UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO CENTRO TECNOLÓGICO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

AMANDIO GONÇALVES DE OLIVEIRA FILHO

ANÁLISE COMPARATIVA DA ESTIMATIVA DO ÍNDICE DE COMPRESSÃO DE ARGILAS POR REDES NEURAIS ARTIFICIAIS E CORRELAÇÕES EMPÍRICAS

VITÓRIA 2019

ANÁLISE COMPARATIVA DA ESTIMATIVA DO ÍNDICE DE COMPRESSÃO DE ARGILAS POR REDES NEURAIS ARTIFICIAIS E CORRELAÇÕES EMPÍRICAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do título de Mestre em Engenharia Civil.

Orientadora: Prof. Dra. Kátia Vanessa Bicalho.

Coorientador: Prof. Dr. Willian Hiroshi Hisatugu.

VITÓRIA 2019

Ficha catalográfica disponibilizada pelo Sistema Integrado de Bibliotecas - SIBI/UFES e elaborada pelo autor

Oliveira Filho, Amandio Gonçalves de, 1987-Análise comparativa da estimativa do índice de compressão de argilas por redes neurais artificiais e correlações empíricas / Amandio Gonçalves de Oliveira Filho. - 2019. 204 f. : il.
Orientadora: Kátia Vanessa Bicalho. Coorientador: Willian Hiroshi Hisatugu. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal do Espírito Santo, Centro Tecnológico.
1. Argila. 2. Artificial neural networks. 3. Correlação

1. Argila. 2. Artificial neural networks. 3. Correlação (Estatistica). 4. Engenharia geotécnica. 5. Engenharia civil. 6. Geotécnica. I. Bicalho, Kátia Vanessa. II. Hisatugu, Willian Hiroshi. III. Universidade Federal do Espírito Santo. Centro Tecnológico. IV. Título.

CDU: 624

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO

ANÁLISE COMPARATIVA DA ESTIMATIVA DO INDICE DE COMPRESSÃO DE ARGILAS POR REDES NEURAIS ARTIFICIAIS E CORRELAÇÕES EMPÍRICAS

Amandio Gonçalves de Oliveira Filho

Dissertação apresentada ao Curso de Mestrado em Engenharia Civil do Programa de Pós-Graduação em Engenharia Civil da Universidade Federal do Espírito, como requisito parcial para obtenção do título de Mestre em Engenharia Civil, área de Estruturas (Geotecnia e Fundações).

Aprovada no dia 01 de novembro de 2019 por:

Katia anina Bicallio

Profa. Dra. Kátia Vanessa Bicalho Doutora em Engenharia Civil Orientadora – UFES

William

Prof. Dr. Willian Hiroshi Hisatugu Doutor em Engenharia Eletrica Coorienador – UFES

lus C. Ale

Prof. Dr. Élcio Cassimiro Alves Doutor em Engenharia e Tecnologia Espaciais Examinador Interno - UFES

Prof. Dr. Celso Romanel Doutor em Engenharia Civil Examinador Externo - PUC-RIO Prof. Dr. Antônio Manoel Ferreira Frasson

Doutor em Engenharia Eletrica Examinador Externo - UFES

0

123

AGRADECIMENTOS

Aos professores orientadores Kátia Vanessa Bicalho e Willian Hiroshi Hisatugu que me guiaram na realização desta pesquisa deixo meus mais sinceros agradecimentos. Ao meu filho Pedro e a minha esposa Francielly ficam meus agradecimentos pela compreensão de sempre. Agradeço também aos meus pais pela confiança e incentivo que sempre depositaram aos meus esforços acadêmicos.

Deixo meus agradecimentos aos professores da Comissão Examinadora que aceitaram contribuir na construção deste estudo: Celso Romanel, Antônio Manoel Ferreira Frasson e Élcio Cassimiro Alves.

Ao meu amigo Higor Fernando Nunes agradeço a sua dedicação em compartilhar comigo das experiências de estudos em redes neurais artificiais.

Ao Departamento de Engenharia Civil da Universidade Federal do Espírito Santo agradeço pela excelência e profissionalismo na gestão do Programa de Pós-Graduação em Engenharia Civil.

Agradeço também à Petrobras por consentir a minha participação neste curso de mestrado.

Enfim, a todos que direta ou indiretamente me ajudaram a conquistar esta vitória, muito obrigado.

RESUMO

O índice de compressão, Cc, e a taxa de compressão, CR, obtidos através de ensaio de laboratório de compressão unidimensional, comumente chamado de ensaio de adensamento são normalmente utilizados para calcular o recalque de adensamento de solos argilosos moles quando solicitados por carregamentos externos. Diversas correlações empíricas têm sido publicadas na literatura para prever os valores de Cc e CR para diferentes solos moles em função de suas propriedades índices. A multiplicidade e variabilidade das correlações previamente publicadas indicam a necessidade de critérios de seleção e uso das mesmas. Esta pesquisa investiga uma base de dados de 2.022 amostras de solos moles de diferentes locais geológicos no Brasil e em outros países. O objetivo geral deste estudo é avaliar a capacidade de previsão do índice de compressão e da taxa de compressão a partir de correlações empíricas previamente publicadas na literatura e por correlações empíricas de ajustes propostas nesta pesquisa, em comparação ao uso de Redes Neurais Artificiais (RNAs). As redes neurais artificiais são treinadas com o algoritmo Levenberg-Marguardt, com uma ou duas camadas escondidas operando as funções de ativação do tipo sigmóide e uma camada de saída, ativada por uma função linear. As redes são treinadas em grupos diferentes, primeiro com todas as amostras de solos da base, e em seguida, apenas com as amostras de solos do litoral brasileiro, para assim avaliar a capacidade de generalização das RNAs. O desempenho das previsões é avaliado a partir de técnicas estatísticas que incluem: (i) a raiz do erro quadrático médio – root mean squared error (RMSE), (ii) o coeficiente de determinação (R²), (iii) a variação do índice de compressão medido e estimado (K), (iv) índice de classificação - ranking index (RI) e (v) índice de distância – ranking distance (RD). Os resultados obtidos indicam que as RNAs têm potencial de aplicação como alternativa às correlações empíricas na previsão de Cc e CR para solos moles do litoral brasileiro e também para outros países.

Palavras Chave: Redes Neurais Artificiais, Compressibilidade Unidimensional, Solos Argilosos Moles, Correlações Empíricas.

ABSTRACT

The compression index, C_c, and the compression ratio, CR, obtained through a unidimensional compression laboratory test, normally called consolidation test, are usually used to calculate the consolidation settlement of soft clay soils when requested by external loads. Several empirical correlations have been published in the literature to predict C_c and CR values for different soft soils as a function of their index properties. The multiplicity of published correlations to estimate Cc and CR indicates the need for selection criteria in their use. This research investigates a database of 2,022 soft soil samples from different geological sites in Brazil and other countries. The objective of this study is to evaluate the prediction capacity of the compression index and the compression rate through empirical correlations previously published in the literature and by empirical correlations of adjustments proposed in this research, compared to the use of Artificial Neural Networks (ANNs). Artificial neural networks were trained with the Levenberg-Marquardt algorithm, with one or two hidden layers operating sigmoid activation functions and an output layer activated by a linear function. The ANNs are trained in different groups, first with all soil samples from the dataset, and then only with soil samples from the Brazilian coast, in order to evaluate the generalization capacity of ANNs. Forecasting performance have been assessed using statistical techniques that include: (i) the root mean square error (RMSE), (ii) the estimated and measured compression index ratio (K), (iii) the ranking index (RI) and (iv) the ranking distance (RD). The presented results reveal that the adapted ANNs created for estimation of soft soils Cc and CR from Brazilian coast and other countries have potential application as an alternative to the empirical correlations, especially during preliminary investigation of suitability of a foundation site during planning stages.

Keywords: Artificial Neural Network, Unidimensional Compression, Soft Clay Soils, Empirical Correlations.

LISTA DE FIGURAS

Figura 1 - Prensas de adensamento tipo Bishop da UFES
Figura 2: Exemplo de resultado típico de ensaio de adensamento convencional29
Figura 3 - Esquema de funcionamento de um equipamento de ensaio CRS31
Figura 4 - Fotografia de um equipamento de ensaio CRS do tipo Rapid Consolidation Cell Equipment (RACE)
Figura 5 - Relação típica entre Cc e σ'_v
Figura 6 - Conexão intersináptica39
Figura 7 - Neurônio biológico39
Figura 8 - Neurônio de McCulloch e Pitts41
Figura 9 - Modelo de neurônio artificial43
Figura 10 - Gráfico da função linear46
Figura 11 - Gráfico da função degrau46
Figura 12 - Gráfico da função tangente sigmóide46
Figura 13 - Gráfico da função gaussiana46
Figura 14 - Gráfico da função logística46
Figura 15 - Desenho esquemático mostrando uma RNA47
Figura 16 - Rede feedforward de camada única48
Figura 17 - Rede feedforward de múltiplas camadas49
Figura 18 - Rede neural com recorrência49
Figura 19 - Critério de definição do número de neurônios na camada oculta51
Figura 20 - Histograma das variáveis analisadas: (a) C _C , (b) CR, (c) w _n (%), (d) e ₀ , (e) LL _{CUP} (%) e (f) IP (%)62
Figura 21 - Correlação entre C _C e CR e as demais propriedades índices das amostras de solos moles investigadas: (a) C _C – w _n (%), (b) C _C – e ₀ , (c) C _C – LL _{CUP} (%), (d) C _C – IP (%), (e) CR – C _C , (f) CR – w _n (%), (g) CR – e ₀ , , (h) CR – LL _{CUP} (%),, (i) CR – IP (%).
Figura 22 – Ábaco de Casagrande para as amostras de solos investigadas64
Figura 23 - Avaliação de outliers a partir de Boxplot67
Figura 24 – Amostras de solos após (a) e antes (b) da remoção de <i>outliers</i> das amostras da propriedade índice LL _{CUP} 68
Figura 25 – Amostras de solos após (a) e antes (b) da remoção de <i>outliers</i> das amostras da propriedade índice IP69

Figura 26 – Amostras de solos após (a) e antes (b) da remoção de <i>outliers</i> das amostras da propriedade índice wn
Figura 27 – Amostras de solos após (a) e antes (b) da remoção de <i>outliers</i> das amostras da propriedade índice e ₀
Figura 28 – Amostras de solos após (a) e antes (b) da remoção de <i>outliers</i> das amostras do C _C
Figura 29 - Histograma de distribuição de C _c para Treinamento (n = 1.471) (a) e Validação Cruzada (n = 344) (b)
Figura 30 - Representação gráfica das correlações empíricas investigadas para estimar C _C usando w_n (a), e_0 (b) e LL _{CUP} (c)87
Figura 31 - Representação gráfica das correlações empíricas investigadas para estimar CR usando w_n (a), e_0 (b) e LL _{CUP} (c)88
Figura 32 - Resultados estatísticos das estimativas de C _c a partir de correlações empíricas e redes neurais para (a) treinamento e (b) validação cruzada, para as amostras de solos do grupo G1
Figura 33 - Correlações entre os parâmetros estatísticos <i>RD vs.SD</i> (a), <i>RI vs.RMSE</i> (b) e <i>RMSE vs. R</i> ² (c), para as amostras de solos do grupo G1
Figura 34 - Comparativo entre C _c medido e C _c estimado por correlações empíricas e RNAs para as amostras de solos para (a) treinamento e (b) validação cruzada do grupo G1
Figura 35 - Resultados estatísticos das estimativas de C _c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 673) e (b) validação cruzada (n = 124), para as amostras de solos CH do grupo G1103
Figura 36 - Resultados estatísticos das estimativas de C _c a partir de correlações empíricas e redes neurais para (a) treinamento (n =254) e (b) validação cruzada (n = 86), para as amostras de solos MH-OH do grupo G1104
Figura 37 - Resultados estatísticos das estimativas de C _c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 491) e (b) validação cruzada (n = 114), para as amostras de solos CL do grupo G1105
Figura 38 - Resultados estatísticos das estimativas de C _c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 203) e (b) validação cruzada (n = 52), para as amostras de solos do grupo G1, com destaque para o Brasil107
Figura 39 - Resultados estatísticos das estimativas de C _c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 119) e (b) validação cruzada (n = 29), para as amostras de solos do grupo G1, com destaque para o Canadá109
Figura 40 - Resultados estatísticos das estimativas de C _c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 74) e (b) validação cruzada (n = 18), para as amostras de solos do grupo G1, com destaque para a Coreia

Figura 41 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 331) e (b) validação cruzada (n = 79), para as amostras de solos do grupo G1, com destaque para a Indonésia114

Figura 42 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 266) e (b) validação cruzada (n = 65), para as amostras de solos do grupo G1, com destaque para o Irã......116

Figura 43 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 135) e (b) validação cruzada (n = 33), para as amostras de solos do grupo G1, com destaque para o Japão119

Figura 46 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 119) e (b) validação cruzada (n = 29), para as amostras de solos do grupo G1, com destaque para o Canadá127

Figura 48 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 331) e (b) validação cruzada (n = 79), para as amostras de solos do grupo G1, com destaque para a Indonésia131

Figura 49 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 266) e (b) validação cruzada (n = 65), para as amostras de solos do grupo G1, com destaque para o Irã.......133

Figura 52 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 254) e (b) validação cruzada (n = 86), para amostras de solos MH-OH do grupo G1......136

Figura 53 - Histograma das variáveis analisadas das amostras de solos do Brasil: (a) C_{C} , (b) CR, (c) w_{n} (%), (d) e_{0} , (e) LL_{CUP} (%) e (f) IP (%)......139

Figura 54 - Resultados estatísticos das estimativas de C_C a partir de correlações empíricas e redes neurais para (a) treinamento (n = 203) e (b) validação cruzada (n = 52), para as amostras de solos do Brasil (grupo G2)......147

Figura 56 - Resultados estatísticos das estimativas de C_C a partir de correlações empíricas e redes neurais para (a) treinamento (n = 99) e (b) validação cruzada (n = 23), para as amostras de solos CH do Brasil (grupo G2)......150

Figura 57 - Resultados estatísticos das estimativas de C_C a partir de correlações empíricas e redes neurais para (a) treinamento (n = 78) e (b) validação cruzada (n = 20), para as amostras de solos MH-OH do Brasil (grupo G2)......151

Figura 58 - Resultados estatísticos das estimativas de C_C a partir de correlações empíricas e redes neurais para (a) treinamento (n = 46) e (b) validação cruzada (n = 14), para as amostras de solos do RJ (grupo G2).....153

Figura 59 - Resultados estatísticos das estimativas de C_C a partir de correlações empíricas e redes neurais para (a) treinamento (n = 75) e (b) validação cruzada (n = 15) , para as amostras de solos de SC (grupo G2)......154

Figura 62 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 102) e (b) validação cruzada (n = 29), para as amostras de solos CH do Brasil (grupo G2)......160

Figura 63 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 77) e (b) validação cruzada (n = 20), para as amostras de solos MH-OH do Brasil (grupo G2)......161

Figura 64 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 46) e (b) validação cruzada (n = 14), para as amostras de solos do RJ (grupo G2)......163

Figura 65 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 75) e (b) validação cruzada (n = 15), para as amostras de solos de SC (grupo G2)......164

Figura 67 – Teste de sensibilidade das propriedades índices do solo na modelagem de redes neurais para a estimativa de C_c 167
Figura 68 - Teste de sensibilidade das propriedades índices do solo na modelagem de redes neurais para a estimativa de CR
Figura 69: Exemplo de organização dos dados de treinamento das RNA no excel 187
Figura 70 - Exemplo de declaração de variáveis no Matlab188
Figura 71 - Tela inicial da toolbox nftool189
Figura 72 - Tela de seleção do conjunto de treinamento da rede na nftool189
Figura 73 - Definição dos percentuais do conjunto de treinamento na nftool190
Figura 74 - Definição do número de neurônios escondidos na nftool191
Figura 75 - Tela de inicialização do treino da rede na nftool191
Figura 76 - Tela de controle do progresso do treinamento da rede na nftool192
Figura 77 - Tela de controle da convergência da rede na nftool
Figura 78 - Histograma de erros na fase de treinamento na nftool
Figura 79 - Gráficos dos coeficientes de correlação para o treinamento na nftool194
Figura 80 - Tela de avaliação do desempenho da rede treinada (nftool)195
Figura 81 - Tela de exportação dos parâmetros da rede treinada pela nftool 195
Figura 82 - Tela inicial da <i>nntool</i> 196
Figura 83 - Definição da arquitetura da RNA na <i>nntool</i> 197
Figura 84 - Tela com a arquitetura da RNA criada na nntool197
Figura 85 - Tela de treinamento da rede na <i>nntool</i>
Figura 86 - Tela para seleção dos inputs do teste da <i>nntool</i> 199

LISTA DE TABELAS

Tabela 1 – Alguns critérios previamente publicados para classificação de amostras de solos argilosos moles
Tabela 2: Resumo Histórico de publicações sobre Redes Neurais Artificiais42
Tabela 3 - Resumo da quantidade, localidade e organizador das amostras de solos moles investigadas
Tabela 4 - Descrição estatística das 2.022 amostras de solos moles investigadas61
Tabela 5 - Matriz de correlação (<i>R²</i>) entre as variáveis das amostras de solo investigadas62
Tabela 6 - Descrição estatística de C _C por tipo de solo segundo o SUC65
Tabela 7 - Variação de (a) C $_{ m C}$ e (b) CR por tipo de solo segundo o SUC65
Tabela 8 - Descrição estatística das amostras de solos investigados após a remoção de <i>outlier</i> s
Tabela 9 - Classes de compressibilidade de solos finos 72
Tabela 10 - Divisão das amostras de solos moles para avaliação
Tabela 11 - Resumo das topologias das RNAs treinadas
Tabela 12 - Correlações empíricas previamente publicadas na literatura utilizadas para estimar Cc82
Tabela 13 - Correlações empíricas previamente publicadas na literatura utilizadas para estimar CR.
Tabela 14 - Correlações empíricas de ajuste propostas para estimar C _C 86
Tabela 15 - Correlações empíricas de ajuste propostas para estimar CR
Tabela 16 - Relação das correlações empíricas de previsão de C _C para as amostras de solos do grupo G193
Tabela 17 - Relação das correlações empíricas de previsão de CR para as amostras de solos do grupo G194
Tabela 18 - Resumo estatístico das estimativas de C _C para as amostras de solos de treinamento do grupo G195
Tabela 19 - Resumo estatístico das estimativas de Cc para as amostras de solos de validação cruzada do grupo G196
Tabela 20 - Resumo estatístico das amostras de solos do Brasil investigadas nesta dissertação106

Tabela 21 - Resumo estatístico das amostras de solos do Canadá investigadas nesta dissertação108
Tabela 22 - Resumo estatístico das amostras de solos da Coreia investigadas nesta dissertação110
Tabela 23 - Resumo estatístico das amostras de solos da Indonésia investigadasnesta dissertação
Tabela 24 - Resumo estatístico das amostras de solos do Irã investigadas nesta dissertação115
Tabela 25 - Resumo estatístico das amostras de solos do Japão investigadas nesta dissertação
Tabela 26 - Resumo estatístico das estimativas de CR para as amostras de solos detreinamento do grupo G1122
Tabela 27 - Resumo estatístico das estimativas de CR para as amostras de solos de validação cruzada do grupo G1123
Tabela 28 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos do Brasil
Tabela 29 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos do Canadá
Tabela 30 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos da Coreia128
Tabela 31 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos da Indonésia
Tabela 32 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos do Irã
Tabela 33 - Descrição estatística de Cc por tipo de solo segundo o SUC para as amostras de solos do Brasil138
Tabela 34 - Descrição estatística das amostras de solos do Brasil após a remoção de outliers (n = 255)
Tabela 35 - Matriz de correlação (<i>R</i> ²) entre as variáveis das amostras de solos do Brasil (n = 255)140
Tabela 36 - Correlações empíricas empregadas para estimar Cc para as amostras de solos do Brasil141

Tabela 37 - Correlações empíricas empregadas para estimar CR para as amostras de solos do Brasil
Tabela 38 - Resumo estatístico das estimativas de C _C a partir das amostras de solos de treinamento do Brasil143
Tabela 39 - Resumo estatístico das estimativas de Cc a partir das amostras de solos de validação cruzada do Brasil145
Tabela 40 - Resumo estatístico das estimativas de CR para as amostras de solos de treinamento do Brasil (grupo G2)157
Tabela 41 - Resumo estatístico das estimativas de CR para as amostras de solo de validação cruzada do Brasil (grupo G2)158
Tabela 42 – Resultados estatísticos da previsão de Cc com redes treinadas excluindo uma propriedade índice do solo
Tabela 43 - Resultados estatísticos da previsão de CR com redes treinadas excluindo uma propriedade índice do solo

SÍMBOLOS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ASTM	American Society for Testing and Materials
AT	Argilas Transicionais
AU	Austrália
BR	Brasil
С	Argila
CA	Canadá
Cc	Índice de Compressão
СН	Argila de Alta Compressibilidade
CL	Argila de Baixa Compressibilidade
CN	China
CNN	Convolutional Neural Network
СРТ	Cone Penetration Test
Cr	Índice de Recompressão
CR	Taxa de Compressão
CRS	Ensaio com Velocidade Controlada de Deformação
Cs	Índice de Inchamento do Solo
CV	Coeficiente de variação
DL	Deep Learning
Dr	Compacidade Relativa
e ₀	Índice de vazio inicial
ELM	Extreme Learning Machine (Máquina de Aprendizado Extremo)
ES	Espírito Santo
GPU	Graphics Processing Unit (Unidade de Processamento Gráfico)

GV-ES	Grande Vitória – Espírito Santo
Н	Alta plasticidade
IA	Inteligência Artificial
IP	Índice de Plasticidade
IN	índia
IR	Irã
IT	Itália
LLCUP	Limite de Liquidez Obtido pelo Método de Casagrande
JP	Japão
LM	Algoritmo de Levenberg-Marquardt
LP	Limite de plasticidade
MY	Malásia
К	Variação do índice de compressão medido e estimado
KR	Coreia
LogSig	Função de ativação logística sigmóide
М	Silte
MCP	Modelo de Neurônio de McCulloch e Pitts
MH	Silte de Alta Compressibilidade
ML	Silte de Baixa Compressibilidade
MLP	Multlayer Perceptron (Perceptron Multicamadas)
MSE	Erro Quadrático Médio
NBR	Norma Brasileira
NO	Noruega
NSPT	Valor de Resistência do Solo Medido no ensaio SPT
ОН	Solo Orgânico de Alta Compressibilidade
OL	Solo Orgânico de Baixa Compressibilidade
qc	Resistência de Ponta de Estacas

r	Coeficiente de Correlação
R²	Coeficiente de determinação
RACE	Rapid Consolidation Cell Equipment
RD	Índice de distância (<i>ranking distance</i>)
RI	Índice de classificação (<i>ranking index</i>)
RJ	Rio de Janeiro
RMSE	Root Mean Squared error (raiz do erro quadrático médio)
RN	Rede Neural Artificial
RNA	Rede Neural Artificial
RNN	Recurrent neural network
RNC	Redes Neurais Convolucionais
RNR	Redes neurais recorrentes
SC	Santa Catarina
SG	Singapura
SIC	Ensaio de Adensamento Convencional
SPT	Standard Penetration Test
SUC	Sistema Unificado de Classificação
TanSig	Função de ativação tangente sigmóide
TR	Treinamento
UFES	Universidade Federal do Espírito Santo
US	Estados Unidos
Wn	Umidade Natural
Δe	Variação do índice de vazios
Δw	Ajuste de Pesos Para o Algoritmo Backpropagation
Δx	Ajuste de pesos para o Algoritmo LM
η	Taxa de Aprendizagem

Ι	Matriz Identidade
e	Erro de Aprendizagem Algoritmo Backpropagation
evo	Índice de vazio correspondente à tensão efetiva de campo
e(x)	Erro de aprendizagem do algoritmo LM
J	Matriz Jacobiana
σ'ν	Tensão Vertical Efetiva
σ' _{vm}	Tensão de Pré-adensamento
n	Número de Variáveis
X <i>i</i> , <i>m</i>	Valor da Variável de Entrada
<i>X</i> _{<i>i</i>, <i>p</i>}	Valor da Variável de Saída
$\overline{X}_{i,m}$	Valor Médio das Entradas
$\overline{X}_{i,p}$	Valor Médio das Saídas
Xj	Representa as entradas da rede (inputs);
Wki	Peso Sináptico do Neurônio <i>k</i>
bĸ	parâmetro de ponderação - Bias
f (.)	Função de Ativação
Uk	Combinação Linear dos Sinais de Entrada
Ук	Valor de Saída do Neurônio
α	Coeficiente Angular
μ	Média
SD	Desvio padrão

SUMÁRIO

1. INTRODUÇÃO	20
1.1 OBJETIVOS	22
1.1.1 Objetivo geral	22
1.1.2 Objetivos específicos	22
1.1.3 Justificativa	23
2. FUNDAMENTAÇÃO TEÓRICA	24
2.1 DEPÓSITOS DE SOLOS MOLES	24
2.1.1 Formação dos solos	24
2.1.2 Origem e formação dos depósitos de solos argilosos moles brasileiro	do litoral 25
2.2 IDENTIFICAÇÃO E CLASSIFICAÇÃO DE SOLOS MOLES	26
2.2.1 Limites de consistência	26
2.2.2 Classificação de solos pelo SUC	27
2.3 ENSAIOS DE ADENSAMENTO	27
2.3.1 Ensaio de adensamento convencional (SIC)	27
2.3.2 Ensaio de adensamento com velocidade controlada de deforma	ıção (CRS) 30
2.3.3 Índice de Compressão (Cc) e Taxa de Compressão (CR)	32
2.3.4 Qualidade das amostras	34
2.4 REDES NEURAIS ARTIFICIAIS	35
2.4.1 Fundamentos	35
2.4.2 Inspiração para as redes neurais artificiais: redes biológicas	37
2.4.3 Neurônios biológicos	38
2.4.4 Breve histórico das Redes Neurais Artificiais	40
2.4.5 Neurônio artificial	43
2.4.6 Arquitetura de redes neurais artificias	47
2.4.7 Topologia da rede neural artificial	50
2.4.8 Conjunto de dados e pré-processamento	52
2.4.9 Treinamento e testes	52
2.4.10 Perceptron Multicamadas e o Algoritmo de retropopagação	54

2.4.11 Algoritmo de Levenberg-Marquardt (LM)55
2.4.12 Aplicações de redes neurais artificiais na engenharia civil
3. MATERIAIS E MÉTODOS
3.1 BASE DE DADOS INVESTIGADA
3.1.1 Organização da base de dados58
3.1.2 Avaliação estatística da base de dados de solos argilosos moles66
3.2 METODOLOGIA
3.2.1 Operacionalização dos treinamentos das RNAs74
3.2.2 Divisão da base de dados em treinamento e validação cruzada74
3.2.2.1 Organização das amostras de solos em grupos de avaliação75
3.2.3 Propostas de treinamento das RNAs76
3.2.4 Correlações empíricas79
3.2.5 Propostas de novas correlações empíricas85
3.2.6 Metodologia de avaliação dos resultados
4. RESULTADOS92
4.1 RESULTADOS A PARTIR DAS AMOSTRAS DE SOLOS DO GRUPO G192
4.1.1 Avaliação de Cc a partir das amostras de solos do grupo G194
4.1.2 Avaliação de C_c para as amostras de solos do grupo G1: destaque para as amostras de solos do Brasil106
4.1.3 Avaliação de C $_{\rm C}$ para as amostras de solos do grupo G1: destaque para as amostras de solos do Canadá107
4.1.4 Avaliação de C $_{\rm C}$ para as amostras de solos do grupo G1: destaque para as amostras de solos da Coreia110
4.1.5 Avaliação de C $_{\rm C}$ para as amostras de solos do grupo G1: destaque para as amostras de solos da Indonésia112
4.1.6 Avaliação de C $_{\rm C}$ para as amostras de solos do grupo G1: destaque para as amostras de solos do Irã114
4.1.7 Avaliação de C $_{\rm C}$ para as amostras de solos do grupo G1: destaque para as amostras de solos do Japão117
4.2 RESULTADOS DAS ESTIMATIVAS DE CR A PARTIR DAS AMOSTRAS DE SOLOS DO GRUPO G1120
4.2.1 Avaliação de CR para as amostras de solos do grupo G1: destaque para as amostras de solos do Brasil124

4.2.2 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para as amostras de solos do Canadá126
4.2.3 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para as amostras de solos da Coreia127
4.2.4 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para as amostras de solos da Indonésia129
4.2.5 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para as amostras de solos do Irã131
4.2.6 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para os tipos de solos segundo o SUC133
4.3 RESULTADOS A PARTIR DAS AMOSTRAS DE SOLOS DO GRUPO G2 (BRASIL)
4.3.1 Avaliação de C $_{ m C}$ a partir das amostras de solos do Brasil (grupo G2)142
4.3.2 Avaliação de CR a partir das amostras de solos do Brasil (grupo G2)156
4.4 SENSIBILIDADE DAS PROPRIEDADES ÍNDICES
5.0 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS170
5.1 CONCLUSÕES170
5.2 SUGESTÕES PARA TRABALHOS FUTUROS176
REFERÊNCIAS177

APÊNDICES

APÊNDICE	Α	-	OPERACIONALIZAÇÃO	DOS	TREINAMENTOS	DAS
RNAS						191

1. INTRODUÇÃO

Os engenheiros geotécnicos geralmente calculam compressibilidade unidimensional de solos argilosos moles em termos de variações no índice de vazios. E, a declividade da reta virgem de compressão (i.e, relação entre o índice de vazios (e) e a correspondente tensão vertical efetiva do solo (σ'_v) em escala logarítmica) define o índice de compressão (Cc). A taxa de compressão (CR) é definida como Cc/(1 + e₀), sendo e₀ o índice de vazios inicial. Os parâmetros de compressão C_C e CR são normalmente obtidos através de ensaio de laboratório de compressão unidimensional em amostras de solos indeformadas. O ensaio de compressão unidimensional é comumente chamado de ensaio de adensamento convencional de carregamento incremental (oedométrico).

As correlações empíricas entre Cc ou CR e as propriedades índices do solo, tais como umidade natural (w_n), índice de vazio inicial (e₀), índice de plasticidade (IP) e limite de liquidez medido pelo método de Casagrande (LL_{CUP}) são de importância prática, especialmente durante investigações preliminares de adequação de um local para a disposição de fundações durante as etapas de planejamento. Em geral, o recalque de solo argiloso mole depende da sua origem, da capacidade de absorção de água pelas partículas argilosas, do estado de tensão existente, da tensão de pré-adensamento do solo e, em certa medida, da compressibilidade dos grãos do solo (OZER; ISIK; ORHAN, 2008).

As correlações empíricas previamente publicadas associando as propriedades índices do solo supracitadas a C_c e CR podem não se aplicar a solos de outras formações geológicas e, a variabilidade das correlações empíricas publicadas (TERZAGHI; PECK, 1967; AZZOUZ; KRIZEK; COTORIS, 1976; KOOTAHI; MORADI, 2016; BARONI; ALMEIDA, 2017), indica a necessidade de critérios de avaliação para o seu uso.

Redes neurais artificiais (RNAs) têm sido usadas em engenharia geotécnica para previsões de características geotécnicas de solos a partir de propriedades índices conhecidas. Desde o trabalho de Rumelhart, Hilton e Williams (1986) sobre o

algoritmo *backpropagation*, o emprego de redes neurais artificiais ganhou impulso no meio acadêmico, o que possibilitou nos últimos anos destacado emprego em diversos trabalhos de engenharia civil, como na solução de problemas geotécnicos, tendo obtido relativo sucesso.

Com relação à aplicação de RNAs em estudos de previsão do índice de compressão de argilas (C_c), Kolay, Rosmina e Ling (2008) e Ozer, Isik e Orhan (2008) treinaram redes neurais artificiais com propriedades índices do solo para estimar C_c; Park e Lee (2011) avaliaram a previsão de C_c a partir de RNA empregando as propriedades índices e₀, LL_{cuP}, w_n e IP; Kalantary e Kordnaeij (2012) analisaram centenas de amostras de argilas do norte do Irã com aplicação de redes neurais tendo encontrado bons resultados com o treinamento de RNA com as varáveis w_n, e₀, LL_{cuP} e a densidade específica dos grãos (G_s); Kurnaz *et al.* (2016) a partir das propriedades índices de 246 amostras de solos argilosos, como limite de liquidez (LL_{cuP}), índice de plasticidade (IP), índice de vazios inicial (e₀) e umidade natural (w_n) obtiveram resultados melhores de previsão de C_c comparados às correlações empíricas tradicionais.

Esta dissertação de mestrado avalia a aplicabilidade de algumas correlações empíricas previamente publicadas na literatura e também de outras propostas nesta pesquisa a partir de regressão linear e testes de normalidade de resíduos na estimativa de C_c e CR empregando propriedades índices de diferentes amostras de solos moles do litoral do Brasil e também de outros países.

Uma base de dados organizada com os resultados de 2.022 ensaios oedométricos e suas correspondentes propriedades índices (LL_{CUP}, e₀, IP e w_n), além do índice de compressão (C_c), realizados em uma ampla variabilidade de solos argilosos moles, relatados por diferentes pesquisadores foram compilados nesta pesquisa. As correlações empíricas usam variáveis simples ou múltiplas para prever C_c e CR a partir de propriedades índices do solo como índice de plasticidade (IP), umidade natural (w_n), índice de vazio inicial (e₀) e limite de liquidez determinado pelo método de Casagrande (LL_{CUP}).

Novas correlações empíricas para os resultados experimentais das amostras de solos selecionadas são obtidas a partir de técnicas de regressão linear e análise de normalidade de resíduos. Esta dissertação apresenta o uso da técnica de modelagem baseada em computador, denominada de rede neural artificial (RNA) para prever os

valores de C_C e CR usando as propriedades índices do solo, para assim tentar superar as limitações das correlações empíricas normalmente usadas.

1.1 OBJETIVOS

1.1.1 Objetivo geral

O objetivo principal desta pesquisa é avaliar o uso de redes neurais artificiais e correlações empíricas na previsão dos parâmetros de compressibilidade unidimensional, índice de compressão (C_c) e taxa de compressão (CR) de solos argilosos moles de diferentes regiões do litoral do Brasil e de outras regiões geológicas com propriedades geotécnicas semelhantes de outros países.

1.1.2 Objetivos específicos

- Organizar e agrupar dados com as informações de propriedades índices (tais como limite de liquidez obtido pelo método de Casagrande, LL_{CUP}, índice de plasticidade, IP, índice de vazios inicial, e₀ e umidade natural, w_n) utilizadas na previsão empírica do índice de compressão de solos moles, C_c. As características de textura e plasticidade utilizadas em classificações de solos moles também são incluídas nas informações dos solos selecionados e investigados nesta dissertação. Esses dados são utilizados para a identificação dos solos e treinamento das redes neurais artificias e das correlações empíricas investigadas nesta dissertação;
- Treinar diversas redes neurais com arquiteturas diferentes para melhor aproximação da previsão do índice de compressão (C_C) e também da taxa de compressão (CR) com base nas propriedades índices (LL_{CUP}, e₀, IP e w_n) de solos argilosos moles de diferentes regiões do litoral do Brasil e de outras regiões com propriedades geotécnicas semelhantes em outros países;
- Definir novas correlações empíricas de ajuste para as previsões de Cc e CR dos solos argilosos moles do litoral brasileiro e de outras regiões geotécnicas

de outros países, com base nas propriedades índices do solo (LL_{CUP}, e₀, IP e w_n);

Comparar valores de C_c e de CR dos solos argilosos moles, previstos pelas redes neurais com os resultados previstos por meio de correlações empíricas previamente publicadas na literatura e propostas nesta pesquisa a partir de tratamentos estatísticos. Os valores previstos do índice de compressão dos solos argilosos moles, C_c e da taxa de compressão (CR) são comparados com valores medidos de C_c e CR para os solos investigados. São utilizados testes estatísticos de comparações (tais como coeficiente de determinação, *R*², a raiz do erro quadrático médio, *RMSE*, a variação do índice de compressão medido e estimado, *K*, o índice de classificação, *RI*, e o índice de distância, *RD*, para identificar as diferenças observadas nos resultados previstos e medidos de C_c

1.1.3 Justificativa

O índice de compressão Cc é normalmente determinado a partir de resultados de ensaio de adensamento convencional de carregamento incremental (oedométrico), de longa duração, podendo alcançar semanas ou meses, e requer amostras de solo suficientemente indeformadas e de boa qualidade. Na ausência de resultados de ensaios oedométricos, o índice de compressão de solos moles é estimado por correlações empíricas em função de propriedades índices das amostras desses solos. A multiplicidade e variabilidade das correlações previamente publicadas indicam a necessidade de critérios para a seleção da melhor correlação empírica. As redes neurais artificias representam um recurso tecnológico computacional e matemático capaz de prever resultados de Cc e CR em função de propriedades índices dos solos argilosos, podendo trazer ganhos substanciais à engenharia civil. Nesse sentido, o esforço de avaliar o uso de redes neurais artificias na previsão de Cc e CR se justifica pelo ganho substancial em qualidade e tempo em estudos preliminares de geotecnia, em especial para a previsão de recalques de adensamento de solos argilosos moles.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 DEPÓSITOS DE SOLOS MOLES

2.1.1 Formação dos solos

O objetivo do estudo dos aspectos geológicos e geomorfológicos é uma prerrogativa para o engenheiro geotécnico compreender as particularidades do seu objeto de análise. É recorrente nos estudos de mecânica dos solos, o encontro com as peculiaridades do material particulado em função da sua espacialização, o que indica a intrínseca relação das partículas constituintes do solo com a sua origem. Nesse contexto, o solo é o produto dos processos intempéricos, da redistribuição e da organização das camadas da crosta terrestre, derivados da ação da atmosfera, da hidrosfera, da biosfera e das trocas de energia envolvidas, configurando assim, o resultado de diferentes fatores, como material (fonte), clima, vegetação, hidrografia, relevo e ação de organismos (TOLEDO; OLIVEIRA; MELFI, 2003, p.140).

Nesse sentido é importante se compreender que todos os solos são produtos de processos naturais de intemperismo e da decomposição dos diferentes grupos de rochas que constituem a crosta terrestre. O intemperismo é decorrente da atuação de agentes físicos, químicos e biológicos que agem sobre as formações litológicas do planeta. Essas formas de intemperismo estão intrinsecamente relacionadas às condições climáticas, como temperatura, umidade e pressão do ar, que são as forças que respondem pela intemperização das rochas, que consequentemente culminam na formação de distintos depósitos de sedimentos.

Com relação aos três tipos de processos de intemperismo, o físico (mecânico) é responsável pela desintegração das rochas, que se processam sem que ocorra a alteração química dos minerais constituintes; o intemperismo químico representa a alteração da estrutura química dos minerais originais que compõem as rochas, com destaque para a dissolução, hidratação, hidrólise, carbonatação e oxidação; já o intemperismo biológico é a conjunção dos fatores químicos e mecânicos conduzidos por espécies de plantas e vegetais (CASSETI, 2005).

Assim, os solos são resultados desses intricados processos geológicos e geomorfológicos de conformação da paisagem, constituindo-se de pequenas partículas que se diferenciam pela composição mineralógica e pelo tamanho, que implicam nos solos composição mineralógica basicamente semelhante à rocha de origem (PINTO, 2006, p.14).

2.1.2 Origem e formação dos depósitos de solos argilosos moles do litoral brasileiro

Os solos argilosos moles são caracterizados por serem solos sedimentares marcados pela presença da fração argila, que resulta em características de solo compressível, e consequente baixa resistência à penetração, como revelado em sítios de argilas de Vitória, ES, que apresentam valores de N_{SPT} abaixo de 2 (CASTELLO; POLIDO, 1986).

Suguio, Martin e Flexor (1988) e Martin *et al.* (1997) destacam que a origem dos sedimentos dos depósitos de solos argilosos moles do litoral brasileiro está relacionada aos ciclos deposicionais do Quaternário associados a processos erosivos intermediários. Massad (2005) destaca a formação de dois tipos de argilas no litoral brasileiro, denominada de Argila Pleistocena (Transicional) e Argila Holocênica. As Argilas Transicionais (AT) foram depositadas entre 100.000 e 120.000 anos antes do presente, sendo pré-consolidadas em função da variação do nível marinho, que durante o Pleistoceno, elevou-se aproximadamente 8m acima do nível atual, e posteriormente durante a última glaciação (15.000 anos antes do presente), o nível do mar esteve 130 abaixo do atual. Como consequência de intenso processo erosivo, parte dos sedimentos formados foi removida. Já as argilas do Holoceno foram sedimentadas a partir de 10.000 anos antes do presente, variando de extremamente moles a moles, sendo levemente sobreadensadas devido a curtas ocorrências de rápida variação negativa do nível do mar, em relação ao nível atual (MASSAD, 2005; CAMPOS, 2006).

Assim, existe uma intrínseca relação desses depósitos com a história de tensões, tempo e ambiente deposicional, em que as propriedades físicas e mecânicas dos solos argilosos moles podem geralmente ser relacionadas para se compreender as características geotécnicas desses solos. Esse ponto é importante para se

compreender que muitas das propriedades geotécnicas dos solos mudam em função da sua origem geológica.

2.2 IDENTIFICAÇÃO E CLASSIFICAÇÃO DE SOLOS MOLES

2.2.1 Limites de consistência

Os solos são identificados e classificados a partir dos resultados de ensaios de análise granulométrica e índices de consistência. O solo mole, por sua natureza argilosa, resulta em características de solo compressível, sendo as suas partículas constituintes, majoritariamente, das frações silte e argila, com dimensão menor que 0,002 mm.

