



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TRANSPORTES**

**ANTONIO JÚNIOR ALVES RIBEIRO**

**UM MODELO DE PREVISÃO DO MÓDULO DE RESILIÊNCIA DOS SOLOS NO  
ESTADO DO CEARÁ PARA FINS DE PAVIMENTAÇÃO**

**FORTALEZA**  
**2016**

ANTONIO JÚNIOR ALVES RIBEIRO

UM MODELO DE PREVISÃO DO MÓDULO DE RESILIÊNCIA DOS SOLOS NO  
ESTADO DO CEARÁ PARA FINS DE PAVIMENTAÇÃO

Tese submetida ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como parte dos requisitos para a obtenção do título de doutor em Engenharia de Transportes. Área de concentração Infraestrutura de Transportes

Orientador: Prof. Dr. Carlos Augusto Uchôa da Silva

Coorientadora: Profa. Dra. Suelly Helena de Araújo Barroso

FORTALEZA  
2016

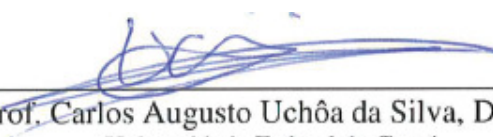
ANTONIO JÚNIOR ALVES RIBEIRO

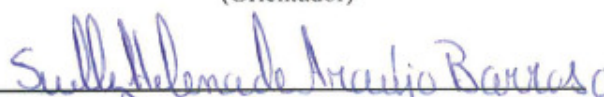
UM MODELO DE PREVISÃO DO MÓDULO DE RESILIÊNCIA DOS SOLOS NO  
ESTADO DO CEARÁ PARA FINS DE PAVIMENTAÇÃO


Tese submetida ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como parte dos requisitos para a obtenção do título de doutor em Engenharia de Transportes. Área de concentração Infraestrutura de Transportes


Aprovado em 13/06/2016

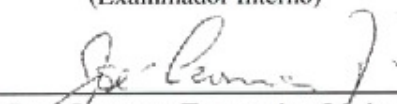
BANCA EXAMINADORA

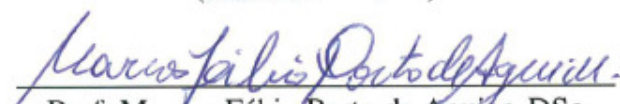
  
Prof. Carlos Augusto Uchôa da Silva, D. Eng  
Universidade Federal do Ceará  
(Orientador)

  
Prof.ª Suelly Helena de Araújo Barroso, D. Eng  
Universidade Federal do Ceará  
(Coorientadora)

  
Prof. Ernesto Ferreira Nobre Júnior, DSc  
Universidade Federal do Ceará  
(Examinador Interno)

  
Prof. Silvrano Adonias Dantas Neto, DSc  
Universidade Federal do Ceará  
(Examinador Interno)

  
Prof. José Leomar Fernandes Júnior, DSc  
Escola de Engenharia de São Carlos/USP  
(Examinador Externo)

  
Prof. Marcos Fábio Porto de Aguiar, DSc  
Instituto Federal do Ceará  
(Examinador Externo)

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

R367m Ribeiro, Antonio Júnior Alves.

Um modelo de previsão do módulo de resiliência dos solos no estado do Ceará para fins de pavimentação / Antonio Júnior Alves Ribeiro. – 2016.  
151 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2016.

Orientação: Prof. Dr. Carlos Augusto Uchôa da Silva.

Coorientação: Profa. Dra. Suelly Helena de Araújo Barroso.

1. Redes Neurais Artificiais. 2. Módulo de Resiliência. 3. Pavimentação. 4. Solos. I. Título.

CDD 388

---

## DEDICATÓRIA

*Dedico este trabalho a Deus que é o nosso pai  
e maior responsável por nossas vitórias*

*Dedico à minha mãe Fátima*

## AGRADECIMENTOS

Sou grato a Deus e seu filho Jesus Cristo, pelas oportunidades que tem colocado na minha vida, na vida da minha família e das pessoas que estão no nosso meio, por todas as vitórias que tem nos concedido, por me manter firme na fé, pela saúde, paz, amor e pela vida.

Agradeço a minha mãe Fátima e ao meu padrinho Antonio Oliveira (*in memoriam*) pela força e auxílio prestado nos meus estudos. Também agradeço aos meus irmãos e amigos.

Agradeço ao meu orientador, Professor Uchôa, pelo incentivo, empenho, pela sinceridade, amizade e dedicação. Mesmo com tantas atribuições, sua sala está sempre aberta para nos receber e contribuir no que for necessário.

Sou grato à minha coorientadora, Professora Suelly, que vem sempre buscando ajudar todos os seus orientados, seja na vida acadêmica, profissional e pessoal, com seus conselhos.

Aos companheiros de trabalho do IFCE – *Campus Juazeiro do Norte*.

Sou grato aos colegas da Pós-Graduação do PETRAN que compartilharam todos os momentos de trabalho, estudos e brincadeiras.

Agradeço aos professores do PETRAN/UFC que contribuíram para minha formação acadêmica e profissional durante esse curso, principalmente Jorge Soares e Ernesto Nobre que ministraram excelentes disciplinas da área de pavimentação e infraestrutura de transportes. Agradeço a Zacarias Barbosa, secretário do PETRAN e amigo, pela sua presteza e disposição em sempre ajudar. Agradeço a Annie, Telma e Clélia e pelo apoio administrativo e operacional que têm prestado.

Agradeço a Diretoria da Quanta Consultoria, na pessoa de José de Ribamar Sousa, pela oportunidade de colaborar durante muito tempo com a empresa, e pela visão que a empresa tem de investir em pessoas.

Resumo da tese submetida ao PETRAN/UFC como parte dos requisitos para a obtenção do título de doutor em Engenharia de Transportes.

## UM MODELO DE PREVISÃO DO MÓDULO DE RESILIÊNCIA DOS SOLOS NO ESTADO DO CEARÁ PARA FINS DE PAVIMENTAÇÃO

Antonio Júnior Alves Ribeiro

Orientador: Carlos Augusto Uchôa da Silva

Coorientadora: Suelly Helena de Araújo Barroso

### RESUMO

O desenvolvimento de modelos como apoio aos projetos de infraestrutura de transportes vem se firmando como uma alternativa para se obter dados e informações acerca das características geotécnicas dos solos de uma determinada região. Uma das técnicas que tem obtido sucesso na geração dessas estimativas é a de Redes Neurais Artificiais (RNA). A modelagem neural tem permitido tanto a predição de diferentes atributos geotécnicos dos solos quanto de suas localizações com relativa precisão para uma dada região de estudo. Sabe-se que os métodos de dimensionamentos empírico-mecanísticos de pavimentos dependem, para sua aplicação, do conhecimento prévio de algumas dessas características. A obtenção de informações geotécnicas de solos, como por exemplo, a classificação da AASHTO, CBR e Módulo de Resiliência (MR), implicam em elevados custos. Assim, esta tese propõe o uso de técnicas de inteligência artificial na geração de modelos destinados a estimar o MR de solos, a fim de que sejam usados nos métodos de dimensionamentos de pavimentos, para os quais esta informação seja imprescindível. Propõe-se a realização de ensaios geotécnicos convencionais (Análise Granulométrica e Compactação) para obtenção dos dados que permitirão a modelagem proposta, visando-se estimar o comportamento resiliente dos solos no estado do Ceará. A partir dos resultados obtidos, foram geradas estimativas que podem ser integradas aos métodos de dimensionamento de pavimentos para a área de estudo, reduzindo-se os custos financeiros dos projetos e o tempo de execução. Os resultados mostraram que as RNA são capazes de prever com boa precisão, com coeficiente de correlação de 0,984, os valores de MR dos solos, se mostrando assim, promissor, o uso de modelos neurais para prever o MR para o dimensionamento empírico-mecanístico de pavimentos. Esta técnica permite assim o uso dos modelos gerados no dimensionamento de pavimentos, quando da ausência de informações ou escassez de recursos financeiros para projetos rodoviários.

**Palavras Chave: Redes Neurais Artificiais. Módulo de Resiliência. Pavimentação. Solos.**

Abstract of thesis submitted to PETRAN/UFC as portion of the requirements for obtaining the title of doctor in Transportation Engineering.

A PREDICTION MODEL OF RESILIENT MODULUS OF SOILS IN THE STATE OF  
CEARÁ FOR THE PURPOSE OF PAVING

Antonio Júnior Alves Ribeiro

Advisor: Carlos Augusto Uchôa da Silva

CoAdvisor: Suelly Helena de Araújo Barroso

**ABSTRACT**

The development of models to support the transport infrastructure design has established itself as an alternative to obtain data and information on the geotechnical characteristics of the soil in a given region. One of the techniques that have been successful in generating the estimates is the Artificial Neural Networks (ANN). The neural modeling has allowed both the prediction of different geotechnical soil attributes as their locations with relative accuracy for a given study area. It is known that the methods of empirical-mechanistic pavement design depend on their application, prior knowledge of some of these characteristics. Obtaining geotechnical soil information, such as AASHTO classification, CBR and resilient modulus (RM), imply high financial cost. Thus, this thesis proposes the use of artificial intelligence techniques to generate models to estimate the RM of soil in order to be used in methods of pavement design, for which this information is essential. It is proposed to perform conventional geotechnical testing (Particle size analysis of soils and Compaction) to obtain data that will allow the proposed model, aiming to estimate the resilient behavior of soils in the state of Ceará. From the results, estimates were generated that can be integrated into the pavement design methods for the study area, reducing the financial costs of the projects and the execution time. The results showed that the ANN are able to predict with good accuracy, with 0.984 correlation coefficient, RM values of the soil, showing that the use of neural models to predict the RM to the empirical-mechanistic design of pavements is possible. This technique allows the use of the models generated for the design of pavements, where there is lack of information or lack of funding for road design.

**Keywords: Artificial Neural Networks. Resilient Modulus. Paving. Soils.**



## SUMÁRIO

<b>CAPÍTULO 1</b> .....	<b>22</b>
<b>1 INTRODUÇÃO</b> .....	<b>22</b>
<b>1.1 Contextualização</b> .....	<b>22</b>
<b>1.2 Questões de Pesquisa</b> .....	<b>24</b>
<b>1.3 Objetivos</b> .....	<b>25</b>
<b>1.3.1 Objetivo Geral</b> .....	<b>25</b>
<b>1.3.2 Objetivos Específicos</b> .....	<b>25</b>
<b>1.4 Contribuição da tese</b> .....	<b>25</b>
<b>1.5 Estrutura do Trabalho</b> .....	<b>26</b>
<b>CAPÍTULO 2</b> .....	<b>27</b>
<b>2 CARACTERIZAÇÃO DE SOLOS APLICADA À PAVIMENTAÇÃO</b> .....	<b>27</b>
<b>2.1 Considerações Iniciais</b> .....	<b>27</b>
<b>2.2 Propriedades dos Solos de Interesse na Área de Pavimentação</b> .....	<b>27</b>
<b>2.2.1 Características Básicas Gerais</b> .....	<b>27</b>
<b>2.2.2 Módulo de Resiliência (MR)</b> .....	<b>28</b>
<b>2.2.3 Modelos Resilientes de Solos</b> .....	<b>30</b>
<b>2.2.4 Considerações Finais</b> .....	<b>35</b>
<b>CAPÍTULO 3</b> .....	<b>36</b>
<b>3 TÉCNICA DE REDES NEURAIS ARTIFICIAIS APLICADA À GEOTÉCNIA E PAVIMENTAÇÃO</b> .....	<b>36</b>
<b>3.1 Considerações Iniciais</b> .....	<b>36</b>
<b>3.2 Redes Neurais Artificiais (RNA)</b> .....	<b>36</b>
<b>3.2.1 Histórico das RNA</b> .....	<b>37</b>
<b>3.2.2 O Neurônio Artificial</b> .....	<b>38</b>
<b>3.2.3 Estrutura das RNA</b> .....	<b>39</b>
<b>3.2.4 Topologia de uma Rede Neural Artificial</b> .....	<b>40</b>
<b>3.2.5 Funções de Ativação</b> .....	<b>41</b>
<b>3.2.6 Aprendizagem em RNA</b> .....	<b>42</b>
<b>3.2.7 Perceptron Multicamadas (MLP) e o Algoritmo Error Backpropagation</b> ....	<b>43</b>
<b>3.3 Redes Neurais Artificiais Aplicadas a Solos</b> .....	<b>44</b>
<b>3.4 Considerações Finais</b> .....	<b>47</b>
<b>CAPÍTULO 4</b> .....	<b>48</b>

<b>4</b>	<b>MODELOS DE PREVISÃO DO MÓDULO DE RESILIÊNCIA.....</b>	<b>48</b>
4.1	Considerações Iniciais .....	48
4.2	Modelos de Predição do Módulo de Resiliência a partir do CBR.....	48
4.3	Modelos de Predição do Módulo de Resiliência por Diversas Propriedades Geotécnicas .....	52
4.4	Modelos de Predição do Módulo de Resiliência usados pelos DOT no Dimensionamento de Pavimentos.....	58
4.5	Considerações Finais .....	63
	<b>CAPÍTULO 5.....</b>	<b>64</b>
<b>5</b>	<b>MATERIAIS E MÉTODOS.....</b>	<b>64</b>
5.1	Considerações Iniciais .....	64
5.2	Escolha da Área de Estudo .....	64
5.3	Dados Utilizados.....	67
5.4	Aplicativos Computacionais Empregados .....	67
5.4.1	ArcGIS.....	68
5.4.2	Autodesk Civil 3D.....	68
5.4.3	Microsoft Excel.....	68
5.4.4	IBM SPSS .....	69
5.4.5	MATLAB.....	69
5.4.6	CAP3D .....	69
5.5	Metodologia Adotada .....	70
5.5.1	Revisão da Literatura .....	71
5.5.2	Pesquisa e Aquisição de Dados .....	71
5.5.3	Definição do Esforço Amostral.....	71
5.5.4	Execução do Programa Experimental.....	72
5.5.5	Construção do Banco de Dados Georreferenciado .....	72
5.5.6	Pré-processamento dos Dados.....	73
5.5.7	Tratamento de Dados.....	75
5.5.8	Previsão do Módulo de Resiliência .....	75
5.5.9	Disponibilização do Gerador de Estimativas MR.....	77
5.5.10	Considerações Finais .....	78
	<b>CAPÍTULO 6.....</b>	<b>79</b>
<b>6</b>	<b>APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS.....</b>	<b>79</b>
6.1	Considerações Iniciais .....	79

<b>6.2</b>	<b>Análise dos Dados .....</b>	<b>79</b>
6.2.1	Análise Descritiva dos Dados.....	80
6.2.2	Relações Estatísticas entre as Variáveis .....	90
<b>6.3</b>	<b>Modelos de Regressão Linear .....</b>	<b>92</b>
6.3.1	Considerações sobre os Modelos de Regressão Gerados .....	95
<b>6.4</b>	<b>Modelagem Neural do Módulo de Resiliência.....</b>	<b>96</b>
6.4.1	Árvore de Testes .....	97
6.4.2	Modelo Neural M1.....	99
6.4.3	Modelo Neural M2.....	103
6.4.4	Modelo Neural M3.....	106
6.4.5	Modelo Neural M4.....	109
6.4.6	Modelo Neural M5.....	112
6.4.7	Análise dos Modelos Neurais Gerados e Escolha do Melhor Modelo.....	115
6.4.8	Comparação dos Resultados com outros Modelos de Predição de características geotécnicas de Solos .....	119
<b>6.5</b>	<b>Apresentação, Uso e Aplicação do Modelo Escolhido .....</b>	<b>121</b>
<b>6.6</b>	<b>Considerações Finais .....</b>	<b>130</b>
<b>CAPÍTULO 7 .....</b>		<b>134</b>
<b>7</b>	<b>CONCLUSÕES E RECOMENDAÇÕES .....</b>	<b>134</b>
7.1	Considerações Iniciais .....	134
7.2	Principais Constatações.....	135
7.2.1	Quanto ao Método e a Modelagem Neural.....	135
7.2.2	Quanto às incertezas dos modelos gerados.....	135
7.2.3	Quanto ao uso de estimativas de MR na Pavimentação .....	136
7.2.4	Quanto às variáveis explicativas dos modelos.....	136
7.2.5	Quanto à generalização dos modelos neurais.....	137
7.2.6	Quanto aos modelos de regressão linear para previsão do MR .....	137
7.2.7	Quanto aos modelos de previsão do MR Regionalizados.....	138
7.3	Recomendações e Sugestões para Trabalhos Futuros .....	138
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>		<b>140</b>

## LISTA DE FIGURAS

Figura 3.1– Modelo não linear de neurônio artificial.....	38
Figura 3.2– Modelo Estrutural de uma Rede Neural.....	40
Figura 5.1– Localização da RMF no estado do Ceará e no Brasil. ....	65
Figura 5.2 – Malha Rodoviária Pavimentada da RMF.....	66
Figura 5.3 – Fluxograma do Método Proposto.....	70
Figura 6.1 - Distribuição Espacial dos Pontos de Coleta de Solos.....	80
Figura 6.2 – Gráfico da variável Umidade Ótima. ....	82
Figura 6.3 – Gráfico da variável Massa Específica Seca Máxima. ....	82
Figura 6.4 – Gráfico da variável CBR.....	83
Figura 6.5 – Gráfico da variável Expansão. ....	83
Figura 6.6 – Gráfico da variável Limite de Liquidez. ....	84
Figura 6.7 – Gráfico da variável Índice de Plasticidade.....	84
Figura 6.8 – Gráfico da variável Passante na Peneira 25,4 mm. ....	85
Figura 6.9 – Gráfico da variável Passante na Peneira 9,5 mm. ....	85
Figura 6.10 – Gráfico da variável Passante na Peneira 4,76 mm. ....	86
Figura 6.11 – Gráfico da variável Passante na Peneira 2,00 mm. ....	86
Figura 6.12 – Gráfico da variável Passante na Peneira 0,42 mm. ....	87
Figura 6.13 – Gráfico da variável Passante na Peneira 0,074 mm. ....	87
Figura 6.14 – Gráfico da variável Classificação da AASTHO. ....	88
Figura 6.15 – Gráfico da variável Módulo de Resiliência.....	88
Figura 6.16 – Gráfico da variável Deformação Específica Resiliente Recuperável. ....	89
Figura 6.17 – Gráfico do modelo de regressão múltipla do banco de dados completo.....	95
Figura 6.18 – Gráficos calculado x ensaiado do Modelo M1 para o MR dos três conjuntos de dados. ....	101
Figura 6.19 – Gráfico da evolução do MSE com o número de interações do Modelo M1 para o MR. ....	101
Figura 6.20 – Gráficos calculado x ensaiado do Modelo M1 para o $\epsilon_r$ dos três conjuntos de dados. ....	102
Figura 6.21 – Gráfico da evolução do MSE com o número de interações do Modelo M1 para o $\epsilon_r$ . ....	102

Figura 6.22 – Gráficos calculado x ensaiado do Modelo M2 para o MR dos três conjuntos de dados. ....	104
Figura 6.23 – Gráfico da evolução do MSE com o número de interações do Modelo M2 para o MR. ....	104
Figura 6.24 – Gráficos calculado x ensaiado do Modelo M2 para o $\epsilon_r$ dos três conjuntos de dados. ....	105
Figura 6.25 – Gráfico da evolução do MSE com o número de interações do Modelo M2 para o $\epsilon_r$ . ....	105
Figura 6.26 – Gráficos calculado x ensaiado do Modelo M3 para o MR dos três conjuntos de dados. ....	107
Figura 6.27 – Gráfico da evolução do MSE com o número de interações do Modelo M3 para o MR. ....	107
Figura 6.28 – Gráficos calculado x ensaiado do Modelo M3 para o $\epsilon_r$ dos três conjuntos de dados. ....	108
Figura 6.29 – Gráfico da evolução do MSE com o número de interações do Modelo M3 para o $\epsilon_r$ . ....	108
Figura 6.30 – Gráficos calculado x ensaiado do Modelo M4 para o MR dos três conjuntos de dados. ....	110
Figura 6.31 – Gráfico da evolução do MSE com o número de interações do Modelo M4 para o MR. ....	110
Figura 6.32 – Gráficos calculado x ensaiado do Modelo M4 para o $\epsilon_r$ dos três conjuntos de dados. ....	111
Figura 6.33 – Gráfico da evolução do MSE com o número de interações do Modelo M4 para o $\epsilon_r$ . ....	111
Figura 6.34 – Gráficos calculado x ensaiado do Modelo M5 para o MR dos três conjuntos de dados. ....	113
Figura 6.35 – Gráfico da evolução do MSE com o número de interações do Modelo M5 para o MR. ....	113
Figura 6.36 – Gráficos calculado x ensaiado do Modelo M5 para o $\epsilon_r$ dos três conjuntos de dados. ....	114
Figura 6.37 – Gráfico da evolução do MSE com o número de interações do Modelo M5 para o $\epsilon_r$ . ....	114
Figura 6.38 – Topologia do Modelo M4 (10:21:1) para previsão do MR. ....	121
Figura 6.39 – Gráfico dos valores de MR do ensaio x RNA para o solo 1. ....	126

Figura 6.40 – Gráfico dos valores de MR do ensaio x RNA para o solo 2. ....	126
Figura 6.41 – Estrutura e propriedades do pavimento com CBUQ utilizado para análise numérica.....	127
Figura 6.42 – Estrutura e propriedades do pavimento com TSD utilizado para análise numérica.....	128
Figura 6.43 – Distribuição das tensões verticais (kPa) no pavimento com CBUQ analisado para o módulo de resiliência do subleito modelado e ensaiado. ....	129
Figura 6.44 – Distribuição das tensões verticais (kPa) no pavimento com TSD analisado para o módulo de resiliência do subleito modelado e ensaiado. ....	129
Figura 6.45 - Visão geral do Aplicativo MR Simples Ceará.....	132
Figura 6.46 – Predição do MR pelo Aplicativo MR Simples Ceará.....	133

## LISTA DE TABELAS

Tabela 2.1 – Sequência de tensões para fase de condicionamento.....	29
Tabela 2.2 – Sequência de tensões para determinação do módulo de resiliência. ....	30
Tabela 3.1 – Estado da Arte em RNA. ....	37
Tabela 3.2 – Principais funções de ativação das RNA. ....	42
Tabela 4.1 – Valores Típicos de MR usados no nível 3 do MEPDG. ....	58
Tabela 5.1 – Variáveis do banco de dados. ....	73
Tabela 5.2– Exemplo de numerização dos dados alfanuméricos. ....	74
Tabela 5.3– Exemplo de normalização dos dados com valores decimais. ....	74
Tabela 6.1 – Estatística descritiva dos dados. ....	81
Tabela 6.2 – Matriz de Correlação entre as variáveis do banco de dados. ....	91
Tabela 6.3 – Valores Típicos do Módulo de Resiliência para RMF. ....	93
Tabela 6.4 – Topologia e Desempenho da RNA 15:31:1 para o MR.....	100
Tabela 6.5 – Topologia e Desempenho da RNA 15:31:1 para o $\epsilon_r$ . ....	100
Tabela 6.6 – Topologia e Desempenho da RNA 13:27:1 para o MR.....	103
Tabela 6.7 – Topologia e Desempenho da RNA 13:27:1 para o $\epsilon_r$ . ....	103
Tabela 6.8 – Topologia e Desempenho da RNA 11:23:1 para o MR.....	106
Tabela 6.9 – Topologia e Desempenho da RNA 11:23:1 para o $\epsilon_r$ . ....	106
Tabela 6.10 – Topologia e Desempenho da RNA 10:21:1 para o MR.....	109
Tabela 6.11 – Topologia e Desempenho da RNA 10:21:1 para o $\epsilon_r$ .....	109
Tabela 6.12 – Topologia e Desempenho da RNA 7:15:1 para o MR.....	112
Tabela 6.13 – Topologia e Desempenho da RNA 7:15:1 para o $\epsilon_r$ .....	112
Tabela 6.14 – Topologia e Desempenho dos modelos para o conjunto de teste do MR.....	118
Tabela 6.15 – Valores dos pesos sinápticos e dos biases entre a camada de entrada e a camada intermediária do modelo. ....	122
Tabela 6.16 – Valores dos pesos sinápticos e dos biases entre a camada intermediária e a camada de saída do modelo. ....	123
Tabela 6.17 – Valores máximos e mínimos das variáveis do modelo neural M4 (10:21:1). .	124
Tabela 6.18 – Valores dos ensaios de granulometria e massa específica seca máxima para os solos testados. ....	124
Tabela 6.19 – Valores das saídas dos neurônios da camada intermediária para o solo 1.....	125
Tabela 6.20 – Valores da saída do neurônio da camada de saída e desnormalizada (valor real). ....	125

## LISTA DE SÍMBOLOS

% CLAY=percentual de argila

% COMP = grau de compactação

% SILT = percentual de silte

%SAND = percentual de areia

%W = umidade ótima de compactação

B = variável obtida para cada tipo de material (parâmetro de regressão)

$b_k$ = termo bias

C = percentual de argila

$C_c$  = coeficiente de curvatura da curva granulométrica

CLASS = classificação da AASTHO

Clay = percentual de argila

$C_u$  = coeficiente de uniformidade da curva granulométrica

DD = massa específica

DEN = massa específica seca máxima

$\epsilon_r$  = deformação resiliente recuperável

EXP = expansão

$f(S)$  = saturação normalizada

$f(\sigma)$  = tensão de cisalhamento octaédrica normalizada



GC = grau de compactação

k = coeficiente de permeabilidade

$k_1$  = constante determinada experimentalmente (ensaio triaxial dinâmico)

$k_2$  = constante determinada experimentalmente (ensaio triaxial dinâmico)

$k_3$  = constante determinada experimentalmente (ensaio triaxial dinâmico)

$k_4$  = constante determinada experimentalmente (ensaio triaxial dinâmico)

LL = limite de liquidez (%)

LP = limite de plasticidade (%)

MAXDD = massa específica seca máxima

MC = teor de umidade

MCROMC/MC

MR = módulo de resiliência

OMC = umidade ótima

OT = umidade ótima de compactação

#P0,074 = percentual passante na peneira 0,074 mm

#P0,42 = percentual passante na peneira 0,42 mm

#P2 = percentual passante na peneira 2 mm

#P25,4 = percentual passante na peneira 25,4 mm

#P4,76 = percentual passante na peneira 4,76 mm

#P9,5 = percentual passante na peneira 9,5 mm

$P_a$  = pressão atmosférica

$PI$  = índice de plasticidade (%)

$S$  = grau de saturação (%)

$S_{200}$  = percentual passante na peneira número #200

$SATU$  = grau de saturação

$SM$  = igual a 1 se o solo for uma areia siltosa e igual a 0, se for outro solo

$u_k$  = combinação linear dos sinais de entrada

$w$  = teor de umidade em %

$W_{km}$  = pesos sinápticos, associados a cada entrada

$w_{opt}$  = umidade ótima de compactação

$X_i$  = valor decimal

$X_m$  = Entradas da rede

$X_{max}$  = maior valor da variável

$X_{min}$  = menor valor da variável

$X_n$  = valor normalizado

$Y_k$  = saída do neurônio

$\gamma_{dr}$  = massa específica / massa específica seca máxima

$\Delta w$  = variação da umidade ótima de compactação

$\Delta \gamma_d$  = variação da massa específica seca máxima

$\theta$  = primeiro invariante de tensão

$\sigma_1$  = tensão axial cíclica

$\sigma_3$  = tensão de confinamento

$\sigma_d$  = tensão desvio

$\tau_{oct}$  = tensão octaédrica

$\varphi$  (.) = função de ativação

## LISTA DE ABREVIACÕES

AASHTO = *American Association of State Highway and Transportation Official*

CAD = Desenho Assistido por Computador

CBR = *California Bearing Ratio*

CIPP = Complexo Industrial e Portuário do Pecém

CPT = *Cone Penetration Test*

DNIT = Departamento Nacional de Infraestrutura de Transportes

ESRI = *Environmental Systems Research Institute*

GPS = *Global Positioning System*

GRNN = *Generalized Regression Neural Networks*

GTTEMA = Grupo de Trânsito, Transporte e Meio Ambiente

Hz = Ciclos por Minuto

IBGE = Instituto Brasileiro de Geografia e Estatística

IPECE = Instituto de Pesquisas Econômicas do Ceará

kPa = Kilo Pascal

LAG = Laboratório de Geomática Aplicada

MATLAB = MATrix LABoratory

MCT = Miniatura, Compactada, Tropical

MEPDG = *Mechanistic-Empirical Pavement Design Guide*

MLP = *Multilayer Perceptron*

MPa = Mega Pascal

MSE = *Mean of Squared Error*

NCHRP = *National Cooperative Highway Research Program*

NNTOOL = *Neural Network Tool*

OCR = *Over Conservation Ratio*

QME = Quadrado Médio dos Erros

RMF = Região Metropolitana de Fortaleza

RNA = Redes Neurais Artificiais

RPA = Razão de Pré-Adensamento

RSC = Resistência à Compressão Simples

RSE = Força Relativa de Efeito

SIG = Sistemas de Informações Geográficas

TRAINLM = Algoritmo *Levenberg-Marquardt*

TRAINGDX = Algoritmo de gradiente descendente com momento e taxa adaptativa

UFC = Universidade Federal do Ceará

## CAPÍTULO 1

### INTRODUÇÃO

#### 1.1 Contextualização

Embora no Brasil ainda se adotem métodos empíricos para o dimensionamento de pavimentos, como, por exemplo, o método de dimensionamento proposto por Souza (1979), o qual se baseia em informações geotécnicas e mecânicas obtidas nos ensaios laboratoriais de cargas estáticas, sendo o principal deles o CBR (*California Bearing Ratio*); pesquisas realizadas ao longo do tempo evidenciam que o CBR não representa, de maneira adequada, a natureza das cargas aplicadas aos pavimentos, que são dinâmicas e possuem ciclos de carregamento que variam com a velocidade com as quais passam sobre a rodovia. Dessa constatação, surgiu a necessidade da adoção de ensaios que mais se aproximem da realidade das cargas às quais, de fato, são submetidos os pavimentos.

Internacionalmente, os métodos de dimensionamento empírico-mecanísticos de pavimentos flexíveis, como por exemplo o *Guide of Design Pavement Structure* (AASTHO, 1993), o *Guide For Mechanistic – Empirical Design of New Rehabilitated Pavement Structures-NCHRP 1-37A* (AASTHO, 2004) e o *Mechanistic-Empirical Pavement Design Guide* (AASTHO, 2008), utilizam o Módulo de Resiliência (MR) para caracterização mecânica dos materiais das camadas dos pavimentos e do subleito, sobretudo dos solos que geralmente compõe a maior parte da estrutura.

O Módulo de Resiliência é determinado a partir dos ensaios triaxiais de carga repetida, sendo definido como a razão entre a tensão desvio e a deformação elástica recuperável ou resiliente. Quando os solos são submetidos à aplicação de carregamentos de qualquer natureza, ocorrem processos bastante complexos. Suas respostas a esses carregamentos dependem de um conjunto de fatores relacionados à mecânica, gênese e física de solos. Dentre esses fatores, podem-se citar: as condições de carregamento e estado de tensão; fatores de formação do solo, relacionada à origem; composição e estrutura; o estado físico do solo, definido pelo teor de umidade e massa específica seca; além das condições ambientais e paleoambientais que influenciaram no seu desenvolvimento ao longo dos anos geológico-pedológicos.

Os ensaios triaxiais de carga repetida ou cíclica são executados em corpos de prova moldados na umidade próxima à ótima de compactação. Com base nestes resultados,

são definidos os modelos de comportamento resiliente utilizados nos *softwares* de cálculo de tensões e deformações, que por sua vez determinam o valor do módulo de resiliência em função do estado de tensões vigente, ou seja, aqueles que consideram o comportamento elástico não linear dos materiais. No Brasil, esse ensaio é especificado pela NORMA DNIT 134/2010 – ME (DNIT, 2010).

Em comparação aos ensaios tradicionalmente executados para projetos de pavimentação, o MR é de execução mais complexa, tanto no que se refere aos recursos humanos quanto ao equipamento utilizado. Enquanto os ensaios ditos tradicionais podem ser executados em laboratórios rudimentares, dotados apenas de equipamentos básicos e instalados em regiões remotas, as câmaras destinadas ao ensaio triaxial de cargas repetidas consistem de um aparato relativamente sofisticado, o que dificulta, ou mesmo inviabiliza, o seu deslocamento e a sua utilização fora de locais devidamente adaptados. A isto se somam os problemas relativos aos custos, da ordem de R\$ 450.000,00, com preços de 2016, para aquisição do equipamento triaxial. No Brasil existe um número relativamente pequenos de equipamentos triaxiais de carga repetida, sendo que, a maior parte estão disponíveis apenas nas Universidades e Centros de Pesquisas.

Os fatores citados são determinantes para que a obtenção dos valores de MR ainda não seja uma prática amplamente difundida e executada usualmente nos laboratórios de pavimentação do Brasil, fato esse que concorre para uma baixa aplicação dos métodos de dimensionamento empírico-mecanísticos de pavimentos, tornando o processo de caracterização do comportamento mecânico de solos por meio de ensaios triaxiais cíclicos mais difícil.

Além disso, os custos financeiros dos projetos rodoviários, bem como a restrição dos recursos destinados à caracterização e controle de qualidade dos materiais empregados nas camadas e nas fundações dos pavimentos, têm motivado diversos pesquisadores a buscar correlações e modelos de predição confiáveis do módulo de resiliência com outras propriedades geotécnicas dos solos, na tentativa de que, através dessas propriedades (variáveis explicativas), obtenham-se os resultados do MR para uso em anteprojeto e projetos rodoviários, de forma mais fácil, rápida e com baixo custo. Cabe ressaltar que esses modelos não podem ser usados unicamente para substituir os ensaios de MR, mas sim para ter-se uma visão do comportamento resiliente dos materiais em uma etapa inicial do projeto. Já para o detalhamento do projeto em nível executivo, faz-se necessário a realização de ensaio para confirmar os valores previstos pelos modelos.

Os métodos de dimensionamentos *Guide For Mechanistic – Empirical Design of New Rehabilitated Pavement Structures* NCHRP 1-37A (AASTHO, 2004) e o *Mechanistic-Empirical Pavement Design Guide* (AASTHO, 2008) permitem a utilização de relações entre o módulo de resiliência e outras características dos solos para os níveis de 2 e 3 de dimensionamentos, que correspondem, respectivamente, ao projeto de rodovias de tráfego pesado, onde os equipamentos de ensaios, em laboratório ou de campo não são disponíveis e ao projeto de rodovias de baixo volume de tráfego.

Podem-se mencionar alguns trabalhos que geraram previsões do comportamento resiliente de solos a partir de outras características geotécnicas, como: RODGHER (2002), SUKUMARAN *et al.*, (2002), ZEGHAL e KHOGALI (2005), MASADA *et al.*, (2004), VIANA (2007), FERREIRA (2008) e SOLIMAN *et al.*, (2010). Os autores citados utilizaram diversas técnicas de modelagem matemática para criação de modelos de previsão do módulo de resiliência.

A partir dessas constatações, esta tese visa contribuir para o estudo do comportamento mecânico dos solos no estado do Ceará, gerando estimativas de MR e tendo como área de trabalho a Região Metropolitana de Fortaleza (RMF) e áreas adjacentes. Tais previsões visam apoiar os dimensionamentos empírico-mecanísticos de pavimentos na região estudada. Para isso, foi utilizada a técnica de Redes Neurais Artificiais (RNA), que permitiu a obtenção de estimativas de MR, com bons ajustes, a partir de resultados de ensaios básicos, o que certamente pode concorrer para uma maior aplicação dos métodos de dimensionamento empírico-mecanísticos de pavimentos, bem como para a redução dos custos de coleta e tempo de execução de ensaios mais complexos.

## 1.2 Questões de Pesquisa

Com o intuito de balizar as investigações para o desenvolvimento deste trabalho, elencaram-se as seguintes questões de pesquisa:

- Os dimensionamentos empírico-mecanísticos de pavimentos podem utilizar estimativas de MR?
- Quais dados geotécnicos (variáveis, atributos, características) possuem maior poder explicativo quanto ao comportamento resiliente de solos da região de estudo?
- É possível obter modelos de previsão confiáveis de MR a partir dos ensaios de caracterização físicas dos solos na região de estudo?



- A técnica de RNA é adequada à modelagem do comportamento resiliente dos solos para uma determinada região?
- Como sistematizar e disponibilizar um modelo que gere estimativas do ensaio de Módulo de Resiliência dos solos para a região de estudo?
- Qual a precisão de um modelo proposto em relação à geração de estimativas do comportamento resiliente de solos no estado do Ceará?

### **1.3 Objetivos**

#### ***1.3.1 Objetivo Geral***

Propor, calibrar, validar e testar um modelo destinado à geração de estimativas do módulo de resiliência de solos no estado do Ceará, como uma alternativa mais rápida, simples, precisa e de baixo custo, que sirva de suporte a alguns níveis do dimensionamento empírico-mecanístico de pavimentos flexíveis.

#### ***1.3.2 Objetivos Específicos***

- Verificar se os métodos de dimensionamentos empírico-mecanísticos existentes de pavimentos podem utilizar estimativas de MR como opção aos ensaios.
- Identificar quais dos dados geotécnicos têm maior poder de contribuição na predição do Módulo de Resiliência de Solos na área de estudo.
- Implementar modelos de predição confiáveis de MR a partir dos ensaios físicos de caracterização dos solos para a região de estudo.
- Validar a técnica de Redes Neurais Artificiais como técnica adequada à modelagem do módulo resiliente dos solos para a região estudada.
- Desenvolver e disponibilizar um aplicativo computacional destinado à geração de estimativas dos valores de Módulo de Resiliência para área de estudo.

