RS: ABMS, mar. 2001. v. 1, p. 76-92.

GERSCOVICH, D. M. S. **Fluxo em solos saturados**. Faculdade de Engenharia, Departamento de Estruturas e Fundações, 2011.

GERSCOVICH, D. M. S.; GUEDES, M. N. Avaliação das relações de condutividade hidráulica em solos brasileiros não saturados. In: 5º SIMPÓSIO BRASILEIRO DE SOLOS NÃO SATURADOS, 2004, São Carlos/SP. **Anais [...]**. São Carlos/SP: ABMS, 2004. p. 249-254.

GERSCOVICH, D. M. S.; VARGAS JR., E. A.; CAMPOS, T. M. P. Modelagem tridimensional do regime de fluxo de um talude na cidade do Rio de Janeiro, Brasil. In: 3º SIMPÓSIO SOBRE SOLOS NÃO SATURADOS, 1997, Rio de Janeiro. **Anais [...]**. Rio de Janeiro: ABMS, 1997. v. 1, p. 281-294.

GOH, Anthony T. C. *Probabilistic neural network for evaluating seismic liquefaction potential*. **Canadian Geotechnical Journal**, 39(1): 219-232, 2002.

GOH, Anthony T. C.; KULHAWY, Fred H. *Neural network approach to model the limit state surface for reliability analysis*. **Canadian Geotechnical Journal**, 40(6): 1235-1244, 2003.

HANANDEH, Shadi; ARDAH, Allam; ABU-FARSAKH, Murad. *Using artificial neural network and genetics algorithm to estimate the resilient modulus for stabilized subgrade and propose new empirical formula*. **Transportation Geotechnics**, v. 24, 2020.

HANNA, Adel M.; MORCOUS, George; HELMY, Mary. *Efficiency of pile groups installed in cohesionless soil using artificial neural networks*. **Canadian Geotechnical Journal**, v. 41, n. 6, p. 1241-1249, 2004.

HANNA, Adel M.; URAL, Derin; SAYGILI, Gokhan. *Neural network model for liquefaction potential in soil deposits using Turkey and Taiwan earthquake data*. **Soil Dynamics and Earthquake Engineering**, v. 27, p. 521-540, 2007.

HASANPOUR, Rohola; ROSTAMI, Jamal; SCHMITT, Jürgen; OZCELIK, Yilmaz; SOHRABIAN, Babak. *Prediction of TBM jamming risk in squeezing grounds using Bayesian and artificial neural networks*. **Journal of Rock Mechanics and Geotechnical Engineering**, v. 12, p. 21-31, 2020.

HAYKIN, Simon. **Redes neurais: princípios e prática**. 2^a ed. Porto Alegre/RS: Bookman, 2001. Traduzido por: Paulo Martins Engel.

HAYKIN, Simon. *Neural networks and learning machines*. 3rd ed. Prentice Hall International Inc, Upper Saddle River, 2009.

HILLEL, Daniel. *Introduction to soil physics*. New York: Academic Press, 1982.

HILLEL, Daniel. *Introduction to environmental soil physics*. San Diego: Elsevier Academic Press, 2004.

ISMEIK, M.; AL-RAWI, O. *Modeling Soil Specific Surface Area with Artificial Neural Networks*. **Geotechnical Testing Journal**, 37, n. 4: 678-688, 2014.

JAVAD, Gholamnejad; NARGES, Tayarani. *Application of artificial neural networks to the prediction of tunnel boring machine penetration rate*. **Mining Science and Technology (China)**, v. 20, n. 5, p. 727-733, 2010.

JAVDANIAN, H.; JAFARIAN, Y.; HADDAD, A. *Predicting damping ratio of fine-grained soils using soft computing methodology*. **Arab J Geosci**, 8, 3959–3969, 2015.

KAUNDA, Rennie B.; CHASE, Ronald B.; KEHEW, Alan E.; KAUGARS, Karlis; SELEGEAN, James P. *Neural network modeling applications in active slope stability problems*. **Environ Earth Sci**, 60, 1545–1558, 2010.

KIM, Y.; KIM, B. *Use of artificial neural networks in the prediction of liquefaction resistance of sands*. **Journal of Geotechnical and Geoenvironmental Engineering**, 132(11), 1502-1504, 2006.

KOOPIALIPOOR, M.; TOOTOONCHI, H.; ARMAGHANI, D. J.; MOHAMAD, E. T.; HEDAYAT, A. *Application of deep neural networks in predicting the penetration rate of tunnel boring machines*. **Bull Eng Geol Environ**, 78, 6347–6360, 2019.

KOVACEVIC, Meho Sasa; BACIC, Mario; GAVIN, Kenneth. *Application of Neural Networks for the Reliability Design of a Tunnel in Karst Rock Mass*. **Canadian Geotechnical Journal**, 2020.

KOVÁCS, Z. L. **Redes neurais artificiais: Fundamentos e Aplicações**. 3. ed. São Paulo: Livraria da Física, 2002.

KRAHN, J.; FREDLUND, D. G. *On Total, Matric and Osmotic Suction*. **Journal of Soil Science**, v. 114, n. 5, p. 339-348, set. 1972.

KROSE, B.; SMAGT, P. V. *An Introduction to Neural Network*. The University of Amsterdam. Amsterdam, Netherland, p. 29, 1996.

KRUK, Edyta; MALEC, Magdalena; KLATKA, Slawomir; BRODZINSKA-CYGAN, Andzelika; KOLODZIEJ, Jan. *Pedotransfer function for determining saturated hydraulic conductivity using artificial neural network (ANN)*. **Acta Sci. Pol. Formatio Circumiectus**, 16 (4) 2017, p. 115-126.

KUMAR, Vijay; VENKATESH, Kumar; KUMAR, Yeetendra. *Approaches for estimating liquefaction potential of soils*. **Int J Struct Civ Eng**, v. 1, n. 2, p. 35-53, 2012.

LAI, Jinxing; QIU, Junling; FENG, Zhihua; CHEN, Jianxun; FAN, Haobo. *Prediction of Soil Deformation in Tunnelling Using Artificial Neural Networks*. **Computational Intelligence and Neuroscience**, 2015.

LAMBE, T. W., WHITMAN, R. V. **Mecânica de solos**. México: Limusa, 582 p., 2004.

LEITE, Ana Raquel Sena. **Aplicação de redes neurais artificiais para previsão do comportamento cisalhante em descontinuidades de maciços rochosos**. Orientador: Silvrano Adonias Dantas Neto. 2019. 156 f. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, dez. 2019.

LEITE, A. R. S.; DANTAS NETO, S. A.; POLEMIS JÚNIOR, K.; OLIVEIRA, C. M. O. *Study on the shear behaviour of rock joints using different models of artificial neural networks*. In: **14th International Congress on Rock Mechanics and Rock Engineering**. Foz do Iguaçu, Brazil, 2019.

LEME, Rosiel Ferreira. **Influência da sucção mátrica nas condições de fluxo e estabilidade de taludes da Barragem Pesqueiro**. Orientador: Silvrano Adonias Dantas Neto. 2009. 149 f. Dissertação (Mestrado em Recursos Hídricos) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, jun. 2009.

LI, An-Jui; LIM, K.; CHIU, Chien-Kuo; HSIUNG, B. *Application of artificial neural network in assessing fill slope stability*. World Academy of Science, Engineering and Technology, **International Journal Of Geotechnical And Geological Engineering**, v. 12, n. 2, 2018.

LI, An-Jui; LIM, Kelvin; FATTY, Abdoulie. *Stability evaluations of three-layered soil slopes based on extreme learning neural network*. **Journal of the Chinese Institute of Engineers**, 2020.

LISBOA, Rafael Luis Lobato. **Determinação da condutividade hidráulica não saturada de solos residuais com o permeâmetro Guelph e ensaios de laboratório**. Orientador: Roberto Francisco de Azevedo. 2006. 89 f. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal de Viçosa, Programa de Pós-Graduação em Engenharia Civil, Viçosa/MG, fev. 2006.

LIU, L.; MOAYEDI, H.; RASHID, A. S. A.; RAHMAN, S. S. A.; NGUYEN, H. *Optimizing an ANN model with genetic algorithm (GA) predicting load-settlement behaviours of eco-friendly raft-pile foundation (ERP) system*. **Engineering with Computers**, 36, 421–433, 2020.

LLANQUE AYALA, Grover Romer. **Verificação da estabilidade do talude de montante em barragem de terra submetida a rebaixamento rápido realizada com ensaios em solos não saturados e modelagem numérica**. Orientador: Francisco Chagas da Silva Filho. Coorientador: Rosiel Ferreira Leme. 2018. 136 f. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, 2018.

LÔBO NETO, José Benevides; SILVA FILHO, Francisco Chagas da; LOPES, Caio Petrônios de Araújo. *Análise numérica de solos não saturados colapsíveis: aplicação em uma pequena barragem de terra experimental*. **Revista Geotecnia**, n. 144, p. 5-19, nov. 2018.

LORENZI, Alexandre. **Aplicação de redes neurais artificiais para estimativa da resistência à compressão do concreto a partir da velocidade de propagação do pulso ultra-sônico**. Orientador: Luiz Carlos Pinto da Silva Filho. 2009. Tese (Doutorado em Engenharia) – Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Programa de Pós-Graduação em Engenharia Civil, Porto Alegre/RS, 2009.

LU, Ning; LIKOS, William J. *Unsaturated Soil Mechanics*. John Willey & Sons, 2004.

MACHADO, S. L.; CARVALHO, M. F.; MATTA, B. M. *Utilização do permeâmetro Guelph para estudo da condutividade hidráulica de solos residuais de granulito da cidade de Salvador – BA*. In: 5º SIMPÓSIO BRASILEIRO DE SOLOS NÃO SATURADOS, 2004, São Carlos/SP. **Anais [...]**. São Carlos/SP: ABMS, 2004. p. 255-261.

MACHADO, Sandro Lemos; VILAR, Orenco Monje. *Potenciais da água no solo*. In: CARVALHO, José Camapum de *et al.* (org.). **Solos não saturados no contexto geotécnico**. São Paulo: ABMS, 2015. p. 79-96.

MACHADO, S. L.; ZUQUETTE, L. V. *Transporte de massa e mecanismos de retenção em solos não saturados*. In: 5º SIMPÓSIO BRASILEIRO DE SOLOS NÃO SATURADOS, 2004, São Carlos/SP. **Anais [...]**. São Carlos/SP: ABMS, 2004. v. 2, p. 544-572.

MACHADO JÚNIOR, José Christiano; NOGUEIRA, Christianne de Lyra. **Análise bidimensional de problemas de fluxo em meios porosos não saturados pelo método dos elementos finitos**. 2000.

MARINHO, Fernando Antônio Medeiros. Medição de Sucção em Solos. *In: 3º SIMPÓSIO BRASILEIRO DE SOLOS NÃO SATURADOS*, 1997, Rio de Janeiro/RJ. **Anais [...]**. Rio de Janeiro/RJ: Freitas Bastos, abr. 1997. v. 2, p. 373-398.

MARINHO, Fernando Antônio Medeiros. **Os solos não saturados: aspectos teóricos, experimentais e aplicados**. Concurso de Livre-Docência na especialidade “Geomecânica” – Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia de Estruturas e Fundações, fev. 2005.

MARRAPU, B. M.; JAKKA R. S. *A Comparative Study on the Performance of ANN, MLR and MNR in the Assessment of Slope Stability for Kalla - Coonoor Hill Road Stretch of Nilgiris*. *In: SATAPATHY, S. et al. (eds) International Conference on Emerging Trends in Engineering (ICETE). Learning and Analytics in Intelligent Systems*, vol 2. Springer, Cham, 2020.

MARTÍNEZ CARVAJAL, Hernán Eduardo. **Modelagem constitutiva de areias usando redes neurais artificiais**. Orientador: Márcio Muniz de Farias. 2006. 250 p. Tese (Doutorado em Geotecnia) – Universidade de Brasília, Faculdade de Tecnologia, Departamento de Engenharia Civil, Brasília/DF, mar. 2006.

MAYORAZ, F.; VULLIET, L. *Neural networks for slope movement prediction*. **International Journal of Geomechanics**, v. 2, 2002.

MENDES, Rodolfo Moreda. **Estudo das propriedades geotécnicas de solos residuais não saturados de Ubatuba (SP)**. Orientador: Fernando Antônio Medeiros Marinho. 2008. 236 p. Tese (Doutorado em Engenharia Geotécnica) – Escola Politécnica da Universidade de São Paulo, Departamento de Engenharia de Estruturas e Geotecnia, São Paulo/SP, 2008.

MEULENKAMP, F.; GRIMA, M. A. *Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness*. **Int J Rock Mech Min Sci**, 36:29–39, 1999.

MODESTO, Beatriz. Análise das condições de fluxo em uma barragem de terra. *In: XXIII SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS*, 2019, Foz do Iguaçu/PR. **Anais [...]**. Foz do Iguaçu/PR: ABRHidro, nov. 2019.

MORALES, Marlene Susy Tapia. **Estudo numérico e experimental de problemas de fluxo saturado – não saturado em solos**. Orientador: Eurípedes do Amaral Vargas Jr. 2008. 125 f. Dissertação (Mestrado em Engenharia Civil) – Pontifícia Universidade Católica do Rio de Janeiro, Programa de Pós-Graduação em Engenharia Civil, Rio de Janeiro/RJ, fev. 2008.

MOREIRA, Aniele Lacerda; AZEVEDO, Ilana Borges de; SANTOS, Isabella Christine de Paula. Análises de percolação e estabilidade de taludes em uma barragem de terra homogênea sob a perspectiva de segurança de barragens. *In: IX ENCONTRO CIENTÍFICO DAS ENGENHARIAS*, 2019, Rio Verde/GO. **Anais [...]**. Rio Verde/GO: UniRV, nov. 2019.

MOTA, Daniel Gurgel do Amaral. *Prediction of soil shear strength parameters using artificial neural networks*. Orientador: Silvrano Adonias Dantas Neto. 2019. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, ago. 2019.

MUALEM, Yechezkel. *A new model for predicting the hydraulic conductivity of unsaturated porous media*. **Water Resources Research**, v. 12, n. 3, 1976.

NAKASHIMA, Carlos Henrique. **Estudos de curvas características de solos que compõem o perfil geotécnico da formação Guabirotuba**. Orientador: Ronaldo Luis dos Santos Izzo. 2017. 103 f. Dissertação (Mestrado em Estruturas e Geotecnia) – Universidade Tecnológica Federal do Paraná, Programa de Pós-Graduação em Engenharia Civil, Curitiba/PR, mar. 2017.

NEJAD, F. P.; JAKSA, M. B.; MCCABE, B. A. *Prediction of pile settlement using artificial neural networks based on standard penetration test data*. Elsevier Sci: Computers and Geotechnics, [S.l.], p. 1125-1133. set. 2009.

OLIVEIRA, Desireé Alves de. **Análise do fluxo d'água na barragem Engenheiro Armando Ribeiro Gonçalves – Açú/RN**. Orientador: Olavo Francisco dos Santos Junior. Coorientadora: Ada Cristina Scudelari. 2014. 110 f. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Natal/RN, dez. 2014.

PARK, H. I. *Development of neural network model to estimate the permeability coefficient of soils*. **Marine Georesources & Geotechnology Journal**, v. 29, 2011.

PARK, Hyun Il; LEE, Seung Rae. *Evaluation of the compression index of soils using an artificial neural network*. **Computers and Geotechnics**, v. 38, p. 472-481, 2011.

PHAM, Tuan Anh; LY, Hai-Bang; TRAN, Van Quan; GIAP, Loi Van; VU, Huong-Lan Thi; DUONG, Hong-Anh Thi. *Prediction of Pile Axial Bearing Capacity Using Artificial Neural Network and Random Forest*. **Appl. Sci.**, 2020.

PRESA, Erundino Pousada. **Indeformabilidade de Las Arcillas Expansivas Bajo Succion Controlada**. Tesis Doctoral, Universidad Politecnica de Madrid, 1982.

QIAN, Z. G.; LI, A. J.; CHEN, W. C.; LYAMIN, A. V.; JIANG, J. C. *An artificial neural network approach to inhomogeneous soil slope stability predictions based on limit analysis methods*. **Soils and Foundations**, v. 59, p. 556-569, 2019.

RABIEI, M.; CHOBBASTI, A. J. *Innovative piled raft foundations design using artificial neural network*. **Front. Struct. Civ. Eng.** 14, 138–146, 2020.

REZAEI, S.; CHOBBASTI, A. J. *Liquefaction assessment using microtremor measurement, conventional method and artificial neural network (Case study: Babol, Iran)*. **Front. Struct. Civ. Eng.**, 8, 292–307 2014.

RIOS FILHO, Marcelo Gomes. **Comportamento de um aterro compactado em campo e laboratório**. Orientadores: Márcio de Sousa Soares de Almeida; Maurício Ehrlich. 2006. 145 p. Dissertação (Mestrado em Ciências) – Universidade Federal do Rio de Janeiro, Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Rio de Janeiro/RJ, mar. 2006.

RICHARDS, B. G. *Measurement of free energy of soil moisture by the psychrometric technique using thermistors*. In: **Moisture Equilibria and Moisture Changes in Soils Beneath Covered Areas**. A Symposium in Print. Butterworth, Sydney, 1965. p. 39–46.

SÃO MATEUS, M. S. C.; VILAR, O. M. Determinação experimental da condutividade hidráulica de solos não saturados. In: 2º SIMPÓSIO SOBRE SOLOS NÃO SATURADOS, 1994, Recife/PE. **Anais [...]**. Recife/PE: 1994. p. 53-59.

SALES, Maurício Martines; VILAR, Orenco Monje; MASCARENHA, Márcia Maria dos Anjos; PEREIRA, José Henrique Feitosa; SILVA, Carlos Medeiros; CARVALHO, José Camapum de. Fundações em solos não saturados. In: CARVALHO, José Camapum de *et al.* (org.). **Solos não saturados no contexto geotécnico**. São Paulo: ABMS, 2015. p. 651-685.

SAMUI, P. *Three-Dimensional Site Characterization Model of Bangalore using Support Vector Machine*. **ISRN Soil Science**, s. l., v. 2012, p. 1-10, 2012.

SANTOS JR., O. J. **Análise de dados de instrumentação de túneis do metrô de São Paulo: uma abordagem por Redes Neurais**. 160f. Dissertação (Mestrado em Geotecnia), Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos/SP, 2006.