A análise granulométrica dos solos é normalizada no Brasil pela NBR 7181 (ABNT, 2016b). A classificação dos solos finos pelo Sistema Unificado de Classificação (SUC) é complementada pelos valores do limite de liquidez (LL_{CUP}) e limite de plasticidade (LP) - NBR 6459 (ABNT, 2017) e NBR 7180 (ABNT, 2016a), respectivamente.

O limite de liquidez determinado pelo método de Casagrande consiste no teor de umidade do solo com o qual uma ranhura feita no solo disposto em uma concha se fecha depois de 25 golpes. Segundo Haigh (2012), o limite de liquidez foi descrito primeiramente por Atterberg (1911) e normalizado na engenharia geotécnica por Casagrande em 1932 e 1958. Os resultados do limite de liquidez são largamente empregados na engenharia, além de serem usados para a classificação de solos finos, também são empregados na determinação de propriedades do solo como resistência ao cisalhamento não drenado, compressibilidade e permeabilidade (OZER; ISIK; ORHAN, 2008).

O limite de plasticidade é definido como o teor mínimo de umidade presente no solo, em que se consegue moldar um cilindro com 3 mm de diâmetro, rolando-se uma porção de solo com a palma da mão sobre uma superfície lisa, sem causar a sua fratura. A partir da diferença entre o LL_{CUP} e o LP, determina-se o índice de plasticidade (IP), que é comumente empregado em sistemas de classificação de solos finos.

2.2.2 Classificação de solos pelo SUC

No Sistema Unificado de Classificação (SUC), os solos finos são identificados pelas letras M (silte) e C (argila) acompanhadas das letras H (alta compressibilidade) ou L (baixa compressibilidade). Ainda, os solos orgânicos são identificados pela letra O.

A importância da determinação do LL_{CUP} e do IP está na aplicação desses índices na classificação dos solos finos através da Carta ou Ábaco de Casagrande. Nesta carta, que representa um gráfico, são plotados pontos em um plano cartesiano, em que o eixo das abcissas corresponde ao LL_{CUP} e o eixo das ordenadas ao IP. Os pontos são separados no ábaco por uma reta inclinada denominada Linha A (Equação 1). Os pontos abaixo dessa linha são classificados como siltosos e orgânicos, mesmo que apresente frações de argila. Os pontos acima da Linha A e geralmente limitados pela Linha U (Equação 2) são classificados como argilosos.

O ábaco de Casagrande pode ser utilizado como auxílio na avaliação das propriedades físicas de solos finos argilosos. Como referências, podem ser citados os trabalhos de Bain (1971) e Vardanega e Haigh (2014). No capítulo 3 apresenta-se a caracterização dos solos finos investigados nesta pesquisa.

$$IP = 0.73(LL - 20) \tag{1}$$

$$IP = 0,90(LL - 8)$$
(2)

2.3 ENSAIOS DE ADENSAMENTO

2.3.1 Ensaio de adensamento convencional (SIC)

O ensaio de adensamento é estruturado no princípio da mecânica dos solos que considera tanto os sólidos quanto a água presente nos vazios do solo como incompressíveis, resultando na variação de volume apenas através de água para dentro ou para fora do solo saturado (ANDRADE, 2009). Assim, o adensamento primário consiste no processo de compressão de um solo saturado ao longo do tempo,

com a consequente expulsão de água. Essa quantidade de água corresponde ao volume de vazios antes preenchidos por água, correspondendo à transferência gradual da poropressão (tensões entre a água) para a tensão efetiva (tensão entre os sólidos).

O ensaio de adensamento é comumente empregado no cálculo de recalque e sua evolução ao longo do tempo (ALMEIDA; MARQUES, 2014, p. 73). Para a avaliação de recalques em solos argilosos moles, o ensaio de adensamento oedométrico é normalmente empregado, no Brasil normatizado pela NBR 12007 (ABNT, 1990).

O ensaio de adensamento oedométrico, ou ensaio de adensamento convencional de carregamento (SIC – *Standard Incremental Consolidation*) consiste em manter uma amostra de solo confinada lateralmente em um anel metálico rígido, acoplado a uma prensa, de forma que as deformações e o fluxo de água sejam impedidos de ocorrerem na horizontal. A amostra de solo é carregada axialmente de forma incremental, mantendo-se a pressão constante, até a dissipação do excesso de poropressão. Durante todo o ensaio são registradas, periodicamente, as medidas de deformações da amostra, que são utilizadas nos cálculos dos parâmetros de adensamento que descrevem a relação entre o índice de vazios e a tensão efetiva vertical. Almeida e Marques (2014, p. 73) apontam que este ensaio tem a duração usual de duas semanas quando incluídos ciclos de descarregamento para avaliação da magnitude dos recalques secundários. A Figura 1 mostra um exemplo de equipamento empregado no ensaio de adensamento convencional presente no Laboratório de Mecânica dos Solos da UFES.



Figura 1 - Prensas de adensamento tipo Bishop da UFES

Fonte: Autor (2018)

Os resultados do ensaio de adensamento são plotados em um gráfico com o eixo das abcissas indicando o logaritmo das pressões aplicadas, e no eixo das ordenadas os índices de vazios, conforme apresentado na Figura 2. Nota-se que a partir de certa tensão (σ'_{vm}), nomeada como tensão de pré-adensamento, o índice de vazios varia linearmente com o logaritmo da pressão aplicada em um trecho considerável após essa tensão. A esse trecho retilíneo dá-se o nome de *reta virgem*.





Fonte: Autor (2019)

O índice de compressão (Cc) indica a inclinação da reta virgem, descrito conforme a Equação 3

$$C_c = -\frac{\Delta_e}{\Delta lo \ g\sigma'} \tag{3}$$

A tensão de pré-adensamento, (σ'_{vm}), marca o início da mudança abrupta do comportamento da compressão unidimensional do solo, que indica a tensão efetiva onde se iniciam grandes alterações na estrutura do solo. No trecho de recompressão, anterior à σ'_{vm} , a tensão efetiva é acomodada pela estrutura do solo, de forma a não ocorrerem significantes deslocamentos das partículas, o que marca os recalques de baixa dimensão (TERZAGHI; PECK; MERSIR, 1996). Para a determinação da tensão de pré-adensamento são comumente empregados os métodos de Casagrande e de Pacheco e Silva, conforme descrito por Pinto (2006, p.192-193).

Nas situações em que as tensões efetivas finais, devidas ao carregamento no solo não ultrapassem a σ'_{vm} , o índice de recompressão (C_r) é utilizado para o cálculo dos recalques utilizando-se a mesma Equação 3, entretanto a partir das variações da tensão efetiva vertical e do índice de vazio do trecho de recompressão.

Importante ressaltar que os valores de C_c empregados nesta pesquisa foram obtidos a partir das diversas teses e artigos consultados.

2.3.2 Ensaio de adensamento com velocidade controlada de deformação (CRS)

Além do ensaio de adensamento convencional (SIC) existem outros ensaios de laboratório utilizados para a determinação do índice de compressão (C_c) de solos argilosos, entre eles, o ensaio com velocidade controlada de deformação, ou *constant rate-of-strain* (CRS) tem notável aplicação na geotecnia por possibilitar a obtenção de parâmetros de compressão do solo em um tempo bastante reduzido, podendo ser executado em horas (KASSSIM *et al.*, 2016). Este ensaio é normatizado pela ASTM D 4186 (ASTM, 2012).

O ensaio CRS consiste na aplicação de uma compressão unidimensional gradual sobre uma amostra de solo saturada, sendo o deslocamento axial aumentado a uma taxa constante e com drenagem em sentido ao topo. São obtidas duas medidas essenciais neste ensaio: poropressão no topo (face não-drenada) e poropressão na base (face drenada) (FOX; PU; CHRISTIAN, 2014). A Figura 3 mostra um esquema de estrutura de uma célula de ensaio CRS.



Figura 3 - Esquema de funcionamento de um equipamento de ensaio CRS

Fonte: Adaptado de Kassim et al. (2016)

A Figura 4 mostra uma fotografia de um exemplo de equipamento para ensaio CRS.

Figura 4 - Fotografia de um equipamento de ensaio CRS do tipo Rapid Consolidation Cell Equipment (RACE)



Fonte: Kassim et al. (2016)

2.3.3 Índice de Compressão (Cc) e Taxa de Compressão (CR)

No trecho de compressão da reta virgem, a magnitude dos recalques é considerável, devido à destruição das ligações entre as partículas e posterior reorganização das mesmas (TERZAGHI; PECK; MERSIR, 1996).

Sabe-se que o trecho de compressão virgem das curvas *e* versus o logaritmo da σ'_v de amostras de boa qualidade não é retilíneo, ou seja, o índice de compressão C_c não é constante (ALVES; SANTA MARIA, 2001).

Embora o valor de C_c seja usualmente assumido como constante, Hanzawa, Fukaya e Suzuki (1990) destacam que para argilas normalmente consolidadas, C_c não é constante ao longo de toda a reta virgem, dependendo também do intervalo de carregamento. Os pesquisadores também destacam que o valor de C_c próximo à tensão de pré-adensamento é normalmente maior, isso porque nessa situação, a estrutura desenvolvida pelo efeito de "*aging*" está sendo destruída, tendendo a diminuir com o acréscimo de tensão, conforme mostrado na Figura 5.
Figura 5 - Relação típica entre C_C e σ'_v



Fonte: Adaptado de Onitsuka et al. (1995)

Nagaraj, Joshi e Murthy (1988) destacam que diversos estudos observaram que o recalque de uma camada de solo, para uma determinada taxa de tensão efetiva é proporcional a CR, que pode ser determinado conforme a Equação 4:

$$CR = \frac{C_C}{1+e_0} \tag{4}$$

Nagaraj; Joshi; Murthy (1988) observam que o recalque de adensamento primário (Equação 5) é mais dependente de CR do que Cc.

$$\rho = \frac{\Delta_e}{1 + e_0} * H_C \tag{5}$$

onde Δ_e representa a variação do índice de vazios devido ao acréscimo de carga; e_0 é o índice de vazios inicial; H_c é a altura da camada de solo mole. Importante ressaltar que os valores da taxa de compressão (CR) usados nesta pesquisa foram calculados conforme a Equação 4.

2.3.4 Qualidade das amostras

Dentre os principais fatores que influenciam na determinação do índice de compressão do solo (C_c), a qualidade da amostra é o preponderante. A qualidade da amostra é influenciada pelo grau de perturbação além do tamanho e forma do corpo de prova. Djoenaidi (1985) destaca que o atrito lateral entre a amostra e a célula de compressão durante o ensaio também influencia na qualidade do resultado do ensaio de determinação de C_c.

Lunne, Berre e Strandvik (1997) sugerem classificar a qualidade de amostras, com base na variação do índice de vazio correspondente à tensão efetiva de campo (e_{v0}) e o índice de vazio inicial da amostra ensaiada, conforme a Equação 6:

$$\frac{e_0 - e_{\nu 0}}{e_0} = \frac{\Delta e}{e_0}$$
(6)

Oliveira (2002) sugere uma adaptação da proposta de Lunne, Berre e Strandvik (1997) para avaliar a qualidade das amostras de solos, mais adaptada às argilas moles brasileiras, conforme apresentado na Tabela 1, onde se avalia a qualidade das amostras de solos argilosos moles em função da razão de sobreadensamento (OCR).

		∆ e/e ₀				
OCR	Muito Boa a Excelente	Regular a Boa	Ruim	Muito Ruim		
Lunne <i>et al.</i> (1997)						
1 - 2	< 0,04	0,04 - 0,07	0,07 - 0,14	> 0,14		
2-4	< 0,03	0,03 - 0,05	0,05 - 0,10	> 0,10		
		Oliveira (2002)				
1 – 2,5	< 0,05	0,05 - 0,08	0,08 - 0,14	> 0,14		
(00.10)						

Tabela 1 – Alguns critérios previamente publicados para classificação de amostras de solos argilosos moles

Fonte: Autor (2019)

Embora não tenha sido possível realizar uma avaliação da qualidade das amostras de solos nesta pesquisa, quando possível foi critério para a seleção das mesmas a classificação de qualidade realizada pelos autores das pesquisas consultadas, selecionando apenas as amostras de solos classificadas como de qualidade minimamente regular.

2.4 REDES NEURAIS ARTIFICIAIS

2.4.1 Fundamentos

A inteligência é um conceito de certa forma plural e intrigante, pois se revela inerente a fatores intrínsecos e ambientais da posição humana. Se da abordagem comum do termo inteligência emerge a noção de qualidade dos indivíduos, na aproximação da linguagem científica essa se refere à propriedade do comportamento (MIRANDA, 2002). De forma objetiva Colom *et al.* (2010) definem a inteligência como uma habilidade mental geral para raciocinar, resolver problemas e aprender.

Em uma abordagem preliminar, a inteligência é o resultado dos processos de adaptação, assimilação e acomodação. A estrutura biológica do indivíduo que permite a assimilação do conhecimento é continuamente desenvolvida a partir das interações com o meio, ou seja, da interação do sujeito com o objeto. A assimilação é em si a apropriação de conhecimentos e habilidades, que infere na modificação da estrutura mental existente, ajustando-as a permitir essa materialização da aprendizagem (ROCHA, 2017). Assim, a inteligência pode ser descrita como uma função adaptativa, pois com esse processo são coletadas informações do meio e as suas organizações, de forma a permitir que o sujeito da aprendizagem possa compreender melhor a realidade do contexto em que está inserido.

Não distante dessa abordagem emerge o conceito de Inteligência Artificial (IA). Luger (2013) define a IA como o ramo da ciência da computação que se ocupa da automação do comportamento inteligente. O mesmo pesquisador busca na fundamentação histórica do conceito de inteligência uma aproximação óbvia para a base essencial do estudo da Inteligência Artificial. Verifica-se na concepção do fundamento da inteligência uma não separação entre os estados mentais e as ações físicas (como discutido no conceito de adaptação). Assim, os processos mentais são alcançados por sistemas físicos (cérebro), que tem seu correspondente tecnológico o computador. A caracterização dos processos mentais físicos no contexto de IA é alcançada a partir de cálculo matemático. Dessa forma, as discussões no campo da Inteligência Artificial apontam para o potencial da aplicação da inteligência automatizada na solução de problemas complexos do cotidiano da sociedade.

A Inteligência Artificial ganha destaque com a sua aplicação em diversos campos da ciência como engenharia biomédica, engenharia de computação, sistemas de identificação e robótica, como exemplos, possibilitadas pelo avanço de sistemas computacionais e máquinas, deixando de ser apenas uma pretensa tecnologia do futuro. Nesse contexto emerge a lógica do Aprendizado de Máquina (*Machine Learning*), que consiste na capacidade das máquinas, a partir da operação de algoritmos coletarem dados, processá-los e aprender com eles. As máquinas são treinadas com um conjunto de exemplos para adquirem habilidades de aprenderem e executarem tarefas.

As Redes Neurais Artificiais (RNAs) se caracterizam por serem técnicas de IA que inspiradas no funcionamento do cérebro humano, de forma a simularem o seu funcionamento em sistemas computacionais de maneira simplificada. A principal habilidade de uma RNA reside na sua capacidade de generalização e aprendizagem a partir dos erros. As redes neurais artificiais se destacam por realizar três operações essenciais: aprender e armazenar conhecimento; aplicar o conhecimento adquirido na solução de problemas propostos; além de contrair novos conhecimentos a partir da aprendizagem constante, fruto da experimentação (KHANNA, 1990).

Seguindo os avanços tecnológicos do estado da arte atual em IA, as técnicas de Deep Learning (DL) e Extreme Learning Machines (ELM) se destacam pela possibilidade do emprego dessas ferramentas em soluções complexas de técnicas de aprendizagem. Entretanto, a eficácia do uso de ferramentas baseadas nessas técnicas para análise de dados depende bastante da quantidade de amostras de dados para treinamento e testes. Embora não haja uma definição da quantidade mínima de amostras necessárias, os trabalhos que utilizam essas técnicas utilizam bases de dados da ordem de milhares de amostras. O processamento de grande volume de dados demanda altos custos computacionais, sendo necessário o uso de processadores de alto desempenho como robustas unidades de processamento gráficas (GPU). DL, ou aprendizagem profunda, é uma técnica de rede neural artificial baseada no uso de várias camadas de neurônios escondidas. Dentre as redes neurais empregadas em DL, têm-se destacado as redes neurais convolucionais (RNC, ou CNN do inglês) e as redes neurais recorrentes (RNR, ou RNN do inglês). Melhor discussão de DL pode ser obtida em Schmidhuber (2015) e Lecun, Bengio e Hinton (2015). O princípio de funcionamento das máquinas de aprendizado extremo (ELM) é semelhante ao de uma

RNA convencional, entretanto, a aprendizagem não é baseada em gradiente descendente do algoritmo *backpropagation,* e sim na geração aleatória de uma matriz de pesos entre a camada de entrada e a oculta (YU *et al.*, 2015). Huang *et al.* (2015) apontam que na ELM, os nós ocultos são iniciados aleatoriamente sem a necessidade de ajustes, o que pode possibilitar a aprendizagem pelas conexões entre a camada oculta e a de saída.

Embora as técnicas de *Deeping Learning* e *Extreme Learning Machine* sejam uma realidade atual, o seu emprego é indicado quando se dispõe de uma base de dados ampla e recurso computacional mais eficiente. No âmbito desta pesquisa, a base de dados disponível de amostras de solo e recursos computacionais são limitados, o que sugere o treinamento das redes neurais aplicadas à pesquisa usando algoritmos de RNA que demandem menor esforço computacional e menor base de dados amostrais para se conduzirem a resultados satisfatórios de convergência das redes. Além disso, o uso de redes neurais artificias com o algoritmo *backpropagation* tem sido uma realidade em estudos de engenharia civil, conforme apontado por Kurnaz *et al.* (2016).

Essas capacidades atuais das redes neurais foram possíveis graças ao avanço dos recursos computacionais e do empenho de diversos cientistas, que trabalharam no desenvolvimento de algoritmos e aplicação de funções matemáticas em RNA, como discutido nos tópicos seguintes.

2.4.2 Inspiração para as redes neurais artificiais: redes biológicas

A genialidade humana sempre buscou estímulos nos movimentos das naturezas física e biológica das coisas para as descobertas e avanços da ciência. Embora o enriquecimento da ciência tenha atravessado dezenas de séculos, o Renascimento, iniciado em meados do século XIV, marca na história da humanidade o surgimento da ciência moderna, com destaque para o racionalismo e experimentalismo, que permitiram avanços significativos no campo científico (GOMES, 1996). A busca pelo conhecimento da anatomia do corpo humano teve destaque com Leonardo da Vinci que, aliando habilidades artísticas com a matemática e a medicina, legou à humanidade grandes contribuições acerca do corpo humano, que é de grande relevância por estar situado em um momento de amplo fomento da intelectualidade do homem. Dessa forma, o desenvolvimento do conhecimento sobre a estrutura do cérebro humano e do seu funcionamento foi constante ao longo da história, desde as primeiras observações de Galeno de que o cérebro controla o movimento do corpo até o entendimento da anatomia detalhada do cérebro descrita por *Ramón* e *Cajal* no século XIX (KÓVACS, 1996).

O entendimento da estrutura individual dos neurônios biológicos, bem como das suas conexões e o comportamento conjugado desses elementos, de elevada capacidade de processamento, compõem a base para os estudos das redes neurais artificiais. As RNAs tentam simular as funções das redes biológicas, porém apresentam grau de complexidade sensivelmente inferior às redes neurais naturais em situação de funcional e dinâmica. Enquanto RNAs utilizam comportamento as até aproximadamente 1.000 neurônios artificiais dispostas em mais de 1 milhão de conexões, o cérebro humano pode apresentar mais de 10¹¹ neurônios com aproximadamente 10¹⁴ conexões (GAGARIN; FLOOD; ALBRECHT, 1994). Braga, Carvalho e Ludemir (2007) sobre as redes neurais biológicas e as artificiais destacam que:

> "Como características comuns, pode-se citar que os dois sistemas são baseados em unidade de computação paralela e distribuída que se comunicam por meio de conexões sinápticas, possuem detectores de características, redundância e modularização das conexões" (p. 6).

2.4.3 Neurônios biológicos

Os neurônios biológicos são divididos, de maneira objetiva, em três seções: corpo celular (ou soma), dendritos e axônio. Cada seção tem funções específicas, mas complementares. Como qualquer célula biológica, o neurônio é delimitado por uma membrana celular de espessura muito fina, que é, entre outras funções biológicas, responsável pelo funcionamento elétrico das células nervosas.

A estrutura de um neurônio biológico pode ser observada na Figura 6 e na Figura 7.



Fonte: Adaptado de Cardoso (2000)





Fonte: Adaptado de Fausett (1994 apud ROCHA, 2018, p.48)

O corpo celular (*soma*) mede poucos milímetros de comprimento e nele reside o centro dos processos metabólicos da célula nervosa. Do corpo celular se projetam os dendritos com alguns milímetros de comprimento e o axônio, de comprimento variado e espessura uniforme, constituindo essas estruturas extensões filamentares que compõem as formas de comunicações entre os diversos neurônios. Os dendritos têm a missão de receber os impulsos nervosos, traduzidos como informações, provenientes de outros neurônios e conduzi-las até o *soma*. Os dendritos, por vezes possuem um volume considerável, formando assim uma árvore dendrital. Essas

informações recebidas de outros neurônios pelos dendritos são processadas a partir de conexões sinápticas, que conectam a árvore dendrital de um determinado neurônio aos axônios de outras células nervosas. Uma vez recebidas as informações pelo corpo celular, ali são processadas e novos pulsos são gerados, para posteriormente serem transmitidos pelo axônio até os dendritos dos neurônios conjugados. O fluxo das informações pelos neurônios é controlado pelas sinapses, que funcionam como válvulas instaladas entre a terminação axônica de determinado neurônio e o dendrito de outro. Esse ponto de contato determina a união funcional de uma rede neural biológica. Desse ponto de vista, os neurônios biológicos funcionam como uma espécie de dispositivo computacional do sistema nervoso, constituído por diversas entradas e uma saída. A partir do axônio estes diversos fluxos de informações que fluem através das conexões sinápticas são transcritos como pulsos elétricos, que são denominados de impulsos nervosos ou potenciais de ação. É justamente nesta intricada complexidade de sinais elétricos que reside o funcionamento das operações realizadas pelo cérebro humano. Essa transmissão de pulsos entre neurônios é controlada pelo potencial de ação, que é devido a perturbações do estado de repouso da membrana celular que envolve os neurônios que estão inseridos em regiões eletroquimicamente ativas (sinapses). A membrana por onde chega um estímulo originário de outra célula é denominada de pré-sináptica e a membrana dos dendritos é denominada de pós-sináptica. A comunicação dos estímulos dentro dessa zona intersináptica é realizada por substâncias conhecidas como neurotransmissores (KRUEGER-BECK et al., 2011).

2.4.4 Breve histórico das Redes Neurais Artificiais

O funcionamento dos neurônios biológicos foi a inspiração para McCulloch e Pitts (1943) proporem o primeiro modelo artificial de um neurônio biológico, denominado de (MCP). Os pesquisadores se empenharam em descrever os princípios do funcionamento de um neurônio artificial e apontar as suas capacidades computacionais. O modelo descrito pelos pesquisadores pode ser observado na Figura 8. Esse neurônio é composto por terminais de entrada (que representam os dendritos no neurônio natural) que recebem os valores iniciais x_0 , x_1 , x_2 ,..., x_n (representando as ativações dos neurônios precedentes) e uma saída, denominada

pelo caractere *j* ou *y* (seria o axônio do neurônio biológico). Os caracteres w_{j0} , $w_{j1},...,w_{jn}$ representam os pesos de ponderação de cada entrada, constituindo assim a estrutura das sinapses do neurônio. Neste modelo, o neurônio artificial é disparado quando a soma ponderada dos produtos x_iw_i atinge determinado limiar (*threshold*), com saídas igual a 1 ou 0.

Figura 8 - Neurônio de McCulloch e Pitts.

A partir do trabalho que descreveu o modelo do neurônio artificial MCP, outras pesquisas foram de grande destaque no desempenho de apresentar técnicas de aprendizado das RNAs. Ainda que uma revisão histórica sobre o desenvolvimento das RNAs seja de extrema importância, esta é uma tarefa extensa que foge ao escopo desta pesquisa, por essa razão é apresentado na Tabela 2 um breve resumo cronológico das principais publicações sobre redes neurais artificias, com base em Braga, Carvalho e Ludemir (2007), Schmidhuber (2015) e Lecun, Bengio e Hinton (2015).

Fonte: Adaptado de Diminsky (2000)

ANO	PESQUISADOR	AVANÇO
1943	McCulloch e Pitts	Descrição de um neurônio e apontamento das suas capacidades.
1949	Donald Hebb	Explica a teoria do aprendizado existente entre nodos biológicos e o reforço das ligações sinápticas entre os nodos excitados. Propôs que o cérebro humano muda suas conexões ao aprender, excitando novos agrupamentos neurais conforme executa tarefas. A regra de Hebb é empregada em vários algoritmos de aprendizado.
1958	Frank Rosenblatt	Desenvolveu o modelo <i>Perceptron</i> baseado no conceito MCP. Abordou conceitos de aprendizado supervisionado; ligações sinápticas entre neurônios excitados; limitações nas funções lógicas. O mais importante: propôs um algoritmo para treinar a rede para executar determinados tipos de funções.
1960	Widrow e Hoff	Sugeriram uma regra de aprendizado conhecida como regra de Widrow-Hoff, ou <i>regra delta,</i> que é baseada no método do gradiente descendente para minimização do erro de um neurônio com resposta linear.
1967	Widrow e Hoff	Adaline (Adaptative linear element);
1969	Minsky e Papert	Provaram que o <i>Perceptron simples</i> de Rosenblatt, de uma única camada, está limitado à resolução de problemas linearmente separáveis.
1982	John Hopfield	Mostrou a relação entre redes recorrentes autoassociativas e sistemas físicos.
1986	Rumelhart, Hilton e Williams	Descrição do algoritmo <i>backpropagation</i> (ou algoritmo de correção de erros).
1989	Lecun et al (1989)	Aplicação do algoritmo <i>backpropagation</i> em redes neurais convolucionais (Potencial de <i>Deep Learning</i>)
2006	Hinton; Hinton, Osindero e Teh; Bengio et al; Ranzato et al	Interesse pelo estudo de <i>Deep feedforward networks</i> pelo grupo de pesquisadores do Instituto para Pesquisas Avançadas do Canadá (CIFAR): introdução de procedimentos aprendizagem não supervisionada a partir de dados não rotulados

Tabela 2: Resumo Histórico de publicações sobre Redes Neurais Artificiais

Fonte: Adaptado de Braga, Carvalho e Ludemir (2007); Schmidhuber (2015); Lecun, Bengio e Hinton (2015)

2.4.5 Neurônio artificial

Partindo do entendimento sobre as redes neurais construído até aqui, pode-se apontar que as mesmas são estruturadas no tripé: armazenar conhecimento; aplicar o conhecimento adquirido na solução de problemas propostos; e se aperfeiçoar e adquirir novos conhecimentos a partir da experimentação. Essas são funções inspiradas no funcionamento do cérebro humano, de forma que a sua realização seja possível com o emprego de recursos computacionais que permitam a reprodução das experiências sinápticas de comunicação entre neurônios.

Nesse sentido, a partir do modelo de neurônio MCP, Rosenblatt (1958) propôs uma rede de múltiplas camadas do tipo *discriminadores lineares* denominada de *Perceptron,* que representa a ilustração de algumas propriedades fundamentais do sistema de inteligência natural extrapolado para aplicação em máquinas. A Figura 9 apresenta o modelo de um neurônio artificial inspirado no *Perceptron.*



Figura 9 - Modelo de neurônio artificial

Fonte: Adaptado de Haykin (2001)

Em que:

- X_j representam as entradas da rede (*inputs*);
- *w_{ki}* caracteriza um peso sináptico, onde *k* corresponde ao número do neurônio e *j* ao estímulo da entrada;

- *b_k* é um parâmetro de ponderação (chamado *bias*) que pode aumentar ou diminuir o valor da combinação linear das entradas da função de ativação, dependendo se for positivo ou negativo, respectivamente;
- f (.) é a função de ativação do neurônio;
- *u_k* representa a combinação linear dos sinais de entrada;
- *y_k* corresponde ao valor de saída do neurônio (*output*).

Da Figura 9 é possível aprender de w_{kj} que, quanto maior o peso (w), maior é a contribuição da entrada correspondente (k) para o somatório dos pesos. Assim, o processo de ponderação das entradas representa a taxa de aprendizado adquirido por uma RNA. Os pesos são ajustados à medida que o conjunto de dados de entrada é apresentado à rede. Dessa forma, o processo de aprendizado supervisionado em uma RNA é baseado no ajuste dos pesos sinápticos, de forma que o valor de saída seja aproximado ao valor esperado (*target*).

O neurônio artificial pode ser descrito matematicamente conforme as Equações 7 e 8:

$$u_k = \sum_{j=1}^n w_{kj} \cdot x_j \tag{7}$$

$$y_k = f(u_k + b_k) \tag{8}$$

Em que:

 u_k representa a saída do combinador linear;

 y_k representa o sinal de saída do neurônio;

b_k representa o *bias;*

f (.) é a função de ativação do neurônio;

wki representa os pesos sinápticos do neurônio k;

 x_j representa os sinais de entrada.

A função de ativação corresponde à ordem de amplitude normalizada do neurônio, que tem por objetivo limitar os sinais de entrada em um determinado intervalo, normalmente compreendido entre [0;1] e [-1;1]. Dessa forma, a função de ativação tem a missão de gerar o neurônio de saída a partir dos valores de entrada da rede (x_i) e dos pesos ajustados (w_{kj}), podendo ser, entre os tipos mais utilizados, em degrau, linear, sigmoidal (logística ou tangente hiperbólica) e gaussiana. As Figura 10, Figura 11, Figura 12, Figura 13 eFigura 14 apresentam os gráficos das principais funções. As funções de ativação podem ser expressas pelas Equações 9, 10, 11, 12 e 13:

- Função degrau:

$$f(v) = 1 \text{ se } v > 0 \text{ ou } 0 \text{ se } v < 0$$
 (9)

- Função linear:

$$f(v) = \alpha v \tag{10}$$

onde, α é o coeficiente angular limitante dos valores de *f* entre [0;1] ou [-1;1].

- Função logística:

$$f(v) = \frac{1}{1 + e^{-\alpha v}} \tag{11}$$

- Função tangente hiperbólica:

$$f(v) = \frac{e^{\alpha v} - e^{-\alpha v}}{e^{\alpha v} + e^{-\alpha v}}$$
(12)

onde α é uma constante limitante dos valores de *f* entre [0;1] ou [-1;1].

- Função gaussiana:

$$f(v) = e \frac{-(v-\mu)^2}{r^2}$$
(13)

onde μ é o centro (ponto médio) e r é o raio de abertura da função.

Função Linear 0.8 0.6 0.4 0.2 (n) 0 -0.2 -0.4 -0.6 -0.8 -0.8 -0.6 -0.4 -1 -0.2 0 0.2 0.4 0.6 0.8 u

Figura 10 - Gráfico da função linear

Fonte – Autor (2019)





Fonte – Autor (2019)

Figura 12 - Gráfico da função tangente sigmóide



Fonte – Autor (2019)





Fonte - Autor (2019).





Fonte – Autor (2019)

Assim como uma rede neurológica biológica, uma RNA também é constituída pela junção de diversos neurônios conectados entre si, sendo a maneira como estão vinculados a arquitetura da rede.

2.4.6 Arquitetura de redes neurais artificias

A arquitetura de uma RNA, na acepção da palavra, significa a maneira como nas redes neurais os seus neurônios estão organizados e conectados. A estrutura da rede pode ser em uma única camada ou em várias camadas. Às camadas situadas entre os neurônios de entrada e de saída, dá-se o nome de camada intermediária ou camada oculta/escondida, como é mais recorrente a denominação. O número de camadas ocultas é função do grau de complexidade do problema a ser resolvido, a qual pode ser estimada pela quantidade de variáveis. Dessa forma, a determinação de uma configuração apropriada da estrutura de uma RNA (número de camadas e de neurônios) é um grande desafio para a aplicação das redes por parte dos pesquisadores. A Figura 15 mostra o desenho esquemático de um tipo de RNA. Nela é possível perceber, que a rede é formada por uma camada de entrada com dois neurônios; existe apenas uma camada escondida com três neurônios; e uma camada de saída com um neurônio.



Figura 15 - Desenho esquemático mostrando uma RNA

Em geral é possível identificar fundamentalmente três diferentes classes de arquitetura de redes neurais artificiais, conforme descrito por Haykin (2001):

Rede neural de camada única alimentada para frente (feedforward): nesse tipo de rede os neurônios estão organizados em camadas. Na forma mais simples, existe uma camada de entrada de nós de origem que se projeta em uma camada de saída, sempre para frente (unidirecional). A Figura 16 mostra um tipo de rede feedforward de camada única. Importante destacar, que existe processamento apenas a partir da camada subsequente à camada de entrada, de forma a caracterizar a rede como sendo de apenas uma camada.





Fonte: Adaptado de Haykin (2001)

Redes neurais feedforward de múltiplas camadas: nesse tipo de rede há a presença de uma ou mais camadas ocultas, aqui aos neurônios dessas camadas ocultas, dá-se o nome de neurônios escondidos (*hidden neurons*). Na Figura 17 pode ser observada uma rede com quatro neurônios de entrada conectados à primeira camada oculta de 5 neurônios, e dessa camada segue a conexão à segunda camada oculta de 3 neurônios, e por fim os resultados do processamento são dispostos em dois neurônios (*outputs*).





Fonte: Adaptado de Haykin (2001)

Redes neurais com recorrência: esse tipo de rede apresenta realimentação dos pesos. Na rede recorrente o sinal de saída de um neurônio de saída realimenta a entrada de outros neurônios da rede na mesma camada, como pode ser observado na Figura 18.

Figura 18 - Rede neural com recorrência



Fonte: Adaptado de Haykin (2001)

2.4.7 Topologia da rede neural artificial

Ainda não há consenso sobre uma arquitetura ótima de uma RNA entre os pesquisadores. Isso se deve ao fato de não existir uma determinação precisa do número de camadas ocultas e de neurônios que seja adequada para a modelagem de qualquer problema. É preciso compreender que os problemas apresentados às redes são diversos, com variáveis de entrada e de saída distintos, que apresentarão respostas particulares em função da arquitetura da rede e das funções de ativação utilizadas. As RNAs não são corolários matemáticos. Elas são construídas a partir de metodologia estatística capaz de resolver problemas complexos em diferentes áreas de conhecimentos, como afirma Diminsky (2000).

Como observado, determinar o número de camadas ocultas e de seus neurônios não é tarefa trivial, sendo definida a partir da experiência empregada em soluções de problemas próximos a partir do processo de tentativa e erro. Entretanto, Hecht-Nielsen (1989) defende que uma única camada oculta de neurônio, operando uma função de ativação sigmoidal é suficiente para modelar uma grande diversidade de problemas práticos. Ainda, Flood e Kartam (1994a) sugerem que, com base no comportamento das funções de ativação das redes é possível notar ganho de potencial para desenvolver soluções que estejam mais próximas do padrão de treinamento, entretanto, os mesmos pesquisadores apontam que um grande número de neurônios torna as operações da rede mais lenta e susceptível de conduzir a soluções erradas. Outro ponto relevante com relação às camadas ocultas está na definição do número de neurônios que cada camada deve abrigar. Nessa direção, Caudil (1988) sugere que a camada oculta deve ser provida por número de neurônios regido pela expressão (2i + 1), onde i representa o número de variáveis de entrada. Há autores como Nawari, Liang e Nusairat. (1999) que apontam que melhores resultados podem ser encontrados iniciando a rede com um número pequeno de neurônios escondidos e paulatinamente aumentar a quantidade de neurônios. Nesse sentido, nota-se que uma boa abordagem para resolver o problema de topologia de uma rede é a adoção de diferentes configurações do número de camadas e de neurônios escondidos, de forma a buscar melhorar o desempenho da rede e acurácia dos resultados modelados, conforme observado por Najjar, Basheer e Naouss (1996).

Interessante abordagem de definição de topologia de RNA é encontrada em Fernandes e Lona (2005). Os pesquisadores classificam as RNAs em três tipos de acordo com o número de variáveis de entrada e saída. A Figura 19 mostra um esquema da tipificação das redes propostas pelos autores:

- ✓ Classe I: refere-se às redes que têm mais entradas do que saídas;
- Classe II: a rede possui mesmo número de entradas e saídas; e
- ✓ Classe III: a rede apresenta um número de saídas maior que as entradas.

Figura 19 - Critério de definição do número de neurônios na camada oculta



Fonte: Fernandes e Lona (2005)

Dessa abordagem, Fernandes e Lona (2005) assinalam que, para sistema a ser modelado com número pequeno de entradas e boa correlação entre as variáveis de entrada e saída, que se encaixam na Classe I, uma única camada oculta com número de neurônios definidos pela expressão (*N-1*) oferece bons resultados, onde *N* representa o número de variáveis de entrada. Para a Classe II, os pesquisadores recomendam utilizar pelo menos duas camadas escondidas. Para o caso de duas camadas ocultas é indicado o uso de 13 a 20 neurônios na primeira camada e cinco neurônios a mais na camada subsequente. Já para a Classe III, é indicado o uso de duas ou três camadas escondidas, sendo aplicados de 10 a 20 neurônios na primeira camada escondida, esta deve receber o mesmo número de neurônios da segunda camada.

2.4.8 Conjunto de dados e pré-processamento

A aplicação de uma rede neural obedece à necessidade do uso de uma técnica de otimização de processamento de dados diversos, para a resolução de um problema complexo. Por essa razão, o conjunto de dados de entrada deve ser escolhido com atenção, de forma a ser suficientemente representativo no domínio de interesse do problema a ser estudado.

Para melhorar a eficiência da rede durante a etapa de processamento dos treinamentos é importante que as variáveis (*inputs* e *outputs*) estejam dentro de um intervalo normalizado, de preferência [0;1] ou [-1;1], pois as principais funções de ativação operam nesses intervalos. Essa etapa é chamada de pré-processamento dos dados, e tem o objetivo de garantir que todas as variáveis recebam a mesma atenção durante o processo de treinamento (SHAHIN; JAKSA; MAIER, 2008).

2.4.9 Treinamento e testes

Superadas as etapas de seleção dos dados representativos do problema a ser modelado, topologia da rede e pré-processamento das variáveis de entrada e saída, segue-se para a fase de treinamento e teste da rede, que consiste em atividade de definição dos pesos adequados para melhorar o desempenho da RNA.

O primeiro passo consiste na separação de amostras para o treinamento e para os testes. É importante que os dados de treinamento sejam representativos de todo o domínio do problema processado. Nejad *et al.* (2009) argumentam que comumente se utiliza aproximadamente 85% dos dados para a fase de treinamento, e os 15% restantes são apresentados à rede somente após o seu desempenho ser considerado satisfatório na fase de treinamento. Os dados de testes são empregados na missão de avaliar a capacidade de generalização da rede. A intenção da generalização não é a de treinar a rede para reproduzir as soluções dos exemplos treinados, mas preferencialmente encontrar a solução generalizada para problemas similares ao do treinamento (FLOOD; KARTAM, 1994a).

O treinamento consiste na apresentação à RNA do conjunto de dados selecionado. A rede processa os dados do padrão de entrada, de forma a multiplicar as entradas

pelos pesos sinápticos. Esses produtos são em seguida submetidos às funções de ativação dos neurônios. Como resultado dessas funções, as saídas são as respostas a estes estímulos. Esses resultados são então comparados aos resultados de saída previstos, e desta comparação são extraídos os erros da fase de treinamento, que representam a diferença real entre a saída (*output*) estimada pela rede e o seu valor verdadeiro. A partir desse mecanismo de comparação, busca-se então ajustar os valores dos pesos sinápticos de ponderação das entradas, a partir de algoritmos matemáticos.

Na etapa de treinamento, o aprendizado da rede é dependente do modo que é executado o ajuste dos pesos sinápticos. Entre outros tipos, Zuluaga e Martínez (2011) destacam dois principais modos de treinamento de uma RNA:

- Supervisionado os exemplos de treinamento estão compostos por variáveis de entrada (x) e saídas (y). Assim, a rede pode aprender com a aproximação do valor esperado;
- Não-Supervisionado nesse tipo de treinamento apenas os valores de entrada são fornecidos (*x*). A RNA precisa aprender as características internas inerentes do conjunto de amostra.

Como síntese do treinamento e teste, o propósito da validação é assegurar que a rede tenha a habilidade de generalizar o aprendizado obtido das amostras de treinamento. A verificação da confiabilidade da rede é normalmente avaliada a partir do coeficiente de correlação, r, e do erro quadrado médio (*MSE*). Esses são parâmetros estatísticos empregados para determinar a correlação relativa e a qualidade do ajuste entre os dados estimados pela RNA e os esperados. Sobre o coeficiente de correlação, Shahin, Jaksa e Maier (2008) apontam a proposta de Smith (1986) para a intepretação dos valores de "r" entre [0; 1]:

✓	r ≥ 0,8	existe forte correlação entre duas variáveis;
✓	0.2 < <i>r</i> < 0.8	existe correlação entre duas variáveis; e

✓ r ≤ 0,2
 existe fraca correlação entre duas variáveis.