### **1.4 Contribuição da tese**

A principal contribuição desta pesquisa para o estudo do comportamento mecânico dos solos é a implementação de modelos destinados à geração de estimativas confiáveis dos resultados do ensaio de MR para os solos naturais no estado do Ceará, tendo como área de trabalho a Região Metropolitana de Fortaleza (RMF) e municípios circunvizinhos.

A metodologia proposta visou também contribuir para difusão do uso dos métodos de dimensionamentos empírico-mecanísticos de pavimentos, pela facilitação na obtenção de MR, ajudando na redução dos custos de coleta e tempo de execução dos ensaios triaxiais de cargas repetidas em solos de fundação e das camadas granulares dos pavimentos rodoviários.

Espera-se ainda que os modelos de geração de estimativas do módulo contribuam com os projetistas e tomadores de decisão quanto à caracterização e localização, *a priori*, dos solos no estado do Ceará, fazendo parte das indicações de modelos alternativos ao ensaio de módulo de resiliência para uso nos projetos de engenharia rodoviária, respeitando-se suas restrições, dentro do estado do Ceará. Para isso, utilizou-se a técnica de Redes Neurais Artificiais (RNA), o que permitiu a geração de estimativas do MR com baixo nível de incerteza a partir de resultados de ensaios mais simples.

O modelo gerado contribui, de forma ímpar, na implementação do método de dimensionamento empírico-mecanístico de pavimentos para o estado do Ceará, por possibilitar o uso de um modelo de previsão de MR, em alternativa aos ensaios triaxiais de carga repetida.

## **1.5 Estrutura do Trabalho**

Este trabalho está dividido em sete capítulos. No Capítulo 1 é apresentada uma contextualização geral do trabalho, bem como os objetivos e justificativas que nortearam a pesquisa. Os Capítulos 2, 3 e 4 apresentam o estado da arte e da prática dos assuntos que subsidiaram este trabalho, sendo respectivamente: caracterização de solos aplicada à Pavimentação, uso de redes neurais artificiais na modelagem de solos e modelos de predição indireta do Módulo de Resiliência. O Capítulo 5 detalha a metodologia proposta nesta pesquisa, bem como apresenta os materiais que foram utilizados. No Capítulo 6, são apresentados, analisados e discutidos os resultados obtidos. Finalmente, o Capítulo 7 traz as conclusões e recomendações a respeito dos resultados obtidos.

## CAPÍTULO 2

### CARACTERIZAÇÃO DE SOLOS APLICADA À PAVIMENTAÇÃO

#### 2.1 Considerações Iniciais

Neste tópico serão mostradas algumas das principais características dos solos utilizadas na área de pavimentação, bem como as inter-relações entre a Geotecnia e outras variáveis que possam explicar e/ou influenciar na formação do solo e em suas características geotécnicas. Tal contextualização apresenta uma em visão geral sobre solos e propriedades dos solos de interesse na Pavimentação, o qual está dividido em características básicas gerais, módulo de resiliência e modelos resilientes.

#### 2.2 Propriedades dos Solos de Interesse na Área de Pavimentação

##### 2.2.1 Características Básicas Gerais

A Pavimentação utiliza-se da Mecânica dos Solos para estudar a melhor aplicação dos solos nas camadas estruturais e na fundação dos pavimentos. Para tanto, a Engenharia Rodoviária considera o solo como todo material inconsolidado ou parcialmente consolidado, inorgânico ou não, que possa ser escavado sem o emprego de técnicas especiais.

A caracterização básica de solos na pavimentação consiste em conhecer as propriedades índices, a estrutura dos solos e a resistência mecânica quando submetido a um carregamento estático ou dinâmico. Para tanto, a obtenção desses dados é realizada através de ensaios de laboratório. A estrutura e as propriedades índices são encontradas através de análise granulométrica e pela determinação dos limites de liquidez e de plasticidade, os quais são importantes para classificar os solos segundo a classificação da AASHTO. Já o parâmetro mecânica é obtido através dos ensaios de *California Bearing Ratio* (CBR) para carregamento estático e Módulo de Resiliência (MR) para carregamento cíclico. Contudo, para realização dos ensaios mecânicos, necessita-se ainda determinar os parâmetros da compactação (teor de umidade e massa específica aparente seca máxima) para uma dada energia.

No Brasil, o dimensionamento empírico convencional (Souza, 1979) de estruturas dos pavimentos ainda utiliza o CBR como parâmetro de rigidez. Este parâmetro caracteriza

mecanicamente solos e britas naturais ou misturas destes, estabilizadas granulométrica ou quimicamente.

A classificação de solos da AASHTO utiliza a análise granulométrica por peneiramento e a determinação dos limites de liquidez e de plasticidade para classificar os solos na área rodoviária. Já o CBR pode ser explicado como sendo a medida de resistência à penetração de uma amostra saturada compactada segundo o método Proctor. O valor da resistência à penetração é computado em porcentagem, sendo que 100% é o valor correspondente à penetração em uma amostra de brita graduada de elevada qualidade que foi adotada como padrão de referência na época da concepção do ensaio.

Atualmente um grande empenho de pesquisa vem sendo realizado no Brasil com o intuito de desenvolver um método de dimensionamento que utilize os conceitos de mecânica dos pavimentos. Neste método o MR é o parâmetro de caracterização mecânica de solos, seja para subleito ou para as camadas dos pavimentos. Esse esforço pode ser representado pelo projeto chamado Rede Temática de Asfaltos da Petrobras, iniciado em 2006, que contempla pesquisa, aquisição de equipamentos, reforma e construção de laboratórios de pavimentação em várias universidades brasileiras.

### **2.2.2 Módulo de Resiliência (MR)**

Pode-se afirmar que o Módulo de Resiliência (MR) é uma propriedade mecânica do solo. Na pavimentação, este conceito foi introduzido por Hveem (1955). Para esse autor, o trincamento dos revestimentos betuminosos originava-se na deformação elástica das camadas subjacentes do pavimento que gerava excessivos esforços de tração nos revestimentos. Usa-se o termo resiliente quando um material é solicitado, no caso do tráfego, por cargas repetidas aplicadas em frações de segundos que provocam deslocamentos verticais transientes nos materiais. Uma vez cessada a ação das cargas, parte desse deslocamento se torna permanente, não recuperável, e parte é resiliente, recuperável.

Matematicamente, o Módulo de Resiliência (MR) é definido como a razão entre a tensão desvio ( $\sigma_d$ ) aplicada repetidamente e a deformação específica resiliente correspondente ( $\epsilon_r$ ), conforme apresenta a Equação 2.1.

$$MR = \sigma_d / \epsilon_r \quad (2.1)$$

onde:

MR = Módulo de Resiliência;

$\sigma_d = \sigma_1 - \sigma_3 =$  tensão desvio;

$\sigma_1 =$  tensão axial cíclica;

$\sigma_3 =$  tensão de confinamento;

$\epsilon_r =$  deformação recuperável ou resiliente.

O procedimento de laboratório utilizado para obtenção do Módulo de Resiliência do solo é o ensaio triaxial cíclico. Os ensaios triaxiais de cargas repetidas objetivam reproduzir em laboratório as condições de carregamento impostas aos materiais quando submetidos às cargas de tráfego na estrutura do pavimento.

Este ensaio tem basicamente duas fases: a fase de condicionamento e a fase do ensaio propriamente dito. A fase de condicionamento tem por objetivo reduzir a influência das grandes deformações plásticas e reduzir o efeito da história de tensões no valor do Módulo de Resiliência, além de garantir que o ensaio seja realizado no regime elástico. É na verdade uma sequência de carregamentos dinâmicos que permite dotar o material de uma condição como de “pré-adensamento”. A obtenção dos valores de MR é feita na segunda fase do ensaio, onde para cada par de tensões  $\sigma_d$  (tensão desvio) e  $\sigma_3$  (tensão confinante) aplicado é feita a medição da deformação resiliente recuperável.

Durante a etapa de condicionamento, aplicam-se 200 repetições para cada tensão desvio com frequência das cargas repetidas de 1 Hz (60 ciclos por minuto) e duração de cerca de 0,1 segundo. A determinação do módulo de resiliência é feita a partir da aplicação de sequência de 18 pares de tensões com 10 repetições de carga para cada par. A partir dessas repetições são obtidas as leituras das deformações específicas resilientes recuperáveis. As Tabelas 2.1 e 2.2 apresentam os pares de tensões de condicionamento e do ensaio triaxial cíclico, segundo a NORMA DNIT 134/2010 – ME, respectivamente.

Tabela 2.1– Sequência de tensões para fase de condicionamento.

Tensão Confinante $\sigma_3$ (MPa)	Tensão Desvio $\sigma_d$ (MPa)	Razão ( $\sigma_1/\sigma_3$ )
0,069	0,069	2
0,069	0,206	4
0,103	0,309	4

Fonte: Adaptado de NORMA DNIT 134/2010 – ME

Tabela 2.2 – Sequência de tensões para determinação do módulo de resiliência.

Tensão Confinante $\sigma_3$ (MPa)	Tensão Desvio $\sigma_d$ (MPa)	Razão ( $\sigma_1/\sigma_3$ )
0,021	0,021	2
0,021	0,041	3
0,021	0,062	4
0,034	0,034	2
0,034	0,069	3
0,034	0,103	4
0,051	0,051	2
0,051	0,103	3
0,051	0,155	4
0,069	0,069	2
0,069	0,137	3
0,069	0,206	4
0,103	0,103	2
0,103	0,206	3
0,103	0,309	4
0,137	0,137	2
0,137	0,275	3
0,137	0,412	4

Fonte: Adaptado de NORMA DNIT 134/2010 – ME

### 2.2.3 Modelos Resilientes de Solos

Os solos têm seu comportamento tensão-deformação expressos por duas parcelas principais, a parcela relativa à deformação elástica, que cessa quando a estrutura é descarregada; e a parcela plástica, que dá origem às deformações permanentes, não recuperáveis com a retirada das cargas. Para quantificação da deformação elástica dos materiais, utiliza-se o Módulo de Resiliência (MR). Uma característica no comportamento desses materiais é que eles tendem a uma relação tensão-deformação não linear, ou seja, na maioria dos materiais utilizados há uma grande dependência em relação ao estado de tensões vigente. Sendo assim, foram criados diversos modelos que expressam o MR em função das tensões aplicadas aos materiais, especialmente a Tensão Desvio ( $\sigma_d$ ) e a Tensão Confinante ( $\sigma_3$ ).

Os modelos matemáticos para obtenção dos valores de MR em função das tensões e deformações aplicadas aos corpos de prova de solos foram pioneiramente propostos por Hicks (1970) e Barksdale e Hicks (1973), separados em três equações, sendo uma para

utilização em solos de comportamento granular, Equação (2.2), e os outros dois para solos de comportamento coesivo, Equação (2.3) e (2.4).

Thompson e Elliott (1985) ao discutirem os modelos representados pelas Equações (2.3) e (2.4) os nomearam de modelo bilinear e constataram que o valor do MR aumenta com a tensão desvio até um limiar, a partir do qual o valor começa a diminuir com o aumento da mesma.

$$MR = k_1 \sigma_3^{k_2} \quad (2.2)$$

$$MR = k_2 + k_3 (k_1 - \sigma_d), \quad \text{para } \sigma_d < k_1 \quad (2.3)$$

$$MR = k_2 + k_4 (\sigma_d - k_1), \quad \text{para } \sigma_d > k_1 \quad (2.4)$$

sendo:

MR = Módulo de resiliência;

$\sigma_3$  = Tensão de confinamento;

$\sigma_d$  = Tensão-desvio;

$k_1$ ,  $k_2$ ,  $k_3$  e  $k_4$  = Constantes determinadas experimentalmente (ensaio triaxial dinâmico).

Dunlap (1963) formulou o modelo representado na Equação 2.5 no qual o MR é calculado através da tensão confinante e da pressão atmosférica. Nesta formulação, as constantes  $k_1$  e  $k_3$  do modelo são normalizadas e adimensionais.

$$MR = k_1 Pa \left( \frac{\sigma_3}{Pa} \right)^{k_2} \quad (2.5)$$

onde:

Pa = Pressão Atmosférica.

Seed *et al.*, (1967) apresentaram o modelo baseado no primeiro invariante de tensão e na pressão atmosférica. O autor ressaltou que o modelo apresentado na Equação 2.6 foi usado principalmente para solos granulares. O primeiro invariante de tensão  $\theta$  é dado pelo

somatório da tensão principal maior ( $\sigma_1$ ), da tensão principal intermediária ( $\sigma_2$ ) e da tensão principal menor ou de confinamento ( $\sigma_3$ ).

$$MR = k_1 Pa \left( \frac{\theta}{Pa} \right)^{k_2} \quad (2.6)$$

onde:

$\theta$  = Primeiro invariante de tensão.

O modelo conhecido como K- $\theta$ , apresentado na Equação (2.7), considera para cálculo do valor de MR, o 1º Invariante de Tensões, ou seja, são levadas em conta as tensões principais aplicadas ao corpo-de-prova no ensaio triaxial de cargas repetidas (ALLEN e THOMPSON, 1974).

$$MR = k_1 \theta^{k_2} \quad (2.7)$$

Svenson (1980) propôs para cálculo de MR de solos coesivos o modelo representado pela Equação (2.8), em escala log-log, com  $k_2$  negativo.

$$MR = k_1 \sigma_d^{k_2} \quad (2.8)$$

Aranovich (1985) propôs o modelo conhecido como combinado ou misto, conforme as Equações (2.9) e (2.10). Esse modelo diferencia-se dos modelos tradicionais para solos arenosos ou coesivos devido levar em consideração a influência conjunta das tensões desvio e confinante no valor do MR.

$$MR = [k_2 + k_3 (k_1 - \sigma_d)] \sigma_3^{k_5}, \quad \text{para } \sigma_d < k_1 \quad (2.9)$$



$$MR = [k_2 + k_4(\sigma_d - k_1)] \sigma_3^{k_5}, \quad \text{para } \sigma_d > k_1 \quad (2.10)$$

Witczak e Uzan (1988) revisaram a equação anteriormente proposta por Uzan (1985), chegando à Equação 2.11, a qual considera as tensões desvio e octaédrica para o cálculo do MR. Este modelo foi recomendado para o cálculo do MR no guia de dimensionamento de pavimentos (AASHTO, 2008).

$$MR = k_1 Pa \left( \frac{\theta}{Pa} \right)^{k_2} \left( \frac{\tau_{oct}}{Pa} \right)^{k_3} \quad (2.11)$$

em que:

$\tau_{oct}$  = Tensão octaédrica cisalhante

Pezo (1993) apresentou uma forma para representar o MR de materiais granulares de rodovias, testados no estado do Texas, por um modelo que incorporou as tensões desvio e confinante. O modelo ficou conhecido como UT-Austin Model conforme apresentado na Equação 2.12.

$$MR = k_1 \sigma_3^{k_2} \sigma_d^{k_3} \quad (2.12)$$

O mesmo modelo de Pezo (1993), apresentado na Equação 2.12, foi trazido para o Brasil por Macêdo (1996), que propôs o seu uso na obtenção do módulo de resiliência para qualquer tipo de material, pois ele considera a influência conjunta das tensões confinante e desvio no cálculo do MR. Segundo este autor, muitas vezes não é recomendável, para um determinado tipo de material, que se determine o módulo de resiliência apenas em função de uma das tensões aplicadas ao corpo-de-prova. Esse modelo ficou conhecido no Brasil como Modelo Composto, sendo capaz de eliminar as dificuldades quanto à necessidade de definição prévia do comportamento resiliente dos solos.

Ni *et al.*, (2002) recomendam o uso da Equação 2.13, a qual utiliza as pressões confinante, desvio e atmosférica. Este modelo foi formulado, devido as Equações 2.11 e 2.12 apresentarem MR igual a zero quando a tensão confinante também apresentar valor igual a zero.

$$MR = k_1 Pa \left(1 + \frac{\sigma_3}{Pa}\right)^{k_2} \left(1 + \frac{\sigma_d}{Pa}\right)^{k_3} \quad (2.13)$$

Ooi *et al.*, (2006) recomendam o uso de dois modelos concebidos a partir da modificação dos parâmetros do modelo de NI *et al.*, (2002), conforme mostram as Equações 2.14 e 2.15.

$$MR = k_1 Pa \left(1 + \frac{\theta}{Pa}\right)^{k_2} \left(1 + \frac{\sigma_d}{Pa}\right)^{k_3} \quad (2.14)$$

$$MR = k_1 Pa \left(1 + \frac{\theta}{Pa}\right)^{k_2} \left(1 + \frac{\tau_{oct}}{Pa}\right)^{k_3} \quad (2.15)$$

Wolfe e Butalia (2004) desenvolveram o modelo de correlação apresentado na Equação 2.16 e salientaram que o modelo apenas é válido para aplicação em solos coesivos.

$$\frac{MR}{Pa} = k_1 \left(\frac{Pa \times \sigma_{oct}}{\tau_{oct}^2}\right)^{k_2} \quad (2.16)$$

onde:

$\sigma_{oct}$  = Tensão octaédrica normal

Os métodos de dimensionamentos (AASHTO, 2004) e o (AASHTO, 2008) recomendam a Equação 2.17 que utilizam cinco parâmetros para o cálculo do MR. Esse modelo é bastante utilizado no mundo para o cálculo do MR.

$$MR = k_1 Pa \left(\frac{\theta}{Pa}\right)^{k_2} \left(1 + \frac{\tau_{oct}}{Pa}\right)^{k_3} \quad (2.17)$$

#### **2.2.4 Considerações Finais**

Dentre os diversos modelos de obtenção dos valores de MR, em função das tensões aplicadas durante a realização do ensaio triaxial, o modelo que mais se ajusta aos solos do estado Ceará é UT-Austin Model (Equação 2.12). Essa afirmação foi constatada em pesquisas realizadas por Souza Júnior (2005), Gondim (2008), Araújo (2009) e Bastos (2013), as quais mostram que, no estado do Ceará, esse modelo é o que melhor representa o comportamento dos solos granulares e coesivos. Cabe ressaltar, que mesmo esse modelo sendo considerado o de melhor ajuste aos solos na região, ainda existe a necessidade de desenvolvimento de novos modelos para o estado, pois os ajustes (r-quadrados) que ele proporciona são considerados razoáveis, expressando valores de  $R^2$  da ordem de 0,60. Evidenciando, assim, a necessidade de desenvolvimento de novas pesquisas voltadas à obtenção de novos modelos de MR para os solos do Ceará.

## CAPÍTULO 3

### TÉCNICA DE REDES NEURAIS ARTIFICIAIS APLICADA À GEOTÉCNIA E PAVIMENTAÇÃO

#### 3.1 Considerações Iniciais

Neste tópico serão apresentadas as principais características do funcionamento das Redes Neurais Artificiais, bem como alguns trabalhos que utilizaram essa técnica para previsão das características importantes dos solos tanto em Geotecnia quanto em Pavimentação.

#### 3.2 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) são técnicas de Inteligência Artificial (IA) que tentam simular o funcionamento do cérebro humano em sistemas computacionais de maneira simplificada. Para isso, são usados sistemas paralelos distribuídos compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas. Essas unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais.

Haykin (2001) descreveu as redes neurais artificiais como um processador paralelamente distribuído de unidades de processamento simples, através dos quais se pode armazenar conhecimento experimental e torná-lo disponível para uso posterior.

As RNA são constituídas de neurônios artificiais, projetados para simular o comportamento dos neurônios biológicos, assemelhando-se ao cérebro em dois aspectos principais: o primeiro se refere ao conhecimento que é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; já o segundo leva em consideração a intensidade da conexão entre neurônios, conhecidos como pesos sinápticos utilizados para armazenar o conhecimento adquirido (HAYKIN, 2001).

A investigação aqui proposta não pretende propor nenhuma teoria para o melhoramento, aprofundamento ou entendimento das RNA, mas apenas estudar sua aplicação como ferramenta de modelagem dedicada à geração das estimativas de informações a partir de dados oriundos de ensaios geotécnicos aplicados à pavimentação.

### 3.2.1 Histórico das RNA

Mcculloch e Pitts (1943) desenvolveram o primeiro modelo artificial de um neurônio biológico. Nesse trabalho eles se concentraram em descrever um modelo artificial de um neurônio e apresentar suas capacidades computacionais. Mais tarde, outros pesquisadores começaram a desenvolver estudos sobre o aprendizado de redes biológicas e artificiais e sobre sua capacidade de executar determinadas funções conforme pode ser consultado em Braga *et al.* (2000).

O histórico das publicações que envolvem RNA é bem extenso, contudo apresenta-se na Tabela 3.1 um resumo cronológico feito por Bocanegra (2002) e Zampiere (2006) de algumas das principais publicações sobre esse tema.

Tabela 3.1–Estado da Arte em RNA (continua)

ANO	PESQUISADOR	PUBLICAÇÃO	AVANÇO
1943	Warren McCulloch e Walter Pitts	“ <i>A logical Calculus of the Ideas Immanent in Nervous Activity</i> ”	Concentrou-se em descrever um modelo de neurônio e apresentar suas capacidades.
1949	Donald Hebb	“ <i>The Organization of Behavior</i> ”	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.
1958	Frank Rosenblatt	“ <i>Principles of Neurodynamics</i> ”	Introduziu o modelo <i>perceptron</i> baseado nos conceitos de Pitts e McCulloch. Aborda, ainda: aprendizado supervisionado; sinapses ajustáveis; limitações nas funções lógicas.
<b>1967</b>	Widrow e Hoff		Adaline (Adaptative linear element); lei de aprendizado; saídas analógicas ao invés de saídas binárias; reconhecimento de padrões.

Tabela 3.1 – Estado da Arte em RNA (continuação)

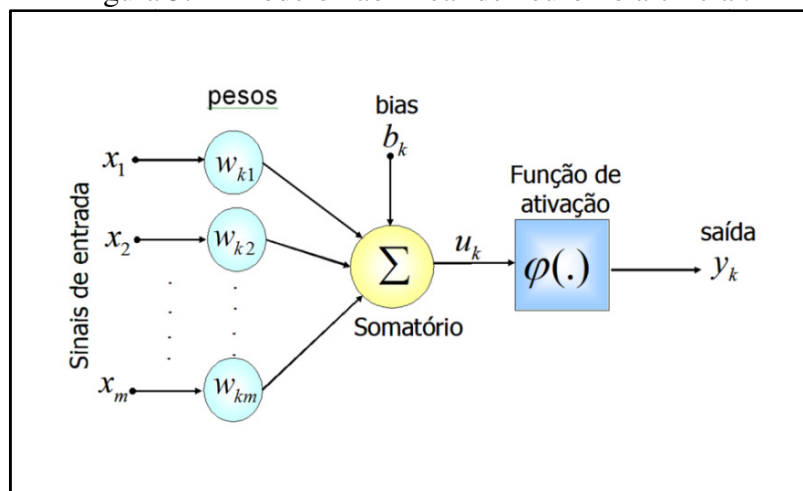
ANO	PESQUISADOR	PUBLICAÇÃO	AVANÇO
1969	Minsky e Papert	“Perceptrons”	Provaram formalmente que uma rede formada de uma única camada de neurônios, independentemente do algoritmo de aprendizagem, é capaz de resolver o problema de associação de padrões apenas quando os conjuntos são linearmente separáveis.
1982	John Hopfield		Propriedades associativas das RNA.
1986	Rumelhart, Hilton e Williams		Algoritmo de retro propagação de erro ( <i>backpropagation</i> ).

Fonte: Bocanegra (2002) e Zampiere (2006).

### 3.2.2 O Neurônio Artificial

O modelo inicial para um neurônio artificial, proposto por McCulloch e Pitts (1943), foi posteriormente aprimorado por Rosenblatt (1958) que o nomeou de *Perceptron*. Esse neurônio representa uma aproximação bastante simplificada sob a ótica neurofisiológica, porém conserva várias características básicas de um neurônio biológico e viabiliza sua implementação computacional. A Figura 3.1 apresenta o modelo de um neurônio artificial do ponto de vista matemático, onde a representação do neurônio  $k$  é melhor descrita pelas Equações 3.1, 3.2 e 3.3.

Figura 3.1– Modelo não linear de neurônio artificial.



Fonte: Da Silva (2003).

$$u_k = \sum_{i=1}^m w_{ki} x_i \quad (3.1)$$

$$v_k = u_k + b_k \quad (3.2)$$

$$y_k = \varphi(v_k) \quad (3.3)$$

onde:

$x_m$  = entradas da rede;

$w_{ki}$  = pesos, ou pesos sinápticos, associados a cada entrada;

$b_k$  = termo *bias*;

$u_k$  = combinação linear dos sinais de entrada;

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

$y_k$  = saída do neurônio.

Pode-se dizer que é no conjunto de pesos que reside todo o conhecimento adquirido pela rede. Os pesos são os parâmetros ajustáveis e que mudam e se adaptam à medida que o conjunto de treinamento é apresentado à rede neural. Assim sendo, o processo de aprendizado supervisionado em uma RNA, resulta em sucessivos ajustes dos pesos sinápticos de tal forma que a saída da rede seja a mais próxima possível da resposta desejada (HAYKIN, 2001).

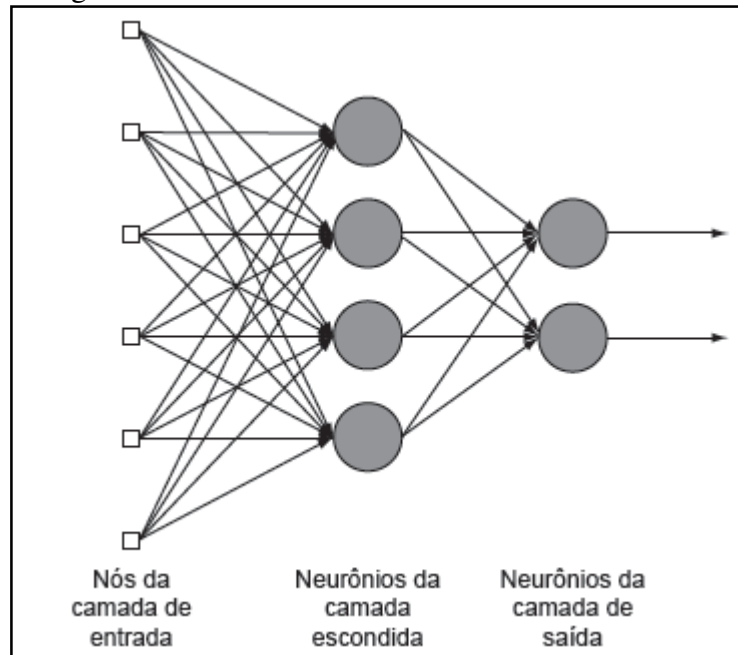
Tipicamente, a ordem de amplitude normalizada da saída do neurônio está no intervalo  $[0, 1]$  ou  $[-1, 1]$ . O modelo neural também inclui um termo chamado de *bias*, aplicado externamente, simbolizado por  $b_k$ . O *bias*  $b_k$  tem o efeito do acréscimo ou decréscimo da função de ativação na entrada da rede, dependendo se é positiva ou negativa, respectivamente. Ele serve para aumentar os graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural, ao conhecimento fornecido a ela (HAYKIN, 2001).

### 3.2.3 Estrutura das RNA

A estrutura das RNA pode ser composta por várias unidades de cálculo, onde as informações são processadas. Elas possuem unidades de processamento chamadas de

“neurônios”, as quais são conectadas entre si através de ligações que determinam o fluxo da informação pela rede, assim como acontece na rede neural biológica. As unidades de processamento podem ser através das ligações, posicionadas em camadas intermediárias ou camadas ocultas entre a entrada e a saída, como está representado na Figura 3.2.

Figura 3.2– Modelo Estrutural de uma Rede Neural.



Fonte: Haykin (2001).

### 3.2.4 Topologia de uma Rede Neural Artificial

A topologia em RNA corresponde à quantidade de camadas intermediárias, entradas, saídas e quantidade de neurônios nessas camadas. Procura-se definir a melhor topologia para um determinado problema com a finalidade de obter uma melhor qualidade no resultado (saídas do modelo).

Da Silva (2003) relata que o desempenho da rede está diretamente associado à quantidade de camadas e de neurônios, pois uma maior quantidade de camadas aumenta a capacidade de aprendizado, melhorando a precisão com que a rede delimita regiões de decisão. No entanto, na prática, aumentar o número de camadas intermediárias e a quantidade de neurônios, às vezes, se torna inviável devido ao esforço computacional.

Diversos pesquisadores estabelecem critérios matemáticos para determinar uma topologia ótima para o funcionamento da rede, dentre esses estão: Hecht-Nelson (1989), que afirmam que “com apenas uma camada intermediária na rede neural, já é possível calcular



uma função arbitrária qualquer a partir de dados fornecidos”; Cybenko (1989) e Bounds *et al.*, (1988), que sugeriram que uma camada intermediária é suficiente para classificar os padrões em grupo de dados; Chester (1990) argumentou que redes com duas camadas ocultas devem ter melhor desempenho do que redes com uma única camada oculta; Fahlman e Lebiere (1990) afirmam que mais do que uma camada escondida pode ser útil em certas arquiteturas, tais como a correlação cascata; Swingler (1996) diz que a escolha do número de neurônios na camada escondida depende do problema.

A abordagem conservadora é selecionar um número entre o número de neurônios de entrada e o número de neurônios de saída. É consenso entre os pesquisadores que a seleção do número inicial de neurônios ocultos é um pouco conflitante. Parece ser uma boa regra iniciar com o número de neurônios da camada oculta igual à metade do número de neurônios da camada de entrada e, em seguida, adicionar mais neurônios, se o erro de treinamento permanecer alto, ou reduzir os neurônios se o erro de treinamento cair rapidamente para um erro de treinamento muito baixo.

Hecht-Nelson (1987) orientam que a camada oculta deve ter por volta de  $(2i+1)$  neurônios, onde  $i$  é o número de variáveis de entrada. Lippmann (1987) defende que, quando houver uma segunda camada intermediária na topologia da rede, ela deve ter o dobro de neurônios da camada de saída. No entanto, no caso de existir apenas uma camada oculta, essa deverá possuir  $s(i+1)$  neurônios, onde  $s$  é o número de neurônios de saída e  $i$  o número de neurônios de entrada. Lawrence e Fredrickson (1988) sugeriram que a melhor estimativa para o número de neurônios ocultos é a média entre o número de neurônios de entrada e saída.

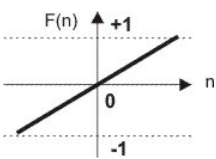
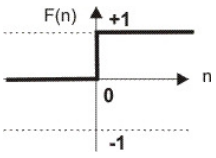
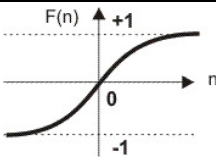
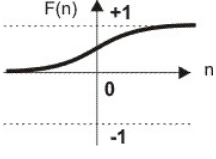
Como as RNA são empregadas em várias áreas para resolver diversos problemas, esses parâmetros apresentados são apenas indicações de partida para definição da quantidade de neurônios e camadas. Na maioria das vezes, o método empregado é de tentativa e erro, baseando-se nas medidas de desempenho para escolher o melhor modelo com menor custo computacional.

### **3.2.5 Funções de Ativação**

Em uma RNA, cada unidade de processamento está associada a um estado de ativação que é determinado pela função de ativação, contínua ou discreta, que se quer representar com o modelo. A função escolhida para o estado de ativação é responsável pelo sinal a ser transmitido por um determinado neurônio aos demais a ele conectados. Em geral, as funções mais utilizadas são a linear, a rampa, a degrau, tangente hiperbólica e a sigmoideal.

De acordo com Haykin (2001), a saída de um neurônio é definida pela função de ativação de acordo com o tipo de atividade de entrada. Existem diversas funções que produzem diferentes saídas, sendo que as mais encontradas na bibliografia pesquisada estão apresentadas na Tabela 3.2.

Tabela 3.2 – Principais funções de ativação das RNA.

NOME DA FUNÇÃO	REPRESENTAÇÃO GRÁFICA	CARACTERÍSTICA	FUNÇÃO
Linear		Função que não limita a saída da RNA e é usada para armazenar entrada e saída de dados. Os neurônios que possuem esta função atuam como aproximadores lineares.	$\varphi_i(t+1) = v_i(t)$
Degrau ou Limiar		Função utilizada para neurônios que tomam decisões binárias, limitando a saída do neurônio somente a dois valores, sendo assim, classificadora.	$\varphi_i(t+1) = \begin{cases} 1, & \text{se } v_i(t) \geq \theta \\ 0, & \text{se } v_i(t) < \theta \end{cases}$
Tangente Sigmoidal		Função limitada, definida no intervalo de -1 e +1.	$\varphi_i(t+1) = (1 - e^{-v_i(t)}) / (1 + e^{-v_i(t)})$
Sigmóide ou Logística		Função limitada, definida no intervalo de 0 e +1.	$\varphi_i(t+1) = 1/(1 + e^{-v_i(t)})$

Fonte: Adaptado de Beale (2010).

### 3.2.6 Aprendizagem em RNA

As RNA possuem a capacidade de aprender diferentes tipos de problemas, para isso extraem informações relevantes de padrões de informação apresentados, criando assim uma representação própria para o problema (BRAGA *et al.*, 2000). Existem diversos tipos de

aprendizagem, contudo aqui serão apresentados apenas os dois principais: o processo de aprendizagem supervisionado e não supervisionado.

De acordo com Braga *et al.*, (2000), o aprendizado supervisionado é o método mais comum no treinamento das RNA. É chamado de aprendizado supervisionado porque a entrada e a saída desejadas para a rede são fornecidas por um supervisor externo. O objetivo é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos.

No aprendizado não supervisionado, não existem pares de entrada e saída, só entradas. Neste caso, a RNA procura “características estatisticamente relevantes” (SILVA *et al.*, 2004) entre os dados apresentados, sendo que tal técnica só é aplicável se houver uma grande quantidade de dados.

### **3.2.7 *Perceptron Multicamadas (MLP) e o Algoritmo *Error Backpropagation****

As RNA do tipo *perceptrons* de múltiplas camadas (*Multilayer Perceptron* – MLP) constituem o tipo de arquitetura mais comum, consistindo em um conjunto de unidades de processamento com unidades de entrada, unidades intermediárias (ou camadas escondidas) e camada de saída. “Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva, ou seja, da entrada para saída” (BOCANEGRA, 2002). Sua aplicação tem sido feita em problemas “envolvendo altos graus de não linearidades” (BOCANEGRA, 2002).

Neste trabalho, será utilizado um algoritmo do tipo Retropropagação de erro, mais conhecido na literatura por *Error backpropagation*. Segundo Haykin (2001), o *Error backpropagation* é o algoritmo de Redes Neurais mais usado em aplicações práticas de previsão, classificação e reconhecimento de padrões em geral.

Esse algoritmo funciona em duas fases: (i) na primeira, o sinal que parte da entrada se desloca em direção à saída, os pesos sinápticos são mantidos e a saída simulada é comparada com saída observada, os dados observados são subtraídos dos dados simulados gerando assim um sinal de erro; (ii) na segunda fase, o erro gerado na primeira fase percorre o caminho inverso (da saída para a entrada), e esse retorno do sinal é denominado de “retropropagação do erro”. Os pesos sinápticos são ajustados e o sinal propagado novamente pela rede, de forma a buscar um sinal de erro menor a cada propagação (HAYKIN, 2001).

Descreve-se o processo de treinamento de uma RNA em cinco passos:

- a) Apresentar à rede um conjunto de dados com entradas e suas respectivas saídas conhecidas;
- b) Ajustar os pesos das camadas intermediárias (os pesos são iniciados com valores aleatórios);
- c) Estimar a saída a partir dos dados fornecidos como entrada;
- d) O sinal se propaga pela rede até atingir a saída, é quando os pesos da saída são ajustados;
- e) Conferir o erro que pode ser feito de várias formas, o objetivo principal de tal passo é determinar um critério que o erro deve atingir e, caso o erro não atenda ao critério, o processo é repetido, os pesos das camadas intermediárias são reajustados, novos valores para saídas são estimados e o novo erro é encontrado.

### 3.3 Redes Neurais Artificiais Aplicadas a Solos

O trabalho publicado por Shahin *et al.*, (2001) consistiu em uma revisão bibliográfica sobre os sucessos da aplicação de RNA em problemas de engenharia geotécnica. A revisão da literatura revelou que as RNA têm sido utilizadas com sucesso na previsão da capacidade de suporte do solo, modelagem do comportamento do solo, caracterização *in situ*, estruturas de contenção de terras, assentamento de estruturas, projetos de estabilidade de taludes, aberturas de túneis, permeabilidade do solo, condutividade hidráulica, compactação do solo e classificação dos solos.

Ao contrário dos modelos convencionais constitutivos, os modelos neurais não precisam de nenhum conhecimento prévio, ou quaisquer constantes e/ou suposições sobre as características dos solos. Outros atributos poderosos dos modelos de RNA são a sua flexibilidade e adaptabilidade que desempenham um papel importante na modelação dos solos e materiais (GHABOUSSI e SIDARTA, 1998).

Agrawal *et al.*, (1994), Gribb e Gribb (1994) e Najjar e Basheer (1996) utilizaram redes neurais para estimar a permeabilidade solos argilosos. Goh (1995) usou redes neurais para modelar a correlação entre a densidade relativa e a resistência pelo *Cone Penetration Test* (CPT), para areias normalmente adensadas. Os dados laboratoriais calibrados foram usados para treinar e testar o modelo de rede neural com sucesso. Goh (1995) utilizou um modelo neural com o algoritmo *backpropagation* para prever o atrito em estacas em solos argilosos, onde foram obtidos bons resultados, com correlação da ordem de 0,80.

Ellis *et al.*, (1995) desenvolveram um modelo de RNA para as areias com base na distribuição de tamanho de grão e história de tensões. Najjar *et al.*, (1996) mostraram que os modelos baseados em redes neurais podem ser usados para avaliar com precisão a expansão do solo e que modelos de redes neurais podem proporcionar melhorias significativas na precisão dos modelos estatísticos.