SHAHIN, Mohamed A. *Intelligent computing for modeling axial capacity of pile foundations*. **Canadian Geotechnical Journal**, v. 47, n. 2, p. 230-243, 2010.

SHAHIN, M. A.; JAKSA, M. B.; MAIER, H. R. *Stochastic Simulation of Settlement Prediction of Shallow Foundations Based on a Deterministic Artificial Neural Network Model 1*. 2005.

SHAHIN, Mohamed A.; JAKSA, Mark B.; MAIER, Holger R. *State of the art of artificial neural networks in geotechnical engineering*. **Electronic Journal of Geotechnical Engineering**, v. 8, n. 1, p. 1-26, 2008.

SHARMA, L. K.; SINGH, R.; UMRAO, R. K.; SHARMA, K. M.; SINGH, T. N. *Evaluating the modulus of elasticity of soil using soft computing system*. **Engineering with Computers**, 33, 497–507, 2017.

SIHAG, Parveen. *Prediction of unsaturated hydraulic conductivity using fuzzy logic and artificial neural network*. **Modeling Earth Systems and Environment**, 2018.

SILLERS, W. S.; FREDLUND, D. G.; ZAKERZADEH, N. *Mathematical attributes of some soil-water characteristic curve models*. **Geotechnical and Geological Engineering**, 19: 243-283, 2001.

SILVA, Arthur Lima Siqueira da; SALES JUNIOR, Valdick B. de. Aplicações e benefícios obtidos através das redes neurais artificiais (RNA). **Revista Facima Digital Gestão**, 2017.

SILVA, M. M.; COUTINHO, R. Q. Caracterização geotécnica de um solo não saturado da Formação Barreiras envolvido num movimento de massa em Camaragibe – PE. *In: VI SIMPÓSIO BRASILEIRO DE SOLOS NÃO SATURADOS*, 2007, Salvador/BA. **Anais [...]**. Salvador/BA: ABMS, 2007. p. 391-398.

SILVA FILHO, Francisco Chagas da. Modelagem de solos não-saturados por elementos finitos. **Revista Tecnologia**, Fortaleza/CE, v. 25, n. 1, p. 1-10, jun. 2004.

SILVEIRA, Mariana Vela. **Modelo neuronal para previsão de recalques em estacas hélice contínua, metálica e escavada**. Orientador: Silvrano Adonias Dantas Neto. 2014. 198 f. Dissertação (Mestrado em Geotecnia) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil, Fortaleza/CE, ago. 2014.

SOUZA PINTO, C. **Curso Básico de Mecânica dos Solos**. 3ª ed. São Paulo: Oficina de Textos, 2006.

SREEDEEP, S.; SINGH, D. N. *A Critical Review of the Methodologies Employed for Suction Measurement for Developing the SWCC*. *In: 12th International Conference of International Association for Computer Methods and Advances in Geomechanics (IACMAG)*. Goa, India, 2008.

STEPHENS, Daniel B. *Vadose zone hydrology*. CRC Press, 1995.

STERCK, Wagner Nogueira. **Estudo da função de condutividade hidráulica de solos não saturados através de amostras centrifugadas**. Orientador: Rodrigo Martins Reis. Coorientador: Eduardo Dell’Avanzi. 2011. Dissertação (Mestrado em Engenharia Civil) – Universidade Estadual do Norte Fluminense Darcy Ribeiro, Centro de Ciência e Tecnologia, Campos dos Goytacazes, mai. 2011.

TERZAGHI, Karl. *Theoretical Soil Mechanics*. New York: John Wiley & Sons, 1943.

TERZAGHI, Karl; PECK, Ralph B.; MESRI, Gholamreza. *Soil Mechanics in Engineering Practice*. 3ª ed. New York: John Wiley & Sons, 1996.

TINOCO, Joaquim Agostinho Barbosa; CORREIA, A. Gomes; CORTEZ, Paulo; TOLL, David. *Artificial neural networks for soil embankments stability condition identification*. *In: XVII European Conference on Soil Mechanics and Geotechnical Engineering*, Reykjavík, Island, p. 1-8, 2019.

TIZPA, P.; CHENARI, R. J.; FARD, M. K.; MACHADO, S. L. *ANN prediction of some geotechnical properties of soil from their index parameters*. **Arab J Geosci**, v. 8, n. 5, p. 2911–2920, 2014.

TOTOLA, Lucas Broseghini. **Aplicação de redes neurais artificiais na estimativa de curvas de retenção de solos brasileiros**. Orientadora: Kátia Vanessa Bicalho. Coorientador: Wilian Hiroshi Hisatugu. 2020. 124 f. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal do Espírito Santo, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Civil, Vitória/ES, 2020.

- VANAPALLI, S. K.; FREDLUND, D. G.; PUF AHL, D. E.; CLIFTON, A. W. *Model for the prediction of shear strength with respect to soil suction*. **Canadian Geotechnical Journal**, v. 33, n. 3, p. 379-392, 1996.
- VANAPALLI, S.; FREDLUND, D. G.; BARBOUR, S. L. *A Rationale for an Extended Soil-Water Characteristic Curve*. In: **49th Canadian Geotechnical Conference**. St. John's, Newfoundland. 1996. v.1, p. 457-464.
- VANAPALLI, S. K.; SILLERS, W. S.; FREDLUND, M. D. *The meaning and relevance of residual state to unsaturated soils*. In: **51st Canadian Geotechnical Conference**. Edmonton, Alberta, 1998.
- VAN GENUCHTEN, M. T. *A closed-form equation for predicting the hydraulic conductivity of unsaturated soils*. **Journal of Soil Science Society of America**, 1980. v. 44, p. 892–898.
- VAN GENUCHTEN, M. T.; LEIJ, F. J.; YATES, S. R. *The RETC code for quantifying the hydraulic functions of unsaturated soils*. U.S. Salinity Lab., Department of Agricultural Research Service. Riverside, CA, 1991.
- VENKATESH, Kumar; KUMAR, Vijay; TIWARI, R. P. *Appraisal of liquefaction potential using neural network and neuro fuzzy approach*. **Applied Artificial Intelligence**, v. 27, 2013.
- WANG, H.; MOAYEDI, H.; KOK FOONG, L. *Genetic algorithm hybridized with multilayer perceptron to have an economical slope stability design*. **Engineering with Computers**, 2020.
- WENGANG, Z.; GOH, A. T. C.; RUNHONG, Z.; YONGQIN, L.; NING, W. *Back-propagation neural network modeling on the load–settlement response of single piles*. **Handbook of Probabilistic Models**, p. 467-487, 2020.
- XUE, X.; LIU, E. *Seismic liquefaction potential assessed by neural networks*. **Environ Earth Sci**, 76, 192, 2017.
- YOO, Chungsik; KIM, Joo-Mi. *Tunneling performance prediction using an integrated GIS and neural network*. **Computers and Geotechnics**, v. 34, p. 19-30, 2007.
- ZHANG, Tao; WANG, Cai-Jin; LIU, Song-Yu; ZHANG, Nan; ZHANG, Tong-Wei. *Assessment of soil thermal conduction using artificial neural network models*. **Cold Regions Science and Tecnology**, v. 169, 102907, 2020.
- ZHOU, J.; BEJARBANEH, B. Y.; ARMAGHANI, D. J.; TAHIR, M. M. *Forecasting of TBM advance rate in hard rock condition based on artificial neural network and genetic programming techniques*. **Bull Eng Geol Environ**, 79, 2069–2084, 2020.
- ZHOU, Jian; YU, Jian-Lin. *Influences affecting the soil-water characteristic curve*. **Journal of Zhejiang University – SCIENCE A**, v. 6, n. 8, p. 797-804, 2005.

**APÊNDICE A – CONJUNTO EXPERIMENTAL UTILIZADO NO
DESENVOLVIMENTO DO MODELO DE RNA PARA A CONFIGURAÇÃO C1**

	x₁	x₂	x₃	x₄	x₅	x₆	x₇	x₈	y
Exemplo	e_o	w_o (%)	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
1	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	20,00	3,72E-09
2	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	25,00	2,71E-09
3	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	30,00	1,87E-09
4	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	35,00	1,62E-09
5	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	40,00	1,33E-09
6	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	45,00	1,18E-09
7	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	50,00	1,03E-09
8	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	55,00	7,81E-10
9	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	60,00	6,16E-10
10	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	65,00	5,40E-10
11	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	70,00	4,43E-10
12	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	75,00	3,93E-10
13	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	80,00	3,35E-10
14	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	85,00	3,06E-10
15	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	90,00	2,86E-10
16	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	95,00	2,64E-10
17	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	100,00	2,47E-10
18	0,93	14,70	27,00	16,00	57,00	15,00	3,10E-03	150,00	1,24E-10
19	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	25,00	1,54E-07
20	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	50,00	2,61E-08
21	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	75,00	9,85E-09
22	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	100,00	4,85E-09
23	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	125,00	3,02E-09
24	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	150,00	1,78E-09
25	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	175,00	1,17E-09
26	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	200,00	7,99E-10
27	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	225,00	6,39E-10
28	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	250,00	5,23E-10
29	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	275,00	4,19E-10
30	0,95	35,00	35,00	10,00	55,00	0,00	3,50E-03	300,00	3,28E-10
31	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	5,00	1,39E-03
32	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	10,00	1,17E-03
33	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	15,00	9,73E-04
34	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	20,00	8,10E-04
35	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	25,00	6,87E-04
36	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	30,00	5,52E-04

	x₁	x₂	x₃	x₄	x₅	x₆	x₇	x₈	y
Exemplo	e_o	w_o (%)	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
37	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	35,00	4,66E-04
38	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	40,00	3,80E-04
39	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	45,00	3,19E-04
40	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	50,00	2,66E-04
41	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	55,00	2,19E-04
42	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	60,00	1,80E-04
43	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	65,00	1,47E-04
44	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	70,00	1,19E-04
45	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	75,00	1,01E-04
46	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	80,00	8,44E-05
47	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	85,00	7,04E-05
48	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	90,00	5,88E-05
49	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	95,00	4,71E-05
50	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	100,00	3,55E-05
51	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	105,00	3,32E-05
52	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	110,00	3,09E-05
53	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	115,00	2,39E-05
54	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	120,00	2,15E-05
55	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	125,00	1,92E-05
56	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	130,00	1,69E-05
57	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	135,00	1,22E-05
58	1,19	22,00	9,50	27,50	63,00	0,00	1,70E-03	140,00	1,22E-05
59	0,39	16,13	27,58	21,42	50,25	9,00	3,77E-05	16,64	3,37E-05
60	0,39	16,13	27,58	21,42	50,25	9,00	3,77E-05	62,63	3,03E-05
61	0,39	16,13	27,58	21,42	50,25	9,00	3,77E-05	118,50	2,64E-05
62	0,39	16,13	27,58	21,42	50,25	9,00	3,77E-05	174,30	2,24E-05
63	0,39	16,13	27,58	21,42	50,25	9,00	3,77E-05	262,90	1,86E-05
64	0,39	16,13	27,58	21,42	50,25	9,00	3,77E-05	485,00	1,47E-05
65	0,39	16,13	27,58	21,42	50,25	9,00	3,77E-05	802,30	1,14E-05
66	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	0,10	1,18E-04
67	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	0,15	1,18E-04
68	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	0,27	1,14E-04
69	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	0,39	1,12E-04
70	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	0,61	1,10E-04
71	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	1,00	1,08E-04
72	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	2,02	1,06E-04
73	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	3,98	1,04E-04
74	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	9,11	9,17E-05
75	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	15,16	7,64E-05
76	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	21,61	6,31E-05
77	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	28,20	5,12E-05

	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	Y
Exemplo	e _o	w _o (%)	C (%)	M (%)	S (%)	IP (%)	k _{sat} (cm/s)	u _a -u _w (kPa)	k _w (cm/s)
78	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	35,98	4,11E-05
79	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	46,60	3,10E-05
80	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	52,83	2,53E-05
81	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	59,46	2,09E-05
82	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	85,39	1,01E-05
83	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	91,26	8,47E-06
84	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	96,82	6,99E-06
85	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	105,80	5,57E-06
86	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	113,90	4,16E-06
87	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	125,40	3,08E-06
88	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	131,10	2,54E-06
89	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	140,10	2,06E-06
90	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	163,60	9,92E-07
91	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	170,80	7,87E-07
92	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	181,20	6,10E-07
93	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	188,40	5,02E-07
94	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	194,10	3,94E-07
95	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	202,70	3,08E-07
96	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	209,90	2,51E-07
97	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	218,40	2,07E-07
98	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	240,90	1,04E-07
99	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	250,60	8,12E-08
100	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	260,60	6,30E-08
101	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	268,40	5,00E-08
102	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	276,40	4,07E-08
103	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	284,70	3,27E-08
104	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	293,20	2,59E-08
105	1,20	46,00	28,00	42,00	30,00	40,00	1,18E-04	299,00	2,06E-08
106	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	0,10	1,40E-04
107	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	0,20	1,30E-04
108	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	0,30	1,30E-04
109	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	0,40	1,20E-04
110	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	0,50	1,15E-04
111	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	0,60	9,44E-05
112	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	0,90	5,64E-05
113	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	1,20	4,11E-05
114	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	1,60	2,36E-05
115	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	2,00	1,53E-05
116	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	3,00	4,46E-06
117	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	4,00	1,21E-06
118	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	5,00	3,53E-07
119	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	6,00	8,82E-08

	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	y
Exemplo	e _o	w _o (%)	C (%)	M (%)	S (%)	IP (%)	k _{sat} (cm/s)	u _a -u _w (kPa)	k _w (cm/s)
120	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	7,00	2,91E-08
121	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	8,00	7,26E-09
122	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	9,00	2,04E-09
123	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	10,00	5,74E-10
124	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	12,00	5,33E-11
125	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	14,00	4,21E-12
126	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	16,00	4,96E-13
127	0,90	12,00	26,00	11,50	62,50	13,00	4,40E-04	20,00	1,30E-15
128	1,04	16,00	31,00	5,00	64,00	13,00	4,60E-03	0,20	4,00E-04
129	1,04	16,00	31,00	5,00	64,00	13,00	4,60E-03	0,90	1,20E-04
130	1,04	16,00	31,00	5,00	64,00	13,00	4,60E-03	1,40	5,22E-05
131	1,04	16,00	31,00	5,00	64,00	13,00	4,60E-03	1,70	3,09E-05
132	1,32	44,86	39,00	48,00	12,00	12,96	1,77E-04	10,00	9,68E-09
133	1,32	44,86	39,00	48,00	12,00	12,96	1,77E-04	12,00	4,39E-09
134	1,32	44,86	39,00	48,00	12,00	12,96	1,77E-04	14,00	2,47E-09
135	1,32	44,86	39,00	48,00	12,00	12,96	1,77E-04	16,00	1,60E-09
136	1,32	44,86	39,00	48,00	12,00	12,96	1,77E-04	18,00	9,33E-10
137	1,32	44,86	39,00	48,00	12,00	12,96	1,77E-04	20,00	6,51E-10
138	1,32	44,86	39,00	48,00	12,00	12,96	1,77E-04	25,00	2,65E-10
139	1,32	44,86	39,00	48,00	12,00	12,96	1,77E-04	30,00	1,39E-10
140	1,31	39,82	16,00	38,00	47,00	14,50	1,38E-03	10,00	1,75E-07
141	1,31	39,82	16,00	38,00	47,00	14,50	1,38E-03	12,00	1,08E-07
142	1,31	39,82	16,00	38,00	47,00	14,50	1,38E-03	16,00	5,02E-08
143	1,31	39,82	16,00	38,00	47,00	14,50	1,38E-03	18,00	3,58E-08
144	1,31	39,82	16,00	38,00	47,00	14,50	1,38E-03	20,00	2,55E-08
145	1,31	39,82	16,00	38,00	47,00	14,50	1,38E-03	25,00	1,47E-08
146	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	10,00	1,51E-07
147	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	14,00	5,99E-08
148	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	18,00	3,45E-08
149	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	22,00	1,92E-08
150	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	30,00	9,48E-09
151	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	39,00	5,45E-09
152	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	55,00	2,10E-09
153	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	76,00	7,85E-10
154	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	100,00	4,25E-10
155	0,92	22,34	52,00	10,00	39,00	21,55	1,12E-03	141,00	1,85E-10
156	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,01	1,74E-04
157	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,02	1,51E-04
158	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,03	1,37E-04
159	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,04	1,31E-04
160	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,06	1,24E-04

	x₁	x₂	x₃	x₄	x₅	x₆	x₇	x₈	y
Exemplo	e_o	w_o (%)	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
161	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,08	1,19E-04
162	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,10	1,15E-04
163	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,20	8,96E-05
164	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,30	7,24E-05
165	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,40	6,06E-05
166	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,60	4,90E-05
167	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	0,80	3,43E-05
168	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	1,00	2,87E-05
169	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	2,00	1,22E-05
170	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	3,00	5,59E-06
171	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	4,00	3,16E-06
172	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	6,00	1,35E-06
173	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	8,00	6,15E-07
174	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	10,00	4,01E-07
175	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	20,00	7,81E-08
176	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	30,00	2,99E-08
177	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	40,00	1,69E-08
178	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	60,00	7,46E-09
179	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	80,00	4,37E-09
180	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	100,00	3,41E-09
181	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	200,00	1,67E-09
182	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	300,00	1,21E-09
183	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	400,00	1,05E-09
184	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	600,00	6,87E-10
185	1,24	18,90	6,00	46,00	48,00	12,00	2,30E-04	800,00	3,89E-10
186	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,01	1,42E-04
187	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,02	1,28E-04
188	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,03	1,11E-04
189	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,04	1,03E-04
190	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,06	9,29E-05
191	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,08	8,65E-05
192	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,10	7,78E-05
193	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,20	6,28E-05
194	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,30	5,26E-05
195	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,40	4,25E-05
196	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,60	3,31E-05
197	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	0,80	2,67E-05
198	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	1,00	2,08E-05
199	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	2,00	9,19E-06
200	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	3,00	5,59E-06
201	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	4,00	3,39E-06