Dentre os algoritmos matemáticos de treinamento das RNAs, os mais utilizados são o de *error backpropagation* (retropropagação do erro) e de *Levenberg-Marquardt* (LM), (DIMINSKY, 2000; NETO *et al.*, 2006; OZER; ISIK; ORHAN, 2008).

2.4.10 Perceptron Multicamadas e o Algoritmo de retropopagação

O Perceptron proposto por Rosenblatt (1958) é formado por neurônios MCP e pela topologia de rede neural artificial, o que permite à rede criar regras de aprendizagem a partir da adaptação dos seus pesos sinápticos, conduzindo a RNA a ter capacidade de executar determinada tarefa. Para redes de camada única, a correção dos pesos sinápticos é realizada pela expressão $\Delta w = \eta e x$, onde Δw representa o ajuste de pesos; η é a taxa de aprendizagem e **e** corresponde ao erro de aprendizagem. Este tipo de rede com uma única camada tem a limitação de resolver problemas de comportamentos lineares. Por outro lado, os *Perceptron* de Múltiplas Camadas (MLP) são redes neurais artificiais de múltiplas camadas compostas por funções de ativação do tipo sigmoidal nas camadas escondidas. Com esse tipo de arquitetura, a camada oculta passa a utilizar função de ativação não linear, com a função sigmoidal, conferindo à rede um modelo genuinamente não linear. Para os MLP, diferentemente do *Perceptron* simples, o erro **e** não é obtido simplesmente da diferença entre a saída desejada e a saída calculada pela rede, pois existem agora camadas intermediárias, assim, para o treinamento das redes de múltiplas camadas, Rumelhart; Hilton e Williams (1986) propõem o algoritmo de retropropagação (backpropagation). O princípio do algoritmo de treinamento backpropagation é estimar o erro das camadas intermediárias a partir da estimativa do efeito que estas provocam no erro da camada de saída, utilizando-se o gradiente descendente. O erro é assim retropropagado na rede, de forma a corrigir os pesos sinápticos das camadas ocultas. Por essa razão, as funções de ativação precisam ser contínuas e diferenciáveis, como as funções logística e tangente hiperbólica (BRAGA; CARVALHO; LUDEMIR, 2007). As redes MLP com mais de uma camada intermediária é capaz de aproximar qualquer função (CYBENKO, 1989), o que demonstra ser este tipo de rede uma poderosa ferramenta para a solução de problemas complexos.

Diminsky (2000) descreve de forma sucinta um processo de treinamento em redes com algoritmo de treinamento *backpropagation*:

1 - as entradas dos exemplos do conjunto de treinamento são apresentadas à rede;

2 – estes dados são processados pela rede: em cada camada, a partir da multiplicação pelos pesos sinápticos, posterior somatório e aplicação da função de ativação, são fornecidas as saídas relacionadas às entradas apresentadas;

3 - as saídas fornecidas pela rede são comparadas com os valores reais obtidos dos experimentos e, desta variação, é calculado o erro;

4 - com o valor do erro, o ajuste para os pesos da última camada é calculado. O erro é então "retropropagado" na rede, corrigindo os pesos sinápticos das camadas escondidas, visando um melhor ajuste da RNA ao fenômeno a ser modelado.

Assim, o algoritmo *backpropagation* basicamente tem duas fases, para cada padrão apresentado, conforme aponta Silva (2003):

- ✓ feedforward: os sinais percorrem a rede em uma única direção, a partir da camada de entrada até a camada de saída;
- ✓ feedbackward: os erros se propagam na direção contrária ao fluxo de dados, indo da camada de saída até a primeira camada escondida.

Embora o algoritmo *backpropagation* seja um dos mais utilizados em aplicações práticas de RNA, outro algoritmo de destaque é o de Levenberg-Marquardt (LM).

2.4.11 Algoritmo de Levenberg-Marquardt (LM)

O algoritmo *Levenberb-Marquardt* (LM) é uma técnica matemática para otimização do algoritmo *backpropagation* (incorporação de algoritmo para mínimos quadrados não lineares). Hagan e Menhaj (1994) descrevem o LM como um algoritmo de aproximação do mínimo da função erro pelo método de Newton. Esta aproximação é descrita pela Equação 14:

$$\Delta x = [J^{T}(x)J(x) + \mu I]^{-1}J^{t}(x)e(x)$$
(14)

Onde *I* é a matriz identidade, e(x) representa o erro e *J* corresponde à matriz jacobiana. Para os mesmos autores, este tipo de rede é altamente eficiente comparado a outros métodos de aprendizagem quando aplicado em redes neurais artificiais limitadas a poucas centenas de pesos sinápticos.

2.4.12 Aplicações de redes neurais artificiais na engenharia civil

O campo de aplicação de redes neurais artificiais na solução de problemas diversos é bastante vasto e abrangente nos diferentes campos da ciência, e por esta natureza é uma importante ferramenta a ser utilizada na modelagem de distintos fenômenos ligados às áreas da engenharia, entre elas a engenharia civil. Desde o trabalho de Rumelhart, Hilton e Williams (1986) sobre o algoritmo *backpropagation*, o emprego de redes neurais artificiais ganhou impulso no meio acadêmico, o que possibilitou nos últimos anos destacado emprego em diversos trabalhos de engenharia civil, como na solução de problemas geotécnicos, tendo obtido relativo sucesso.

As aplicações de redes neurais em engenharia civil podem ser consultadas em diversos artigos publicados nos últimos anos, o que tornaria a referência a esses estudos bastante ampla, entretanto é abordado nesta pesquisa um recorte de importantes trabalhos publicados nas últimas décadas. Nesta direção, tem destacada importância a publicação de Shahin, Jaksa e Maier (2008), que elaboraram uma ampla revisão bibliográfica sobre o emprego das RNAs em diferentes campos da engenharia civil, como previsão de capacidade de carga, modelagem do comportamento de solos, caracterização da distribuição espacial dos solos, recalque de fundações, estabilidade de taludes, permeabilidade e condutividade, compactação de solos, entre outros.

Flood e Kartam (1994a) e Flood e Kartam (1994b) publicaram dois estudos complementares sobre aplicação de RNA em engenharia civil que subsidiam a compreensão do potencial das redes neurais pelos engenheiros civis, discutindo a importância técnica das principais funções de ativação e critérios de treinamento das redes. Os estudos de resistência mecânica de areias e condutividade hidráulica em argilas podem ser encontrados em Goh (1995), que encontrou excelentes resultados de treinamento de RNA para estimar a resistência de ponta de estacas (q_c) a partir das entradas de compacidade relativa (D_r) e tensão efetiva vertical (σ'_v).

Ainda, no espectro da geotecnia, pode-se apontar os trabalhos de Najjar, Basheer e Naouss (1996) que previram o valor da umidade ótima e máxima densidade seca do solo para projetos de compactação; Nawari, Liang e Nusairat. (1999) empregaram RNA para a análise de fundações profundas, tendo previsto com boa confiabilidade a capacidade de carga de estacas a partir do N_{SPT}; Nejad *et al.* (2009) estudaram a previsão de recalques a partir de correlação com resultados de ensaios *Standard Penetration Test* (SPT); Isik (2009) estudou a aplicação de RNA na previsão do índice de inchamento do solo (C_s); Benali e Bouzid (2013) também estudaram a capacidade de carga de estacas neurais artificiais.

Sobre a aplicação de RNA em análise estrutural, pode-se apontar o trabalho de Barbosa (2004) e Almeida (2012) que avaliaram o comportamento de estruturas metálicas com recursos de redes neurais.

Das e Basudhar (2008) usaram redes neurais artificias na estimativa de ângulo de atrito de argilas.

O trabalho de Diminsky (2000) constitui importante fonte de pesquisa em língua portuguesa sobre os fundamentos do emprego de RNA em engenharia civil.

Com relação à aplicação de RNAs em estudos de previsão do índice de compressão de argilas (Cc), Kolay, Rosmina e Ling (2008) e Ozer, Isik e Orhan (2008) treinaram redes neurais artificiais com propriedades índices do solo para estimar Cc; Park e Lee (2011) avaliaram a previsão de Cc através de RNA empregando as propriedades índices e₀, LL_{CUP}, w_n e IP; Kalantary e Kordnaeij (2012) analisaram centenas de amostras de argilas do norte do Irã com aplicação de redes neurais, com o treinamento de RNA com as varáveis w_n, e₀, LL_{CUP} e Gs; Kurnaz *et al.* (2016) analisaram 246 amostras de solo, a partir das propriedades índices do solo de limite de liquidez (LL_{CUP}), índice de plasticidade (IP), índice de vazios inicial (e₀) e umidade natural (w_n) onde obtiveram resultados melhores de previsão de C_c do que com o emprego de equações empíricas tradicionais;

Vale ressaltar, que na grande maioria dos trabalhos consultados, as redes foram treinadas com as variações do algoritmo *backpropagation*, em especial o algoritmo LM.

3. MATERIAIS E MÉTODOS

Este capítulo apresenta a base de dados organizada nesta pesquisa e utilizada na modelagem das RNAs e das correlações empíricas, em seguida expõe a organização do trabalho em termos metodológicos para a sua execução.

3.1 BASE DE DADOS INVESTIGADA

Para atingir objetivo principal desta pesquisa, que é avaliar o uso de redes neurais artificias na previsão do parâmetro de compressibilidade unidimensional de solos moles de diferentes regiões do litoral do Brasil e de outras regiões geológicas com propriedades geotécnicas semelhantes, a investigação contempla a incorporação de ensaios de laboratório de amostras de solos argilosos moles de sítios geológicos de diferentes estados brasileiros, e também amostras de outros países. As propriedades índices das amostras de solos investigadas são: índice de plasticidade (IP), umidade natural (w_n), índice de vazio inicial (e₀) e limite de liquidez determinado pelo método de Casagrande (LL_{CUP}), além do índice de compressão (C_c). Dessa forma é possível avaliar a capacidade de generalização das RNAs treinadas no âmbito desta dissertação de mestrado.

3.1.1 Organização da base de dados

A base de dados é compilada a partir de diversas pesquisas publicadas previamente na literatura brasileira e internacional, além de amostras de solos da Grande Vitória, ES, ensaiadas no Laboratório de Mecânica dos Solos da UFES. Ao todo foram agrupadas informações de 2.022 amostras de solos argilosos moles de 25 sítios geológicos ao redor do mundo. As amostras de solos investigadas são de origem marinha, coletadas na parte terrestre do litoral e também na porção *offshore*.

Do total de 2.022 amostras de solos argilosos, 295 são do litoral brasileiro, sendo 56 amostras ensaiadas no Laboratório de Mecânica dos solos da UFES. Complementa a

base de amostras brasileiras mais 66 amostras de solos argilosos de diferentes cidades do litoral brasileiro organizadas por Silva (2013),109 amostras, organizadas por Baran (2014), 49 amostras organizadas por Kootahi e Moradi (2016) e outras 7 amostras do litoral de Macaé são de Póvoa (2016), além de 8 amostras de Itaguaí-RJ publicadas por Queiroz (2013).

As demais amostras são organizadas por outros 4 pesquisadores: 391 amostras do litoral iraniano, no Mar Cáspio, organizadas por Kalantary e Kordnaeij (2012), 425 amostras da província de Surubaya, Indonésia, organizadas por Sari e Firmansyah (2013), outras 20 amostras da Indonésia foram publicadas por Widodo e Ibrahim (2012), as demais amostras (891) são organizadas por Kootahi e Moradi (2016), a partir de dezenas de publicações na literatura, que abrangem 25 sítios geológicos de solos argilosos marinhos.

A Tabela 3 mostra um resumo da quantidade e localidade dos sítios das amostras de solos investigadas.

Localidade	Organização	N°
Brasil: Grande Vitória – ES	Laboratório de Mecânica dos Solos da UFES	56
Brasil: Araranguá, Florianópolis, Itajaí, Palhoça, Penha e Tubarão – SC; Recife – PE; Rio Grande - RS	Baran (2014)	108
Brasil: Macaé – RJ	Póvoa (2016)	7
Brasil: Itaguaí – RJ	Queiroz (2013)	8
Brasil: Duque de Caxias e Queimados – RJ; Recife e Suape - PE; Florianópolis – SC; Santos – SP	Silva (2013)	66
Brasil: Juturnaíba, Macaé e Rio de Janeiro – RJ; Recife – PE	Kootahi e Moradi (2016)	50
Alaska: Shelikof Strait		6

Tabela 3 - Resumo da quantidade, localidade e organizador das amostras de solos moles investigadas (continua)

 Tabela 3 - Resumo da quantidade, localidade e organizador das amostras de solos moles

 investigadas
 (continuação)

Localidade	Organização	N°
Atlântico Sul: Walvis Ridge	_	15
Austrália: Queensland; New South Wales; Margem Continental Leste da Austrália; Ballina	-	52
Canadá: Otrawa; Ontário; Newfoundland; Vancouver; Breaufort Sea; Saguenay Fjord;		152
Chile/Peru: Margem Continental Chile/Peru	-	13
China: Hangzhou; Shanghai	Kootahi e Moradi (2016)	38
Coréia: Busan; Inchon; Costa Sudeste da Coréia; Kyunggi; Yeosu; Yongsan River		100
Egito: Mar Mediterrâneo	-	11
Escócia: Bothkennar	-	10
Finlândia: Helsinki	-	5
Índia: Visakhapatnam; Karvar; Andaman Islands		49
Indonésia: Pontianak; Surubaya	Sari e Firmansyah (2013)	445
Irã: Mazandaran	Kalantary e Kordnaeij (2012)	391
Irlanda: Belfast		13
Itália: Venice; Mar Adriático		25
Japão: Fukoaka; Saga; Yokohama; Kyushu Island; Oki Ridge e Kita Yamato; Saitama e Tokyo		171
Malásia: Klang; Costa Peninsular da Malásia; Perak; Sembilan;	Kootahi e Moradi (2016)	37
Noruega: Oslo; Drammen		25
Singapura: Changai; Singapore Arts Centre	-	24
Tailândia: Kangkok		18
Taiwan: Chunan		17
EUA: São Francisco; Califórnia; Margem Continental Cascadia; Boston; Massachusetts; Maine; Califórnia, Boston, Maine; Ottawa; Salt Lake City; Golfo do México; Califórnia; Carolina Trough		
Vietnã: Ba Ria-Vung Tau		17
TOTAL		2.022

A descrição estatística das amostras de solos moles investigadas está organizada na Tabela 4, mostrando os intervalos de valores máximo e mínimo de cada variável, além da média (μ), desvio padrão (*SD*) e o coeficiente de variação (*CV*).

Variável	Mínimo	Máximo	μ	SD	CV (%)
LL _{CUP} (%)	17,10	531,00	70,51	39,05	55,38
IP (%)	1,60	218,00	39,52	26,85	67,94
w n (%)	9,79	384,00	63,61	39,28	61,75
e ₀	0,28	9,82	1,70	1,01	59,41
Cc	0,05	5,21	0,76	0,62	81,58
CR	0,03	0,83	0,25	0,14	56,00

Tabela 4 - Descrição estatística das 2.022 amostras de solos moles investigadas

Fonte: Autor (2019)

A Figura 20 mostra o histograma de variação de cada variável, revelando a grande diferença de valores, conforme também apresentado pelo elevado coeficiente de variação (*CV*). Embora os intervalos de variação sejam altos, os histogramas de cada variável revelam que existe uma baixa representatividade de valores elevados de $e_0 > 4,0$, $w_n > 200\%$, LL_{CUP} > 200%, IP > 100% e C_C > 2,5, o que pode mostrar que estes dados sejam *outliers* (dados espúrios) para a realidade média da base de dados, corroborando a necessidade de pré-processamento estatístico dos dados antes da sua avaliação pelas RNAs, conforme Shahin, Jaksa e Maier, (2008).



Figura 20 - Histograma das variáveis analisadas: (a) C_C , (b) CR, (c) w_n (%), (d) e_0 , (e) LL_{CUP} (%) e (f) IP (%)

A Tabela 5 mostra a matriz de correlação entre todas as variáveis. Nota-se que C_c tem forte correlação positiva com as propriedades índices w_n e e₀ ($R^2 = 0,78$ para ambas). Por outro lado, as correlações de CR com as variáveis avaliadas decrescem significativamente, sendo o melhor valor encontrado para CR-IP ($R^2 = 0,44$). A Figura 21 ilustra a correlação entre C_c e CR com as demais propriedades índices do solo avaliadas.

	CR	w n (%)	e ₀	LL _{CUP} (%)	IP (%)
Cc	0,79	0,78	0,78	0,69	0,60
CR		0,42	0,42	0,40	0,44
w _n (%)			0,96	0,70	0,57
e ₀				0,68	0,56
LL _{CUP} (%)					0,89

Tabela 5 - Matriz de correlação (R²) entre as variáveis das amostras de solo investigadas

Fonte: Autor (2019)

Fonte: Autor (2019)

Quando avaliada a correlação CR-C_c, existe melhor ajuste para valores de C_c < 1,5, e uma grande dispersão a partir desse ponto.



Figura 21 - Correlação entre $C_C e CR e$ as demais propriedades índices das amostras de solos moles investigadas: (a) $C_C - w_n$ (%), (b) $C_C - e_0$, (c) $C_C - LL_{CUP}$ (%), (d) $C_C - IP$ (%), (e) $CR - C_C$, (f) $CR - w_n$ (%), (g) $CR - e_0$, (h) $CR - LL_{CUP}$ (%), (i) CR - IP (%)

O primeiro critério de seleção das amostras de solos para treinamento das redes neurais artificiais foi o uso do Ábaco de Casagrande, sendo selecionadas apenas as amostras de solos finos. Na Carta de Plasticidade de Casagrande, as amostras de solos são plotadas segundo os valores do índice de plasticidade (IP) no eixo das ordenadas e os valores do limite de liquidez no eixo das abcissas. Solos argilosos são localizados acima da reta inclinada denomina como Linha A. Já os solos orgânicos, mesmo que argilosos, e solos siltosos se situam abaixo da Linha A. A reta que determina a Linha A é determinada pela Equação 15:

$$IP = 0.73(LLCUP - 20)$$
(15)

Fonte: Autor (2019).

Ainda no Ábaco de Casagrande, a Linha U (Equação 16) é o limite superior para a identificação dos solos finos, pontos acima deste limite podem indicar ensaios que precisam de revisão. As amostras de solos finos são ainda classificadas secundariamente como de alta compressibilidade (H), ou de baixa compressibilidade (L), em função do valor do limite de liquidez, sendo a Linha B ($LL_{CUP} = 50\%$) o divisor entre as duas classes.

$$IP = 0.9(LLCUP - 8)$$
 (16)

A Figura 22 mostra o Ábaco de Casagrande para todas as amostras de solos investigadas. É possível observar que as amostras se dividem preferencialmente entre argilas (C), siltes (M) ou solos orgânicos (O) de alta plasticidade (H) e argilas de baixa plasticidade (CL).

É possível observar a presença de amostras de solos acima da Linha U. Essas amostras de solos foram removidas da base de dados. Também é possível notar que a grande maioria das amostras de solos estão abaixo de um limite de liquidez igual a 200%.



Figura 22 – Ábaco de Casagrande para as amostras de solos investigadas

Fonte: Autor (2019)

A grande variação do intervalo do limite de liquidez indica variabilidade na composição mineralógica das amostras de solo.

A Tabela 6 e a Tabela 7 analisam a variação do índice de compressão das amostras de solos investigadas de acordo com o Sistema Unificado de Classificação (SUC)

SUC	n	Mínimo	Máximo	μ	SD	CV (%)
СН	877	0,14	3,49	0,95	0,53	55,79
CL	667	0,05	2,01	0,29	0,21	72,41
MH-OH	405	0,21	5,21	1,16	0,76	65,52
ML-OL	73	0,12	1,94	0,40	0,30	75,00

Tabela 6 - Descrição estatística de C_C por tipo de solo segundo o SUC

Fonte: Autor (2019)



Tabela 7 - Variação de (a) C_c e (b) CR por tipo de solo segundo o SUC

Fonte: Autor (2019)

A maioria das amostras é classificada como argilas de alta plasticidade (CH), somando 877 ou 43,37% do total. Também compõe o grupo de amostras à direita da linha B, de alta plasticidade, as amostras de solos classificadas como silte ou solos orgânicos de alta plasticidade (MH-OH), representando 20,03% do total (n = 405). Esses dois grupos de amostras de solos de alta plasticidade apresentam ampla variação de valores de C_C, com os maiores valores de *SD*. As amostras de solos classificadas como argilas de baixa plasticidade (CL) representam 32,39% (n = 667). Essa classe de solo apresenta a menor variação de *SD*, o que mostra menor dispersão das amostras. Já as amostras de solo ML-OL representam apenas 3,61% da base de dados, assim como CL, essas amostras siltosas ou orgânicas de baixa plasticidade apresentam a menor variação entre mínimo e máximo valores de C_c. Embora relevantes, informações sobre a presença de matéria orgânica não são reveladas pela grande maioria dos autores

Importante destacar que, embora os dados utilizados nesta pesquisa sejam agrupados por trabalhos organizados por 8 pesquisadores, além dos fornecidos pelo Laboratório de Mecânica dos Solos da UFES, os mesmos pesquisadores compilaram os dados a partir de 93 publicações. O grande número de publicações envolvidas traz dificuldades para o controle da qualidade e confiabilidade dos resultados de laboratório envolvidos que fogem ao controle desta pesquisa.

3.1.2 Avaliação estatística da base de dados de solos argilosos moles

A preocupação em identificar possíveis incertezas em observações geotécnicas em condições de variabilidade espacial do solo é comumente levantada em estudos geotécnicos (MYERS, 2005; PAPAIOANNOU; STRAUB, 2012), existindo diversos métodos matemáticos e estatísticos para essa avaliação, entre eles a avaliação de discrepâncias por b*oxplot*, uma técnica de fácil operacionalização e largamente empregada em pesquisas de geotecnia para identificar *oultlier* (OLIVEIRA; ANTÔNIO, 2017). Segundo Pham *et al.* (2019), a existência de dados de entrada discrepantes em relação ao geral pode causar sérios problemas ao desempenho dos algoritmos de treinamentos das redes neurais artificiais.

Nesse sentido, com o intuito de avaliar a presença de valores atípicos às amostras de solos argiloso organizadas nesta pesquisa é empregada a plotagem das amostras, organizadas em grupos segundo o país de origem, e avaliadas as medidas de tendência central e distribuição de cada propriedade índice, para cada grupo definido. Essa análise exploratória das variáveis foi realizada no programa *Minitab* a partir do recurso gráfico *boxplot*.

O *boxplot,* também conhecido como diagrama de caixa é um recurso gráfico estatístico que permite visualizar a distribuição dos valores de determinada variável, e assim identificar valores discrepantes dos dados. O *boxplot* é formado pelas medidas estatísticas descritivas: mínimo, máximo, primeiro quartil, segundo quartil (ou mediana) e terceiro quartil. A Figura 23 mostra a representação de um *boxplot*, nela é possível identificar pontos que extrapolam os limites inferior e superior, que representam os valores discrepantes (ou *outliers*).



Figura 23 - Avaliação de outliers a partir de Boxplot

Fonte: Autor (2019)

Considerando que a base organizada possui uma ampla variabilidade espacial, contemplando diversos países litorâneos, a organização dos dados para avaliação no *boxplot* é realizada apenas para os sítios geológicos que possuem mais de 20 amostras, um valor mínimo para a avaliação de tendências indicado pelo programa

computacional empregado (MINITAB, 2017). Dessa forma, os dados dos países que possuem menos de 20 amostras não foram tratados estatisticamente para a identificação de *outliers*, entretanto, do universo de 2.022 amostras, apenas 86 se enquadram nessa categoria, as quais foram classificadas como amostras para treinamento das redes neurais artificiais.

A identificação dos *outliers* foi realizada segundo cada propriedade índice e do C_c das amostras de solos dos países estudados, refletindo assim uma tentativa de particularização de coleta das amostras, mesmo que extrapolando o sítio geológico para o contexto geográfico de um país. A partir dessa metodologia foram identificados 207 *outliers* do total de amostras de solo mole, restando assim 1.815 amostras aprovadas para serem utilizadas nos treinamentos das redes neurais artificias e nas correlações empíricas (somadas as amostras dos sítios geológicos com número menor que 20).

As Figuras 24, 25, 26, 27 e 28 apresentam os gráficos *boxplot* das medidas de tendência central e distribuições de cada propriedade índice e de C_c para os sítios geológicos dos países que possuem mais de 20 amostras, sendo que as figuras de índice (a) apresentam a distribuição das amostras após a remoção dos *outliers* e as figuras de índice (b) o contrário.





Fonte: Autor (2019).




Fonte: Autor (2019)

Figura 26 – Amostras de solos após (a) e antes (b) da remoção de *outliers* das amostras da propriedade índice w_n .



Fonte: Autor (2019).







Figura 28 – Amostras de solos após (a) e antes (b) da remoção de *outliers* das amostras do C_c

Observando os gráficos *boxplot* de LL_{CUP}, constata-se que os *outliers* identificados para o Brasil (BR) são majoritariamente de amostras com valor elevado de limite de liquidez, superior a 200%, mostrando que para este sítio são maiores as amplitudes de variação dessa propriedade índice, onde para os outros países são menores que 200%, mesmo antes da remoção dos valores atípicos. Importante destacar, que mesmo apresentando baixa amplitude de LL_{CUP}, o sítio geológico do Irã (IR), segue o Brasil com o segundo maior número de *outliers*.

A identificação dos *outliers* das amostras da propriedade índice IP seguiu a tendência de LL_{CUP}, com a remoção dos valores mais elevados do índice de plasticidade, sendo novamente o Brasil o sítio geológico com a maior variação dos valores máximos e mínimos.

Quanto a w_n, esta foi a propriedade índice que mais contribuiu para a remoção de *outliers*, sendo identificada para a maioria dos sítios geológicos investigados. Após a remoção dos *outliers*, as amostras ficaram restritas a valores inferiores a 200% contra aproximadamente 400% antes da remoção, sendo novamente o Brasil o sítio geológico com maior amplitude dessa propriedade índice.

A propriedade índice e₀ apresentou os valores discrepantes para as amostras com valores superiores ao limite superior do *boxplot*, com exceção do Irã que teve valores discrepantes abaixo do limite inferior. Após o tratamento estatístico foram excluídas as amostras com valores de e₀ superiores a 4,75.

Avaliando o *boxplot* para C_C, mais uma vez os *outliers* estão localizados acima dos limites superiores, sendo os sítios geológicos do Brasil (BR), Irã (IR) e Indonésia (ID) os maiores contribuintes.

No geral é possível destacar que as amostras brasileiras apresentam as maiores variações entre os limites máximo e mínimo das propriedades investigadas, o que reflete a complexidade geológica e geomorfológica desses depósitos sedimentares ao longo do litoral brasileiro, que apresenta grande extensão territorial. Nota-se também, que as amostras do sítio geológico iraniano, que possui 391 amostras, apresentam quase todas as amostras na faixa de baixa plasticidade (LL_{CUP} < 50%), assim como a China (CN) e Itália (IT).

Importante destacar que a remoção das amostras de solos que ocorreram nesta pesquisa foi necessária para restringir o grupo de amostras dentro de um intervalo de maior representatividade da base de dados, dado que a partir do limite de $C_c > 3,25$ o número de amostras de solo é limitado, o que poderia trazer dificuldade de generalização das RNAs treinadas.

A Tabela 8 apresenta um resumo estatístico das amostras de solo investigadas após a remoção dos *outliers*. No geral, os valores atípicos excluídos da base de dados estão concentrados acima do limite superior do gráfico *boxplot* onde as propriedades índices apresentam menor amplitude entre máximo e mínimo valores: LL_{CUP} máximo passa de 531% para 177% após tratamento estatístico, IP máximo passa de 218% para 117%, wn tem redução do valor máximo de 384% para 185%, a mesma tendência ocorre para e_0 que passou de um limite de 9,82 para 4,75 e também C_c, cujo limite superior foi reduzido de 5,21 para 3,25. Essa remoção de *outliers* mostra que as amostras de solos moles com maiores valores do índice de compressão (C_c > 3,25) apresentam as maiores divergências dentro da base de dados.

Variável	Mínimo	Máximo	μ	SD	CV (%)
LL _{CUP} (%)	17,10	177,00	67,19	30,51	45,41
IP (%)	1,60	117,00	37,60	23,24	61,81
W _n (%)	9,79	185,00	60,23	31,96	53,06
e ₀	0,37	4,75	1,62	0,83	51,23
Cc	0,08	3,25	0,71	0,53	74,65
CR	0,05	0,83	0,24	0,13	54,17

Tabela 8 - Descrição estatística das amostras de solos investigados após a remoção de outliers

Fonte: Autor (2019)

A análise da distribuição dos valores das propriedades índices das amostras de solos argilosos moles revelam uma variação mineralógica, que pode ser observada na distribuição da plasticidade, conforme a classificação das amostras de acordo com o Ábaco de Casagrande, com a presença de solos de compressibilidades entre baixa e alta, conforme a classificação de Castello e Polido (1986), apresentada na Tabela 9.

Tabela 9 - Classes de compressibilidade de solos finos

Compressibilidade	Cc	LL _{CUP}	%
Baixa	0 – 0,19	0 – 30	4,63
Média	0,20 - 0,39	31 – 50	31,85
Alta	> 0,39	> 50	63,53

Fonte: Castello e Polido (1986)

3.2 METODOLOGIA

A execução desta pesquisa de mestrado se desenvolveu a partir de revisão bibliográfica, que abrange os conteúdos pertinentes à fundamentação teórica que atravessam a compreensão das particularidades de depósitos de solos argilosos moles e as técnicas e recursos computacionais empregados na modelagem de redes neurais artificiais.

Concomitante à revisão bibliográfica se desenvolveram os treinamentos das redes neurais artificiais modeladas na pesquisa e a proposição de novas correlações empíricas de ajustes para prever C_c e CR.

Também foram investigadas diferentes correlações empíricas previamente publicadas na literatura para prever C_c e CR das amostras de solos investigadas.

A operacionalização da pesquisa observou a proposta genérica de Libault (1971 apud ROSS, 1990), que propunha a sistematização da pesquisa a partir da organização de informações primárias e secundárias segundo os níveis: Compilatório, Correlativo, Semântico e Normativo.

O primeiro nível, Compilatório, compreende a fase inicial da pesquisa que contempla a obtenção de dados relevantes e a sua organização. Nesta etapa são organizadas a revisão bibliográfica e a base de dados empregada na pesquisa.

No Nível Correlativo, segunda fase, os dados e informações preliminares são correlacionados, para assim, possibilitar a posterior interpretação dos resultados. Nesta etapa as redes neurais são treinadas empregando diferentes arquiteturas. Também, nesta etapa se processa a investigação do índice de compressão a partir de correlações empíricas.

A terceira etapa, Nível Semântico, corresponde à fase de interpretação das informações processadas, possibilitando a obtenção de resultados conclusivos a partir dos dados manipulados nas fases anteriores. Neste momento é possível a identificação de parâmetros que auxiliam na aplicação dos resultados.

No Nível Normativo, última fase, são apresentados os resultados obtidos nas etapas anteriores. Constituem os produtos finais da pesquisa: gráficos, tabelas, mapas, relatórios e textos finais.

A execução do treinamento das redes neurais artificias ocorreu no programa computacional *Matlab* seguindo diferentes critérios de arquitetura de redes, conforme é discutido nos tópico seguintes.

3.2.1 Operacionalização dos treinamentos das RNAs

O treinamento das RNAs foi executado no *software Matlab* usando as *toolboxes nftool* e *nntool.* As etapas de treinamento das redes nessas ferramentas por serem úteis a pesquisadores que desejarem fazer uso desse recurso, é apresentado em um mini tutorial de uso dessas ferramentas no APÊNDICE A.

3.2.2 Divisão da base de dados em treinamento e validação cruzada

Shahin (2013) destaca que, para um melhor desempenho, os modelos das redes neurais artificiais devem seguir uma sistemática que engloba a determinação da qualidade das variáveis de entrada, o pré-processamento dos dados, a definição da arquitetura da rede, além da divisão dos dados.

Normalmente, a divisão dos dados para entradas nas RNAs segue o critério de separação em 2 subconjuntos denominados de treinamento e validação cruzada. O conjunto de validação cruzada é apresentado à rede apenas após o seu treinamento, dessa forma representa a oportunidade de avaliação da capacidade de generalização do modelo. Nesse sentido, as propriedades dos conjuntos de validação cruzada e treinamento devem ser representativas da base de dados (SHAHIN; MAIER; JAKSA, 2004).

Nejad *et al.* (2009) argumentam que comumente se utiliza aproximadamente 85% dos dados para a fase de treinamento e 15% para a validação cruzada. Shahin, Mayer e Jaksa (2004) também argumentam que não existe uma relação direta entre essa proporção, embora tenham encontrado o valor de 24% da base de dados usada na validação cruzada como um número adequado.

A divisão adequada da base de dados pode mitigar o problema de *overfitting*, que consiste, da rede na fase de treinamento, de certa forma memorizar os resultados experimentados, perdendo assim a sua capacidade de generalização quando testada na fase de validação cruzada (SHAHIN, 2013). Esse erro de *overfitting* é marcado por uma diminuição contínua do erro nas amostras de treinamento enquanto aumenta no conjunto de teste.

Nesta dissertação foi adotado o critério de separar os dados na proporção de aproximadamente 80% para a fase de treinamento e 20% para a validação cruzada. A seleção das amostras para esses dois conjuntos seguiu os critérios de representatividade do índice de compressão. Dessa forma, tanto as amostras de treinamento quanto de validação cruzada cobriram todas as faixas de distribuição do histograma de variação de C_c, conforme pode ser observado na Figura 29.

Figura 29 - Histograma de distribuição de C_c para Treinamento (n = 1.471) (a) e Validação Cruzada (n = 344) (b)



Fonte: Autor (2019)

3.2.2.1 Organização das amostras de solos em grupos de avaliação

Após a remoção dos *outliers,* foram aprovadas 1.815 amostras de solos divididas entre 20 sítios geológicos distintos (extrapolando país como unidade geográfica dessa divisão). As amostras foram organizadas em 2 grupos para serem treinados pelas redes neurais artificiais e correlações empíricas.

O primeiro grupo (G1) contempla todas as 1.815 amostras de solos da base de dados. O grupo 2 (G2) representa as 255 amostras de solos do Brasil. Essa organização é uma tentativa de avaliar as particularidades de desempenho das redes treinadas para diferentes sítios geológicos e a capacidade de generalização. A Tabela 10 apresenta o resumo da organização da divisão das amostras nos 2 grupos de pesquisa.

Grupo	N° de Amostras	Origem
G1	1.815	Diversos Países
G2	255	Brasil

Tabela 10 - Divisão das amostras de solos moles para avaliação

Fonte: Autor (2019)

3.2.3 Propostas de treinamento das RNAs

A definição da topologia de uma RNA não é tarefa trivial, sendo na maioria das vezes definida a partir de experiências anteriores e de processos de tentativa e erro. Cybenko (1989) e Flood e Kartam (1994a) sugerem o número de uma ou dias camadas para a modelagem de problemas geotécnicos.

Com base em Hecht-Nielsen (1989) e Fernandes e Lona (2005) uma única camada escondida operando uma função de ativação do tipo sigmóide é suficiente para as redes treinadas convergirem para bons resultados. Os resultados Obtidos por Kurnaz *et al.* (2016) apontam que RNAs treinadas com o algoritmo *Levenberg-Marquardt* com apenas uma camada escondida, e função de ativação logística e linear operando na camada escondida e de saída, respectivamente, conduzem a resultados satisfatórios na previsão de Cc. Segundo Kolay, Rosmina e Ling (2008), o uso do algoritmo de treinamento *Levenberg-Marquardt* comparado a outros algoritmos presentes no *Matlab*, encontrou melhores resultados de estimativas de Cc para grupo de amostras de solos argilosos moles investigados em RNAs de apenas uma camada oculta.

Embora o treinamento de redes com apenas uma camada escondida tenha sido apresentado por diversos autores, Kalantary e Kordnaeij (2012) encontram melhor previsão do Cc em RNA com duas camadas escondidas, com 9 e 3 neurônios, respectivamente. As redes também foram treinadas com o algoritmo *Levenberg-Marquardt.* Os autores utilizaram a função de ativação logística (LogSig) na primeira camada oculta, tangente sigmóide (TanSig) na segunda camada oculta e linear (Purelin) na camada de saída.

Nesse sentido, esta pesquisa opta por investigar a previsão do C_c e CR a partir de RNAs estruturadas em uma e duas camadas ocultas. O algoritmo *Levenberg-Marquardt* é empregado, associado às funções de ativação LogSig, TanSig e Purelin,

operando em diferentes combinações. São treinadas assim diversas redes para cada condição de separação das amostras. O número de neurônios na primeira camada escondida é adotado como 2, 3, 5, 9, e 20. Na segunda camada escondida o número de neurônios é adotado como a metade do número de neurônios da primeira camada: 1, 2, 3, 5 e 10 (valores fracionados foram arredondados). Como pode ser observado na Tabela 11, para cada grupo de amostras de solos são treinadas 20 redes, sendo as 10 primeiras dotadas de apenas uma camada escondida operando as funções de ativação LogSig ou Tansig na camada oculta e Linear na saída. Já as redes com duas camadas ocultas, a partir da 11° são treinadas operando alternadamente em cada camada oculta as funções LogSig e Tansig, sendo adotada também a função de ativação Linear para a camada de saída.

Rede	N ° 1	N° 2	Algoritmo	F1	F2	FS
RN1	2	-	LM	LogSig	-	Linear
RN2	3	-	LM	LogSig	-	Linear
RN3	5	-	LM L		-	Linear
RN4	9	-	LM	LogSig	-	Linear
RN5	20	-	LM	LogSig	-	Linear
RN6	2	-	LM	TanSig	-	Linear
RN7	3	-	LM	TanSig	-	Linear
RN8	5	-	LM	TanSig	-	Linear
RN9	9	-	LM	TanSig	-	Linear
RN10	20	-	LM	TanSig	-	Linear
RN11	2	1	LM	LogSig	TanSig	Linear
RN12	3	2	LM	LogSig	TanSig	Linear
RN13	5	3	LM	LogSig	TanSig	Linear
RN14	9	5	LM	LogSig	TanSig	Linear
RN15	20	10	LM	LogSig	TanSig	Linear
RN16	2	1	LM	TanSig	LogSig	Linear
RN17	3	2	LM	TanSig	LogSig	Linear
RN18	5	3	LM	TanSig	LogSig	Linear
RN19	9	5	LM	TanSig	LogSig	Linear
RN20	20	10	LM	TanSig	LogSig	Linear

Tabela 11 - Resumo das topologias das RNAs treinadas

LM = Levemberg Marquardt, N^o 1 e N^o 2 = número de neurônios na 1^o e na 2^o camada escondida, respectivamente, F1 e F2 = função de ativação da 1^o e 2^o camada escondida, respectivamente, e FS = função de ativação na camada de saída.

Fonte: Autor (2019)

Conforme definido no APÊNDICE A, a etapa de treinamento das redes é dividido em três fases: treino, validação e teste. Assim, quando nesta pesquisa se fala em treinamento consiste nos resultados das amostras de treino, validação e teste de um ciclo de treinamento nas *toolboxes* utilizadas. Dessa forma, as amostras de solos para treinamento foram divididas nos percentuais de 70%, 15% e 15%, respectivamente. Durante o treinamento, a rede ajusta os valores dos pesos sinápticos de acordo com os erros; o percentual de validação é empregado para medir a generalização da rede, ainda dentro do grupo de amostras do treinamento, quando a rede durante o treinamento não apresentar mais melhora de generalização, o treinamento é interrompido. Já as amostras de teste não são apresentadas à rede para validação, ou seja, são medidas independentes dos ajustes ocorridos na fase de treino, revelando assim o desempenho final da rede. Em resumo, a etapa de validação

cruzada utilizada nesta pesquisa (com 20% das amostras de solos da base) consiste essencialmente na etapa de teste da fase de treinamento. A opção por utilizar a fase de validação cruzada está no fato de maior facilidade para identificar as amostras que não foram apresentadas às RNAs para o treinamento.

3.2.4 Correlações empíricas

O tempo de realização dos ensaios de adensamento, a necessidade de amostras indeformadas e os custos financeiros, muitas vezes representam dificuldades para a realização de ensaios oedométricos. Normalmente, para estudos preliminares, as correlações empíricas são ferramentas comumente empregadas. Nessa direção, diferentes estudos foram realizados correlacionando as propriedades índices do solo, tais quais LL_{CUP}, w_n, e₀ e IP com C_c e CR.

As correlações empíricas que utilizam as propriedades índices, consideram o princípio que a compressibilidade do solo é resultante de fatores como a mineralogia e o estado de tensões. Nesse sentido, LL_{CUP} e IP refletem a influência do percentual de partículas de argila e a sua mineralogia, assim como e₀ é uma propriedade que reflete os estados de tensões atual e de pré-adensamento, e w_n indica a medida de água livre nos vazios do solo.

Desde Skempton (1944) e Terzaghi e Peck (1967) diversas correlações empíricas foram propostas na literatura para correlacionar propriedades índices do solo com a sua compressibilidade.

Para efeitos comparativos, a presente pesquisa selecionou algumas correlações publicadas na literatura, comumente avaliadas em artigos científicos, para as estimativas de C_c e CR. Observa-se que a maioria das correlações empíricas publicadas para estimar C_c e CR são lineares com uma única variável de regressão.