Lee e Lee (1996) utilizaram redes neurais para prever a capacidade de suporte de estacas com base nos resultados do teste de prova de carga *in situ*. Romero e Pamukcu (1996) mostraram que as redes neurais são capazes de efetivamente caracterizar e estimar o módulo tangencial de materiais granulares. Abu-kiefa (1998) utilizou uma rede neural de regressão generalizada (GRNN), que é um tipo de rede neural probabilística, para prever a capacidade de carga de estacas cravadas em solos coesivos.

Yang e Rosenbaum (2002) afirmaram que as propriedades geotécnicas são controladas por fatores como geologia, mineralogia e água nos poros das partículas minerais e que essas são dinâmicas, podendo mudar em resposta à intervenção humana no meio ambiente. Segundo os autores essas características são interdependentes, fato que dificulta o estabelecimento de suas interações para respostas geotécnicas através de métodos estatísticos. Por esse motivo, foi utilizada a ferramenta de RNA para prever o comportamento geotécnico de Força Relativa de Efeito (RSE) através de características petrográficas.

Um modelo de previsão do parâmetro OCR (*Over Conservation Ratio*) ou RPA (Razão de Pré-Adensamento) de areias a partir da medição de CPT (*Cone Penetration Test*) em campo foi desenvolvido por Juang *et al.*, (2002), utilizando como técnica de modelagem redes neurais artificiais. Nesse trabalho, a RNA atuou como classificador e aproximador de funções probabilísticas para prever o parâmetro geotécnico OCR.

O módulo de resiliência foi modelado no trabalho de Zeghal e Khogali (2005), no qual se previu este parâmetro, com coeficiente de correlação variando de 0,40 a 0,45, a partir de materiais granulares utilizando técnicas de redes neurais artificiais, tendo como dados de entrada do modelo, massa específica seca máxima, estado de tensões e umidade.

O módulo de resiliência (MR) de solos tropicais do interior de estado de São Paulo foi previsto a partir de redes neurais artificiais com eficiência no trabalho de Viana (2007). Esse autor utilizou um banco de dados de 70 amostras de solos, que se enquadram na classificação MCT, para realizar a predição do MR. Viana (2007) utilizou como variáveis de entrada, de seu modelo, características geotécnicas como: composição granulométrica, LL, IP, umidade ótima e resultados dos ensaios de compressão simples.

Ferreira (2008) utilizou técnicas de *Data Mining* e redes neurais artificiais para predição do Módulo de Resiliência de solos estabilizados e britas a partir de parâmetros geotécnicos simples. Para tanto, foi utilizado um banco de dados existente no laboratório de pavimentação da COPPE-UFRJ, sendo os resultados bastante promissores, com r-quadrados da ordem de 0,90.

Gunaydin *et al.*,(2010) afirmaram que a previsão da resistência à compressão simples (RCS) de solos coesivos é importante para determinar as propriedades de resistência ao cisalhamento. Nesse trabalho, os autores apresentaram a aplicação de diferentes métodos de análise e redes neurais artificiais para a previsão da RCS a partir de propriedades básicas do solo, como: grau de compactação, granulometria, umidade e massa específica seca máxima. A análise de regressão e por redes neurais artificiais indicaram que existem correlações aceitáveis entre as propriedades do solo e a resistência à compressão simples. Além disso, as redes neurais artificiais mostraram um maior desempenho do que os tradicionais modelos estatísticos para prever RCS.

Taskiran (2010) afirmou que a maioria dos modelos de predição dos valores de CBR existentes são essencialmente correlações estatísticas e que muitos desses modelos geralmente produzem valores de CBR insatisfatórios. Na tentativa de criar modelos de previsão de CBR mais realistas, o autor aplicou técnicas de RNA e Algoritmos Genéticos para a predição de CBR de solos finos da Anatólia, região sudeste da Turquia. Os resultados mostraram que ambas as técnicas utilizadas são capazes de aprender e inferir a relação entre CBR e propriedades básicas dos solos, com  $R^2 = 0,91$ , tais como: massa específica seca máxima, índice de plasticidade, umidade ótima, teores de (areia, argila e silte), limite de liquidez e quantidade de cascalho.

Park *et al.*, (2009) usaram modelos neurais para desenvolver um modelo empírico para predição do módulo de resiliência dos solos do subleito e sub-base. Para tanto, utilizaram como dados de entrada do modelo propriedades básicas dos solos e o estado de tensões.

Park e Kim (2010) propuseram um modelo de RNA, com ajustes de 0,92 para o conjunto de testes, para predizer a compressão simples de solos leves reforçados que consiste em um solo dragado misturado com cimento e espuma de ar, envolvido por rede. Esse material é muito utilizado como material de enchimento em construções na Ásia.

Johari *et al.*, (2011) juntaram redes neurais e algoritmos genéticos para a modelagem do comportamento mecânico de solos não saturados por meio de ensaios triaxiais. Na abordagem proposta, um algoritmo genético foi usado para otimizar os pesos da rede neural. Os dados de entrada utilizados no modelo foram: massa específica seca máxima,

deformação axial, grau de saturação, tensão desvio e tensão média. Os resultados obtidos foram considerados bastante satisfatórios, visto que foram obtidos  $R^2 = 0,96$  para o conjunto de testes do modelo neural.

Yildirim e Gunaydin (2011) utilizaram com sucesso redes neurais artificiais para a predição do CBR das camadas dos pavimentos de vias públicas de diversas cidades em regiões diferentes da Turquia. Os dados de entrada para a predição do CBR foram: análise granulométrica, limites de Atterberg, peso seco e umidade ótima, os melhores modelos de predição tiveram correlação de 0,80. Os autores recomendaram o uso de RNA para realizar esse tipo de predição como forma de subsidiar um projeto preliminar ou projeto básico, principalmente quando houver limitação financeira e de tempo.

Dantas Neto *et al.*, (2014) utilizaram a técnica de RNA para estimar a capacidade de carga em estacas para diferentes condições de solos. Eles utilizaram como dados de entrada da rede: tipo de estaca, diâmetro, comprimento e valores NSPT, onde tiveram coeficiente de correlação de 0,94, o que indica um bom resultado para previsão de capacidade carga em solos para uso em fundações.

Ribeiro, da Silva e Barroso (2015) usaram RNA para previsão da classificação da AASHTO nos solos da RMF, para tanto o modelo teve como dados de entrada, pedologia, vegetação, geomorfologia, geologia e altimetria. O índice de acertos da classificação da AASHTO foi de 92,6%. Os resultados mostram que as redes neurais artificiais podem prever com baixo nível de incerteza essa característica dos solos da região do estudo.

### **3.4 Considerações Finais**

Diante do exposto, ao longo deste capítulo, é possível afirmar que a técnica de RNA pode contribuir para o conhecimento prévio e modelagem de informações geotécnicas e de materiais para pavimentação. Assim, justifica-se o uso dessa técnica de modelagem na previsão do módulo de resiliência de solos dentro do estado do Ceará, podendo um modelo neural, de estimativas do MR, facilitar a obtenção dessa propriedade e difundir o uso dos métodos de dimensionamentos empírico-mecânico de pavimentos no estado do Ceará.

## CAPÍTULO 4

### MODELOS DE PREVISÃO DO MÓDULO DE RESILIÊNCIA

#### 4.1 Considerações Iniciais

Este capítulo faz uma explanação sobre os diversos modelos existentes para estimar o Módulo de Resiliência a partir de características básicas dos solos, obtidas de outros ensaios. Os modelos apresentados são oriundos de pesquisas que tentaram prever o módulo sem necessidade de realização de ensaios triaxiais cíclicos, facilitando assim a obtenção desse importante parâmetro do solo para a pavimentação.

#### 4.2 Modelos de Predição do Módulo de Resiliência a partir do CBR

As primeiras relações desenvolvidas para prever o módulo de resiliência a partir de outros ensaios foram feitas de forma direta com o CBR, tendo em vista esse ensaio ser muito difundido na área rodoviária.

Heukelom e Foster (1960) estudaram alguns materiais e fizeram relações entre o MR e CBR. Esses autores verificaram que a relação variou entre os limites de 50 e 200, aproximadamente, e que o valor médio do coeficiente da relação era 110 (ver Equação 4.1). Eles constataram que a razão entre a deformação plástica e elástica variava para os diversos tipos de solos, de modo que uma relação entre MR e CBR apresentava uma dispersão considerável. Esta relação foi uma das primeiras a tentar relacionar o módulo de resiliência e o CBR, porém apresentou um alto nível de incerteza.

$$\text{MR}=110 \text{ CBR} \tag{4.1}$$

Heukelom e Foster (1962) deram continuidade aos seus estudos, porém com um maior número de amostras e desenvolveram uma segunda correlação entre o CBR e MR (Equação 4.2). Esta expressão tem sido recomendada pelo guia de dimensionamento de pavimentos da AASHTO 2004. Segundo os autores, a Equação 4.2 pode fornecer estimativas



razoáveis de módulo resiliente para solos finos, porém se adapta melhor para os valores de CBR inferiores a 10%.

$$MR=1500 \text{ CBR} \quad (4.2)$$

Witczak *et al.*, (1995) propuseram uma outra relação (ver Equação 4.3), que considera uma variação exponencial do módulo de resiliência com o índice CBR. Observou-se que esta relação já tinha sido proposta originalmente por Green e Hall (1975).

$$MR=5409 \text{ CBR}^{0,711} \quad (4.3)$$

Medina e Preussler (1980) desenvolveram uma correlação a partir do estudo de 10 amostras de solos de CBR com valores inferiores a 20% (Equação 4.4). A relação entre o MR e o CBR foi estabelecida para solos argilosos e considerou somente a tensão desvio equivalente a  $2 \text{ kg/cm}^2$ , com umidade igual ou superior à ótima. Apesar do número reduzido de amostras contempladas nessa pesquisa, conseguiu-se um coeficiente de determinação de 0,82.

$$MR=326+67 \text{ CBR} \quad (4.4)$$

Rada e Witczak (1981) estudaram muitos materiais grossos (areias siltosas, cascalhos arenosos, misturas arenosas incluindo cascalhos britados, pedras britadas, calcários e escórias de siderúrgicas) e apresentaram uma relação entre o módulo de resiliência e o CBR e com o primeiro invariante de tensão, conforme mostra a Equação 4.5.

$$MR= (490 \log \theta - 243) \text{ CBR} \quad (4.5)$$

O *Asphalt Institute* (1982) publicou a Equação 4.6, que também prevê o valor do MR a partir do CBR.

$$MR = 10,3 \text{ CBR} \quad (4.6)$$

Powell *et al.*, (1984) chegaram a uma relação entre o CBR e módulo de resiliência, que está apresentada na Equação 4.7. Essa relação foi bastante utilizada em projetos de pavimentos rodoviários nos Estados Unidos da América.

$$MR=2554 \text{ CBR}^{0,64} \quad (4.7)$$

Cardoso (1988) acrescentou a tensão principal maior ( $\sigma_1$ ), além do primeiro invariante de tensão ( $\theta$ ), na sua expressão para correlacionar o módulo de resiliência com o CBR, conforme mostra a Equação 4.8. Esta expressão, que foi desenvolvida especificamente para os solos lateríticos de Brasília, apresentou uma correlação com  $R^2 = 0,92$ .

$$MR = \frac{179,0412 \text{ CBR}^{1,08774} \theta^{1,43833}}{\sigma_1^{1,18598}} \quad (4.8)$$

Zaman *et al.*, (1994) também propuseram uma correlação entre o módulo e o CBR, ao estudar as características resilientes de seis materiais granulares mais utilizados nas camadas de pavimentos de rodovias, em Oklahoma. Os autores justificaram este tipo de correlação citando que o CBR é muito usado como um indicador das características de resistência dos solos e sua correlação com o módulo de resiliência pode ser bastante útil na prática. Essa correlação foi estabelecida usando-se uma média de valores do módulo para quatro níveis de tensões (14, 20, 30 e 100 psi), variando em função do parâmetro B, conforme mostra a Equação 4.9.

$$MR = B \text{ CBR} \quad (4.9)$$

onde:

MR = módulo de resiliência (psi);

B = variável obtida para cada tipo de material (parâmetro de regressão);

CBR = Índice de Suporte Califórnia (%).

O DOT (*Department of Transportation*) do estado de Ohio - EUA propôs a Equação 4.10 para prever as propriedades resilientes do subleito a partir do valor do CBR.

$$MR = 1200 \text{ CBR} \quad (4.10)$$

Um modelo muito parecido com o modelo de Powel *et al.*, (1984) foi introduzido no método de dimensionamento AASTHO GUIDE (2002) e no MEPDG (2008) para predição do MR a partir do CBR para o nível 2 de projeto, conforme mostra a Equação 4.11.

$$MR = 2555 \text{ CBR}^{0,64} \quad (4.11)$$

Dentre as relações mostradas envolvendo o módulo de resiliência e o CBR apenas duas consideram o estado de tensões atuante no solo. Essas relações foram duramente criticadas ao longo dos anos. Considera-se que essas relações que envolvem diretamente o CBR e o MR não expressam resultados satisfatórios, isso ocorre devido a não consideração do estado de tensões que atuam no material. Por isso, existe a necessidade de se criar modelos de predição que combinem outros ensaios mecânicos e de caracterização básica de solos com os valores das tensões atuantes no solo.

Rada e Witczak (1981) enfatizaram que, pelo fato de o ensaio de MR depender da tensão, o coeficiente que relaciona o MR e CBR deve ser dependente da tensão, que é variável, portanto as relações que não consideram o estado de tensão atuante no material são consideradas limitadas.

### 4.3 Modelos de Predição do Módulo de Resiliência por Diversas Propriedades Geotécnicas

Muitos autores vêm tentando desenvolver modelos de correlação do módulo de resiliência de solos e materiais para pavimentação com outras características geotécnicas de fácil obtenção em laboratório. Diferentemente dos modelos de correlação feitos diretamente com o CBR, esses modelos relacionam diversos parâmetros dos materiais, já consagrados na área rodoviária, para prever o valor do MR.

Tais modelos tendem a ser mais confiáveis que os modelos utilizando apenas o CBR, isso ocorre devido ao fato de se trabalhar com mais variáveis explicativas. As maiorias dos modelos, geralmente, associam o MR com: a granulometria, os limites de consistência, a massa específica seca máxima, a umidade, bem como as tensões atuantes no corpo de prova durante o ensaio triaxial de carga repetida.

Jones e Witczak (1977) desenvolveram um modelo, apresentado na Equação 4.12 que relaciona o valor do módulo de resiliência com a umidade e o grau de saturação do subleito de solos coesivos de uma rodovia experimental em San Diego – EUA. Esta equação teve um coeficiente de determinação de 0,44 e somente deve ser utilizada para solos do tipo A-7-6 da classificação da AASHTO.

$$\log MR = -0,111109w + 0,021699S + 1,17869 \quad (4.12)$$

onde:

MR = Módulo de Resiliência;

w = teor de umidade em %;

S = grau de saturação em %.

Thompson e Robnett (1979) estudaram as características resilientes de vários solos coesivos de subleito do estado americano de Illinois. Nesse estudo, eles mantiveram a tensão confinante igual a zero e a tensão desvio igual a 6psi, correlacionando os valores de MR com as características geotécnicas básicas dos solos. A Equação 4.13 ilustra o modelo gerado com um coeficiente de determinação de 0,80, sugerindo assim uma boa correlação entre o MR e as variáveis investigadas.

$$MR = 6,37 + 0,034\%CLAY + 0,45 \times PI - 0,0038\%SILT - 0,244CLASS \quad (4.13)$$

onde:

MR = Módulo de Resiliência;

%CLAY = percentual de argila;

PI = índice de plasticidade;

% SILT = percentual de silte;

CLASS = classificação da AASHTO.

Rada e Witczak (1981) utilizaram seis tipos de solos granulares para desenvolver um modelo que correlacionasse o MR com o primeiro invariante de tensão, o grau de saturação e o grau de compactação. A Equação 4.14 apresenta o modelo criado.

$$\log MR = 4,022 - 0,006832 S + 0,007055 GC + 0,005516 \log \theta \quad (4.14)$$

onde:

MR = Módulo de Resiliência;

$\theta$  = primeiro invariante de tensão;

S = grau de saturação em %;

GC = grau de compactação.

Visser, Queiroz e Hudson (1981), desenvolveram dois modelos de predição de MR a partir dos Limites de Atterberg, sendo um para solos arenosos (Equação 4.15) e o outro para solos argilosos (Equação 4.16).

$$\log MR = 3848 + 0,0243(LL) + 0,1011 \log \sigma_d - 0,0683 (LP) - 0,0198(LP) \log \sigma_d \quad (4.15)$$

$$\log MR = 2932 + 0,0348(LL) + 0,293 \log \sigma_d - 0,0683 (LP) \quad (4.16)$$

onde:

MR = Módulo de Resiliência;

LL = limite de liquidez %;

LP = limite de plasticidade %;  
 $\sigma_d$  = tensão desvio.

O modelo mostrado na Equação 4.17 foi desenvolvido por Carmichael e Stewart (1985) e se baseia em um banco de dados de módulos resilientes preexistente. O valor de coeficiente de determinação desse modelo foi de 0,80, sugerindo que esta é uma boa correlação. Os autores alertaram que tal formulação é válida tão somente para solos de subleito contendo argila e silte.

$$MR = 37,4 - 0,45PI - 0,62w - 0,14S200 + 0,18\sigma_3 - 0,32\sigma_d + 36,4CH + 17,1MH \quad (4.17)$$

em que:

w = umidade;

S200 = percentual passante na peneira número #200;

CH = igual a 1 se o solo for muito argiloso e igual a 0, se caso contrário;

MH = igual a 1 se o solo for muito siltoso e igual a 0, se caso contrário.

Carmichael e Stewart (1985) também propuseram uma correlação (Equação 4.18) para solos granulares e agregados provenientes de base de pavimentos.

$$\log MR = 0,523 - 0,0225\%W + 0,544\log \theta + 0,173SM + 0,197GR \quad (4.18)$$

em que:

%W = umidade ótima de compactação;

SM = igual a 1 se o solo for uma areia siltosa e igual a 0, se for outro solo;

GR = igual a 1 se o solo for pedregulhoso e igual a 0, se for outro solo.

Thompson e Lagrow (1988) desenvolveram o modelo de correlação mostrado na Equação 4.19 para os subleitos compactados do estado de Illinois – EUA. Eles propuseram também fatores de correção para umidade, que devem ser aplicados na previsão do módulo de resiliência. Para argila, argila siltosa e silte argiloso, o fator de correção é de 0,7; já para a argila franca, o fator de correção é de 1,5.

$$MR = 4,46 + 0,098C + 0,12PI \quad (4.19)$$

em que:

MR = Módulo de Resiliência;

C = percentual de argila;

PI = índice de plasticidade.

Elliott *et al.*, (1988) testaram vários solos do estado Americano do Arkansas e desenvolveram dois seguintes modelos de predição de módulo de resiliência para duas diferentes tensões desvio de 4 psi (Equação 4.20) e 8 psi (Equação 4.21). Os coeficientes de determinação das Equações 4.20 e 4.21 foram de 0,80 e 0,77, respectivamente. Os módulos resilientes determinados a partir dessas relações são válidos apenas para as tensões apresentadas acima e para solos coesivos.

$$MR = 11.21 + 0.17\%CLAY + 0.20PI - 0.73w_{opt} \quad (4.20)$$

$$MR = 9.81 + 0.13\%CLAY + 0.16PI - 0.60w_{opt} \quad (4.21)$$

onde:

$w_{opt}$  = umidade ótima de compactação.

Farrar e Turner (1991) correlacionaram o módulo de resiliência com outras variáveis geotécnicas de 13 amostras de solos finos do subleito do estado de Wyoming - EUA. Eles obtiveram um  $R^2 = 0,663$ , que representa uma forte correlação segundo a estatística, porém para fins práticos de uso na pavimentação, esse valor de correlação é tido como baixo (ver Equação 4.22).

$$MR = 30280 - 359S - 325\sigma_d + 237\sigma_3 + 86PI + 107S200 \quad (4.22)$$

Visser, Queiroz e Hudson (1981) desenvolveram a correlação apresentada na Equação 4.23, a partir de amostras indeformadas de solos arenosos oriundos do subleito de rodovias da região central do Brasil. Esse modelo apresentou um  $R^2 = 0,64$ .

$$\log MR = 2,79 + 0,0268LL - 0,0573LP - 0,000158 LP \sigma_d \quad (4.23)$$

Diversos ensaios de MR foram elaborados por Hudson *et al.*, (1994) para 8 amostras de solos finos, provenientes do subleito do estado americano do Tennessee. As amostras eram compostas por solos do tipo A-4 e A-7-6. De posse dos resultados dos ensaios de módulo, pôde-se relacioná-los com os resultados dos ensaios geotécnicos mais simples criando assim um modelo (Equação 4.24) com um  $R^2 = 0,70$ .

$$\begin{aligned} \log MR = & 46,93 + 0,018\sigma_d + \Delta\gamma_d - 0,114LI + 0,468S + 0,0085CLASS - 0,0033\Delta w \\ & - 0,0012 \sigma_3 + 0,0001 PL - 0,0278 LI - 0,0017 S - 38,44 \log S - 0,2222 \log \sigma_d \end{aligned} \quad (4.24)$$

onde:

$\Delta w$  = variação da umidade ótima de compactação;

$\Delta\gamma_d$  = variação da massa específica seca máxima.

Berg *et al.*, (1996) realizaram um estudo do módulo de resiliência dos solos coesivos finos e grossos do estado de Minnesota - EUA. A partir desse estudo desenvolveram o modelo de predição do MR mostrado na Equação 4.25. Esse modelo obteve um coeficiente de determinação de 0,95, caracterizando assim a equação como potencialmente adequada para predição do módulo de resiliência dos solos no estado de Minnesota.

$$MR = 1,518.10^{30} [f(S)]^{13,85} [(f(\sigma))]^{-0,272} \quad (4.25)$$

onde:

$f(S)$  = é a saturação normalizada (valor entre 0 e 1);

$f(\sigma)$  = é tensão de cisalhamento octaédrica normalizada (valor entre 0 e 1).



Gupta *et al.*, (2007) propuseram a Equação 4.26 para previsão do módulo resiliente a partir da sucção do solo ( $\psi$ ). A pesquisa foi desenvolvida apenas para solos coesivos e obteve-se um valor de  $R^2 = 0,76$ . Ressalta-se que o módulo de resiliência calculado por essa expressão só é válido para o primeiro invariante de tensão de 83 kPa e tensão octaédrica de 19,3 kPa.

$$MR = -54105 + 57898 \log(\psi) \quad (4.26)$$

Çöleri (2007), ao estudar o comportamento dos solos da Turquia, afirmou que os modelos de previsão do módulo de resiliência podem ser melhorados através da inclusão das propriedades índices do solo, de modo a minimizar os erros residuais. Para o autor, os parâmetros mais eficazes e que têm grande significado para calcular o MR são: CBR, limite de liquidez (LL) e umidade ótima (MAC). A partir desses parâmetros foi desenvolvido um modelo de regressão para o MR com  $R^2 = 0,7089$ , como mostra a Equação 4.27.

$$MR = 228376,7946 - 1479,8978 \times LL - 12381,4217 \times MAC \\ + 689,5 \times CBR + 152,9164 \times LL \times MAC \quad (4.27)$$

Behiry (2014) desenvolveu modelos de regressão para calcular o módulo de resiliência em função do CBR e da massa específica seca dos solos ( $\gamma_d$ ) do Egito. Essa pesquisa teve como objetivo determinar o módulo de resiliência para uso em concepção de pavimentos utilizando o método empírico-mecanístico do país. A Equação 4.28 apresenta o modelo desenvolvido para predição dos MR do subleito, onde um  $R^2 = 0,92$  foi alcançado com as amostras pesquisadas.

$$MR = -5170,88 + 41CBR + 178406,47\gamma_d \quad (4.28)$$

#### 4.4 Modelos de Predição do Módulo de Resiliência usados pelos DOT no Dimensionamento de Pavimentos

Para identificação de qual método ou variáveis são melhores para prever o módulo de resiliência de solos para o uso nos níveis 2 e 3 de dimensionamento da AASTHO (2008) e AASTHO (2004), que correspondem, respectivamente, ao projeto de rodovias de tráfego pesado, onde os equipamentos de ensaios, em laboratório ou de campo não são disponíveis e ao projeto de rodovias de baixo volume de tráfego.

Em virtude disso, vários departamentos de transporte (DOT) dos Estados Unidos foram encorajados a realizar pesquisas regionais para verificação e validação de modelos de predição do MR a partir de variáveis secundárias. Tais pesquisas foram conduzidas por cada DOT com a finalidade de identificar a realidade das ocorrências dos solos de cada estado. Assim, diversos modelos foram gerados e definidos para uso em cada DOT.

Ainda para o nível 3 de dimensionamento, o MEPDG (AASHTO, 2008) recomenda a utilização de valores típicos de MR obtidos a partir dos resultados dos ensaios realizados em todos os Estados Unidos. A Tabela 4.1 apresenta os valores típicos de MR para as classificações da AASTHO e SUCS.

Tabela 4.1 – Valores Típicos de MR usados no nível 3 do MEPDG (continua)

Sistema de Classificação	Classificação do Material	MPa	
		Faixa de MR	MR Típico
AASHTO	A-1-a	265,45 - 289,59	275,80
	A-1-b	244,77 - 275,8	262,01
	A-2-4	193,06 - 258,56	220,64
	A-2-5	165,48 - 227,53	193,06
	A-2-6	148,24 - 213,74	179,27
	A-2-7	148,24 - 193,06	165,48
	A-3	168,92 - 244,77	199,96
	A-4	148,24 - 199,95	165,48
	A-5	117,21 - 175,82	137,90
	A-6	93,08 - 165,48	117,22
	A-7-5	55,16 - 120,66	82,74
	A-7-6	34,47 - 93,08	55,16

Tabela 4.1 – Valores Típicos de MR usados no nível 3 do MEPDG (continuação)

Sistema de Classificação	Classificação do Material	MPa	
		Faixa de MR	MR Típico
USCS	CH	34,47 - 93,08	55,16
	MH	55,16 - 120,66	79,29
	CL	93,08 - 165,48	117,22
	ML	117,21 - 175,82	137,90
	SW	193,06 - 258,56	220,64
	SP	165,48 - 227,53	193,06
	SW – SC	148,24 - 213,74	175,82
	SW – SM	165,48 - 227,53	193,06
	SP – SC	148,24 - 213,74	175,82
	SP – SM	165,48 - 227,53	193,06
	SC	148,24 - 193,06	165,48
	SM	193,06 - 258,56	220,64
	GW	272,35 - 289,59	282,70
	GP	244,77 - 275,8	262,01
	GW – GC	193,06 - 275,8	237,88
	GW – GM	244,77 - 279,24	265,46
	GP – GC	193,06 - 268,9	234,43
	GP – GM	213,74 - 275,8	248,22
	GC	165,48 - 258,56	213,75
GM	227,53 - 289,59	265,46	

Fonte: AASTHO (2008)

O DOT da Flórida desenvolveu um modelo de predição do módulo de resiliência de solos do tipo A-3 e A-2-4, os quais são os solos predominantes no estado. O modelo é apresentado na Equação 4.28 e foi obtido a partir de regressões múltiplas com o coeficiente de determinação igual a 0,525. Esse modelo é utilizado para prever o MR no estado da Flórida para os níveis 2 e 3 de dimensionamento de pavimentos (PING e LING, 2007).

$$\ln MR = 9,76 - 0,0602C_c + 0,121C_u - 0,0297w + 0,0303Clay + 6,7k \quad (4.28)$$

onde:

$C_c$  = coeficiente de curvatura da curva granulométrica;

$C_u$  = coeficiente de uniformidade da curva granulométrica;

k = coeficiente de permeabilidade;  
Clay = percentual de argila.

O DOT do estado de Illinois utiliza para predição do módulo de resiliência, a Equação 4.29 desenvolvida por Thompson e Lagrow (1988). O modelo foi gerado com o coeficiente de determinação igual a 0,63.

$$MR = 4,46 + 0,098Clay + 0,119PI \quad (4.29)$$

O DOT do estado de Indiana utiliza para predição do MR, para o nível 1 de dimensionamento, três modelos (Equação 4.30, 4.31 e 4.32) para cálculo das constantes (k1, k2 e k3), que são utilizadas para obtenção do valor do MR através da aplicação direta das constantes de regressão obtidas no modelo resiliente geral descrito na Equação 2.17 e adotado no AASHTO (2008). Os três modelos obtiveram um  $R^2 = 0,84$  na determinação do MR. Os resultados desse trabalho são apresentados por Kim e Siddiki (2006).

$$\begin{aligned} \log k_1 = & -20,62 - 0,0594 OMC + 0,02689 MC - 1,1974 MCR + 0,18322 MDD \\ & - 0,1689DD + 23,5925\%COMP - 0,4651 SATU - 0,007 \% SAND \\ & - 0,0047\% SILT - 0,0028\% CLAY + 0,04087LL - 0,0244PI \end{aligned} \quad (4.30)$$

$$\begin{aligned} k_2 = & 11,9183 - 0,0948OMC + 0,08235MC - 2,19MCR - 0,0867MDD + 0,12727DD \\ & - 14,03\%COMP + 1,02965SATU - 0,0302\%SAND - 0,012\%SILT - 0,0278\%CLAY \\ & + 0,05654LL - 0,0384PI \end{aligned} \quad (4.31)$$

$$\begin{aligned} k_3 = & -131,46 + 0,30203OMC - 0,7234MC + 7,13189MCR + 1,22272MDD - 1,1918DD \\ & + 122,713\%COMP + 3,61448SATU - 0,0796 \%SAND - 0,0185\%SILT + \end{aligned}$$

$$0,00251\%CLAY + 0,03458LL + 0,08488PI \quad (4.32)$$

onde:

OMC = umidade ótima;

MC = teor de umidade;

DD = massa específica;

% COMP = grau de compactação;

SATU = grau de saturação;

%SAND = percentual de areia;

SILT% = percentual de silte;

%CLAY = percentual de argila.

Segundo Von Quintus (2007), no estado do Kansas, o DOT estima o MR do subleito das rodovias a partir de uma equação de regressão que foi desenvolvida nos anos 1980 por este mesmo autor. Os valores de MR são obtidos através apenas do limite de liquidez do solo, conforme ilustra a Equação 4.33.

$$MR = 372,47 LL^{-1,329} \quad (4.33)$$

Os estados que compõem a região da Nova Inglaterra (Maine, Massachusetts, New Hampshire, Vermont, Rhode Island e Connecticut) fizeram um consórcio através dos DOT e estudaram modelos de predição de MR a partir de outras variáveis. Com isso, desenvolveram diversos modelos de previsão do módulo para cada classe de solos da Classificação da AASHTO e da Classificação Unificada.

Os pesquisadores dos DOT da Nova Inglaterra optaram por prever as constantes do modelo resiliente geral (Equação 2.17), indicado no AASHTO (2004) e no AASHTO (2008), ao invés do valor do MR. Nesses estados, a maior parte dos solos predominante são os solos do tipo A-3. Apresentam-se nas Equações 4.34, 4.35 e 4.36 apenas os modelos de predição para esse tipo de solo, que obteve um coeficiente de determinação de 0,98 (MALLA e JOSHI, 2006).

$$\text{Log } k_1 = - 1,80028 + 0,06083MC + 0,09612OMC \quad (4.34)$$

$$k_2 = 1,11468 - 0,03964MC - 0,04803CLAY \quad (4.35)$$

$$k_3 = 1,89076 - 0,08899OMC - 0,00055406MAXDD \quad (4.36)$$

onde:

MAXDD = massa específica seca máxima.

O DOT da Georgia testou uma série de materiais granulares para o ensaio triaxial de carga repetida e criaram um banco de dados para viabilizar a construção de um modelo de correlação para previsão do módulo de resiliência para uso no método empírico-mecanístico de dimensionamento de pavimentos. A pesquisa chegou à Equação de regressão 4.37.

$$MR = 3116 (CBR)^{0,49} \quad (4.37)$$

Rahim e George (2004) investigaram a relevância do uso de propriedades índices na previsão do módulo de resiliência dos solos do Mississippi. Duas expressões foram desenvolvidas, sendo uma para solo fino (Equação 4.38) e outra para solo granular (Equação 4.39). Esses modelos foram desenvolvidos a partir de 20 amostras de solos do estado do Mississippi. O DOT do estado aceita essas equações para predição do MR para os níveis 2 e 3 de dimensionamento de pavimentos.

$$MR = 16,75((LL/w \gamma_{dr})^{2,06} + (P200/100)^{-0,59}) \quad (4.38)$$

$$MR = 307,4 (\gamma_{dr}/w_c)^{0,86} (P200/\log Cu)^{-0,46} \quad (4.39)$$

onde:

$\gamma_{dr}$  = massa específica / massa específica seca máxima.

Edil *et al.*, (2006) e Gupta *et al.*, (2007) estudaram os efeitos da sucção na predição do módulo de resiliência nos solos do estado de Minnesota. Esses estudos foram

desenvolvidos em parceria com o DOT local (MnDOT), eles abordaram a necessidade de incorporar os efeitos da sucção para a modelagem do MR. Os resultados mostraram que o valor de MR aumenta com o aumento da sucção. Com isso foi desenvolvido um modelo, já mostrado anteriormente na Equação 4.26, de predição do MR a partir da sucção com um coeficiente de determinação de 0,76. Tal modelo é sugerido pelo MnDOT para calcular o MR para os níveis 2 e 3 de dimensionamento pelo MEPDG.

#### **4.5 Considerações Finais**

Com base nos assuntos discutidos nos capítulos 2, 3 e 4, é possível afirmar que a modelagem da previsão do módulo de resiliência tem sido proposta e utilizada em substituição ao ensaio. Percebe-se que a maioria dos autores trabalhou com métodos estatísticos de regressão múltipla e alguns poucos com ferramentas e técnicas de modelagens computacionais para previsão desse parâmetro, obtendo assim resultados satisfatórios para seus estudos. Ainda viu-se que na prática alguns desses modelos de predição do MR são utilizados pelos órgãos rodoviários de alguns estados americanos, no dimensionamento de pavimentos.

No Brasil, os métodos de dimensionamento de pavimentos vigentes não fazem uso do módulo de resiliência de solos. Porém, como a construção de um novo método de dimensionamento está em curso e nele será adotado os conceitos de mecânica dos pavimentos, que usa o módulo de resiliência como principal parâmetros mecânico dos solos, torna-se importante que cada estado, ou região do Brasil, tenha seus próprios modelos e equações de previsão do módulo de resiliência dos solos para se trabalhar, pelo menos em nível de pré-projeto e anteprojetado. Para isso, pesquisas desse tipo precisam ser desenvolvidas pelos órgãos rodoviários (DNIT e DER) de cada estado Brasileiro, em parceria com as universidades e instituições de pesquisas.

## CAPÍTULO 5

### MATERIAIS E MÉTODOS

#### 5.1 Considerações Iniciais

Esse trabalho foi motivado pela necessidade de se contribuir, difundir e popularizar no Brasil, o uso do método de dimensionamento empírico-mecanístico de pavimentos flexíveis, através da facilitação na obtenção dos valores dos MR de solos no estado do Ceará, a partir de técnicas de RNA e de ensaios geotécnicos mais simples.

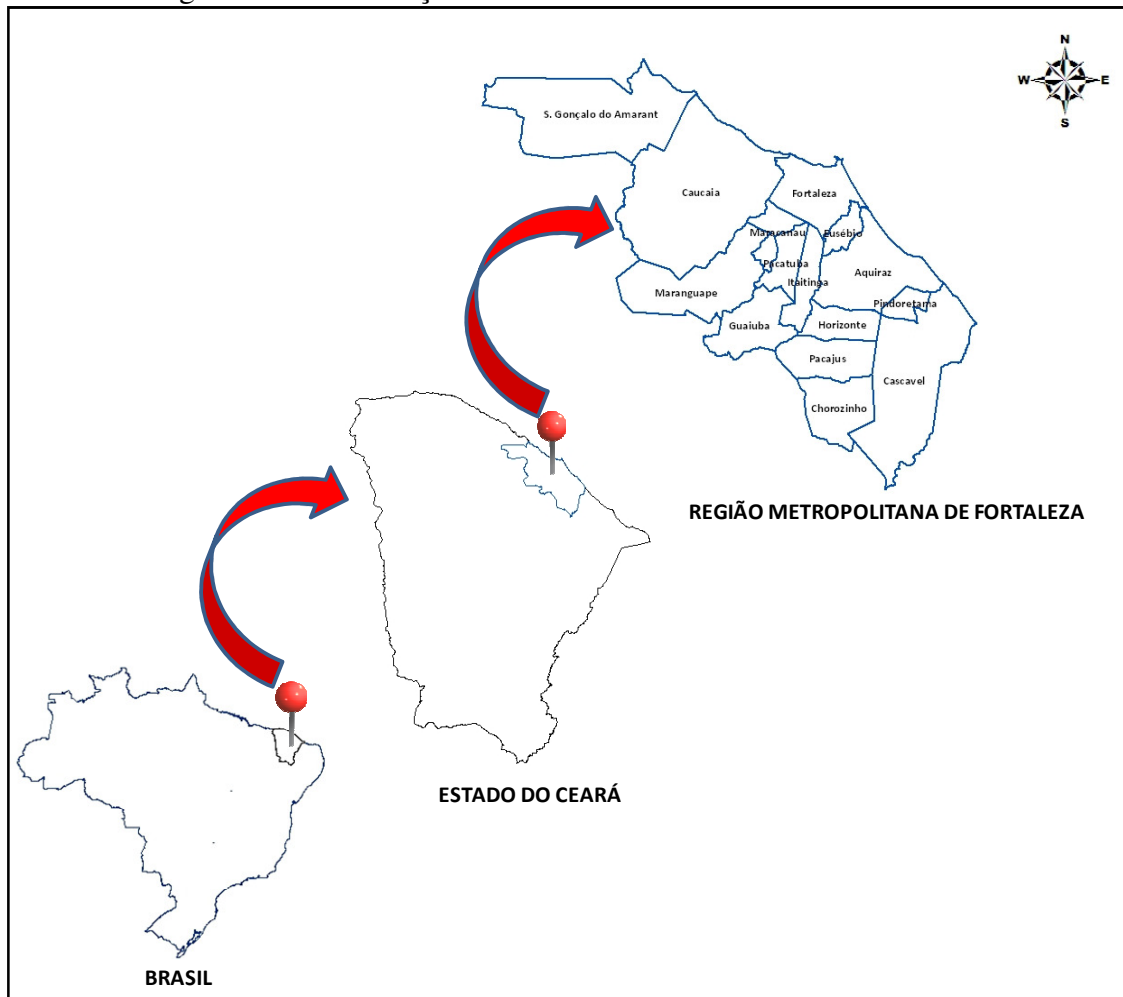
A região escolhida para a modelagem foi a Região Metropolitana de Fortaleza (RMF)-CE e os municípios adjacentes. Esta seleção ocorreu devido a uma série de fatores que serão mais detalhados ainda neste capítulo. As informações utilizadas para elaboração desta investigação foram basicamente dados geotécnicos, amostras de solos e aplicativos computacionais. A partir dessas informações, criaram-se modelos neurais de previsão do MR.