	x₁	x₂	x₃	x₄	x₅	x₆	x₇	x₈	y
Exemplo	e_o	w_o (%)	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
202	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	6,00	1,73E-06
203	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	8,00	9,43E-07
204	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	10,00	5,94E-07
205	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	20,00	1,54E-07
206	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	30,00	6,54E-08
207	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	40,00	3,83E-08
208	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	60,00	1,95E-08
209	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	80,00	1,23E-08
210	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	100,00	8,01E-09
211	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	200,00	3,66E-09
212	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	300,00	2,30E-09
213	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	400,00	1,67E-09
214	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	600,00	9,81E-10
215	1,14	25,60	5,50	30,50	64,00	15,00	2,30E-04	800,00	5,75E-10
216	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,01	5,07E-05
217	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,02	3,68E-05
218	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,03	3,08E-05
219	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,04	2,49E-05
220	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,06	1,87E-05
221	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,08	1,46E-05
222	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,10	1,18E-05
223	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,20	5,20E-06
224	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,30	2,84E-06
225	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,40	1,92E-06
226	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,60	8,78E-07
227	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	0,80	5,15E-07
228	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	1,00	3,36E-07
229	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	2,00	7,27E-08
230	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	3,00	3,10E-08
231	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	4,00	1,63E-08
232	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	6,00	6,24E-09
233	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	8,00	3,29E-09
234	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	10,00	2,00E-09
235	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	20,00	4,18E-10
236	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	30,00	1,78E-10
237	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	40,00	9,04E-11
238	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	60,00	3,99E-11
239	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	80,00	2,26E-11
240	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	100,00	1,47E-11
241	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	200,00	5,06E-12
242	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	300,00	3,08E-12

	x ₁	x ₂	x ₃	x ₄	x ₅	x ₆	x ₇	x ₈	y
Exemplo	e _o	w _o (%)	C (%)	M (%)	S (%)	IP (%)	k _{sat} (cm/s)	u _a -u _w (kPa)	k _w (cm/s)
243	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	400,00	2,31E-12
244	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	600,00	1,68E-12
245	1,11	18,70	31,00	15,50	53,50	13,00	2,60E-04	800,00	1,51E-12
246	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,01	6,82E-04
247	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,02	6,13E-04
248	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,03	5,70E-04
249	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,04	5,31E-04
250	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,06	4,45E-04
251	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,08	4,00E-04
252	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,10	3,59E-04
253	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,20	2,61E-04
254	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,30	1,89E-04
255	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,40	1,58E-04
256	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,60	1,03E-04
257	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	0,80	7,50E-05
258	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	1,00	5,26E-05
259	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	2,00	1,74E-05
260	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	3,00	7,97E-06
261	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	4,00	4,68E-06
262	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	6,00	1,99E-06
263	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	8,00	9,77E-07
264	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	10,00	5,73E-07
265	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	20,00	1,33E-07
266	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	30,00	6,09E-08
267	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	40,00	3,57E-08
268	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	60,00	2,02E-08
269	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	80,00	1,37E-08
270	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	100,00	9,91E-09
271	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	200,00	4,22E-09
272	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	300,00	2,56E-09
273	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	400,00	1,56E-09
274	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	600,00	6,18E-10
275	1,41	20,60	10,00	40,00	50,00	4,00	1,20E-03	800,00	3,14E-10

**APÊNDICE B – CONJUNTO EXPERIMENTAL UTILIZADO NO
DESENVOLVIMENTO DO MODELO DE RNA PARA A CONFIGURAÇÃO C2**

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
1	27,00	16,00	57,00	15,00	3,10E-03	20,00	3,72E-09
2	27,00	16,00	57,00	15,00	3,10E-03	25,00	2,71E-09
3	27,00	16,00	57,00	15,00	3,10E-03	30,00	1,87E-09
4	27,00	16,00	57,00	15,00	3,10E-03	35,00	1,62E-09
5	27,00	16,00	57,00	15,00	3,10E-03	40,00	1,33E-09
6	27,00	16,00	57,00	15,00	3,10E-03	45,00	1,18E-09
7	27,00	16,00	57,00	15,00	3,10E-03	50,00	1,03E-09
8	27,00	16,00	57,00	15,00	3,10E-03	55,00	7,81E-10
9	27,00	16,00	57,00	15,00	3,10E-03	60,00	6,16E-10
10	27,00	16,00	57,00	15,00	3,10E-03	65,00	5,40E-10
11	27,00	16,00	57,00	15,00	3,10E-03	70,00	4,43E-10
12	27,00	16,00	57,00	15,00	3,10E-03	75,00	3,93E-10
13	27,00	16,00	57,00	15,00	3,10E-03	80,00	3,35E-10
14	27,00	16,00	57,00	15,00	3,10E-03	85,00	3,06E-10
15	27,00	16,00	57,00	15,00	3,10E-03	90,00	2,86E-10
16	27,00	16,00	57,00	15,00	3,10E-03	95,00	2,64E-10
17	27,00	16,00	57,00	15,00	3,10E-03	100,00	2,47E-10
18	27,00	16,00	57,00	15,00	3,10E-03	150,00	1,24E-10
19	35,00	10,00	55,00	0,00	3,50E-03	25,00	1,54E-07
20	35,00	10,00	55,00	0,00	3,50E-03	50,00	2,61E-08
21	35,00	10,00	55,00	0,00	3,50E-03	75,00	9,85E-09
22	35,00	10,00	55,00	0,00	3,50E-03	100,00	4,85E-09
23	35,00	10,00	55,00	0,00	3,50E-03	125,00	3,02E-09
24	35,00	10,00	55,00	0,00	3,50E-03	150,00	1,78E-09
25	35,00	10,00	55,00	0,00	3,50E-03	175,00	1,17E-09
26	35,00	10,00	55,00	0,00	3,50E-03	200,00	7,99E-10
27	35,00	10,00	55,00	0,00	3,50E-03	225,00	6,39E-10
28	35,00	10,00	55,00	0,00	3,50E-03	250,00	5,23E-10
29	35,00	10,00	55,00	0,00	3,50E-03	275,00	4,19E-10
30	35,00	10,00	55,00	0,00	3,50E-03	300,00	3,28E-10
31	9,50	27,50	63,00	0,00	1,70E-03	5,00	1,39E-03
32	9,50	27,50	63,00	0,00	1,70E-03	10,00	1,17E-03
33	9,50	27,50	63,00	0,00	1,70E-03	15,00	9,73E-04
34	9,50	27,50	63,00	0,00	1,70E-03	20,00	8,10E-04
35	9,50	27,50	63,00	0,00	1,70E-03	25,00	6,87E-04
36	9,50	27,50	63,00	0,00	1,70E-03	30,00	5,52E-04

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
37	9,50	27,50	63,00	0,00	1,70E-03	35,00	4,66E-04
38	9,50	27,50	63,00	0,00	1,70E-03	40,00	3,80E-04
39	9,50	27,50	63,00	0,00	1,70E-03	45,00	3,19E-04
40	9,50	27,50	63,00	0,00	1,70E-03	50,00	2,66E-04
41	9,50	27,50	63,00	0,00	1,70E-03	55,00	2,19E-04
42	9,50	27,50	63,00	0,00	1,70E-03	60,00	1,80E-04
43	9,50	27,50	63,00	0,00	1,70E-03	65,00	1,47E-04
44	9,50	27,50	63,00	0,00	1,70E-03	70,00	1,19E-04
45	9,50	27,50	63,00	0,00	1,70E-03	75,00	1,01E-04
46	9,50	27,50	63,00	0,00	1,70E-03	80,00	8,44E-05
47	9,50	27,50	63,00	0,00	1,70E-03	85,00	7,04E-05
48	9,50	27,50	63,00	0,00	1,70E-03	90,00	5,88E-05
49	9,50	27,50	63,00	0,00	1,70E-03	95,00	4,71E-05
50	9,50	27,50	63,00	0,00	1,70E-03	100,00	3,55E-05
51	9,50	27,50	63,00	0,00	1,70E-03	105,00	3,32E-05
52	9,50	27,50	63,00	0,00	1,70E-03	110,00	3,09E-05
53	9,50	27,50	63,00	0,00	1,70E-03	115,00	2,39E-05
54	9,50	27,50	63,00	0,00	1,70E-03	120,00	2,15E-05
55	9,50	27,50	63,00	0,00	1,70E-03	125,00	1,92E-05
56	9,50	27,50	63,00	0,00	1,70E-03	130,00	1,69E-05
57	9,50	27,50	63,00	0,00	1,70E-03	135,00	1,22E-05
58	9,50	27,50	63,00	0,00	1,70E-03	140,00	1,22E-05
59	27,58	21,42	50,25	9,00	3,77E-05	16,64	3,37E-05
60	27,58	21,42	50,25	9,00	3,77E-05	62,63	3,03E-05
61	27,58	21,42	50,25	9,00	3,77E-05	118,50	2,64E-05
62	27,58	21,42	50,25	9,00	3,77E-05	174,30	2,24E-05
63	27,58	21,42	50,25	9,00	3,77E-05	262,90	1,86E-05
64	27,58	21,42	50,25	9,00	3,77E-05	485,00	1,47E-05
65	27,58	21,42	50,25	9,00	3,77E-05	802,30	1,14E-05
66	28,00	42,00	30,00	40,00	1,18E-04	0,10	1,18E-04
67	28,00	42,00	30,00	40,00	1,18E-04	0,15	1,18E-04
68	28,00	42,00	30,00	40,00	1,18E-04	0,27	1,14E-04
69	28,00	42,00	30,00	40,00	1,18E-04	0,39	1,12E-04
70	28,00	42,00	30,00	40,00	1,18E-04	0,61	1,10E-04
71	28,00	42,00	30,00	40,00	1,18E-04	1,00	1,08E-04
72	28,00	42,00	30,00	40,00	1,18E-04	2,02	1,06E-04
73	28,00	42,00	30,00	40,00	1,18E-04	3,98	1,04E-04
74	28,00	42,00	30,00	40,00	1,18E-04	9,11	9,17E-05
75	28,00	42,00	30,00	40,00	1,18E-04	15,16	7,64E-05
76	28,00	42,00	30,00	40,00	1,18E-04	21,61	6,31E-05
77	28,00	42,00	30,00	40,00	1,18E-04	28,20	5,12E-05

	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	y
Exemplo	C (%)	M (%)	S (%)	IP (%)	k _{sat} (cm/s)	u _a -u _w (kPa)	k _w (cm/s)
78	28,00	42,00	30,00	40,00	1,18E-04	35,98	4,11E-05
79	28,00	42,00	30,00	40,00	1,18E-04	46,60	3,10E-05
80	28,00	42,00	30,00	40,00	1,18E-04	52,83	2,53E-05
81	28,00	42,00	30,00	40,00	1,18E-04	59,46	2,09E-05
82	28,00	42,00	30,00	40,00	1,18E-04	85,39	1,01E-05
83	28,00	42,00	30,00	40,00	1,18E-04	91,26	8,47E-06
84	28,00	42,00	30,00	40,00	1,18E-04	96,82	6,99E-06
85	28,00	42,00	30,00	40,00	1,18E-04	105,80	5,57E-06
86	28,00	42,00	30,00	40,00	1,18E-04	113,90	4,16E-06
87	28,00	42,00	30,00	40,00	1,18E-04	125,40	3,08E-06
88	28,00	42,00	30,00	40,00	1,18E-04	131,10	2,54E-06
89	28,00	42,00	30,00	40,00	1,18E-04	140,10	2,06E-06
90	28,00	42,00	30,00	40,00	1,18E-04	163,60	9,92E-07
91	28,00	42,00	30,00	40,00	1,18E-04	170,80	7,87E-07
92	28,00	42,00	30,00	40,00	1,18E-04	181,20	6,10E-07
93	28,00	42,00	30,00	40,00	1,18E-04	188,40	5,02E-07
94	28,00	42,00	30,00	40,00	1,18E-04	194,10	3,94E-07
95	28,00	42,00	30,00	40,00	1,18E-04	202,70	3,08E-07
96	28,00	42,00	30,00	40,00	1,18E-04	209,90	2,51E-07
97	28,00	42,00	30,00	40,00	1,18E-04	218,40	2,07E-07
98	28,00	42,00	30,00	40,00	1,18E-04	240,90	1,04E-07
99	28,00	42,00	30,00	40,00	1,18E-04	250,60	8,12E-08
100	28,00	42,00	30,00	40,00	1,18E-04	260,60	6,30E-08
101	28,00	42,00	30,00	40,00	1,18E-04	268,40	5,00E-08
102	28,00	42,00	30,00	40,00	1,18E-04	276,40	4,07E-08
103	28,00	42,00	30,00	40,00	1,18E-04	284,70	3,27E-08
104	28,00	42,00	30,00	40,00	1,18E-04	293,20	2,59E-08
105	28,00	42,00	30,00	40,00	1,18E-04	299,00	2,06E-08
106	26,00	11,50	62,50	13,00	4,40E-04	0,10	1,40E-04
107	26,00	11,50	62,50	13,00	4,40E-04	0,20	1,30E-04
108	26,00	11,50	62,50	13,00	4,40E-04	0,30	1,30E-04
109	26,00	11,50	62,50	13,00	4,40E-04	0,40	1,20E-04
110	26,00	11,50	62,50	13,00	4,40E-04	0,50	1,15E-04
111	26,00	11,50	62,50	13,00	4,40E-04	0,60	9,44E-05
112	26,00	11,50	62,50	13,00	4,40E-04	0,90	5,64E-05
113	26,00	11,50	62,50	13,00	4,40E-04	1,20	4,11E-05
114	26,00	11,50	62,50	13,00	4,40E-04	1,60	2,36E-05
115	26,00	11,50	62,50	13,00	4,40E-04	2,00	1,53E-05
116	26,00	11,50	62,50	13,00	4,40E-04	3,00	4,46E-06
117	26,00	11,50	62,50	13,00	4,40E-04	4,00	1,21E-06
118	26,00	11,50	62,50	13,00	4,40E-04	5,00	3,53E-07
119	26,00	11,50	62,50	13,00	4,40E-04	6,00	8,82E-08

	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	y
Exemplo	C (%)	M (%)	S (%)	IP (%)	k _{sat} (cm/s)	u _a -u _w (kPa)	k _w (cm/s)
120	26,00	11,50	62,50	13,00	4,40E-04	7,00	2,91E-08
121	26,00	11,50	62,50	13,00	4,40E-04	8,00	7,26E-09
122	26,00	11,50	62,50	13,00	4,40E-04	9,00	2,04E-09
123	26,00	11,50	62,50	13,00	4,40E-04	10,00	5,74E-10
124	26,00	11,50	62,50	13,00	4,40E-04	12,00	5,33E-11
125	26,00	11,50	62,50	13,00	4,40E-04	14,00	4,21E-12
126	26,00	11,50	62,50	13,00	4,40E-04	16,00	4,96E-13
127	26,00	11,50	62,50	13,00	4,40E-04	20,00	1,30E-15
128	31,00	5,00	64,00	13,00	4,60E-03	0,20	4,00E-04
129	31,00	5,00	64,00	13,00	4,60E-03	0,90	1,20E-04
130	31,00	5,00	64,00	13,00	4,60E-03	1,40	5,22E-05
131	31,00	5,00	64,00	13,00	4,60E-03	1,70	3,09E-05
132	39,00	48,00	12,00	12,96	1,77E-04	10,00	9,68E-09
133	39,00	48,00	12,00	12,96	1,77E-04	12,00	4,39E-09
134	39,00	48,00	12,00	12,96	1,77E-04	14,00	2,47E-09
135	39,00	48,00	12,00	12,96	1,77E-04	16,00	1,60E-09
136	39,00	48,00	12,00	12,96	1,77E-04	18,00	9,33E-10
137	39,00	48,00	12,00	12,96	1,77E-04	20,00	6,51E-10
138	39,00	48,00	12,00	12,96	1,77E-04	25,00	2,65E-10
139	39,00	48,00	12,00	12,96	1,77E-04	30,00	1,39E-10
140	16,00	38,00	47,00	14,50	1,38E-03	10,00	1,75E-07
141	16,00	38,00	47,00	14,50	1,38E-03	12,00	1,08E-07
142	16,00	38,00	47,00	14,50	1,38E-03	16,00	5,02E-08
143	16,00	38,00	47,00	14,50	1,38E-03	18,00	3,58E-08
144	16,00	38,00	47,00	14,50	1,38E-03	20,00	2,55E-08
145	16,00	38,00	47,00	14,50	1,38E-03	25,00	1,47E-08
146	52,00	10,00	39,00	21,55	1,12E-03	10,00	1,51E-07
147	52,00	10,00	39,00	21,55	1,12E-03	14,00	5,99E-08
148	52,00	10,00	39,00	21,55	1,12E-03	18,00	3,45E-08
149	52,00	10,00	39,00	21,55	1,12E-03	22,00	1,92E-08
150	52,00	10,00	39,00	21,55	1,12E-03	30,00	9,48E-09
151	52,00	10,00	39,00	21,55	1,12E-03	39,00	5,45E-09
152	52,00	10,00	39,00	21,55	1,12E-03	55,00	2,10E-09
153	52,00	10,00	39,00	21,55	1,12E-03	76,00	7,85E-10
154	52,00	10,00	39,00	21,55	1,12E-03	100,00	4,25E-10
155	52,00	10,00	39,00	21,55	1,12E-03	141,00	1,85E-10
156	6,00	46,00	48,00	12,00	2,30E-04	0,01	1,74E-04
157	6,00	46,00	48,00	12,00	2,30E-04	0,02	1,51E-04
158	6,00	46,00	48,00	12,00	2,30E-04	0,03	1,37E-04
159	6,00	46,00	48,00	12,00	2,30E-04	0,04	1,31E-04
160	6,00	46,00	48,00	12,00	2,30E-04	0,06	1,24E-04