Entre os trabalhos mais comumente discutidos sobre a compressibilidade de solos argilosos moles, destaca-se a publicação de Azzouz, Krizek e Cotoris (1976) sobre solos argilosos moles de sítios geológicos da Grécia e Estados Unidos. Os pesquisadores desenvolveram correlações empíricas a partir de técnicas de regressão sobre uma base de 700 amostras de solos indeformadas. Foram propostas

correlações lineares simples entre Cc ou CR e as propriedades índices de wn, LLcup, eo e IP e correlação empírica com múltiplas variáveis.

Kootahi e Moradi (2016) organizaram uma base de dados de solos marinhos de diversos países do mundo (mais de 1000 amostras) e propuseram correlações empíricas lineares simples e com múltiplas variáveis para prever C_c a partir de propriedades índices do solo. Os pesquisadores concluem que a variedade de correlações empíricas publicadas na literatura tende a subestimar C_c.

Widodo e Ibrahin (2012), a partir de uma base limitada de amostras de solos argilosos moles da região de Pontianak, na Indonésia propõem correlações empíricas simples para estimar C_c usando w_n, LL_{CUP}, e₀. As equações propostas apresentaram no geral R^2 abaixo de 0,5. Resultados semelhantes foram encontrados pelos pesquisadores utilizando outras correlações empíricas previamente publicadas na literatura. Ainda na Indonésia, Sari e Firmansyah (2013) desenvolveram correlação empírica usando w_n para estimar C_c para a região de Surubaya. Os autores destacam que as amostras de solos apresentam origem marinha e fluvial, sendo predominantemente argilas de baixa plasticidade. Os autores também avaliaram outras correlações empíricas usando propriedades índices do solo para estimar C_c para as amostras de Surubaya, os desempenhos medidos por R^2 estiveram próximos a 0,5.

Kalantary e Kordnaeij (2012) estudaram a compressibilidade de solos argilosos moles da província de Mazandaran, Irã, e propuseram correlações empíricas para prever Cc usando w_n e e₀, além de RNA. A base é composta por 391 amostras de solos preferencialmente argilosos de baixa compressibilidade, situadas no litoral iraniano do Mar Cáspio.

Park e Lee (2011) avaliaram 947 amostras de solos argilosos moles da Coréia e propuseram correlações empíricas usando w_n , e_0 e LL_{CUP} para estimar C_c. Os autores encontraram melhores resultados para a correlação usando w_n .

Oh e Chai (2006) também propuseram uma correlação empírica de múltiplas variáveis para estimar C_c para amostras de solos argilosos moles da Malásia.

Na literatura brasileira também existe um grande número de correlações empíricas publicadas, no geral com resultados semelhantes, para os sítios geológicos avaliados.

Nesta pesquisa são organizadas correlações empíricas de diferentes estados brasileiros. Cozzolino (1961), propõe correlações empíricas usando wn e LL_{CUP} para

estimar C_c para solos argilosos ricos em montmorilonita da cidade de São Paulo, SP, e de um sítio de argila siltosa localizado em Santos, SP. Castello e Polido (1986) e Bicalho *et al.* (2014) propuseram correlações empíricas para estimar C_c usando w_n, e₀ e LL_{CUP} para amostras de solos moles do litoral da Grande Vitória, ES.

Para sítios geológicos do Rio de Janeiro, Almeida *et al.* (2008) e Baroni e Almeida (2017) propuseram correlações empíricas simples para estimar C_c. Importante destacar a presença de matéria orgânica nas amostras avaliadas, o que é caracterizado pela alta variabilidade da umidade natural (10% a 700%).

Na Tabela 12 são apresentadas as correlações empíricas para estimar C_c avaliadas nesta pesquisa, nela é possível avaliar o intervalo dos valores das propriedades índices base para as correlações, além do número de amostras de solos que cada pesquisador utilizou para propor as correlações empíricas e o local de origem das amostras de solos.

Variável	Referência	ID	Correlação Empírica	Localidade	Intervalo	n	Grupos de Avaliação
	Azzouz, Krizek e Cotoris (1976)	C1	$C_{C} = 0.0100 w_{n} - 0.05$	Grécia e EUA	5 < w _n < 128	717	G1, G2
	Castello e Polido (1986)	C2	$C_{C} = 0.014 w_{n} - 0.17$	Brasil (ES)	19 < w _n < 97	64	G2
	Almeida et al. (2008)	C3	$C_{C} = 0.013 w_{n}$	Brasil (RJ)	10 < w _n < 450	-	G1, G2
	Kalantary e Kordnaeij (2012)	C4	$C_C = 0,0074 w_n - 0,007$	Irã (Mazandaran)	$10,2 < w_n < 70$	400	G1
Wn	Widodo e Ibrahin (2012)	C5	$C_{C} = 0,0102(w_{n} + 11,57)$	Indonésia (Pontianak)	34,86 < w _n < 90,96	20	G1
	Sari e Firmansyah (2013)	C6	$C_C = 0.0143 w_n - 0.0165$	Indonésia (Surubaya)	ésia (Surubaya) -		G1
	Bicalho et al. (2014)	C7	C _C = 0,0128w _n - 0,0951 Brasil (ES)		19 < w _n < 97	80	G2
	Kootahi e Moradi (2016)	C8	$C_C = 0.012(w_n - 7.75)$	Diversos países	10 < wn < 384	500	G1, G2
	Baroni e Almeida (2017)	C9	$C_C = 0,011 w_n$	Brasil (RJ)	$60 < w_n < 700$	85	G2
	Cozzolino (1961)	C10	$C_{C} = 0.0186(LL_{CUP} - 30)$	Brasil (Santos)	47 < LL _{CUP} < 136	-	G2
	Terzaghi e Peck (1967)	C11	$C_{C} = 0,009(LL_{CUP} - 10)$	-	20 < LL _{CUP} < 130	30	G1, G2
-	Azzouz, Krizek e Cotoris (1976)	C12	$C_{C} = 0,006(LL_{CUP} - 9)$	Grécia e EUA	18 < LL _{CUP} < 98	678	G1, G2
LLCUP	Park e Lee (2011)	C13	$C_{\rm C} = 0,014(LL_{\rm CUP} - 0,168)$	Coréia	$6,9 < LL_{CUP} < 144$	947	G2
	Widodo e Ibrahin (2012)	C14	$C_{C} = 0,01706(LL_{CUP} - 1,3)$	Indonésia (Pontianak)	$17,10 < LL_{CUP} < 62,46$	20	G1
	Bicalho <i>et al.</i> (2014)	C15	$C_{C} = 0,011(LL_{CUP} - 8,3)$	Brasil (ES)	11 < LL _{CUP} < 40	80	G1, G2
	Kootahi e Moradi (2016)	C16	$C_{C} = 0.012(LL_{CUP} - 8.0)$	Diversos países	19 < LL _{CUP} < 395	500	G1, G2
	Azzouz, Krizek e Cotoris (1976)	C17	$C_C = 0,400e_0 - 0,100$	Grécia e EUA	0,276 < e ₀ < 2,12	717	G1, G2
	Castello e Polido (1986)	C18	$C_{\rm C} = 0,228e_0 + 0,22$	Brasil (ES)	0,1 < e ₀ < 1,53	54	G2
	Bicalho et al. (2014)	C19	$C_C = 0,4196e_0 - 0,1163$	Brasil (ES)	0,1 < e₀ < 1,53	80	G1, G2
e ₀	Kootahi e Moradi (2016)	C20	C _C =0,510(e ₀ -0,33)	Diversos países	0,3 < e ₀ < 8,8	500	G1, G2
	Baroni e Almeida (2017)	C21	$C_{C} = 0,5284e_{0}$	Brasil (RJ)	1,3 < e ₀ < 8,8	74	G2
	Widodo e Ibrahin (2012)	C22	$C_{C} = 0,5217 \ (e_{0} - 0,20)$	Indonésia (Pontianak)	0,88 < e ₀ < 7,11	20	G3
	Kalantary e Kordnaeij (2012)	C23	$C_{C} = 0,3608e_{0} - 0,0713$	Irã (Mazandaran)	0,357 < e ₀ < 1,882	400	G1
eo, LL _{CUP} , wn	Azzouz, Krizek e Cotoris (1976)	C24	$C_C = 0.37(e_0 + 0.003LL_{CUP} + 0.0004w_n - 0.34)$	Grécia e EUA	-	678	G1, G2
eo, LL _{CUP} , IP	Oh e Chai (2006)	C25	$C_C = 0.5393 e_0 - 0.0074 Pl + 0.0049 LL_{CUP} - 0.1248$	Malásia	-	60	G1, G2
e ₀ , LL _{CUP}	Kootahi e Moradi (2016)	C26	$C_{C} = 0.374(e_{0} + 0.01LL_{CUP} - 0.47)$	Diversos países	-	500	G1, G2

Tabela 12 - Correlações empíricas previamente publicadas na literatura utilizadas para estimar C_{C}

Além das correlações empíricas para estimar C_c, também são utilizadas correlações empíricas previamente publicadas na literatura para prever CR.

Cox (1968 apud NAGARAJ; JOSHI; MURTHY, 1988) desenvolveu correlações empíricas para estimar CR para solos marinhos do sudoeste asiático. Enquanto Balasubramaniam e Bremer (1981) apresentaram correlações para estimar CR usando apenas amostras de solos argilosos de Bangkok e Tailândia. Nagaraj, Joshi e Murthy. (1988) a partir de técnicas matemáticas de derivação de equações de compressibilidade de solos saturados e normalmente adensados propõem uma equação linear simples para estimar CR usando LL_{CUP}.

Elnaggar e Krizek (1970) avaliando argilas de fácies orgânicas, inorgânicas e siltosas de diferentes partes dos Estados Unidos propõem uma correlação entre CR e e₀. Vidalie (1977) propõe correlação para estimar CR usando w_n, isso para argilas da França.

Crumley, Fernándes e Regalado (2003) estudaram amostras de solos moles de origem aluvial de Porto Rico, encontrando bons resultados para estimar CR usando w_n.

Na Tabela 13 são apresentadas as correlações empíricas para estimar CR avaliadas nesta pesquisa.

Variável	Referência	ID	Correlação Empírica	Localidade	Intervalo	n	Grupos de Avaliação
	Cox (1968 apud NAGARAJ et al.,1988)	CR1	$CR = 0,0043w_n$	Sudeste da Ásia	-	-	
Wn	Vidalie (1977)	CR2	$CR = 0.403 logw_n - 0.478$ $CR = 0.0039 w_n + 0.013$	França	w _n > 100 w _n < 100	-	
	Balasubramaniam e Bremer (1981)	CR3	$CR = 0,00566w_n - 0,037$	Bangkok e Tailândia	-	-	_
	Crumley, Fernándes e Regalado (2003)	CR4	$CR = 0,001w_n + 0,114$	Porto Rico		400	_
	Cox (1968 apud NAGARAJ et al., 1988)	CR5	$CR = 0,0054LL_{CUP}$	Sudeste da Ásia	-	-	_
	Azzouz, Krizek e Cotoris (1976)	CR6	$CR = 0,002(LL_{CUP} + 9)$	Grécia + EUA	18 < LL _{CUP} < 98	678	G1, G2
LLCUP	Nagaraj <i>et al.</i> (1988)	CR7	$CR = 0,003LL_{CUP}$	Diversos países	-	-	_
	Balasubramaniam e Bremer (1981)	CR8	$CR = 0,00463LL_{CUP} - 0,013$	Bangkok e Tailândia	-	-	_
	Elmaggar e Krizek (1970)	CR9	$CR = 0,156e_0 + 0,0107$	EUA	e ₀ < 2,0	230	_
e_0	Azzouz, Krizek e Cotoris (1976)	CR10	$CR = 0.14(e_0 + 0.007)$	Grécia e EUA	0,276 < e ₀ <2,12	717	
e_0, LL_{CUP}, w_n	Azzouz, Krizek e Cotoris (1976)	CR11	$CR = 0,135(e_0 + 0,01LL_{CUP} - 0,002w_n - 0,06)$	Grécia e EUA	-	678	_

Tabela 13 - Correlações empíricas previamente publicadas na literatura utilizadas para estimar CR.

Fonte: Autor (2019)

3.2.5 Propostas de novas correlações empíricas

Com base no conjunto de dados organizados nesta pesquisa são propostas novas correlações empíricas de ajuste para a estimativa de C_c e CR. As novas correlações empíricas de ajuste são modeladas para cada grupo específico de análise, ou seja, para os grupos G1 e G2. Para cada grupo de análise são desenvolvidas correlações simples C_c-w_n, C_c-e₀ e C_c-LL_{cuP}, além de uma correlação de múltiplas variáveis C_c-w_n, e₀, LL_{cuP}. A mesma estratégia se repete para o desenvolvimento de correlações para estimar CR.

Para a criação das correlações empíricas de ajuste foi utilizado o programa estatístico *Minitab.* As correlações foram desenvolvidas utilizando apenas a base de amostras separadas para treinamento, para cada grupo de análise.

A partir das amostras separadas para treinamento de cada grupo, para cada propriedade índice foi plotada a sua distribuição no eixo X e no eixo Y C_C medido, assim, por regressão linear, pontos fora de um intervalo de confiança de 95% foram removidos. Ainda, para confirmar a validade da correlação encontrada foi empregada a análise dos resultados dos resíduos entre C_C medido e C_C estimado pela correlação criada. Neste teste de normalidade, assume-se que a distribuição dos resíduos é independente e tem uma distribuição normal (SANTOS, 2017). O teste de hipótese de Kolmogorov-Smirnov foi utilizado para análise de aderência dos resultados.

No teste de Kolmogorov-Smirnov (Teste *KS*), o resultado do teste (D_{KS}) é comparado ao valor crítico (D'_{KS}) para avaliação da hipótese. Caso o valor de *KS* seja maior que D'_{KS} , a hipótese H_0 com 1- α de confiança pode ser rejeitada, em que H_0 representa a hipótese nula (ou seja, a hipótese assumida como verdadeira) e α representa o nível de significância (MINITAB, 2017). Quando a hipótese de normalidade for reprovada, pontos fora do intervalo de confiança de 95% são removidos da base, e em seguida repetido o teste (BERGER; ZHOU, 2014). O parâmetro *Valor-P* no teste hipótese de Kolmogorov-Smirnov maior que 0,05 índica que a distribuição dos resíduos da regressão é normal.

A Tabela 14 e a Tabela 15 mostram as correlações empíricas de ajuste criadas para cada grupo de análise para estimar C_c e CR. Nota-se que as correlações empíricas

simples com w_n e e₀ e as com múltiplas variáveis apresentam as maiores correlações positivas com C_c. As correlações empíricas propostas para o grupo G1, embora apresentem valores elevados de R^2 , normalmente não mostram aderência aos testes de normalidade (*Valor-P* < 0,05).

Variável	Correlação Empírica	Intervalo	Ν	R²	Valor-P	Grupos de Avaliação
\٨/	Cc = 0,01389wn - 0,1700 (Eq. Cc-a)	14,50 < w _n < 167,00	1.261	0,91	< 0,05	G1
۷۷n	Cc = 0,01595w _n - 0,2854 (Eq. Cc-b)	19,23 < w _n < 167,00	156	0,86	> 0,05	G2
LL _{CUP}	C _C = 0,01265LL _{CUP} – 0,2036 (Eq. C _C -c)	19,00 < LL _{CUP} < 177,00	1.192	0,81	< 0,05	G1
	C _C = 0,01875LL _{CUP} - 0,3688 (Eq. C _C -d)	$28,00 < LL_{CUP} < 140,00$	159	0,69	> 0,05	G2
0	C _C = 0,5166e ₀ – 0,1752 (Eq. C _C -e)	$0,45 < e_0 < 4,39$	1.237	0,91	< 0,05	G1
e ₀	$C_{c} = 0,6032e_{0} - 0,3029$ (Eq. C_{c} -f)	$0,64 < e_0 < 4,39$	157	0,85	> 0,05	G2
e ₀ , LL _{CUP} ,	$C_{C} = 0,00285w_{n} + 0,3193e_{0}$ - 0,002658LL _{CUP} - 0,20647 (Eq. C _C -g)	14,50 < w _n < 138,00	1.082	0,91	< 0,05	G1
Wn	$C_c = 0,00489w_n + 0,3660e_0$ + 0,00520LL _{CUP} - 0,5083 (Eq. C _c -h)	19,23 < w _n < 185,00	157	0,86	> 0,05	G2

Tabela 14 - Correlações empíricas de ajuste propostas para estimar Cc

Fonte: Autor (2019)

Tabela 15 - Correlações empíricas de ajuste propostas para estimar CR

Variável	Correlação Empírica	Intervalo	Ν	R²	Valor-P	Grupos de Avaliação
\ A /	CR = 0,00333wn + 0,03007 (Eq. CR-a)	14,50 < w _n < 167	1.024	0,80	< 0,05	G1
۷۷n	CR = 0,00234w _n + 0,0919 (Eq. CR-b)	19,23 < w _n < 167	166	0,56	< 0,05	G2
	CR = 0,00319LL _{CUP} + 0,01580 (Eq. CR-c)	19,00 < LL _{CUP} < 112,00	1.082	0,75	< 0,05	G1
	CR = 0,00423LL _{CUP} + 0,0034 (Eq. CR-d)	28,0 < LL _{CUP} < 135,00	152	0,67	> 0,05	G2
0-	CR = 0,1294e ₀ + 0,02189 (Eq. CR-e)	$0,45 < e_0 < 2,59$	956	0,83	< 0,05	G1
eo	CR = 0,08975e ₀ + 0,0914 (Eq. CR-f)	$0,64 < e_0 < 4,39$	160	0,85	> 0,05	G2
eo, LL _{CUP} ,	$\begin{array}{l} CR = 0.01847 - 0.00022 w_{n} + \\ 0.0926 e_{0} + 0.00112 LL_{CUP} \\ (Eq. \ CR-g) \end{array}$	14,50 < w _n < 136,00	1.043	0,82	< 0,05	G1
Wn	$\label{eq:criterion} \begin{array}{l} {\sf CR} = 0,00056 w_n + 0,0376 e_0 \\ + 0,01340 LL_{CUP} + 0,0802 \\ ({\sf Eq. CR-h}) \end{array}$	19,23 < w₁ < 185,00	176	0,56	> 0,05	G2

Fonte: Autor (2019)

Já o grupo das amostras brasileiras (G2), embora também seja heterogêneo, com grandes variações das propriedades índices, apresentou valores elevados do coeficiente de determinação.

Diferente das correlações para estimar C_C, as correlações empíricas de ajuste para prever CR mostraram, no geral, dificuldades de aderência aos testes de normalidade (*Valor-P* > 0,05) e moderados valores de R^2 .

Na Figura 30 são apresentadas graficamente as correlações empíricas propostas nesta pesquisa para estimar C_C em comparação às publicadas previamente na literatura usando as propriedades índices w_n, e₀ e LL_{CUP}. Essa relação indica que o aumento das propriedades índices implicam em maiores compressibilidades das amostras de solos argilosos moles. Nota-se que todas as correlações apresentam relação direta e positiva entre as propriedades índices e C_C. Pode-se atribuir a diferença entre elas à variação da base de dados de origem. As correlações C_C-w_n apresentam pouca diferença de inclinações das retas de correlação, com maior proximidade entre as correlações empíricas C2 (CASTELLO; POLIDO, 1986), C3 (ALMEIDA *et al.*, 2008), C7 (BICALHO *et al.*, 2014) e C_C-a (ESTE ESTUDO, 2019).

Figura 30 - Representação gráfica das correlações empíricas investigadas para estimar C_C usando w_n (**a**), e_0 (**b**) e LL_{CUP} (**c**)



Fonte: Autor (2019)

Assim como as correlações C_c-w_n, as correlações C_c-e₀ apresentam baixa variação na inclinação das retas das correlações empíricas. Embora as correlações empíricas desenvolvidas para solos marinhos tendem a superestimar os valores de C_c, a

correlação C18, proposta por Castello e Polido (1986) apresentou maior variação em relação as demais correlações lineares. As correlações empíricas Equação Cc-e, proposta nesta pesquisa e C20, de Kootahi e Moradi (2016) tiveram inclinação praticamente idênticas, isso se explica porque os dados organizados por estes pesquisadores compõem a maior parte da base de amostras desta pesquisa de mestrado.

As correlações Cc-LL_{CUP}, apresentam maior variabilidade nos resultados avaliados. As correlações empíricas C11, proposta por Terzachi e Peck (1967) e C12, proposta por Azzouz, Krizek e Cotoris (1976) mais se aproximam da correlação empírica de ajuste C_c-f, proposta nesta pesquisa.

A Figura 31 apresenta graficamente as correlações empíricas propostas nesta pesquisa para estimar CR comparadas às publicadas previamente na literatura usando as propriedades índices wn, eo e LL_{CUP}.

No geral, as correlações empíricas analisadas apresentam uma grande variação das retas de inclinação, especialmente quando usam as variáveis LL_{CUP} e w_n. Por outro lado, como mostra a Figura 31, as correlações CR-e₀ apresentam maior proximidade entre as retas de inclinação, o que é esperado, sendo CR calculado como C_c / (1 + e₀).





Fonte: Autor (2019)

3.2.6 Metodologia de avaliação dos resultados

A definição de qual correlação empírica escolher não é tarefa trivial, requer critério na sua seleção, o que sugere o uso de técnicas estatísticas de avaliação da confiabilidade das equações usadas e investigações geotécnicas. O mesmo critério também é dispensado na seleção das RNAs com desempenhos satisfatórios.

Como metodologia para a avaliação da capacidade de previsões de correlações empíricas e RNAs, alguns critérios estatísticos são avaliados nesta pesquisa: (i) a raiz do erro quadrático médio – *root mean squared error* (*RMSE*), (ii) o coeficiente de determinação (R^2), (iii) a variação do índice de compressão medido e estimado (K), (iv) índice de classificação – *ranking index* (*RI*) e (v) índice de distância – *ranking distance* (*RD*). Essa metodologia é baseada nas publicações prévias de Briaud e Turker (1988), Cherubini e Orr (2000), Ozer; Isik e Orhan (2008), Onyejekwe *et al.* (2015) e Güllü, Canakci e Alhashemy (2016).

O *RMSE* é a raiz do somatório do quadrado da diferença entre os valores estimados e medidos, dividido pelo número de observações, o que consequentemente atribui maior peso aos maiores erros. Valor próximo de zero indica melhor desempenho do modelo. *RMSE* é calculado de acordo com a Equação 17.

$$RMSE = \sqrt{\frac{1}{N} \sum_{1}^{N} (C_{Cestimado} - C_{C medido})^2}$$
(17)

onde *N* representa o número de observações, C_c estimado é o valor de C_c estimado pelas correlações empíricas ou pelas RNAs; C_c medido é o valor de C_c medido em laboratório.

O coeficiente de determinação (R^2), em geral tem por objetivo medir a relação existente entre duas variáveis distintas, mostra o quanto a variável independente pode ser explicada pela variável fixa. Valor de R^2 próximo a 1 indica melhor ajuste de correlação. Jarushi, Alkaabim e Cosentino (2015) apontam a seguinte escala de classificação dos valores de R^2 .

- correlação perfeita (R² = 1);
- correlação forte (0,7 < R² < 0,9);
- correlação moderada (0,4 < R² < 0,6);
- correlação baixa (0,1 < R² < 0,3);
- sem correlação (R² < 0,1).

A Equação 18 é empregada para calcular R².

$$R^{2} = 1 - \frac{\sum_{i=1}^{n} (C_{cestimado,i} - C_{cmedido,i})^{2}}{\sum_{i=1}^{n} (C_{cmedido,i} - \overline{C}_{cmedido,m})^{2}}$$
(18)

onde, $\bar{C}_{cmedido,m}$ é o valor médio das entradas de C_c medidos em laboratório, $C_{cmedido,i}$ representa o valor medido em laboratório de C_c e $C_{Cestimado,i}$ é o valor de C_c estimado.

A média e o desvio padrão da razão entre os valores estimados e o índice de compressão medido (*K*) compõem os parâmetros de exatidão e precisão dos métodos de *RI* e *RD*. *K* é calculado pela Equação 19:

$$K = \frac{C_{c \ estimado}}{C_{c \ medido}} \tag{19}$$

Briaud e Tucker (1988) apontam que a acurácia de *K* na avaliação da capacidade preditiva de um método é representada pela média de *K*. A precisão do método referese à dispersão dos valores estimados em torno de *K*, que é medido pelo desvio padrão de *K*. Teoricamente, o fator *K* varia entre zero e infinito, com um valor ótimo igual a 1 (BRIAUD; TUCKER, 1988). *K* < 1 indica que os valores previstos estão subestimados, enquanto K > 1 indica previsões superestimadas (ABU-FARSAKH; TITI, 2004). Os melhores resultados estimados estão associados à média de *K* próxima a 1 e desvio padrão de *K* próximo a 0 (ABU-FARSAKH; TITI, 2004; GÜLLÜ; CANAKCI; ALHASHEMY, 2016).

Importante compreender que a acurácia de um método está relacionada ao grau de proximidade de uma estimativa com o seu parâmetro de referência, enquanto a precisão é a representação do grau de consistência das estimativas em relação à

média (MIKHAIL; ACKERMANN, 1976). Dessa abordagem, pode-se apreender que a precisão está relacionada à dispersão das estimativas, enquanto a acurácia reflete o quanto as estimativas se aproximam aos valores parâmetros. Nessa direção, os valores da $\mu(K)$ próximos a 1 é indicativo de acurácia das estimativas.

O *ranking index* (*RI*) foi proposto por Briaud e Tucker (1988) para aliviar o problema da distribuição não simétrica dos valores de *K*. O *RI* é um índice geral que relaciona a média, $\mu(K)$, e o desvio padrão, *SD*(*K*) de todos os valores de *K* de um grupo de estimativas de valores de uma variável, para assim ser possível um julgamento da acurácia e precisão das estimativas. Para a avaliação, baixos valores de *RI* indicam bom desempenho do modelo de previsão. O *RI* é determinado pela Equação 20.

$$RI = |\mu(\ln[K])| + SD(\ln[K])$$
(20)

onde μ e *SD* representam a média e o desvio padrão de todos os valores analisados de *K*, respectivamente.

O *ranking distance* (*RD*) é um índice geral alternativo proposto por Cherubini e Orr (2000) para avaliação da qualidade de um método de cálculo, avaliando a acurácia e a precisão de uma estimativa. Como *RI*, *RD* também considera μ e *SD* de todos os valores analisados de *K*. Para avaliação, baixos valores de *RD* indicam que os valores estimados possuem alta acurácia e precisão, enquanto que altos valores indicam o oposto. Considerando um gráfico plotando os valores médios de *K* no eixo *X* e os desvios padrões no eixo *Y*, *RD* indica a distância entre um ponto estimado e o ponto que representa a condição ótima de previsão, quando $\mu(K) = 1$ e *SD*(*K*) = 0. O *RD* é calculado conforme a Equação 21.

$$RD = \sqrt{\left(1 - \mu_{[k]}\right)^2 + (SD_{[k]})^2}$$
(21)

4. RESULTADOS

Neste capítulo são discutidos os resultados obtidos para a previsão de C_c e CR para os diferentes grupos de amostras de solos moles analisados. Os resultados são apresentados de forma comparativa entre as estimativas das variáveis obtidas a partir de correlações empíricas e redes neurais artificiais.

As redes neurais foram treinadas conforme os critérios definidos no tópico 3.2.3, sendo os treinamentos executados para cada grupo de análise definido. São analisadas as correlações empíricas definidas na Tabela 12 e na Tabela 13, conforme a sua separação para cada grupo de análise. Essa separação da aplicação das correlações empíricas, previamente publicadas, buscou melhor adequação das equações aos sítios geológicos de análise, e também otimizar a apresentação dos resultados e discussões. As correlações empíricas de ajustes propostas nesta pesquisa também são empregadas conforme a sua definição de grupo de aplicação.

Seguindo orientação de Diminsky (2000), as redes foram inicializadas 5 vezes. Em cada inicialização o sistema escolhe aleatoriamente os pesos sinápticos das conexões. De acordo com a pesquisadora, essa ação é uma tentativa de mitigar o risco de a rede convergir para um mínimo local da superfície de erros da RNA.

4.1 RESULTADOS A PARTIR DAS AMOSTRAS DE SOLOS DO GRUPO G1

O grupo G1 compõe a organização de 1.815 amostras de solos argilosos moles, toda a base de dados da pesquisa, que contempla sítios geológicos de 20 países, entre eles o Brasil. Trata-se de um universo de amostras de solos de complexa heterogeneidade, com variação de LL_{CUP} entre 17,10% e 177,00% e de Cc entre 0,08 e 3,25. A maioria das amostras de solos é composta por solos de alta compressibilidade (CH e MH-OH), somando 62,71% e solos argilosos de baixa compressibilidade (CL) representando 33,37%.

Para facilitar a leitura dos gráficos de apresentação dos resultados, as correlações empíricas e as RNAs avaliadas são identificadas conforme a Tabela 16 e a Tabela 17

O termo RN é o identificador da rede neural artificial treinada, e sua arquitetura é a mesma sequência do algarismo apresentado na Tabela 11.

Variável	ID	Referência	Correlação Empírica
	G1_C1	Azzouz, Krizek e Cotoris (1976)	$C_C = 0.0100 w_n - 0.05$
	G1_C2	Kootahi e Moradi (2016)	$C_{C} = 0.012(w_{n} - 7.75)$
	G1_C3	Almeida <i>et al.</i> (2008)	$C_{C} = 0.013 w_{n}$
Wn	G1_C4	Bicalho <i>et al.</i> (2014)	$C_{C} = 0.0128 w_{n} - 0.0951$
	G1_C5	Sari e Firmansyah (2013)	$C_C = 0.0143 w_n - 0.0165$
	G1_C6	Kalantary e Kordnaeij (2012)	$C_C = 0,0074w_n - 0,007$
	G1_C7	Este Estudo (Eq. C _c -a) (2019)	$C_{C} = 0.01389 w_{n} - 0.17$
	G1_C8	Terzaghi e Peck (1967)	$C_{C} = 0,009(LL_{CUP} - 10)$
LLCUP	G1_C9	Azzouz, Krizek e Cotoris (1976)	$C_{C} = 0,006(LL_{CUP} - 9)$
	G1_C10	Bicalho <i>et al</i> . (2014)	$C_{C} = 0.011(LL_{CUP} - 8.3)$
	G1_C11	Kootahi e Moradi (2016)	$C_{C} = 0.012(LL_{CUP} - 8.0)$
	G1_C12	Este Estudo (Eq. Cc-c) (2019)	$C_{C} = 0.01265 LL_{CUP} - 0.2036$
	G1_C13	Kalantary e Kordnaeij (2012)	$C_{C} = 0.3608e_{0} - 0.0713$
	G1_C14	Azzouz, Krizek e Cotoris (1976)	$C_{C} = 0,400e_{0} - 0,100$
e 0	G1_C15	Bicalho <i>et al.</i> (2014)	$C_{C} = 0,4196e_{0} - 0,1163$
	G1_C16	Kootahi e Moradi (2016)	C _C =0,510(e ₀ -0,33)
	G1_C17	Este Estudo (Eq. Cc-e) (2019)	Cc =0,51166e ₀ - 0,1752
eo, LL _{CUP} , w _n	G1_C18	Azzouz, Krizek e Cotoris (1976)	$C_{C} = 0.37(e_0 + 0.003LL_{CUP} + 0.0004w_n - 0.34)$
eo, LL _{CUP}	G1_C19	Kootahi e Moradi (2016)	$C_{C} = 0.374(e_0 + 0.01LL_{CUP} - 0.47)$
eo, LL _{CUP} , IP	G1_C20	Oh e Chai (2006)	$C_{C} = 0.5393e_{0} - 0.0074IP + 0.0049LL_{CUP} - 0.1248$
eo, LLcup, wn	G1_C21	Este Estudo (Eq. Cc-g) (2019)	$C_{C} = 0,00285w_{n} + 0,3193e_{0} - 0,002658LL_{CUP} - 0,20647$ (Eq. C _C -g)

Tabela 16 - Relação das correlações empíricas de previsão de $C_{\rm C}$ para as amostras de solos do grupo G1

Fonte: Autor (2019)

Variável	ID	Referência	Correlação Empírica
	G1_CR1	Cox (1968 apud NAGARAJ et al.,1988)	CR = 0,0043wn
	G1_CR2	Vidalie (1977)	$CR = 0,403 logw_n - 0,478$ $CR = 0,0039w_n + 0,013$
Wn	G1_CR3	Balasubramaniam e Bremer (1981)	$CR = 0,00566w_n - 0,037$
	G1_CR4	Crumlley (2003)	$CR = 0,001w_n + 0,114$
	G1_CR5	Este Estudo (Eq. CR-a) (2019)	CR = 0,00333wn + 0,03007
	G1_CR6	Cox (1968 apud NAGARAJ et al.,1988)	$CR = 0,0045LL_{CUP}$
	G1_CR7	Azzouz, Krizek e Cotoris (1976)	$CR = 0,002(LL_{CUP} + 9)$
LL _{CUP}	G1_CR8	Nagaraj <i>et al.</i> (1988)	$CR = 0,003LL_{CUP}$
	G1_CR9	Balasubramaniam e Bremer (1981)	$CR = 0,00463LL_{CUP} - 0,013$
	G1_CR10	Este Estudo (Eq. CR-c) (2019)	CR = 0,00398LL _{CUP} + 0,01580
	G1_CR11	Elnaggar e Krizek (1970)	$CR = 0,156e_0 + 0,0107$
e ₀	G1_CR12	Azzouz, Krizek e Cotoris (1976)	$CR = 0,14(e_0 + 0,007)$
	G1_CR13	Este Estudo (Eq. CR-e) (2019)	$CR = 0,1294e_0 + 0,02189$
eo, LLcup, Wn	G1_CR14	Azzouz, Krizek e Cotoris (1976)	$CR = 0.135(e_0 + 0.01LL_{CUP} - 0.002w_n - 0.06)$
e ₀ , LL _{CUP} , Wn	G1_CR15	Este Estudo (Eq. CR-g) (2019)	$\label{eq:criterion} \begin{split} CR &= 0,01847 - 0,00022 w_n + 0,0926 e_0 + \\ 0,00112 LL_{CUP} \end{split}$

Tabela 17 - Relação das correlações empíricas de previsão de CR para as amostras de solos do grupo G1

Fonte: Autor (2019)

4.1.1 Avaliação de C_c a partir das amostras de solos do grupo G1

Nessa primeira abordagem dos resultados, o desempenho das estimativas de C_c e CR a partir de correlações empíricas e redes neurais artificiais é avaliado por diferentes parâmetros estatísticos (*i.e.*, *RMSE*, *K*, *RI*, *RD*, $\mu(K)$, *SD*(*K*) e *R*²), os quais representam o comportamento de diferentes métodos.

Por ser este grupo composto por diferentes sítios geológicos, os resultados são apresentados em forma tanto geral quanto individual para alguns países, incluindo o Brasil. São destacados também os resultados em função da compressibilidade das amostras de solos moles investigadas. Um resumo do desempenho das redes neurais treinadas e das correlações empíricas avaliadas é apresentado na Tabela 18 e na Tabela 19, para as amostras de solos de treinamento e validação cruzada, respectivamente.

., ., .	ID	К		_					
Variaveis		% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	RN1	42,31	57,69	1,10	0,34	0,34	0,35	0,80	0,24
	RN2	40,00	60,00	1,12	0,36	0,38	0,38	0,80	0,24
RN 1a	RN3	47,62	52,38	1,06	0,32	0,31	0,33	0,81	0,23
	RN4	45,03	54,97	1,08	0,33	0,33	0,34	0,81	0,23
	RN5	39,18	60,82	1,12	0,36	0,37	0,38	0,79	0,24
	RN6	42,45	57,55	1,10	0,34	0,35	0,36	0,80	0,23
	RN7	42,45	57,55	1,10	0,34	0,34	0,36	0,81	0,23
RN 1b	RN8	45,10	54,90	1,08	0,33	0,32	0,34	0,81	0,23
	RN9	42,24	57,76	1,09	0,33	0,34	0,34	0,82	0,23
	RN10	47,07	52,93	1,06	0,33	0,31	0,34	0,83	0,22
	RN11	43,74	56,26	1,09	0,33	0,34	0,35	0,80	0,23
	RN12	40,41	59,59	1,10	0,33	0,34	0,35	0,81	0,23
RN 2a	RN13	41,16	58,84	1,10	0,32	0,34	0,34	0,81	0,23
	RN14	42,95	57,05	1,10	0,34	0,34	0,35	0,81	0,23
	RN15	48,60	51,40	1,05	0,33	0,30	0,34	0,81	0,23
	RN16	42,55	57,45	1,10	0,34	0,35	0,36	0,80	0,24
	RN17	42,89	57,11	1,09	0,33	0,34	0,34	0,80	0,23
RN 2b	RN18	42,11	57,89	1,09	0,32	0,33	0,34	0,81	0,23
	RN19	48,98	51,02	1,05	0,31	0,29	0,31	0,84	0,21
	RN20	45,71	54,29	1,07	0,33	0,31	0,34	0,83	0,22
	C1	65,62	34,38	0,93	0,34	0,48	0,34	0,77	0,33
	C2	52,62	47,38	1,03	0,36	0,37	0,36	0,77	0,28
	C3	25,46	74,54	1,38	0,54	0,63	0,66	0,77	0,27
Wn	C4	43,57	56,43	1,11	0,39	0,39	0,40	0,77	0,26
	C5	18,18	81,82	1,47	0,57	0,69	0,74	0,77	0,29
	C6	81,55	18,45	0,77	0,30	0,71	0,38	0,77	0,43
	C7	50,03	49,97	1,03	0,35	0,37	0,36	0,77	0,26
	C8	67,73	32,27	0,94	0,50	0,66	0,50	0,56	0,42
	C9	87,75	12,25	0,64	0,34	1,04	0,50	0,56	0,54
LLCUP	C10	47,17	52,83	1,20	0,64	0,54	0,67	0,56	0,36
	C11	38,46	61,54	1,31	0,70	0,64	0,77	0,56	0,35
	C12	52,62	47,38	1,12	0,60	0,49	0,61	0,77	0,35
	C13	75,83	24,17	0,85	0,29	0,54	0,32	0,77	0,36
	C14	71,68	28,32	0,89	0,29	0,48	0,31	0,77	0,33
e ₀	C15	41,05	58,95	1,12	0,37	0,39	0,39	0,77	0,26
	C16	51,12	48,88	1,03	0,33	0,33	0,33	0,77	0,26
	C17	51,33	48,67	1,03	0,33	0,33	0,33	0,77	0,26
LL _{CUP} , e ₀ , w _n	C18	70,52	29,48	0,90	0,29	0,46	0,30	0,78	0,32
LLCUP, e0	C19	43,50	56,50	1,10	0,36	0,35	0,37	0,78	0,26
LLCUP, e0, IP	C20	23,89	76,11	1,37	0,52	0,62	0,64	0,74	0,28
LLCUP, e0, wn	C21	51,67	48,33	1,03	0,32	0,31	0,32	0,79	0,25

Tabela 18 - Resumo estatístico das estimativas de C_{C} para as amostras de solos de treinamento do grupo G1

		К							
Variáveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	RN1	40,70	59,30	1,12	0,40	0,40	0,42	0,76	0,26
	RN2	38,95	61,05	1,16	0,42	0,44	0,45	0,76	0,27
RN 1a	RN3	44,77	55,23	1,08	0,39	0,37	0,39	0,77	0,26
	RN4	42,44	57,56	1,11	0,40	0,39	0,41	0,79	0,25
	RN5	40,99	59,01	1,13	0,42	0,41	0,44	0,77	0,26
	RN6	39,24	60,76	1,13	0,40	0,40	0,42	0,77	0,26
	RN7	40,41	59,59	1,12	0,40	0,40	0,42	0,78	0,26
RN 1b	RN8	43,02	56,98	1,10	0,41	0,40	0,42	0,77	0,26
	RN9	43,02	56,98	1,11	0,41	0,41	0,43	0,77	0,26
	RN10	45,93	54,07	1,09	0,44	0,39	0,45	0,76	0,26
	RN11	40,70	59,30	1,12	0,40	0,40	0,41	0,76	0,26
	RN12	40,41	59,59	1,12	0,40	0,40	0,41	0,77	0,26
RN 2a	RN13	41,28	58,72	1,12	0,39	0,40	0,41	0,78	0,25
	RN14	42,73	57,27	1,15	0,45	0,43	0,47	0,74	0,28
	RN15	43,31	56,69	1,09	0,40	0,37	0,41	0,77	0,26
	RN16	40,70	59,30	1,13	0,40	0,40	0,42	0,77	0,26
	RN17	41,28	58,72	1,12	0,40	0,40	0,41	0,77	0,26
RN 2b	RN18	41,86	58,14	1,11	0,39	0,39	0,40	0,78	0,25
	RN19	45,06	54,94	1,07	0,37	0,35	0,38	0,79	0,25
	RN20	47,09	52,91	1,09	0,41	0,37	0,42	0,78	0,26
	C1	58,72	41,28	0,97	0,40	0,52	0,40	0,71	0,35
	C2	49,42	50,58	1,08	0,43	0,41	0,44	0,71	0,30
	C3	24,42	75,58	1,44	0,63	0,71	0,77	0,71	0,30
Wn	C4	39,24	60,76	1,16	0,47	0,48	0,50	0,71	0,29
	C5	18,60	81,40	1,54	0,66	0,77	0,86	0,71	0,32
	C6	77,03	22,97	0,80	0,35	0,74	0,40	0,71	0,44
	C7	45,06	54,94	1,08	0,44	0,42	0,44	0,71	0,29
	C8	62,79	37,21	0,96	0,50	0,65	0,50	0,60	0,41
	C9	88,37	11,63	0,65	0,34	1,03	0,49	0,60	0,54
LL _{CUP}	C10	45,93	54,07	1,22	0,64	0,57	0,68	0,60	0,35
	C11	37,79	62,21	1,34	0,71	0,66	0,79	0,60	0,34
	C12	48,84	51,16	1,14	0,59	0,49	0,61	0,60	0,35
	C13	68,31	31,69	0,88	0,34	0,60	0,36	0,72	0,37
	C14	65,41	34,59	0,92	0,35	0,55	0,36	0,72	0,34
e ₀	C15	38,95	61,05	1,16	0,44	0,47	0,47	0,72	0,29
	C16	48,55	51,45	1,06	0,41	0,42	0,41	0,72	0,29
	C17	47,97	52,03	1,06	0,41	0,42	0,41	0,72	0,29
LL _{CUP} , e ₀ , w _n	C18	64,83	35,17	0,92	0,34	0,51	0,35	0,74	0,33
LLCUP, e0	C19	43,60	56,40	1,12	0,41	0,40	0,43	0,76	0,27
LLCUP, e0, IP	C20	20,64	79,36	1,43	0,61	0,71	0,75	0,68	0,32
LLCUP, e0, wn	C21	49,13	50,87	1,06	0,39	0,35	0,40	0,75	0,27

Tabela 19 - Resumo estatístico das estimativas de C_C para as amostras de solos de validação cruzada do grupo G1

A Figura 32 apresenta graficamente o desempenho estatísticos das previsões de Cc das amostras de solos do grupo G1.