#### 5.2 Escolha da Área de Estudo

A Região Metropolitana de Fortaleza está localizada no nordeste do estado do Ceará, ocupando uma área de 584.301,35 hectares. É formada por 15 municípios: Fortaleza, Caucaia, Maranguape, Pacatuba, Aquiraz, Maracanaú, Eusébio, Guaiúba, Itaitinga, Chorozinho, Pacajus, Horizonte, São Gonçalo do Amarante, Pindoretama e Cascavel (IBGE 2010). Ela tem como vizinhos e adjacentes os municípios (Paráipaba, Paracuru, São Luís do Curu, Trairi, Itapipoca, Itarema, Acaraú) do Pólo Ceará Costa do Sol, onde o turismo se desenvolve mais forte nesta região. A Figura 5.1 ilustra a localização da RMF no estado do Ceará e no Brasil.



Figura 5.1– Localização da RMF no estado do Ceará e no Brasil.

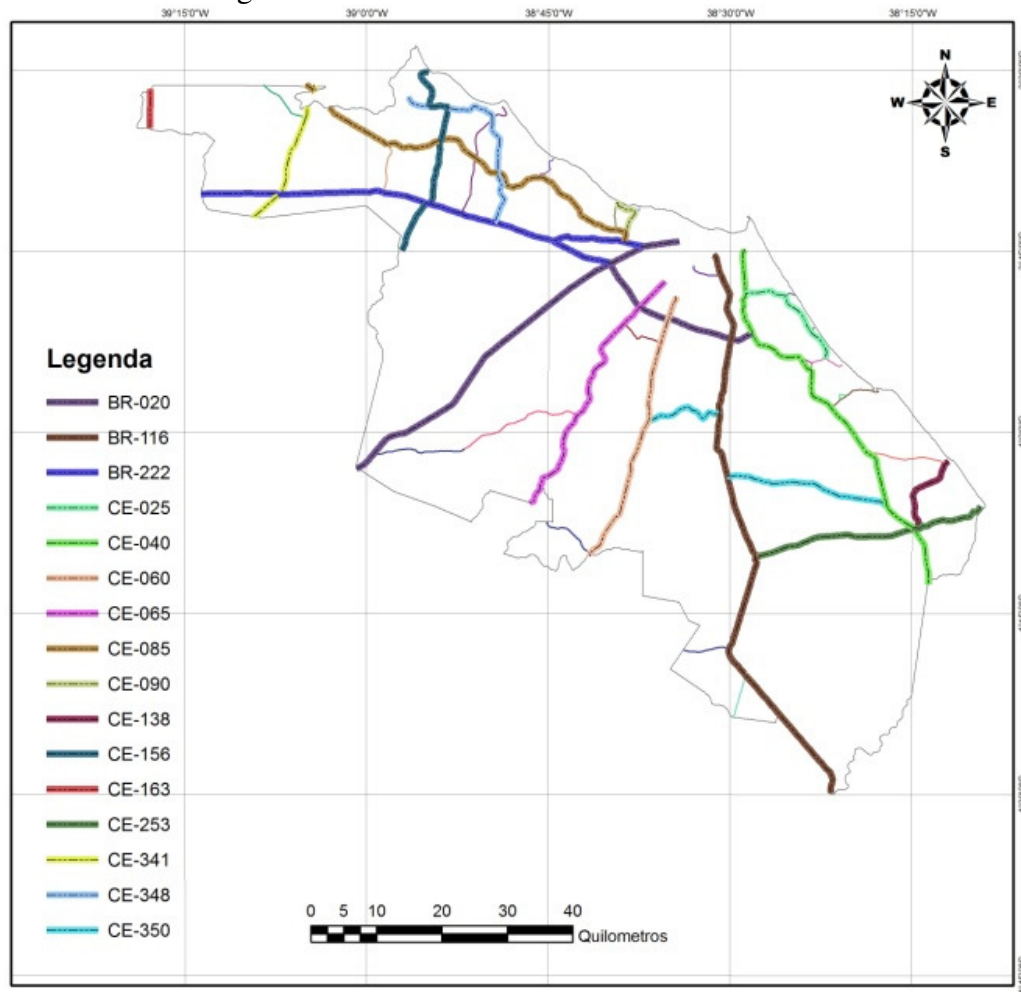


Fonte: O autor.

A RMF ocupa cerca de 4% da área total do estado do Ceará e possui uma população de 3.610.379 habitantes, o que representa 42,74% da população total do estado (IPECE, 2010). Nela está inserido o Complexo Industrial e Portuário do Pecém (CIPP), nos limites dos municípios de São Gonçalo do Amarante e Caucaia, bem como os pólos industriais de Maracanaú e Horizonte-Pacajus, que abrigam a maior parte da produção industrial do estado. A indústria da RMF é diversificada em vários setores, sendo os principais: vestuário, alimentos, metalurgia, têxtil e químico. O turismo é outra atividade bastante representativa na economia da RMF.

A região possui uma malha viária constituída por dezesseis rodovias de grande e médio porte, sendo três federais (BR-222, BR-020, BR-116) e treze estaduais (CE-025, CE-040, CE-060, CE-065, CE-085, CE-090, CE-138, CE-156, CE-163, CE-253, CE-341, CE-350, CE-348). Há ainda 20 rodovias estaduais pavimentadas de ligação que se estendem pelos municípios adjacentes a RMF. A Figura 5.2 ilustra a malha pavimentada da RMF.

Figura 5.2 – Malha Rodoviária Pavimentada da RMF.



Fonte Ribeiro *et al.*, (2012).

Desde a inauguração do Porto do Pecém, em 2002, e do CIPP (Complexo Industrial e Portuário do Pecém) na RMF, muitos investimentos industriais têm se deslocado para essa região. A Companhia Siderúrgica do Pecém e a Termelétrica Porto do Pecém são exemplos de novas indústrias que somam investimentos de cerca de US\$ 22.100.000.000,00 (IPECE, 2010).

Para que esses empreendimentos tornem-se viáveis e haja desenvolvimento na região e entorno, o poder público tem investido na melhoria da infraestrutura da região, tendo como principais focos: duplicação e desvios de rodovias existentes e abertura de novas rodovias, além de melhoria das vias já implantadas. Esses investimentos devem trazer grande demanda de estudos de solos na região para fins de pavimentação e uso em Engenharia no geral. Alguns trabalhos de reconhecimento de solos para fins de pavimentação já foram executados na RMF, podendo-se citar os trabalhos de Ribeiro *et al.*, (2015), Barroso (2002) e Chaves (2000).

Barroso (2002) realizou a caracterização de sessenta solos na RMF. Essas amostras foram georreferenciadas com o auxílio do sistema GPS (*Global Positioning System*), possibilitando a obtenção de suas coordenadas geográficas, viabilizando assim, o futuro emprego desses dados em ambiente SIG. Já Chaves (2000) caracterizou geotecnicamente os solos da Formação Barreiras da RMF segundo a metodologia MCT (Miniatura, Compactada, Tropical) e realizou ensaios de módulo de resiliência.

### **5.3 Dados Utilizados**

Para aplicar, testar e validar os modelos de predição do módulo de resiliência na região escolhida, foi necessário criar um banco de dados geotécnico, que foi formado por dados existentes extraídos de trabalhos acadêmicos (dissertações e teses) desenvolvidos para a região de estudo. Tais investigações tiveram como objeto de estudo o MR dos solos, *in natura*, do estado do Ceará, sendo utilizados os trabalhos de Chaves (2000), Benevides (2000), Souza Júnior (2006) e Bastos (2013) para extração de informação.

Adicionalmente, foram obtidos dados a partir de um esforço amostral que envolveu a coleta e caracterização através de ensaios em amostras retiradas da região estudada, não apenas pelo autor, mas em trabalhos acadêmicos realizados concomitantemente a esta investigação.

### **5.4 Aplicativos Computacionais Empregados**

Os aplicativos computacionais ArcGIS e Civil 3D foram utilizados na realização de todas as operações espaciais de georreferenciamento, população do banco de dados, cruzamento de informações, produção de mapas, dentre outras. O IBM SPSS foi utilizado para executar a análise estatística de correlação e significância das variáveis envolvidas na modelagem, bem como testar alguns modelos de regressão. O MS Excel foi utilizado no pré-processamento dos dados que antecedeu a modelagem neural, assim como análise dos resultados após a saída dos dados da rede neural. O MATLAB foi usado nas etapas de treinamento, teste e validação dos modelos neurais para predição do MR. Utilizou-se, também, um programa de análise de tensão e deformação, o CAP3D, desenvolvido pelo grupo do Laboratório de Mecânica dos Pavimentos (LMP) da UFC (Universidade Federal do Ceará) para realizar uma análise numérica para validação do modelo neural escolhido.

#### **5.4.1 ArcGIS**

Utilizou-se a versão 9.3 do ArcGIS, bem como suas extensões para análise espacial, desenvolvido pela ESRI (*Environmental Systems Research Institute*), disponível no LAG(Laboratório de Geomática Aplicada) da UFC. Trata-se de um Sistema de Informações Geográficas (SIG) que conjuga os procedimentos adequados para visualização, exploração e análise de informação espacial. É o principal SIG do mercado mundial na atualidade, possuindo uma série de recursos para manipulação dos mais variados dados geograficamente posicionáveis. Neste trabalho, o ArcGIS foi utilizado para executar a manipulação de dados espaciais, georreferenciamento e geração de mapas temáticos.

#### **5.4.2 Autodesk Civil 3D**

O Autodesk Civil 3D 2010, desenvolvido pela Autodesk, é um sistema CAD (Desenho Assistido por Computador) utilizado na Engenharia para fazer análise geoespacial, identificar a melhor localização para projetos, definir traçado, localizar pontos de estudos, realizar cálculos dinâmicos de trabalhos de terraplanagem, otimizar a utilização de materiais, bem como visualizar em 3D para melhor compreender os impactos do projeto no meio ambiente. Nesta tese, este aplicativo foi utilizado para espacialização dos pontos geotécnicos que não estavam georreferenciados.

#### **5.4.3 Microsoft Excel**

O MS-Excel 2007® é um aplicativo desenvolvido pela Microsoft® para elaboração de planilhas eletrônicas que possui recursos para cálculo de funções matemáticas básicas e avançadas, bem como cálculos financeiros e estatísticos. Nesta proposta metodológica, ele foi utilizado para montar a base de dados para a modelagem, processamento dos ensaios, fazer o pré-processamento dos dados para a modelagem, esta última é uma etapa fundamental que precede o desenvolvimento do modelo neural, além da análise dos dados após a saída das redes neurais adotadas, bem como para implementação do modelo neural de melhor desempenho.

#### 5.4.4 IBM SPSS

O SPSS é um aplicativo desenvolvido pela IBM versão 22 *Trial* apropriado para elaboração de análise estatística de matrizes de dados. O seu uso permite gerar relatórios tabulados, gráficos e dispersões de distribuições utilizadas na realização de análises descritivas e de correlação entre variáveis. Nesta pesquisa, ele foi utilizado para realizar estatística descritiva das variáveis, bem como criar modelos de regressão para prever o módulo de resiliência, ainda foi utilizado o *toolbox* de redes neurais artificiais para criar modelos neurais mais simples do problema em estudo.

#### 5.4.5 MATLAB

O MATLAB (*MATrix LABoratory*) 2014 desenvolvido pela *Mathworks* disponível no GTTEMA (Grupo de Trânsito, Transporte e Meio Ambiente) é um *software* interativo de alto desempenho voltado para o cálculo numérico e matemático. O MATLAB é capaz de integrar análise numérica, cálculo com matrizes, processamento de sinais e construção de gráficos em um ambiente fácil de usar, onde problemas e soluções são expressos somente como eles são escritos matematicamente, ao contrário da programação tradicional.

O aplicativo computacional MATLAB foi utilizado para o treinamento das RNA proposta neste trabalho, sendo escolhido por possuir uma interface gráfica de treinamento de redes neurais. Essa interface deixa transparecer também seu código fonte, o que permite a implementação de outros recursos nessa mesma ferramenta. Esse aplicativo suporta os mais diversos tipos de algoritmos de treinamento de redes neurais, permitindo que se possa executar uma extensa árvore de testes na tentativa de definir o modelo neural mais adequado.

#### 5.4.6 CAP3D

O CAP3D (*Computational Analysis of Pavements – 3D*) é um programa para análise numérica baseado no Método dos Elementos Finitos (MEF) e está sendo desenvolvido utilizando a técnica de Programação Orientada a Objetos (POO) que permite ao sistema ser expandido com maior facilidade. O CAP3D está sendo desenvolvido no LMP/UFC, com intuito de subsidiar os métodos empírico-mecanísticos de dimensionamentos de pavimentos.

## 5.5 Metodologia Adotada

A metodologia proposta para elaboração desta investigação está descrita nos tópicos seguintes, e contemplará as seguintes etapas: revisão da literatura, pesquisa e aquisição de dados, definição da área de estudo, definição do esforço amostral (escolha dos pontos de coleta de solos georreferenciados), execução do programa experimental (ensaios de laboratório), construção do banco de dados georreferenciado, pré-processamento dos dados, tratamento de dados, modelagem preditiva do MR, construção e disponibilização do gerador de estimativas MR. A Figura 5.3 é um fluxograma que resume o método utilizado.

Figura 5.3 – Fluxograma do Método Proposto.



Fonte: O autor.

### **5.5.1 Revisão da Literatura**

Nesta etapa, foram realizadas pesquisas sobre modelagem geotécnica, RNA, Geotecnia aplicada à pavimentação, modelos de predição do MR, sendo as principais fontes: artigos, livros, periódicos, trabalhos acadêmicos, dentre outros meios. Essa revisão visou suprir as necessidades de aprofundamento teórico, bem como conhecer o estado da arte e o estado da prática dos estudos de módulo de resiliência aplicados à pavimentação e procurou, também, responder algumas questões de pesquisa.

### **5.5.2 Pesquisa e Aquisição de Dados**

Essa etapa teve a finalidade de obtenção dos dados possíveis (resultados dos ensaios de granulometria por peneiramento, limite de liquidez, limite de plasticidade, compactação, CBR e Triaxial de Carga Repetida) para subsidiarem o trabalho através da diminuição do esforço amostral de laboratório e criar banco de dados de informações existentes para área de estudo. Realizou-se uma pesquisa para identificar quais trabalhos tinham tais informações. Nesses trabalhos, pôde-se extrair parte das informações, os dados complementares com detalhes de obtenção foram conseguidos diretamente com os pesquisadores que desenvolveram essas pesquisas.

### **5.5.3 Definição do Esforço Amostral**

Após a definição da área de estudo foi consultada na literatura a quantidade de amostras utilizadas nos trabalhos que também previram o MR, também foram realizadas novamente análises espaciais para definir a quantidade de pontos amostrados, bem como sua espacialização, necessárias para trazer uma maior representatividade da área como um todo. No Brasil, foram encontrados dois trabalhos que modelaram o MR, sendo um com 76 amostras (VIANA, 2007) apenas para solos lateríticos do estado de São Paulo e 463 amostras (FERREIRA, 2008) de materiais de todo o Brasil e América Latina de diversas procedências (solos estabilizados granulometricamente, solos estabilizados quimicamente e britas).

Encontrou-se ainda, trabalhos que estudaram solos da RMF para fins de pavimentação com 60 amostras (BARROSO, 2002) e 11 amostras (CHAVES, 2000). Dessa forma, e devido à limitação de tempo e recursos definiu-se, que o banco de dados geotécnico poderia ter entre 80 e 100 amostras para predição do MR, ou uma quantidade de amostras na

qual os níveis de incerteza da predição fosse tanto quanto menor, sendo medido pelo MSE e pelo coeficiente de correlação entre o modelado e o ensaiado.

#### ***5.5.4 Execução do Programa Experimental***

O programa experimental foi executado com a realização dos seguintes ensaios para composição do banco de dados para modelagem do ensaio de módulo de resiliência:

- NBR-7181 – Análise Granulométrica de Solos;
- NBR 7182 – Ensaio de Compactação;
- NBR-7180 – Limite de Plasticidade;
- NBR-6459 – Limite de Liquidez;
- NBR-9895/89 – Determinação do CBR;
- DNIT134/2010ME- Determinação do módulo de resiliência.

Conforme o programa experimental foi avançando, o banco de dados geotécnico foi sendo aumentado, de forma a garantir uma maior representatividade dos solos da região em estudo e uma modelagem mais precisa do fenômeno em estudo.

Escolheram-se esses ensaios para compor o banco de dados geotécnico devido aos órgãos rodoviários estaduais e federais do Brasil especificarem esses ensaios como caracterização básica. Assim, o modelo aqui desenvolvido pode ser utilizado para regiões onde já existam estudos geotécnicos para rodovias implantadas e em processo de implantação e, a partir desses dados, pode-se prever os módulos de resiliência dos solos.

#### ***5.5.5 Construção do Banco de Dados Georreferenciado***

Com os dados adquiridos e com o avanço do Programa Experimental, os resultados dos ensaios foram sendo organizados em um banco de dados georreferenciado. Utilizou-se Coordenadas Este e Norte, em projeção cartográfica UTM e o Sistema de Referência SIRGAS 2000, Fuso 24 Sul. Assim, foi atribuído um caráter espacial aos dados dos ensaios já descritos. O banco de dados implementado é composto pelas variáveis apresentadas na Tabela 5.1.



Tabela 5.1 – Variáveis do banco de dados.

Variável	Descrição
OT (%)	Umidade Ótima de Compactação
DEN (g/cm <sup>3</sup> )	Massa Específica Seca Máxima
CBR (%)	<i>California Bearing Ratio</i>
EXP (%)	Expansão
LL (%)	Limite de Liquidez
IP (%)	Índice de Plasticidade
#P25,4	% de material que passa na Peneira 1"
#P9,5	% de material que passa na Peneira 3/8"
#P4,76	% de material que passa na Peneira Nº 4
#P 2	% de material que passa na Peneira Nº 10
#P0,42	% de material que passa na Peneira Nº 40
#P0,074	% de material que passa na Peneira Nº 200
Class	Classificação da AASTHO
$\sigma_3$	Tensão Confinante
$\sigma_d$	Tensão Desvio
MR	Módulo de Resiliência
Er	Deformação Específica Resiliente Recuperável

Fonte: O autor.

### 5.5.6 Pré-processamento dos Dados

Nesta etapa, os dados oriundos dos ensaios geotécnicos foram submetidos a um pré-processamento com a finalidade de se adequarem às restrições impostas pela modelagem neural. Tal procedimento foi dividido em duas etapas:

- **numerização dos dados:** consistiu em se atribuir um valor decimal aos dados que possuem valores alfanuméricos (variáveis qualitativas) oriundos de ensaios geotécnicos como, por exemplo: o Índice de Plasticidade (IP), o Limite de Liquidez (LL) e a Classificação da AASHTO. A Tabela 5.2 apresenta um exemplo de numerização dos dados alfanuméricos.

Tabela 5.2– Exemplo de numerização dos dados alfanuméricos.

Variável	Dados Alfanuméricos	Numerizado
LL	NP	0
IP	NP	0
Classificação da AASTHO	A-2-4	2,4

Fonte: O autor.

- **normalização dos dados:** esta operação transforma os valores decimais em valores limitantes de uma função, neste caso, compreendidos entre -1 e 1. Para isso, foi utilizada a expressão de normalização mostrada na Equação 5.1. Na Tabela 5.3, pode-se verificar um exemplo de normalização dos dados com todos os resultados dos ensaios em valores decimais e em valores normalizados.

$$X_n = 2 \frac{X_i (X_i - X_{\max})}{(X_{\max} - X_{\min})} - 1 \quad (5.1)$$

onde:

$X_n$  = Valor normalizado;

$X_i$  = Valor decimal;

$X_{\max}$  = Maior valor da variável;

$X_{\min}$  = Menor valor da variável.

Tabela 5.3– Exemplo de normalização dos dados com valores decimais (continua)

Variável	Valor Decimal	Valor Normalizado
OT (%)	8	-0,296875
DEN (g/cm <sup>3</sup> )	2,16	0,944444444
CBR (%)	73	-0,627949183
EXP (%)	0	0
LL (%)	0	0
IP (%)	0	0

Tabela 5.3– Exemplo de normalização dos dados com valores decimais (continuação)

Variável	Valor Decimal	Valor Normalizado
25,4	88	0,4
9,5	57	-0,283333333
4,76	53	0,397435897
2	49	0,37804878
0,42	26	-0,16
0,074	8	-0,045454545
Class	1,1	0
$\sigma_3$	0,021	0,021
$\sigma_d$	0,021	0,021
MR	1265	0,611153481
Er	1,66008E-05	0,56012301

Fonte: O autor.

### 5.5.7 Tratamento de Dados

Nesta etapa, foi realizada uma descrição dos dados por meio de análise estatística descritiva, através da qual buscou-se definir as correlações das variáveis explicadas com as explicativas (elementos do banco de dados georreferenciado). Tal procedimento visou filtrar as variáveis, isoladas ou em conjunto que têm um maior poder explicativo e que deveriam ser usadas para a geração de estimativas do Módulo de Resiliência e da deformação resiliente específica recuperável dos solos na área estudada.

Em adição, criaram-se modelos de regressão das variáveis explicativas com o módulo de resiliência e com a deformação resiliente específica recuperável, a fim de avaliar o poder de predição da regressão para os dados disponíveis.

### 5.5.8 Previsão do Módulo de Resiliência

Os resultados dos ensaios de MR foram estimados por meio da técnica de Redes Neurais Artificiais. Nesta etapa, testaram-se diversas topologias com o objetivo de prever o módulo de resiliência e a deformação resiliente específica recuperável.

O desenvolvimento de um modelo neural consiste em treinar, validar e testar diversas topologias até que se encontre o modelo de melhor ajuste. Para isso, utilizou-se um módulo de ferramentas denominado *Toolboxes* e, dentro dele, mais especificamente o *Neural*

*Network Tool* ou simplesmente NNTOOL. Esse último é uma interface gráfica que possibilita a construção de diferentes topologias, com variações de algoritmos e parâmetros de treinamento de RNA no aplicativo MATLAB.

Assim, foi elaborada uma árvore de testes, que consiste em desenvolver uma bateria de testes no NNTOOL buscando encontrar uma arquitetura mais adequada para o problema em questão, ou seja, aquela na qual os erros das saídas estimadas, para o conjunto de testes, sejam menores quando comparados aos valores reais. Esta ferramenta tem sido empregada em diversos trabalhos que utilizaram modelagem através de RNA. Da Silva (2003) destaca a grande flexibilidade na manipulação e formatação de arquivos e diversidade de algoritmos implementados eficientemente como alguns dos pontos positivos que o levaram a eleger essa ferramenta na modelagem neural realizada em seu trabalho.

Os parâmetros envolvidos em um algoritmo de RNA permitem uma grande variação nas possibilidades de treinamento. Por esse motivo, torna-se quase inviável testar todas as possibilidades com variações diferentes nos parâmetros. Para este trabalho, foi realizado um conjunto de variações até que se chegou aos parâmetros que melhor se adaptaram aos dados, ou seja, os parâmetros que possibilitaram uma taxa de acerto maior.

Os dados utilizados para realizar o treinamento dos modelos, desenvolvidos aqui, foram divididos em três conjuntos, sendo 60% utilizados para treinamento, 20% para validação, necessária para implementação da regra de parada do algoritmo de aprendizagem, e 20% para teste. Esses conjuntos de dados foram selecionados randomicamente sem repetição. Inicialmente os dados de entrada das RNA foram os dados do banco de dados completo, sendo: Umidade Ótima de Compactação, Massa Específica Seca Máxima, CBR, Expansão, Limite de Liquidez, Índice de Plasticidade, % de material que passa nas peneiras (1", 3/8", N° 4, N° 10, N° 40 e N° 200), Classificação da AASHTO, Tensão Confinante e Tensão Desvio. Já os dados de saída da rede são separadamente: Módulo de Resiliência e a Deformação Específica Resiliente Recuperável.

Ao longo da pesquisa variaram-se os dados de entrada (variáveis explicativas) da RNA, em busca do modelo com a menor quantidade de variáveis de entrada e com menor custo de processamento, mas que não interferisse no desempenho da previsão do MR. Esses testes foram realizados para se chegar a um modelo mais simples e com variáveis de fácil obtenção.

Após a definição dos conjuntos de dados, deu-se início ao treinamento das RNA, com a finalidade de se encontrar a(s) melhor(es) topologia(s) que se ajustassem aos fenômenos modelados. Para isto, foram testados diversos algoritmos, realizou-se ainda a

variação de seus parâmetros (número de camadas intermediárias, quantidade de neurônios em cada camada, taxa de aprendizagem, termo momentum, número de épocas de treinamento e outros).

O algoritmo selecionado para iniciar os testes foi o *Levenberg-Marquardt* (TRAINLM). Esse algoritmo é uma das formas modificadas do algoritmo *Error backpropagation*. A escolha inicial desse algoritmo deu-se em função das recomendações contidas em Beale *et al.*, (2010).

O TRAINLM é uma função que atualiza os pesos e valores dos bias de acordo com sua otimização. Frequentemente é considerado como o mais rápido dos algoritmos de treinamento retropropagação do erro, porém requer mais memória computacional do que os outros algoritmos.

Beale *et al.* (2010) sugeriram seu uso por ser um algoritmo de treinamento rápido quando se tem um conjunto de treinamento de tamanho não muito grande e por apresentar bons resultados de generalização para a maioria dos casos.

Apesar de outros algoritmos, como por exemplo, o algoritmo de gradiente descendente *Error backpropagation* com *momentum* e taxa de aprendizagem adaptativa (TRAINGDX) terem sido testados, foi confirmada a eficiência do algoritmo *Levenberg-Marquardt*, (TRAINLM), onde os melhores resultados para predição do Módulo de Resiliência e da Deformação Específica Resiliente Recuperável foi obtido através desse algoritmo.

Os resultados obtidos, a partir do modelo neural foram analisados através do cálculo do MSE (*Mean of Squared Error*) ou (Quadrado Médio dos Erros), bem como através de testes estatísticos de correlação que verificaram e compararam os valores estimados pela RNA e os valores reais obtidos em ensaios. Esses testes foram realizados para atestar a precisão dos modelos geotécnicos neurais produzidos.

### **5.5.9 Disponibilização do Gerador de Estimativas MR**

Na última etapa desenvolveu-se um aplicativo em linguagem *web* (*Javascript*) e uma planilha eletrônica, com os pesos sinápticos extraídos do modelo gerado pela RNA que melhor se adaptou ao fenômeno modelado. Ou seja, é capaz de gerar estimativas dos modelos de predição do módulo de resiliência com a mesma precisão do modelo gerado pelo NNTOOL. Isso foi feito para tornar os modelos produzidos utilizáveis e permitir o uso do MR

de forma facilitada, mesmo se os usuários não tiverem conhecimento ou entendimento acerca do processo de modelagem.

Para tanto, os pesos sinápticos do modelo de predição desenvolvido (treinamento, validação e teste) no MATLAB foram exportados, com a finalidade de que fossem usados para calcular o MR, de forma simples e rápida, bastando para isso que o usuário apresente ao modelo as variáveis explicativas do local em questão.

Essa etapa é essencial para que o modelo gerado seja posteriormente incorporado ao novo método de dimensionamento empírico-mecanístico de pavimentos para o estado do Ceará. Dessa forma, é possível se prever os valores dos módulos de resiliência dos solos dentro do estado, quando não houver condições para realização do ensaio triaxial de carga repetida.

#### ***5.5.10 Considerações Finais***

A metodologia apresentada neste capítulo foi aplicada para a criação de modelos de predição dos valores do ensaio de módulo de resiliência de solos potencialmente utilizáveis, tanto como subleito e quanto em camadas dos pavimentos de rodovias (reforço, base e sub-base). Os MR assim estimados poderão servir de insumos em alguns níveis do método de dimensionamento empírico-mecanístico de pavimentos flexíveis na Região Metropolitana de Fortaleza (RMF) e nos municípios adjacentes.

## CAPÍTULO 6

### APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

#### 6.1 Considerações Iniciais

Este capítulo apresenta os resultados e discussões da geração de modelos de predição dos ensaios de MR de solos, a partir de características geotécnicas de fácil obtenção e já consagradas na área rodoviária, técnicas estatísticas e RNA. Para tanto, são apresentados e discutidos os resultados obtidos durante a etapa de tratamento e descrição dos dados utilizados e a modelagem dos valores obtidos no ensaio de módulo de resiliência, bem como os desempenhos de cada modelo, usando indicadores estatísticos.

#### 6.2 Análise dos Dados

Os dados utilizados para geração dos modelos de predição dos resultados dos ensaios de módulo de resiliência foram adquiridos tanto em trabalhos acadêmicos que estudaram o MR de solos naturais da área de estudo, quanto obtidos através da realização de ensaios triaxiais de cargas repetidas e ensaios de caracterização geotécnica básica durante a realização desta pesquisa.

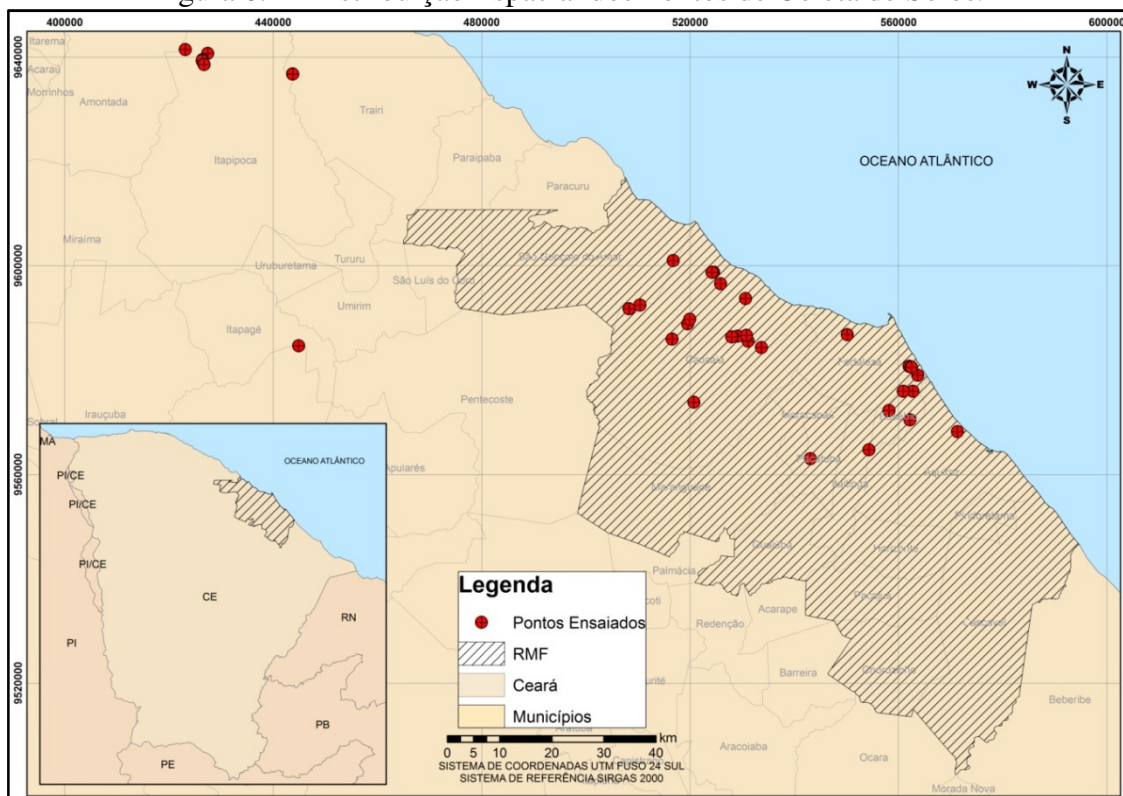
Desta forma, criou-se um banco de dados com 85 amostras de solos naturais da área de estudo, perfazendo um total de 1.341 padrões de valores de módulo de resiliência e da deformação resiliente recuperável. Decidiu-se trabalhar com a previsão dos valores oriundos do próprio ensaio de MR e não as constantes dos modelos de regressão baseadas nas tensões atuantes durante o ensaio. Isso foi necessário para maximizar o número de padrões, pois para cada amostra de solo é possível extrair até 18 valores de MR, o qual varia com o par de tensão atuante no solo.

O banco de dados foi criado com 17 variáveis, sendo 15 variáveis preditoras e 2 variáveis preditas. Conforme informado no capítulo anterior, as variáveis usadas como explicativas foram: umidade ótima de compactação (OT), massa específica seca máxima (DEN), CBR, expansão (EXP), limite de liquidez (LL), índice de plasticidade (IP), percentual que passa nas peneiras (25,4 mm, 9,5 mm, 4,76 mm, 2 mm, 0,42 mm, 0,074 mm), classificação da AASHTO, tensão confinante ( $\sigma_3$ ) e tensão desvio ( $\sigma_d$ ). Já as variáveis

explicadas foram: o valor do módulo de resiliência (MR) e valor da deformação resiliente recuperável ( $\epsilon_r$ ).

Com isso, nesta seção foi realizada uma análise exploratória do banco de dados através da estatística descritiva e uma análise de correlação das variáveis e, finalmente serão apresentados histogramas para descrever a composição e ocorrências de cada variável do banco de dados. A Figura 6.1 é um mapa de distribuição espacial dos pontos de coleta dos solos estudados na RMF e áreas adjacentes. É importante destacar que a visualização dos 85 pontos no mapa fica difícil devido à escala de apresentação dos dados ser muito pequena, havendo assim sobreposição espacial de alguns pontos nesta visualização.

Figura 6.1– Distribuição Espacial dos Pontos de Coleta de Solos.



Fonte: O autor.

### 6.2.1 Análise Descritiva dos Dados

Na fase inicial da pesquisa, trabalhou-se com três variantes na composição do banco de dados: o banco completo, o banco apenas com amostras de comportamento coesivo e o banco apenas com amostras granulares. Isso foi feito devido aos valores das variáveis: expansão (EXP), limite de liquidez (LL) e índice de plasticidade (IP) das amostras granulares



terem sido iguais a zero, não possuindo, assim, variações que permitissem diferenciação dos padrões, que é uma condição necessária para previsão dos valores do ensaio de MR para esses solos. No entanto, os resultados iniciais indicaram que o banco de dados completo era mais eficiente nas previsões. Motivo pelo qual, a investigação prosseguiu utilizando o banco de dados completo, contendo 1.341 padrões de valores do Módulo de Resiliência.

Quanto às variáveis, inicialmente trabalhou-se com todas as 15 variáveis explicativas para previsão do MR. Na sequência, procedeu-se com a tentativa de se reduzir gradativamente a quantidade de variáveis de entrada e, assim, melhorar o modelo com o refinamento da topologia. No entanto, para a descrição e análise estatística serão apresentados os resultados do banco de dados completo, sem a preocupação de selecionar apenas as variáveis escolhidas para compor o modelo final adotado.

A Tabela 6.1 evidencia a estatística descritiva do conjunto de dados utilizados (1341 padrões). A partir dessa tabela foi possível extrair informações de dispersão e medida central dos dados, de forma a conhecer melhor cada variável.

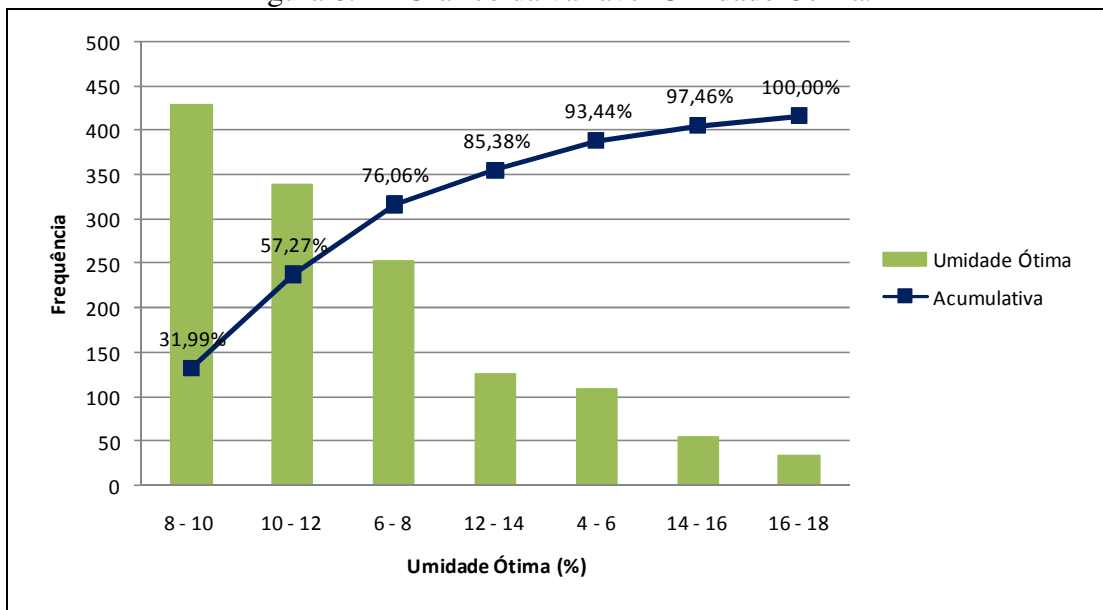
Tabela 6.1 – Estatística descritiva dos dados.