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
161	6,00	46,00	48,00	12,00	2,30E-04	0,08	1,19E-04
162	6,00	46,00	48,00	12,00	2,30E-04	0,10	1,15E-04
163	6,00	46,00	48,00	12,00	2,30E-04	0,20	8,96E-05
164	6,00	46,00	48,00	12,00	2,30E-04	0,30	7,24E-05
165	6,00	46,00	48,00	12,00	2,30E-04	0,40	6,06E-05
166	6,00	46,00	48,00	12,00	2,30E-04	0,60	4,90E-05
167	6,00	46,00	48,00	12,00	2,30E-04	0,80	3,43E-05
168	6,00	46,00	48,00	12,00	2,30E-04	1,00	2,87E-05
169	6,00	46,00	48,00	12,00	2,30E-04	2,00	1,22E-05
170	6,00	46,00	48,00	12,00	2,30E-04	3,00	5,59E-06
171	6,00	46,00	48,00	12,00	2,30E-04	4,00	3,16E-06
172	6,00	46,00	48,00	12,00	2,30E-04	6,00	1,35E-06
173	6,00	46,00	48,00	12,00	2,30E-04	8,00	6,15E-07
174	6,00	46,00	48,00	12,00	2,30E-04	10,00	4,01E-07
175	6,00	46,00	48,00	12,00	2,30E-04	20,00	7,81E-08
176	6,00	46,00	48,00	12,00	2,30E-04	30,00	2,99E-08
177	6,00	46,00	48,00	12,00	2,30E-04	40,00	1,69E-08
178	6,00	46,00	48,00	12,00	2,30E-04	60,00	7,46E-09
179	6,00	46,00	48,00	12,00	2,30E-04	80,00	4,37E-09
180	6,00	46,00	48,00	12,00	2,30E-04	100,00	3,41E-09
181	6,00	46,00	48,00	12,00	2,30E-04	200,00	1,67E-09
182	6,00	46,00	48,00	12,00	2,30E-04	300,00	1,21E-09
183	6,00	46,00	48,00	12,00	2,30E-04	400,00	1,05E-09
184	6,00	46,00	48,00	12,00	2,30E-04	600,00	6,87E-10
185	6,00	46,00	48,00	12,00	2,30E-04	800,00	3,89E-10
186	5,50	30,50	64,00	15,00	2,30E-04	0,01	1,42E-04
187	5,50	30,50	64,00	15,00	2,30E-04	0,02	1,28E-04
188	5,50	30,50	64,00	15,00	2,30E-04	0,03	1,11E-04
189	5,50	30,50	64,00	15,00	2,30E-04	0,04	1,03E-04
190	5,50	30,50	64,00	15,00	2,30E-04	0,06	9,29E-05
191	5,50	30,50	64,00	15,00	2,30E-04	0,08	8,65E-05
192	5,50	30,50	64,00	15,00	2,30E-04	0,10	7,78E-05
193	5,50	30,50	64,00	15,00	2,30E-04	0,20	6,28E-05
194	5,50	30,50	64,00	15,00	2,30E-04	0,30	5,26E-05
195	5,50	30,50	64,00	15,00	2,30E-04	0,40	4,25E-05
196	5,50	30,50	64,00	15,00	2,30E-04	0,60	3,31E-05
197	5,50	30,50	64,00	15,00	2,30E-04	0,80	2,67E-05
198	5,50	30,50	64,00	15,00	2,30E-04	1,00	2,08E-05
199	5,50	30,50	64,00	15,00	2,30E-04	2,00	9,19E-06
200	5,50	30,50	64,00	15,00	2,30E-04	3,00	5,59E-06
201	5,50	30,50	64,00	15,00	2,30E-04	4,00	3,39E-06

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
202	5,50	30,50	64,00	15,00	2,30E-04	6,00	1,73E-06
203	5,50	30,50	64,00	15,00	2,30E-04	8,00	9,43E-07
204	5,50	30,50	64,00	15,00	2,30E-04	10,00	5,94E-07
205	5,50	30,50	64,00	15,00	2,30E-04	20,00	1,54E-07
206	5,50	30,50	64,00	15,00	2,30E-04	30,00	6,54E-08
207	5,50	30,50	64,00	15,00	2,30E-04	40,00	3,83E-08
208	5,50	30,50	64,00	15,00	2,30E-04	60,00	1,95E-08
209	5,50	30,50	64,00	15,00	2,30E-04	80,00	1,23E-08
210	5,50	30,50	64,00	15,00	2,30E-04	100,00	8,01E-09
211	5,50	30,50	64,00	15,00	2,30E-04	200,00	3,66E-09
212	5,50	30,50	64,00	15,00	2,30E-04	300,00	2,30E-09
213	5,50	30,50	64,00	15,00	2,30E-04	400,00	1,67E-09
214	5,50	30,50	64,00	15,00	2,30E-04	600,00	9,81E-10
215	5,50	30,50	64,00	15,00	2,30E-04	800,00	5,75E-10
216	31,00	15,50	53,50	13,00	2,60E-04	0,01	5,07E-05
217	31,00	15,50	53,50	13,00	2,60E-04	0,02	3,68E-05
218	31,00	15,50	53,50	13,00	2,60E-04	0,03	3,08E-05
219	31,00	15,50	53,50	13,00	2,60E-04	0,04	2,49E-05
220	31,00	15,50	53,50	13,00	2,60E-04	0,06	1,87E-05
221	31,00	15,50	53,50	13,00	2,60E-04	0,08	1,46E-05
222	31,00	15,50	53,50	13,00	2,60E-04	0,10	1,18E-05
223	31,00	15,50	53,50	13,00	2,60E-04	0,20	5,20E-06
224	31,00	15,50	53,50	13,00	2,60E-04	0,30	2,84E-06
225	31,00	15,50	53,50	13,00	2,60E-04	0,40	1,92E-06
226	31,00	15,50	53,50	13,00	2,60E-04	0,60	8,78E-07
227	31,00	15,50	53,50	13,00	2,60E-04	0,80	5,15E-07
228	31,00	15,50	53,50	13,00	2,60E-04	1,00	3,36E-07
229	31,00	15,50	53,50	13,00	2,60E-04	2,00	7,27E-08
230	31,00	15,50	53,50	13,00	2,60E-04	3,00	3,10E-08
231	31,00	15,50	53,50	13,00	2,60E-04	4,00	1,63E-08
232	31,00	15,50	53,50	13,00	2,60E-04	6,00	6,24E-09
233	31,00	15,50	53,50	13,00	2,60E-04	8,00	3,29E-09
234	31,00	15,50	53,50	13,00	2,60E-04	10,00	2,00E-09
235	31,00	15,50	53,50	13,00	2,60E-04	20,00	4,18E-10
236	31,00	15,50	53,50	13,00	2,60E-04	30,00	1,78E-10
237	31,00	15,50	53,50	13,00	2,60E-04	40,00	9,04E-11
238	31,00	15,50	53,50	13,00	2,60E-04	60,00	3,99E-11
239	31,00	15,50	53,50	13,00	2,60E-04	80,00	2,26E-11
240	31,00	15,50	53,50	13,00	2,60E-04	100,00	1,47E-11
241	31,00	15,50	53,50	13,00	2,60E-04	200,00	5,06E-12
242	31,00	15,50	53,50	13,00	2,60E-04	300,00	3,08E-12

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	C (%)	M (%)	S (%)	IP (%)	k_{sat} (cm/s)	u_a-u_w (kPa)	k_w (cm/s)
243	31,00	15,50	53,50	13,00	2,60E-04	400,00	2,31E-12
244	31,00	15,50	53,50	13,00	2,60E-04	600,00	1,68E-12
245	31,00	15,50	53,50	13,00	2,60E-04	800,00	1,51E-12
246	10,00	40,00	50,00	4,00	1,20E-03	0,01	6,82E-04
247	10,00	40,00	50,00	4,00	1,20E-03	0,02	6,13E-04
248	10,00	40,00	50,00	4,00	1,20E-03	0,03	5,70E-04
249	10,00	40,00	50,00	4,00	1,20E-03	0,04	5,31E-04
250	10,00	40,00	50,00	4,00	1,20E-03	0,06	4,45E-04
251	10,00	40,00	50,00	4,00	1,20E-03	0,08	4,00E-04
252	10,00	40,00	50,00	4,00	1,20E-03	0,10	3,59E-04
253	10,00	40,00	50,00	4,00	1,20E-03	0,20	2,61E-04
254	10,00	40,00	50,00	4,00	1,20E-03	0,30	1,89E-04
255	10,00	40,00	50,00	4,00	1,20E-03	0,40	1,58E-04
256	10,00	40,00	50,00	4,00	1,20E-03	0,60	1,03E-04
257	10,00	40,00	50,00	4,00	1,20E-03	0,80	7,50E-05
258	10,00	40,00	50,00	4,00	1,20E-03	1,00	5,26E-05
259	10,00	40,00	50,00	4,00	1,20E-03	2,00	1,74E-05
260	10,00	40,00	50,00	4,00	1,20E-03	3,00	7,97E-06
261	10,00	40,00	50,00	4,00	1,20E-03	4,00	4,68E-06
262	10,00	40,00	50,00	4,00	1,20E-03	6,00	1,99E-06
263	10,00	40,00	50,00	4,00	1,20E-03	8,00	9,77E-07
264	10,00	40,00	50,00	4,00	1,20E-03	10,00	5,73E-07
265	10,00	40,00	50,00	4,00	1,20E-03	20,00	1,33E-07
266	10,00	40,00	50,00	4,00	1,20E-03	30,00	6,09E-08
267	10,00	40,00	50,00	4,00	1,20E-03	40,00	3,57E-08
268	10,00	40,00	50,00	4,00	1,20E-03	60,00	2,02E-08
269	10,00	40,00	50,00	4,00	1,20E-03	80,00	1,37E-08
270	10,00	40,00	50,00	4,00	1,20E-03	100,00	9,91E-09
271	10,00	40,00	50,00	4,00	1,20E-03	200,00	4,22E-09
272	10,00	40,00	50,00	4,00	1,20E-03	300,00	2,56E-09
273	10,00	40,00	50,00	4,00	1,20E-03	400,00	1,56E-09
274	10,00	40,00	50,00	4,00	1,20E-03	600,00	6,18E-10
275	10,00	40,00	50,00	4,00	1,20E-03	800,00	3,14E-10

**APÊNDICE C – CONJUNTO EXPERIMENTAL UTILIZADO NO
DESENVOLVIMENTO DO MODELO DE RNA PARA A CONFIGURAÇÃO C3**

	x_1	x_2	x_3	x_4	x_5	x_6	y
Exemplo	θ	C (%)	M (%)	S (%)	IP (%)	u_a-u_w (kPa)	k_w (cm/s)
1	47,50	27,00	16,00	57,00	15,00	0,00	3,10E-03
2	28,98	27,00	16,00	57,00	15,00	20,00	3,72E-09
3	28,31	27,00	16,00	57,00	15,00	25,00	2,71E-09
4	27,77	27,00	16,00	57,00	15,00	30,00	1,87E-09
5	27,45	27,00	16,00	57,00	15,00	35,00	1,62E-09
6	27,20	27,00	16,00	57,00	15,00	40,00	1,33E-09
7	26,89	27,00	16,00	57,00	15,00	45,00	1,18E-09
8	26,70	27,00	16,00	57,00	15,00	50,00	1,03E-09
9	26,51	27,00	16,00	57,00	15,00	55,00	7,81E-10
10	26,38	27,00	16,00	57,00	15,00	60,00	6,16E-10
11	26,32	27,00	16,00	57,00	15,00	65,00	5,40E-10
12	26,19	27,00	16,00	57,00	15,00	70,00	4,43E-10
13	26,06	27,00	16,00	57,00	15,00	75,00	3,93E-10
14	25,94	27,00	16,00	57,00	15,00	80,00	3,35E-10
15	25,87	27,00	16,00	57,00	15,00	85,00	3,06E-10
16	25,82	27,00	16,00	57,00	15,00	90,00	2,86E-10
17	25,74	27,00	16,00	57,00	15,00	95,00	2,64E-10
18	25,68	27,00	16,00	57,00	15,00	100,00	2,47E-10
19	25,31	27,00	16,00	57,00	15,00	150,00	1,24E-10
20	48,89	35,00	10,00	55,00	0,00	0,00	3,50E-03
21	20,28	35,00	10,00	55,00	0,00	25,00	1,54E-07
22	17,50	35,00	10,00	55,00	0,00	50,00	2,61E-08
23	16,20	35,00	10,00	55,00	0,00	75,00	9,85E-09
24	15,56	35,00	10,00	55,00	0,00	100,00	4,85E-09
25	15,09	35,00	10,00	55,00	0,00	125,00	3,02E-09
26	14,63	35,00	10,00	55,00	0,00	150,00	1,78E-09
27	14,17	35,00	10,00	55,00	0,00	175,00	1,17E-09
28	14,07	35,00	10,00	55,00	0,00	200,00	7,99E-10
29	13,80	35,00	10,00	55,00	0,00	225,00	6,39E-10
30	13,61	35,00	10,00	55,00	0,00	250,00	5,23E-10
31	13,43	35,00	10,00	55,00	0,00	275,00	4,19E-10
32	13,43	35,00	10,00	55,00	0,00	300,00	3,28E-10
33	38,50	9,50	27,50	63,00	0,00	0,00	1,70E-03
34	37,81	9,50	27,50	63,00	0,00	5,00	1,39E-03
35	36,31	9,50	27,50	63,00	0,00	10,00	1,17E-03
36	29,31	9,50	27,50	63,00	0,00	15,00	9,73E-04
37	24,66	9,50	27,50	63,00	0,00	20,00	8,10E-04

	x ₁	x ₂	x ₃	x ₄	x ₅	x ₆	y
Exemplo	θ	C (%)	M (%)	S (%)	IP (%)	u _a -u _w (kPa)	k _w (cm/s)
38	22,45	9,50	27,50	63,00	0,00	25,00	6,87E-04
39	20,30	9,50	27,50	63,00	0,00	30,00	5,52E-04
40	18,30	9,50	27,50	63,00	0,00	35,00	4,66E-04
41	16,45	9,50	27,50	63,00	0,00	40,00	3,80E-04
42	14,90	9,50	27,50	63,00	0,00	45,00	3,19E-04
43	13,70	9,50	27,50	63,00	0,00	50,00	2,66E-04
44	12,55	9,50	27,50	63,00	0,00	55,00	2,19E-04
45	11,60	9,50	27,50	63,00	0,00	60,00	1,80E-04
46	10,85	9,50	27,50	63,00	0,00	65,00	1,47E-04
47	10,05	9,50	27,50	63,00	0,00	70,00	1,19E-04
48	9,75	9,50	27,50	63,00	0,00	75,00	1,01E-04
49	9,60	9,50	27,50	63,00	0,00	80,00	8,44E-05
50	9,40	9,50	27,50	63,00	0,00	85,00	7,04E-05
51	9,25	9,50	27,50	63,00	0,00	90,00	5,88E-05
52	9,20	9,50	27,50	63,00	0,00	95,00	4,71E-05
53	9,00	9,50	27,50	63,00	0,00	100,00	3,55E-05
54	8,95	9,50	27,50	63,00	0,00	105,00	3,32E-05
55	8,90	9,50	27,50	63,00	0,00	110,00	3,09E-05
56	8,85	9,50	27,50	63,00	0,00	115,00	2,39E-05
57	8,75	9,50	27,50	63,00	0,00	120,00	2,15E-05
58	8,70	9,50	27,50	63,00	0,00	125,00	1,92E-05
59	8,65	9,50	27,50	63,00	0,00	130,00	1,69E-05
60	8,60	9,50	27,50	63,00	0,00	135,00	1,22E-05
61	8,45	9,50	27,50	63,00	0,00	140,00	1,22E-05
62	28,00	27,58	21,42	50,25	9,00	0,00	3,77E-05
63	27,55	27,58	21,42	50,25	9,00	16,64	3,37E-05
64	27,07	27,58	21,42	50,25	9,00	62,63	3,03E-05
65	26,52	27,58	21,42	50,25	9,00	118,50	2,64E-05
66	26,12	27,58	21,42	50,25	9,00	174,30	2,24E-05
67	25,73	27,58	21,42	50,25	9,00	262,90	1,86E-05
68	25,21	27,58	21,42	50,25	9,00	485,00	1,47E-05
69	24,57	27,58	21,42	50,25	9,00	802,30	1,14E-05
70	35,07	26,00	11,50	62,50	13,00	0,00	4,40E-04
71	35,07	26,00	11,50	62,50	13,00	0,10	1,40E-04
72	35,07	26,00	11,50	62,50	13,00	0,20	1,30E-04
73	35,07	26,00	11,50	62,50	13,00	0,30	1,30E-04
74	35,07	26,00	11,50	62,50	13,00	0,40	1,20E-04
75	35,07	26,00	11,50	62,50	13,00	0,50	1,15E-04
76	35,03	26,00	11,50	62,50	13,00	0,60	9,44E-05
77	34,80	26,00	11,50	62,50	13,00	0,90	5,64E-05
78	34,47	26,00	11,50	62,50	13,00	1,20	4,11E-05

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	θ	C (%)	M (%)	S (%)	IP (%)	u_a-u_w (kPa)	k_w (cm/s)
79	34,09	26,00	11,50	62,50	13,00	1,60	2,36E-05
80	33,68	26,00	11,50	62,50	13,00	2,00	1,53E-05
81	32,67	26,00	11,50	62,50	13,00	3,00	4,46E-06
82	31,20	26,00	11,50	62,50	13,00	4,00	1,21E-06
83	29,89	26,00	11,50	62,50	13,00	5,00	3,53E-07
84	28,73	26,00	11,50	62,50	13,00	6,00	8,82E-08
85	27,68	26,00	11,50	62,50	13,00	7,00	2,91E-08
86	26,51	26,00	11,50	62,50	13,00	8,00	7,26E-09
87	25,83	26,00	11,50	62,50	13,00	9,00	2,04E-09
88	24,97	26,00	11,50	62,50	13,00	10,00	5,74E-10
89	23,47	26,00	11,50	62,50	13,00	12,00	5,33E-11
90	22,35	26,00	11,50	62,50	13,00	14,00	4,21E-12
91	21,45	26,00	11,50	62,50	13,00	16,00	4,96E-13
92	20,40	26,00	11,50	62,50	13,00	20,00	1,30E-15
93	32,50	31,00	5,00	64,00	13,00	0,00	4,60E-03
94	32,50	31,00	5,00	64,00	13,00	0,20	4,00E-04
95	32,50	31,00	5,00	64,00	13,00	0,90	1,20E-04
96	32,50	31,00	5,00	64,00	13,00	1,40	5,22E-05
97	32,50	31,00	5,00	64,00	13,00	1,70	3,09E-05
98	55,00	39,00	48,00	12,00	12,96	0,00	1,77E-04
99	53,17	39,00	48,00	12,00	12,96	10,00	9,68E-09
100	51,88	39,00	48,00	12,00	12,96	12,00	4,39E-09
101	50,85	39,00	48,00	12,00	12,96	14,00	2,47E-09
102	49,99	39,00	48,00	12,00	12,96	16,00	1,60E-09
103	49,05	39,00	48,00	12,00	12,96	18,00	9,33E-10
104	48,36	39,00	48,00	12,00	12,96	20,00	6,51E-10
105	46,98	39,00	48,00	12,00	12,96	25,00	2,65E-10
106	46,21	39,00	48,00	12,00	12,96	30,00	1,39E-10
107	45,00	16,00	38,00	47,00	14,50	0,00	1,38E-03
108	44,98	16,00	38,00	47,00	14,50	10,00	1,75E-07
109	44,57	16,00	38,00	47,00	14,50	12,00	1,08E-07
110	44,16	16,00	38,00	47,00	14,50	16,00	5,02E-08
111	44,03	16,00	38,00	47,00	14,50	18,00	3,58E-08
112	43,75	16,00	38,00	47,00	14,50	20,00	2,55E-08
113	43,62	16,00	38,00	47,00	14,50	25,00	1,47E-08
114	36,45	52,00	10,00	39,00	21,55	0,00	1,12E-03
115	36,26	52,00	10,00	39,00	21,55	10,00	1,51E-07
116	36,12	52,00	10,00	39,00	21,55	14,00	5,99E-08
117	35,98	52,00	10,00	39,00	21,55	18,00	3,45E-08
118	35,91	52,00	10,00	39,00	21,55	22,00	1,92E-08
119	35,42	52,00	10,00	39,00	21,55	30,00	9,48E-09