Figura 32 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para (a) treinamento e (b) validação cruzada, para as amostras de solos do grupo G1



Redes Neurais e Correlações Empíricas

CE = número de neurônios escondidos; RN = rede neural; 1a = rede com uma camada escondida operando as funções de ativação LogSig e Linear; 1b = rede com uma camada escondida operando as funções de ativação TanSig e Linear; 2a = rede com duas camadas escondidas operando as funções de ativação LogSig, Tansig e Linear; 2b = rede com duas camadas escondidas operando as funções de ativação Tansig, LogSig e Linear;

Fonte: Autor (2019)

Quando observada a Figura 32, nota-se que para praticamente todas as redes treinadas, os valores de *RI*, *RD* e *SD*(*K*) são ligeiramente constantes, tanto na fase do treinamento quanto da validação cruzada, o que não ocorre com as correlações empíricas, que apresentam comportamentos divergentes dos parâmetros estatísticos avaliados, especialmente para as correlações com LL_{CUP}.

Altos valores de R^2 associados a baixos valores de *RMSE* são evidências de bom desempenho estatístico. Assim como as medidas de acurácia e precisão são evidenciadas a partir da taxa de variação *K* (Cc estimado/Cc medido). Considerando a dispersão das estimativas em torno da média de *K*, uma correlação exata exibiria $\mu(K) = 1$ e SD(K) = 0. Nessa mesma direção, os parâmetros *RI* e *RD* com baixos valores indicam bom desempenho das estimativas.

Considerando as fases de treinamento e validação cruzada, os valores de *R*² variam entre 0,74 e 0,85 para as redes neurais, com pouca diferença entre as distintas arquiteturas investigadas. Já *RMSE* variou entre 0,21 e 0,27, considerando ambas as fases, treinamento e validação cruzada.

Entre as correlações empíricas investigadas, as correlações usando w_n , e_0 ou múltiplas variáveis apresentam os menores valores de *RMSE* associados a altos valores de *R*². Considerando as fases de treinamento e validação cruzada, os valores de *RMSE* variam entre 0,25 e 0,55, e os valores de *R*² variam entre 0,56 e 0,79, sendo os valores mais desfavoráveis associados às correlações com LL_{CUP}.

Em termos de acurácia e precisão medidas a partir dos valores de *K*, um balanço entre os percentuais de valores de K > 1 e K < 1 é melhor observado para as redes neurais artificiais, com ligeira tendência de superestimar as previsões de C_C ($\mu(K) > 1$), por outro lado as correlações empíricas tendem a subestimar os valores de C_c, especialmente as correlações simples C_C-LL_{CUP}.

Conforme pode ser observado na Figura 33 existe forte correlação direta positiva e crescente para *RD versus SD (K)* e *RI versus RMSE*, enquanto existe correlação direta negativa entre *RMSE* e *R*².

Figura 33 - Correlações entre os parâmetros estatísticos *RD vs.SD* (a), *RI vs.RMSE* (b) e *RMSE vs. R*²(c), para as amostras de solos do grupo G1



Fonte: Autor (2019)

Em uma análise geral, os menores valores de *RMSE*, *RI* e *RD* foram observados para as redes neurais artificias, não tendo grande relevância a variação das arquiteturas investigadas, o que sugere que redes treinadas com uma única camada oculta, com número de neurônios próximo ao número de variáveis de entrada, apresentam desempenho satisfatório, o que vai ao encontro do trabalho de Ozer, Isik e Orhan (2008). Entre as redes treinadas, considerando ambas as fases, de treinamento e validação cruzada, podem ser destacadas as redes com uma única camada oculta RN3 e RN10, a primeira com 3 neurônios na camada oculta operando uma função de ativação LogSig e a segunda com 20 neurônios na camada oculta operando uma função de ativação TanSig. Já para as redes com duas camadas ocultas, que também tiveram desempenho satisfatório, destacam-se as redes RN15 e RN19. A consistência do desempenho estatístico das redes neurais nas fases de treinamento e validação cruzada indicam a ausência de *overfitting*. Vale destacar que, os resultados apresentados neta pesquisa como fase de treinamento contemplam todos os valores das estimativas de C_c ou CR previstos para treino, validação e teste, dessa forma, a

fase de validação cruzada representa um segundo teste de capacidade de generalização das redes.

Quanto às correlações empíricas avaliadas, destacam-se as correlações propostas nesta pesquisa C7 (Eq. C_C-a) usando w_n, C17 (Eq. C_C-e) usando e₀ e C21 (Eq. C_C-g) usando LL_{CUP}, e₀ e w_n. Considerando as fases de treinamento e validação cruzada, os menores valores de *RI*, *RD*, *SD(K)* e *RMSE* foram encontrados pela correlação com múltiplas variáveis C21 (proposta nesta pesquisa: Eq.C_C-g), 0,31, 0,33, 0,22 e 0,25, respectivamente, acompanhados de R^2 = 0,79. Ainda podem ser destacadas as correlações propostas por Kootahi e Moradi (2016): C_C-w_n (C2), C_C-e₀ (C16), C_C-LL_{CUP}, e₀ (C19), o que evidentemente era esperado, por serem essas correlações derivadas da maior parte das amostras da base de dados avaliada.

Ainda, na Figura 34 é apresentada uma comparação da reta de tendência das estimativas de C_c realizadas pelos melhores ajustes de correlações empíricas e redes neurais nas fases de treinamento e validação cruzada.





Fonte: Autor (2019)

Embora as correlações empíricas avaliadas sejam validadas apenas para intervalos específicos das propriedades índices, definidos em função da base de dados de solos

utilizadas para as suas proposições, nesse comparativo todas as correlações empíricas são extrapoladas para os limites das propriedades índices das amostras de argilas estudadas nesta pesquisa. É possível destacar a maior proximidade das retas das redes neurais à Linha Igual, por outro lado as correlações mantêm-se mais distantes, especialmente a correlação Cc-LLcuP (C12). Em geral, ambas, correlações empíricas e redes neurais tendem a subestimar os valores elevados do índice de compressão (Cc > 1). Como observado graficamente, as correlações com w_n e e₀ apresentam resultados mais próximos à Linha Igual de Cc medido, corroborando com os parâmetros estatísticos previamente avaliados.

Quanto ao desempenho das correlações empíricas Cc-LLcuP serem relativamente inferiores dentre as correlações empíricas avaliadas, é importante destacar a complexidade da estrutura dos argilominerais e a sua relação com o comportamento dos solos moles, como destaca Pinto (2006, p.16-20), em que a estrutura dos solos é resultante da combinação das forças de atração e repulsão entre as partículas, que evidentemente refletem a forma como essas partículas estão dispostas na massa de solo. Al-Khafaji e Andersland (1992) destacam que a compressibilidade de solos moles depende, além da proporção relativa das frações de argilas e silte, da área de superfície das partículas coloidais, de forma que as partículas com maior área de superfície por unidade de massa, tem a habilidade de maior atração de água. Assim, considerando o limite de liquidez como a variável mais dependente das características estruturais e mineralógicas do solo, é possível que essa seja uma explicação para as correlações Cc-LLcuP serem inferiores, tendo em vista a variabilidade das amostras avaliadas nesta pesquisa.

As Figuras 35, 36 e 37 apresentam a avaliação da capacidade de previsão de Cc de acordo com o SUC das amostras de solos investigadas do grupo G1. Como a classe SUC ML-OL é pouco representativa, apenas as classes CH, CL e MH-OH são avaliadas. As correlações empíricas apresentam entre elas maior variabilidade de desempenho, especialmente as correlações Cc-LLcuP, que apresentam baixos valores de *R*², sobretudo para os solos argilosos de baixa compressibilidade. Para as três classes de solos avaliadas, as redes com uma única camada escondida RN3 e RN8 melhor aproximaram os valores mínimos de *RMSE*, *RI*, *RD* e *SD*, embora a rede RN19, com duas camadas ocultas apresente desempenho semelhante. Por outro

lado, as correlações empíricas para todas as classes SUC apresentam desempenho estatístico inferiores. Para as amostras de solos CH, destacam-se as correlações empíricas C_C-w_n, C4 e C7, a primeira proposta por Bicalho *et al.* (2014) para solos moles da Grande Vitória, ES, a segunda foi desenvolvida nesta pesquisa (Eq. C_C-a). Ainda para os solos moles CH podem ser apontadas as correlações com e₀, C16 (KOOTAHI; MORADI, 2016) e C17 (Eq. C_C-e). A correlação com múltiplas variáveis C21 (Eq. C_C-g) também apresenta desempenho satisfatório.

Quanto às amostras de solo MH-OH, as correlações empíricas simples C2 e C16 propostas por Kootahi e Moradi (2016) apresentam os melhores desempenhos, acompanhadas da correlação empírica com múltiplas variáveis (C21, Eq. Cc-g), proposta nesta pesquisa. Já as amostras de solos CL foram melhor modeladas pelas correlações simples C6 (Cc-wn) e C13 (Cc-eo) de Kalantary e Kordnaeij (2012), desenvolvidas para as argilas iranianas, que são predominantemente de baixa compressibilidade. A correlação com múltiplas variáveis C21 (Eq. Cc-g) também apresenta desempenho satisfatório para essa classe de solo.

Figura 35 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 673) e **(b)** validação cruzada (n = 124), para as amostras de solos CH do grupo G1



Redes Neurais e Correlações Empíricas

Fonte: Autor (2019)

Figura 36 - Resultados estatísticos das estimativas de C_C a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 254) e **(b)** validação cruzada (n = 86), para as amostras de solos MH-OH do grupo G1



Redes Neurais e Correlações Empíricas

Fonte: Autor (2019)
Figura 37 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 491) e **(b)** validação cruzada (n = 114), para as amostras de solos CL do grupo G1



Redes Neurais e Correlações Empíricas

Fonte: Autor (2019)

Embora a base do grupo G1 seja composta por amostras de solos de 20 países distintos, em função do número limitado de amostras para alguns sítios geológicos de análise, os resultados são apresentados apenas para 6 países: Brasil, Canadá, Coreia, Indonésia, Irã e Japão. Nesse sentido, a seguir são apresentados destaques dos desempenhos das redes treinadas com as amostras do grupo G1 para os países selecionados. Trata-se da análise dos resultados apenas de determinado país, dentro do grupo G1.

4.1.2 Avaliação de C_c para as amostras de solos do grupo G1: destaque para as amostras de solos do Brasil

Após a remoção dos *outliers* restaram 255 amostras de solos do litoral brasileiro que foram utilizadas nos treinamentos das redes neurais. As amostras brasileiras apresentam a maior variabilidade entre os grupos de países avaliados. Os limites estatísticos das amostras brasileiras são apresentados na Tabela 20.

Variável	Mínimo	Máximo	μ	SD	CV (%)
LL _{CUP} (%)	32,80	177,00	88,90	34,40	38,70
IP (%)	4,00	117,00	51,01	24,36	47,75
w n (%)	29,00	185,00	94,23	34,51	36,62
eo	0,73	4,75	2,49	0,90	36,28
Cc	0,13	3,25	1,25	0,68	52,75
CR	0,06	0,73	0,36	0,14	39,67

Tabela 20 - Resumo estatístico das amostras de solos do Brasil investigadas nesta dissertação

Fonte: Autor (2019)

Os resultados de previsão de Cc encontrados para as amostras de solos argilosso moles do litoral brasileiro são apresentados na Figura 38, revelando similaridade de desempenho com o grupo geral. Podem ser destacadas as redes RN4, RN10, RN15 e RN19 com os melhores desempenhos, todas com coeficiente de determinação próximo de 0,80, considerando as fases de treinamento e validação cruzada. Durante a fase de treinamento, os parâmetros estatísticos de avaliação de precisão e acurácia se apresentam com maior proximidade, na fase de validação esses se mostram mais desfavoráveis, com valores mais elevados de *SD(K)* e *RD*, embora os valores de *RMSE* sejam menores. Por outo lado, as correlações empíricas avaliadas mostram o mesmo comportamento do grupo geral, grande dispersão de desempenho entre as equações avaliadas, com os melhores resultados encontrados pelas correlações de ajuste propostas nesta dissertação: Cc-wn (C7), Cc-eo (C17) e Cc-LLcuP, eo, wn (C21), o que demonstra a influência do caráter de regionalidade das correlações avaliadas.

Figura 38 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 203) e **(b)** validação cruzada (n = 52), para as amostras de solos do grupo G1, com destaque para o Brasil



Fonte: Autor (2019)

4.1.3 Avaliação de Cc para as amostras de solos do grupo G1: destaque para as amostras de solos do Canadá

As amostras de solos moles do Canadá são divididas em 119 para treinamento e 29 para validação cruzada, representando 8 sítios geológicos distintos, entretanto, o mais representativo é a região de *Newfoundland*, na bacia de Placentia Bay. Essa região é de característica geológica complexa, com presença de rochas pré-cambrianas

vulcânicas e rochas sedimentares que apresentam relativo metamorfismo. Os sedimentos que compõem os solos moles dessa região investigados nesta pesquisa foram depositados no Pleistoceno, sob influência da variação do nível do mar e eventos glaciais, conforme aponta Abdel-Gawad (1980), quem organizou a base de dados das amostras dessa região em pesquisa de mestrado. Importante destacar que essas amostras de solos argilosos foram coletadas em uma profundidade média atual de lâmina d'água igual a 200m.

No geral, as amostras de solos argilosos canadenses são divididas majoritariamente em CH (n = 52) e CL (n = 52), embora sejam encontradas as classes SUC MH-OH (26) e ML-OL (n = 18), sendo as amostras argilosas de baixa compressibilidade encontradas em sítios geológicos de Ontário e Quebec (KOOTAHI; MORADI, 2016). Um resumo estatístico das amostras de solos do Canadá é apresentado na Tabela 21. Nota-se que estão centradas em uma variação de C_c entre 0,08 e 1,06, entretanto, a maior parte das amostras está situada em faixa de variação de C_c entre 0,30 e 0,75. Quanto a LL_{CUP}, embora os valores variem entre 19% e 81%, a média é 52,40%, limite muito próximo à Linha B, além disso essa propriedade apresenta baixo *CV (28,66%)*.

Variável	Mínimo	Máximo	μ	SD	CV (%)
LL _{CUP} (%)	19,00	81,00	52,40	15,02	28,66
IP (%)	2,00	52,00	26,03	11,61	44,59
W n (%)	16,00	87,00	52,46	16,68	31,79
eo	0,42	2,32	1,40	0,45	31,92
Cc	0,08	1,06	0,49	0,20	40,49
CR	0,05	0,34	0,20	0,06	29,45

Tabela 21 - Resumo estatístico das amostras de solos do Canadá investigadas nesta dissertação

Fonte: Autor (2019)

Os resultados das estimativas de C_c para as amostras de solos canadenses são apresentados na Figura 39. A primeira observação está no alto valor de R^2 , com valores próximos a 0,80 para as redes e 0,70 para as correlações empíricas. Outro ponto importante está no fato da maioria das correlações com w_n apresentarem

valores de *RI* e *RD*, superiores às correlações com LL_{CUP}, o que difere dos resultados avaliados pelo grupo geral e até mesmo o destaque das amostras de solos do Brasil.





Fonte: Autor (2019)

Embora a maioria das correlações empíricas C_c -w_n tiveram a tendência de superestimar C_c , a correlação empírica C1, de Azzouz, Krizek e Cotoris (1976) teve um dos melhores desempenhos estatísticos. Os mesmos autores também são os

responsáveis pelas correlações empíricas C_{C-e_0} (C14) e $C_{C-LL_{CUP}}$, e_0 , w_n (C18), que tiveram bons desempenhos.

As redes neurais, novamente não apresentaram grandes divergências de desempenho, com destaque para a rede de única camada oculta RN4, com 9 neurônios escondidos e operando a função de ativação LogSig na camada oculta.

4.1.4 Avaliação de C_c para as amostras de solos do grupo G1: destaque para as amostras de solos da Coreia

Segundo Yoon, Kim e Jeon (2004) os depósitos de solos moles da costa da Coreia foram formados predominantemente no período Quaternário, com camadas variando em alguns sítios geológicos entre 9 e 18 metros e outros entre 9 e 25 metros. Segundo os pesquisadores, as argilas do litoral coreano são tipicamente inorgânicas sendo encontradas as variações de amostras de baixa a alta compressibilidade. As amostras dos sítios geológicos da Coreia pesquisadas nesta dissertação de mestrado foram organizadas por Kootahi e Moradi (2016), sendo divididas em CH (n = 38), CL (n = 38), MH-OH (n = 7) e ML-OL (n = 9). O valor médio de LL_{CUP} é de 54,25% e Cc é 0,59, conforme pode ser observado na Tabela 22.

Variável	Mínimo	Máximo	μ	SD	CV (%)
LL _{CUP} (%)	27,00	100,00	54,25	20,22	37,28
IP (%)	3,00	71,00	29,78	18,02	60,51
W _n (%)	28,00	95,00	53,05	18,01	33,95
e ₀	0,75	2,71	1,43	0,50	35,07
Cc	0,18	1,50	0,59	0,34	56,95
CR	0,10	0,45	0,23	0,09	38,23

Tabela 22 - Resumo estatístico das amostras de solos da Coreia investigadas nesta dissertação

Fonte: Autor (2019)

A Figura 40 apresenta os resultados estatísticos das estimativas de C_c pelas redes neurais e correlações empíricas.

Figura 40 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 74) e **(b)** validação cruzada (n = 18), para as amostras de solos do grupo G1, com destaque para a Coreia



Fonte: Autor (2019)

No geral, tanto as redes neurais quanto as correlações empíricas apresentaram elevados valores de *R*², superiores a 0,85, além disso, os baixos valores de *RMSE* corroboram o bom desempenho para as estimativas de Cc, especialmente pelas RNAs, cujos valores estão próximos a 0,13, considerando as fases de treinamento e validação cruzada. Importante destacar que todas as redes treinadas tendem a superestimar as previsões de Cc. Embora as redes apresentem desempenho estatístico similares, a rede RN6, com uma única camada oculta com 2 neurônios,

operando a função de ativação TanSig parece ser a mais adequada. As correlações empíricas Cc-LL_{CUP} (C11) de Kootahi e Moradi (2016) e Cc-w_n, e₀, LL_{CUP}, proposta neste estudo (Eq. C_c-g) apresentam os melhores desempenhos, embora também tendam a superestimar o índice de compressão.

4.1.5 Avaliação de C_c para as amostras de solos do grupo G1: destaque para as amostras de solos da Indonésia

As amostras de solos moles da Indonésia somam 410 amostras de toda a base de dados. A grande maioria foi organizada por Sari e Firmansyah (2013), 391 amostras de solos, todas da região de Surubaya. Os autores destacam, que essa região litorânea apresenta uma grande diversidade de solos argilosos em função das características geográficas locais, com presença de ilhas e rios em ambiente litorâneo, essas amostras de solos apresentam forte influência marinha na formação das argilas, mas também das deposições de frações finas de solos trazidas pelos rios de diferentes origens geológicas. Essa heterogeneidade das amostras de solos da Indonésia corrobora em resultados conservadores de *R*², normalmente abaixo de 0,50 para a maioria das correlações avaliadas. A Tabela 23 apresenta um resumo estatístico das amostras de solos moles da Indonésia.

Variável	Mínimo	Máximo <i>µ</i>		SD	CV (%)	
LL _{CUP} (%)	17,10	148,50	81,58	28,58	35,03	
IP (%)	1,60	116,40	50,31	24,77	49,23	
W _n (%)	13,25	118,18	60,84	23,26	38,24	
eo	0,43	3,36	1,70	0,59	35,08	
Cc	0,14	2,10	0,83	0,45	53,72	
CR	0,08	0,83	0,30	0,13	44,49	

Tabela 23 - Resumo estatístico das amostras de solos da Indonésia investigadas nesta dissertação

Fonte: Autor (2019)

As amostras de solos da Indonésia apresentam uma variação de C_c entre 0,14 e 2,10, com valor médio de 0,83, acompanhado de valor médio de LL_{CUP} de 81,58%, mostrando que a maioria das amostras é de argilas de alta compressibilidade, sendo 292 amostras de solos CH, 47 MH-OH, e ainda 57 amostras CL e 14 ML-OL.

Dos países analisados, esse destaque para a Indonésia apresentou o pior desempenho estatístico, tanto para as redes quanto para as correlações empíricas. A Figura 41 apresenta graficamente o desempenho estatístico das previsões de Cc para as amostras da Indonésia. No geral, as RNAs avaliadas apresentaram valores de $\mu(K)$ próximos a 1 indicando que existe um balanço entre as estimativas de Cc entre superestimar e subestimar, entretanto, os elevados valores de SD(K) mostram que as previsões não estão ajustadas à média. Os valores de RI e RD estão próximos a 0,50 acompanhados de valores de RMSE = 0,35. Pode-se constatar assim uma baixa precisão das estimativas do índice de compressão. Seguindo a tendência das análises dos outros grupos, não ocorrem diferenças significativas de desempenho em termos de arquiteturas das redes, podendo destacar a rede RN1, com uma única camada oculta de 2 neurônios.

Quanto as correlações empíricas avaliadas, existe uma grande divergência entre elas, com os piores resultados encontrados pelas correlações C_C-LL_{CUP}, que mostram uma redução substancial do valor de *R*². Para esse recorte de análise, a correlação empírica de ajuste com múltiplas variáveis (Eq. C_C-g), proposta nesta pesquisa, C21, parece melhor ajustar os parâmetros estatísticos.

Figura 41 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 331) e **(b)** validação cruzada (n = 79), para as amostras de solos do grupo G1, com destaque para a Indonésia



Fonte: Autor (2019)

4.1.6 Avaliação de C_c para as amostras de solos do grupo G1: destaque para as amostras de solos do Irã

As amostras de solos moles do Irã foram organizadas por Kalantary e Kordnaeij (2012), sendo todas da província de Mazandaran. As amostras de solos apresentam origem marinha e fluvial, sendo predominantemente argilas de baixa plasticidade. Abdullayev e Leroy (2016) destacam que a bacia do Mar Cáspio, que hoje

corresponde a um lago, durante o Oligoceno e Mioceno teve ligação com o Mar Mediterrâneo. Os mesmos autores também reforçam a influência dos rios no processo de deposição de material terrígeno no Mar Cáspio, o que traz para essa região diferenças mineralógicas para as argilas encontradas: ilitas, caulinitas e esmectitas.

As amostras de solos iranianas são representadas por 287 amostras de solo CL, 38 de CH e 6 de ML-OL, mostrando que são majoritariamente argilas de baixa compressibilidade, cujo limite de Cc está entre 0,08 e 0,32, além de LL_{CUP} entre 24,00% e 60,00%. As amostras iranianas investigadas compõem o sítio geológico avaliado com os menores valores de *CV* das propriedades índices avaliadas nesta pesquisa. Essa característica, previsivelmente poderia indicar melhor ajuste dos parâmetros estatísticos, considerando os critérios de pré-processamento dos dados de entrada para limites mais homogêneos, entretanto, os resultados encontrados mostram baixos valores de correlações entre Cc medido e Cc estimado, tanto para as redes quanto para as correlações empíricas. Por outro lado, os valores de *RMSE* encontrados são baixos, próximos de 0,05. Um resumo estatístico das variáveis do Irã está apresentado na Tabela 24.

Variável	Mínimo	Máximo	μ	SD	CV (%)
LL _{CUP} (%)	24,00	60,00	38,46	8,31	21,61
IP (%)	4,00	36,00	17,56	7,44	42,38
W n (%)	14,50	39,80	27,03	5,03	18,62
e ₀	0,48	1,00	0,73	0,10	14,26
Cc	0,08	0,32	0,19	0,05	26,76
CR	0,05	0,18	0,11	0,03	23,46

Tabela 24 - Resumo estatístico das amostras de solos do Irã investigadas nesta dissertação

Fonte: Autor (2019)

Para esse grupo de análise, as estimativas de C_c pelas RNAs mostraram-se mais favoráveis para as redes com 2 camadas escondidas. A RN19, com 9 e 5 neurônios ocultos, e operando as funções de ativação LogSig e TanSig nas camadas ocultas, respectivamente, apresentou melhor desempenho, embora com tendência de superestimar os valores do índice de compressão, conforme pode ser observado na

Figura 42, com a curva da $\mu(K)$ superior a 1,0. Por outro lado, as correlações empíricas mostram grande divergência de desempenho, especialmente as correlações com LL_{CUP} e w_n, sendo as melhores correlações as baseadas em e₀ e múltiplas variáveis, podendo destacar as correlações C_C-e₀ (C17) proposta nesta pesquisa (Eq. C_C-e) e C_C-LL_{CUP}, e₀, w_n (C18) proposta por Azzouz, Krizek e Cotoris (1976).

Figura 42 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 266) e **(b)** validação cruzada (n = 65), para as amostras de solos do grupo G1, com destaque para o Irã



Fonte: Autor (2019)

Os resultados encontrados para as amostras iranianas divergem dos apontados por Kalantary e Kordnaeij (2012) em termos de R² obtidos por RNAs e pela correlação empírica C13, que segundo os pesquisadores apresentou valor médio de 0,96 entre as amostras de treinamento e validação cruzada. Importante destacar que os pesquisadores não informam quais amostras foram utilizadas para treinamento e para a validação cruzada, além disso eles utilizaram 391 amostras, que nesta pesquisa foram reduzidas a 331, sendo a maioria das amostras excluídas classificadas como CH, entretanto, ao se calcular o coeficiente de determinação para todas as 391 amostras do Irã o valor encontrado é $R^2 = 0,68$, por ambas as correlações propostas pelos pesquisadores, C13 e C17. Já a rede treinada pelos pesquisadores que apresentou o melhor desempenho é de arquitetura semelhante a RN19, embora eles também utilizaram como entrada a propriedade índice de densidade específica dos grãos (Gs) e 3 neurônios na segunda camada oculta. Com a mesma base de 391 amostras do Irã, Oliveira Filho et al. (2018) encontraram valor de R² = 0,82 e RMSE = 0,04 para as amostras de validação cruzada, sendo a rede treinada com 1 camada oculta operando a função de ativação LogSig, com as entradas LL_{CUP}, w_n, e₀, G_S e IP, para este estudo, as amostras de treino e validação cruzada (20%) foram selecionadas aleatoriamente.

Os resultados do recorte do grupo G1 para o Irã sugerem que as amostras descartadas no pré-processamento poderiam melhorar o ajuste do treinamento das redes e que as mesmas redes tiveram dificuldade de generalização para amostras de solos moles de baixa compressibilidade.

4.1.7 Avaliação de C $_{\rm C}$ para as amostras de solos do grupo G1: destaque para as amostras de solos do Japão

Parte das amostras marinhas japonesas organizadas por Kootahi e Moradi (2016) são de sítios geológicos de Tóquio, publicadas por Tsuboi *et al.* (2012), que classificam essas amostras como de origem do Pleistoceno a Holoceno, de alta compressibilidade sob influência de sedimentação marinha em ambiente de alta salinidade. No geral, as amostras de solos argilosos do Japão apresentam valores de C_C variando entre 0,25 e 2,02 e média de 1,07, já o LL_{CUP} médio é de 83,83% e e₀ médio é 2,48, conforme pode ser observado na Tabela 25. As características das propriedades índices das

amostras japonesas mostram que as mesmas são na maioria de alta compressibilidade, sendo representada por 86 amostras de solo CH, 67 MH-OH e apenas 9 CL e 6 ML-OL.

Variável	Mínimo	Máximo	μ	SD	CV (%)
LL _{CUP} (%)	33,00	157,00	83,83	26,25	31,32
IP (%)	8,00	97,00	47,12	19,80	42,03
W n (%)	28,00	167,00	93,71	30,81	32,88
e ₀	0,91	4,37	2,48	0,77	30,91
Cc	0,25	2,02	1,07	0,45	41,53
CR	0,11	0,46	0,30	0,08	26,21

Tabela 25 - Resumo estatístico das amostras de solos do Japão investigadas nesta dissertação

Fonte: Autor (2019)

Analisando a Figura 43, nota-se que as estimativas de Cc pelas RNAs apresentam bons indicadores estatísticos, embora com ligeira tendência de superestimar os valores do índice de compressão, podendo destacar a RN2 com uma única camada escondida com 3 neurônios, com *R*² superior 0,8 e *RD* e *RI* menores que 0,4. Quanto às correlações empíricas, a maioria das correlações simples com w_n e e₀ e as correlações com múltiplas variáveis apresentaram bom desempenho. A correlação empírica Cc-w_n (C2), de Kootahi e Moradi (2016), juntamente com a C21 (Eq. Cc-g), proposta nesta pesquisa (Cc-LL_{CUP}, e₀, w_n).

Figura 43 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 135) e **(b)** validação cruzada (n = 33), para as amostras de solos do grupo G1, com destaque para o Japão



Fonte: Autor (2019)

4.2 RESULTADOS DAS ESTIMATIVAS DE CR A PARTIR DAS AMOSTRAS DE SOLOS DO GRUPO G1

A forte correlação entre C_c e C_c/(1+e₀), CR, é evidenciada por Bicalho *et al.* (2015) quando avaliadas argilas marinhas da Grande Vitória, ES, encontrando um R^2 = 0,89. Conforme mostrado na Tabela 5, para as amostras investigadas nesta pesquisa também é encontrada uma forte correlação entre C_c e CR (R^2 = 0,79), por outro lado, CR apresenta correlação moderada com as outras propriedades índices, com R^2 próximo a 0,40. Entretanto, como apontam Nagaraj, Joshi e Murthy (1988), diversos estudos observaram que o recalque de uma camada de solo, para uma determinada taxa de tensão efetiva é proporcional a CR. Por essas razões esta pesquisa de mestrado também avalia a aplicabilidade de técnicas computacionais de redes neurais e outros métodos, tais como correlações empíricas para a previsão de CR, a partir de propriedades índices do solo.

As investigações ocorreram segundo a mesma metodologia dos estudos para estimarem C_c e as correlações investigadas apresentadas na Tabela 17, sendo CR calculado a partir da medida de laboratório de C_c, representando C_c/(1+e₀).

Os resultados encontrados revelam que, para o conjunto de todas as amostras, o desempenho estatístico das estimativas de CR para os parâmetros de entrada, no geral, foi menos assertivo que as estimativas de Cc pelas redes neurais. As estimativas de CR pela correlação empírica simples CR-w_n (CR2), proposta por Vidalie (1977) para argilas francesas e a correlação empírica com múltiplas variáveis CR-w_n, e₀, LL_{CUP} (CR15), proposta nesta pesquisa (Eq. CR-g) tiveram desempenhos próximos aos das RNAs. Essas duas correlações empíricas e as redes avaliadas apresentam um balanço entre os valores percentuais K > 1 e K < 1, destacando as RNAs com uma única camada oculta RN2 e RN5.

Os valores de R^2 encontrados nesta pesquisa para as estimativas de CR estão relativamente superiores aos valores médios encontrados na pesquisa de Azzouz, Krizek e Cotoris (1976), que foram da ordem de um R^2 = 0,50, entretanto, quando comparados aos valores de R^2 encontrados pelas RNAs para Cc (R^2 = 0,80), são

menores. A Figura 44 apresenta graficamente os resultados estatísticos das estimativas de CR pelas RNAs e correlações empíricas.



Figura 44 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento e (b) validação cruzada, para as amostras de solos do grupo G1

A Tabela 26 e a Tabela 27 apresentam os resumos dos resultados estatísticos das estimativas de CR para as amostras de solos de treinamento e validação cruzada, respectivamente.

Fonte: Autor (2019)

			ĸ			_			
Variáveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	RN1	43,36	56,64	1,09	0,33	0,34	0,35	0,61	0,08
	RN2	44,38	55,62	1,08	0,33	0,32	0,34	0,64	0,07
RN 1a	RN3	42,75	57,25	1,09	0,33	0,33	0,34	0,61	0,08
	RN4	42,61	57,39	1,09	0,33	0,33	0,35	0,62	0,08
	RN5	43,70	56,30	1,08	0,32	0,32	0,33	0,63	0,07
	RN6	44,04	55,96	1,09	0,33	0,33	0,34	0,62	0,08
	RN7	42,61	57,39	1,09	0,33	0,34	0,34	0,62	0,08
RN 1b	RN8	41,93	58,07	1,09	0,32	0,33	0,34	0,63	0,07
	RN9	44,32	55,68	1,08	0,32	0,32	0,33	0,63	0,07
	RN10	43,36	56,64	1,08	0,33	0,32	0,34	0,65	0,07
	RN11	43,57	56,43	1,09	0,34	0,34	0,35	0,60	0,08
	RN12	43,16	56,84	1,09	0,32	0,32	0,33	0,62	0,08
RN 2a	RN13	42,55	57,45	1,10	0,34	0,34	0,35	0,62	0,08
	RN14	44,79	55,21	1,07	0,32	0,31	0,33	0,62	0,08
	RN15	45,68	54,32	1,07	0,33	0,31	0,34	0,65	0,07
	RN16	43,36	56,64	1,09	0,33	0,33	0,34	0,62	0,08
	RN17	43,16	56,84	1,09	0,32	0,33	0,33	0,62	0,08
RN 2b	RN18	45,13	54,87	1,08	0,33	0,32	0,34	0,63	0,08
	RN19	42,95	57,05	1,09	0,32	0,32	0,33	0,66	0,07
	RN20	43,77	56,23	1,08	0,33	0,32	0,34	0,66	0,07
	CR1	41,59	58,41	1,12	0,38	0,40	0,40	0,51	0,10
	CR2	48,81	51,19	1,05	0,33	0,32	0,33	0,55	0,08
Wn	CR3	30,50	69,50	1,27	0,48	0,55	0,55	0,51	0,14
	CR4	70,18	29,82	0,88	0,39	0,63	0,41	0,51	0,12
	CR5	49,49	50,51	1,03	0,33	0,35	0,33	0,51	0,09
	CR6	22,19	77,81	1,37	0,53	0,61	0,65	0,47	0,12
	CR7	87,88	12,12	0,71	0,27	0,77	0,40	0,47	0,13
LL _{CUP}	CR8	69,03	30,97	0,91	0,35	0,52	0,36	0,47	0,10
	CR9	25,32	74,68	1,34	0,53	0,59	0,63	0,47	0,12
	CR10	52,14	47,86	1,06	0,41	0,36	0,41	0,47	0,09
	CR11	36,01	63,99	1,16	0,39	0,42	0,42	0,51	0,10
e ₀	CR12	56,84	43,16	0,99	0,34	0,39	0,34	0,51	0,09
	CR13	50,78	49,22	1,03	0,34	0,34	0,35	0,51	0,09
LL_{CUP}, e_0, w_n	CR14	26,41	73,59	1,25	0,41	0,48	0,48	0,55	0,10
LL_{CUP}, e_0, w_n	CR15	45,68	54,32	1,07	0,33	0,31	0,34	0,65	0,07

Tabela 26 - Resumo estatístico das estimativas de CR para as amostras de solos de treinamento do grupo G1

Fonte: Autor (2019)

_

			ĸ			_			
Variáveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	RN1	40,70	59,30	1,12	0,40	0,40	0,41	0,50	0,10
	RN2	41,28	58,72	1,10	0,39	0,38	0,40	0,53	0,09
RN 1a	RN3	41,28	58,72	1,12	0,40	0,39	0,41	0,51	0,10
	RN4	40,99	59,01	1,11	0,40	0,40	0,41	0,50	0,10
	RN5	41,57	58,43	1,11	0,39	0,38	0,41	0,54	0,09
	RN6	41,28	58,72	1,10	0,39	0,38	0,40	0,51	0,09
	RN7	39,83	60,17	1,12	0,40	0,40	0,42	0,52	0,09
RN 1b	RN8	41,86	58,14	1,11	0,40	0,40	0,41	0,51	0,10
	RN9	41,57	58,43	1,10	0,38	0,38	0,40	0,52	0,09
	RN10	42,15	57,85	1,11	0,41	0,39	0,42	0,57	0,09
	RN11	40,41	59,59	1,12	0,40	0,39	0,42	0,50	0,10
	RN12	42,44	57,56	1,11	0,39	0,39	0,40	0,51	0,10
RN 2a	RN13	39,83	60,17	1,12	0,41	0,40	0,42	0,50	0,10
	RN14	41,86	58,14	1,09	0,38	0,37	0,39	0,52	0,09
	RN15	43,31	56,69	1,10	0,41	0,38	0,42	0,56	0,09
	RN16	41,28	58,72	1,11	0,39	0,39	0,41	0,51	0,09
	RN17	40,99	59,01	1,10	0,38	0,38	0,40	0,51	0,09
RN 2b	RN18	41,86	58,14	1,10	0,39	0,38	0,40	0,53	0,09
	RN19	42,15	57,85	1,12	0,40	0,39	0,41	0,54	0,09
	RN20	43,31	56,69	1,12	0,44	0,40	0,45	0,55	0,09
	C1	37,21	62,79	1,17	0,48	0,50	0,51	0,35	0,13
	C2	43,31	56,69	1,09	0,42	0,41	0,43	0,40	0,11
Wn	C3	32,27	67,73	1,33	0,60	0,65	0,69	0,35	0,16
	C4	64,83	35,17	0,92	0,44	0,65	0,44	0,35	0,14
	C5	45,35	54,65	1,08	0,42	0,40	0,43	0,35	0,11
	C6	22,97	77,03	1,40	0,57	0,64	0,69	0,47	0,12
	C7	86,92	13,08	0,72	0,29	0,77	0,40	0,47	0,14
LL _{CUP}	C8	67,73	32,27	0,93	0,38	0,51	0,38	0,47	0,11
	C9	24,42	75,58	1,37	0,56	0,62	0,67	0,47	0,12
	C10	49,42	50,58	1,08	0,44	0,38	0,44	0,47	0,10
	C11	34,30	65,70	1,20	0,47	0,51	0,51	0,35	0,12
e ₀	C12	48,55	51,45	1,03	0,41	0,46	0,41	0,35	0,12
	C13	45,35	54,65	1,07	0,41	0,40	0,42	0,35	0,11
LL_{CUP}, e_0, w_n	C14	26,45	73,55	1,29	0,48	0,55	0,56	0,43	0,12
LL_{CUP}, e_0, w_n	C15	43,31	56,69	1,10	0,41	0,38	0,42	0,56	0,09

Tabela 27 - Resumo estatístico das estimativas de CR para as amostras de solos de validação cruzada do grupo G1

Fonte: Autor (2019)

_

4.2.1 Avaliação de CR para as amostras de solos do grupo G1: destaque para as amostras de solos do Brasil

O desempenho das estimativas de CR para um recorte do Brasil, no geral foi inferior à média de todas as amostras do grupo G1, apresentando valor médio de SD(K) 30% superior para as RNAs, avaliando apenas as amostras da validação cruzada. Importante destacar que as correlações empíricas se mostraram menos assertivas que as redes neurais, de forma que o valor de *RMSE* médio é de 0,16, contra 0,10 das RNAs, ou seja, 60% superior, corroborado ainda por um valor médio de R^2 = 0,30, em média 100% inferior ao valor das RNAs. Pode-se destacar a correlação empírica simples CR-w_n (CR2), de Vidalie (1977) e a correlação empírica com múltiplas variáveis CR-w_n, e₀, LL_{CUP} (CR15), proposta nesta pesquisa (CR-g), além das redes com uma única camada oculta RN2 e RN9, cujos resultados estatísticos são apresentados na Tabela 28.