Medida	Média	Mediana	Moda	Desvio padrão	Variância da amostra	Amplitude
<b>OT (%)</b>	9,33119	9,20000	7,70000	2,57559	6,63366	12,80000
<b>DEN (g/cm<sup>3</sup>)</b>	2,00214	2,01000	2,07000	0,12515	0,01566	0,54000
<b>CBR (%)</b>	38,04160	32,00000	11,00000	28,05558	787,11533	110,20000
<b>EXP (%)</b>	0,09508	0,00000	0,00000	0,19186	0,03681	0,80000
<b>LL (%)</b>	12,75883	16,00000	0,00000	13,07834	171,04308	46,00000
<b>IP (%)</b>	3,87683	3,00000	0,00000	4,35132	18,93395	14,00000
<b>25,4</b>	93,99828	97,00000	100,00000	7,42201	55,08620	20,00000
<b>9,5</b>	78,41602	79,00000	100,00000	21,82596	476,37247	60,00000
<b>4,76</b>	72,40410	74,00000	100,00000	27,57781	760,53548	78,00000
<b>2</b>	68,49450	68,00000	98,00000	28,68131	822,61726	82,00000
<b>0,42</b>	52,37482	54,00000	20,00000	25,95117	673,46301	75,00000
<b>0,074</b>	20,95727	13,00000	13,00000	15,81619	250,15201	66,00000
<b><math>\sigma_3</math></b>	0,06893	0,05100	0,05100	0,03988	0,00159	0,11600
<b><math>\sigma_d</math></b>	0,13738	0,10300	0,10300	0,10197	0,01040	0,39100
<b>Class</b>	2,55883	2,40000	2,40000	1,44877	2,09892	6,40000
<b>MR</b>	542,37633	509,00000	635,00000	372,90575	139058,70059	1987,93087
<b>Er</b>	0,00044	0,00026	0,00027	0,00049	0,00000	0,00306

Fonte: O autor.

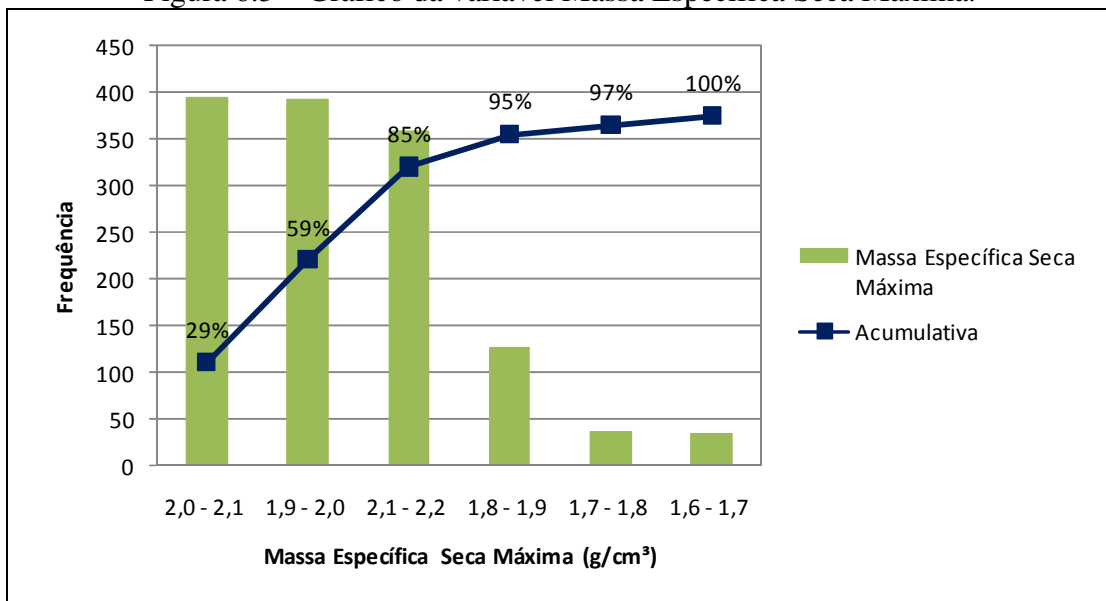
Como o banco de dados tem um tamanho relativamente grande, decidiu-se apresentar os dados, de forma indireta, por meio de gráficos de cada variável dos 1.341 padrões, conforme ilustrados da Figura 6.2 até a Figura 6.16. A partir da elaboração desses gráficos, pode-se perceber a dimensão, quantidade e variações de cada variável dentro do banco de dados. Não foram criados gráficos das variáveis tensão desvio e tensão confinante, pois as mesmas já são conhecidas, tendo seus valores especificados segundo DNIT-134/2010 – ME.

Figura 6.2 – Gráfico da variável Umidade Ótima.




Fonte: O autor.

Figura 6.3 – Gráfico da variável Massa Específica Seca Máxima.




Fonte: O autor.

Figura 6.4 – Gráfico da variável CBR.



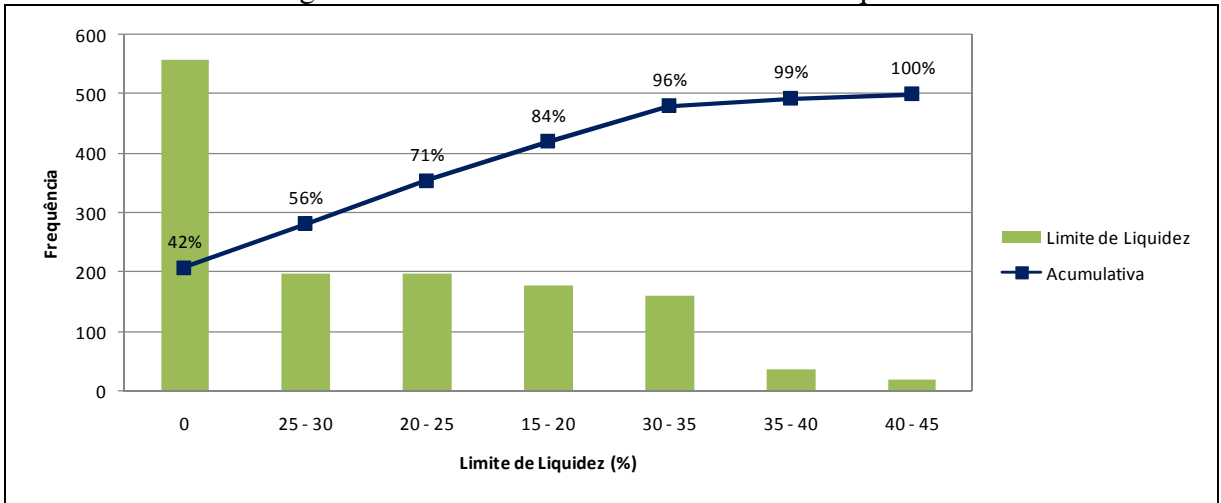
Fonte: O autor.

Figura 6.5 – Gráfico da variável Expansão.



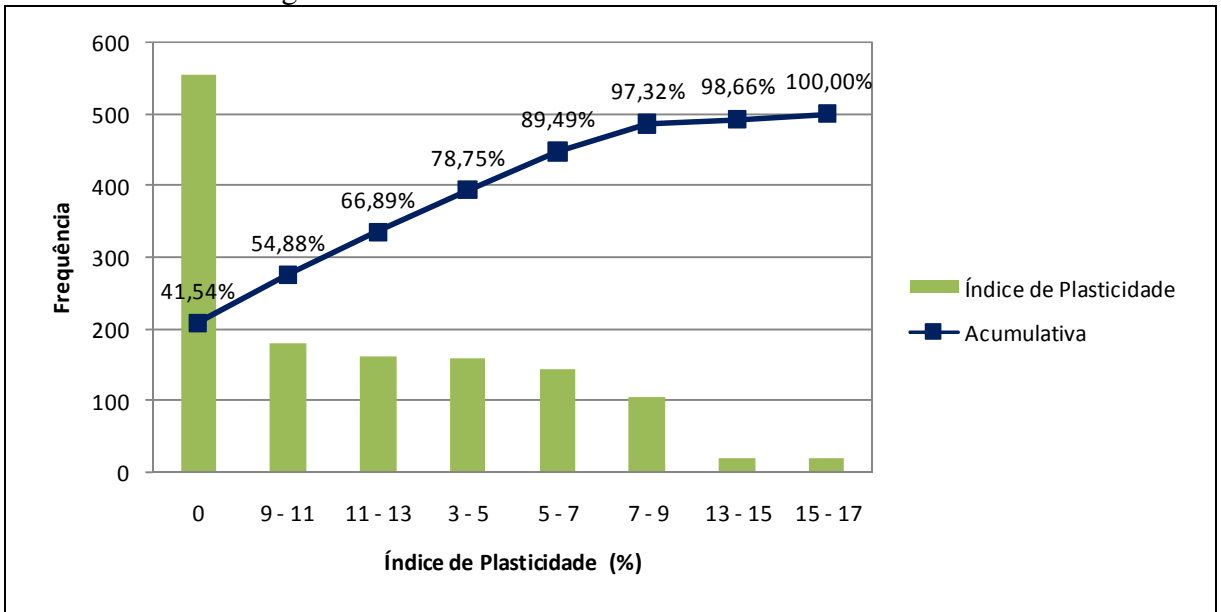
Fonte: O autor.

Figura 6.6 – Gráfico da variável Limite de Liquidez.




Fonte: O autor.

Figura 6.7 – Gráfico da variável Índice de Plasticidade.




Fonte: O autor.

Figura 6.8 – Gráfico do percentual que passa na peneira 25,4 mm.




Fonte: O autor.

Figura 6.9 – Gráfico do percentual que passa na peneira 9,5 mm.




Fonte: O autor.

Figura 6.10 – Gráfico do percentual que passa na peneira 4,76 mm.



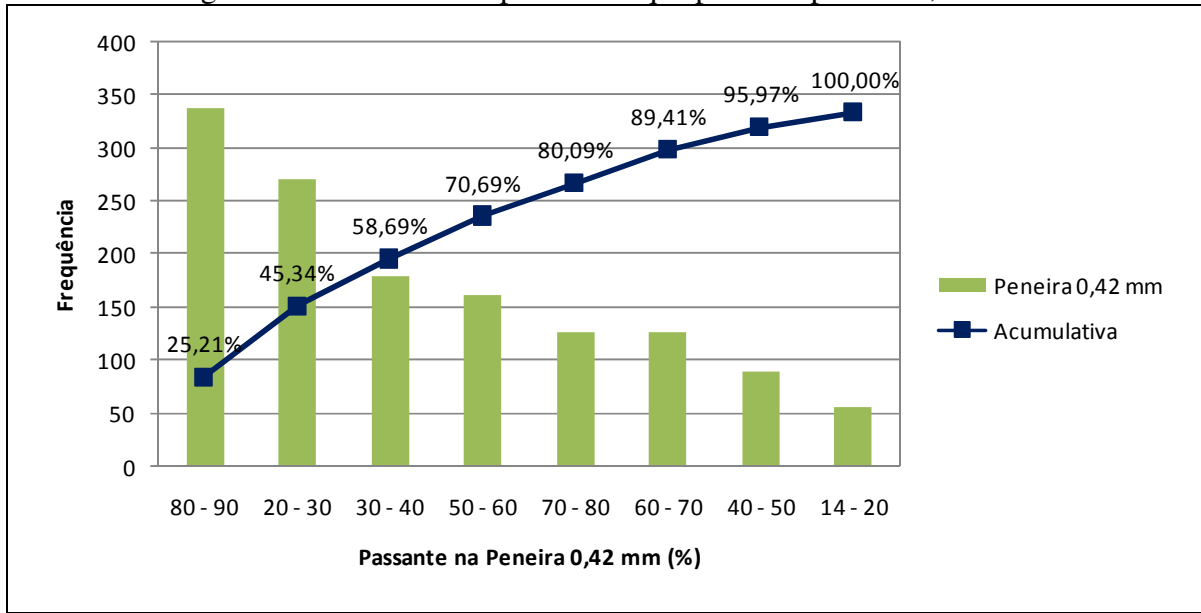
Fonte: O autor.

Figura 6.11 – Gráfico do percentual que passa na peneira 2,00 mm.



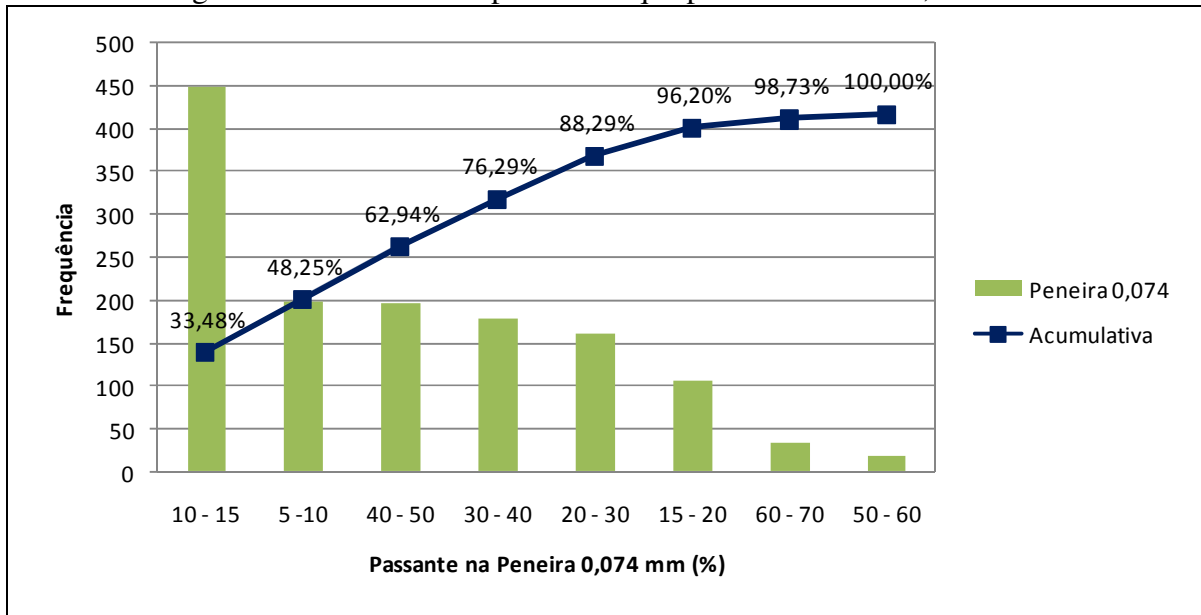
Fonte: O autor.

Figura 6.12 – Gráfico do percentual que passa na peneira 0,42 mm.



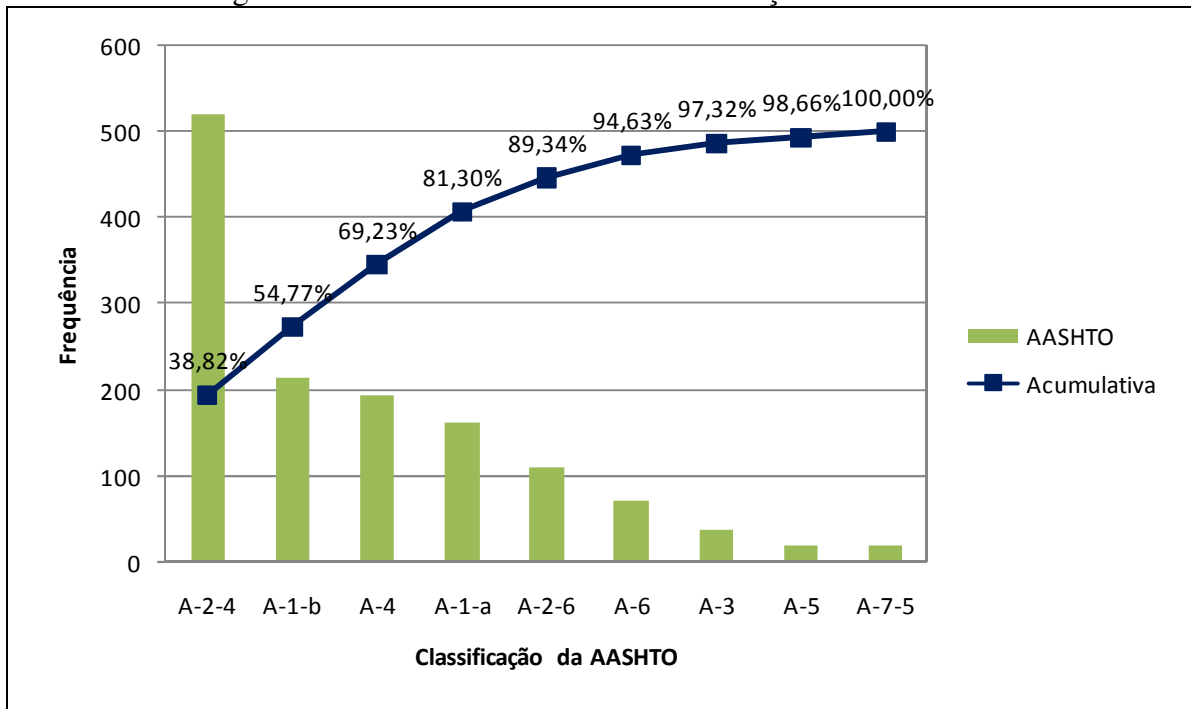
Fonte: O autor.

Figura 6.13 – Gráfico do percentual que passa na Peneira 0,074 mm.




Fonte: O autor.

Figura 6.14 – Gráfico da variável Classificação da AASTHO.



Fonte: O autor.


Figura 6.15 – Gráfico da variável Módulo de Resiliência.



Fonte: O autor.



Figura 6.16 – Gráfico da variável Deformação Específica Resiliente Recuperável.



Fonte: O autor.

Observando-se os gráficos e tabelas da estatística descritiva de cada variável é possível realizar algumas análises básicas acerca do banco de dados usado nesta tese:

- percebe-se que o banco de dados geotécnico tem uma boa representatividade do ponto de vista quantitativo e qualitativo;
- dentre as variáveis, o MR tem os maiores valores e a maior amplitude de variação. Já os menores valores e a menor amplitude são da deformação resiliente recuperável, isso ocorre devido ao fato de que essas variáveis são inversamente proporcionais;
- para as variáveis limite de liquidez, índice de plasticidade e expansão, percebe-se que em torno da metade dos dados os valores são iguais a zero, isso ocorre devido à metade dos dados serem de solos arenosos;
- os dados de CBR possuem alguns valores altos, porém com predominância de valores mais baixos, valores esses que expressam materiais não indicados a comporem as camadas estruturais dos pavimento;
- cerca de 80% dos valores de módulo de resiliência estão abaixo de 1.200 MPa, e em torno de 20% estão entre 1.200 e 2.000 MPa; esse fato pode refletir em maiores erros na predição de MR mais elevados. Os valores de MR considerados mais altos no banco de dados, provavelmente são oriundos de solos granulares do tipo A-1-a, os quais têm essa característica.

### ***6.2.2 Relações Estatísticas entre as Variáveis***

Conforme já informado anteriormente, para a criação dos modelos de predição das características mecânica dos solos (MR e  $\epsilon_r$ ), na RMF e áreas adjacentes, foram selecionadas as variáveis preditoras (OT, DEN, CBR, EXP, LL, IP, % que passa em cada peneira de análise, Class, tensão confinante e tensão desvio).

De forma a se analisar o nível de correlação entre as variáveis de entrada e saída consideradas nos modelos estudados, procedeu-se à elaboração da matriz de correlações apresentada na Tabela 6.2

A análise de correlação foi utilizada para relacionar de forma individual e/ou múltipla as variáveis preditoras com os resultados dos ensaios de módulo de resiliência do banco de dados. A partir dos resultados obtidos, podem-se inferir quais variáveis possuem relação direta e se podem contribuir com a predição do MR por meio da modelagem proposta.

Tabela 6.2 – Matriz de Correlação entre as variáveis do banco de dados.

	<b>OT (%)</b>	<b>DEN (g/cm<sup>3</sup>)</b>	<b>CBR (%)</b>	<b>EXP (%)</b>	<b>LL (%)</b>	<b>IP (%)</b>	<b>25,4</b>	<b>9,5</b>	<b>4,76</b>	<b>2</b>	<b>0,42</b>	<b>0,074</b>	<b>σ<sub>3</sub></b>	<b>σ<sub>d</sub></b>	<b>MR</b>	<b>ε<sub>r</sub></b>	<b>Class</b>
<b>OT (%)</b>	1,0000																
<b>DEN (g/cm<sup>3</sup>)</b>	-0,2438	1,0000															
<b>CBR (%)</b>	-0,1974	0,7031	1,0000														
<b>EXP (%)</b>	0,2170	0,0748	-0,2146	1,0000													
<b>LL (%)</b>	0,6853	-0,2174	-0,3406	0,4481	1,0000												
<b>IP (%)</b>	0,6969	-0,2178	-0,3044	0,3805	0,9308	1,0000											
<b>25,4</b>	0,0964	-0,6139	-0,5596	-0,1364	0,0419	0,0344	1,0000										
<b>9,5</b>	-0,0840	-0,7080	-0,6822	-0,0584	0,0362	0,1166	0,7593	1,0000									
<b>4,76</b>	-0,1408	-0,6728	-0,6399	-0,1207	0,0473	0,1373	0,7075	0,9856	1,0000								
<b>2</b>	-0,1599	-0,6763	-0,6253	-0,1469	0,0635	0,1404	0,7017	0,9738	0,9947	1,0000							
<b>0,42</b>	-0,0814	-0,7470	-0,7198	-0,1072	0,0105	0,0582	0,7030	0,9497	0,9559	0,9645	1,0000						
<b>0,074</b>	0,5544	-0,5975	-0,5894	0,0880	0,5388	0,4537	0,4515	0,5936	0,5832	0,5590	0,5981	1,0000					
<b>σ<sub>3</sub></b>	-0,0147	0,0119	0,0107	0,0021	0,0050	0,0070	0,0115	0,0095	0,0087	0,0082	0,0093	0,0174	1,0000				
<b>σ<sub>d</sub></b>	-0,0224	0,0176	0,0156	0,0030	0,0086	0,0108	0,0156	0,0142	0,0131	0,0122	0,0138	0,0269	0,7711	1,0000			
<b>MR</b>	<b>0,1197</b>	<b>0,5680</b>	<b>0,6113</b>	<b>0,0794</b>	<b>0,1145</b>	<b>0,1642</b>	<b>0,6015</b>	<b>0,7598</b>	<b>0,7494</b>	<b>0,7353</b>	<b>0,7531</b>	<b>0,4892</b>	<b>0,2341</b>	<b>0,1286</b>	<b>1,0000</b>		
<b>ε<sub>r</sub></b>	<b>-0,2038</b>	<b>-0,3512</b>	<b>-0,4604</b>	<b>0,0213</b>	<b>0,1174</b>	<b>0,1392</b>	<b>0,4020</b>	<b>0,4893</b>	<b>0,4813</b>	<b>0,4788</b>	<b>0,5108</b>	<b>0,2217</b>	<b>0,3443</b>	<b>0,5132</b>	<b>0,5608</b>	<b>1,0000</b>	
<b>Class</b>	0,4833	-0,6955	-0,6982	0,1559	0,5847	0,6171	0,5259	0,5303	0,4923	0,4821	0,5486	0,7751	0,0118	0,0171	<b>0,4352</b>	<b>0,2526</b>	1,0000

Fonte: O autor.

Os resultados dos testes de correlação entre todas as variáveis dos ensaios geotécnicos de interesse à pavimentação, reportados na Tabela 6.2 revelam que tais variáveis têm valores de correlação, segundo a estatística, considerados bons, explicando assim os diversos modelos lineares e polinomiais gerados entre esses parâmetros, mostrados nos Capítulos 3 e 4 desta tese.

Percebe-se que os valores de correlação das variáveis explicativas com o MR e com o  $\epsilon_r$  variaram, porém os valores das relações são considerados bons para quase todas as variáveis, exceto o LL, IP e EXP, isso ocorre devido à metade dos valores dessas variáveis serem iguais a zero, impossibilitando assim diferenciação entre estas variáveis.

Haykin (2001) ressalta que valores de correlação negativa ou positiva entre as variáveis preditoras e preditas superiores a 0,30 aumentam a chance do modelo neural ser mais eficiente para tais dados. Esse autor indica ainda que uma rede neural será melhor treinada com variáveis que tenham correlação pelo menos igual a 0,30 ou -0,30, porém o pesquisador recomenda que não se descartem dados que tenham correlações inferiores a esses valores sem antes serem testadas em um modelo neural. Haykin (2001) afirma que é importante fazer uma análise de correlação antes de iniciar a modelagem neural para conhecimento prévio das relações entre as variáveis que se pretende trabalhar.

Com isso, pode-se afirmar que, para o banco de dados completo, as variáveis umidade ótima, LL, IP, EXP e as tensões dos ensaios triaxial poderiam não fazer parte do modelo neural. Porém, seguindo recomendação de Haykin (2001), todas as variáveis do banco de dados foram mantidas na modelagem e apenas serão descartadas após a modelagem neural, sendo adotadas como preditoras, as variáveis usadas no modelo que apresentar a melhor medida de desempenho. Para a modelagem neural, decidiu-se utilizar todas as variáveis explicativas como parâmetros de entrada dos modelos, mesmo aquelas que não atingiram o coeficiente de correlação de pelo menos 0,30.

### **6.3 Modelos de Regressão Linear**

Antes de realizar a modelagem neural, buscou-se utilizar uma técnica de inferência mais simples para a predição dos valores do ensaio de módulo de resiliência. Motivo pelo qual optou-se pelo uso da técnica de regressão linear para gerar modelos lineares de predição dos valores de MR e de  $\epsilon_r$ .

Como na área rodoviária é comum se relacionar os resultados dos ensaios geotécnicos com a Classificação AASHTO de solos, bem como seguindo-se o que foi feito no

MEPDG da AASTHO (2008), nesta pesquisa, criou-se um modelo linear geral para uma única variável, o qual classificou o MR em valores para cada classe de solo na Classificação AASHTO.

Para criar esse modelo, precisou-se inicialmente dividir os valores de módulo de resiliência por classes AASHTO. Na sequência, realizaram-se alguns testes estatísticos, verificando se cada grupo de MR seguia uma distribuição normal. Como todos os grupos testados atenderam a essa premissa, pôde-se implementar um modelo linear geral para cada classe de solo.

Para isso, calculou-se para cada grupo de solos, o valor do módulo de resiliência típico, em seguida, foram calculados os valores extremos para cada valor típico, para um intervalo de confiança de 95%. Assim, foi obtido um modelo linear geral para cada classe de solos, sendo estratificado pelo valor típico do MR e pelos valores do intervalo de confiança. A Tabela 6.3 apresenta os resultados dos modelos de regressão.

Tabela 6.3 – Valores Típicos do Módulo de Resiliência para área de estudo.

<b>Classificação da AASHTO</b>	<b>Valor Típico de Módulo de Resiliência (MPa)</b>	<b>Intervalo de Valores de Módulo de Resiliência (MPa)</b>
A-5	109	93 - 124
A-3	112	102 - 122
A-4	234	216 - 253
A-6	311	274 - 348
A-2-4	421	388 - 453
A-2-6	515	439 - 591
A-7	589	536 - 643
A-1-a	779	743 - 814
A-1-b	829	793 - 865

Fonte: O autor.

Em seguida, foi gerado um modelo de predição do MR a partir do CBR para o conjunto de dados, sendo obtido um r-quadrado de 0,58. Isso foi feito devido à existência de diversos modelos de regressão na literatura que traçam uma correlação direta do MR com o CBR. A Equação 6.1 mostra o modelo de predição para o banco de dados com  $R^2 = 0,58$ , que mesmo não apresentando um excelente ajuste, pode-se dizer que ainda é melhor que alguns modelos expostos no Capítulo 4.

$$MR = 97,18 + 8,24CBR \quad (6.1)$$

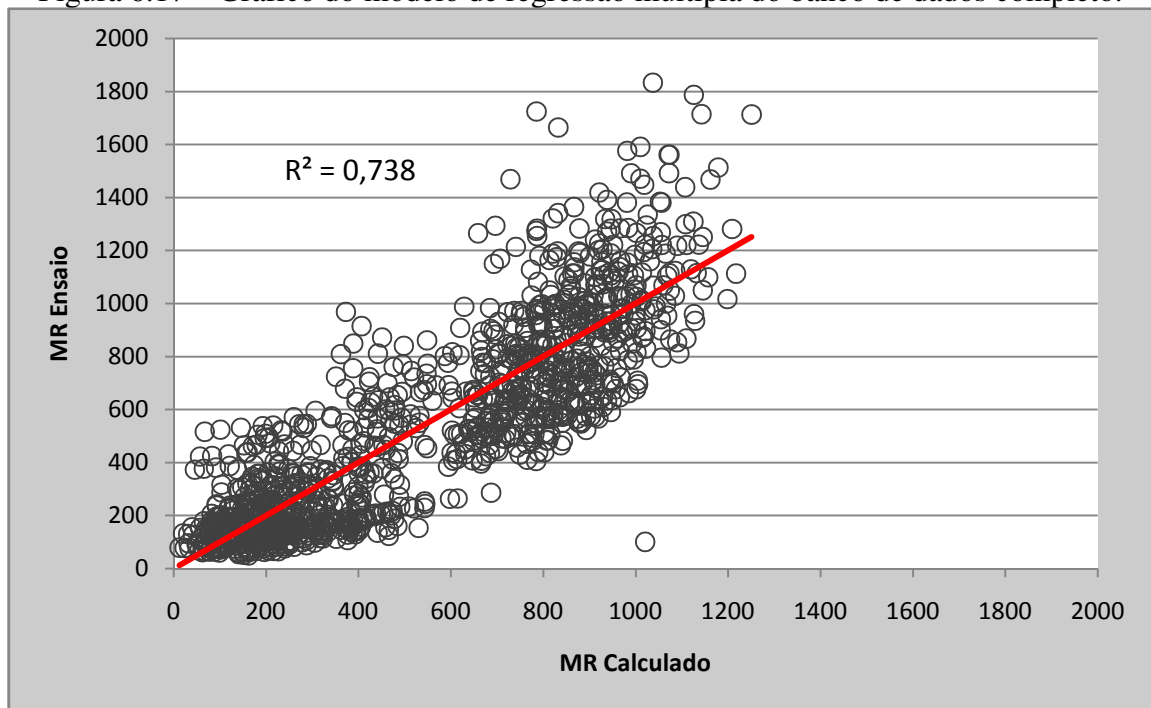
Como o modelo gerado para predição do MR a partir do CBR apresentou um r-quadrado abaixo de 0,60, decidiu-se usar modelos de regressão múltipla (RM) com todas as variáveis do conjunto de dados.

Assim, usou-se como variáveis explicativas: OT, DEN, CBR, EXP, LL, IP, percentual que passa na peneira 25,4 mm (P25,4), percentual que passa na peneira 9,5 mm (P9,5), percentual que passa na peneira 4,76 mm (P4,76), percentual que passa na peneira 2 mm (P2), percentual que passa na peneira 0,42 mm (P0,42), percentual que passa na peneira 0,074 mm (P0,074), classificação da AASTHO (Class), tensão confinante e tensão desvio. Assim, se obteve resultados mais confiáveis e superiores quando comparados aos modelos de CBR x MR, conforme mostram o gráfico da Figura 6.17.

Observa-se no gráfico da Figura 6.17, que o desempenho do melhor modelo usando-se RM, obteve um ajuste ( $R^2$ ) de 0,74 para o banco de dados completo. Podendo-se reportar um modelo de ajuste razoável na Equação 6.2.

$$\begin{aligned} MR = & 696,05 + 21OT + 130,73DEN + 2,8CBR - 135,72EXP + 6,88LL \\ & + 13,53IP - 8,14(P25,4) + 10,76(P9,5) - 26,30(P4,76) + 20,85(P2) \\ & - 7(P0,42) - 6,63(P0,074) + 3135,97\sigma_3 - 522,52\sigma_d - 34,26Class \end{aligned} \quad (6.2)$$

Figura 6.17 – Gráfico do modelo de regressão múltipla do banco de dados completo.



Fonte: O autor.

Adicionalmente, foram gerados modelos de regressão múltipla para o cálculo do  $\epsilon_r$  para o conjunto de dados total, porém estes não obtiveram ajustes melhores que os modelos de predição do MR. Sendo que o melhor ajuste obteve ( $R^2$ ) de 0,64.

### 6.3.1 Considerações sobre os Modelos de Regressão Gerados

Como os ajustes dos modelos de predição do MR, usando-se a técnica de regressão, ficaram melhores que os ajustes dos modelos de predição do  $\epsilon_r$ , recomenda-se apenas o uso do modelo de previsão do MR.

O modelo de predição do MR gerado a partir do banco dados obteve bom ajuste com  $R^2 = 0,74$ , com a técnica de RM. Considera-se que esse modelo pode ser usado para calcular o MR para qualquer par de tensões na ausência de um equipamento triaxial de carga repetida ou para conhecimento prévio do comportamento mecânico de solos no estado do Ceará. Verifica-se que o ajuste desse modelo é melhor do que o ajuste de alguns modelos gerados por outros autores, conforme citado no Capítulo 4.

E, para a região de estudo, esse modelo deve ter melhor aplicação que outros modelos estudados em outras regiões do Brasil e do mundo. Essa afirmação é válida devido às

especificidades locais das ocorrências de materiais, bem como a intensidade dos processos de formação dos solos, que são produtos das variações ambientais de cada região.

Os valores típicos do MR (Tabela 6.3), classificados para os grupos de solos da Classificação AASHTO, os quais são oriundos de um modelo linear geral, também surge como alternativa de uso para região estudada, bastando ter apenas os dados para se chegar a Classificação da AASHTO, ou seja, Granulometria, LL e LP.

#### **6.4 Modelagem Neural do Módulo de Resiliência**

A modelagem neural, executada nesta investigação, foi realizada para conjunto de dados completo, conforme dito anteriormente. As variáveis a serem estimadas são os resultados do ensaio de módulo de resiliência, que são o próprio valor de MR e o valor de  $\epsilon_r$ , pois é possível calcular o MR dividindo a tensão desvio pelo  $\epsilon_r$ .

Os dados foram organizados de forma que os valores de OT, DEN, CBR, EXP, LL, IP, P25,4, P9,5, P4,76, P2, P0,42, P0,074, Class, tensão confinante e tensão desvio fossem usados como dados de entrada das RNA e os valores de MR e  $\epsilon_r$  fossem utilizados como dados de saída.

Para a realização da modelagem, inicialmente, testaram-se as 15 variáveis supracitadas como dados de entrada do modelo, e posteriormente procedeu-se com a variação (redução gradual) do número de variáveis de entrada, de tal sorte que se pudesse encontrar um modelo neural com menor custo de laboratório (menor número de variáveis de entrada) e computacional (menor tempo de processamento e menores erros) quando comparadas as suas saídas às respostas conhecidas do banco de dados. Ressalta-se que, para as saídas das RNA, não serão calculados simultaneamente os valores de MR e  $\epsilon_r$ . A modelagem deles será realizada separadamente, logo, serão criados, validados e testados modelos de predição independentes para cada uma das saídas, quais sejam MR e  $\epsilon_r$ .

Após ser concluída a etapa da modelagem neural com o conjunto de treinamento e validação, apresentaram-se às redes neurais os resultados dos ensaios de módulo de resiliência (MR e  $\epsilon_r$ ) do conjunto de testes para cada modelo gerado. Os resultados dessas estimativas foram organizados de forma a possibilitar sua interpretação e análise.



### 6.4.1 *Árvore de Testes*

Neste trabalho foram testados diversos algoritmos do tipo *errorbackpropagation feed-forward*. No entanto, o algoritmo que melhor se adaptou à previsão dessas propriedades foi o TRAINLM (*Levenberg-Marquardt*). Verificou-se que ele foi quem produziu os melhores resultados para o conjunto de dados na previsão dos parâmetros esperados como saída das redes neurais. Para Beale *et al.*, (2010), o TRAINLM é um algoritmo de treinamento rápido que utiliza o método de Newton para aproximação do mínimo da função de erro que ainda apresenta ótima capacidade de generalização.

Como esta tese se propõe a modelar duas características geotécnicas de interesse à pavimentação, mas provenientes do mesmo ensaio e que se pode obter uma em função da outra, buscou-se testar os mesmos modelos para previsão de ambas. Além disso, considerando que existe um conjunto de dados com 15 variáveis explicativas, optou-se pela busca parcimoniosa dos modelos neurais para cada variável. Desta forma, procedeu-se com o treinamento, validação e teste de cada modelo em separado nos quais se obtinham como variáveis de saída o MR ou a  $\epsilon_r$ .