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	θ	C (%)	M (%)	S (%)	IP (%)	u_a-u_w (kPa)	k_w (cm/s)
120	35,00	52,00	10,00	39,00	21,55	39,00	5,45E-09
121	34,51	52,00	10,00	39,00	21,55	55,00	2,10E-09
122	33,95	52,00	10,00	39,00	21,55	76,00	7,85E-10
123	33,53	52,00	10,00	39,00	21,55	100,00	4,25E-10
124	33,46	52,00	10,00	39,00	21,55	141,00	1,85E-10
125	52,17	6,00	46,00	48,00	12,00	0,00	2,30E-04
126	52,17	6,00	46,00	48,00	12,00	0,01	1,74E-04
127	52,17	6,00	46,00	48,00	12,00	0,02	1,51E-04
128	52,07	6,00	46,00	48,00	12,00	0,03	1,37E-04
129	51,97	6,00	46,00	48,00	12,00	0,04	1,31E-04
130	51,97	6,00	46,00	48,00	12,00	0,06	1,24E-04
131	51,97	6,00	46,00	48,00	12,00	0,08	1,19E-04
132	51,97	6,00	46,00	48,00	12,00	0,10	1,15E-04
133	51,97	6,00	46,00	48,00	12,00	0,20	8,96E-05
134	51,97	6,00	46,00	48,00	12,00	0,30	7,24E-05
135	51,76	6,00	46,00	48,00	12,00	0,40	6,06E-05
136	51,46	6,00	46,00	48,00	12,00	0,60	4,90E-05
137	51,36	6,00	46,00	48,00	12,00	0,80	3,43E-05
138	50,75	6,00	46,00	48,00	12,00	1,00	2,87E-05
139	49,43	6,00	46,00	48,00	12,00	2,00	1,22E-05
140	48,01	6,00	46,00	48,00	12,00	3,00	5,59E-06
141	46,90	6,00	46,00	48,00	12,00	4,00	3,16E-06
142	45,08	6,00	46,00	48,00	12,00	6,00	1,35E-06
143	43,76	6,00	46,00	48,00	12,00	8,00	6,15E-07
144	42,75	6,00	46,00	48,00	12,00	10,00	4,01E-07
145	40,01	6,00	46,00	48,00	12,00	20,00	7,81E-08
146	38,39	6,00	46,00	48,00	12,00	30,00	2,99E-08
147	37,28	6,00	46,00	48,00	12,00	40,00	1,69E-08
148	36,36	6,00	46,00	48,00	12,00	60,00	7,46E-09
149	35,45	6,00	46,00	48,00	12,00	80,00	4,37E-09
150	34,54	6,00	46,00	48,00	12,00	100,00	3,41E-09
151	33,22	6,00	46,00	48,00	12,00	200,00	1,67E-09
152	32,21	6,00	46,00	48,00	12,00	300,00	1,21E-09
153	31,40	6,00	46,00	48,00	12,00	400,00	1,05E-09
154	29,58	6,00	46,00	48,00	12,00	600,00	6,87E-10
155	27,45	6,00	46,00	48,00	12,00	800,00	3,89E-10
156	46,00	5,50	30,50	64,00	15,00	0,00	2,30E-04
157	45,89	5,50	30,50	64,00	15,00	0,01	1,42E-04
158	45,89	5,50	30,50	64,00	15,00	0,02	1,28E-04
159	45,79	5,50	30,50	64,00	15,00	0,03	1,11E-04
160	45,79	5,50	30,50	64,00	15,00	0,04	1,03E-04

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	θ	C (%)	M (%)	S (%)	IP (%)	u_a-u_w (kPa)	k_w (cm/s)
161	45,88	5,50	30,50	64,00	15,00	0,06	9,29E-05
162	45,80	5,50	30,50	64,00	15,00	0,08	8,65E-05
163	45,80	5,50	30,50	64,00	15,00	0,10	7,78E-05
164	45,80	5,50	30,50	64,00	15,00	0,20	6,28E-05
165	45,65	5,50	30,50	64,00	15,00	0,30	5,26E-05
166	45,72	5,50	30,50	64,00	15,00	0,40	4,25E-05
167	45,57	5,50	30,50	64,00	15,00	0,60	3,31E-05
168	45,42	5,50	30,50	64,00	15,00	0,80	2,67E-05
169	45,34	5,50	30,50	64,00	15,00	1,00	2,08E-05
170	44,35	5,50	30,50	64,00	15,00	2,00	9,19E-06
171	43,66	5,50	30,50	64,00	15,00	3,00	5,59E-06
172	42,98	5,50	30,50	64,00	15,00	4,00	3,39E-06
173	42,06	5,50	30,50	64,00	15,00	6,00	1,73E-06
174	41,30	5,50	30,50	64,00	15,00	8,00	9,43E-07
175	40,61	5,50	30,50	64,00	15,00	10,00	5,94E-07
176	38,33	5,50	30,50	64,00	15,00	20,00	1,54E-07
177	37,26	5,50	30,50	64,00	15,00	30,00	6,54E-08
178	36,27	5,50	30,50	64,00	15,00	40,00	3,83E-08
179	35,35	5,50	30,50	64,00	15,00	60,00	1,95E-08
180	34,44	5,50	30,50	64,00	15,00	80,00	1,23E-08
181	33,83	5,50	30,50	64,00	15,00	100,00	8,01E-09
182	32,30	5,50	30,50	64,00	15,00	200,00	3,66E-09
183	31,08	5,50	30,50	64,00	15,00	300,00	2,30E-09
184	30,09	5,50	30,50	64,00	15,00	400,00	1,67E-09
185	28,11	5,50	30,50	64,00	15,00	600,00	9,81E-10
186	26,59	5,50	30,50	64,00	15,00	800,00	5,75E-10
187	42,55	31,00	15,50	53,50	13,00	0,00	2,60E-04
188	42,14	31,00	15,50	53,50	13,00	0,01	5,07E-05
189	41,76	31,00	15,50	53,50	13,00	0,02	3,68E-05
190	41,68	31,00	15,50	53,50	13,00	0,03	3,08E-05
191	41,61	31,00	15,50	53,50	13,00	0,04	2,49E-05
192	41,45	31,00	15,50	53,50	13,00	0,06	1,87E-05
193	41,38	31,00	15,50	53,50	13,00	0,08	1,46E-05
194	41,22	31,00	15,50	53,50	13,00	0,10	1,18E-05
195	40,92	31,00	15,50	53,50	13,00	0,20	5,20E-06
196	40,54	31,00	15,50	53,50	13,00	0,30	2,84E-06
197	40,16	31,00	15,50	53,50	13,00	0,40	1,92E-06
198	39,32	31,00	15,50	53,50	13,00	0,60	8,78E-07
199	38,78	31,00	15,50	53,50	13,00	0,80	5,15E-07
200	38,25	31,00	15,50	53,50	13,00	1,00	3,36E-07
201	36,73	31,00	15,50	53,50	13,00	2,00	7,27E-08

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	θ	C (%)	M (%)	S (%)	IP (%)	u_a-u_w (kPa)	k_w (cm/s)
202	35,74	31,00	15,50	53,50	13,00	3,00	3,10E-08
203	35,20	31,00	15,50	53,50	13,00	4,00	1,63E-08
204	34,21	31,00	15,50	53,50	13,00	6,00	6,24E-09
205	33,75	31,00	15,50	53,50	13,00	8,00	3,29E-09
206	33,30	31,00	15,50	53,50	13,00	10,00	2,00E-09
207	31,92	31,00	15,50	53,50	13,00	20,00	4,18E-10
208	31,47	31,00	15,50	53,50	13,00	30,00	1,78E-10
209	30,86	31,00	15,50	53,50	13,00	40,00	9,04E-11
210	30,32	31,00	15,50	53,50	13,00	60,00	3,99E-11
211	29,86	31,00	15,50	53,50	13,00	80,00	2,26E-11
212	29,48	31,00	15,50	53,50	13,00	100,00	1,47E-11
213	28,64	31,00	15,50	53,50	13,00	200,00	5,06E-12
214	28,19	31,00	15,50	53,50	13,00	300,00	3,08E-12
215	27,88	31,00	15,50	53,50	13,00	400,00	2,31E-12
216	27,35	31,00	15,50	53,50	13,00	600,00	1,68E-12
217	27,12	31,00	15,50	53,50	13,00	800,00	1,51E-12
218	52,74	10,00	40,00	50,00	4,00	0,00	1,20E-03
219	52,74	10,00	40,00	50,00	4,00	0,01	6,82E-04
220	52,74	10,00	40,00	50,00	4,00	0,02	6,13E-04
221	52,66	10,00	40,00	50,00	4,00	0,03	5,70E-04
222	52,66	10,00	40,00	50,00	4,00	0,04	5,31E-04
223	52,66	10,00	40,00	50,00	4,00	0,06	4,45E-04
224	52,66	10,00	40,00	50,00	4,00	0,08	4,00E-04
225	52,58	10,00	40,00	50,00	4,00	0,10	3,59E-04
226	52,43	10,00	40,00	50,00	4,00	0,20	2,61E-04
227	52,20	10,00	40,00	50,00	4,00	0,30	1,89E-04
228	52,05	10,00	40,00	50,00	4,00	0,40	1,58E-04
229	51,36	10,00	40,00	50,00	4,00	0,60	1,03E-04
230	50,98	10,00	40,00	50,00	4,00	0,80	7,50E-05
231	50,53	10,00	40,00	50,00	4,00	1,00	5,26E-05
232	48,54	10,00	40,00	50,00	4,00	2,00	1,74E-05
233	47,09	10,00	40,00	50,00	4,00	3,00	7,97E-06
234	46,03	10,00	40,00	50,00	4,00	4,00	4,68E-06
235	44,20	10,00	40,00	50,00	4,00	6,00	1,99E-06
236	43,21	10,00	40,00	50,00	4,00	8,00	9,77E-07
237	42,29	10,00	40,00	50,00	4,00	10,00	5,73E-07
238	39,70	10,00	40,00	50,00	4,00	20,00	1,33E-07
239	38,48	10,00	40,00	50,00	4,00	30,00	6,09E-08
240	37,34	10,00	40,00	50,00	4,00	40,00	3,57E-08
241	36,19	10,00	40,00	50,00	4,00	60,00	2,02E-08
242	35,35	10,00	40,00	50,00	4,00	80,00	1,37E-08

	x₁	x₂	x₃	x₄	x₅	x₆	y
Exemplo	θ	C (%)	M (%)	S (%)	IP (%)	u_a-u_w (kPa)	k_w (cm/s)
243	34,52	10,00	40,00	50,00	4,00	100,00	9,91E-09
244	32,46	10,00	40,00	50,00	4,00	200,00	4,22E-09
245	30,40	10,00	40,00	50,00	4,00	300,00	2,56E-09
246	28,80	10,00	40,00	50,00	4,00	400,00	1,56E-09
247	25,44	10,00	40,00	50,00	4,00	600,00	6,18E-10
248	22,77	10,00	40,00	50,00	4,00	800,00	3,14E-10