			ĸ		_				
Variáveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
			Amos	tras do Tr	einamento	•			
RN	RN2	54,68	45,32	1,07	0,45	0,34	0,42	0,57	0,10
1a	RN9	54,68	45,32	1,05	0,38	0,34	0,39	0,54	0,10
Wn	CR2	58,13	41,87	1,05	0,42	0,38	0,42	0,39	0,12
LL_{CUP}, e_0, w_n	CR15	57,14	42,86	1,05	0,47	0,41	0,47	0,31	0,13
			Amostra	s da Valid	ação Cruza	ada			
RN	RN2	46,15	53,85	1,16	0,53	0,43	0,55	0,63	0,10
1a	RN9	51,92	48,08	1,15	0,52	0,42	0,55	0,66	0,09
Wn	CR2	42,31	57,69	1,16	0,55	0,46	0,57	0,40	0,12
LL_{CUP}, e_0, w_n	CR15	51,92	48,08	1,15	0,54	0,45	0,56	0,32	0,13

Tabela 28 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos do Brasil

Fonte: Autor (2019)

A Figura 45 apresenta graficamente as curvas dos parâmetros estatísticos avaliados para as de CR pelas redes e correlações empíricas, nota-se que as curvas das redes se mantêm praticamente idênticas. As correlações empíricas CR2 e CR15 tem comportamentos próximos das redes neurais. Os resultados indicam que correlações com múltiplas variáveis não implicam na melhor opção para as previsões de CR das amostras de solos do litoral brasileiro, o que corrobora as conclusões de Azzouz, Krizek e Cotoris (1976) quando estudou os solos argilosos dos Estados Unidos e Grécia.

Figura 45 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 203) e (b) validação cruzada (n = 52), para as amostras de solos do grupo G1, com destaque para o Brasil



Redes Neurais e Correlações Empíricas

Fonte: Autor (2019)

4.2.2 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para as amostras de solos do Canadá

Observando o desempenho das estimativas de CR para um recorte do Canadá, a partir do grupo de avaliação G1, embora todas as redes tenham desempenho estatístico semelhante, pode-se destacar a RN10 com 20 neurônios com única camada oculta, operando a função de ativação TanSig, a qual apresenta resultados estatísticos mais favoráveis em relação à média de todas as amostras de solos, em especial o SK(K) igual a 0,23, considerando as amostras do treinamento e da validação cruzada. Para essa rede neural são registrados RI = 0,31 e RD = 0,26. Esses parâmetros são semelhantes quando avaliado esse mesmo grupo de amostras de solos nas previsões de Cc, a diferença principal está no valor de R^2 , enquanto para a previsão de CR a rede RN10 apresenta $R^2 = 0,60$, para prever C_c a média das redes neurais foi $R^2 = 0,77$. A Tabela 29 mostra um resumo das avaliações estatísticas da rede RN10 e da correlação empírica CR15, proposta nesta pesquisa (CR-g).

		K							
Variaveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
			Amost	tras do Tr	einamento	D			
RN 1a	RN10	31,93	68,07	1,10	0,22	0,28	0,24	0,61	0,05
LL _{CUP} , e ₀ , w _n	CR15	46,22	53,78	1,03	0,22	0,23	0,22	0,48	0,04
			Amostras	s da Valida	ação Cruz	ada			
RN 1a	RN10	19,23	80,77	1,14	0,24	0,34	0,28	0,60	0,03
LL_{CUP}, e_0, w_n	CR15	19,23	80,77	1,05	0,21	0,24	0,21	0,49	0,03

Tabela 29 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos do Canadá

Fonte: Autor (2019)

Importante observar, que para este sítio geológico, a correlação empírica com múltiplas variáveis, embora apresente menor valor do coeficiente de determinação, os demais parâmetros são melhores do que os realizados pela rede neural. A Figura 46 apresenta graficamente os resultados das estimativas de CR para o destaque Canadá.

Figura 46 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 119) e (b) validação cruzada (n = 29), para as amostras de solos do grupo G1, com destaque para o Canadá



Fonte: Autor (2019)

4.2.3 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para as amostras de solos da Coreia

Seguindo a tendência das estimativas do recorte do Canadá, os resultados encontrados para o destaque da Coreia apresentam grande diferença entre o balanço

de K > 1 e K < 1, entre as amostras de treinamento e de validação cruzada, enquanto para as primeiras a tendência das redes foi subestimar as estimativas, para as amostras de validação cruzada acontece o oposto. Como ocorreu nas estimativas de C_c, as correlações empíricas com LL_{CUP} mostraram bom desempenho para as amostras de solo da Coreia, diferentemente da média geral. Para efeitos de comparação são destacadas a rede neural RN6 e a correlação empírica CR-LL_{CUP} (CR10), proposta nesta pesquisa (CR-c), e seus resultados são apresentados na Tabela 30.

			К			_				
Variáveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE	
Amostras do Treinamento										
RN 1a	RN6	62,16	37,84	0,98	0,21	0,24	0,21	0,76	0,04	
LL _{CUP}	CR10	83,78	16,22	0,85	0,18	0,39	0,24	0,75	0,06	
			Amostras	s da Valida	ação Cruz	ada				
RN 1a	RN6	16,67	83,33	1,13	0,22	0,31	0,26	0,77	0,05	
LL _{CUP}	CR10	72,22	27,78	0,95	0,16	0,24	0,17	0,81	0,05	

Tabela 30 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos da Coreia

Fonte: Autor (2019)

Para esse grupo de amostras de solos da Coreia, os resultados da fase de validação cruzada indicam que a correlação empírica CR10 apresenta melhor desempenho estatístico, embora exista uma tendência de subestimar CR. Importante destacar que existe uma equiparação entre a rede neural e a correlação empírica avaliada em termos de *RMSE* e de R^2 , sendo esse último parâmetro próximo a 0,80. A Figura 47 mostra a disposição de CR x w_n para as amostras de validação cruzada.

Figura 47 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 74) e (b) validação cruzada (n = 18), para as amostras de solos do grupo G1, com destaque para a Coreia



Fonte: Autor (2019)

4.2.4 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para as amostras de solos da Indonésia

Os resultados das estimativas de CR para o recorte das amostras de solos da Indonésia revelam que para essas amostras de solo, as estimativas dos parâmetros de compressibilidade unidimensional apresentam baixa precisão e acurácia, conforme relevado pelos parâmetros estatísticos avaliados. Considerando apenas o grupo de validação cruzada, o desempenho das redes neurais foi inferior ao observado nas estimativas de Cc, com um valor médio de $R^2 = 0,11$ para todas as 20 redes na previsão de CR. Na mesma direção, as correlações empíricas avaliadas apresentam uma média de $R^2 = 0,07$. Importante destacar que, as correlações empíricas do tipo CR-LL_{CUP} tiveram desempenho mais assertivo que as correlações empíricas Cc-LL_{CUP}, mostrando mais uma vez, que o limite de liquidez é uma propriedade de melhor correlação com a taxa de compressão (CR), para as amostras de solo da Indonésia. No geral, pode-se destacar a rede com camada única RN2 com o melhor desempenho, além disso a correlação empírica CR-LL_{CUP} (CR8), proposta por Nagaraj, Joshi e Murthy. (1988), além da correlação com múltiplas variáveis CR15, proposta nesta pesquisa. A Tabela 31 e a Figura 48 apresentam graficamente o desempenho estatístico da RN2 e da correlação empírica CR8.

Tabela 31 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos da Indonésia

				_						
Variáveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE	
Amostras do Treinamento										
RN 1a	RN2	50,76	49,24	1,07	0,43	0,39	0,44	0,26	0,11	
LL _{CUP} ,	CR8	60,42	39,58	0,95	0,48	0,65	0,48	0,09	0,14	
			Amostras	s da Valida	ação Cruz	ada				
RN 1a	RN2	54,43	45,57	1,04	0,48	0,52	0,48	0,14	0,15	
LL _{CUP}	CR8	65,82	34,18	0,92	0,48	0,70	0,49	0,14	0,17	

Fonte: Autor (2019)

Figura 48 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 331) e (b) validação cruzada (n = 79), para as amostras de solos do grupo G1, com destaque para a Indonésia



Fonte: Autor (2019)

4.2.5 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para as amostras de solos do Irã

Comparando as estimativas de CR com as estimativas de Cc, para o grupo de amostras de solos iranianos, uma primeira observação está no fato das correlações empíricas apresentarem resultados de previsão da taxa de compressão menos assertivos, especialmente usando LL_{CUP}, revelado principalmente por um baixo

coeficiente de determinação, em média $R^2 = 0,18$. Assim como para C_C, os valores de CR foram superestimados. Em termos de medidas de acurácia e precisão medidos por RI e RD, as estimativas das redes apresentaram desempenho em média 30% mais favorável, embora quando avaliadas apenas as correlações CR-e₀ estas apresentam desempenho superiores às redes neurais, com menores valores de RI, RD e SD(K). Por outro lado, existe uma equiparação entre as redes e as correlações empíricas em termos de RMSE. Embora o desempenho estatístico das redes seja semelhante, pode-se destacar a rede com duas camadas ocultas RN15. Quanto às correlações empíricas, os melhores ajustes são dados pelas correlações com e₀, como destacado na correlação empírica C12, proposta como Azzouz, Krizek e Cotoris (1976). A Tabela 32 e a Figura 49 apresentam os destaques da RN15 e da correlação empírica CR12. Quando observados os resultados estatísticos das estimativas da correlação empírica CR12, nota-se que os resultados foram mais assertivos que as RNAs, isso se explica pelo valor da $\mu(K)$ ser próxima a 1, o que resultou em um menor valor de SD(K), para esse grupo de amostras de solos, entende-se que as redes neurais tiveram desempenho inferiores às correlações com eo.

Variáveis		К			_				
	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
Amostras do Treinamento									
RN 2a	RN15	36,47	63,53	1,09	0,24	0,29	0,26	0,23	0,02
e ₀	CR12	54,14	45,86	0,99	0,21	0,25	0,21	0,21	0,02
Amostras da Validação Cruzada									
RN 2a	RN15	37,50	62,50	1,09	0,25	0,29	0,27	0,32	0,02
e ₀	CR12	43,75	56,25	1,02	0,23	0,22	0,23	0,25	0,02

Tabela 32 - Resumo estatístico das estimativas de CR a partir das amostras de solos de treinamento e validação cruzada do grupo G1: destaque para as amostras de solos do Irã

Fonte: Autor (2019)

Figura 49 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 266) e (b) validação cruzada (n = 65), para as amostras de solos do grupo G1, com destaque para o Irã



Fonte: Autor (2019)

4.2.6 Avaliação de CR a partir das amostras de solos do grupo G1: destaque para os tipos de solos segundo o SUC

A avaliação gráfica das estimativas de CR de acordo com os tipos de solos segundo o SUC, para o total das amostras de solos investigadas é apresentada nas Figura 50.

Figura 50 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 673) e (b) validação cruzada (n =124), para as amostras de solos CH do grupo G1



Fonte: Autor (2019)

Figura 51 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 491) e (b) validação cruzada (n = 114), para as amostras de solos CL do grupo G1



Redes Neurais e Correlações Empíricas

Fonte: Autor (2019)

Figura 52 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 254) e **(b)** validação cruzada (n = 86), para amostras de solos MH-OH do grupo G1



Fonte: Autor (2019)

Quando avaliadas as amostras de argilas de alta plasticidade (CH), nota-se que os parâmetros de acurácia e precisão *RI*, *RD* e *SD* são praticamente constantes para as redes neurais tanto para as amostras de treinamento quanto de validação cruzada, entretanto, o parâmetro R^2 na fase da correlação cruzada apresenta considerável diminuição, algo semelhante ocorre com as amostras MH-OH (Figura 52). Por outro lado, os resultados das redes mostraram-se mais consistentes para as amostras de solos argilosos de baixa compressibilidade, com *SD* (*K*) 30% mais favorável que a média entre as amostras de solo CH e MH-OH, além de R^2 60% superior.

Analisando o desempenho das estimativas de CR do grupo G1 em termos das correlações empíricas, os melhores resultados também são registrados para a classe de solo CL. Diferentemente das redes neurais, os resultados das correlações empíricas são variados, apresentando correlações com desempenho próximo às redes, porém outros resultados bastante discrepantes, como a correlação empírica com LLcuP, CR6, proposta por Cox (1968 apud NAGARAJ; JOSHI; MURTHY, 1988), que apresenta resultados ruins para as três classes de solos avaliadas. Em termos gerais, as correlações empíricas simples com e₀ e as com múltiplas variáveis com LLcuP, e₀ e w_n apresentam os melhores desempenhos, com destaque para a correlação empírica CR15, proposta nesta pesquisa. Quando comparados os resultados das redes neurais e das correlações empíricas, as classes de solo CH e MH-OH tiveram melhores desempenhos com as redes neurais, enquanto para a classe CL, os resultados foram semelhantes para ambas.

Os resultados das estimativas de CR mostram que, para as amostras de solos com alta plasticidade, os resultados da validação cruzada são discrepantes em relação à fase de treinamento, o que sugere dificuldade de generalização das redes para as estimativas da taxa de compressão, entretanto, melhores generalizações são encontradas para as amostras de baixa compressibilidade.

4.3 RESULTADOS A PARTIR DAS AMOSTRAS DE SOLOS DO GRUPO G2 (BRASIL)

As amostras de solos moles do litoral brasileiro investigadas nesta pesquisa, como discutido no tópico 2.1.2 são de origem marinha, de características variáveis, entretanto marcadamente de alta compressibilidade. Essas amostras de solos investigadas são de diferentes localidades do litoral do Brasil, incluindo os estados do Espírito Santo, Pernambuco, Rio Grande do Sul, Santa Catarina, São Paulo e Rio de Janeiro. Inicialmente os dados do grupo G2 apresentavam 295 amostras de solos, entretanto, após os filtros estatísticos para a remoção de amostras com dados de laboratório discrepantes, restaram 255 amostras de solos do Brasil que foram usadas no treinamento das RNAs.

As 255 amostras de solos são divididas preferencialmente em argilas de alta compressibilidade (CH) e siltes ou matérias orgânicas de alta compressibilidade (MH-OH), conforme apresentado na Tabela 33.

SUC	n	Mínimo	Máximo	μ	SD	CV (%)
СН	131	0,17	3,25	1,25	0,66	52,6
MH-OH	97	0,44	2,75	1,53	0,62	40,53
CL	23	0,13	1,86	0,64	0,46	72,62
ML-OL	4	0,25	0,44	0,33	0,09	27,93

Tabela 33 - Descrição estatística de C_{C} por tipo de solo segundo o SUC para as amostras de solos do Brasil

Fonte: Autor (2019)

Importante destacar a grande dispersão dos valores das propriedades índices das amostras de solo do litoral brasileiro, como por exemplos o índice de vazio inicial variando entre 0,7 e 4,8, além do LL_{CUP} com mínimo de 32,80% e máximo de 177,00%. A Tabela 34 mostra um resumo estatístico das propriedades índices das 255 amostras de solos do Brasil, onde normalmente, os limites superiores das propriedades índices das amostras brasileiras refletem os limites superiores de toda a base de dados pesquisada.

Tabela 34 - Descrição estatística das amostras de solos do Brasil após a remoção de *outliers* (n = 255)

Variável	Mínimo	Máximo	μ	SD	CV (%)
LL _{CUP} (%)	32,80	177,00	88,90	34,40	38,70
IP (%)	4,00	117,00	51,01	24,36	47,75
w n (%)	29,00	185,00	94,23	34,51	36,62
e ₀	0,73	4,75	2,49	0,90	36,28
Cc	0,13	3,25	1,29	0,68	52,75
CR	0,06	0,73	0,36	0,14	39,67

Fonte: Autor (2019)

A Figura 53 apresenta os histogramas de distribuição de todas as propriedades índices avaliadas, além do índice compressão, C_c, e da taxa de compressão, CR. Embora a variação de C_c esteja entre 0,13 e 3,25, a maioria das amostras de solos está concentrada entre 0,50 e 2,50, o que é corroborado pela média igual a 1,29 e *CV* = 52,75.

Figura 53 - Histograma das variáveis analisadas das amostras de solos do Brasil: (a) C_C , (b) CR, (c) w_n (%), (d) e_0 , (e) LL_{CUP} (%) e (f) IP (%)



Fonte: Autor (2019)

Analisando a correlação entre as variáveis investigadas, nota-se que as propriedades índices das amostras de solo do litoral brasileiro apresentam, no geral, valores de R^2 inferiores à média de todas as 1.815 amostras da base de dados. Conforme apresentado na Tabela 35, as melhores correlações são obtidas com C_c e as propriedades índices w_n e e₀, respectivamente. Além disso, C_c e CR apresentam forte correlação entre eles, $R^2 = 0.82$.

Para este grupo de análise, os critérios de treinamento das redes neurais são os mesmos empregados na avaliação do grupo G1, com todas as amostras da base de dados. Essa segunda avaliação comparada às avaliações realizadas no grupo G1 é uma tentativa de verificar a capacidade de generalização das redes neurais, quando treinadas com variáveis de sítios geológicos distintos.

	CR	W n (%)	e ₀	LL _{CUP} (%)	IP (%)
Cc	0,82	0,63	0,59	0,42	0,36
CR		0,25	0,22	0,27	0,31
w n (%)			0,94	0,45	0,27
e ₀				0,41	0,23
LL _{CUP} (%)					0,83

Tabela 35 - Matriz de correlação (R^2) entre as variáveis das amostras de solos do Brasil (n = 255)

Fonte: Autor (2019)

Importante destacar que outras correlações empíricas propostas para os solos argilosos do litoral brasileiro são avaliadas, além de algumas das correlações empíricas apresentadas na literatura, como a de Azzouz, Krizek e Cotoris (1976), que também foram avaliadas no grupo G1. A relação das correlações empíricas para estimar C_c e CR para as amostras do litoral brasileiro são apresentadas na Tabela 36 e na Tabela 37, respectivamente.
Variável	ID	Referência	Correlação Empírica
	G2_C1	Azzouz, Krizek e Cotoris (1976)	$C_{C} = 0.0100 w_{n} - 0.05$
	G2_C2	Kootahi e Moradi (2016)	$C_{C} = 0.012(w_{n} - 7.75)$
	G2_C3	Almeida et al. (2008)	$C_{\rm C} = 0.013 w_{\rm n}$
Wn	G2_C4	Bicalho <i>et al. (</i> 2014)	$C_{C} = 0.0128 w_{n} - 0.0951$
	G2_C5	Castello e Polido (1986)	$C_{C} = 0.014 w_{n} - 0.017$
	G2_C6	Baroni e Almeida (2017)	$C_{C} = 0.011 w_{n}$
	G2_C7	Este Estudo (Eq. Cc-b) (2019)	$C_{\rm C} = 0,1595 w_{\rm n} - 0,2854$
	G2_C8	Terzaghi e Peck (1967)	$C_{\rm C} = 0,009(LL_{\rm CUP} - 10)$
	G2_C9	Azzouz, Krizek e Cotoris (1976)	$C_{C} = 0,006(LL_{CUP} - 9)$
11	G2_C10	Bicalho <i>et al.</i> (2014)	$C_{C} = 0.011(LL_{CUP} - 8.3)$
	G2_C11	Kootahi e Moradi (2016)	$C_{C} = 0.012(LL_{CUP} - 8.0)$
	G2_C12	Cozzolino (1961)	$C_{C} = 0.0186(LL_{CUP} - 30)$
	G2_C13	Este Estudo (Eq. C _C -d) (2019)	$C_{C} = 0.018754 LL_{CUP} - 0.3688$
	G2_C14	Castello e Polido (1986)	$C_{C} = 0,228e_{0} + 0,22$
	G2_C15	Azzouz, Krizek e Cotoris (1976)	$C_{C} = 0,400e_{0} - 0,100$
0	G2_C16	Bicalho <i>et al.</i> (2014)	$C_{C} = 0,4196e_{0} - 0,1163$
e ₀	G2_C17	Kootahi e Moradi (2016)	Cc =0,510(e ₀ -0,33)
	G2_C18	Baroni e Almeida (2017)	$C_{C} = 0,5284e_{0}$
	G2_C19	Este Estudo (Eq. C _C -f) (2019)	$C_{C} = 0,6032e_{0} - 0,3029$
eo, LLcup, wn	G2_C20	Azzouz, Krizek e Cotoris (1976)	$C_{C} = 0.37(e_{0} + 0.003LL_{CUP} + 0.0004w_{n} - 0.34)$
eo, LLCUP	G2_C21	Kootahi e Moradi (2016)	$C_{C} = 0.374(e_0 + 0.01LL_{CUP} - 0.47)$
e ₀ , LL _{CUP} , IP	G2_C22	Oh e Chai (2006)	$C_{C} = 0,5393e_{0} - 0,0074PI + 0,0049LL_{CUP} - 0,1248$
eo, LLCUP, Wn	G2_C23	Este Estudo (Eq. Cc-h) (2019)	$C_{C} = 0.00489 w_{n} + 0.366 e_{0} + 0.0052 LL_{CUP} - 0.5083$

Tabela 36 - Correlações empíricas empregadas para estimar C_{C} para as amostras de solos do Brasil

Variável	ID	Referência	Correlação Empírica		
	G2_CR1	Azzouz, Krizek e Cotoris (1976)	CR = 0,003(w _n + 7)		
	G2_CR2	Cox (1968 apud NAGARAJ et al.,1988)	$CR = 0,0043w_n$		
Wn	G2_CR3	Vidalie (1977)	$CR = 0.403 logw_n - 0.478$ $CR = 0.0039w_n + 0.013$		
	G2_CR4	Balasubramaniam e Bremer (1981)	$CR = 0,00566w_n - 0,037$		
	G2_CR5	Crumlley (2003)	$CR = 0,001w_n + 0,114$		
	G2_CR6	Este Estudo (Eq. CR-b) (2019)	$CR = 0,00234w_n + 0,0919$		
	G2_CR7	Cox (1968 apud NAGARAJ et al.,1988)	CR = 0,0045LL _{CUP}		
-	G2_CR8	Nagaraj <i>et al.</i> (1988)	$CR = 0,003LL_{CUP}$		
LLCUP	G2_CR9	Balasubramaniam e Bremer (1981)	$CR = 0,00463LL_{CUP} - 0,013$		
	G2_CR10	Azzouz, Krizek e Cotoris (1976)	$CR = 0,002(LL_{CUP} + 9)$		
	G2_CR11	Este Estudo (Eq. CR-d) (2019)	CR = 0,004231LL _{CUP} + 0,0034		
	G2_CR12	Elnaggar e Krizek (1970)	$CR = 0,156e_0 + 0,0107$		
e ₀	G2_CR13	Azzouz, Krizek e Cotoris (1976)	$CR = 0,14(e_0 + 0,007)$		
	G2_CR14	Este Estudo (Eq. CR-f) (2019)	$CR = 0,08975e_0 + 0,0914$		
eo, LLcup, Wn	G2_CR15	Azzouz, Krizek e Cotoris (1976)	$CR = 0,135(e_0 + 0,01LL_{CUP} - 0,002w_n - 0,06)$		
eo, LLcup, Wn	G2_CR16	Este Estudo (Eq. CR-h) (2019)	CR = 0,0802 + 0,00056wn + 0,0376e0 + 0,00134LL _{CUP}		

Tabela 37 - Correlações empíricas empregadas para estimar CR para as amostras de solos do Brasil

4.3.1 Avaliação de Cc a partir das amostras de solos do Brasil (grupo G2)

Semelhante ao comportamento do treinamento das redes com amostras do grupo G1, na oportunidade de treinamento do grupo G2, o desempenho das RNAs apresenta baixa variação entre as diversas arquiteturas avaliadas, embora na fase da validação cruzada é observada maior distância entre os parâmetros estatísticos avaliados, especialmente *RI*, que indica menor acurácia das estimativas. Por outro lado, esse padrão de similaridade não é observado nas correlações empíricas. As correlações com LL_{CUP} apresentam um comportamento mais divergente entre as equações.

A Tabela 38 e a Tabela 39 apresentam os resultados estatísticos das estimativas de C_c pelas redes neurais e correlações empíricas, para as amostras do treinamento e da validação cruzada, respectivamente.

			I	<					
Variáveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	G2_RN1	58,59	41,41	1,07	0,39	0,33	0,40	0,74	0,35
RN 1a	G2_RN2	54,04	45,96	1,10	0,39	0,36	0,41	0,76	0,34
	G2_RN3	52,53	47,47	1,08	0,35	0,33	0,36	0,78	0,32
	G2_RN4	52,02	47,98	1,10	0,36	0,34	0,37	0,79	0,31
	G2_RN5	40,40	59,60	1,13	0,36	0,38	0,38	0,78	0,35
	G2_RN6	49,49	50,51	1,11	0,39	0,36	0,40	0,74	0,35
	G2_RN7	52,02	47,98	1,07	0,37	0,33	0,38	0,73	0,35
RN 1b	G2_RN8	65,15	34,85	1,04	0,37	0,31	0,37	0,77	0,33
	G2_RN9	56,06	43,94	1,06	0,33	0,30	0,34	0,81	0,30
	G2_RN10	67,17	32,83	0,93	0,33	0,38	0,34	0,81	0,31
	G2_RN11	50,51	49,49	1,10	0,40	0,36	0,41	0,71	0,37
	G2_RN12	52,02	47,98	1,12	0,40	0,37	0,42	0,74	0,34
RN 2a	G2_RN13	52,02	47,98	1,11	0,39	0,36	0,40	0,75	0,34
	G2_RN14	56,57	43,43	1,07	0,39	0,36	0,40	0,74	0,35
	G2_RN15	51,01	48,99	1,08	0,35	0,38	0,35	0,82	0,29
	G2_RN16	50,00	50,00	1,11	0,42	0,38	0,43	0,72	0,36
	G2_RN17	49,49	50,51	1,12	0,42	0,38	0,44	0,74	0,35
RN 2b	G2_RN18	52,53	47,47	1,08	0,34	0,31	0,35	0,85	0,27
	G2_RN19	57,58	42,42	1,09	0,37	0,34	0,38	0,77	0,33
	G2_RN20	50,00	50,00	1,08	0,36	0,32	0,37	0,84	0,27
	G2_C1	76,26	23,74	0,82	0,38	0,67	0,42	0,63	0,61
	G2_C2	70,20	29,80	0,94	0,42	0,52	0,43	0,63	0,50
	G2_C3	50,51	49,49	1,14	0,54	0,44	0,56	0,63	0,43
Wn	G2_C4	63,64	36,36	1,01	0,46	0,45	0,46	0,63	0,46
	G2_C5	60,61	39,39	1,03	0,45	0,42	0,45	0,63	0,44
	G2_C6	70,20	29,80	0,96	0,46	0,52	0,46	0,63	0,51
	G2_C7	58,59	41,41	1,06	0,44	0,37	0,45	0,63	0,42
	G2_C8	85,86	14,14	0,66	0,38	1,01	0,50	0,42	0,79
	G2_C9	95,96	4,04	0,45	0,26	1,40	0,61	0,42	0,99
	G2_C10	78,79	21,21	0,83	0,47	0,79	0,50	0,42	0,66
LL _{CUP}	G2_C11	66,67	33,33	0,91	0,52	0,70	0,53	0,42	0,61
	G2_C12	64,14	35,86	0,94	0,55	0,80	0,55	0,42	0,59
	G2_C13	48,99	51,01	1,17	0,66	0,53	0,68	0,42	0,55

Tabela 38 - Resumo estatístico das estimativas de C_C a partir das amostras de solos de treinamento do Brasil (continua)

									/
				ĸ					
Variaveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
e ₀	G2_C14	79,29	20,71	0,78	0,44	0,82	0,49	0,60	0,74
	G2_C15	76,26	23,74	0,80	0,34	0,66	0,39	0,60	0,61
	G2_C16	61,62	38,38	1,01	0,43	0,44	0,43	0,60	0,47
	G2_C17	64,14	35,86	0,98	0,40	0,46	0,40	0,60	0,48
	G2_C18	42,93	57,07	1,22	0,55	0,51	0,60	0,60	0,43
	G2_C19	57,07	42,93	1,03	0,41	0,39	0,41	0,60	0,44
e_0, LL_{CUP}, w_n	G2_C20	76,77	23,23	0,81	0,33	0,64	0,38	0,63	0,60
e ₀ , LL _{CUP}	G2_C21	61,62	38,38	0,98	0,40	0,45	0,40	0,64	0,47
e ₀ , LL _{CUP} , IP	G2_C22	47,47	52,53	1,16	0,53	0,46	0,55	0,55	0,46
e ₀ , LL _{CUP} , w _n	G2_C23	48,99	51,01	1,12	0,41	0,39	0,43	0,65	0,41

Tabela 38 - Resumo estatístico das estimativas de C_C a partir das amostras de solos de treinamento do Brasil (conclusão)

Mariferria	10	К							
Variaveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	G2_RN1	45,83	54,17	1,17	0,54	0,43	0,57	0,77	0,33
	G2_RN2	45,83	54,17	1,22	0,60	0,48	0,64	0,74	0,35
RN 1a	G2_RN3	43,75	56,25	1,23	0,61	0,49	0,65	0,72	0,37
	G2_RN4	39,58	60,42	1,21	0,53	0,45	0,57	0,80	0,32
	G2_RN5	39,58	60,42	1,25	0,54	0,50	0,59	0,75	0,41
	G2_RN6	43,75	56,25	1,21	0,59	0,47	0,63	0,71	0,37
	G2_RN7	43,75	56,25	1,20	0,56	0,45	0,60	0,76	0,34
RN 1b	G2_RN8	50,00	50,00	1,16	0,56	0,43	0,58	0,77	0,33
	G2_RN9	54,17	45,83	1,16	0,56	0,42	0,58	0,75	0,34
	G2_RN10	58,33	41,67	1,08	0,53	0,42	0,53	0,77	0,33
	G2_RN11	37,50	62,50	1,21	0,52	0,46	0,56	0,77	0,34
RN 2a	G2_RN12	41,67	58,33	1,25	0,62	0,51	0,67	0,75	0,35
	G2_RN13	43,75	56,25	1,25	0,60	0,50	0,65	0,78	0,34
	G2_RN14	54,17	45,83	1,18	0,54	0,58	0,57	0,74	0,35
	G2_RN15	50,00	50,00	1,18	0,61	0,85	0,64	0,78	0,32
	G2_RN16	45,83	54,17	1,22	0,56	0,48	0,60	0,74	0,35
	G2_RN17	41,67	58,33	1,25	0,64	0,51	0,69	0,74	0,35
RN 2b	G2_RN18	50,00	50,00	1,22	0,73	0,56	0,76	0,59	0,44
	G2_RN19	39,58	60,42	1,21	0,56	0,46	0,59	0,73	0,36
	G2_RN20	47,92	52,08	1,18	0,67	0,47	0,70	0,73	0,36
	G2_C1	72,92	27,08	0,88	0,46	0,64	0,47	0,60	0,59
	G2_C2	68,75	31,25	1,02	0,52	0,49	0,52	0,60	0,49
	G2_C3	43,75	56,25	1,22	0,66	0,53	0,70	0,60	0,43
Wn	G2_C4	56,25	43,75	1,09	0,56	0,42	0,56	0,60	0,45
	G2_C5	52,08	47,92	1,11	0,55	0,42	0,56	0,60	0,44
	G2_C6	68,75	31,25	1,04	0,56	0,50	0,56	0,60	0,50
	G2_C7	43,75	56,25	1,15	0,54	0,45	0,57	0,60	0,43
	G2_C8	81,25	18,75	0,74	0,49	0,98	0,56	0,40	0,75
	G2_C9	95,83	4,17	0,50	0,33	1,37	0,60	0,40	0,96
	G2_C10	72,92	27,08	0,92	0,62	0,76	0,62	0,40	0,63
LL _{CUP}	G2_C11	64,58	35,42	1,01	0,68	0,66	0,68	0,40	0,58
	G2_C12	58,33	41,67	1,07	0,71	0,75	0,71	0,40	0,59
	G2_C13	35,42	64,58	1,31	0,87	0,66	0,92	0,40	0,59

 Tabela 39 - Resumo estatístico das estimativas de C_C a partir das amostras de solos de validação cruzada do Brasil
 (continua)

				К					
variaveis	U	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	G2_C14	75,00	25,00	0,84	0,54	0,81	0,56	0,56	0,71
e ₀	G2_C15	72,92	27,08	0,88	0,45	0,64	0,47	0,56	0,58
	G2_C16	56,25	43,75	1,10	0,57	0,42	0,58	0,56	0,46
	G2_C17	58,33	41,67	1,08	0,54	0,43	0,55	0,56	0,47
	G2_C18	33,33	66,67	1,33	0,72	0,62	0,80	0,56	0,45
	G2_C19	45,83	54,17	1,15	0,56	0,45	0,57	0,56	0,45
e_0, LL_{CUP}, w_n	G2_C20	72,92	27,08	0,89	0,46	0,61	0,47	0,59	0,57
e ₀ , LL _{CUP}	G2_C21	60,42	39,58	1,08	0,56	0,42	0,57	0,61	0,45
e ₀ , LL _{CUP} , IP	G2_C22	35,42	64,58	1,28	0,71	0,60	0,76	0,49	0,49
e ₀ , LL _{CUP} , w _n	G2_C23	35,42	64,58	1,25	0,59	0,51	0,64	0,62	0,45

Tabela 39 - Resumo estatístico das estimativas de C_C a partir das amostras de solos de
validação cruzada do Brasil(conclusão)

A Figura 54 apresenta graficamente o desempenho estatístico das estimativas de Cc para as amostras de solos brasileiros (grupo G2).

Considerando as fases de treinamento e validação cruzada, os valores de R^2 variam entre 0,59 e 0,85, com pequenas variações entre as redes treinadas, com exceção da G2_RN18, que apresentou o menor valor do coeficiente de determinação, na fase de validação cruzada. Já o parâmetro, *RMSE*, que é inversamente proporcional a R^2 , para os mesmos conjuntos das amostras de solos variou entre 0,27 e 0,44, com os menores valores encontrados durante os treinamentos.

Entre as correlações empíricas investigadas, as correlações usando w_n, e₀ ou múltiplas variáveis apresentaram os menores valores de *RMSE* associados a valores mais elevados de *R*². Considerando as fases de treinamento e validação cruzada, os valores de *RMSE* variam entre 0,41 e 0,99, e os valores de *R*² variam entre 0,42 e 0,65, sendo os valores mais desfavoráveis associados às correlações com LL_{CUP}. Nessa primeira abordagem fica evidente que as redes apresentam parâmetros estatísticos mais ajustados em detrimento às correlações empíricas com melhores resultados de estimativas.

Figura 54 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 203) e **(b)** validação cruzada (n = 52), para as amostras de solos do Brasil (grupo G2)



Redes Neurais e Correlações Empíricas

Fonte: Autor (2019)

Em termos de acurácia e precisão, avaliadas através dos valores de *K*, um balanço entre os percentuais de valores de K > 1 e K < 1 é melhor observado para as redes neurais artificiais, com ligeira tendência de superestimar as previsões de Cc ($\mu(K) > 1$), por outro lado, as correlações empíricas não apresentam uma tendência geral, embora as correlações simples Cc-LLcuP, a maioria tenda a subestimar os valores de Cc. Os valores de *SD*(*K*) indicam que as redes, na média apresentam maior consistência das estimativas de Cc, com maior valor igual a 0,73, contra 1,37 das correlações empíricas, o que é corroborado pelos valores de *RI* e *RD*, na média com menores para as redes neurais.

Em uma análise geral, os melhores resultados estatísticos foram observados pelas redes neurais, não tendo grande relevância a arquitetura da rede, sendo que redes treinadas com uma única camada oculta, mostraram-se satisfatórias, conforme já observado na análise do grupo G1. Entre as redes treinadas podem ser destacadas as redes com única camada oculta G2_RN4 e G2_RN9, sendo a primeira com 9 neurônios na camada oculta e operando a função de ativação LogSig, enquanto a segunda usa a função de ativação TanSig com os mesmos 9 neurônios ocultos. Quanto as correlações empíricas, destacam-se as correlações simples G2_C2 e G2_C7 com w_n, e as correlações empíricas com múltiplas variáveis G2_C20, proposta por Azzouz, Krizek e Cotoris (1976) e G2_C23, proposta nesta pesquisa (Eq. Cc-h).

Comparando os resultados das estimativas de Cc obtidos no grupo G2 aos resultados do destaque para o Brasil obtidos no grupo G1, nota-se similaridades dos resultados, o que indica capacidade de generalização das redes neurais. A Figura 55 mostra uma comparação da reta de tendência das estimativas de Cc realizadas pelos melhores ajustes de correlações empíricas e redes neurais, nas fases de treinamento e validação cruzada. A rede RN4 do grupo de treinamento G1 também é avaliada nesse conjunto. Importante destacar, que as estimativas da rede G1_RN4 foram menos conservativas que as redes treinadas apenas com as amostras de solo do Brasil (grupo G2), tendendo a estimar valores abaixo aos previstos pelas redes G2.

Figura 55 - Comparativo entre C_c medido e C_c estimado por correlações empíricas e RNAs para **(a)** treinamento (n = 203) e **(b)** validação cruzada (n = 52), para as amostras de solos do Brasil (grupo G2)



Fonte: Autor (2019)

A Figura 56 e a Figura 57 mostram os resultados estatísticos das previsões de C_c de acordo com a o tipo de solo segundo o SUC das amostras de solos do Brasil.

Figura 56 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 99) e **(b)** validação cruzada (n = 23), para as amostras de solos CH do Brasil (grupo G2)



Fonte: Autor (2019)

Figura 57 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 78) e **(b)** validação cruzada (n = 20), para as amostras de solos MH-OH do Brasil (grupo G2)



Fonte: Autor (2019)

São avaliadas apenas as classes CH e MH-OH que apresentam maior número de amostras. Os resultados para ambas as classes de solos apurados pelas redes neurais tiveram comportamento semelhante, com exceção das redes com duas camadas ocultas G2_RN14 e G2_RN15, que apresentaram altos valores de *RMSE,* podendo indicar que os treinamentos dessas redes podem ter convergido para um mínimo local da função. Observando os valores da $\mu(K)$ praticamente todas as redes

superestimam Cc, enquanto as correlações empíricas tendem a subestimar, para ambas as classes de solos. As correlações empíricas com LL_{CUP} apresentam baixos valores de *R*² associados a elevados valores de *RMSE* indicando que essas correlações não são bem ajustadas para as amostras de solos do litoral brasileiro. As correlações simples com w_n e e₀ e as correlações empíricas com múltiplas variáveis foram mais assertivas para as duas classes de solos avaliadas. Quanto às redes neurais, para ambas as classes de solos avaliadas, a rede com uma única camada oculta G2_RN4 mostrou-se a mais adequada. Já as correlações empíricas, para as amostras de solos CH podem ser destacadas as correlações simples Cc-w_n (G2_C7) e Cc-e₀ (G2_C19), além da correlaçõo com múltiplas variáveis G2_C23, todas propostas nesta pesquisa. Por outro lado, para as amostras de solos MH-OH, as melhores correlações simples foram Cc-w_n (G2_C4), proposta por Bicalho *et al.* (2014), Cc-e₀ (G2_C17), proposta por Kootahi e Moradi (2016), além da correlação com múltiplas variáveis G2_C21, proposta também por Kootahi e Moradi (2016).

Ainda para o grupo G2 são individualizados os resultados por estados brasileiros, entretanto, em função do número limitado de amostras de solos, são apresentados os resultados da validação cruzada apenas para Rio de Janeiro e Santa Catarina, adotando como critério o número mínimo de 10 amostras de solos. Para o Espírito Santo são apresentados apenas os resultados da fase de treinamento. A Figura 58, a Figura 59 e a Figura 60 apresentam os resultados estatísticos das previsões de Cc para cada um dos 3 estados. Praticamente todas as redes neurais apresentaram capacidade de estimar C_C de forma aproximada para o ES. No geral, os resultados dos parâmetros estatísticos apurados para as redes neurais indicam maior precisão de estimativas de Cc, especialmente para SC e RJ.

Figura 58 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 46) e **(b)** validação cruzada (n = 14), para as amostras de solos do RJ (grupo G2)



Fonte: Autor (2019)

Figura 59 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 75) e **(b)** validação cruzada (n = 15), para as amostras de solos de SC (grupo G2)



Fonte: Autor (2019)



Figura 60 - Resultados estatísticos das estimativas de C_c a partir de correlações empíricas e redes neurais para (a) treinamento (n = 49), para as amostras de solos do ES (grupo G2)

Fonte: Autor (2019)

Complementando a análise dos resultados das estimativas de Cc para os estados do ES, SC e RJ, é importante destacar que algumas correlações empíricas mostraram resultados satisfatórios. Para as amostras de solo do ES podem ser destacadas as correlações Cc-wn (G2_C7), proposta nesta pesquisa (Eq. Cc-b) e as correlações com múltiplas variáveis G2_C20, proposta por Azzouz, Krizek e Cotoris (1976) e G2_C23 (Eq. Cc-h), proposta nesta pesquisa. Para o estado do RJ, as melhores correlações empíricas foram registradas para Cc-e₀, como G2_C17, proposta por Kootahi e Moradi (2016), G2_C18 de Baroni e Almeida (2017) e G2_C19 (Eq. Cc-f), proposta nesta pesquisa, além da correlaçõe empírica com múltiplas variáveis G2_C21, também de Kootahi e Moradi (2016). Já para Santa Catarina são destacadas as correlações simples Cc-wn (G1_C5), proposta por Castello e Polido (1988) e Cc-e₀ (G2_C17), proposta por Kootahi e Moradi (2016), além da correlação com múltiplas variáveis proposta nesta pesquisa (Eq. Cc-h), G2_C23.

Diferente das redes neurais, as correlações empíricas mostraram uma grande diversidade de estimativas de C_c, evidenciando a influência da regionalidade das amostras de solos de sua origem.

4.3.2 Avaliação de CR a partir das amostras de solos do Brasil (grupo G2)

Neste tópico são apresentados os resultados das estimativas de CR através das redes neurais treinadas apenas com as amostras de solos brasileiros.