Com a definição de se buscar os modelos de previsão do MR e do  $\epsilon_r$  independentes, realizou-se a seguinte árvore de testes para se chegar à(s) topologia(s) mais adequada(s) para cada variável:

- redes com diversos algoritmos de treinamento, mas principalmente o TRAINLM e o TRAINGDX;
- topologias com uma, duas e três camadas intermediárias;
- topologias com variações do número de neurônios nas camadas intermediárias, inicialmente testou-se a indicação de Hetch-Nelson (1989) para determinação do número de neurônios na camada intermediária, posteriormente o número de neurônios foram variando de diversas formas, isso em diferentes camadas;
- testou-se outras formas de variação do número de neurônios nas camadas intermediárias, como um número entre a camada de entrada e saída, o dobro de neurônios da indicação de Hetch-Nelson (1989);
- também buscou-se o número de neurônios entre as camadas intermediárias, variando entre o número de entradas e saída;

- topologias com função de ativação Logística Sigmoidal (*logsig*) e Tangente Sigmoidal (*tansig*) nos neurônios da(s) camada(s) intermediária(s) e função identidade (*pureline*) nos neurônios de saída;
- topologias com diferentes parâmetros de treinamento: taxa de aprendizagem entre 0,001 e 0,1, e número de épocas variando entre 10 e 10000 ciclos;
- uso de regra de parada implementada no algoritmo de treinamento, de forma a evitar o super-treinamento (*overfitting*) do conjunto de dados, melhorando assim a capacidade de generalização do modelo escolhido.

Certamente, para se chegar à topologia ótima, poder-se-iam adotar estratégias diferentes daquela apresentada aqui, na busca da topologia mais adequada, contudo, elegeu-se uma conduta lógica e racional na tentativa de definir a topologia mais apropriada que convergisse para um erro mínimo em um menor tempo de processamento com menor custo de ensaios. A topologia escolhida nestes resultados, e tomada aqui como mais adequada, foi àquela possível de se encontrar dentro das limitações de tempo disponível para a execução dos sucessivos refinamentos necessários.

O período de testes demandou 18 meses, principalmente devido à obtenção de dados que dependiam da realização de ensaios em laboratório. Esse tempo possibilitou que fossem testadas cerca de 2.000 topologias diferentes para cada uma das variáveis de saída, para cada conjunto de dados, na tentativa incansável de identificação da topologia que melhor se adaptasse à modelagem desse fenômeno.

Conforme citado por Da Silva (2003), esta maneira de definir a topologia demanda um tempo considerável e, ainda assim, é provável que haja uma combinação não testada que responda melhor às expectativas de generalização e tempo de convergência que aquela adotada como sendo a mais adequada.

Para medir o desempenho das topologias testadas, adotou-se o MSE (*Mean of Squared Error* ou Quadrado Médio dos Erros), medida de desempenho bastante difundida para avaliar o desempenho dos modelos neurais, sendo a mesma definida pela Equação 6.4.

$$\text{MSE} = \frac{\text{SSE}}{n-p} \quad (6.4)$$

onde:

SSE = Diferenças quadráticas entre os valores de saída da RNA e os valores esperados como ideais;

$n$  = Número de exemplos do conjunto de treinamento (quantidade de padrões);

$p$  = Número de parâmetros a serem estimados (quantidade de pesos da rede).

Para ilustrar o esforço dessa etapa do trabalho, apresentam-se aqui os 5 (cinco) melhores modelos para predição das variáveis modeladas. Os resultados das topologias são apresentados variando-se, principalmente, os dados de entrada e o número de neurônios na camada intermediária, onde o MR e o  $\Xi_r$  são as variáveis de saída para todas as variações dos conjuntos de dados de entrada dos modelos. Para cada modelo gerado deu-se um nome com a finalidade de facilitar a sua referência.

Ressalte-se também que, para cada topologia da rede neural da árvore de testes, para cada uma das duas variáveis modeladas, foram obtidos o MSE e coeficiente de correlação ( $R$ ), considerando os conjuntos de treinamento, validação e teste. Os resultados destes indicadores são ilustrados nas tabelas e figuras que sucedem este item e que serão analisados posteriormente.

#### 6.4.2 Modelo Neural M1

O Modelo Neural M1 para estimação individual do MR e  $\Xi_r$  têm as seguintes características:

- i. algoritmo TRAINLM (*Levenberg-Marquardt*);
- ii. uma camada de entrada com 15 neurônios representados pelas variáveis: OT, DEN, CBR, EXP, LL, IP, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$ ,  $\sigma_d$  e Class;
- iii. uma camada intermediária (escondida) com 31 neurônios;
- iv. uma camada de saída com 1 neurônio para o modelo do MR e 1 neurônio para o modelo do  $\Xi_r$ ;
- v. uso da função de ativação identidade nas camadas de entrada e saída, função de ativação tangente sigmoideal (*tansig*) com intervalo de ativação [-1; 1] para as camadas intermediárias.

Os resultados do Modelo Neural M1, com 15 neurônios na camada de entrada, 31 neurônios na camada intermediária e 1 neurônio na camada de saída (15:31:1), podem ser

observados nas Tabelas 6.4 e 6.5 e nas Figuras 6.18 a 6.21, as quais apresentam as topologias e medidas de desempenho dos modelos para esse conjunto de dados.

Tabela 6.4 – Topologia e desempenho da RNA 15:31:1 para o MR.

<b>Modelo</b>	<b>MR</b>		
<b>RNA</b>	15:31:1		
<b>Conjunto</b>	Treinamento	Validação	Teste
<b>MSE</b>	0,002	0,005	0,003
<b>R</b>	0,9923	0,9843	0,9844

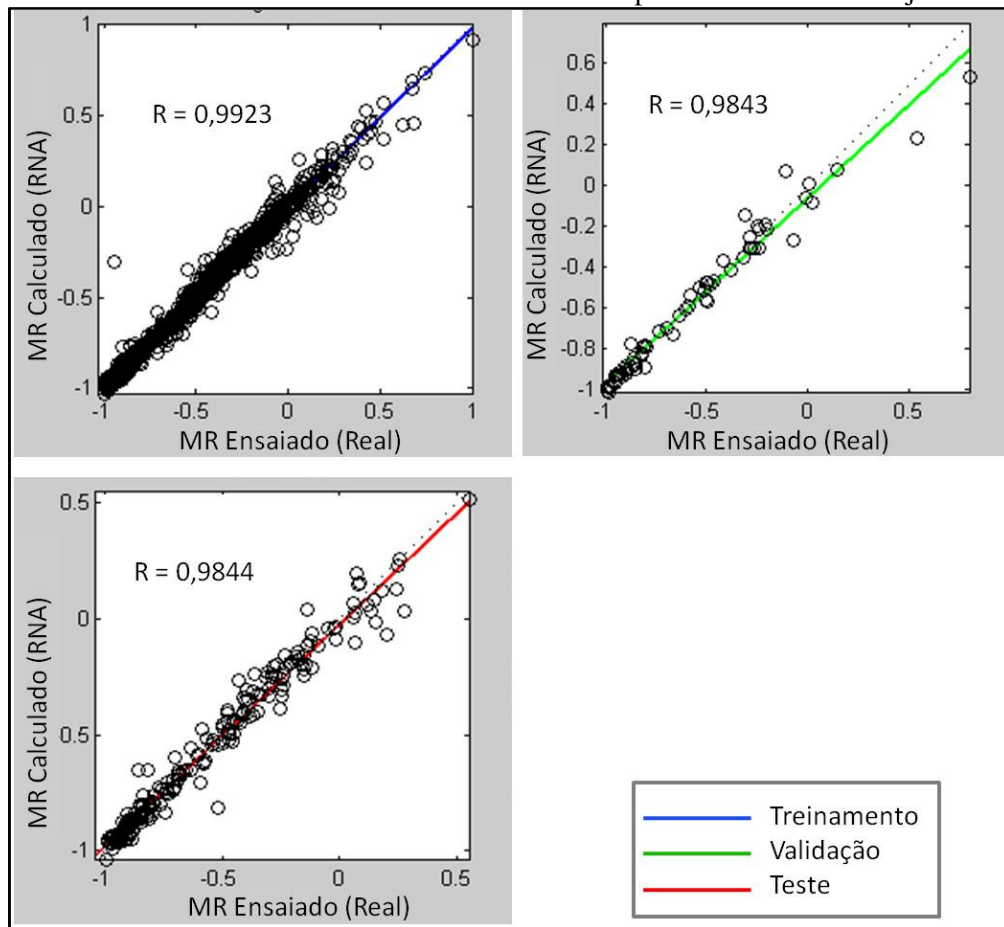
Fonte: O autor.

Tabela 6.5 – Topologia e desempenho da RNA 15:31:1 para o  $\epsilon_r$ .

<b>Modelo</b>	<b><math>\epsilon_r</math></b>		
<b>RNA</b>	15:31:1		
<b>Conjunto</b>	Treinamento	Validação	Teste
<b>MSE</b>	0,001	0,007	0,004
<b>R</b>	0,9931	0,9620	0,9800

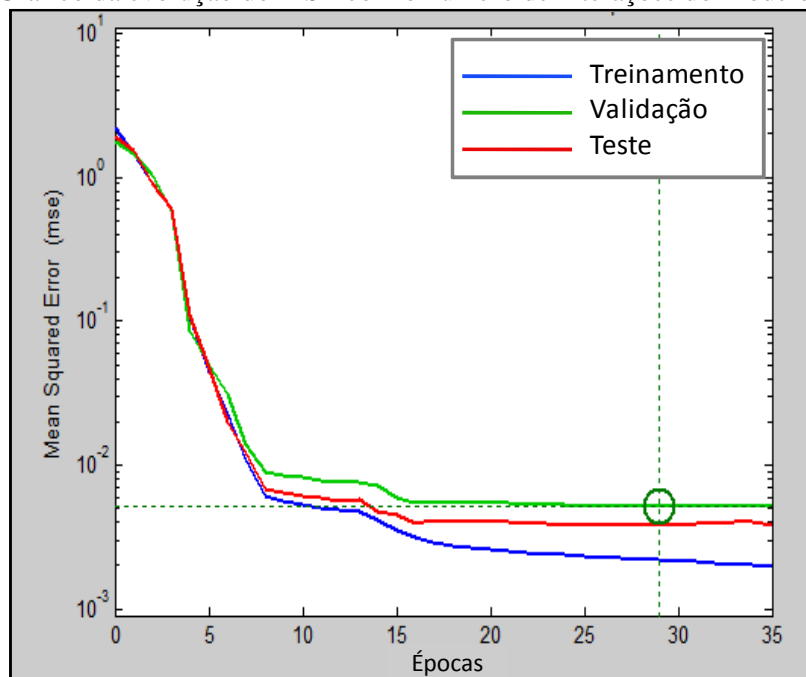
Fonte: O autor.

Figura 6.18 – Gráficos calculado  $\times$  ensaiado do Modelo M1 para o MR dos três conjuntos de dados.



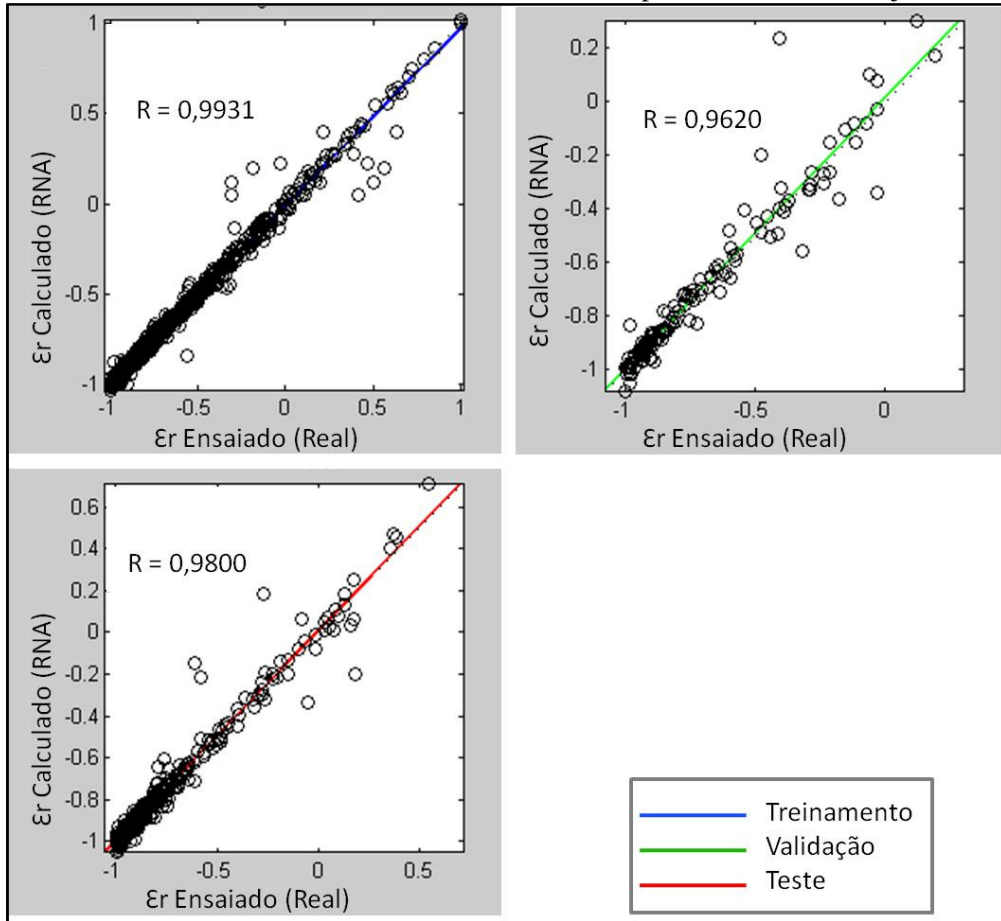
Fonte: O autor.

Figura 6.19 – Gráfico da evolução do MSE com o número de interações do Modelo M1 para o MR.




Fonte: O autor.

Figura 6.20 – Gráficos calculado  $\times$  ensaiado do modelo M1 para o  $\epsilon_r$  dos três conjuntos de dados.



Fonte: O autor.

Figura 6.21 – Gráfico da evolução do MSE com o número de interações do Modelo M1 para o  $\epsilon_r$ .



Fonte: O autor.

### 6.4.3 Modelo Neural M2

O Modelo Neural M2 para estimação individual do MR e  $\epsilon_r$  têm as seguintes características:

- i. algoritmo TRAINLM (*Levenberg-Marquardt*);
- ii. uma camada de entrada com 13 neurônios representados pelas variáveis: OT, DEN, LL, IP, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$ ,  $\sigma_d$  e Class;
- iii. uma camada intermediária (escondida) com 27 neurônios;
- iv. uma camada de saída com 1 neurônio para o modelo do MR e 1 neurônio para o modelo do  $\epsilon_r$ ;
- v. uso da função de ativação identidade nas camadas de entradas e saída, função de ativação tangente sigmoideal (*tansig*) com intervalo de ativação [-1; 1] para as camadas intermediárias.

Os resultados do Modelo Neural M2, com 13 neurônios na camada de entrada, 27 neurônios na camada intermediária e 1 neurônio na camada de saída (13:27:1), podem ser observados nas Tabelas 6.6 e 6.7 e nas Figuras 6.22 a 6.25, as quais apresentam as topologias e medidas de desempenho dos modelos para esse conjunto de dados.

Tabela 6.6 – Topologia e desempenho da RNA 13:27:1 para o MR.

<b>Modelo</b>	<b>MR</b>		
<b>RNA</b>	13:27:1		
<b>Conjunto</b>	Treinamento	Validação	Teste
<b>MSE</b>	0,002	0,004	0,004
<b>R</b>	0,9934	0,9881	0,9847

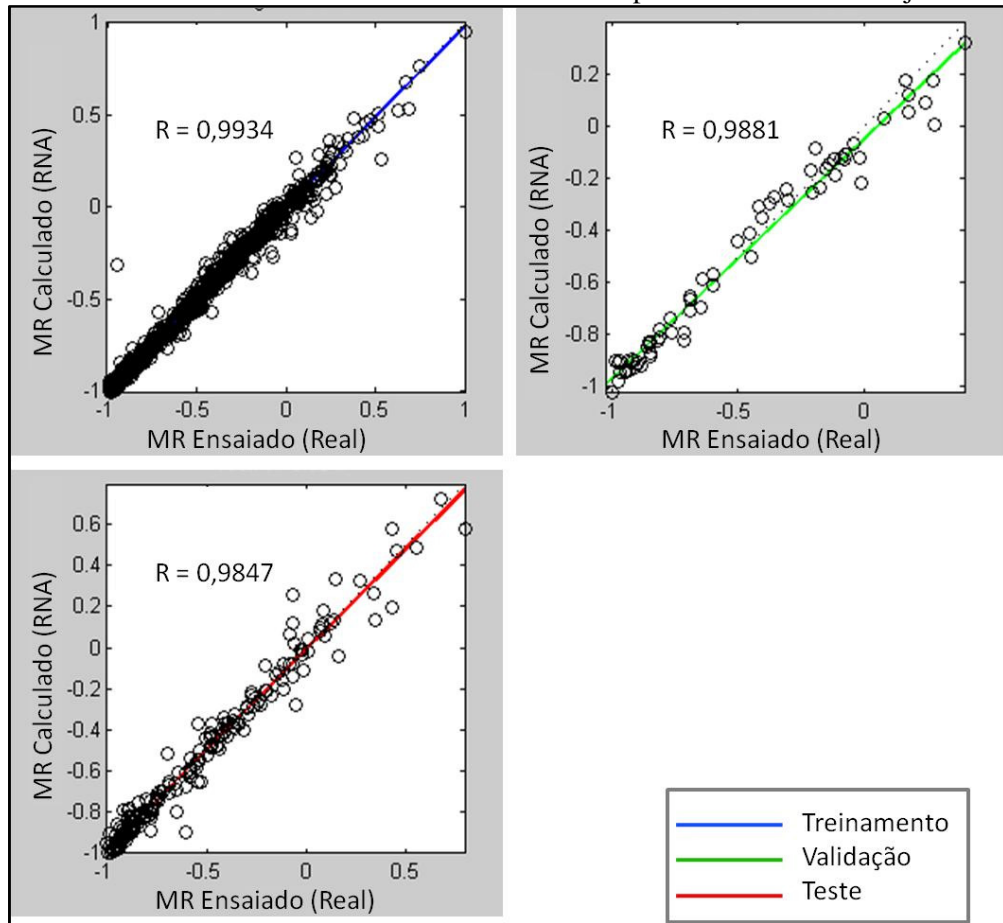
Fonte: O autor.

Tabela 6.7 – Topologia e desempenho da RNA 13:27:1 para o  $\epsilon_r$ .

<b>Modelo</b>	<b><math>\epsilon_r</math></b>		
<b>RNA</b>	13:27:1		
<b>Conjunto</b>	Treinamento	Validação	Teste
<b>MSE</b>	0,002	0,01	0,008
<b>R</b>	0,9925	0,9532	0,9609


Fonte: O autor.

Figura 6.22 – Gráficos calculado × ensaiado do modelo M2 para o MR dos três conjuntos de dados.



Fonte: O autor.

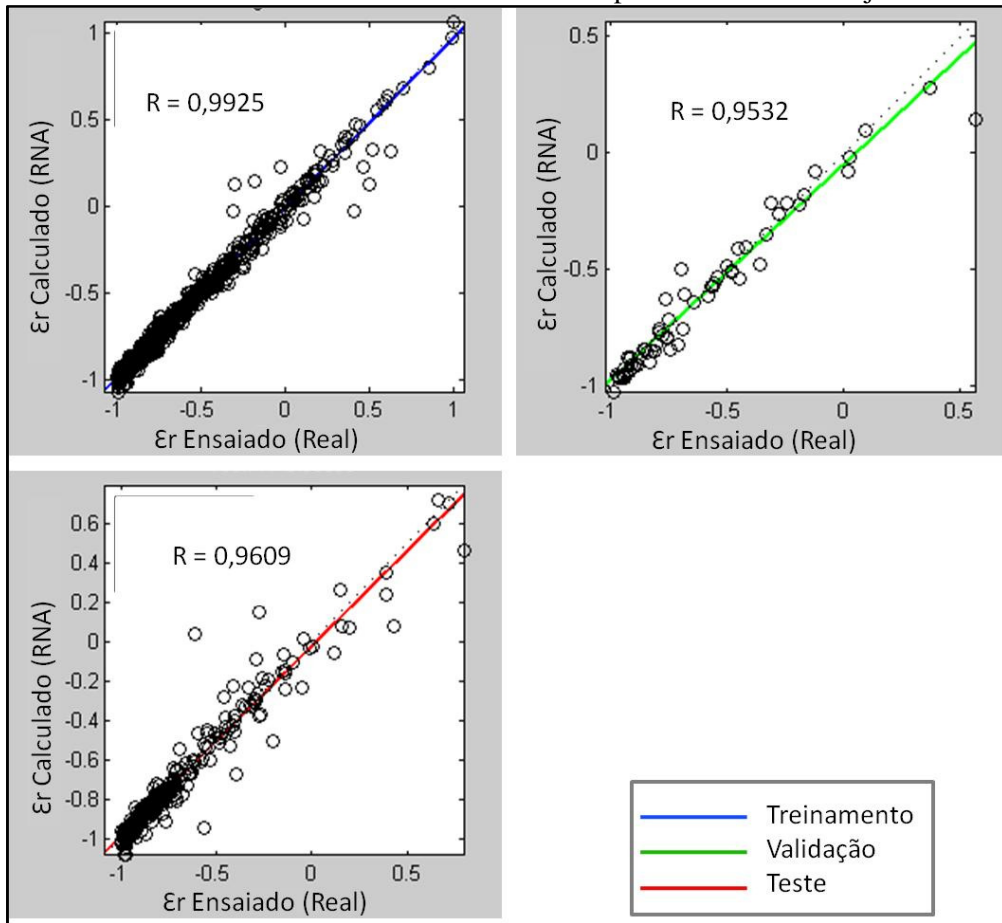
Figura 6.23 – Gráfico da evolução do MSE com o número de interações do Modelo M2 para o MR.



Fonte: O autor.




Figura 6.24 – Gráficos calculado × ensaiado do Modelo M2 para o Er dos três conjuntos de dados.



Fonte: O autor.

Figura 6.25 – Gráfico da evolução do MSE com o número de interações do modelo M2 para o Er.



Fonte: O autor.

#### 6.4.4 Modelo Neural M3

O Modelo Neural M3 para estimação individual do MR e  $\xi_r$  têm as seguintes características:

- i. algoritmo TRAINLM (*Levenberg-Marquardt*);
- ii. uma camada de entrada com 11 neurônios representados pelas variáveis: CBR, DEN, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$ ,  $\sigma_d$  e Class;
- iii. uma camada intermediária (escondida) com 23 neurônios;
- iv. uma camada de saída com 1 neurônio para o modelo do MR e 1 neurônio para o modelo do  $\xi_r$ ;
- v. uso da função de ativação identidade nas camadas de entrada e saída, função de ativação tangente sigmoideal (*tansig*) com intervalo de ativação [-1; 1] para as camadas intermediárias.

Os resultados do Modelo Neural M3, com 11 neurônios na camada de entrada, 23 neurônios na camada intermediária e 1 neurônio na camada de saída (11:23:1), podem ser observados nas Tabelas 6.8 e 6.9 e nas Figuras 6.26 a 6.29, as quais apresentam as topologias e medidas de desempenho dos modelos para esse conjunto de dados.

Tabela 6.8 – Topologia e Desempenho da RNA 11:23:1 para o MR.

Modelo	MR		
RNA	11:23:1		
Conjunto	Treinamento	Validação	Teste
MSE	0,002	0,005	0,003
R	0,9914	0,9827	0,9878

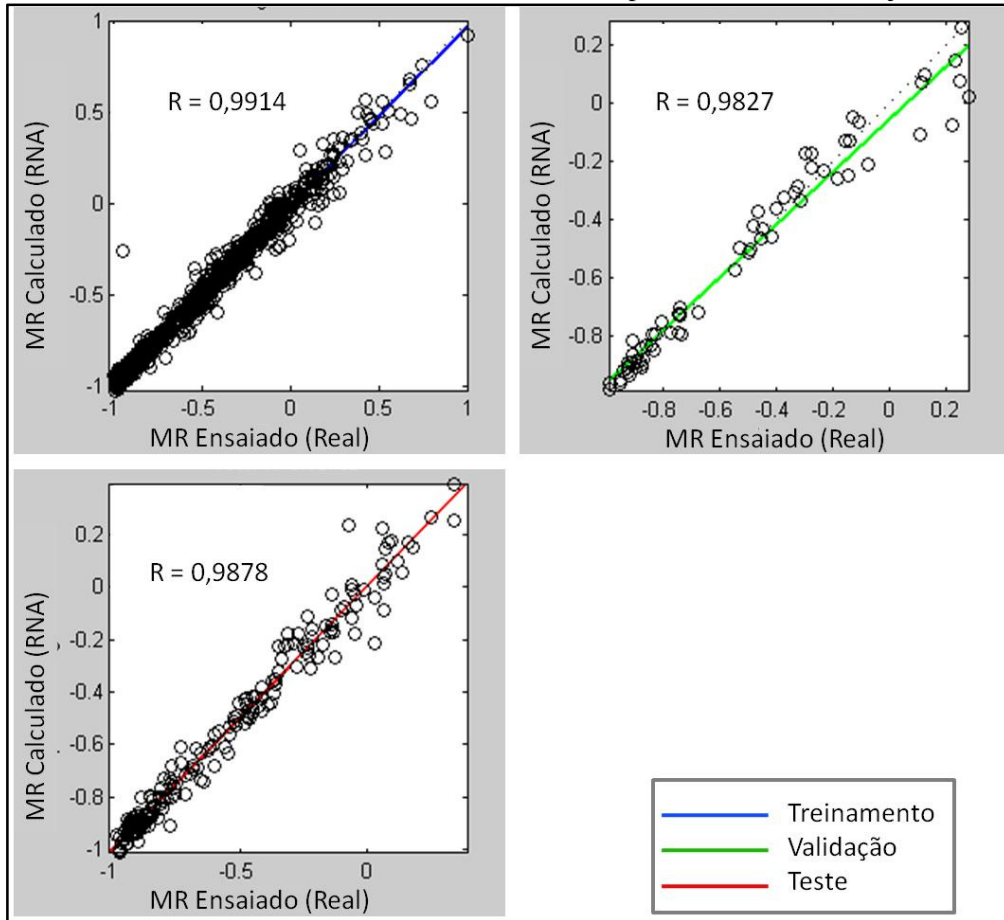
Fonte: O autor.

Tabela 6.9 – Topologia e Desempenho da RNA 11:23:1 para o  $\xi_r$ .

Modelo	$\xi_r$		
RNA	11:23:1		
Conjunto	Treinamento	Validação	Teste
MSE	0,002	0,01	0,008
R	0,9892	0,9429	0,9654


Fonte: O autor.

Figura 6.26 – Gráficos calculado × ensaiado do Modelo M3 para o MR dos três conjuntos de dados.



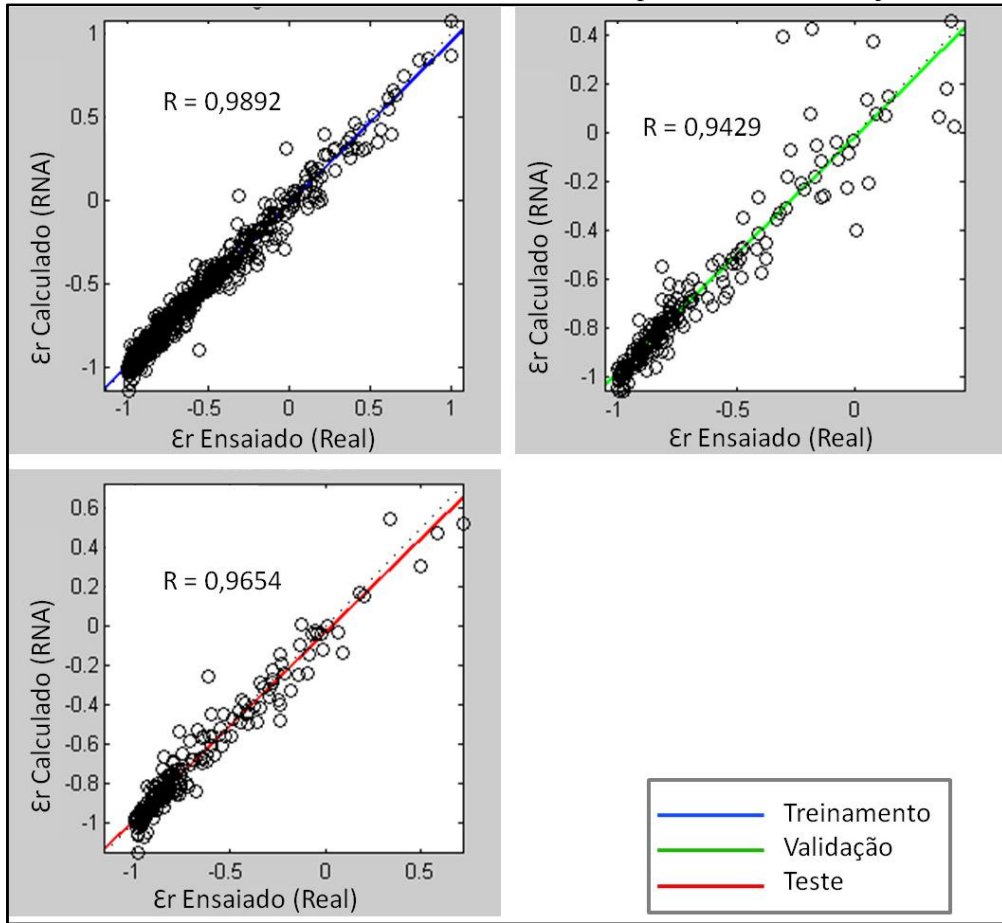
Fonte: O autor.

Figura 6.27 – Gráfico da evolução do MSE com o número de interações do Modelo M3 para o MR.




Fonte: O autor.

Figura 6.28 – Gráficos calculado x ensaiado do Modelo M3 para o Er dos três conjuntos de dados.



Fonte: O autor.

Figura 6.29 – Gráfico da evolução do MSE com o número de interações do Modelo M3 para o Er.



Fonte: O autor.

### 6.4.5 Modelo Neural M4

O Modelo Neural M4 para estimação individual do MR e  $\epsilon_r$  têm as seguintes características:

- i. algoritmo TRAINLM (*Levenberg-Marquardt*);
- ii. uma camada de entrada com 10 neurônios representados pelas variáveis: OT, DEN, (P25,4), (P9,5), (P4,76), (P2), (P0,42), (P0,074),  $\sigma_3$  e  $\sigma_d$ ;
- iii. uma camada intermediária (escondida) com 21 neurônios;
- iv. uma camada de saída com 1 neurônio para o modelo do MR e 1 neurônio para o modelo do  $\epsilon_r$ ;
- v. uso da função de ativação identidade nas camadas de entrada e saída, função de ativação tangente sigmoideal (*tansig*) com intervalo de ativação [-1; 1] para as camadas intermediárias.

Os resultados do Modelo Neural M4, com 10 neurônios na camada de entrada, 21 neurônios na camada intermediária e 1 neurônio na camada de saída (10:21:1), podem ser observados nas Tabelas 6.10 e 6.11 e nas Figuras 6.30 a 6.33, as quais apresentam as topologias e medidas de desempenho dos modelos para esse conjunto de dados.

Tabela 6.10 – Topologia e desempenho da RNA 10:21:1 para o MR.

Modelo	MR		
RNA	10:21:1		
Conjunto	Treinamento	Validação	Teste
MSE	0,003	0,005	0,004
R	0,9896	0,9850	0,9857

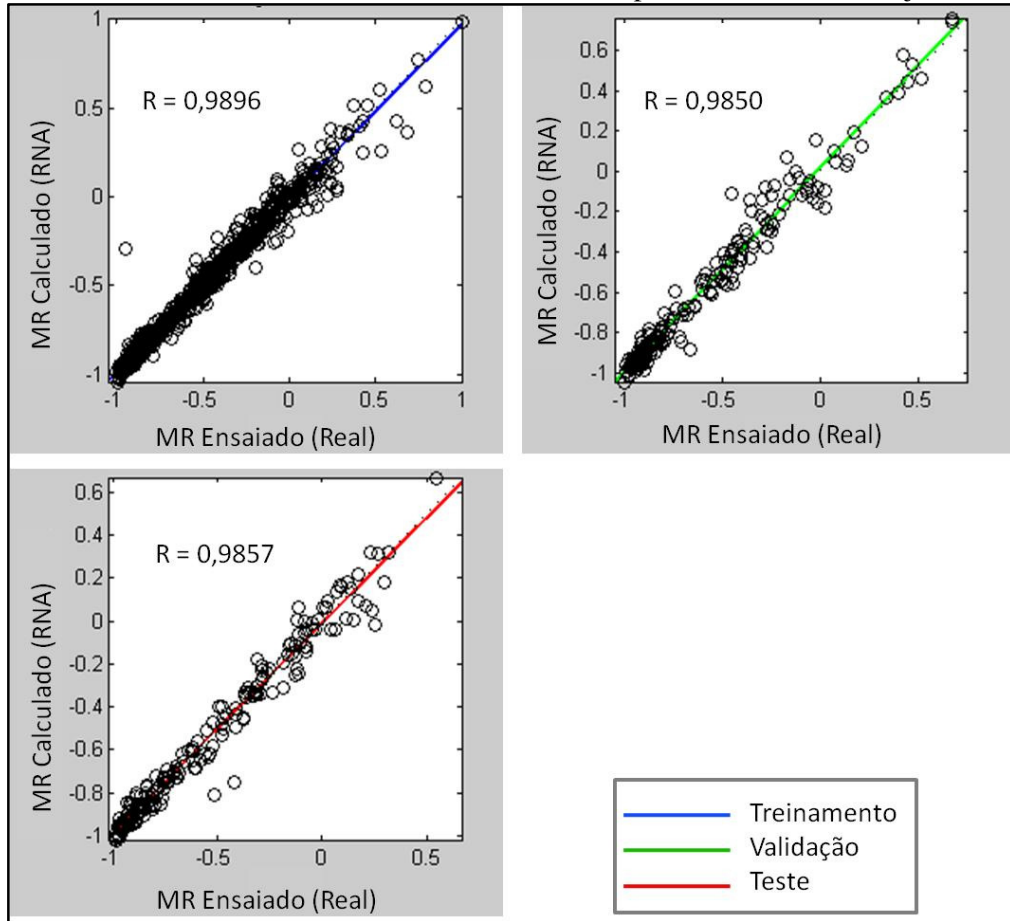
Fonte: O autor.

Tabela 6.11 – Topologia e desempenho da RNA 10:21:1 para o  $\epsilon_r$ .

Modelo	$\epsilon_r$		
RNA	10:21:1		
Conjunto	Treinamento	Validação	Teste
MSE	0,003	0,01	0,005
R	0,9900	0,9574	0,9762


Fonte: O autor.

Figura 6.30 – Gráficos calculado × ensaiado do modelo M4 para o MR dos três conjuntos de dados.



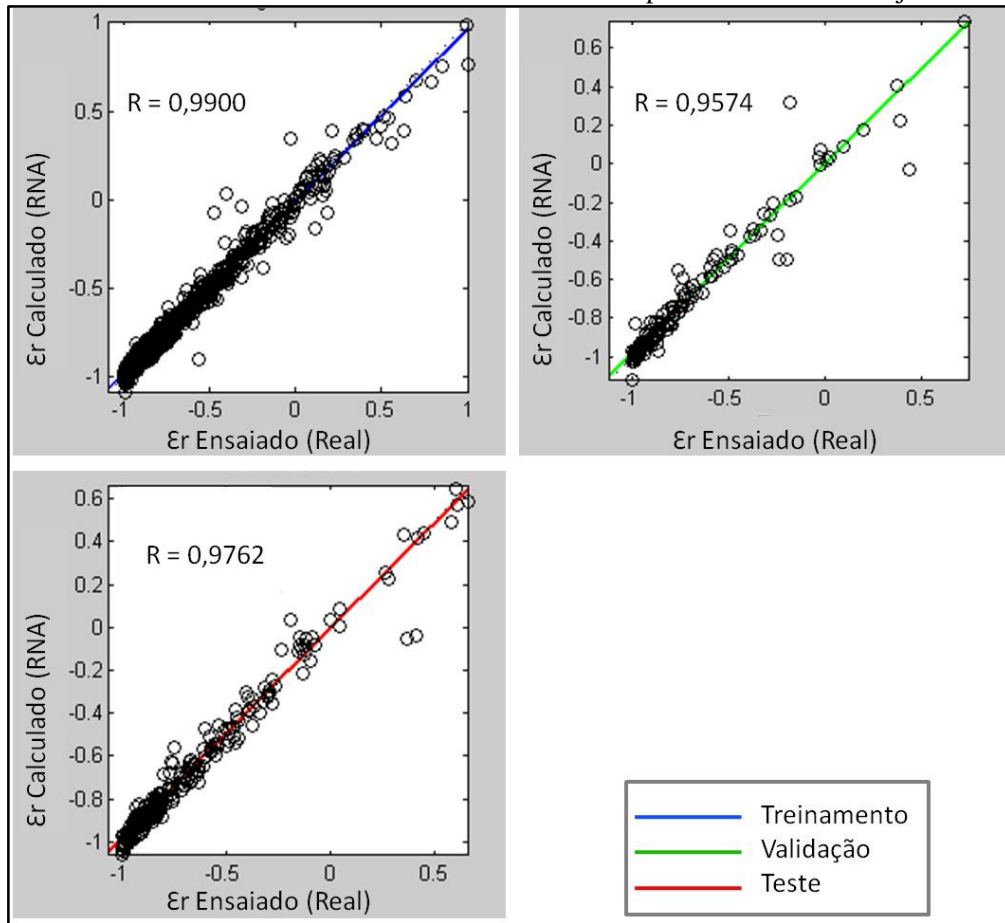
Fonte: O autor.

Figura 6.31 – Gráfico da evolução do MSE com o número de interações do Modelo M4 para o MR.




Fonte: O autor.

Figura 6.32 – Gráficos calculado  $\times$  ensaiado do Modelo M4 para o  $\epsilon_r$  dos três conjuntos de dados.



Fonte: O autor.

Figura 6.33 – Gráfico da evolução do MSE com o número de interações do Modelo M4 para o  $\epsilon_r$ .