APÊNDICE D – CORRELAÇÃO E RMS PARA TODAS AS ARQUITETURAS ANALISADAS

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,032078	0,933102	TREINAMENTO
50 K	0,030946	0,844248	TESTE
100 K	0,030657	0,939083	TREINAMENTO
100 K	0,030478	0,851029	TESTE
150 K	0,030001	0,941722	TREINAMENTO
150 K	0,030278	0,853001	TESTE
200 K	0,029631	0,943251	TREINAMENTO
200 K	0,029889	0,857553	TESTE
250 K	0,029280	0,944565	TREINAMENTO
250 K	0,029010	0,867086	TESTE
300 K	0,029035	0,945527	TREINAMENTO
300 K	0,028286	0,874846	TESTE
350 K	0,028813	0,946371	TREINAMENTO
350 K	0,027798	0,879724	TESTE
400 K	0,028595	0,947204	TREINAMENTO
400 K	0,027496	0,882709	TESTE
450 K	0,028380	0,948016	TREINAMENTO
450 K	0,027243	0,884932	TESTE
500 K	0,028165	0,948820	TREINAMENTO
500 K	0,027014	0,886975	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,032247	0,932375	TREINAMENTO
50 K	0,031157	0,840028	TESTE
100 K	0,031067	0,937364	TREINAMENTO
100 K	0,030815	0,846719	TESTE
150 K	0,030529	0,939582	TREINAMENTO
150 K	0,030540	0,851097	TESTE
200 K	0,029990	0,941761	TREINAMENTO
200 K	0,030450	0,851726	TESTE
250 K	0,029548	0,943516	TREINAMENTO
250 K	0,030267	0,852856	TESTE
300 K	0,029203	0,944864	TREINAMENTO
300 K	0,029791	0,857670	TESTE
350 K	0,028861	0,946187	TREINAMENTO
350 K	0,029046	0,865553	TESTE
400 K	0,028554	0,947356	TREINAMENTO
400 K	0,028437	0,871840	TESTE
450 K	0,028255	0,948483	TREINAMENTO
450 K	0,028011	0,875969	TESTE
500 K	0,027943	0,949656	TREINAMENTO
500 K	0,027693	0,878674	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,032143	0,932827	TREINAMENTO
50 K	0,031353	0,838271	TESTE
100 K	0,031217	0,936832	TREINAMENTO
100 K	0,030894	0,845625	TESTE
150 K	0,030771	0,938590	TREINAMENTO
150 K	0,030461	0,851587	TESTE
200 K	0,030369	0,940232	TREINAMENTO
200 K	0,030171	0,855387	TESTE
250 K	0,029877	0,942214	TREINAMENTO
250 K	0,029882	0,858743	TESTE
300 K	0,029364	0,944238	TREINAMENTO
300 K	0,029653	0,859917	TESTE
350 K	0,028979	0,945733	TREINAMENTO
350 K	0,029516	0,860079	TESTE
400 K	0,028644	0,947014	TREINAMENTO
400 K	0,029100	0,863990	TESTE
450 K	0,028333	0,948192	TREINAMENTO
450 K	0,028642	0,868670	TESTE
500 K	0,028009	0,949403	TREINAMENTO
500 K	0,028202	0,873123	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-12-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,032491	0,931317	TREINAMENTO
50 K	0,031321	0,837983	TESTE
100 K	0,031177	0,936906	TREINAMENTO
100 K	0,031403	0,839287	TESTE
150 K	0,030680	0,938964	TREINAMENTO
150 K	0,030897	0,846181	TESTE
200 K	0,030108	0,941290	TREINAMENTO
200 K	0,030284	0,853577	TESTE
250 K	0,029616	0,943248	TREINAMENTO
250 K	0,030104	0,854560	TESTE
300 K	0,029217	0,944813	TREINAMENTO
300 K	0,029753	0,857943	TESTE
350 K	0,028873	0,946148	TREINAMENTO
350 K	0,029125	0,864528	TESTE
400 K	0,028550	0,947374	TREINAMENTO
400 K	0,028524	0,870888	TESTE
450 K	0,028245	0,948522	TREINAMENTO
450 K	0,028075	0,875122	TESTE
500 K	0,027922	0,949722	TREINAMENTO
500 K	0,027741	0,878263	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-4-2-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,030093	0,941368	TREINAMENTO
50 K	0,028729	0,867138	TESTE
100 K	0,026743	0,954001	TREINAMENTO
100 K	0,024068	0,912277	TESTE
150 K	0,025439	0,958471	TREINAMENTO
150 K	0,021522	0,933800	TESTE
200 K	0,024718	0,960837	TREINAMENTO
200 K	0,019831	0,946713	TESTE
250 K	0,024196	0,962501	TREINAMENTO
250 K	0,018712	0,954412	TESTE
300 K	0,023731	0,963963	TREINAMENTO
300 K	0,017672	0,960568	TESTE
350 K	0,023311	0,965240	TREINAMENTO
350 K	0,017132	0,963841	TESTE
400 K	0,022918	0,966431	TREINAMENTO
400 K	0,016436	0,967098	TESTE
450 K	0,022519	0,967596	TREINAMENTO
450 K	0,016327	0,967648	TESTE
500 K	0,022032	0,969008	TREINAMENTO
500 K	0,016125	0,967683	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-4-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,028416	0,947880	TREINAMENTO
50 K	0,026780	0,888252	TESTE
100 K	0,026275	0,955613	TREINAMENTO
100 K	0,023278	0,919043	TESTE
150 K	0,025029	0,959821	TREINAMENTO
150 K	0,021032	0,934589	TESTE
200 K	0,023668	0,964140	TREINAMENTO
200 K	0,021453	0,929732	TESTE
250 K	0,022738	0,966952	TREINAMENTO
250 K	0,020865	0,933724	TESTE
300 K	0,022050	0,968951	TREINAMENTO
300 K	0,019880	0,940727	TESTE
350 K	0,021478	0,970568	TREINAMENTO
350 K	0,018838	0,947837	TESTE
400 K	0,021001	0,971879	TREINAMENTO
400 K	0,017941	0,953976	TESTE
450 K	0,020593	0,972975	TREINAMENTO
450 K	0,017180	0,958784	TESTE
500 K	0,020241	0,973902	TREINAMENTO
500 K	0,016689	0,962010	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-8-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,030750	0,938677	TREINAMENTO
50 K	0,030090	0,853600	TESTE
100 K	0,028659	0,946960	TREINAMENTO
100 K	0,027182	0,884944	TESTE
150 K	0,027360	0,951819	TREINAMENTO
150 K	0,024963	0,907889	TESTE
200 K	0,026350	0,955354	TREINAMENTO
200 K	0,023070	0,924300	TESTE
250 K	0,025641	0,957777	TREINAMENTO
250 K	0,021753	0,935041	TESTE
300 K	0,025024	0,959828	TREINAMENTO
300 K	0,020668	0,943115	TESTE
350 K	0,024439	0,961727	TREINAMENTO
350 K	0,019311	0,950587	TESTE
400 K	0,023840	0,963608	TREINAMENTO
400 K	0,018912	0,954251	TESTE
450 K	0,023257	0,965398	TREINAMENTO
450 K	0,018273	0,957468	TESTE
500 K	0,022547	0,967514	TREINAMENTO
500 K	0,017779	0,959211	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-8-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,028178	0,948771	TREINAMENTO
50 K	0,027145	0,883998	TESTE
100 K	0,026127	0,956134	TREINAMENTO
100 K	0,023776	0,915503	TESTE
150 K	0,024487	0,961567	TREINAMENTO
150 K	0,021778	0,928260	TESTE
200 K	0,023354	0,965108	TREINAMENTO
200 K	0,020778	0,934467	TESTE
250 K	0,022566	0,967458	TREINAMENTO
250 K	0,020043	0,939131	TESTE
300 K	0,021991	0,969120	TREINAMENTO
300 K	0,019369	0,943537	TESTE
350 K	0,021499	0,970508	TREINAMENTO
350 K	0,018735	0,947986	TESTE
400 K	0,021083	0,971656	TREINAMENTO
400 K	0,018016	0,952441	TESTE
450 K	0,020725	0,972622	TREINAMENTO
450 K	0,017420	0,956354	TESTE
500 K	0,020401	0,973485	TREINAMENTO
500 K	0,016843	0,960000	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-10-5-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,028791	0,946494	TREINAMENTO
50 K	0,027822	0,877771	TESTE
100 K	0,026037	0,956431	TREINAMENTO
100 K	0,024285	0,911341	TESTE
150 K	0,024562	0,961327	TREINAMENTO
150 K	0,022240	0,926352	TESTE
200 K	0,023512	0,964620	TREINAMENTO
200 K	0,020994	0,934252	TESTE
250 K	0,022733	0,966966	TREINAMENTO
250 K	0,020080	0,939779	TESTE
300 K	0,022104	0,968799	TREINAMENTO
300 K	0,019341	0,944388	TESTE
350 K	0,021574	0,970300	TREINAMENTO
350 K	0,018594	0,948751	TESTE
400 K	0,021097	0,971619	TREINAMENTO
400 K	0,018011	0,952445	TESTE
450 K	0,020617	0,972913	TREINAMENTO
450 K	0,017363	0,955890	TESTE
500 K	0,020235	0,973921	TREINAMENTO
500 K	0,016828	0,958737	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-10-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,029038	0,945505	TREINAMENTO
50 K	0,028270	0,872996	TESTE
100 K	0,026097	0,956225	TREINAMENTO
100 K	0,024179	0,910301	TESTE
150 K	0,024429	0,961750	TREINAMENTO
150 K	0,021964	0,927127	TESTE
200 K	0,023356	0,965097	TREINAMENTO
200 K	0,020729	0,935785	TESTE
250 K	0,022585	0,967402	TREINAMENTO
250 K	0,019905	0,941370	TESTE
300 K	0,022010	0,969067	TREINAMENTO
300 K	0,019272	0,945631	TESTE
350 K	0,021505	0,970492	TREINAMENTO
350 K	0,018677	0,949874	TESTE
400 K	0,021080	0,971663	TREINAMENTO
400 K	0,018024	0,953998	TESTE
450 K	0,020717	0,972646	TREINAMENTO
450 K	0,017448	0,957766	TESTE
500 K	0,020398	0,973492	TREINAMENTO
500 K	0,016955	0,961044	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-10-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,030789	0,938523	TREINAMENTO
50 K	0,030017	0,854527	TESTE
100 K	0,028221	0,948611	TREINAMENTO
100 K	0,026912	0,886712	TESTE
150 K	0,026598	0,954490	TREINAMENTO
150 K	0,024025	0,913906	TESTE
200 K	0,025676	0,957660	TREINAMENTO
200 K	0,022050	0,931082	TESTE
250 K	0,024994	0,959926	TREINAMENTO
250 K	0,020697	0,941920	TESTE
300 K	0,024389	0,961880	TREINAMENTO
300 K	0,019693	0,949227	TESTE
350 K	0,023763	0,963847	TREINAMENTO
350 K	0,018907	0,954348	TESTE
400 K	0,023089	0,965908	TREINAMENTO
400 K	0,018276	0,957574	TESTE
450 K	0,022303	0,968224	TREINAMENTO
450 K	0,017947	0,958855	TESTE
500 K	0,021543	0,970385	TREINAMENTO
500 K	0,017665	0,959577	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-12-6-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,031026	0,937539	TREINAMENTO
50 K	0,030244	0,851543	TESTE
100 K	0,028467	0,947689	TREINAMENTO
100 K	0,027020	0,886660	TESTE
150 K	0,027201	0,952352	TREINAMENTO
150 K	0,024839	0,908316	TESTE
200 K	0,026276	0,955612	TREINAMENTO
200 K	0,023168	0,923216	TESTE
250 K	0,025594	0,957933	TREINAMENTO
250 K	0,021927	0,933710	TESTE
300 K	0,024998	0,959910	TREINAMENTO
300 K	0,020891	0,941902	TESTE
350 K	0,024456	0,961664	TREINAMENTO
350 K	0,019976	0,948437	TESTE
400 K	0,023950	0,963264	TREINAMENTO
400 K	0,019106	0,953812	TESTE
450 K	0,023467	0,964760	TREINAMENTO
450 K	0,018528	0,957309	TESTE
500 K	0,022978	0,966250	TREINAMENTO
500 K	0,018126	0,959414	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-12-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,029445	0,943931	TREINAMENTO
50 K	0,028579	0,870051	TESTE
100 K	0,027225	0,952265	TREINAMENTO
100 K	0,025534	0,901611	TESTE
150 K	0,025736	0,957459	TREINAMENTO
150 K	0,023063	0,922250	TESTE
200 K	0,024338	0,962043	TREINAMENTO
200 K	0,021766	0,929163	TESTE
250 K	0,023279	0,965331	TREINAMENTO
250 K	0,020813	0,934885	TESTE
300 K	0,022429	0,967859	TREINAMENTO
300 K	0,019969	0,940305	TESTE
350 K	0,021758	0,969783	TREINAMENTO
350 K	0,019215	0,945131	TESTE
400 K	0,021202	0,971330	TREINAMENTO
400 K	0,018433	0,950087	TESTE
450 K	0,020747	0,972566	TREINAMENTO
450 K	0,017656	0,954806	TESTE
500 K	0,020386	0,973526	TREINAMENTO
500 K	0,017013	0,958703	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-14-7-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,029479	0,943802	TREINAMENTO
50 K	0,028793	0,867033	TESTE
100 K	0,027328	0,951898	TREINAMENTO
100 K	0,024921	0,907079	TESTE
150 K	0,026164	0,955996	TREINAMENTO
150 K	0,022922	0,924154	TESTE
200 K	0,025455	0,958401	TREINAMENTO
200 K	0,021663	0,933010	TESTE
250 K	0,024898	0,960243	TREINAMENTO
250 K	0,020587	0,939774	TESTE
300 K	0,024346	0,962017	TREINAMENTO
300 K	0,019835	0,944660	TESTE
350 K	0,023823	0,963663	TREINAMENTO
350 K	0,019086	0,949513	TESTE
400 K	0,023299	0,965278	TREINAMENTO
400 K	0,018206	0,954677	TESTE
450 K	0,022640	0,967244	TREINAMENTO
450 K	0,017822	0,956314	TESTE
500 K	0,021971	0,969181	TREINAMENTO
500 K	0,018078	0,955009	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-14-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,031718	0,934619	TREINAMENTO
50 K	0,030889	0,845213	TESTE
100 K	0,029799	0,942525	TREINAMENTO
100 K	0,029008	0,865931	TESTE
150 K	0,028155	0,948856	TREINAMENTO
150 K	0,026742	0,890152	TESTE
200 K	0,027067	0,952830	TREINAMENTO
200 K	0,024792	0,909242	TESTE
250 K	0,026264	0,955650	TREINAMENTO
250 K	0,023277	0,922714	TESTE
300 K	0,025572	0,958007	TREINAMENTO
300 K	0,021985	0,932987	TESTE
350 K	0,024955	0,960053	TREINAMENTO
350 K	0,020828	0,941045	TESTE
400 K	0,024404	0,961830	TREINAMENTO
400 K	0,019809	0,947462	TESTE
450 K	0,023922	0,963361	TREINAMENTO
450 K	0,018895	0,952779	TESTE
500 K	0,023455	0,964796	TREINAMENTO
500 K	0,018222	0,956698	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-10-5-2-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,033661	0,926055	TREINAMENTO
50 K	0,032280	0,831136	TESTE
100 K	0,029292	0,944522	TREINAMENTO
100 K	0,028912	0,867655	TESTE
150 K	0,027019	0,953001	TREINAMENTO
150 K	0,024780	0,908652	TESTE
200 K	0,025755	0,957391	TREINAMENTO
200 K	0,022167	0,931327	TESTE
250 K	0,024797	0,960566	TREINAMENTO
250 K	0,020297	0,945317	TESTE
300 K	0,024049	0,962954	TREINAMENTO
300 K	0,018964	0,953955	TESTE
350 K	0,023360	0,965087	TREINAMENTO
350 K	0,017872	0,960101	TESTE
400 K	0,022722	0,966999	TREINAMENTO
400 K	0,017000	0,964314	TESTE
450 K	0,022117	0,968762	TREINAMENTO
450 K	0,016182	0,967585	TESTE
500 K	0,021566	0,970326	TREINAMENTO
500 K	0,015955	0,968313	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-14-8-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,033153	0,928348	TREINAMENTO
50 K	0,032139	0,831254	TESTE
100 K	0,029834	0,942388	TREINAMENTO
100 K	0,029564	0,859506	TESTE
150 K	0,026819	0,953710	TREINAMENTO
150 K	0,024807	0,906892	TESTE
200 K	0,025151	0,959408	TREINAMENTO
200 K	0,021348	0,936043	TESTE
250 K	0,024189	0,962515	TREINAMENTO
250 K	0,019487	0,948823	TESTE
300 K	0,023419	0,964903	TREINAMENTO
300 K	0,018348	0,954962	TESTE
350 K	0,021986	0,969134	TREINAMENTO
350 K	0,018216	0,952581	TESTE
400 K	0,020786	0,972458	TREINAMENTO
400 K	0,017568	0,955364	TESTE
450 K	0,019949	0,974661	TREINAMENTO
450 K	0,016875	0,958972	TESTE
500 K	0,019247	0,976433	TREINAMENTO
500 K	0,016287	0,962051	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-14-10-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,032200	0,932561	TREINAMENTO
50 K	0,031378	0,840929	TESTE
100 K	0,029372	0,944213	TREINAMENTO
100 K	0,028394	0,872168	TESTE
150 K	0,027232	0,952246	TREINAMENTO
150 K	0,024693	0,907696	TESTE
200 K	0,025948	0,956738	TREINAMENTO
200 K	0,022501	0,926639	TESTE
250 K	0,024951	0,960066	TREINAMENTO
250 K	0,020806	0,940143	TESTE
300 K	0,024106	0,962777	TREINAMENTO
300 K	0,019250	0,951317	TESTE
350 K	0,023380	0,965025	TREINAMENTO
350 K	0,017937	0,959578	TESTE
400 K	0,022739	0,966950	TREINAMENTO
400 K	0,016921	0,964942	TESTE
450 K	0,022136	0,968705	TREINAMENTO
450 K	0,016154	0,968333	TESTE
500 K	0,021586	0,970267	TREINAMENTO
500 K	0,015708	0,969979	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-14-10-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,031558	0,935296	TREINAMENTO
50 K	0,030672	0,847232	TESTE
100 K	0,029737	0,942769	TREINAMENTO
100 K	0,028394	0,872972	TESTE
150 K	0,028097	0,949075	TREINAMENTO
150 K	0,025956	0,898726	TESTE
200 K	0,026913	0,953381	TREINAMENTO
200 K	0,023811	0,920138	TESTE
250 K	0,025954	0,956717	TREINAMENTO
250 K	0,022055	0,936027	TESTE
300 K	0,025156	0,959395	TREINAMENTO
300 K	0,020641	0,946999	TESTE
350 K	0,024383	0,961910	TREINAMENTO
350 K	0,019583	0,954257	TESTE
400 K	0,023680	0,964106	TREINAMENTO
400 K	0,018479	0,959123	TESTE
450 K	0,022968	0,966271	TREINAMENTO
450 K	0,017652	0,962071	TESTE
500 K	0,022273	0,968315	TREINAMENTO
500 K	0,017012	0,963857	TESTE