Uma primeira observação está no fato das redes neurais treinadas tanto com amostras do grupo G1 quanto do grupo G2 apresentarem desempenhos estatísticos semelhantes, como refletidos nos valores médios de *RMSE* e *R*² praticamente idênticos para ambos os grupos, próximos a 0,10 e 0,58, respectivamente. A mesma tendência ocorreu para os demais parâmetros estatísticos avaliados.

Avaliando os parâmetros estatísticos para o grupo G2, todas as redes neurais apresentaram valores de $\mu(K)$ superiores a 1, indicando que os valores de CR são superestimados, corroborando os resultados encontrados também no grupo G1. Considerando as fases de treinamento e validação cruzada, foram observados valores médios de $R^2 = 0.58$, RMSE = 0.10, SD(K) = 0.46, RI = 0.40 e RD = 0.49. Por outro lado, quando avaliados os resultados encontrados pelas correlações empíricas, existe uma grande dispersão dos parâmetros estatísticos encontrados, entretanto é possível destacar as correlações simples CR-wn (G2_CR6) e CR-e0 (G2_CR14), ambas propostas nesta pesquisa, sendo as equações CR-b e CR-f, respectivamente. Comparando apenas essas 2 correlações empíricas com a média das RNAs, nota-se que o valor de R^2 das correlações empíricas é 62% inferior (0,22), RMSE = 0,13 é 39% superior, embora ambos os métodos sejam equivalentes em termos de SD(K), RI e RD. Em termos estatísticos, considerando todas as amostras do grupo G2, o desempenho das RNAs apresentou valores dos parâmetros estatísticos mais favoráveis que as correlações empíricas. A Tabela 40 e a Tabela 41 trazem os resumos dos resultados estatísticos das estimativas de CR para as amostras de solos do treinamento e da validação cruzada do grupo G2, respectivamente.

Variáveis	חו	К							
Vanaveis	ID	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	G2_RN1	51,01	48,99	1,10	0,38	0,35	0,40	0,50	0,10
	G2_RN2	54,04	45,96	1,07	0,35	0,33	0,36	0,55	0,10
RN 1a	G2_RN3	50,00	50,00	1,08	0,33	0,32	0,34	0,58	0,09
	G2_RN4	51,01	48,99	1,08	0,33	0,32	0,34	0,59	0,09
	G2_RN5	52,02	47,98	1,07	0,31	0,30	0,31	0,64	0,08
	G2_RN6	53,03	46,97	1,10	0,39	0,35	0,40	0,52	0,10
	G2_RN7	56,57	43,43	1,06	0,36	0,32	0,37	0,54	0,10
RN 1b	G2_RN8	55,56	44,44	1,08	0,36	0,33	0,37	0,55	0,10
	G2_RN9	50,51	49,49	1,09	0,36	0,33	0,37	0,61	0,09
	G2_RN10	44,44	55,56	1,12	0,34	0,35	0,36	0,63	0,09
	G2_RN11	51,01	48,99	1,09	0,38	0,35	0,39	0,51	0,10
	G2_RN12	49,49	50,51	1,11	0,42	0,38	0,44	0,45	0,11
RN 2a	G2_RN13	57,07	42,93	1,08	0,38	0,34	0,39	0,53	0,10
	G2_RN14	45,45	54,55	1,08	0,30	0,27	0,30	0,68	0,08
	G2_RN15	50,51	49,49	1,11	0,37	0,35	0,39	0,54	0,10
	G2_RN16	53,03	46,97	1,10	0,40	0,36	0,41	0,51	0,10
	G2_RN17	50,00	50,00	1,11	0,39	0,36	0,40	0,53	0,10
RN 2b	G2_RN18	53,03	46,97	1,09	0,36	0,34	0,37	0,59	0,09
	G2_RN19	49,49	50,51	1,07	0,31	0,29	0,31	0,67	0,08
	G2_RN20	49,49	50,51	1,09	0,33	0,33	0,34	0,62	0,09
	G2_CR1	90,91	9,09	0,64	0,25	0,89	0,43	0,26	0,19
	G2_CR2	36,36	63,64	1,25	0,48	0,53	0,54	0,26	0,15
	G2_CR3	59,60	40,40	1,04	0,41	0,38	0,41	0,34	0,12
Wn	G2_CR4	26,26	73,74	1,51	0,60	0,73	0,79	0,26	0,22
	G2_CR5	88,38	11,62	0,69	0,30	0,85	0,44	0,26	0,20
	G2_CR6	59,09	40,91	1,00	0,40	0,44	0,40	0,26	0,13
	G2_CR7	40,91	59,09	1,23	0,54	0,52	0,59	0,28	0,15
	G2_CR8	79,29	20,71	0,82	0,36	0,67	0,40	0,28	0,15
LL _{CUP}	G2_CR9	41,92	58,08	1,22	0,54	0,51	0,59	0,28	0,15
	G2_CR10	90,91	9,09	0,61	0,26	0,95	0,47	0,28	0,20
	G2_CR11	45,96	54,04	1,17	0,51	0,47	0,54	0,28	0,14
	G2_CR12	37,88	62,12	1,23	0,51	0,52	0,56	0,23	0,15
eo	G2_CR13	48,48	51,52	1,08	0,45	0,39	0,46	0,23	0,14
	G2_CR14	58,59	41,41	1,01	0,42	0,44	0,42	0,23	0,13
e ₀ , LL _{CUP} . w _e	G2_CR15	33,84	66,16	1,30	0,52	0,55	0,60	0,28	0,15
e ₀ , LL _{CUD} , W ₂	G2_CR16	51,01	48,99	1,10	0,43	0,38	0,44	0,31	0,12
- 07									

Tabela 40 - Resumo estatístico das estimativas de CR para as amostras de solos de treinamento do Brasil (grupo G2)

Mariávaia	חו		K						
variaveis	U	% < 1	% > 1	μ	SD	RI	RD	R²	RMSE
	G2_RN1	37,50	62,50	1,20	0,54	0,45	0,58	0,61	0,09
	G2_RN2	43,75	56,25	1,18	0,55	0,44	0,58	0,58	0,10
RN 1a	G2_RN3	37,50	62,50	1,24	0,57	0,48	0,62	0,58	0,10
	G2_RN4	39,58	60,42	1,19	0,54	0,45	0,57	0,62	0,09
	G2_RN5	47,92	52,08	1,19	0,59	0,46	0,62	0,59	0,09
	G2_RN6	41,67	58,33	1,22	0,59	0,48	0,63	0,57	0,10
	G2_RN7	50,00	50,00	1,18	0,58	0,44	0,60	0,57	0,10
RN 1b	G2_RN8	39,58	60,42	1,21	0,60	0,51	0,63	0,52	0,10
	G2_RN9	41,67	58,33	1,21	0,55	0,45	0,59	0,68	0,09
	G2_RN10	33,33	66,67	1,31	0,64	0,57	0,72	0,40	0,13
	G2_RN11	43,75	56,25	1,18	0,51	0,43	0,54	0,62	0,09
	G2_RN12	43,75	56,25	1,23	0,55	0,49	0,60	0,55	0,10
RN 2a	G2_RN13	43,75	56,25	1,19	0,58	0,45	0,61	0,59	0,09
	G2_RN14	43,75	56,25	1,20	0,62	0,44	0,65	0,55	0,10
	G2_RN15	41,67	58,33	1,23	0,54	0,48	0,58	0,60	0,10
RN 2b	G2_RN16	43,75	56,25	1,23	0,60	0,49	0,65	0,56	0,10
	G2_RN17	37,50	62,50	1,22	0,55	0,46	0,59	0,68	0,09
	G2_RN18	43,75	56,25	1,19	0,54	0,44	0,57	0,61	0,09
	G2_RN19	41,67	58,33	1,21	0,63	0,48	0,66	0,58	0,10
	G2_RN20	39,58	60,42	1,23	0,58	0,47	0,63	0,66	0,09
	G2_CR1	87,50	12,50	0,71	0,32	0,83	0,43	0,21	0,18
	G2_CR2	27,08	72,92	1,38	0,62	0,65	0,73	0,21	0,17
	G2_CR3	43,75	56,25	1,15	0,55	0,45	0,57	0,35	0,12
Wn	G2_CR4	20,83	79,17	1,68	0,76	0,85	1,02	0,21	0,25
	G2_CR5	81,25	18,75	0,75	0,39	0,82	0,46	0,21	0,19
	G2_CR6	50,00	50,00	1,10	0,52	0,41	0,52	0,21	0,13
	G2_CR7	37,50	62,50	1,40	0,74	0,67	0,84	0,27	0,17
	G2_CR8	68,75	31,25	0,93	0,49	0,61	0,50	0,27	0,14
LL _{CUP}	G2_CR9	37,50	62,50	1,39	0,74	0,66	0,83	0,27	0,17
	G2_CR10	89,58	10,42	0,69	0,36	0,90	0,48	0,27	0,19
	G2_CR11	39,58	60,42	1,32	0,70	0,61	0,77	0,27	0,16
	G2_CR12	25,00	75,00	1,38	0,65	0,65	0,75	0,17	0,17
e ₀	G2_CR13	39,58	60,42	1,21	0,57	0,52	0,60	0,17	0,15
	G2_CR14	52,08	47,92	1,11	0,54	0,43	0,55	0,17	0,14
e ₀ , LL _{CUP} , w _n	G2_CR15	20,83	79,17	1,46	0,68	0,69	0,82	0,24	0,18
e ₀ , LL _{CUP} , w _n	G2_CR16	43,75	56,25	1,22	0,59	0,51	0,63	0,27	0,13
Fonto: Autor (2010)								

Tabela 41 - Resumo estatístico das estimativas de CR para as amostras de solo de validação cruzada do Brasil (grupo G2)

A Figura 61 apresenta graficamente os resultados estatísticos das redes neurais e das correlações empíricas, podendo ser destacadas as RNAs G2_RN2 e G2_RN9, ambas com uma única camada oculta.





Fonte: Autor (2019)

Analisando as estimativas de CR das amostras de solos do grupo G2 em termos dos tipos de solos classificados pelo SUC, os resultados para as duas classes avaliadas, CH e MH-OH refletem aproximadamente os resultados globais observados para todas as amostras do Brasil, considerando que essas classes formam a maior parte das

amostras de solos investigadas nesta pesquisa. Entretanto, em termos gerais, podese apontar que os resultados estatísticos apurados para as amostras de solos MH-OH foram ligeiramente melhores. Para a classe de solo CH são destacadas as redes com única camada oculta G2_RN2 e G2_RN9, além das correlações empíricas simples CR-wn (G2_CR3), proposta por Vidalie (1977) e CR-e₀ (CR14), proposta nesta pesquisa de mestrado (Eq. CR-f), conforme pode ser observado na Figura 62.

Figura 62 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 102) e (b) validação cruzada (n = 29), para as amostras de solos CH do Brasil (grupo G2)



Fonte: Autor (2019)

Quanto às amostras de solo MH-OH, no geral, o balanço em termos de valor da $\mu(K)$ é ligeiramente superior ao observado para as argilas de alta plasticidade, indicando que os valores de CR são normalmente superestimados. São destacadas as redes com única camada oculta G2_RN4 e G2_RN9. Já as melhores correlações empíricas simples foram CR-wn (CR6) e CR-e0 (CR14), ambas propostas nesta pesquisa (Eq. CR-b e CR-f, respectivamente). A Figura 63 apresenta os resultados das estimativas de CR para a classe de solo MH-OH.

Figura 63 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para **(a)** treinamento (n = 77) e **(b)** validação cruzada (n = 20), para as amostras de solos MH-OH do Brasil (grupo G2)



Individualizando os resultados por estados brasileiros, conservando os mesmos critérios da apresentação dos resultados de C_c, as estimativas de CR pelas redes neurais indicam ser melhores aplicadas para Santa Catarina (SC), apresentando os melhores parâmetros estatísticos, como *RMSE* médio aproximadamente 40% menor ao observado para o Rio de Janeiro (RJ), além disso, *RI* e *RD* são 21% inferiores, e *R*² 20% superior, considerando as estimativas de CR para o sítio RJ superiores às observadas para o Espírito Santo. Destacando a melhor rede neural por estado: ES (G2_RN2), RJ (G2_RN5) e SC (G2_RN5).

Complementando a análise dos resultados por estado, o comportamento das estimativas de CR pelas correlações empíricas apresenta o mesmo padrão das análises gerais, com grande variação entre os parâmetros estatísticos observados. Para o Rio de Janeiro podem ser destacadas as correlações empíricas CR-wn (G2 CR3), proposta por Vidalie (1977) e CR-e₀ (G2 CR14), proposta nesta pesquisa (Eq. CR-f), ambas com desempenho inferiores às RNAs, como evidenciado por um valor médio de $R^2 = 0.24$ e SD(K) = 0.35. As correlações empíricas CR-w_n (G2_CR6) e CR-e0 (G2_CR14), ambas propostas nesta pesquisa (Eq. CR-b e CR-f, respectivamente), apresentam os melhores resultados para Santa Catarina, registrando um valor médio de $R^2 = 0.53$ considerando as amostras do treinamento e da validação cruzada, além disso registram SD(K) = 0,32, cerca de 10% superior à média medido pelas redes neurais, evidenciando aproximação dessas correlações às RNAs. Já para o Espírito Santo, medido apenas para as amostras de solos da fase de treinamento, os parâmetros estatísticos em geral são pronunciadamente inferiores aos outros dois estados e também às redes neurais, destacando-se também as mesmas correlações observadas para Santa Catarina.

A Figura 64, a Figura 65 e a Figura 66 apresentam graficamente os parâmetros estatísticos das estimativas de CR segundo os estados do Rio de Janeiro, Santa Catarina e Espírito Santo.

Figura 64 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 46) e (b) validação cruzada (n = 14), para as amostras de solos do RJ (grupo G2)



Redes Neurais e Correlações Empíricas

Fonte: Autor (2019)



Figura 65 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 75) e (b) validação cruzada (n = 15), para as amostras de solos de SC (grupo G2)

Fonte: Autor (2019)



Figura 66 - Resultados estatísticos das estimativas de CR a partir de correlações empíricas e redes neurais para (a) treinamento (n = 49), para as amostras de solos do ES (grupo G2)

Fonte: Autor (2019)

4.4 SENSIBILIDADE DAS PROPRIEDADES ÍNDICES

Conforme observado na Tabela 5 e na Figura 21 as propriedades índices do solo apresentam uma correlação diferente com os parâmetros de compressibilidade unidimensional, sendo w_n e e₀ as variáveis com maior correlação com C_c, seguidas por LL_{CUP} e IP. Já a taxa de compressão (CR) apresenta maior correlação com IP e w_n, seguida por e₀ e LL_{CUP}, embora os valores observados de *R*² sejam praticamente iguais para as 4 variáveis, o que se difere de C_c. Neste tópico é analisada a influência de cada propriedade índice na capacidade de generalização das RNAs, medida inicialmente através da validação das redes treinadas segundo a proposta de Shahin, Maier e Jaksa (2005), e também pelo treinamento de novas redes neurais excluindo uma das propriedades índices do solo.

Shahin, Maier e Jaksa (2005) propõe uma análise de robustez das redes treinadas com base nas respostas das redes em função do grau de liberdade das variáveis de entrada. A técnica consiste, para todas as variáveis de entrada, exceto uma, fixar os valores da entrada na média dos valores observados, e para a última variável criar valores sintéticos variando entre o mínimo e o máximo observados, seguindo um incremento de 5%. As respostas da rede são examinadas. O processo é repetido para todas as variáveis de entrada.

Adaptando a interpretação dessa proposta para esta pesquisa, foi escolhida uma das redes neurais com melhor desempenho para as estimativas de C_c e de CR. Foram definidos os valores sintéticos para cada propriedade índice. Assim, as novas entradas de dados foram levadas às redes neurais previamente treinadas para preverem novos saídas de C_c e CR. As saídas são assim avaliadas, em termos de resultados às expectativas de valores das medidas de C_c ou CR para os intervalos de análise da propriedade índice incrementada.

Considerando o desempenho das redes neurais treinadas nesta pesquisa foram destacadas a rede RN3 treinada para estimar C_c e a rede RN2 treinada para estimar CR, ambas do grupo de análise de todas as amostras de solos da base (G1).

Com base no comportamento natural das propriedades índices com C_c e CR, esperase que os valores calculados desses índices através dos dados sintéticos apresentem a mesma tendência, caso contrário a interpretação possível é que a propriedade índice incrementada pouco influencia na modelagem das redes neurais.

A Figura 67 apresenta os gráficos de correlações entre C_c estimado pela rede RN3 com as entradas modificadas de acordo com os critérios anteriormente discutidos, em comparação aos respectivos gráficos de correlação entre C_c medido e a própria propriedade índice, para os dados originais do modelo. Nota-se que as respostas da RN3 com as entradas sintéticas variando LL_{CUP} e IP (**a**, **b**) apresentam correlação positiva e direta entre C_c estimado e as respectivas propriedades índices, o que evidentemente era o esperado. Esse comportamento demonstra, que para o teste proposto, essas variáveis exercem menor influência na modelagem da rede. Por outro lado, para a variação de w_n e e₀ (**c**, **d**) as saídas da RN3 ficaram prejudicadas, com o comportamento dos gráficos distintos ao esperado. Essa constatação indica que essas duas variáveis são as mais sensíveis na modelagem da rede neural. Considerando que as amostras de argilas estudadas são saturadas é natural a forte correlação entre w_n e e₀, o que consequentemente se reflete na avaliação da sensibilidade dessas duas propriedades índices.



Figura 67 – Teste de sensibilidade das propriedades índices do solo na modelagem de redes neurais para a estimativa de $C_{\rm C}$

(a), (b), (c) e (d) representam a dispersão dos pontos de C_c estimado x as propriedades índices com valores sintéticos: LL_{CUP}, IP, w_n e e₀, respectivamente. (a'), (b'), (c') e (d') representam as correlações entre C_c medido e as propriedades índices LL_{CUP}, IP, w_n e e₀, respectivamente.

Por outro lado, a Figura 68 apresenta os resultados para os testes da avaliação da sensibilidade para o cálculo de CR. Conforme pode ser observado na Figura 68 (a-a', c-c', d-d'), para as propriedades LL_{CUP}, w_n e e₀, o comportamento dos gráficos das

estimativas de CR pela rede RN2 foram aleatórios ao comportamento esperado, o que denuncia que essas variáveis são as mais sensíveis para a modelagem das redes neurais na previsão de CR.



Figura 68 - Teste de sensibilidade das propriedades índices do solo na modelagem de redes neurais para a estimativa de CR

(a), (b), (c) e (d) representam a dispersão dos pontos de CR estimado x as propriedades índices com valores sintéticos: LL_{CUP}, IP, w_n e e₀, respectivamente. (a'), (b'), (c') e (d') representam as correlações entre CR medido e as propriedades índices LL_{CUP}, IP, w_n e e₀, respectivamente.

Complementando a análise de sensibilidade das propriedades índices na modelagem das redes, também foram treinadas novas redes neurais com apenas três variáveis de entrada, dotadas de uma única camada oculta e 5 neurônios, operando as funções de ativação LogSig na camada oculta e linear na saída. Essa abordagem foi uma tentativa de avaliar se a retirada de determinada variável na modelagem implicaria em mudanças substanciais nos parâmetros estatísticos avaliados. Os resultados, conforme apresentados na Tabela 42 e na Tabela 43 foram inconclusivos, dado que tanto para as estimativas de C_C quanto de CR os parâmetros estatísticos apurados foram semelhantes.

Tabela 42 – Resultados estatísticos da previsão de C_C com redes treinadas excluindo uma propriedade índice do solo

Variável	% k < 1	% k> 1	μ(K)	SD (K)	RI	RD	R²	RMSE
Sem_LL _{CUP}	41,43	58,57	1,11	0,35	0,36	0,37	0,80	0,24
Sem_IP	36,87	63,13	1,14	0,36	0,38	0,38	0,79	0,24
Sem_w _n	41,22	58,78	1,11	0,34	0,35	0,36	0,79	0,24
Sem_e ₀	42,45	57,55	1,10	0,36	0,36	0,37	0,80	0,24

Fonte: Autor (2019)

Tabela 43 - Resultados estatísticos da previsão de CR com redes treinadas excluindo uma propriedade índice do solo.

Variável	% k < 1	% k> 1	μ(K)	SD (K)	RI	RD	R²	RMSE
Sem_LL _{CUP}	40,41	59,59	1,09	0,32	0,32	0,33	0,64	0,08
Sem_IP	45,51	54,49	1,07	0,32	0,31	0,32	0,63	0,08
Sem_wn	42,93	57,07	1,08	0,32	0,31	0,33	0,63	0,08
Sem_e ₀	41,43	58,57	1,09	0,33	0,33	0,34	0,64	0,08

5.0 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

5.1 CONCLUSÕES

Nesta dissertação foi avaliada a capacidade de estimativa do índice de compressão (Cc) e da taxa de compressão (CR) a partir de redes neurais artificias e de correlações empíricas previamente publicadas na literatura e correlações empíricas de ajuste propostas nesta pesquisa. As estimativas foram avaliadas usando uma base de dados de 2.022 amostras de solos argilosos moles de diferentes sítios geológicos do Brasil e de outros países, composta pelas propriedades índices LL_{CUP}, w_n, e₀ e IP.

Dada a heterogeneidade das amostras de solos foi empregada a técnica estatística de *boxplot* para a identificação de discrepâncias na base de dados. Nesse sentido, os sítios geológicos foram extrapolados para o contexto geográfico de um país, e avaliada a distribuição para cada propriedade índice, resultando na remoção de 207 amostras de solos da base. No geral, as discrepâncias encontradas foram majoritariamente em amostras de solos de alta compressibilidade, marcadas por valores elevados de w_n e LL_{CUP}, esta última apresentava valores máximos de 400%, sendo reduzidos para 200%.

O treinamento das RNAs utilizou o programa *Matlab*, através das *toolboxes nftool* e *nntool*. As amostras de solos foram organizadas em dois grupos para avaliação: grupo G1, com todas as 1.815 amostras de solos da base e grupo G2, composta apenas com as amostras de solos do Brasil (255). Para ambos os grupos, foram utilizados 80% da base para o treinamento e 20% para a validação cruzada. As RNAs foram treinadas com o algoritmo Levenberg-Marquardt, associados às funções de ativação LogSig, TanSig e Linear, operando em diferentes combinações, em uma ou duas camadas ocultas.

Através de técnicas estatísticas de regressão linear e avaliação da normalidade de distribuição dos resíduos, através do teste de normalidade Kolmogorov-Smirnov, usando o programa *Minitab*, foram propostas novas correlações empíricas de ajustes simples e com múltiplas variáveis para as estimativas de C_c e CR, para os dois grupos de amostras de solos organizados.

Foram adotados os critérios estatísticos: (i) a raiz do erro quadrático médio – *root mean squared error* (*RMSE*), (ii) o coeficiente de determinação (R^2), (iii) a variação do índice de compressão medido e estimado (*K*), (iv) índice de classificação – *ranking index* (*RI*) e (v) índice de distância – *ranking distance* (*RD*) para avaliação da capacidade de previsões das correlações empíricas e das RNAs.

Analisando os resultados do grupo G1 em termos gerais para estimar Cc, foi observado que todas as RNAs treinadas apresentam parâmetros estatísticos ligeiramente constantes, revelando que a arquitetura adotada não sugere grande interferência nas previsões do índice de compressão. Por outro lado, as correlações empíricas apresentam comportamento divergente dos parâmetros estatísticos avaliados, especialmente para as correlações com LL_{CUP}. Em geral as correlações empíricas e as RNAs tendem a subestimar os valores Cc > 1. Para as correlações empíricas, melhores resultados foram observados para as correlações com w_n e e₀ e com múltiplas variáveis, com R^2 próximo a 0,80 e *RMSE* a 0,25, podendo ser destacadas as correlações empíricas simples de ajustes Cc-w_n (Eq. Cc-a) e Cc-e₀ (Eq. Cc-e), e a correlações com múltiplas variáveis variáveis com múltiplas variáveis de mestrado.

Os resultados do grupo G1 apurados de acordo com o tipo SUC revelam também desempenho estatístico mais favorável para as RNAs, com pouca variação para as diferentes arquiteturas avaliadas. Para as amostras de solos CH, destacam-se as correlações empíricas Cc-wn (C4 e C7), propostas por Bicalho *et al.* (2014) para solos moles da Grande Vitória, ES, e nesta pesquisa (Eq. Cc-a), respectivamente, ambas com valores de *RMSE* < 0,4. Ainda, para os solos moles CH podem ser apontadas as correlações com e₀, C16 (KOOTAHI; MORADI, 2016) e C17 (Eq. Cc-e). A correlação com múltiplas variáveis C21 (Eq. Cc-g) também apresenta desempenho satisfatório. Quanto as amostras de solos MH-OH, o desempenho das RNAs foi semelhante ao observado para a classe de solo CH, com pouca diferença entre as redes, podendo destacar as correlações simples Cc-wn (C2) e Cc-e₀ (C16), ambas propostas por Kootahi e Moradi (2016), além da correlação empírica com múltiplas variáveis, Eq. Cc-g, proposta nesta pesquisa também apresentou desempenho estatístico próximo aos das RNAs para a classe de solo CL.

Avaliando os resultados do grupo G1 para alguns sítios geológicos distintos, foi possível constatar que as RNAs avaliadas apresentaram comportamento estatístico próximo para a maioria dos países avaliados. Quanto ao Brasil, as redes treinadas com todas as amostras da base de dados apresentaram similaridade de desempenho, podendo ser destacadas as redes com única camada oculta RN4 e RN10, apresentando coeficiente de determinação próximo a 0,80. Por outo lado, as correlações empíricas avaliadas mostram o mesmo comportamento do grupo geral, grande dispersão de desempenho entre as equações avaliadas, sendo os melhores resultados encontrados pelas correlações empíricas de ajustes propostas nesta pesquisa: Cc-wn (Eq. Cc-a), Cc-e₀ (Eq. Cc-e) e Cc-LL_{CUP}, e₀, w_n (Eq. C21), ambas com R^2 próximo a 0,7 e *RMSE* < 0,4.

Além do destaque para o Brasil, outros sítios geológicos foram avaliados. O Canadá, revelou que as estimativas das RNAs e da maioria das correlações empíricas apresentaram valor elevado de R^2 , 0,80 e 0,70 respectivamente, além disso, diferente do observado para todas as amostras de solos, as correlações com LL_{CUP} apresentam valores de *RI* e *RD* inferiores às correlações com w_n.

Olhando o sítio geológico Coreia, são destacados os valores elevados do coeficiente de determinação observados pelas redes e correlações empíricas, próximos a 0,90. Embora as redes apresentem desempenho estatístico similares, a rede RN6, com uma única camada oculta com 2 neurônios, operando a função de ativação TanSig parece apresentar maior potencial de previsão. As correlações empíricas Cc-LLcuP (C11) de Kootahi e Moradi (2016) e Cc-wn, eo, LLcuP, proposta neste estudo (Eq. Cc-g) apresentam os melhores desempenhos, embora tendam a superestimar o índice de compressão.

O sítio geológico da Indonésia revela que para as redes e as correlações empíricas, os valores elevados de SD(K) mostram que as previsões de C_c não estão ajustadas à média, corroborando o trabalho de Sari e Firmansyah (2013), que mostram que existe dificuldades em propor correlações empíricas de estimativas de C_c para essas amostras de solos dessa região.

Entre os sítios geológicos avaliados, o iraniano apresentou a maior homogeneidade em termos de compressibilidade, sendo predominantemente de argilas de baixa compressibilidade, CL. Essa característica, previsivelmente poderia indicar melhor ajuste dos parâmetros estatísticos, considerando os critérios de pré-processamento dos dados de entrada para limites mais homogêneos, entretanto, os resultados encontrados mostram baixos valores de correlações entre C_c medido e C_c estimado, para as redes e para as correlações empíricas. Além disso, os resultados das redes sugerem, que para amostras de solos CL, as redes com duas camadas ocultas são mais indicadas, como a rede RN19, com 9 e 5 neurônios escondidos, operando as funções de ativação LogSig e TanSig nas camadas ocultas, respectivamente.

Dentre os países avaliados, as amostras de solos marinhos do Japão, majoritariamente de alta compressibilidade, apresentaram resultados estatísticos próximos aos encontrados para as amostras de solos marinhos da Coreia, podendo ser destacada a rede RN2 de camada única oculta, com 3 neurônios. Os melhores resultados das correlações empíricas foram observados para C_C-w_n (C2), de Kootahi e Moradi (2016), juntamente com a C21 (Eq. C_C-g), proposta nesta pesquisa (C_C-LL_{CUP}, e₀, w_n), onde *RMSE* < 0,13, *R*² próximo a 0,85 e valores de *RI* e *RD* inferiores a 0,3.

Dados os resultados observados, nota-se que as estimativas de Cc pelas RNAs foram mais assertivas para todos os cenários geológicos avaliados em detrimento das correlações empíricas. Além disso é possível destacar que independentemente do método de estimativas adotado: RNAs ou correlações empíricas, a qualidade das amostras parece ser fator essencial para o desempenho dos resultados. Além disso, considerando o histograma de distribuição das amostras, os sítios geológicos como Japão e Coreia que apresentaram melhores resultados estatísticos, são compostos por amostras de solos com valores de C_c mais representativos do grupo geral.

Embora exista forte correlação entre C_c e CR, a tentativa de prever CR a partir de correlações empíricas e redes neurais usando as propriedades índices do solo avaliadas nesta pesquisa, mostraram-se menos favoráveis que as estimativas de C_c. para o conjunto de todas as amostras, o desempenho das estimativas de CR foi inferior às estimativas de C_c pelas redes neurais, como exemplificado em valores de *R*² em média 25% menores. As estimativas de CR pela correlação empírica simples CR-w_n (CR2), proposta por Vidalie (1977) para argilas francesas e a correlação empírica com múltiplas variáveis CR-w_n, e₀, LL_{CUP} (CR15), proposta nesta pesquisa (Eq. CR-g) tiveram desempenhos próximos aos das RNAs. Podendo ser destacadas também as RNAs de única camada oculta, como a RN2 e a RN5. É possível destacar que correlações empíricas com múltiplas variáveis variáveis não implicaram na melhor opção

para as previsões de CR, o que corrobora as conclusões de Azzouz, Krizek e Corotis (1976).

Quando avaliadas as estimativas de CR apenas para o destaque de países, nota-se que para o sítio geológico da Coreia melhores resultados foram alcançados pelas correlações com LL_{CUP}, inclusive com melhor resultado obtido pela correlação empírica CR10 (Eq. CR-c), proposta nesta pesquisa em detrimento das redes neurais. Importante destacar, os resultados das redes mostraram-se mais consistentes para as amostras de solos moles de baixa compressibilidade, com SD(K) 30% mais favorável que a média entre as amostras de solo CH e MH-OH, além de R^2 60% superior. Os resultados das estimativas de CR mostram que, para as amostras de solo com alta plasticidade, os resultados da validação cruzada são discrepantes em relação à fase de treinamento, o que sugere dificuldade de generalização das redes para as estimativas da taxa de compressão, entretanto, melhores generalizações são encontradas para as amostras de baixa compressibilidade.

Analisando os resultados do grupo G2, apenas as amostras de solos do Brasil, notase que as propriedades índices das amostras de solo do litoral brasileiro apresentam, no geral, valores de *R*² inferiores à média de todas as 1.815 amostras da base de dados. Semelhante ao comportamento do treinamento das redes com amostras do grupo G1, na oportunidade de treinamento do grupo G2, o desempenho das RNAs apresenta baixa variação entre as diversas arquiteturas avaliadas, embora na fase da validação cruzada é observada maior distância entre os parâmetros estatísticos avaliados, especialmente *RI*, que indica menor acurácia das estimativas. Por outro lado, esse padrão de similaridade não é observado nas correlações empíricas. As correlações com LL_{CUP} apresentam um comportamento mais divergente entre as equações.

Em uma análise geral, os melhores resultados estatísticos foram observados pelas redes neurais, não tendo grande relevância da arquitetura da rede, sendo que redes treinadas com uma única camada oculta, mostraram-se satisfatórias, conforme já observado na análise do grupo G1. Quanto às correlações empíricas, destacam-se a correlação simples com w_n G2_C7 (Eq. C_C-b) e a correlação com múltiplas variáveis G2_C23 (Eq. C_C-h), ambas propostas nesta pesquisa. Comparando os resultados das estimativas de C_C obtidos no grupo G2 aos resultados do destaque para o Brasil

obtidos no grupo G1, nota-se similaridades dos resultados, o que indica capacidade de generalização das redes neurais.

Avaliando os resultados das estimativas de C_c pelo grupo G2 para o contexto de estado brasileiro, maiores acurácia e precisão medidas em termos de *RI* e *RD* foram encontrados para os estados de Santa Catarina e RJ, respectivamente, tanto pelas RNAs quanto pelas correlações empíricas.

Ainda, dentro do grupo G2, uma primeira observação está no fato das redes neurais treinadas tanto com amostras do grupo G1 quanto do grupo G2 apresentarem desempenhos estatísticos semelhantes, como refletidos nos valores médios de RMSE e R^2 praticamente idênticos para ambos os grupos, próximos a 0,10 e 0,58, respectivamente. Em termos dos valores de $\mu(K)$ superiores a 1 os valores de CR são superestimados, corroborando os resultados encontrados também no grupo G1. Comparando os melhores resultados encontrados pelas RNAs e pelas correlações empíricas, nota-se que o valor de $R^2 = 0,22$ das correlações empíricas é 62% inferior aos observados pelas redes, RMSE = 0,13 é 39% superior, embora ambos os métodos sejam equivalentes em termos de SD(K), RI e RD. Em termos estatísticos, considerando todas as amostras de solos do grupo G2, o desempenho das RNAs foram mais favoráveis que as correlações empíricas. Analisando as estimativas de CR das amostras do grupo G2 em termos das classes de solos SUC, os resultados para as duas classes avaliadas, CH e MH-OH refletem aproximadamente os resultados globais observados para todas as amostras do Brasil, considerando que essas classes formam a maior parte das amostras de solos. Entretanto, em termos gerais, pode-se apontar que os resultados estatísticos apurados para as amostras de solos MH-OH foram ligeiramente melhores.

Os resultados apresentados revelam que as RNAs treinadas têm potencial de aplicação para as estimativas dos índices de compressão de solos moles como alternativa às correlações empíricas durante a investigação preliminar de adequação de estudos de geotecnia. Importante destacar que as correlações empíricas são melhores aplicadas aos sítios geológicos de origem. Pela capacidade de aprender, os resultados de RNA adaptados são menos influenciados pela variabilidade natural do local geográfico. Além disso, o método da RNA sempre pode ser atualizado para obter melhores resultados, apresentando novos exemplos de solos de treinamento à medida que novos conjuntos de dados com valores de C_c medidos e propriedades

índices correspondentes dos solos argilosos investigados se tornam disponíveis. Assim, a RNA é um método útil para avaliar a variação dos valores preditivos da compressibilidade unidimensional de solos moles da costa brasileira e de outros países em estudos preliminares de geotecnia.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Esta pesquisa não tem a pretensão de esgotar os estudos acerca da aplicação de RNAs na tentativa de prever o índice de compressão e a taxa de compressão de solos moles, pelo contrário, procura contribuir de forma pontual com esse potencial na engenharia geotécnica.

Considerando que as arquiteturas possíveis das redes neurais artificiais para treinamento são incontáveis, sugere-se que novas abordagens sejam adotadas para melhor aproximação dos índices avaliados.

Uma informação bem difundida na literatura consiste no pré-processamento dos dados de entrada como essencial para o bom desempenho das RNAs, nesse sentido, sugere-se que novas formas de pré-processamento das amostras de solos sejam realizadas. Contemplando nessa análise o agrupamento das amostras de solos para treinamento e validação cruzada, um bom ponto de partida consiste no uso de redes neurais não supervisionadas do tipo *Self Organized Maps* (SOM), conhecidas como redes neurais do tipo Mapas de Kohohen. Essa abordagem permitirá o agrupamento das amostras de solos segundo correlações escondidas entre os dados, numa tarefa conhecida como clusterização. Essa abordagem permitirá agrupar os dados segundo similaridades que extrapolam o contexto geográfico.

Além das sugestões anteriores, sugere-se a implementação de uma *toolbox* específica no *Matlab* para uso dos pesos sinápticos das redes treinadas que seja capaz de classificar a amostra de solo segundo os critérios de uma rede SOM treinada e aplicar os pesos sinápticos dos treinamentos para o cálculo de C_C e CR.
REFERÊNCIAS

ABDEL-GAWAD, S. T.. Correlation between geotechnical and acoustic properties of marine sediments – Outer Placentia Bay, Newfoundland. 1980. 137 f. Dissertação (Mestrado) - Curso de Engineering and Applied Science, Memorial University of Newfoundland, Newfoundland, Canada, 1980. Disponível em: <https://research.library.mun.ca/7765/>. Acesso em: 20 out. 2018.

ABDULLAYEV, E.; LEROY, S. A. G. Provenance of clay minerals in the sediments from the Pliocene Productive Series, western South Caspian Basin. **Marine and Petroleum Geology**, [s.l.], v. 73, p.517-527, maio 2016. Elsevier BV. http://dx.doi.org/10.1016/j.marpetgeo.2016.03.002.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 12007**: Solo – Ensaio de adensamento unidimensional. Rio de Janeiro, 1990.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6459**: Solo – Determinação do limite de liquidez. Rio de Janeiro, 2017.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7180**: Solo – Determinação do limite de plasticidade. Rio de Janeiro, 2016a.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7181**: Solo – Análise Granulométrica. Rio de Janeiro, 2016b.

ABU-FARSAKH, M. Y.; TITI, H. H. Assessment of Direct Cone Penetration Test Methods for Predicting the Ultimate Capacity of Friction Driven Piles. **Journal Of Geotechnical and Geoenvironmental Engineering**, [s.l.], v. 130, n. 9, p.935-944, set. 2004. American Society of Civil Engineers (ASCE). http://dx.doi.org/10.1061/(asce)1090-0241(2004)130:9(935).

AL-KHAFAJI, A. W. N.; ANDERSLAND, O. B. Equations for Compression Index Approximation. **Journal of Geotechnical Engineering**, [s.l.], v. 118, n. 1, p.148-153, jan. 1992. American Society of Civil Engineers (ASCE). http://dx.doi.org/10.1061/(asce)0733-9410(1992)118:1(148).

ALMEIDA, M. S. S.; MARQUES, M. E. S. Aterros sobre solos moles: projeto e desempenho. 2. ed. São Paulo: Oficina de Textos, 2014. 254 p.

ALMEIDA, R. L. F. **Aplicação de redes neurais artificiais para aproximar o comportamento de estruturas.** 2012. 115 f. Dissertação (Mestrado) - Curso de Engenharia Mecânica, Universidade Nova de Lisboa, Lisboa, 2012.

ALMEIDA, M. S. S.; FUTAI, M. M.; LACERDA, W. A.; MARQUES, M. E. S. Laboratory behavior of Rio de Janeiro soft clays . Index and compression properties– part 1. *Soils and Rocks*. 31 (2), p. 69-75, 2008.

ALVES, A. M. L.; SANTA MARIA, P. E. L. Análise probabilística de problemas

geotécnicos: aplicação a argila do Sarapuí. **Solos e Rochas**. Vol. 24, No. 1, p. 83-93, 2001.

AMERICAN SOCIETY FOR TESTING AND MATERIALS ASTM. **4186**: Standard Test Method for One-Dimensional Consolidation Properties of Saturated Cohesive Soils Using Controlled-Strain Loading. [s.i.], 2012.

ANDRADE, M. E. S. **Contribuição ao estudo das argilas moles da cidade de Santos.** 2009. 397 f. Dissertação (Mestrado) - Curso de Engenharia Civil, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2009.

AZZOUZ, A. S.; KRIZEK, R. J.; COROTIS, R. B. Regression analysis of soil compressibility. **Soils And Foundations**, [s.l.], v. 16, n. 2, p.19-29, 1976. Elsevier BV. http://dx.doi.org/10.3208/sandf1972.16.2_19.

BAIN, J. A. Plasticity Chart as an Aid to the Identification and Assessment of Industrial Clays. **Clay Minerals**, [s.l.], v. 9, n. 1, p.1-17, 1971. Mineralogical Society. http://dx.doi.org/10.1180/claymin.1971.009.1.01.

BALASUBRAMANIAM, A. S.; BRENNER, R. P. Consolidation and Settlement of Soft Clay. **Developments in Geotechnical Engineering**, [s.l.], p.479-566, 1981. Elsevier. http://dx.doi.org/10.1016/b978-0-444-41784-8.50010-1.

BARAN, K. R. **Propriedades geotécnicas de compressibilidade de uma argila mole de Itajaí-SC**. 2014. 335 f. Dissertação (Mestrado), Curso de Engenharia Civil, Centro Tecnológico, Universidade Federal de Santa Catarina, Santa Catarina, 2014.

BARBOSA, A. H. Análise de confiabilidade estrutural utilizando o método de monte carlo e redes neurais. 2004. 143 f. Dissertação (Mestrado) – Curso Engenahria Civil, do Departamento de Engenharia Civil, Escola de Minas, Universidade Federal de Ouro Preto. Ouro Preto, Minas Gerais, 2004.

BARONI, M; ALMEIDA, M. S. S. Compressibility and stress history of very soft organic clays. **Proceedings Of The Institution Of Civil Engineers - Geotechnical Engineering**, [s.l.], v. 170, n. 2, p.148-160, abr. 2017. Thomas Telford Ltd.. http://dx.doi.org/10.1680/jgeen.16.00146.

BENALI, A. N.; BOUZID, A. "Principal Component Analysis and Neural Networks for Predicting the Pile Capacity Using SPT," *International Journal of Engineering and Technology* vol. 5, no. 1, pp. 162-169, 2013.