Fonte: O autor.

### 6.4.6 Modelo Neural M5

O Modelo Neural M5 para estimação individual do MR e  $\epsilon_r$  têm as seguintes características:

- i. algoritmo TRAINLM (*Levenberg-Marquardt*);
- ii. uma camada de entrada com 7 neurônios representados pelas variáveis: OT, DEN, (P9,5), (P2), (P0,074),  $\sigma_3$  e  $\sigma_d$ ;
- iii. uma camada intermediária (escondida) com 15 neurônios;
- iv. uma camada de saída com 1 neurônio para o modelo do MR e 1 neurônio para o modelo do  $\epsilon_r$ ;
- v. uso da função de ativação identidade nas camadas de entrada e saída, função de ativação tangente sigmoideal (*tansig*) com intervalo de ativação [-1; 1] para as camadas intermediárias.

Os resultados do Modelo Neural M5, com 7 neurônios na camada de entrada, 15 neurônios na camada intermediária e 1 neurônio na camada de saída (7:15:1), podem ser observados nas Tabelas 6.12 e 6.13 e nas Figuras 6.34 a 6.37, as quais apresentam as topologias e medidas de desempenho dos modelos para esse conjunto de dados.

Tabela 6.12 – Topologia e desempenho da RNA 7:15:1 para o MR.

Modelo	MR		
RNA	7:15:1		
Conjunto	Treinamento	Validação	Teste
MSE	0,004	0,003	0,004
R	0,9840	0,9857	0,9847

Fonte: O autor.

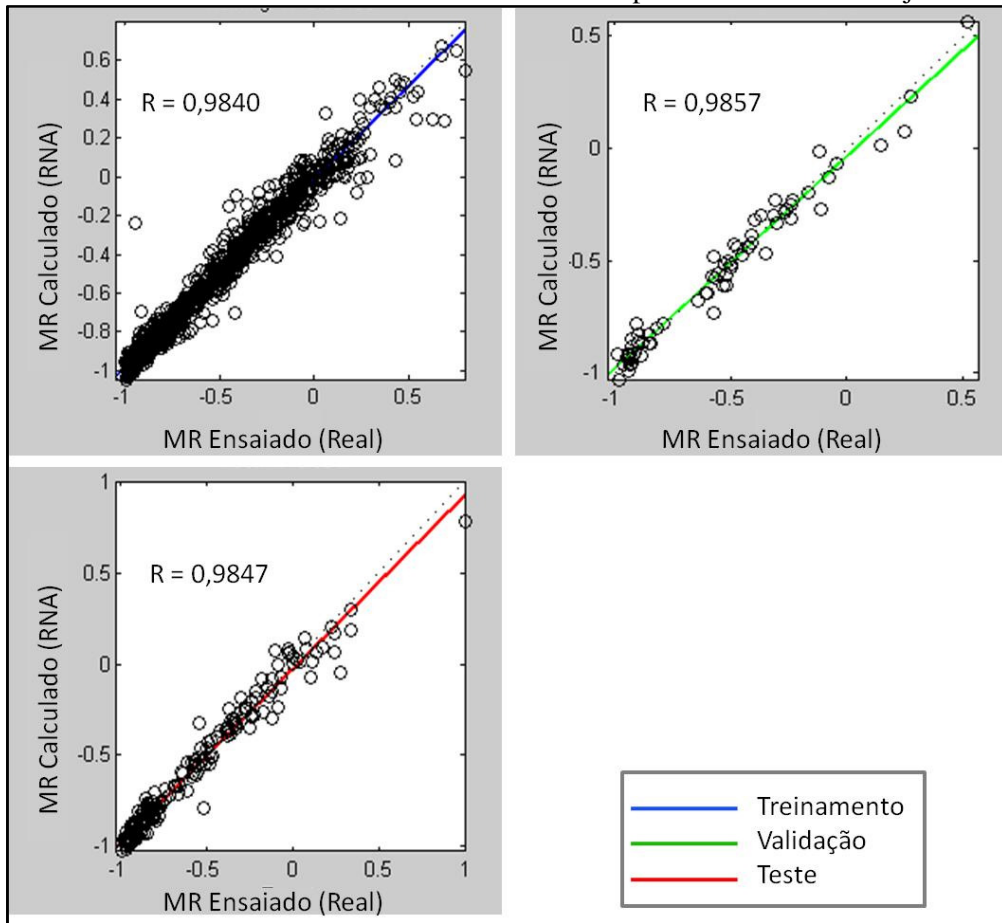
Tabela 6.13 – Topologia e desempenho da RNA 7:15:1 para o  $\epsilon_r$ .

Modelo	$\epsilon_r$		
RNA	7:15:1		
Conjunto	Treinamento	Validação	Teste
MSE	0,004	0,007	0,01
R	0,9826	0,9671	0,9639

Fonte: O autor.




Figura 6.34 – Gráficos calculado  $\times$  ensaiado do Modelo M5 para o MR dos três conjuntos de dados.



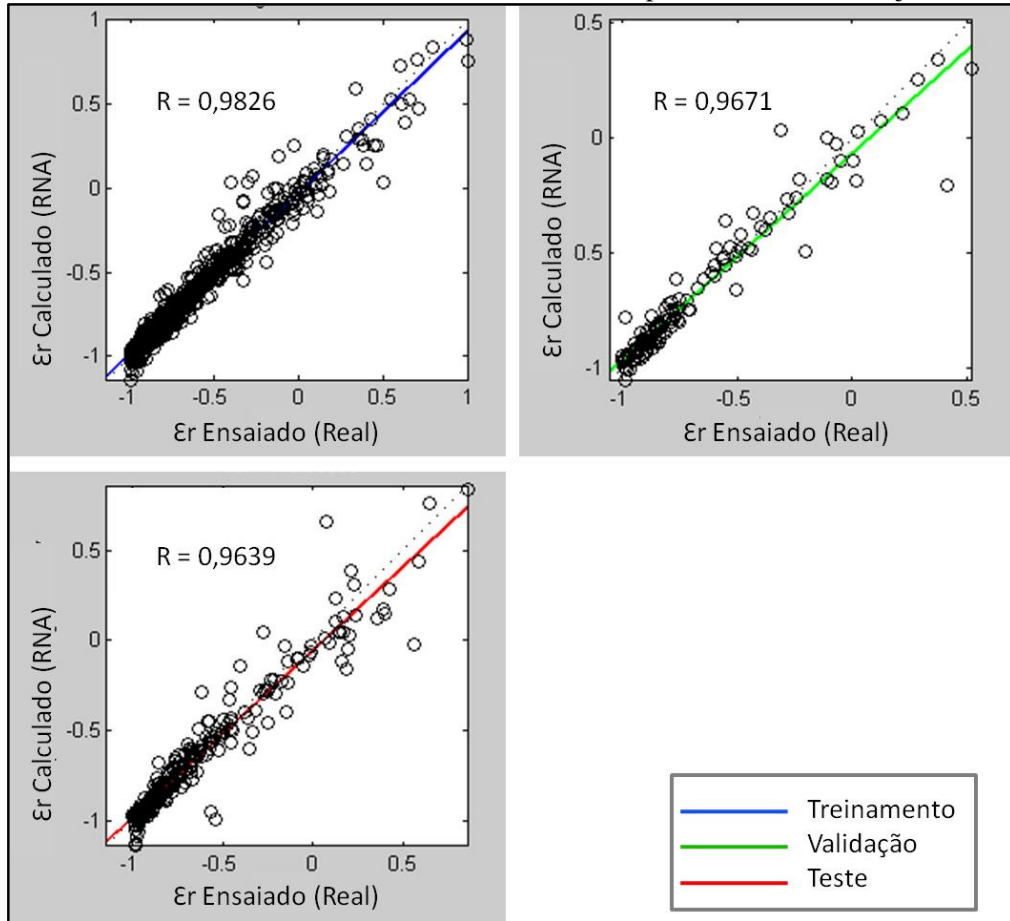
Fonte: O autor.

Figura 6.35 – Gráfico da evolução do MSE com o número de interações do modelo M5 para o MR.




Fonte: O autor.

Figura 6.36 – Gráficos calculado x ensaiado do Modelo M5 para o  $\epsilon_r$  dos três conjuntos de dados.



Fonte: O autor.

Figura 6.37 – Gráfico da evolução do MSE com o número de interações do Modelo M5 para o  $\epsilon_r$ .



Fonte: O autor.

#### 6.4.7 *Análise dos Modelos Neurais Gerados e Escolha do Melhor Modelo*

Mostrou-se anteriormente os cinco melhores modelos neurais testados para gerar estimativas do MR e do  $\epsilon_r$  dos solos da RMF e áreas adjacentes. Com isso, foi possível verificar que todos os modelos apresentados têm uma boa capacidade de prever as duas variáveis com bons ajustes.

Observando as Tabelas 6.7 a 6.13, percebe-se que os MSE finais dos conjuntos de treinamento, validação e teste de todos os modelos são muito baixos, indicando pequenos erros em todos os modelos gerados. Também nessas tabelas observa-se que os ajustes finais de todos os modelos podem ser considerados excelentes superando o coeficiente de correlação de 0,95.

Os tempos de convergência dos modelos também foram muito baixos, chegando a ser a maior parte dos tempos próximos de 1 segundo e atingindo no máximo 20 segundos, são ciclos considerados excelentes para quantidade de dados. Isso ocorre devido à implantação da regra de parada de treinamento no algoritmo *Levenberg-Marquardt*. Tal regra não permite que a rede continue treinando caso o conjunto de validação dos dados tenha uma quantidade de erros consecutivos. Nesta etapa adotaram-se seis ciclos sem que haja diminuição significativa nos erros, o que provoca a parada no treinamento.

Essa é uma forma de garantir que a rede não irá acumular super-treinamento (*overfitting*), pois a partir dessa etapa no treinamento da rede, embora o conjunto de treinamento melhore o ajuste, o conjunto de teste não tem o mesmo desempenho, por isso a importância da existência do conjunto de validação e da existência de regras e critérios de parada.

Os índices de acertos dos modelos neurais são medidos, geralmente pelo conjunto de teste, pois destes dados à rede neural não conhecia as saídas, sendo as saídas da RNA comparadas aos dados reais apresentados à rede apenas após o treinamento e validação. Foi através deste conjunto que se mediu o desempenho dos modelos calibrados quando da generalização e indicação de utilização dos melhores modelos para prever o MR e o  $\epsilon_r$  dos solos da área de estudo.

Adicionalmente, pode-se observar nas Tabelas 6.4 até a 6.13 que foi introduzida uma medida de correlação dos modelos (R) para comparar os resultados do desempenho das RNA para previsão os dados após a etapa de treinamento e validação, a partir dos dados de teste. Nessas tabelas, além do MSE, também são mostrados os resultados da correlação do

MR e  $\epsilon_r$  com os calculados pelas RNA e os valores reais obtidos nos ensaios triaxiais de cargas repetidas, isso para todos os conjuntos de dados.

Nas Figuras 6.18 até a 6.37, são mostrados os resultados de MR e  $\epsilon_r$  (normalizados entre -1 e 1) previstos pela RNA para os três conjuntos de dados contra os resultados obtidos nos ensaios do módulo de resiliência para o banco de dados. Também são apresentadas as convergências dos MSE, para todos os modelos e para cada conjunto de dados. Os modelos ilustrados são as seguintes: M1 (15:31:1), M2 (13:27:1), M3 (11:23:1), M4 (10:21:1) e M5 (7:15:1).

Este procedimento foi realizado para mostrar o comportamento das RNA frente à predição para cada conjunto de dados de todos os modelos apresentados. A partir dos gráficos de correlação e da convergência do MSE, foram realizadas análises de comparações do desempenho dos modelos neurais testados para medir qual desses é melhor indicado para se prever os valores de MR e  $\epsilon_r$  dos solos naturais da área de estudo, e a partir disso escolher o modelo que será utilizado como recomendação para generalização destes fenômenos.

Analisando-se a qualidade dos modelos de previsão do MR e  $\epsilon_r$ , considerando como indicador o MSE dos conjuntos de treinamento, validação e teste dos cinco modelos reportados, é possível fazer as seguintes afirmações:

- Os MSE do conjunto de testes para todos os modelos são sempre um pouco mais elevados que os MSE do conjunto de treinamento. Isso ocorre devido à quantidade de dados do conjunto de treinamento ser muito superior ao do conjunto de teste. Ainda, o conjunto de treinamento sofre ajustes dos pesos ao longo do treinamento fazendo com que o erro seja diminuído à medida que o número de etapas de treinamento (interações) vai crescendo;
- Os treinamentos dos cinco modelos foram realizados para o máximo de 10.000 interações (etapas), porém todas as topologias tiveram seus treinamentos encerrados antes da etapa 150, devido à regra de parada implementada no algoritmo TRAINLM;
- Quando comparados os MSE do MR com o MSE do  $\epsilon_r$  para os conjuntos de treinamento, percebe-se que os valores são praticamente iguais para as cinco topologias apresentadas. Já para os conjuntos de teste, todos os MSE do MR são inferiores aos do  $\epsilon_r$ , isso demonstra que o erro de generalização do MR é menor que para o  $\epsilon_r$ ;

- Os melhores modelos de predição do MR, considerando o MSE do conjunto de teste, foram os Modelos M1 e M3, ambos com  $MSE = 0,003$ . Já para a predição do  $\epsilon_r$ , considerando o MSE do conjunto de teste, o melhor modelo foi o M1, com  $MSE = 0,004$ ;
- Considerando apenas o MSE do conjunto de teste, pode-se afirmar que para todos os modelos a variável MR tem melhores ajustes que a variável  $\epsilon_r$ .

A seguir apresenta-se análise semelhante sobre a qualidade dos modelos de previsão do MR e  $\epsilon_r$  a partir dos resultados do ajuste de predição pelos gráficos calculadox esperado (R), dos conjuntos de treinamento, validação e teste dos cinco modelos reportados:

- Os coeficientes de correlação (R) do conjunto de testes para todos os modelos são sempre menores do que os do conjunto de treinamento. Isso ocorre devido à quantidade de dados do conjunto de treinamento ser muito superior ao do conjunto de teste. Percebe-se, ainda, que o conjunto de treinamento sofre correções nos pesos ao longo do treinamento fazendo com que o erro seja diminuído à medida que o número de etapas de treinamento (interações) vai crescendo;
- Quando comparados os coeficientes de correlação do MR com os do  $\epsilon_r$  para os conjuntos de teste, a mesma tendência constatada no MSE também é confirmada, ou seja, os acertos de todas as topologias para a previsão do MR é maior que para a previsão do  $\epsilon_r$ . Esse resultado demonstra que o erro de generalização do MR é menor que para o  $\epsilon_r$ ;
- Os coeficientes de correlação dos cinco modelos que predizem o MR são praticamente iguais, variando entre 0,9844 a 0,9878;
- Para o  $\epsilon_r$  o Modelo M1 (15:31:1) foi o de melhor ajuste, com valor do coeficiente de correlação do conjunto de teste de 0,98;
- Considerando apenas o coeficiente de correlação do conjunto de teste, pode-se afirmar que para todos os modelos a variável MR tem melhores ajustes que a variável  $\epsilon_r$ .

A partir das constatações realizadas com as duas medidas de desempenho do modelo neural (MSE e o coeficiente de correlação), pode-se afirmar que a modelagem do MR obteve resultados mais expressivos que a modelagem do  $\epsilon_r$ . Observa-se que, para o ensaio, é indiferente obter uma ou outra variável, sendo que a variável MR é obtida, rapidamente, dividindo a variável tensão desvio pela variável  $\epsilon_r$ .

Com base nessas constatações, decidiu-se utilizar o melhor modelo neural de previsão do MR para ser implementado em uma planilha eletrônica e em uma linguagem *web* para disponibilização e uso na área de pavimentação no estado do Ceará. Porém foi necessário eger o melhor modelo de previsão do MR do ponto de vista estatístico e laboratorial. Dentre os cinco modelos apresentados, praticamente não há diferenças entre os coeficientes de correlação e os MSE deles, podendo qualquer um dos modelos ser selecionado sem grandes prejuízos na generalização. Essas afirmações podem ser vistas na Tabela 6.14, que mostra os coeficientes de correlação e os MSE dos modelos para o MR.

Tabela 6.14 – Topologia e Desempenho dos modelos para o conjunto de teste do MR.

Modelo	Topologia	R	MSE
M1	15:31:1	0,9844	0,003
M2	13:27:1	0,9847	0,004
M3	11:23:1	0,9878	0,003
M4	10:21:1	0,9857	0,004
M5	7:15:1	0,9847	0,004

Fonte: O autor.

Estatisticamente, o modelo mais indicado e que teve o melhor desempenho foi o Modelo M3, com topologia (11:23:1), pois obteve o maior R e o menor MSE. No entanto, a escolha do melhor modelo também depende do esforço laboratorial para obtenção das variáveis de entrada da RNA. Desta maneira, o melhor modelo, ou modelo mais adequado será aquele com menor esforço amostral e de laboratório, já que as medidas de desempenho estão bastante semelhantes. Analisando-se a Tabela 6.14, é possível verificar que o Modelo M1 é composto de 15 variáveis de entrada, o Modelo M2 de 13, o Modelo M3 de 11, o Modelo M4 de 10 e o Modelo M5 de 7 variáveis.

O Modelo M3 é melhor do ponto de vista estatístico e as variáveis utilizadas nele são obtidas em cinco ensaios de laboratório:

- NBR-7181 - Análise Granulométrica de Solos;
- NBR 7182 - Ensaio de Compactação;
- NBR-7180 - Limite de Plasticidade;
- NBR-6459 - Limite de Liquidez;
- NBR-9895/89 - Determinação do CBR.

Os modelos M1 e M2 também utilizam esses mesmos ensaios para previsão do módulo de resiliência. Logo, pode-se afirmar que os três primeiros modelos necessitam do mesmo esforço de laboratório para a obtenção do MR além da necessidade de coletar mais material em campo.

Para previsão do módulo de resiliência a partir dos modelos M4 e M5 são necessários apenas 2 (dois) ensaios de laboratório e menos material na coleta de campo. Os dois ensaios são os seguintes:

- NBR-7181 - Análise Granulométrica de Solos;
- NBR 7182 - Ensaio de Compactação;

Desta maneira, pode-se afirmar, levando em consideração o desempenho do modelo e o esforço amostral e laboratorial, que o melhor modelo é o M4, com topologia (10:21:1), sendo 10 variáveis de entrada, 21 neurônios na camada escondida e 1 neurônio na camada de saída da rede para estimar o valor de MR.

Esse modelo, que obteve o coeficiente correlação de 0,9857 e MSE = 0,004 para o conjunto de teste, foi escolhido para ser o modelo implementado em planilha eletrônica e em linguagem *web* para servir de recomendação de modelo de previsão dos valores MR de solos para o estado do Ceará. Ele poderá ser utilizado nas análises dos dimensionamentos empírico-mecanístico de pavimentos flexíveis da RMF.

#### **6.4.8 Comparação dos Resultados com outros Modelos de Predição de características geotécnicas de Solos**

A partir dos resultados obtidos neste processo de modelagem, é possível realizar comparações com outros modelos de previsão de características de solos de interesse à pavimentação e geotécnico:

- Juang *et al.*,(2002) realizaram a modelagem do OCR a partir de dados de CPT em areias, obtendo acertos da ordem de 84% utilizando técnicas de redes neurais artificiais;
- Viana (2007) estimou o MR de Solos Tropicais Grossos do estado de São Paulo a partir de RNA, encontrando ajustes em torno de 0,92;
- Ferreira (2008) obteve acertos da ordem 96% para predição do MR de solos, britas e misturas de solos com brita e solos com cal usando a técnica de RNA;

- Kuo *et al.*, (2009) modelaram a capacidade de carga para fundações do tipo sapata em solos coesivos utilizando RNA e obtiveram acertos da ordem de 84% a 96%;
- Taskiran (2010) realizou modelagem de CBR utilizando RNA e como dados de entrada granulometria e limites de consistência, onde obteve acertos variando de 61% a 91%;
- Gunaydin *et al.*, (2010) previram resultados de Resistência à Compressão Simples a partir de propriedades físicas do próprio solo, como granulometria e índices físicos, utilizando Regressão Estatística e RNA, onde conseguiram resultados da ordem de 71% a 95% de acertos para diferentes amostras;
- Ribeiro, Da Silva e Barroso (2015) desenvolveram um modelo de previsão da Classificação da AASTHO a partir de características biofísica com coeficiente de acerto de 92,6% utilizando RNA para a Região Metropolitana de Fortaleza - Ceará.

A partir dos resultados reportados nos trabalhos descritos acima e na revisão bibliográfica do Capítulo 4 desta tese, é possível afirmar que os resultados ilustrados nesta seção, para previsão dos valores de MR dos solos do estado do Ceará, são semelhantes ou superiores aos reportados, considerando-os satisfatórios e relevantes.

Assim sendo, afirma-se que um desses modelos, mas preferencialmente o modelo M4, pode ser utilizado para prever o MR dos solos naturais no estado Ceará a partir de ensaios geotécnicos de fácil obtenção, para uso em dimensionamentos empírico-mecanísticos de pavimentos flexíveis.

Acredita-se que os resultados deste trabalho são bastante satisfatórios para a predição do MR de solos do Ceará, podendo apoiar e difundir o uso desse parâmetro nos dimensionamentos empírico-mecanísticos de pavimentos. Contudo, é fato que não se conseguiu obter valores maiores de acurácia, provavelmente, ou pelo fato dos dados não serem suficientes para obter melhores ajustes e deles serem oriundos de diferentes fontes, ou porque pode ter havido alguma inconsistência nos ensaios, ou erros grosseiros na manipulação dos mesmos.

Ainda tentou-se melhorar os resultados dos modelos, aumentando o número de camadas escondidas e o número de neurônios em cada uma, mas os resultados para o conjunto de testes não foram melhorados. Sendo assim, esse problema foi resolvido com uma topologia

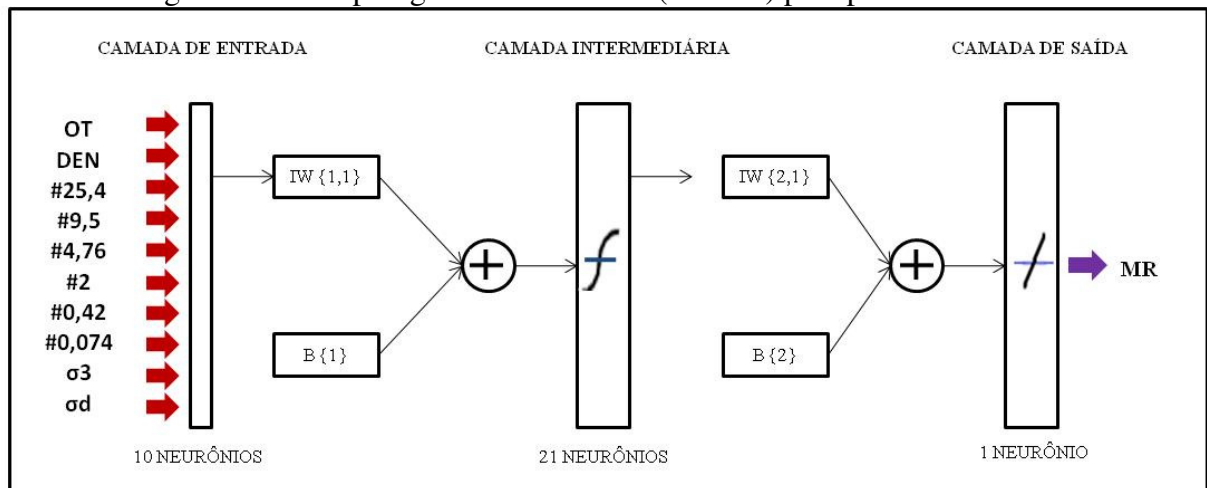


bastante simples e de fácil utilização em uma planilha ou implementação em um algoritmo por meio de uma linguagem de programação.

### 6.5 Apresentação, Uso e Aplicação do Modelo Escolhido

A topologia do modelo escolhido como o mais eficiente para previsão do módulo de resiliência de solos a partir de ensaios geotécnicos tradicionais pode ser melhor observada na Figura 6.38 que ilustra o Modelo M4 (10:21:1).

Figura 6.38 – Topologia do Modelo M4 (10:21:1) para previsão do MR.



Fonte: O autor.

A partir dessa topologia, foi possível extrair os pesos da camada intermediária e da camada de saída da rede M4 para então viabilizar o cálculo do MR fora do NNTOOL/MATLAB. Nas Tabelas 6.15 e 6.16, observam-se os pesos sinápticos ( $w_{ij}$ ) e os vieses ( $b_k$ ) extraídos do *software* de treinamento de redes neurais e que serão utilizados na implementação do modelo na planilha e na *web*.

Tabela 6.15 – Valores dos pesos sinápticos e dos biases entre a camada de entrada e a camada intermediária do modelo.

Camada Intermediária	Camada de Entrada (Variáveis)										
	OT	DEN	#25.4	#9.5	#4.76	#2	#0.42	#0.074	$\sigma_3$	$\sigma_d$	bk
1	0,460480601	-0,373239022	0,577133599	0,450291027	-0,581219723	-0,333018312	1,134249619	-1,574499631	-2,138902943	-2,551591602	3,294286493
2	-3,99275435	2,592651074	-2,142630154	-0,046743637	-0,270547045	-4,092025394	-1,055285093	-2,625565749	-0,046780499	0,13916165	4,404117401
3	1,508926634	-0,043531468	-0,835376021	2,637701503	0,125936637	0,32852223	-2,04252636	-1,376313117	0,067523913	-0,282956378	-1,49891278
4	0,395426268	0,212470071	-0,77720686	2,796278226	-0,861392113	0,394080832	-1,709891856	-0,631678931	0,065423493	-0,400344252	-0,978848301
5	-0,254326204	-0,063353592	0,380578247	-1,240765117	1,029052431	0,064058733	-0,498306068	-0,023711835	0,034406754	-0,287435217	-0,764369457
6	0,230694628	-0,770968315	-2,309380479	2,567626862	0,045199542	-2,995811351	1,69050437	2,589476097	0,133006237	-0,067382949	5,475830484
7	2,210201762	-2,561522837	-0,182409334	1,926867465	-2,511079639	-3,433252465	-0,79318701	-1,772101147	-0,154709971	0,051448977	0,293131049
8	-4,045728578	-2,613394725	0,164030081	1,013668105	-0,579018811	-1,620277796	2,114246786	-0,582615034	-0,207042821	0,270528193	2,527334494
9	0,675380646	1,908031013	-0,55812723	1,387745212	-1,083675111	-0,408603315	2,399108838	0,06264026	0,04432601	-0,083754604	-1,355344325
10	0,954438496	-1,096310472	-1,842869191	1,244109122	0,356584769	0,262320153	-0,807571166	2,295746948	-0,120313194	1,229492288	-0,898362457
11	-0,275012634	1,590281046	-0,657086566	1,996929932	1,625103155	-1,171484868	1,688488941	0,350746192	0,029950594	-0,028570172	-3,394516146
12	-1,063201144	1,919738154	0,833787307	2,631406357	-1,237234701	-3,672626606	5,314346881	-2,200037486	-0,170883788	5,419566967	3,741808304
13	-2,606732348	-2,430484972	-2,895985116	2,426985452	2,192126705	0,35277055	-3,071154999	1,108226103	-0,036035609	0,122392767	0,409938396
14	-1,285575039	1,68622789	-1,653758387	0,459169244	0,284185188	-1,429345804	1,330924165	-0,940829882	-0,099991158	0,573210207	0,108759716
15	-0,11637978	-0,047833065	-0,201985781	1,478608094	-1,700021855	0,993754689	0,214132977	0,191199207	-0,904099272	5,643767023	5,3162962
16	1,404939631	-1,137143123	-1,564387778	-0,272671175	2,243452497	0,772371633	-2,170655065	-0,340047814	0,334875061	-2,817796811	-1,123127856
17	0,1052566	-0,57994984	-1,299141069	1,020206826	0,787514297	-1,66916778	0,429428915	0,45072232	0,033380643	-0,258813792	1,794144432
18	-0,289327848	0,451097991	0,881303942	0,075948235	2,363201354	2,362346658	1,299038353	0,647473962	0,587060345	0,4277311	1,697135295
19	1,232622476	1,089534665	-4,171278647	1,788139824	-1,155471677	5,129823447	-0,583626071	-1,164992421	-0,003874884	0,252862244	-1,605222467
20	4,179859394	-1,633406736	1,929611752	0,871554138	-0,294095313	0,476356163	-3,113255261	-1,475631652	-3,235061754	1,41100159	0,855345899
21	-1,314442539	-2,118482955	1,35040325	-0,128402824	0,134316653	0,371224184	-0,983981654	0,620171584	-0,1607882	-0,229104538	2,419676836

Fonte: O autor.

Tabela 6.16 – Valores dos pesos sinápticos e dos biases entre a camada intermediária e a camada de saída do modelo.

Camada Intermediária	Camada de Saída
1	0,088757298
2	-0,742922073
3	2,467965374
4	-2,079618383
5	5,143708266
6	3,842877935
7	1,168130088
8	0,89343578
9	5,066812581
10	0,455187369
11	-3,273700214
12	0,152869785
13	2,037825877
14	0,806720441
15	-0,566885814
16	-0,174874826
17	-3,52449032
18	0,393887989
19	-1,302933183
20	-0,027643068
21	-1,832007706
bk	3,362675503

Fonte: O autor.

Para implementar o modelo neural em uma planilha eletrônica ou em uma linguagem de programação, é necessário seguir as seguintes etapas e, assim, poder utilizar o modelo já ajustado para o cálculo do MR:

- i. Selecionar as variáveis de entrada do modelo neural escolhido, neste caso o M4, que tem como variáveis de entrada: OT, DEN, #25,4, #9,5, #4,76, #2, #0,42, #0,074,  $\sigma_3$  e  $\sigma_d$ ;
- ii. Normalizar as 10 (dez) variáveis de entrada com valores entre -1 e 1, para atender ao intervalo da função de ativação tangente sigmoideal. Para isso, deve-se utilizar a Equação 5.1 com os valores máximos e mínimos das 10 variáveis de entrada do modelo M4. Esses valores podem ser conferidos na Tabela 6.17.

- iii. Utilizar os pesos sinápticos e biases, mostrados nas Tabelas 6.15 e 6.16, nas Equações 3.1, 3.2 e 3.3 para então calcular as respostas na RNA ajustada para as variáveis de entrada;
- iv. E, por fim, desnormalizar o valor obtido invertendo a Equação 5.1, utilizando e aplicando os valores máximos e mínimos da variável (ver na Tabela 6.17) modelada, neste caso, o módulo de resiliência de solos.

Tabela 6.17 – Valores máximos e mínimos das variáveis do modelo neural M4 (10:21:1).

Variável	OT	DEN	#25,4	#9,5	#4,76	#2	#0,42	#0,074	$\sigma_3$	$\sigma_d$	MR
Máximo	17	2,19	100	100	100	100	89	71	0,137	0,412	50
Mínimo	4,2	1,65	80	40	22	18	14	5	0,021	0,021	2038

Fonte: O autor.

A função utilizada para ativação deste modelo foi a tangente sigmóide que é representada na Equação 3.3, mas é detalhada na Equação 6.5, é o tipo de função de ativação muito utilizado em redes neurais artificiais. É definida como uma função crescente que apresenta um balanço entre o comportamento linear e não linear.

$$\varphi = \frac{2}{(1 + e^{(-2 \times V_k)}) - 1} \quad (6.5)$$

Com intuito de exemplificar a utilização prática do modelo neural gerado nesta pesquisa, foram caracterizados dois solos distintos coletados no município de Caucaia para servir de exemplo de cálculo do MR na planilha eletrônica gerada e na aplicação *web*. Também foram realizados os ensaios de módulo de resiliência para esses dois solos, a fim de realizar uma comparação e aferir a acurácia do modelo M4. As características dos dois solos para entrada na planilha podem ser observadas na Tabela 6.18.

Tabela 6.18 – Valores dos ensaios de granulometria e massa específica seca máxima para os solos testados.

Variável	OT	DEN	#25,4	#9,5	#4,76	#2	#0,42	#0,074
Solo 1	10,74	1,97	100	93	90	81	54	27
Solo 2	8	2,16	88	57	53	49	26	8

Fonte: O autor.

Foram utilizados para calcular os valores do módulo de resiliência os pares de tensões do ensaio, a partir da planilha gerada, que também será disponibilizada juntamente com este trabalho. Desta forma, foram obtidos os valores de MR em função dos pares de tensão, sendo seguido o procedimento indicado acima para utilizar a planilha com os pesos extraídos do modelo escolhido.

Aqui será mostrado um exemplo do uso da planilha apenas para um par de tensão, no qual  $\sigma_3 = 0,103$  MPa e  $\sigma_d = 0,309$  MPa, o qual o módulo de resiliência do ensaio foi MR = 290 MPa para o solo 1. Porém apresenta-se também nas Figuras 6.39 e 6.40, os gráficos dos valores de MR calculados pela planilha e os valores ensaiados, para os pares de tensão.

Nas Tabelas 6.19 e 6.20, são mostrados os valores das saídas resultantes da aplicação das Equações 3.1, 3.2, 3.3, 5.1 e 6.5, utilizando os pesos sinápticos ( $w_{ki}$ ) e biases ( $b_k$ ) mostrados nas Tabelas 6.16 e 6.17 e como dados de entrada os valores das variáveis do solo 1 (ver Tabela 6.18) com os pares de tensões descritos no parágrafo anterior.

Tabela 6.19 – Valores das saídas dos neurônios da camada intermediária para o solo 1.

y1	y2	y3	y4	y5	y6	y7
0,967703253	0,790534468	0,196880089	-0,059023792	-0,604273910	0,990936212	-0,967351420
y8	y9	y10	y11	y12	y13	y14
0,962111112	-0,882886010	-0,951820264	-0,929921338	0,999999515	0,154464110	-0,681709450
y15	y16	y17	y18	y19	y20	y21
0,999999631	-0,976673103	0,559253780	0,999988987	-0,948439451	0,993869895	0,995968614


Fonte: O autor.

Tabela 6.20 – Valores da saída do neurônio da camada de saída e desnormalizada (valor real).

y1	Saída Desnormalizada (MPa)
-0,635001282	312


Fonte: O autor.

Figura 6.39 – Gráfico dos valores de MR do ensaio × RNA para o solo 1.



Fonte: O autor.

Figura 6.40 – Gráfico dos valores de MR do ensaio × RNA para o solo 2.



Fonte: O autor.

Verificou-se nos gráficos (ver Figuras 6.39 e 6.40) calculado esperado que o r-quadrado para o solo 1 foi  $R = 0,964$  e para o solo 2 foi  $R = 0,976$ , valores esses que

confirmam os ajustes do conjunto de testes do Modelo Neural M4, escolhido como o modelo de melhor desempenho, e aqui implementado e gerado os valores para os gráficos mostrados.


Desta maneira, é possível concluir que esse modelo representa bem os valores calculados nos ensaios de módulo de resiliência para os solos no estado do Ceará. No entanto, decidiu-se fazer uma verificação da sensibilidade das diferenças entre os valores ensaiados e calculados pela planilha eletrônica com os pesos do Modelo M4.

Para isso, resolveu-se fazer uma análise numérica, no regime elástico-linear, do comportamento do solo 1 como subleito de um pavimento, comparando o valor da resposta estrutural do MR ensaiado, para o par de tensão  $\sigma_3 = 0,103$  MPa e  $\sigma_d = 0,309$  MPa, com o valor da resposta estrutural do MR calculado pela planilha para o mesmo par de tensão.

Desta forma, criaram-se duas estruturas típicas de pavimento com intuito de se realizar duas análises distintas, sendo um pavimento com revestimento de CBUQ (Concreto Betuminoso Usinado à Quente) e outro com revestimento TSD (Tratamento Superficial Duplo), onde as duas estruturas foram analisadas duas vezes, variando apenas o valor do módulo do subleito, calculado e o ensaiado.

A estrutura do primeiro pavimento utilizado para a comparação tem um revestimento de CBUQ com espessura de 10 cm e  $MR = 3000$  MPa, uma base composta de solo-brita com espessura de 20 cm e com  $MR = 400$  MPa. Já o subleito ensaiado tem o  $MR = 290$  MPa e o subleito calculado tem o  $MR = 312$  MPa, extraído da Tabela 6.20. Os coeficientes de Poisson adotados para a análise desta pesquisa foram:  $\nu = 0,30$  para o revestimento,  $\nu = 0,35$  para a base e  $\nu = 0,40$  para o subleito. A Figura 6.41 apresenta a estrutura do pavimento com CBUQ utilizado com suas propriedades e características.


Figura 6.41 – Estrutura e propriedades do pavimento com CBUQ utilizado para análise numérica.



Fonte: O autor.

O segundo pavimento tem revestimento do tipo TSD com espessura de 2,5 cm e  $MR = 500$  MPa, uma base composta de solo-brita com espessura de 20 cm e com  $MR = 400$  MPa para as mesmas condições de subleito do pavimento com CBUQ com os mesmos coeficientes de Poisson. A Figura 6.42 apresenta a estrutura do pavimento com TSD utilizado com suas propriedades e características.

Figura 6.42 – Estrutura e propriedades do pavimento com TSD utilizado para análise numérica.



Fonte: O autor.


Para realização das análises mecânicas, utilizou-se o *software* CAP3D com as características já apresentadas para os dois pavimentos e para os dois valores do módulo de resiliência do subleito. O carregamento considerado para esta análise corresponde à carga de uma roda do eixo simples padrão, o qual é composto de uma tensão uniforme com valor de 550 kPa a ser aplicada em uma área de formato circular, com raio igual a 0,108 m.

Para realização da análise proposta, gerou-se uma malha pelo módulo gerador de malha PMG (*Pavement Mesh Generator*) do CAP3D, nele gerou-se uma malha mista, com elementos finitos e infinitos. Para as camadas do revestimento asfáltico e de base, foram modelados apenas elementos finitos (Q8), enquanto para o subleito geraram-se elementos finitos (Q8) e infinitos (L6).