CONFIGURAÇÃO C1			
ARQUITETURA A: 8-14-10-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	FASE
50 K	0,031368	0,936109	TREINAMENTO
50 K	0,031168	0,843084	TESTE
100 K	0,027908	0,949784	TREINAMENTO
100 K	0,026696	0,889593	TESTE
150 K	0,025940	0,956765	TREINAMENTO
150 K	0,022508	0,926715	TESTE
200 K	0,024800	0,960560	TREINAMENTO
200 K	0,020292	0,943272	TESTE
250 K	0,023971	0,963201	TREINAMENTO
250 K	0,018896	0,952151	TESTE
300 K	0,023273	0,965351	TREINAMENTO
300 K	0,017897	0,957745	TESTE
350 K	0,022516	0,967606	TREINAMENTO
350 K	0,017290	0,960338	TESTE
400 K	0,020936	0,972062	TREINAMENTO
400 K	0,017239	0,957664	TESTE
450 K	0,020021	0,974475	TREINAMENTO
450 K	0,016786	0,960542	TESTE
500 K	0,019258	0,976410	TREINAMENTO
500 K	0,016138	0,963843	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-6-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,031626	0,936072	TREINAMENTO
50 K	0,037349	0,763229	TESTE
100 K	0,031100	0,938226	TREINAMENTO
100 K	0,035738	0,774994	TESTE
150 K	0,030838	0,939296	TREINAMENTO
150 K	0,035002	0,781259	TESTE
200 K	0,030560	0,940417	TREINAMENTO
200 K	0,034215	0,789188	TESTE
250 K	0,030294	0,941481	TREINAMENTO
250 K	0,033539	0,795906	TESTE
300 K	0,030056	0,942426	TREINAMENTO
300 K	0,329970	0,801761	TESTE
350 K	0,029831	0,943313	TREINAMENTO
350 K	0,032347	0,807800	TESTE
400 K	0,029602	0,944207	TREINAMENTO
400 K	0,031750	0,814115	TESTE
450 K	0,029363	0,945131	TREINAMENTO
450 K	0,031089	0,820897	TESTE
500 K	0,029102	0,946130	TREINAMENTO
500 K	0,030512	0,827739	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,031996	0,934528	TREINAMENTO
50 K	0,037783	0,759314	TESTE
100 K	0,031336	0,937255	TREINAMENTO
100 K	0,036099	0,773285	TESTE
150 K	0,031079	0,938316	TREINAMENTO
150 K	0,035515	0,778709	TESTE
200 K	0,030824	0,939352	TREINAMENTO
200 K	0,034792	0,785298	TESTE
250 K	0,030571	0,940381	TREINAMENTO
250 K	0,034062	0,792836	TESTE
300 K	0,030307	0,941433	TREINAMENTO
300 K	0,033296	0,800163	TESTE
350 K	0,029984	0,942712	TREINAMENTO
350 K	0,032625	0,807912	TESTE
400 K	0,029687	0,943872	TREINAMENTO
400 K	0,031912	0,815609	TESTE
450 K	0,029412	0,944939	TREINAMENTO
450 K	0,031208	0,822631	TESTE
500 K	0,029093	0,946158	TREINAMENTO
500 K	0,030454	0,830685	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,031675	0,935871	TREINAMENTO
50 K	0,037316	0,764333	TESTE
100 K	0,031131	0,938099	TREINAMENTO
100 K	0,035873	0,773843	TESTE
150 K	0,030830	0,939326	TREINAMENTO
150 K	0,035155	0,780355	TESTE
200 K	0,030548	0,940469	TREINAMENTO
200 K	0,034569	0,787235	TESTE
250 K	0,030291	0,941494	TREINAMENTO
250 K	0,033722	0,794194	TESTE
300 K	0,030062	0,942438	TREINAMENTO
300 K	0,033066	0,800326	TESTE
350 K	0,029764	0,943573	TREINAMENTO
350 K	0,032653	0,807107	TESTE
400 K	0,029443	0,944821	TREINAMENTO
400 K	0,032011	0,814721	TESTE
450 K	0,029129	0,946026	TREINAMENTO
450 K	0,031189	0,822927	TESTE
500 K	0,028877	0,946984	TREINAMENTO
500 K	0,030454	0,830445	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-4-2-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,031411	0,937159	TREINAMENTO
50 K	0,036174	0,770335	TESTE
100 K	0,029149	0,945948	TREINAMENTO
100 K	0,028964	0,842791	TESTE
150 K	0,027481	0,952109	TREINAMENTO
150 K	0,025384	0,878554	TESTE
200 K	0,026350	0,956058	TREINAMENTO
200 K	0,024090	0,891863	TESTE
250 K	0,025503	0,958900	TREINAMENTO
250 K	0,023792	0,896427	TESTE
300 K	0,024838	0,961058	TREINAMENTO
300 K	0,023900	0,897787	TESTE
350 K	0,024287	0,962799	TREINAMENTO
350 K	0,024069	0,897989	TESTE
400 K	0,023782	0,964359	TREINAMENTO
400 K	0,024297	0,897927	TESTE
450 K	0,023345	0,965682	TREINAMENTO
450 K	0,024450	0,898107	TESTE
500 K	0,022965	0,966808	TREINAMENTO
500 K	0,024505	0,899173	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-6-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,030585	0,940320	TREINAMENTO
50 K	0,034056	0,793818	TESTE
100 K	0,028557	0,948180	TREINAMENTO
100 K	0,027505	0,858129	TESTE
150 K	0,026861	0,954298	TREINAMENTO
150 K	0,024636	0,883002	TESTE
200 K	0,025422	0,959166	TREINAMENTO
200 K	0,024743	0,887185	TESTE
250 K	0,024277	0,962829	TREINAMENTO
250 K	0,025254	0,886815	TESTE
300 K	0,023503	0,965203	TREINAMENTO
300 K	0,026037	0,885231	TESTE
350 K	0,022935	0,966894	TREINAMENTO
350 K	0,026661	0,883924	TESTE
400 K	0,022455	0,968301	TREINAMENTO
400 K	0,026975	0,883214	TESTE
450 K	0,021646	0,970565	TREINAMENTO
450 K	0,026986	0,888487	TESTE
500 K	0,020955	0,972452	TREINAMENTO
500 K	0,026612	0,893261	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-6-6-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,030397	0,941076	TREINAMENTO
50 K	0,033253	0,802856	TESTE
100 K	0,027176	0,953193	TREINAMENTO
100 K	0,025079	0,884299	TESTE
150 K	0,025354	0,959387	TREINAMENTO
150 K	0,024399	0,895817	TESTE
200 K	0,024022	0,963619	TREINAMENTO
200 K	0,025059	0,894574	TESTE
250 K	0,022064	0,969401	TREINAMENTO
250 K	0,024239	0,900706	TESTE
300 K	0,021149	0,971921	TREINAMENTO
300 K	0,024771	0,898418	TESTE
350 K	0,020548	0,973513	TREINAMENTO
350 K	0,025086	0,896928	TESTE
400 K	0,020047	0,974808	TREINAMENTO
400 K	0,025221	0,896556	TESTE
450 K	0,019633	0,975851	TREINAMENTO
450 K	0,025321	0,897239	TESTE
500 K	0,019298	0,976679	TREINAMENTO
500 K	0,025202	0,898437	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-8-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,030833	0,939329	TREINAMENTO
50 K	0,034598	0,789569	TESTE
100 K	0,028360	0,948924	TREINAMENTO
100 K	0,027211	0,864644	TESTE
150 K	0,026301	0,956229	TREINAMENTO
150 K	0,024546	0,887405	TESTE
200 K	0,024985	0,960585	TREINAMENTO
200 K	0,024791	0,886980	TESTE
250 K	0,024074	0,963461	TREINAMENTO
250 K	0,025361	0,885206	TESTE
300 K	0,023375	0,965589	TREINAMENTO
300 K	0,025847	0,884419	TESTE
350 K	0,022753	0,967426	TREINAMENTO
350 K	0,026242	0,884615	TESTE
400 K	0,022254	0,968862	TREINAMENTO
400 K	0,026432	0,885398	TESTE
450 K	0,021827	0,970063	TREINAMENTO
450 K	0,026555	0,886961	TESTE
500 K	0,021465	0,971064	TREINAMENTO
500 K	0,026541	0,888960	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-8-12-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,030860	0,939207	TREINAMENTO
50 K	0,034626	0,786763	TESTE
100 K	0,028108	0,949838	TREINAMENTO
100 K	0,026495	0,870065	TESTE
150 K	0,026061	0,957039	TREINAMENTO
150 K	0,024442	0,892946	TESTE
200 K	0,024525	0,962051	TREINAMENTO
200 K	0,024527	0,895274	TESTE
250 K	0,023376	0,965584	TREINAMENTO
250 K	0,025281	0,893446	TESTE
300 K	0,022577	0,967936	TREINAMENTO
300 K	0,025934	0,890276	TESTE
350 K	0,021968	0,969676	TREINAMENTO
350 K	0,026425	0,888257	TESTE
400 K	0,021405	0,971228	TREINAMENTO
400 K	0,026408	0,888038	TESTE
450 K	0,019872	0,975250	TREINAMENTO
450 K	0,024230	0,904748	TESTE
500 K	0,019333	0,976592	TREINAMENTO
500 K	0,024697	0,902175	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-10-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,030528	0,940553	TREINAMENTO
50 K	0,033750	0,797324	TESTE
100 K	0,028565	0,948198	TREINAMENTO
100 K	0,026881	0,863375	TESTE
150 K	0,026722	0,954779	TREINAMENTO
150 K	0,024562	0,886846	TESTE
200 K	0,025502	0,958899	TREINAMENTO
200 K	0,024555	0,888239	TESTE
250 K	0,024570	0,961909	TREINAMENTO
250 K	0,024903	0,887044	TESTE
300 K	0,023827	0,964220	TREINAMENTO
300 K	0,025350	0,885935	TESTE
350 K	0,023174	0,966189	TREINAMENTO
350 K	0,025742	0,885376	TESTE
400 K	0,022539	0,968045	TREINAMENTO
400 K	0,026120	0,885635	TESTE
450 K	0,021876	0,969927	TREINAMENTO
450 K	0,026361	0,886543	TESTE
500 K	0,021126	0,971983	TREINAMENTO
500 K	0,026385	0,888549	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-10-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,030933	0,938910	TREINAMENTO
50 K	0,035254	0,779362	TESTE
100 K	0,029077	0,946222	TREINAMENTO
100 K	0,029181	0,842881	TESTE
150 K	0,026875	0,954247	TREINAMENTO
150 K	0,025256	0,878458	TESTE
200 K	0,025037	0,960428	TREINAMENTO
200 K	0,024387	0,889741	TESTE
250 K	0,023270	0,965901	TREINAMENTO
250 K	0,024337	0,895985	TESTE
300 K	0,022101	0,969294	TREINAMENTO
300 K	0,024725	0,896819	TESTE
350 K	0,021266	0,971606	TREINAMENTO
350 K	0,025082	0,896643	TESTE
400 K	0,020646	0,973259	TREINAMENTO
400 K	0,025324	0,896724	TESTE
450 K	0,020150	0,974545	TREINAMENTO
450 K	0,025420	0,897401	TESTE
500 K	0,019771	0,975508	TREINAMENTO
500 K	0,025425	0,898449	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-10-12-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,032055	0,934239	TREINAMENTO
50 K	0,037931	0,744744	TESTE
100 K	0,031029	0,938518	TREINAMENTO
100 K	0,035486	0,775477	TESTE
150 K	0,029765	0,943569	TREINAMENTO
150 K	0,031154	0,822393	TESTE
200 K	0,027623	0,951597	TREINAMENTO
200 K	0,026316	0,871760	TESTE
250 K	0,025584	0,958631	TREINAMENTO
250 K	0,025083	0,893699	TESTE
300 K	0,024489	0,962166	TREINAMENTO
300 K	0,025483	0,892654	TESTE
350 K	0,023745	0,964473	TREINAMENTO
350 K	0,026255	0,887930	TESTE
400 K	0,023113	0,966370	TREINAMENTO
400 K	0,026872	0,882571	TESTE
450 K	0,022557	0,967995	TREINAMENTO
450 K	0,027357	0,878116	TESTE
500 K	0,021964	0,969682	TREINAMENTO
500 K	0,027694	0,875188	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-12-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,030885	0,939105	TREINAMENTO
50 K	0,035251	0,779555	TESTE
100 K	0,029127	0,946031	TREINAMENTO
100 K	0,029795	0,836442	TESTE
150 K	0,026975	0,953896	TREINAMENTO
150 K	0,024937	0,882357	TESTE
200 K	0,024717	0,961440	TREINAMENTO
200 K	0,023142	0,899658	TESTE
250 K	0,023301	0,965808	TREINAMENTO
250 K	0,023323	0,901774	TESTE
300 K	0,022380	0,968502	TREINAMENTO
300 K	0,023775	0,901291	TESTE
350 K	0,021663	0,970519	TREINAMENTO
350 K	0,024238	0,900372	TESTE
400 K	0,021087	0,972087	TREINAMENTO
400 K	0,024618	0,899592	TESTE
450 K	0,020610	0,973354	TREINAMENTO
450 K	0,024893	0,899183	TESTE
500 K	0,020225	0,974352	TREINAMENTO
500 K	0,025059	0,899186	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-14-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,030073	0,942364	TREINAMENTO
50 K	0,032438	0,811442	TESTE
100 K	0,027438	0,952262	TREINAMENTO
100 K	0,025443	0,878725	TESTE
150 K	0,025731	0,958143	TREINAMENTO
150 K	0,024218	0,894609	TESTE
200 K	0,024588	0,961853	TREINAMENTO
200 K	0,024589	0,896627	TESTE
250 K	0,023700	0,964607	TREINAMENTO
250 K	0,025131	0,895763	TESTE
300 K	0,022882	0,967049	TREINAMENTO
300 K	0,025763	0,893446	TESTE
350 K	0,022147	0,969164	TREINAMENTO
350 K	0,026188	0,891017	TESTE
400 K	0,021515	0,970926	TREINAMENTO
400 K	0,026445	0,890027	TESTE
450 K	0,021077	0,972118	TREINAMENTO
450 K	0,026564	0,890045	TESTE
500 K	0,020736	0,973032	TREINAMENTO
500 K	0,026383	0,890043	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-10-5-2-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,033600	0,927518	TREINAMENTO
50 K	0,036913	0,769920	TESTE
100 K	0,031717	0,935685	TREINAMENTO
100 K	0,031912	0,828627	TESTE
150 K	0,029673	0,943944	TREINAMENTO
150 K	0,026971	0,871514	TESTE
200 K	0,028368	0,948888	TREINAMENTO
200 K	0,025311	0,886941	TESTE
250 K	0,027443	0,952249	TREINAMENTO
250 K	0,024416	0,894372	TESTE
300 K	0,026711	0,954817	TREINAMENTO
300 K	0,023702	0,899866	TESTE
350 K	0,026062	0,957034	TREINAMENTO
350 K	0,023042	0,905031	TESTE
400 K	0,025481	0,958974	TREINAMENTO
400 K	0,022594	0,909713	TESTE
450 K	0,025000	0,960536	TREINAMENTO
450 K	0,022114	0,913622	TESTE
500 K	0,024594	0,961832	TREINAMENTO
500 K	0,021660	0,917125	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-10-8-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,032665	0,931652	TREINAMENTO
50 K	0,037820	0,758166	TESTE
100 K	0,030378	0,941154	TREINAMENTO
100 K	0,032796	0,806503	TESTE
150 K	0,027936	0,950467	TREINAMENTO
150 K	0,026470	0,867434	TESTE
200 K	0,026129	0,956808	TREINAMENTO
200 K	0,024308	0,888255	TESTE
250 K	0,024950	0,960697	TREINAMENTO
250 K	0,024127	0,892821	TESTE
300 K	0,024055	0,963517	TREINAMENTO
300 K	0,024172	0,894918	TESTE
350 K	0,023301	0,965810	TREINAMENTO
350 K	0,024293	0,896798	TESTE
400 K	0,022662	0,967690	TREINAMENTO
400 K	0,024322	0,899076	TESTE
450 K	0,022127	0,969221	TREINAMENTO
450 K	0,024227	0,901827	TESTE
500 K	0,021699	0,970419	TREINAMENTO
500 K	0,024079	0,904927	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-12-10-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,031262	0,937577	TREINAMENTO
50 K	0,034872	0,776718	TESTE
100 K	0,027050	0,953634	TREINAMENTO
100 K	0,024833	0,883109	TESTE
150 K	0,024873	0,960942	TREINAMENTO
150 K	0,024425	0,894522	TESTE
200 K	0,023768	0,964401	TREINAMENTO
200 K	0,025057	0,895707	TESTE
250 K	0,022958	0,966825	TREINAMENTO
250 K	0,025239	0,896537	TESTE
300 K	0,022254	0,968861	TREINAMENTO
300 K	0,025313	0,898423	TESTE
350 K	0,021673	0,970491	TREINAMENTO
350 K	0,025054	0,901038	TESTE
400 K	0,021157	0,971900	TREINAMENTO
400 K	0,024614	0,904657	TESTE
450 K	0,020543	0,973528	TREINAMENTO
450 K	0,023722	0,910991	TESTE
500 K	0,019658	0,975799	TREINAMENTO
500 K	0,022258	0,922440	TESTE