BERGER, V. W.; ZHOU, Y. Y. Kolmogorov-Smirnov Test: Overview. Wiley StatsRef: Statistics Reference Online pp 1-5, 2014.

BICALHO, K. V.; BATISTITI, V. G.; XIMMENES, Roberta B. Compressibilidade das argilas marinhas, Grande Vitória, ES, Brasil. *Comunicações Geológicas* (2014). Especial III, CNG/2º CoGePLiP. Rio Grande do Sul, Porto Alegre, 2014a.

BICALHO, K. V.; BATISTI, V. G.; SANTANA, E. S.; DEPOLLI, I. C. Compressibilidade das argilas marinhas, Grande Vitória, ES, Brasil: Compressibilidade das argilas marinhas, Grande Vitória, ES, Brasil. In: XV PAN AMERICAN CONFERENCE ON SOIL MECHANICS AND GEOTECHNICAL ENGINEERING (XV PCSMGE), 15, 2015, Buenos Aires. **Proceedings.** Buenos Aires: Fundamentals to Applications In Geotechnics, 2015. v. 15, p. 1520 - 1527.

BRAGA, A. P.; CARVALHO, A. C. P. F..; LUDEMIR, T. B. Redes Neurais Artificiais: Teoria e Aplicações. Editora LTC. Rio de Janeiro, RJ. ed. 2. p.226, 2007.

BRIAUD, J.; TUCKER, L. M. Measured and Predicted Axial Response of 98 Piles. **Journal Of Geotechnical Engineering**, [s.l.], v. 114, n. 9, p.984-1001, set. 1988. American Society of Civil Engineers (ASCE). http://dx.doi.org/10.1061/(asce)0733-9410(1988)114:9(984).

CAMPOS, A. C. S. L. Características de compressibilidade de uma argila mole da
Zona Industrial de Santa Cruz, Rio de Janeiro. 2006. 175 f. Dissertação (Mestrado)
Curso de Engenharia Civil, Departamento de Engenharia Civil, Pontifícia
Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2006.

CARDOSO, S. H. **Comunicação entre as células nervosas.** 2000. Revista Eletrônica Cérebro e Mente. Disponível em: <http://www.cerebromente.org.br/n12/fundamentos/neurotransmissores/neurotransmi tters2_p.html>. Acesso em: 10 jun. 2018.

CASSETI, V. Geomorfologia. [S.I.]: [2005]. Disponível em: http://www.funape.org.br/geomorfologia/. Acesso em 31/08/2017.

CASTELLO, R. R.; POLIDO, U. F. Algumas características de adensamento das argilas marinhas de Vitória – ES. In: VIII Congresso Brasileiro de Mecânica dos Solos e Engenharia de Fundações. Porto Alegre, RS. p. 149 – 159, 1986.

CASTELLO, R. R.; POLIDO, U. F. Tentativa de sistematização dos solos quaternários de Vitória, ES. In: Depósitos Quaternários das baixadas litorâneas: Origem, Características Geotécnicas e Experiências de Obras. Rio de Janeiro, RJ. Anais... v. 2, p. 3.1-3.23, 1988.

CAUDIL, M. Neural networks primer, Part III. AI Expert, 3(6), p.53-59, 1988.

CHERUBINI, Claudio.; ORR, T. L. L. A rational procedure for comparing measured and calculated values in geotechnics. In: **Proceedings of the international symposium on coastal geotechnical engineering in practice**. p. 261-265, 2000.

COLOM, R.; KARAMA, S.; JUNG, R. E.; HAIER, R. J. Human intelligence and brain networks. **Dialogues In Clinical Neuroscience**, [s.i.], v. 12, n. 4, p.489-501, dez. 2010. Disponível em: https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3181994/. Acesso em: 02 jun. 2018.

COZZOLINO, V. M. Statistical forecasting of compression index. In: Proceedings of the fifth international conference on soil mechanics and foundation engineering, Paris. p. 51-53, 1961.

CRUMLEY, A. R.; FERNÁNDEZ, Américo L.; REGALADO, Carlos. A. Compressibility Relationships for soils in Puerto Rico. *Soils and Rocks*. Massachusetts. n. 12, p. 1-5, 2003.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics** of **Control, Signals, And Systems**, [s.l.], v. 2, n. 4, p.303-314, dez. 1989. Springer Nature. http://dx.doi.org/10.1007/bf02551274.

DAS, S. K.; BASUDHAR, P. K. Prediction of residual friction angle of clays using artificial neural network. **Engineering Geology**, [s.l.], v. 100, n. 3-4, p.142-145, set. 2008. Elsevier BV. <u>http://dx.doi.org/10.1016/j.enggeo.2008.03.001</u>.

DIMINSKY, A. S. Análise de problemas geotécnicos através de redes neurais. Tese (Doutorado em Engenharia Civil)-Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2000.

DJOENAIDI, W. J. Compendium of soil properties and correlations. 788f. Tese (Doutorado). The School of Civil and Mining Engineering, University of Sydney, Sydney, 1985.

ELNAGGAR, H. A.; KRIZEK, R. J. Statistical Approximation for Consolidation Settlement," *Highway Research Record*, No. 323, pp. 87–96, 1970.

FERNANDES, F. A. N.; LONA, L. M. F. Neural network applications in polymerization processes. **Brazilian Journal of Chemical Engineering**, [s.l.], v. 22, n. 3, p.401-418, set. 2005. FapUNIFESP (SciELO). http://dx.doi.org/10.1590/s0104-66322005000300009.

FLOOD, I.; KARTAM, N. Neural Networks in Civil Engineering. I: Principles and Understanding. **Journal of Computing In Civil Engineering**, [s.l.], v. 8, n. 2, p.131-148, abr. 1994a. American Society of Civil Engineers (ASCE). http://dx.doi.org/10.1061/(asce)0887-3801(1994)8:2(131).

FLOOD, I.; KARTAM, N. Neural Networks in Civil Engineering. II: Systems and Application. **Journal of Computing In Civil Engineering**, [s.l.], v. 8, n. 2, p.149-162, abr. 1994b. American Society of Civil Engineers (ASCE). http://dx.doi.org/10.1061/(asce)0887-3801(1994)8:2(149).

FOX, P. J.; PU, H.; CHRISTIAN, J. T. Evaluation of Data Analysis Methods for the CRS Consolidation Test. **Journal Of Geotechnical And Geoenvironmental Engineering**, [S.I.], v. 140, n. 6, [S.I.], jun. 2014. American Society of Civil Engineers (ASCE). http://dx.doi.org/10.1061/(asce)gt.1943-5606.0001103.

GAGARIN, N.; F., I.; ALBRECHT, P. "Computing Truck Attributes with Artificial Neural Networks", Journal of Computing in Civil Engineering, ASCE, Vol. 8, No. 2, p 179 – 200, 1994.

GOH, A T. C. Modeling Soil Correlations Using Neural Networks. **Journal Of Computing In Civil Engineering**, [s.l.], v. 9, n. 4, p.275-278, out. 1995. American Society of Civil Engineers (ASCE). http://dx.doi.org/10.1061/(asce)0887-3801(1995)9:4(275).

GOMES, P. C. C. **Geografia e Modernidade.** Rio de Janeiro: Bertrand Brasil, 1996. 482 p.

GÜLLÜ, H.; CANAKCI, H.; ALHASHEMY, A. Use of ranking measure for performance assessment of correlations for the compression index. **European Journal Of Environmental And Civil Engineering**, [s.l.], v. 22, n. 5, p.578-595, 18 jul. 2016. Informa UK Limited. http://dx.doi.org/10.1080/19648189.2016.1210036.

HAGAN, M. T.; MENHAJ, M. b. Training feedforward networks with the Marquardt algorithm. **Ieee Transactions On Neural Networks**, [s.l.], v. 5, n. 6, p.989-993, 1994. Institute of Electrical and Electronics Engineers (IEEE). http://dx.doi.org/10.1109/72.329697.

HAIGH, S. K. Mechanics of the Casagrande liquid limit test. **Canadian Geotechnical Journal.** p. 1015-1023. set. 2012. doi:10.1139/T2012-066.

HANZAWA, H.; FUKAYA, T.; SUZUKI, K. Evaluation of engineering properties for an Ariake clay. **Soils And Foundations**, [s.l.], v. 30, n. 4, p.11-24, 1990. Elsevier BV. http://dx.doi.org/10.3208/sandf1972.30.4_11.

HAYKIN, S. Neural Networks. A Comprehensive Foundation. Second Edition, Pearson Education, McMaster University, Hamilton, Ontario, Canada. 2001.

HECHT-NIELSEN, R. Theory of the back-propagation neural network. **Proceedings** of the International Joint Conference on Neural Networks, Washington, DC, p. 593-605, 1989.

HUANG, G.; SONG, S.; YOU, K. Trends in extreme learning machines: A review. **Neural Networks**, [s.l.], v. 61, p.32-48, jan. 2015. Elsevier BV. http://dx.doi.org/10.1016/j.neunet.2014.10.001.

ISIK, N. S. Estimation of swell index of fine grained soils using regression equations and artificial neural networks. **Scientific Research and Essay**, Vol.4 (10), pp. 1047-1056, October, 2009.

JARUSHI, F., ALKAABIM, S., COSENTINO, P. **A new correlation between SPT and CPT for various soils.** International Journal of Environmental, Chemical, Ecological, Geological and Geophysical Engineering, v. 9, n.2, 2015.

KALANTARY, F.; KORDNAEIJ, A. Prediction of compression index using artificial neural network. **Scientific Research And Essays**, [s.l.], v. 7, n. 31, p.2835-2848, 9 ago. 2012. Academic Journals. http://dx.doi.org/10.5897/sre12.297.

KASSIM, K. A.; RASHID, A. S. A.; KUEH, A.; CHONG, S. Y. Criteria of Acceptance for Constant Rate of Strain Consolidation Test for Tropical Cohesive Soil. **Geotechnical and Geological Engineering**, [s.l.], v. 34, n. 4, p.931-947, 21 abr. 2016. Springer Nature. http://dx.doi.org/10.1007/s10706-016-0016-8.

KHANNA, T.. **Foundations of neural networks.** [United States of America]: Addison-Wesley Publishing Company, 1990. 196 p.

KOLAY, P. K. ROSMINA, A. B; LING, N. W. Prediction of compression index for tropical soil by using artificial neural network. International Association for Computer Methods and Advances in Geomechanics (IACMAG), 2008. 1-6 October, India.

KOOTAHI, K.; MORADI, G. Evaluation of compression index of marine fine-grained soils by the use of index tests. **Marine Georesources & Geotechnology**, [s.l.], v. 35, n. 4, p.548-570, 29 jul. 2016. Informa UK Limited. http://dx.doi.org/10.1080/1064119x.2016.1213775.

KÓVACS, Z. L. **Redes Neurais Artificiais: fundamentos e aplicacões**. São Paulo: Acadêmica, 1996.

KRUEGER-BECK, E.; SCHEEREN, E. M.; NOGUEIRA-NETO, G. N.; BUTTON, V. L. S. N.; NEVES, E. B.; NOHAMA, P. Potencial de ação: do estímulo à adaptação neural. **Fisioterapia em Movimento**, [s.l.], v. 24, n. 3, p.535-547, set. 2011. FapUNIFESP (SciELO). http://dx.doi.org/10.1590/s0103-51502011000300018.

KURNAZ, T. Frikret; DAGDERIN, Ugur; YILDIZ, Murat; OZKAN, Ozhan. Prediction of compressibility parameters of the soils using artificial neural network. SpringPlus. 2016. 5:1801. p. 1 -11.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, [s.l.], v. 521, n. 7553, p.436-444, 27 maio 2015. Springer Nature. http://dx.doi.org/10.1038/nature14539.

LUGER, G. F. **Inteligência artificial.** 6. ed. São Paulo: Pearson *Education* do Brasil, 2013. 614 p. Tradução do original *Artificial intelligence* por Daniel Vieira.

LUNNE, T.; BERRE, T.; STRANDVIK, S. Sample disturbance effects in soft low plastic Norwegian clay. In: Symposium on Recent Developments in Soil and Pavement Mechanics. Rio de Janeiro, p81-102, 1997.

MARTIN, L.; SUGUIO, K.; DOMINGUEZ, J. M. L.; FLEXOR, J. M. Geologia do Quaternário costeiro do norte do Rio de Janeiro e do Espírito Santo. Belo Horizonte: CPRM, 1997. p.103.

MASSAD, F. Marine soft clays of Santos, Brazil: Building settlements and geological history. **Stand Alone**, [s.l.], n. 16, p.405-408, 2005. IOS Press. <u>http://dx.doi.org/10.3233/978-1-61499-656-9-405</u>.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, [s.l.], v. 5, n. 4, p.115-133, dez. 1943. Springer Science and Business Media LLC. http://dx.doi.org/10.1007/bf02478259.

MIKHAIL, E. M.; ACKERMAN, F. E. Observations and Least Squares. University Press of America, 1976. 497 p.

MINITAB. Guia de introdução ao Minitab. 2017.

MIRANDA, M. J. A inteligência humana: contornos da pesquisa. **Paidéia (ribeirão Preto)**, [s.l.], v. 12, n. 23, p.19-29, 2002. FapUNIFESP (SciELO). <u>http://dx.doi.org/10.1590/s0103-863x2002000200003</u>.

MYERS, D. Reliability and Statistics in Geotechnical Engineering. **Technometrics**, [s.l.], v. 47, n. 1, p.103-104, fev. 2005. Informa UK Limited. http://dx.doi.org/10.1198/tech.2005.s838.

NAGARAJ, T.; JOSHI, R.; MURTHY, B. S. Generalized equatio for compression ratio. *Journal of Testing and Avaluation,* Vol. 16, No. 1, pp. 86-89, 1988.

NAJJAR, Yacoub M.; BASHEER, Imad A.; NAOUSS, Wissam A. On the identification of compaction characteristics by neuronets. **Computers And Geotechnics**, [s.l.], v. 18, n. 3, p.167-187, jan. 1996. Elsevier BV. <u>http://dx.doi.org/10.1016/0266-352x(95)00030-e</u>.

NAWARI, N. O.; LIANG, R.; NUSAIRAT, J. Artificial intelligence techniques for the design and analysis of deep foundations. **Electronic Journal of Geotechnical Engineering**,1999.

NEJAD, F.; JAKSA, M. B.; MCCABE, B. A. Prediction of pile settlement using artificial neural networks based on standard penetration test data. **Computers And Geotechnics**, [s.l.], v. 36, n. 7, p.1125-1133, set. 2009. Elsevier BV. http://dx.doi.org/10.1016/j.compgeo.2009.04.003.

NETO, L. B.; SIEIRA, A. C. Castro F.; DANZIGER, Bernadete Ragoni; SILVA, José Guilherme Santos. Neuro-CPT: classificação de solos usando-se redes neurais artificiais. Engevista, v. 8, n.1, p. 37-48, junho, 2006.

OH, E. Y. N.; CHAI, G. W. K. Characterization of marine clay for road embankment design in coastal area. Proceeding of Sixteenth International Offshore and Polar Engineering Conference, San Francisco, USA, v. 2: p. 560-563, 2006.

OLIVEIRA, J. T. R. A Influência da qualidade da amostra no comportamento tensãodeformação-resistência de argilas moles. 272f. Tese (Doutorado). COPPE/UFRJ, Rio de Janeiro-RJ, 2002

OLIVEIRA, B. R.; ANTÔNIO, G. B. Modelagem geoestatística aplicada a geologia de engenharia. **Boletim Paranaense de Geociências**, [s.l.], v. 73, n. 1, p.46-53, 12 jul. 2017. Universidade Federal do Parana. http://dx.doi.org/10.5380/geo.v73i1.43417.

OLIVEIRA FILHO, A. G.; TOTOLA, L. B.; BICALHO, K. V.; ROMANEL, C. Evaluation of the use of artificial neural networks in predicting the compression index of marine clays. In 16 CNG, Açores, Portugal. 2018. Anais 16 CNG.

ONITSUKA, K.; ZHENSHUN, H.; YUTAKA, H.; SHIGEKI, Y. Interpretation of Oedometer Test Data for Natural Clays. **Soils and Foundations**, [s.l.], v. 35, n. 3, p. 61-70, 1995. Elsevier BV. http://dx.doi.org/10.3208/sandf.35.61.

ONYEJEKWE, S.; KANG, X.; GE, L. Assessment of empirical equations for the compression index of fine-grained soils in Missouri. **Bulletin of Engineering Geology And The Environment**, [s.l.], v. 74, n. 3, p.705-716, 28 ago. 2015. Springer Nature. http://dx.doi.org/10.1007/s10064-014-0659-8.

OZER, M.; ISIK, N. S.; ORHAN, M. Statistical and neural network assessment of the compression index of clay-bearing soils. **Bulletin of Engineering Geology And The Environment**, [s.l.], v. 67, n. 4, p.537-545, 8 out. 2008. Springer Nature. http://dx.doi.org/10.1007/s10064-008-0168-8.

PAPAIOANNOU, I.; STRAUB, D. Reliability updating in geotechnical engineering including spatial variability of soil. **Computers And Geotechnics**, [s.l.], v. 42, p.44-51, maio 2012. Elsevier BV. <u>http://dx.doi.org/10.1016/j.compgeo.2011.12.004</u>.

PARK, H.I., LEE, S.R., (2011). Evaluation of the compression index of soils using an artificial neural network. Computers and Geotechnics, [s.l.], v. 38, n. 4, pp 472-481, jun. 2011. Elsevier BV.http://dx.doi.org/10.1016/j.compgeo.2011.02.011.

PHAM, K.; KIM, D.; YOON, Y.; CHOI, H. Analysis of neural network based pedotransfer function for predicting soil water characteristic curve. **Geoderma**, [s.l.], v. 351, p.92-102, out. 2019. Elsevier BV. http://dx.doi.org/10.1016/j.geoderma.2019.05.013.

PINTO, Carlos de Souza. **Curso básico de mecânica dos solos.** São Paulo: Oficina de Textos, 2006. 367 p.

PÓVOA, Luisa Muylaert de Menezes. **Caracterização geotécnica de um depósito de solo mole em área de baixada localizada em Macaé-RJ**. 2016. 138 f. Dissertação (Mestrado), Curso de Engenharia Civil, Centro de Ciência e Tecnologia, Universidade Estadual do Norte Fluminense Darcy Ribeiro - Uenf, Campos dos Goytacazes, 2016.

QUEIROZ, Camila Moreira. **Propriedades geotécnicas de um depósito de argila mole da região de Itaguaí-RJ**. 2013. 99 f. Dissertação (Mestrado), Curso de Geotecnia e Transportes, Universidade Federal de Minas Gerais, Belo Horizonte, 2013.

ROCHA, Marco Aurélio Martins. Algumas considerações sobre o referencial filosófico de Immanuel Kant na construção da epistemologia genética de Jean Piaget. **Revista Maiêutica**, Indaial, v. 5, n. 01, p. 35-41, 2017.

ROCHA, Priscila Lima. **Reconhecimento de voz utilizando seleção dinâmica de redes neurais.** 2018. 111 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Universidade Federal do Maranhão, São Luís, 2018.

ROSENBLATT, F. The perceptron: A probalistic model for information storage and organization in the brain. *Psychol. Rev., p.* 65:386-408, 1958.

ROSS, J. L. S. Geomorfologia: Ambiente e Planejamento.São Paulo: Contexto, 1990,.85 p.

RUMELHART, D. E.; HILTON, G. E.; WILLIAMS, R. J.Learning representation by back-propagation erros. Nature, 323:533-536, 1986.

SANTOS, Mirella Dalvi dos. Correlações entre sondagem de simples reconhecimento e resultados de ensaios de campo (SPT, CPT, DP) para

diferentes subsolos arenosos. 2017. 175 f. Dissertação (Mestrado) - Curso de Engenharia Civil, Centro Tecnológico, Universidade Federal do Espírito Santo, Vitória-ES, 2017.

SARI, Putu Tantri Kumala; FIRMANSYAH, Yerry Kahaditu. The Empirical Correlation Using Linear Regression of Compression Index for Surabaya Soft Soil. In: ADVANCES IN STRUCTURAL ENGINEERING AND MECHANICS, 13, 2013, Jeju, Korea. **The 2013 World Congress.** Jeju, Korea: The 2013 World Congress On Advances In Structural Engineering And Mechanics, 2013. p. 8 - 12.

SCHMIDHUBER, Jürgen. Deep learning in neural networks: An overview. **Neural Networks,** [s.l.], v. 61, p.85-117, jan. 2015. Elsevier BV. http://dx.doi.org/10.1016/j.neunet.2014.09.003.

SHAHIN, Mohamed A.; MAIER, Holger R.; JAKSA, Mark B. Data Division for Developing Neural Networks Applied to Geotechnical Engineering. **Journal of Computing In Civil Engineering**, [s.l.], v. 18, n. 2, p.105-114, abr. 2004. American Society of Civil Engineers (ASCE). http://dx.doi.org/10.1061/(asce)0887-3801(2004)18:2(105).

SHAHIN, M. A.; MAIER, H. R.; JAKSA, M. B. Investigation into the robustness of artificial neural network models for a case study in civil engineering. **Proceedings of the International Congress on Modeling and Simulation, MODSIM 2005,** Melbourne (Australia), 79-83, 2005.

SHAHIN, Mohamed A.; JAKSA, Mark B.; MAIER, Holger R. State of the art of artificial neural network in geotechnical engineering. **Electronic Journal of Geotechnical Engineering**, vol. 8, pp. 1–26, 2008.

SHAHIN, M. A. Artificial intelligence in geotechnical engineering: applications, modeling aspects, and future directions. In: X.S. Yang *et al.*, Metaheuristics in water, geotechnical and transport engineering. 1.ed. Elsevier. cap.8, p. 169-204, 2013.

SILVA, C. A. U. **Um método para estimar observáveis GPS usando redes neurais artificiais.** 2003. 128 f. Tese (Doutorado) - Curso de Engenharia Civil, Escola de Engenharia de São Carlos, Universidade de São Paulo (USP), São Carlos, 2003.

SILVA, D. M. Estimativa do índice de compressão de argilas moles da costa a partir de ensaios de caracterização. 2013. 182 f. Dissertação (Mestrado), Curso de Engenharia Civil, COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2013.

SKEMPTON, A. W. Notes on the compressibility of clays. Quarterly Journal of the Geological Society, v. 100, n. 1-4, p. 119-135, 1944.

SUGUIO, K.; MARTIN, L.; FLEXOR, J. Quaternary sea levels of the brazilian coast: recent progress. Episodes 11: 203 – 208, 1988.

TERZAGHI, K. PECK, R. B. Soil mechanics in engineering practice. ed. 2. New York: Wiley, 1967.

TERZAGHI, K.; PECK, R. B.; MESRI, G. Soil mechanics in engineering practice. John Wiley & Sons, 1996.

TOLEDO, M. C.; OLIVEIRA, S. M.; MELFI, A. Intemperismo e formação do solo. In:______. **Decifrando a Terra.** TEIXEIRA, W; TOLEDO, M. C. M.; FAIRCHILD, T. R.; TAIOLI, F. (Orgs.). Oficina de Textos, São Paulo: 2000. cap. 8. p. 139 – 166.

TSUBOI, H.; YANASE, Y.; HAMAMOTO, S.; KAWAMOTO, K.; TAKEMURA, T.; ODA, M. Characterization of geotechnical properties as affected by sediment environment in Kanto lowland clays in Japan. **Proceedings of the International Symposium on Advances in Civil Downloaded** by [La Trobe University] at 04:01 30 July 201625 and Environmental Engineering Practices for Sustainable Development (ACEPS-2012),University of Ruhuna, Galle, Sri Lanka, 71–78.

VARDANEGA, P.J.; HAIGH, S. K. The undrained strength – liquidity index relationship. **Canadian Geotechnical Journal**, Canada, v. 51, n. 9, p.1073-1086, set. 2014. Canadian Science Publishing. http://dx.doi.org/10.1139/cgj-2013-0169.

VIDALIE, J. F. Relations entre les propriétés physico-chimiques et les caractéristiques mécaniques des sols compressibles. Rapport de recherche LPC, n. 65, 1977.

WIDODO, S.; IBRAHIM, A. Estimation of Primary Compression Index (Cc) Using Physical Properties of Pontianak Soft Clay. International Journal of Engineering Research And Applications (ijera). v. 2, n. 5, p.2232-2236, 2012.

YOON, G. L.; KIM, B. T.; JEON, S. S. Empirical correlations of compression index for marine clay from regression analysis. **Canadian Geotechnical Journal**, [s.l.], v. 41, n. 6, p.1213-1221, dez. 2004. Canadian Science Publishing. http://dx.doi.org/10.1139/t04-057

YU, W.; ZHUANG, Fuzhen; HE, Q.; SHI, Z. Learning deep representations via extreme learning machines. **Neurocomputing**. n. 149, p. 308-315. 2015. Elsevier BV. http://dx.doi.org/10.1016/j.neucom.2014.03.077.

ZULUAGA, R. A. G.; MARTÍNEZ, H. E. Utilização de redes neurais artificiais para estimar a permeabilidade do solo. **VI Simpósio Brasileiro de Aplicações de Informática em Geotecnia**. Conference Paper. Janeiro, 2011. DOI: 10.13140/2.1.3332;3201.

APÊNDICE A - OPERACIONALIZAÇÃO DOS TREINAMENTOS DAS RNAS

O *Matlab* é uma plataforma computacional de programação difundida no meio acadêmico e profissional de engenharia, que permite a execução de cálculos numéricos complexos, cálculo com matrizes e processamento de sinais. Além de outras funções, o *Matlab* também permite o uso de diversos algoritmos de treinamento de redes neurais artificiais a partir de interfaces gráficas providas de algoritmos previamente organizados em rotinas.

As duas interfaces gráficas de treinamento de redes aplicadas nesta pesquisa são: *nftool* e *nntool*, que consistem basicamente em aplicativos (*toolboxes*) para aplicação em redes neurais artificiais do *Matlab*.

A *toolbox nftool* permite treinar RNA do tipo *multlayer feedforward* com uma única camada oculta, operando uma função sigmóide na camada escondida e linear na de saída. É utilizado o algoritmo de treinamento *backpropagation Levenber-Marquardt*. Também é possível utilizar os algoritmos de treinamento *Bayesian Regularization* e *Scaled Conjugate Gradient*.

Inicialmente é necessário importar os dados que serão utilizados no treinamento das redes (LL_{CUP}, IP, w_n, e₀, C_c, CR) para o ambiente *Matlab*. No *excel* os dados de *input* (LL_{CUP}, IP, w_n, e₀) e *output* (C_c ou CR) devem ser organizados em linhas, isso para cada grupo de treinamento e validação, conforme a Figura 69. Os rótulos não são carregados no *Matlab*, mas é importante no *excel* para identificação das variáveis de entrada.

	INPUT 1	INPUT 2	INPUT 3	INPUT 4	INPUT 5
LL _{CUP}	54,00	53,00	54,00	53,00	34,00
IP	31,00	28,00	30,00	27,00	13,00
w _n	29,80	22,40	31,20	39,80	20,50
e ₀	0,76	0,58	0,78	0,97	0,57
C _C	0,15	0,17	0,18	0,25	0,08
CR	0,08	0,11	0,10	0,13	0,05

Figura 69: Exemplo de organização dos dados de treinamento das RNA no excel

Dentre outras alternativas, uma forma simples de importar os dados para o *Matlab* consiste na declaração de uma variável matricial no programa, simplesmente digitando na tela de comandos principal o nome da variável seguida dos símbolos = [1]. Assim, pode-se declarar as seguintes variáveis:

- InputTreino = contém as entradas para o treinamento das redes (LL_{CUP}, IP, w_n, e₀);
- OutputTreino = contém as saídas esperadas para as redes (C_c ou CR);
- InputVC = contém as entradas (amostras de solos reservadas para a validação cruzada das redes treinadas), LL_{CUP}, IP, w_n e e₀.

A Figura 70 apresenta o exemplo de declarações de variáveis no Matlab.

HOME	PLOTS	APPS		1 2	₫₿(3 Search Do	cumentation	🔺 🔍
New New Script	Open 😰 Compa	re Import Save Data Workspace	New Variable Open Variable Clear Workspace //ARIABLE	CODE	SIMULINK		RESOURCES	
🗇 🍁 🖻 🔊	EDUCAC	AO 🕨 ENGENHARIA_C		ART	IGO_REVIS	TA_1 ► MODE	LAGEM_RNA	- 2
Current Folder	•	Command Window						\odot
🗋 Name 🔺		>> InputTreind	= [1]; InputVC =	[1];	Output	Treino =	[1]	
BRA_G1.mat (M Workspace	IAT-file) 🗸	OutputTreino =	=		Settor-		Declaraci	io das
Name 🔺		1					Declaraça	io uas
InputTreino InputVC OutputTreino	, ,	& >> Variáve	eis Criadas				v ariaveis	

Figura 70 - Exemplo de declaração de variáveis no Matlab

Fonte: Autor (2019)

Após declaradas as variáveis os dados podem simplesmente serem colados do *excel* em cada variável correspondente criada, bastando clique duplo sobre a variável declarada e colar os dados.

Para utilizar a interface gráfica nftool, segue-se os passos:

 Na janela de comandos do *Matlab*, digita-se *nftool.* Abre-se a interface gráfica do aplicativo para prosseguir com a configuração dos parâmetros de treinamento da rede (Figura 71).

Fonte: Autor (2019)

 Na tela seguinte são selecionadas as variáveis de entrada (*inputs*) e de saída (*outputs*) para o treinamento da rede (Figura 72).

Figura 72 - Tela de seleção do conjunto de treinamento da rede na nftool

neural Fitting (nftool)	
Select Data What inputs and targets define your fitting problem?	
Get Data from Workspace	Summary
Input data to present to the network. Input_Train_Ensaio_1	Inputs 'Input_Train_Ensaio_1' is a 4x51 matrix, representing static data: 51 samples of 4 elements.
Target data defining desired network output.	
O Targets: Target_Train_Ensai	Targets 'Target_Train_Ensaio_1' is a 1x51 matrix, representing static data: 51 samples of 1 element.
Samples are: 🕫 🛄 Matrix columns C 🗐 Matrix rows	
Want to try out this tool with an example data set?	
To continue, dick [Next].	
Neural Network Start Neural Network Start	🗢 Back 🔹 Next 🙆 Cancel

3. A etapa seguinte consiste em definir o percentual das amostras de entrada que serão utilizadas para treino, validação e teste da rede na fase de treinamento (nesta pesquisa serão utilizados os percentuais 70%, 15% e 15%, respectivamente). Durante o treinamento, a rede ajusta os valores dos pesos sinápticos de acordo com os erros; o percentual de validação é empregado para medir a generalização da rede, ainda dentro do grupo de amostras do treinamento, quando a rede durante o treinamento não apresentar mais melhora de generalização, o treinamento é interrompido. Já as amostras de teste não são apresentadas à rede para validação, ou seja, são medidas independentes dos ajustes ocorridos na fase de treinamento, revelando assim o desempenho final da rede (Figura 73).

Figura 73 - Definição dos percentuais do conjunto de treinamento na nftool

Answer and Fitting (nftool)		
Validation and Test Da Set aside some samples for valida	ita tion and testing.	
Select Percentages		Explanation
🛃 Randomly divide up the 51 samples:		💑 Three Kinds of Samples:
♥ Training: 70% ♥ Validation: 15% ▼ ♥ Testing: 15% ▼ Restore Defau	35 samples 8 samples 8 samples	 Training: These are presented to the network during training, and the network is adjusted according to its error. Validation: These are used to measure network generalization, and to halt training when generalization stops improving. Testing: These have no effect on training and so provide an independent measure of network performance during and after training.
Change percentages if desired, the	n click [Next] to continue.	
Neural Network Start	me	Back Sector Sector Cancel

Fonte: Autor (2019)

4. Define-se o número de neurônios da camada oculta (Figura 74).

Figura 74 - Definição do número de neurônios escondidos na nftool.

neural Fitting (nftool)	
Set the number of neurons in the fitting network's hidden layer.	
Hidden Layer	Recommendation
Define a fitting neural network. (fitnet) Number of Hidden Neurons: 4	Return to this panel and change the number of neurons if the network does not perform well after training.
Restore Defaults Neural Network Hidden Layer Input	Output Layer Output
Change settings if desired, then click [Next] to continue.	
Reural Network Start Network Start	A Back Next O Cancel

Fonte: Autor (2019)

5. Na janela seguinte (Figura 75), deve-se escolher o algoritmo de treinamento e iniciar o treinamento da rede clicando em *Train*.

Figura 75 - Tela de inicialização do treino da rede na nftool.

	Results			
hoose a training algorithm:		💑 Samples	🔄 MSE	🧭 R
Levenberg-Marquardt	💙 Training:	35	1.70723e-2	8.56835e-1
his algorithm typically takes more memory but less time. Training automatically	Validation:	8	2.63494e-2	7.40741e-1
ops when generalization stops improving, as indicated by an increase in the ean square error of the validation samples.	🥡 Testing:	8	1.64025e-1	5.50508e-2
ain using Levenberg-Marquardt. (trainIm)		Plot Fit Plo	at Error Histogram	1
Retrain		Plot Reg	ression	-
ites				
 Training multiple times will generate different results due to different initial conditions and sampling. 	Mean Squared En difference betwee Lower values are	ror is the average squ en outputs and targe better. Zero means r	uared ts. 10 error.	
	Regression R Value between outputs means a close relationship.	ues measure the corru and targets. An R va ationship, O a randorr	elation slue of 1 1	

6. O desempenho da rede durante o treinamento pode ser monitorado a partir das informações dos resultados dispostas na tela de inicialização do treino e a partir da janela *Neural Network Training* (Figura 76), que se abre automaticamente. Ainda na tela da Figura 76, é possível abrir o gráfico de desempenho de convergência da rede durante as fases que compõem o treinamento (botão *Performance –* Figura 77); o histograma de erros (botão *Error Histogram –* Figura 78); e reta de regressão linear de aproximação dos valores previstos do *output* (botão *Regression –* Figura 79). O treino pode ser repetido a partir da mesma tela de inicialização do treinamento (Figura 75).



Figura 76 - Tela de controle do progresso do treinamento da rede na nftool

Fonte: Autor (2019)







Figura 78 - Histograma de erros na fase de treinamento na nftool.

Fonte: Autor (2019)

Fonte: Autor (2019)







7. Concluído o treinamento, a etapa seguinte (Figura 80), consiste em apresentar à rede o conjunto de amostras que não foi utilizado na fase de treinamento, para uma avaliação final do desempenho da rede treinada. Assim como na etapa anterior, nesta fase também é possível avaliar o gráfico de correlação da variável estimada pela rede e o histograma de erros. Também nesta tela é possível consultar o valor de MSE dos resultados previstos pela rede.

Iterate for improved performance Try training again if a first try did not generate good results or you require marginal inscovement. Try train Again Increase network size if retraining dd not help. Compared Adjust Network Size Not working? You may need to use a larger data set. Compared Larger Data Set	Optionally perform additional tests Tryuts: Target_Test_Ensalo_I Target_Test_Ensalo_I
--	--

Figura 80 - Tela de avaliação do desempenho da rede treinada (nftool)

Fonte: Autor (2019)

- 8. A Figura 81 permite salvar a rede treinada e os parâmetros do treinamento, que poderão ser utilizados em testes futuros para estimar o valor da variável investigada na fase de treino. A rede que é salva nesta etapa pode inclusive ser utilizada, tanto pela própria *toolbox nftool* quanto pela *toolbox nntool*.
- Figura 81 Tela de exportação dos parâmetros da rede treinada pela nftool.

Neural Fitting (nftool)	
Save Results Generate MATLAB scripts, save results and generate diagrams.	
Generate Scripts Recommended >> Use these scripts to reproduce results and solve similar problems.	
Generate a script to train and test a neural network as you just did with this tool:	Simple Script
Generate a script with additional options and example code:	Advanced Script
- Save Data to Workspace	
🥪 📝 Save network to MATLAB network object named:	net
Save performance and data set information to MATLAB struct named:	info
Save outputs to MATLAB matrix named:	output
3 In the second	error
Save inputs to MATLAB matrix named:	input
O Save targets to MATLAB matrix named:	target
Save ALL selected values above to MATLAB struct named:	results
Restore Defaults	Save Results
Save results and click [Finish].	
Reural Network Start Release Action A	Next Sinish

Na mesma direção da *nftool*, a *toolbox nntool* é um recurso gráfico do *Matlab* para treinamento de redes neurais artificiais. Esta ferramenta permite o uso de arquitetura de rede com número variável de camadas ocultas, além de apresentar um número elevado de algoritmos de treinamento que podem ser selecionados. Para utilizar esta ferramenta, deve-se seguir as etapas:

Abrir o programa digitando *nntool* na janela principal do *Matlab*. É exibida a janela principal do aplicativo (Figura 82). Nesta janela é preciso importar as variáveis de entrada modelagem (*input* e *target*). Nesta mesma janela é possível importar uma rede previamente treinada a partir do botão *Import.*

📣 Neural Network/Data Manager (nnto	ol)	
▶ Input Data: Input_Test_cc Input_Train_cc	* Networks	Jutput Data:
 ⊘ Target Data: Target_Train_cc Target_Test_cc ∞ Input Delay States: 		Error Data:
Simport	Open 🔇 🗞 Export	Velete Velete Close

Figura 82 - Tela inicial da nntool

Fonte: Autor (2019)

Após importar as variáveis do treinamento e do teste é preciso criar a arquitetura da RNA. Para isso é preciso clicar no botão *New*. Na janela de criação de uma nova RNA, no campo *Network Type* é possível escolher um tipo de estrutura de rede, podendo ser o tipo *feedforward backpropagation*, ou outro. Ainda nesta janela são selecionados os *inputs* e os *targets* do treino, o algoritmo de treinamento, o número de camadas ocultas e as respectivas funções de ativação para as diferentes camadas da rede, conforme a Figura 83.

Name	
RNA_1	
Network Properties	
Network Type:	Feed-forward backprop
Input data:	Input_Train_cc
Target data:	Target_Train_cc
Training function:	TRAINLM
Adaption learning function:	LEARNGDM ·
Performance function:	MSE
Number of layers:	3
Properties for: Layer 3 🔻	
Number of neurons:	
Transfer Function: PURELIN	
	🞦 View 🔗 👷 Restore Defaults

Figura 83 - Definição da arquitetura da RNA na nntool

Fonte: Autor (2019)

 Após criar a RNA é preciso abrir a mesma a partir da tela apresentada na Figura 82, que dispõe das redes criadas ou importadas (selecionar a rede e clicar em *Open*). A tela com a arquitetura da rede se apresenta (Figura 84).

Figura 84 - Tela com a arquitetura da RNA criada na nntool



Fonte: Autor (2019)

Na aba *Train*, deve-se selecionar os *inputs* e os *targets* do treinamento (Figura 85), define-se também os nomes dos arquivos com os resultados de previsão da rede durante o treinamento e os respectivos erros. Clicando em *Training* se inicia o treinamento. Automaticamente é aberta a janela *Neural Networking Training*. Assim como nas fases de treinamento com a ferramenta *nftool,* os parâmetros de desempenho da rede são monitorados a partir das janelas acessíveis na tela da Figura 76.

Figura 85 - Tela de treinamento da rede na nntool

TNetwork: RNA_1						
View Train Simulate Adapt Reinitialize Weights View/Edit Weights Training Info Training Parameters Training Parameters Training Parameters						
Inputs	Input_Train_cc	•	Outputs	RNA_1_outputs		
Targets	Target_Train_cc	•	Errors	RNA_1_errors		
Init Input Delay States	(zeros)		Final Input Delay States	RNA_1_inputStates		
Init Layer Delay States	(zeros)	Ψ.	Final Layer Delay States	RNA_1_layerStates		
				🐚 Train Network		

Fonte: Autor (2019)

Depois de treinada a rede, segue-se para a simulação, apresentando a ela um conjunto de variáveis que não foi utilizado no treino. Este teste é acessado na aba *Simulate*. Na tela da Figura 86 deve ser escolhido o arquivo com as variáveis de entrada da validação cruzada, ou seja, que contém o conjunto de variáveis do *input* separadas para a validação cruzada. Define-se também o nome de saída do arquivo com os resultados simulados pela rede treinada. Essa opção de salvar os resultados da simulação é uma das vantagens da *nntool* em relação a *nftool* que não permite essa ação.

iew Train Simulate Adap	t Reinitialize Weights View/	/Edit Weights	
imulation Data		Simulation Results	
Inputs	Input_Test_cc	 Outputs 	RESULTADO_TESTE
Init Input Delay States	(zeros)	 Final Input Delay States 	RNA_1_inputStates
Init Layer Delay States	(zeros)	 Final Layer Delay States 	RNA_1_layerStates
Supply Targets			
Targets	(zeros)	 Errors 	RNA_1_errors
			Simulate Network

Figura 86 - Tela para seleção dos inputs do teste da nntool

Fonte: Autor (2019)

 Na aba View/Edit Weights é possível visualizar e editar os pesos sinápticos dos diferentes nós da rede. Todos os resultados do treinamento e da simulação podem ser exportados para o projeto Matlab corrente a partir da tela apresentada na Figura 82.

Importante destacar, que o aplicativo *nntool* utiliza como padrão os percentuais de 70%, 15% e 15% nas etapas de treino, validação e teste, respectivamente.

As *toolboxes* previamente apresentadas têm o recurso de normalizar as variáveis de entrada nos intervalos de [0,1] e [-1,1] automaticamente.