CONFIGURAÇÃO C2			
ARQUITETURA A: 6-14-10-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,031755	0,935526	TREINAMENTO
50 K	0,036855	0,761545	TESTE
100 K	0,028409	0,948729	TREINAMENTO
100 K	0,027621	0,857932	TESTE
150 K	0,026166	0,956685	TREINAMENTO
150 K	0,024231	0,893988	TESTE
200 K	0,024845	0,961033	TREINAMENTO
200 K	0,023876	0,900951	TESTE
250 K	0,023929	0,963907	TREINAMENTO
250 K	0,023900	0,903225	TESTE
300 K	0,023181	0,966165	TREINAMENTO
300 K	0,023911	0,904634	TESTE
350 K	0,022575	0,967942	TREINAMENTO
350 K	0,023834	0,906067	TESTE
400 K	0,022005	0,969565	TREINAMENTO
400 K	0,023572	0,908008	TESTE
450 K	0,021531	0,970883	TREINAMENTO
450 K	0,023323	0,910550	TESTE
500 K	0,021131	0,971974	TREINAMENTO
500 K	0,023017	0,913435	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-6-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,044591	0,751326	TREINAMENTO
50 K	0,085578	0,417802	TESTE
100 K	0,044207	0,756124	TREINAMENTO
100 K	0,078659	0,515953	TESTE
150 K	0,043813	0,761140	TREINAMENTO
150 K	0,073620	0,589820	TESTE
200 K	0,043288	0,767709	TREINAMENTO
200 K	0,066015	0,690973	TESTE
250 K	0,042633	0,775721	TREINAMENTO
250 K	0,056388	0,791578	TESTE
300 K	0,041974	0,783580	TREINAMENTO
300 K	0,047785	0,855833	TESTE
350 K	0,041234	0,792216	TREINAMENTO
350 K	0,040828	0,894104	TESTE
400 K	0,040421	0,801443	TREINAMENTO
400 K	0,037482	0,913796	TESTE
450 K	0,039573	0,810810	TREINAMENTO
450 K	0,039127	0,921625	TESTE
500 K	0,038711	0,820037	TREINAMENTO
500 K	0,044211	0,923471	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,044622	0,750763	TREINAMENTO
50 K	0,085179	0,413476	TESTE
100 K	0,044402	0,753620	TREINAMENTO
100 K	0,082025	0,465330	TESTE
150 K	0,044199	0,757219	TREINAMENTO
150 K	0,078363	0,524177	TESTE
200 K	0,043791	0,761416	TREINAMENTO
200 K	0,072370	0,605135	TESTE
250 K	0,043391	0,766415	TREINAMENTO
250 K	0,065591	0,696657	TESTE
300 K	0,042828	0,773348	TREINAMENTO
300 K	0,062046	0,741802	TESTE
350 K	0,042296	0,779747	TREINAMENTO
350 K	0,058387	0,781967	TESTE
400 K	0,041757	0,786101	TREINAMENTO
400 K	0,053917	0,820771	TESTE
450 K	0,041146	0,793173	TREINAMENTO
450 K	0,051622	0,836942	TESTE
500 K	0,040481	0,800711	TREINAMENTO
500 K	0,053186	0,824323	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,044602	0,751024	TREINAMENTO
50 K	0,085213	0,421236	TESTE
100 K	0,044309	0,754821	TREINAMENTO
100 K	0,081159	0,482727	TESTE
150 K	0,043980	0,759025	TREINAMENTO
150 K	0,077207	0,539403	TESTE
200 K	0,043529	0,764764	TREINAMENTO
200 K	0,077388	0,536731	TESTE
250 K	0,042945	0,771929	TREINAMENTO
250 K	0,076658	0,541316	TESTE
300 K	0,042378	0,778785	TREINAMENTO
300 K	0,074571	0,571612	TESTE
350 K	0,041776	0,785920	TREINAMENTO
350 K	0,070442	0,632321	TESTE
400 K	0,041102	0,793732	TREINAMENTO
400 K	0,066439	0,685862	TESTE
450 K	0,040368	0,802041	TREINAMENTO
450 K	0,065606	0,696777	TESTE
500 K	0,039581	0,810731	TREINAMENTO
500 K	0,068961	0,656880	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-4-2-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,042125	0,781744	TREINAMENTO
50 K	0,038120	0,906719	TESTE
100 K	0,038617	0,820626	TREINAMENTO
100 K	0,046303	0,906409	TESTE
150 K	0,034831	0,857834	TREINAMENTO
150 K	0,047405	0,859164	TESTE
200 K	0,033185	0,871913	TREINAMENTO
200 K	0,051976	0,831359	TESTE
250 K	0,032131	0,880630	TREINAMENTO
250 K	0,055754	0,818598	TESTE
300 K	0,031344	0,886692	TREINAMENTO
300 K	0,060201	0,812345	TESTE
350 K	0,030705	0,891488	TREINAMENTO
350 K	0,065238	0,809519	TESTE
400 K	0,030266	0,894552	TREINAMENTO
400 K	0,069332	0,808687	TESTE
450 K	0,029961	0,896802	TREINAMENTO
450 K	0,072479	0,808951	TESTE
500 K	0,029732	0,898300	TREINAMENTO
500 K	0,074793	0,809516	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-6-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,043790	0,761428	TREINAMENTO
50 K	0,077454	0,529961	TESTE
100 K	0,040556	0,799736	TREINAMENTO
100 K	0,066164	0,908127	TESTE
150 K	0,037349	0,833498	TREINAMENTO
150 K	0,069371	0,885239	TESTE
200 K	0,035263	0,853477	TREINAMENTO
200 K	0,073863	0,869030	TESTE
250 K	0,033779	0,866883	TREINAMENTO
250 K	0,075741	0,859293	TESTE
300 K	0,032613	0,876545	TREINAMENTO
300 K	0,077155	0,850246	TESTE
350 K	0,031684	0,883964	TREINAMENTO
350 K	0,078390	0,842053	TESTE
400 K	0,030956	0,889604	TREINAMENTO
400 K	0,079492	0,834783	TESTE
450 K	0,030428	0,893354	TREINAMENTO
450 K	0,080420	0,828783	TESTE
500 K	0,030064	0,895861	TREINAMENTO
500 K	0,081132	0,824236	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-6-6-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,043967	0,760513	TREINAMENTO
50 K	0,075940	0,548981	TESTE
100 K	0,042323	0,779395	TREINAMENTO
100 K	0,049388	0,922265	TESTE
150 K	0,040062	0,805230	TREINAMENTO
150 K	0,067867	0,895517	TESTE
200 K	0,036818	0,839104	TREINAMENTO
200 K	0,071972	0,874775	TESTE
250 K	0,034803	0,858052	TREINAMENTO
250 K	0,075041	0,862561	TESTE
300 K	0,033413	0,870171	TREINAMENTO
300 K	0,076385	0,855309	TESTE
350 K	0,032359	0,878793	TREINAMENTO
350 K	0,077138	0,850628	TESTE
400 K	0,031504	0,885449	TREINAMENTO
400 K	0,077604	0,847544	TESTE
450 K	0,030860	0,890267	TREINAMENTO
450 K	0,077850	0,845833	TESTE
500 K	0,030388	0,893628	TREINAMENTO
500 K	0,077964	0,845002	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-8-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,042713	0,774720	TREINAMENTO
50 K	0,037311	0,911359	TESTE
100 K	0,039875	0,807399	TREINAMENTO
100 K	0,037992	0,922909	TESTE
150 K	0,038003	0,827231	TREINAMENTO
150 K	0,039974	0,916944	TESTE
200 K	0,036628	0,841484	TREINAMENTO
200 K	0,043183	0,910426	TESTE
250 K	0,035415	0,852434	TREINAMENTO
250 K	0,045915	0,907298	TESTE
300 K	0,034352	0,862027	TREINAMENTO
300 K	0,049582	0,904045	TESTE
350 K	0,033394	0,870283	TREINAMENTO
350 K	0,053619	0,901195	TESTE
400 K	0,032517	0,877430	TREINAMENTO
400 K	0,057653	0,898670	TESTE
450 K	0,031724	0,883646	TREINAMENTO
450 K	0,061198	0,896888	TESTE
500 K	0,031107	0,888453	TREINAMENTO
500 K	0,063639	0,896223	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-8-12-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,045664	0,736909	TREINAMENTO
50 K	0,084364	0,421093	TESTE
100 K	0,044760	0,748964	TREINAMENTO
100 K	0,084406	0,422582	TESTE
150 K	0,044265	0,755382	TREINAMENTO
150 K	0,081582	0,463914	TESTE
200 K	0,044010	0,758641	TREINAMENTO
200 K	0,077821	0,523287	TESTE
250 K	0,043752	0,761905	TREINAMENTO
250 K	0,073970	0,582642	TESTE
300 K	0,043374	0,766628	TREINAMENTO
300 K	0,065026	0,703521	TESTE
350 K	0,042721	0,774617	TREINAMENTO
350 K	0,042157	0,885810	TESTE
400 K	0,041786	0,785720	TREINAMENTO
400 K	0,056743	0,916018	TESTE
450 K	0,040620	0,799020	TREINAMENTO
450 K	0,066000	0,913695	TESTE
500 K	0,037890	0,828290	TREINAMENTO
500 K	0,058808	0,913676	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-10-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,044639	0,750548	TREINAMENTO
50 K	0,084522	0,414337	TESTE
100 K	0,043966	0,759195	TREINAMENTO
100 K	0,081299	0,464595	TESTE
150 K	0,042659	0,775374	TREINAMENTO
150 K	0,036629	0,923827	TESTE
200 K	0,041162	0,792902	TREINAMENTO
200 K	0,069950	0,907820	TESTE
250 K	0,037619	0,831018	TREINAMENTO
250 K	0,071885	0,893883	TESTE
300 K	0,034695	0,858944	TREINAMENTO
300 K	0,073178	0,881101	TESTE
350 K	0,032973	0,873761	TREINAMENTO
350 K	0,074068	0,873392	TESTE
400 K	0,031706	0,883911	TREINAMENTO
400 K	0,075079	0,865152	TESTE
450 K	0,030851	0,890343	TREINAMENTO
450 K	0,075937	0,858503	TESTE
500 K	0,030284	0,894380	TREINAMENTO
500 K	0,076705	0,852881	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-10-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,044487	0,752716	TREINAMENTO
50 K	0,084453	0,420618	TESTE
100 K	0,043996	0,758817	TREINAMENTO
100 K	0,083232	0,433742	TESTE
150 K	0,042968	0,771619	TREINAMENTO
150 K	0,062079	0,748483	TESTE
200 K	0,041372	0,790522	TREINAMENTO
200 K	0,056226	0,902215	TESTE
250 K	0,039511	0,812208	TREINAMENTO
250 K	0,070977	0,851756	TESTE
300 K	0,037934	0,827906	TREINAMENTO
300 K	0,081210	0,803674	TESTE
350 K	0,036716	0,840055	TREINAMENTO
350 K	0,088096	0,768425	TESTE
400 K	0,035611	0,850585	TREINAMENTO
400 K	0,093161	0,741422	TESTE
450 K	0,034639	0,859199	TREINAMENTO
450 K	0,096852	0,721687	TESTE
500 K	0,033779	0,866977	TREINAMENTO
500 K	0,099399	0,707841	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-10-12-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,044364	0,754109	TREINAMENTO
50 K	0,082009	0,461849	TESTE
100 K	0,043428	0,765949	TREINAMENTO
100 K	0,049495	0,842757	TESTE
150 K	0,041914	0,784217	TREINAMENTO
150 K	0,064110	0,912533	TESTE
200 K	0,039841	0,807603	TREINAMENTO
200 K	0,065032	0,893602	TESTE
250 K	0,037089	0,836459	TREINAMENTO
250 K	0,070481	0,854495	TESTE
300 K	0,035442	0,852038	TREINAMENTO
300 K	0,077645	0,824895	TESTE
350 K	0,034154	0,863696	TREINAMENTO
350 K	0,082748	0,801122	TESTE
400 K	0,033054	0,873081	TREINAMENTO
400 K	0,086928	0,780344	TESTE
450 K	0,032095	0,880836	TREINAMENTO
450 K	0,090527	0,761655	TESTE
500 K	0,031354	0,886454	TREINAMENTO
500 K	0,093308	0,746906	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-12-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,043916	0,759839	TREINAMENTO
50 K	0,074871	0,569101	TESTE
100 K	0,042550	0,776683	TREINAMENTO
100 K	0,039122	0,924232	TESTE
150 K	0,040696	0,798212	TREINAMENTO
150 K	0,043258	0,897195	TESTE
200 K	0,039173	0,814932	TREINAMENTO
200 K	0,056244	0,840606	TESTE
250 K	0,038058	0,826594	TREINAMENTO
250 K	0,068054	0,736964	TESTE
300 K	0,037096	0,836277	TREINAMENTO
300 K	0,074593	0,637421	TESTE
350 K	0,036213	0,844846	TREINAMENTO
350 K	0,078778	0,560454	TESTE
400 K	0,035295	0,853428	TREINAMENTO
400 K	0,081715	0,505526	TESTE
450 K	0,034483	0,860742	TREINAMENTO
450 K	0,083329	0,479206	TESTE
500 K	0,033743	0,867130	TREINAMENTO
500 K	0,084076	0,472140	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-14-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,043526	0,764735	TREINAMENTO
50 K	0,066341	0,684389	TESTE
100 K	0,041676	0,786994	TREINAMENTO
100 K	0,062642	0,911230	TESTE
150 K	0,039551	0,810815	TREINAMENTO
150 K	0,058057	0,884960	TESTE
200 K	0,037705	0,830173	TREINAMENTO
200 K	0,065489	0,847565	TESTE
250 K	0,036259	0,844390	TREINAMENTO
250 K	0,072084	0,817347	TESTE
300 K	0,035035	0,855789	TREINAMENTO
300 K	0,076616	0,789724	TESTE
350 K	0,033936	0,865525	TREINAMENTO
350 K	0,080250	0,761981	TESTE
400 K	0,032940	0,873927	TREINAMENTO
400 K	0,083334	0,734656	TESTE
450 K	0,032183	0,880034	TREINAMENTO
450 K	0,085558	0,712906	TESTE
500 K	0,031581	0,884645	TREINAMENTO
500 K	0,087185	0,695312	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-10-5-2-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,041479	0,789279	TREINAMENTO
50 K	0,050633	0,921922	TESTE
100 K	0,039175	0,814678	TREINAMENTO
100 K	0,061548	0,917316	TESTE
150 K	0,037398	0,832787	TREINAMENTO
150 K	0,065713	0,914754	TESTE
200 K	0,035963	0,846541	TREINAMENTO
200 K	0,067359	0,913316	TESTE
250 K	0,034736	0,857707	TREINAMENTO
250 K	0,068186	0,912376	TESTE
300 K	0,033580	0,867759	TREINAMENTO
300 K	0,068679	0,911714	TESTE
350 K	0,032507	0,876685	TREINAMENTO
350 K	0,068975	0,911288	TESTE
400 K	0,031525	0,884530	TREINAMENTO
400 K	0,069207	0,910962	TESTE
450 K	0,030585	0,891839	TREINAMENTO
450 K	0,069561	0,910533	TESTE
500 K	0,029684	0,898421	TREINAMENTO
500 K	0,070163	0,909990	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-10-8-4-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,041694	0,786790	TREINAMENTO
50 K	0,042757	0,923508	TESTE
100 K	0,038657	0,820176	TREINAMENTO
100 K	0,065207	0,917252	TESTE
150 K	0,035659	0,849689	TREINAMENTO
150 K	0,051706	0,838482	TESTE
200 K	0,033288	0,870769	TREINAMENTO
200 K	0,081632	0,475702	TESTE
250 K	0,031608	0,884414	TREINAMENTO
250 K	0,083850	0,433314	TESTE
300 K	0,030540	0,892417	TREINAMENTO
300 K	0,083322	0,440062	TESTE
350 K	0,029882	0,897338	TREINAMENTO
350 K	0,082497	0,453198	TESTE
400 K	0,029443	0,900387	TREINAMENTO
400 K	0,081670	0,467026	TESTE
450 K	0,029653	0,898988	TREINAMENTO
450 K	0,080780	0,482232	TESTE
500 K	0,029889	0,898197	TREINAMENTO
500 K	0,079746	0,499980	TESTE





CONFIGURAÇÃO C3			
ARQUITETURA A: 6-12-10-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,043030	0,770861	TREINAMENTO
50 K	0,037163	0,920614	TESTE
100 K	0,039891	0,807023	TREINAMENTO
100 K	0,062700	0,918302	TESTE
150 K	0,037602	0,830800	TREINAMENTO
150 K	0,067491	0,914656	TESTE
200 K	0,035511	0,850810	TREINAMENTO
200 K	0,069187	0,911388	TESTE
250 K	0,033499	0,868864	TREINAMENTO
250 K	0,070232	0,908163	TESTE
300 K	0,031746	0,883032	TREINAMENTO
300 K	0,070823	0,905853	TESTE
350 K	0,030450	0,893026	TREINAMENTO
350 K	0,071137	0,903877	TESTE
400 K	0,029583	0,899273	TREINAMENTO
400 K	0,071260	0,902482	TESTE
450 K	0,029052	0,903187	TREINAMENTO
450 K	0,071274	0,901857	TESTE
500 K	0,029478	0,900688	TREINAMENTO
500 K	0,071258	0,901756	TESTE





CONFIGURAÇÃO C3			
ARQUITETURA A: 6-14-10-8-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,042472	0,777619	TREINAMENTO
50 K	0,046473	0,924745	TESTE
100 K	0,039894	0,806997	TREINAMENTO
100 K	0,060137	0,918399	TESTE
150 K	0,037666	0,830180	TREINAMENTO
150 K	0,063960	0,914461	TESTE
200 K	0,035569	0,850339	TREINAMENTO
200 K	0,066602	0,910697	TESTE
250 K	0,033687	0,867108	TREINAMENTO
250 K	0,068826	0,907766	TESTE
300 K	0,032133	0,879879	TREINAMENTO
300 K	0,070219	0,906162	TESTE
350 K	0,030925	0,889383	TREINAMENTO
350 K	0,070930	0,905161	TESTE
400 K	0,030047	0,895925	TREINAMENTO
400 K	0,071177	0,904754	TESTE
450 K	0,029476	0,900097	TREINAMENTO
450 K	0,071227	0,904918	TESTE
500 K	0,029108	0,903062	TREINAMENTO
500 K	0,071243	0,905166	TESTE

CONFIGURAÇÃO C3			
ARQUITETURA A: 6-14-10-10-1			
ITERAÇÃO	RMS	CORRELAÇÃO	
50 K	0,044173	0,756566	TREINAMENTO
50 K	0,081050	0,476653	TESTE
100 K	0,043455	0,765624	TREINAMENTO
100 K	0,073110	0,599399	TESTE
150 K	0,042175	0,781156	TREINAMENTO
150 K	0,058670	0,766830	TESTE
200 K	0,040251	0,803133	TREINAMENTO
200 K	0,045852	0,865781	TESTE
250 K	0,038022	0,826731	TREINAMENTO
250 K	0,040153	0,910342	TESTE
300 K	0,035636	0,849963	TREINAMENTO
300 K	0,037485	0,920241	TESTE
350 K	0,033236	0,871246	TREINAMENTO
350 K	0,037168	0,920194	TESTE
400 K	0,031459	0,885544	TREINAMENTO
400 K	0,043058	0,904011	TESTE
450 K	0,030478	0,892876	TREINAMENTO
450 K	0,050906	0,890795	TESTE
500 K	0,029929	0,897045	TREINAMENTO
500 K	0,058168	0,881713	TESTE


**APÊNDICE E – COMPARAÇÃO ENTRE AS FUNÇÕES DE CONDUTIVIDADE HIDRÁULICA MEDIDAS E ESTIMADAS PELOS
MODELOS DE RNA E PELO MODELO DE VAN GENUCHTEN (1980)**

Configuração C1 – RNA A: 8-4-1






Configuração C1 – RNA A: 8-4-1**Configuração C1 – RNA A: 8-14-10-1****Configuração C1 – RNA A: 8-14-10-1**


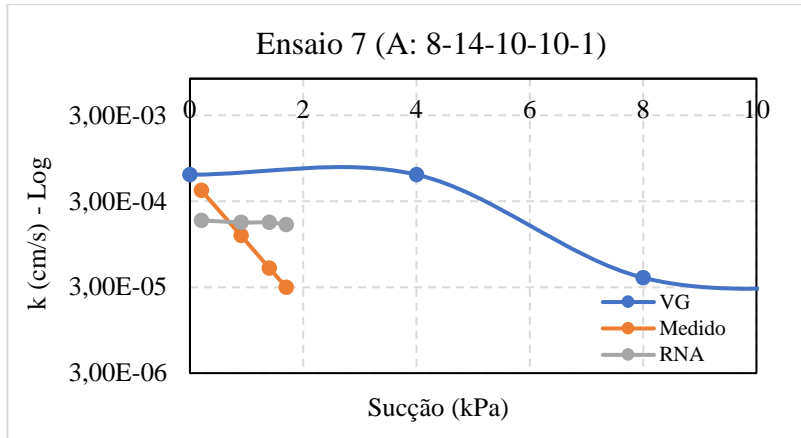
Configuração C1 – RNA A: 8-14-10-1





Configuração C1 – RNA A: 8-14-10-10-1







Configuração C1 – RNA A: 8-14-10-10-1







Configuração C2 – RNA A: 6-10-1





Configuração C2 – RNA A: 6-10-1





Configuração C2 – RNA A: 6-4-2-1




Configuração C2 – RNA A: 6-4-2-1






Configuração C2 – RNA A: 6-12-8-1





Configuração C2 – RNA A: 6-12-8-1





Configuração C2 – RNA A: 6-10-5-2-1







Configuração C2 – RNA A: 6-10-5-2-1







Configuração C2 – RNA A: 6-14-10-10-1





Configuração C2 – RNA A: 6-14-10-10-1





Configuração C3 – RNA A: 6-6-1




Configuração C3 – RNA A: 6-6-1






Configuração C3 – RNA A: 6-8-12-1





Configuração C3 – RNA A: 6-8-12-1





Configuração C3 – RNA A: 6-12-8-1







Configuração C3 – RNA A: 6-12-8-1



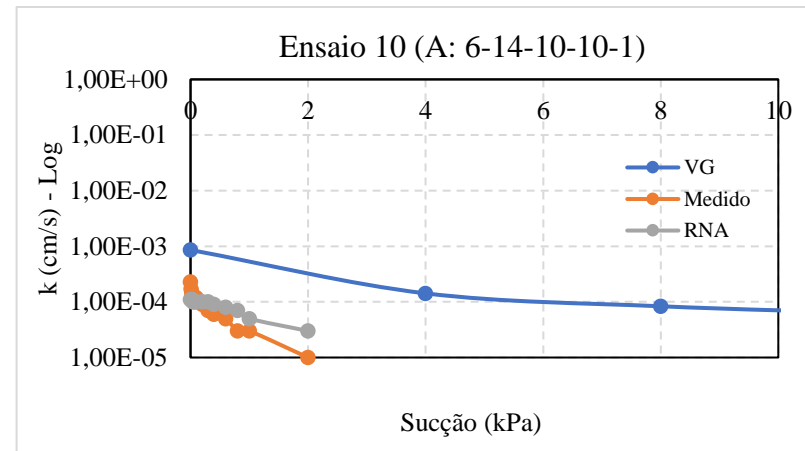



Configuração C3 – RNA A: 6-10-5-2-1




Configuração C3 – RNA A: 6-10-5-2-1



Configuração C3 – RNA A: 6-14-10-10-1



Configuração C3 – RNA A: 6-14-10-10-1

**APÊNDICE F – PARÂMETROS DO MODELO DE VAN GENUCHTEN (1980) PARA
CINCO SOLOS DO CONJUNTO EXPERIMENTAL**

Ensaio	θ_r (cm ³ /cm ³)	θ_s (cm ³ /cm ³)	α (1/cm)	n (-)	k_s (cm/dia)
3	0,0455	0,4559	0,0202	1,4413	134,6400
4	0,0505	0,3004	0,0354	1,1501	1,6300
7	0,0820	0,4705	0,0240	1,3605	52,7800
11	0,0378	0,3917	0,0099	1,5292	74,1000
14	0,0466	0,4317	0,0094	1,5321	88,0100