No caso desta tese, optou-se por apresentar apenas a distribuição das tensões verticais ao longo da estrutura para os dois pavimentos. Também se fez a análise da tensão vertical no topo do subleito para os dois casos. É possível observar, nas Figuras 6.43 e 6.44, a distribuição das tensões verticais ao longo das duas estruturas, bem como a tensão de compressão no topo do subleito modelado e ensaiado para os dois pavimentos.

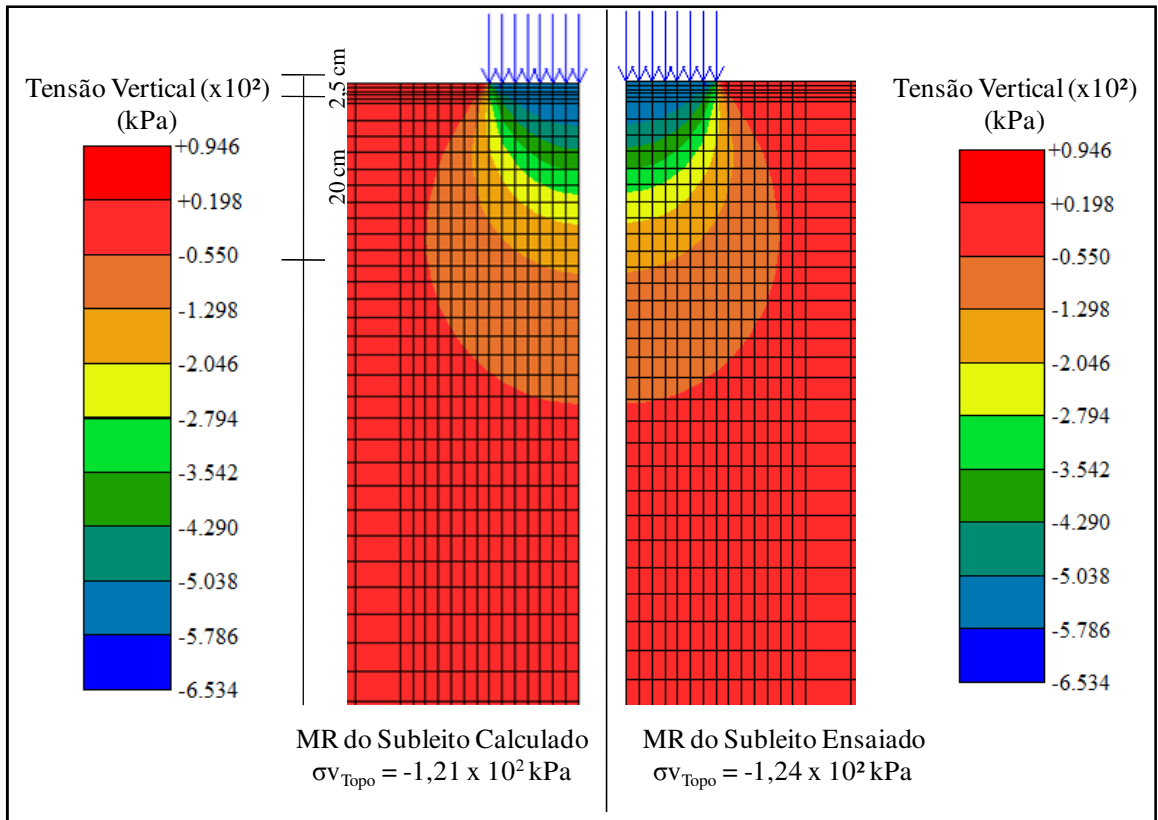


Figura 6.43 – Distribuição das tensões verticais (kPa) no pavimento com CBUQ analisado para o módulo de resiliência do subleito modelado e ensaiado.



Fonte: O autor.

Figura 6.44 – Distribuição das tensões verticais (kPa) no pavimento com TSD analisado para o módulo de resiliência do subleito modelado e ensaiado.



Fonte: O autor.

Observando as Figuras 6.43 e 6.44, pode-se afirmar que as análises realizadas pelo CAP3D apresentaram valores de tensões verticais no topo do subleito ensaiado e modelado muito próximas tanto no pavimento mais robusto, com revestimento de CBUQ, como no pavimento mais delgado, com revestimento TSD.

Fazendo uma comparação entre a distribuição das cargas nos dois pavimentos, observa-se que o bulbo de tensões, praticamente, comporta-se igual nas duas comparações. Para o pavimento com revestimento CBUQ, no topo do subleito calculado pela planilha a tensão vertical máxima foi de  $\sigma_v = -60,1$  kPa. Já no topo do subleito ensaiado, no equipamento triaxial de carga repetida, a tensão vertical máxima foi  $\sigma_v = -58,6$  kPa.

No caso do pavimento com revestimento TSD, no topo do subleito calculado pela planilha a tensão vertical máxima foi de  $\sigma_v = -121$  kPa. Já no topo do subleito ensaiado, no equipamento triaxial de carga repetida, a tensão vertical máxima foi  $\sigma_v = -124$  kPa.

Percebe-se que as diferenças nas tensões que se distribuem ao longo das camadas e dos seus valores no topo do subleito são bastante pequenas. Tendo 1,4 kPa e 3 kPa de diferença entre o modelado e o ensaiado, respectivamente para o pavimento com CBUQ e com TSD. Essas diferenças nas tensões podem ser consideradas desprezíveis no dimensionamento e análise das camadas dos pavimentos. Dessa maneira, avalia-se que o Modelo Neural M4 tem uma boa representação para a previsão do módulo de resiliência dos solos na região estudada.

## 6.6 Considerações Finais

De uma maneira geral, os resultados obtidos nesta pesquisa demonstram que a técnica de redes neurais artificiais tem uma boa capacidade de estimar de maneira eficiente os valores do módulo de resiliência dos solos naturais no estado do Ceará, tendo como base os dados de ensaios geotécnicos simples e convencionais na área rodoviária. Essa afirmação se torna evidente quando considerados os baixos valores de erros e o alto índice de acertos dos valores nos conjuntos de testes dos modelos gerados.

Também fica claro que a ocorrência dos erros no conjunto de testes diminui a capacidade de generalização da rede. Isso ocorre devido à qualidade e quantidade das amostras estudadas serem, talvez, insuficientes para diminuir o erro, podendo haver presença de ruídos, que prejudicaram o treinamento e a validação do modelo neural. Mesmo considerando-se que houve a preocupação em filtrar os dados e analisar inconsistência,

algumas amostras poluídas podem ter sido utilizadas na modelagem. Contudo, os erros dos conjuntos de teste são considerados baixos e satisfatórios para o problema estudado.

Pôde-se observar que a simples comparação dos valores ensaiados com os valores calculados pelo modelo neural poderia não refletir de forma adequada à influência do erro no dimensionamento de pavimentos. Por isso a importância da quantificação da influência do erro a partir da análise mecânica com o CAP3D.

Os resultados apresentados permitiram verificar que a influência do erro de predição do MR na distribuição e propagação das tensões verticais nas camadas do pavimento e no subleito era muito pequena. A partir desta constatação, acredita-se que a estrutura gerada no dimensionamento de pavimentos utilizando a previsão do módulo de resiliência dos solos pelo modelo neural M4 seria praticamente idêntica à estrutura com o valor do módulo de resiliência ensaiado pelo equipamento triaxial de cargas repetidas.

Com isso, não é exagero afirmar que o Modelo Neural M4 pode ser utilizado para substituir, em parte, a realização do ensaio triaxial de cargas repetidas para solos dentro do estado do Ceará pelo menos para o subleito, podendo ser indicado como alternativa à realização do ensaio para níveis de dimensionamentos de pavimentos rodoviários, com cargas atuantes correspondentes a níveis de tráfego de leve a pesados.

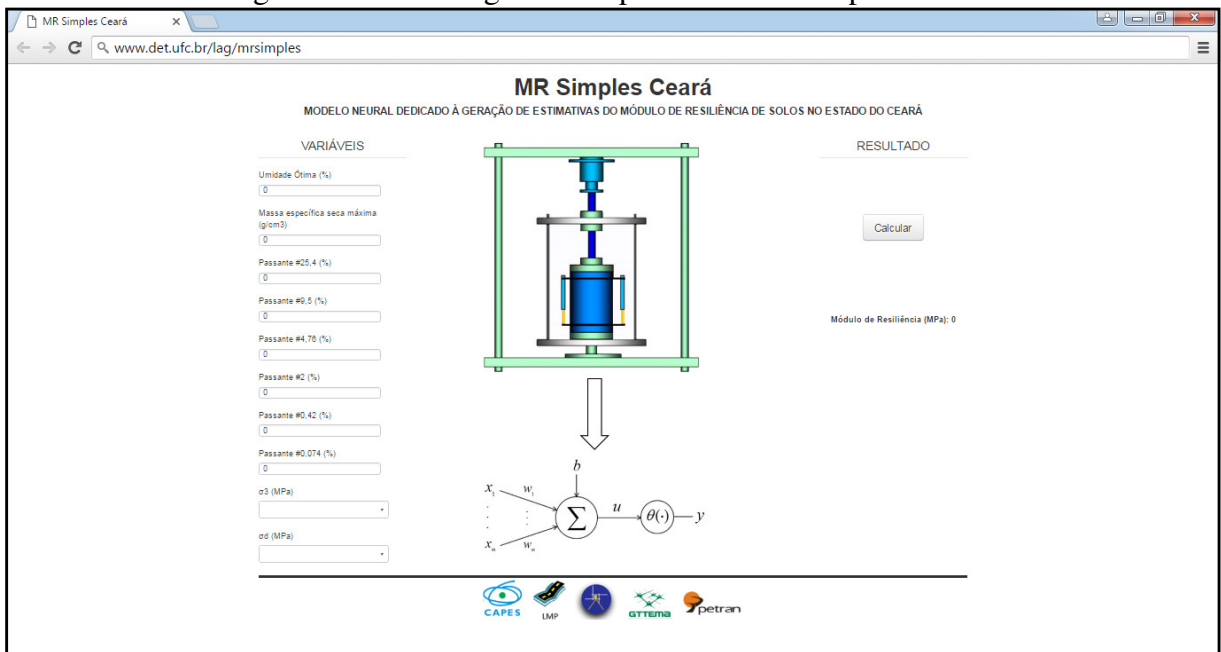
Desta forma, indica-se a incorporação deste modelo neural dentro dos *softwares* de dimensionamentos de pavimentos empírico-mecanísticos em desenvolvimento no Brasil, como forma de calcular o MR para solos quando da ausência de informações mecânicas dos materiais para subleito e sub-base de pavimentos flexíveis dentro da área estudada.

Nesta tese estão disponibilizados os pesos e os valores máximos e mínimos das variáveis de entrada do modelo escolhido. Isto torna possível a incorporação do Modelo M4 a qualquer *software* bastante simples, precisando apenas aplicar as equações mostradas no Capítulo 3. Contudo, o Modelo Neural M4 já está disponibilizado implementado em uma planilha eletrônica adicional a esta pesquisa e na linguagem *web Javascript*, tendo o seu uso facilitado através do sítio do PETRAN na página do Laboratório de Geomática Aplicada (LAG) ou no *link* ([metro.det.ufc.br/rna](http://metro.det.ufc.br/rna)).

A ferramenta *web*, que tem as mesmas funções da planilha eletrônica implementada no Modelo M4, funciona de forma rápida e prática. Basta inserir os dados das variáveis de entrada, selecionar o par de tensão para o qual se quer prever o MR, clicar no botão Calcular e observar o resultado do valor do módulo de resiliência para os dados fornecidos.

Ao aplicativo, deu-se o nome de *MR Simples Ceará* e poderá ser utilizado por qualquer pessoa com acesso a *internet*, de qualquer local do mundo, desde que aceite os termos e condições de uso do aplicativo. Assim como se fez com a planilha, decidiu-se mostrar o exemplo de uso do aplicativo para prever o valor de MR para o solo 1 para o par de tensão  $\sigma_3 = 0,103$  MPa e  $\sigma_d = 0,309$  MPa. As Figuras 6.45 e 6.46 apresentam o aplicativo e demonstram a operação de previsão a partir dele.

Figura 6.45 - Visão geral do Aplicativo MR Simples Ceará.



Fonte: O autor.

Figura 6.46 – Predição do MR pelo Aplicativo MR Simples Ceará.

**MR Simples Ceará**  
 MODELO NEURAL DEDICADO À GERAÇÃO DE ESTIMATIVAS DO MÓDULO DE RESILIÊNCIA DE SOLOS NO ESTADO DO CEARÁ

**VARIÁVEIS**

Unidade Ótima (%)  
 10,74

Massa específica seca máxima (g/cm³)  
 1,97

Passante #25.4 (%)  
 100

Passante #0.5 (%)  
 93

Passante #4.75 (%)  
 90

Passante #2 (%)  
 81

Passante #0.42 (%)  
 54

Passante #0.075 (%)  
 27

c3 (MPa)  
 0,103

od (MPa)  
 0,309

**RESULTADO**

Calcular

Módulo de Resiliência (MPa): 312

Diagram illustrating the neural network structure:  $x_1, \dots, x_n$  are inputs,  $w_1, \dots, w_n$  are weights,  $b$  is bias,  $\sum$  is summation,  $u$  is the net input,  $\theta(\cdot)$  is the activation function, and  $y$  is the output.

Logos: CAPES, LMP, PETRAN

Fonte: O autor.

## CAPÍTULO 7

### CONCLUSÕES E RECOMENDAÇÕES

#### 7.1 Considerações Iniciais

A tese proposta teve como objetivo principal contribuir para a previsão do comportamento mecânico dos solos no estado do Ceará, gerando-se estimativas de módulo de resiliência que possam ser usadas em alguns níveis de dimensionamento empírico-mecânico de pavimentos flexíveis.

Com isso ajudar na difusão do uso desse método, através da facilitação na obtenção de MR, ocasionando uma redução de custos na execução de ensaios triaxiais de cargas repetidas ou fazer projetos sem a necessidade desse ensaio para um determinado nível de cargas/tensões no dimensionamento.

A geração dos modelos desenvolvidos baseou-se na confecção de banco de dados primários, por meio de coleta e ensaios de laboratório. Para tanto, foi selecionada a RMF e áreas adjacentes como área de estudo dentro do estado do Ceará, por ser economicamente a região mais importante do estado do Ceará, portanto, onde ocorre a maioria das intervenções na infraestrutura, incluindo as obras rodoviárias.

Este estudo procurou deixar a sua parcela de contribuição no reconhecimento do comportamento mecânico dos solos dessa região no estado do Ceará, de forma rápida, econômica, no intuito de trazer benefícios para as atividades de projeto, construção e gerenciamento de rodovias da região. Acredita-se que este trabalho contribuiu ainda com a implementação de uma metodologia, de fácil replicação, para que possa ser empregada em outras áreas de estudo onde se tenha interesse em conhecer os solos sob a ótica da pavimentação.

Espera-se que este estudo venha auxiliar na facilitação do reconhecimento prévio do comportamento mecânico dos solos para finalidades de pavimentação no estado do Ceará e no Brasil. Espera-se também que os estados utilizem os métodos de dimensionamento empírico-mecânico de maneira a propiciar a construção e conservação de rodovias de maneira mais econômica, segura, e com menores impactos socioambientais. Desta forma, os recursos públicos serão poupados, podendo ser destinados a outros programas e setores mais carentes de nossa sociedade.

É fato que muito da demora na difusão do método de dimensionamento de pavimentos flexíveis que usem métodos empírico-mecanísticos decorre da dificuldade na obtenção do módulo de resiliência, quer seja pela falta de equipamentos, quer seja pela complexidade do ensaio, que fatalmente demanda recursos humanos capacitados. Espera-se que através dos modelos propostos, com o uso apenas de ensaios geotécnicos básicos, possíveis de se obter em qualquer laboratório, mesmo em campo, tenha-se ajudado na difusão e massificação destes métodos de dimensionamento.

## **7.2 Principais Constatações**

### ***7.2.1 Quanto ao Método e a Modelagem Neural***

Embora tenham sido empreendidos esforços para se escolher as melhores topologias neurais, de sorte a oferecer um erro mínimo, em um baixo tempo de processamento, certamente não foi possível ao longo do trabalho esgotar a imensa combinação de possibilidades entre topologias e parâmetros de treinamento. Desta forma, pode-se utilizar, para a predição dos resultados do ensaio de módulo de resiliência, as topologias apresentadas no Capítulo 6, mas deve-se considerar que potencialmente podem existir outras topologias que possuam um erro menor para o conjunto de teste, não sendo o procedimento aqui adotado um trabalho esgotado.

O melhor modelo, o M4, apresentou um grau de precisão relevante, com um coeficiente de correlação de 0,9857 e erro medido pelo MSE da ordem de 0,004 para o conjunto de testes. A metodologia apresentada neste trabalho demonstrou que é possível produzir modelos de predição dos valores do ensaio de módulo de resiliência de uma determinada região, neste caso a Região Metropolitana de Fortaleza e municípios circunvizinhos, de forma rápida e econômica que subsidie o conhecimento prévio das características resilientes dos solos para emprego em pavimentação e obras viárias a partir de um modelo de previsão.

### ***7.2.2 Quanto às incertezas dos modelos gerados***

Os modelos de previsão do ensaio de módulo de resiliência modelados neste trabalho tiveram os níveis de acertos considerados satisfatórios e relevantes, sendo de 0,984 a

0,9878 para os melhores modelos de previsão do  $\epsilon_r$  e do MR, considerando o coeficiente de correlação (R) como medida ajuste.

Outra medida de desempenho utilizada foi o MSE do conjunto de teste que tem 20% do conjunto de dados disponível para cada modelo estudado. Quando verificado esse valor para os melhores modelos, variaram de 0,004 a 0,0001, sendo considerados erros muito pequenos, dada a quantidade de dados disponíveis.

Comparando estes resultados com os de outros modelos similares de estimativas de parâmetros geotécnicos aplicados à pavimentação ou à geotecnia, observou-se que os modelos gerados têm desempenho igual ou superior aos encontrados na literatura consultada.

### ***7.2.3 Quanto ao uso de estimativas de MR na Pavimentação***

Nos Capítulos 3 e 4, foi possível verificar que os métodos de dimensionamentos empírico-mecanístico de pavimentos pelo mundo utilizam correlações e modelos para previsão de MR de solos. Desta forma, esta tese apresenta resultados expressivos de predição do módulo de resiliência para ser utilizado nos métodos de dimensionamentos empírico-mecanístico dentro do estado Ceará.

Os métodos de dimensionamentos empírico-mecanísticos de pavimentos, necessitam de valores do MR para realização das análises de tensões e deformações no projeto da superestrutura viária. Esses valores podem ser de três formas: MR médio, MR para um determinado par de tensão, nas análises elástico-linear, e ainda valores das constantes de regressão dos modelos de MR com os pares de tensões, para as análises elástico-não linear.

Então, a partir da planilha eletrônica e do aplicativo *web* nos quais foi implementado o Modelo Neural M4, gerado neste trabalho, pode-se calcular o MR para todos os pares de tensões do ensaio de Módulo de Resiliência e obter as constantes de regressão para um modelo que melhor descreva aquele solo, ou ainda utilizar as médias dos MR para todos os pares de tensões, ou um valor qualquer de módulo para um dos 18 pares de tensão do ensaio.

### ***7.2.4 Quanto às variáveis explicativas dos modelos***

Para previsão do MR, inicialmente trabalhou-se com as variáveis: umidade ótima de compactação (OT), massa específica seca máxima (DEN), CBR, expansão (EXP), limite de liquidez (LL), índice de plasticidade (IP), percentual que passa nas peneiras (25,4 mm, 4,76 mm, 2 mm, 0,42 mm, 0,074 mm), classificação da AASTHO, tensão confinante e tensão



desvio. A partir das matrizes de correlação, pôde-se verificar a importância de cada variável para prever os resultados do ensaio de módulo de resiliência. No total, eram 15 variáveis de entrada (explicativas) obtidas a partir de 5 ensaios geotécnicos de laboratório.

Para o modelo de melhor desempenho (Modelo Neural M4), dentre os testados, conseguiu-se diminuir a quantidade de variáveis explicativas para 10, com suas obtenções a partir de apenas 2 ensaios geotécnicos de laboratório. Essas variáveis foram: umidade ótima de compactação (OT), massa específica seca máxima (DEN), percentual que passa na peneira 25,4 mm, percentual que passa na peneira 9,5 mm, percentual que passa na peneira 4,76 mm, percentual que passa na peneira 2 mm, percentual que passa na peneira 0,42 mm, percentual que passa na peneira 0,074 mm, tensão confinante e tensão desvio.

### **7.2.5 Quanto à generalização dos modelos neurais**

Os diversos modelos neurais de estimativas do ensaio de módulo de resiliência gerados para o estado do Ceará tiveram um conjunto de dados utilizados para generalização, este conjunto foi dado o nome de conjunto de testes.

Os acertos desses conjuntos são utilizados para generalizar os modelos neurais para a área de estudo. Como o modelo escolhido como mais eficiente para prever o MR foi o Modelo Neural M4 com topologia (10:21:1), ele apresentou o MSE = 0,004 e o R = 0,9857, logo a generalização para a área de estudo tem essas duas medidas de desempenho.

Ainda foi possível demonstrar a capacidade de generalização do modelo com os dois solos ensaiados *a posteriori*, que para previsão do MR de um ensaio completo teve a correlação (R = 0,964) para o solo 1 e (R = 0,976) para o solo 2, confirmando assim a tendência de generalização do Modelo M4 implementado na planilha eletrônica.

### **7.2.6 Quanto aos modelos de regressão linear para previsão do MR**

Os índices de acertos para os modelos de regressão linear múltipla que previram o MR para o banco de dados completo ficaram com coeficiente de ajuste ( $R^2 = 0,74$ ). Esse modelo também pode ser utilizado para prever o MR de solos da área de estudo, pois ficou com um bom coeficiente de acerto, esse fato culminou para o melhoramento da precisão de estimativa a partir dos modelos neurais.

É possível ver na literatura exposta no capítulo 4 que modelos com ajustes inferiores a esse são utilizados para calcular o módulo de resiliência de solos, no caso de dimensionamentos para níveis de tensões/cargas mais baixas.

### **7.2.7 Quanto aos modelos de previsão do MR Regionalizados**

Conforme visto na literatura indicada neste trabalho, verifica-se que cada vez mais os pesquisadores vêm criando novos modelos de previsão do módulo de resiliência de solos regionalizados, sendo assim esses modelos melhores representam as áreas estudadas. No mesmo sentido, este trabalho também buscou criar modelos de predição do MR para o estado do Ceará, sendo assim também um modelo regional, onde a precisão das estimativas é verdadeira para os tipos de solos ocorrentes nessa região, dada as condições regionais de formação e desenvolvimento dos solos.

### **7.3 Recomendações e Sugestões para Trabalhos Futuros**

A partir dos resultados obtidos e com base no conhecimento adquirido ao longo do desenvolvimento desta pesquisa, percebeu-se que existe a necessidade de trabalhos que venham a complementar este ou ainda melhorar e expandir a área de estudo. Assim, recomenda-se realização das seguintes pesquisas:

- a) Sugere-se que os resultados obtidos neste estudo possam ser usados como alternativa à realização do ensaio de módulo de resiliência, para posterior dimensionamento de pavimentos;
- b) Sugere-se ainda que os resultados obtidos nesse estudo possam ser usados para apoiar a gestão das vias pavimentadas, a partir do melhor entendimento dos subleitos, que servem como suporte das mesmas, podendo utilizar a planilha implementada ou o aplicativo, a serem utilizados como modelo de retro-análise dos MR do subleito à época da construção, bem como ajude na obtenção de materiais adequados às suas manutenção;
- c) Recomenda-se, para trabalhos futuros, a coleta de solos em outras regiões do estado do Ceará, de forma a buscar melhorar o modelo com ensaios de solos modelados em pontos espacialmente mais distribuídos. Com objetivo

de confrontar os resultados de laboratório com os resultados preditos pelos modelos e verificar a sua precisão;

- d) Recomenda-se aos órgãos rodoviários que construam uma base de dados com as informações geotécnicas das rodovias já construídas e/ou projetadas. Essa ação facilitaria os trabalhos atuais e futuros a serem executados nas áreas de interesse e ainda subsidiaria um futuro trabalho do tipo aqui apresentado para uma outra região.
- e) Sugere-se a aplicação dessa metodologia para outras regiões do Brasil ou mesmos expandindo o polígono da RMF para todo o estado do Ceará, de maneira que se possa validar o modelo aqui gerado ou melhorar a sua capacidade de generalização;
- f) Sugere-se que este modelo possa ser utilizado como referência na construção de segmentos experimentais e rodovias de baixos volumes de tráfego pelo menos para o subleito;
- g) Sugere-se a integração de feições biofísicas como variáveis de entrada de novos modelos para previsão do MR. Sabe-se que atualmente há um volume muito grande de dados e informações espaciais disponíveis na *web* de forma gratuita, tanto tabular quanto em formato de imagens vetoriais e matriciais, que podem ser usados em diferentes análises e modelagens.
- h) Sugere-se a utilização de outras técnicas de modelagem para prever o MR, Autômatos Celulares, Análise de Componentes Principais, Redes Neurais Auto-Organizáveis (Mapas de Kohonen), com a finalidade de produzir mapas de MR.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AASHTO (2004) Mechanistic-Empirical Pavement Design Guide: Of New and Rehabilitated Pavement Structures – Final Report. NCHRP. American Association of State Highway and Transportation Officials. United States of America.
- AASHTO (2008) Mechanistic-Empirical Pavement Design Guide-A Manual of Practice. American Association of State Highway and Transportation Officials. USA.
- ABU-KIEFA, M. A. (1998). General regression neural networks for driven piles in cohesion less soils. *J. Geotech. Geoenv. Engrg., ASCE*, Vol.123, No.12, (December 1998), pp. 1177–1185, ISSN 1090-0241
- AGRAWAL, G.; WEERARATNE, S. & KHILNANI, K. (1994). Estimating clay liner and cover permeability using computational neural networks, *Proc., First Congress on Computing in Civil Engrg.*, pp. 20-22, Washington, USA.
- ALLEN, J. and M.R. THOMPSON, “Resilient Response of Granular Materials Subjected to Time Dependent Lateral Stresses,” *Transportation Research Record 510*, Transportation Research Board, National Research Council, Washington, D.C., 1974, pp. 1–13.
- AMERICAN ASSOCIATION OF STATE HIGHWAY AND TRANSPORTATION OFFICIALS. *Guide for design of pavement structures 1993*. Washington, D.C, 1993.
- ARANOVICH, L. A. S., (1985), *Desempenho de Pavimentos de Baixo Custo no Estado do Paraná*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- ARAUJO, A. F. *Avaliação de misturas de solos estabilizados com Cal, em pó e em pasta, para aplicação em rodovias do Estado do Ceará*. 2009. 175 f. Dissertação (Mestrado em Engenharia de Transportes) - Universidade Federal do Ceará, Fortaleza, 2009.
- ASPHALT INSTITUTE, *Research and Development of the Asphalt Institute’s Thickness Design Manual*, 9th ed., Manual Series No. 1, College Park, Md., 1982.
- BARKSDALE, R. D., HIKCS, R. G., (1973), “Material Characterization and layered theory for use in fatigue analyses”. In: *Special Report n.140*, HRB, Washington, DC.

- BARREIRA, L. 85% mais indústrias no Cipp. Disponível em: <<http://www.ipece.ce.gov.br/noticias/85-mais-industrias-no-cipp>>. Acesso em: 10/11/14.
- BARROSO, S. H. A. (2002) Estudo dos solos da região metropolitana de Fortaleza para aplicação na Engenharia Rodoviária. Tese de Doutorado, EESC-USP, Departamento de Transportes, EESC/USP.
- BASTOS, J. B. S. Influência da variação da umidade no comportamento de pavimentos da região metropolitana de Fortaleza. 2013. 164 f. Dissertação (Mestrado em Engenharia de Transportes) - Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2013
- BEALE, M. H.; HAGAN, M. T., DEMUTH H. B (2010), Neural Network Toolbox™ 7 - User's Guide.
- BEHIRY A. E. A. E. M. Characterization of the Layered Pavement by Modelling and Calibration of Resilient Modulus. American Journal of Civil Engineering. Vol. 2, No. 3, 2014, pp. 74-86.
- BENEVIDES, S. A. S. (2000). Análise comparativa dos métodos de dimensionamento dos pavimentos asfálticos: Empírico do DNER e da Resiliência da COPPE/UFRJ em rodovias do estado do Ceará. Tese de Mestrado. Universidade Federal do Rio de Janeiro, COPPE/UFRJ. Rio de Janeiro, RJ.
- BERG, R.L., S.R. BIGI, J.A. STARK, and G.D. DURELL, Resilient Modulus Testing of Materials from Mn/Road Phase 1, Minnesota Road Research Project, CRREL Report 96-19, U.S. Army Cold Regions Research and Engineering Laboratory, Hanover, N.H., 1996.
- BOCANEGRA, C. W. R. (2002) Procedimentos para tornar mais efetivo o uso de Redes Neurais Artificiais em planejamento de transportes. Dissertação de Mestrado. USP-São Carlos, Departamento de Engenharia de Transportes. São Carlos-SP.
- BOULAINÉ, J. (1975), Géographie des soils. Paris, Presses Universités de France.
- BOUNDS, D.G.; LLOYD, P.J.; MATHEW, B.; and WADDELL, G. (1988). A multilayer Perceptron network for the diagnosis of low back pain, Proc. of 2nd IEEE Annual Int'l Conf. on Neural Networks, pp. 481-489, San Diego, NJ, USA, June 21-24, 1988,

- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. (2000) *Redes Neurais Artificiais: teoria e aplicações*. Editora LTC, Rio de Janeiro, RJ, 2000.
- CARDOSO, S. H. (1988). Estudo das deformações resilientes de solos lateríticos da região de Brasília. 23ª Reunião Anual de Pavimentação. ABPV v.1. Florianópolis, SC. p. 203-219.
- CARMICHAEL, R.F., III and E. STUART, "Predicting Resilient Modulus: A Study to Determine the Mechanical Properties of Subgrade Soils," *Transportation Research Record 1043*, Transportation Research Board, National Research Council, Washington, D.C., 1985, pp. 145–148.
- CHAVES, F.J. (2000), *Caracterização Geotécnica de Solos da Formação Barreiras da Região Metropolitana de Fortaleza para Aplicação em Obras Rodoviárias*. Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil. COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- CHESTER, D.L. (1990). Why two hidden layers are better than one, *Proc. of 4th IEEE Annual Int'l Conf. on Neural Networks*, pp. 1.265-1.268, Washington, DC, NJ, USA, Jan. 15-19.
- ÇOLERI E., "Relationship Between Resilient Modulus And Soil Index Properties Of Unbound Materials", Master Of Science in Civil Engineering Department, The Graduate School of Natural and Applied Sciences of Middle East Technical University, 2007.
- CYBENKO, G. (1989). Approximation by superpositions of a sigmoidal function, *Mathematics of Control Signals and Systems*, Vol.2, No.4, pp. 303-314.
- DA SILVA, A. N. R., RAMOS, R. A. R., SOUZA, L. C. L., RODRIGUES, D. S. e MENDES, J. F. G. (2004) *SIG: uma plataforma para introdução de técnicas emergentes no planejamento urbano, regional e de transportes: uma ferramenta 3D para análise ambiental urbana, avaliação multicritério, redes neurais artificiais*. Ed. dos Autores, São Carlos, SP.
- DA SILVA, C. A. U. (2003) *Um método para estimar observáveis GPS usando Redes Neurais Artificiais*. Tese de Doutorado, EESC-USP, Departamento de Transportes, S. Carlos, SP.
- DANIELS, R.B., HAMMER, R.D., (1992), *Soil Geomorphology*. Wiley, NY.

- DANTAS NETO, S. A.; SILVEIRA, M. V.; AMANCIO, L.B.; ANJOS, G. J. M. Pile Settlement Modeling with Multilayer Perceptrons. *The Electronic Journal of Geotechnical Engineering*, v. 19, p. 4517-4528, 2014.
- DEPARTAMENTO NACIONAL DE INFRAESTRUTURA DE TRANSPORTES - DNIT (2010). Pavimentação - Solos - Determinação do módulo de resiliência – Método de ensaio. Rio de Janeiro
- DNIT (2006), Manual de Pavimentação, 2006.
- DUNLAP, W.S., A Report on a Mathematical Model Describing the Deformation Characteristics of Granular Materials, Technical Report 1, Project 2-8-62-27, Texas Transportation Institute, Texas A&M University, CollegeStation, 1963.
- EDIL, T., C. BENSON, and A. SAWANGSURIYA, Resilient Behavior of Unsaturated Subgrade Soils, Interim Report to University of Minnesota, University of Wisconsin–Madison, Dec. 2006.
- ELLIOT, R.P., S.I. THORTON, K.Y. FOO, K.W. SIEW, and R. WOODBRIDGE, Resilient Properties of Arkansas Subgrades, Final Report, TRC-94, Arkansas Highway and Transportation Research Center, University of Arkansas, Fayetteville, 1988.
- ELLIS G.W.; YAO, C; ZHA, o R. & PENUMADU, D. (1995). Stress–strain modeling of sands using artificial neural networks, *J Geotech Eng*, Vol.121, No.5, pp. 429–435, ISSN 1089-3032.
- FAHLMAN, S.E. & LEBIERE, C. (1990). The cascade correlation learning architecture, In: *Advances in Neural Information Processing Systems*, H, D.S. Touretzky, (Ed.), Morgan Kaufmann , San Mateo, CA, USA.
- FARRAR, M.J. and J.P. TURNER, Resilient Modulus of Wyoming Subgrade Soils, MPC Report No. 91-1, Mountain Plains Consortium, Fargo, N.D., 1991.
- FERREIRA, J. G. H. M. (2008) Tratamento de Dados Geotécnicos Para Predição de Módulos de Resiliência de Solos e Britas Utilizando Ferramentas de Data Mining [Rio de Janeiro] 2008. XVI, 264p. 29,7cm (COPPE/UFRJ, D.Sc., Engenharia Civil, 2008). Tese - Universidade Federal do Rio de Janeiro, COPPE.

- GHABOUSSI J., SIDARTA, D.E. (1998). New nested adaptive neural networks for constitutive modeling, *Computers and Geotechnics*, Vol.22, No.1, pp. 29–52, ISSN 0266-352X.
- GOH, A.T.C. (1995). Modeling soil correlations using neural networks. *J. Comput. Civil Eng.*, ASCE, Vol.9, No.4, pp. 275–278, ISSN 1598-2351
- GONDIM, L. M. Estudo experimental de misturas solo-emulsão aplicado às rodovias do agropólo do Baixo Jaguaribe - Estado do Ceará. 2008. 213 f. Dissertação (Mestrado em Engenharia de Transportes) - Centro de Tecnologia, Universidade Federal do Ceará, 2008.
- GRIBB, M. M. & GRIBB, G. W. (1994). Use of neural networks for hydraulic conductivity determination in unsaturated soil.” *Proc., 2nd Int. Conf. Ground Water Ecology*, Water Resources Assoc., pp. 155-163
- GUNAYDIN O., GOKOGLU A.; FENER M., (2010), Prediction of artificial soil’s unconfined compression strength test using statistical analyses and artificial neural networks, *Advances in Engineering Software*, v. 41, p. 1115-1123, 2010.
- GUPTA, S., A. RANAIVOSON, T. EDIL, C. BENSON, and A.SAWANGSURIYA, Pavement Design Using Unsaturated Soil Technology, Report No. MN/RC-2007-11, Final Research Report submitted to Minnesota Department of Transportation, University of Minnesota, Minneapolis, May 2007.
- HAYKIN (2001) *Neural Networks, A Comprehensive Foundation*. Second Edition, Pearson Education, McMaster University, Hamilton, Ontario, Canada.
- HECHT-NELSON, R. (1987). Kolmogorov's mapping neural network existence theorem, *Proc. Of 1st IEEE Annual Int'l Conf. on Neural Networks*, pp. III.11-111.14, San Diego, NJ, USA, June 21-24.
- HECHT-NELSON, R. (1987). Kolmogorov's mapping neural network existence theorem, *Proc. Of 1st IEEE Annual Int'l Conf. on Neural Networks*, pp. III.11-111.14, San Diego, NJ, USA, June 21-24.



- HECHT-NELSON, ROBERT. (1989). *Neurocomputing*. Addison-Wesley Longman Publishing Co. Inc. Boston.
- HEUKELOM, W. & FOSTER, C. R. (1962). Dynamic testing of pavements. *Trans. Am. Soc. Civ. Engrs* 127, 425–457.
- HEUKELOM, W.; FOSTER, C. R. Dynamic testing of pavements. *Journal of the Soil Mechanics and Foundations Divions*, [S.I.], v. 86, n. SM1, p. 1-27, 1960.
- HICKS, R. G., (1970), *Factors Influencing the Resilient Properties of Granular Materials*. Tese de PhD, Universidade da Califórnia, Berkeley.
- HUDSON, J.M., E.C. DRUMM, and M. MADGETT, *Design Handbook for the Estimation of Resilient Response of Fine-Grained Subgrades*, Proceedings of the 4th International Conference on the Bearing Capacity of Roads and Airfields, University of Minnesota, Minneapolis, Vol. 2, 1994, pp. 917–931.
- HVEEM, F. N. (1955). Pavement deflections and fatigue failures. *Bulletin N ° 114*, p. 43-87. Highway Research Board. Washington, DC.
- IBGE (2010) *Censo Populacional 2010*. Rio de Janeiro, RJ.
- JALES, A. W. L. (2009) *Estimação de volumes de tráfego com base na morfologia urbana*. Estudo de caso: cidade de Fortaleza-CE. Dissertação de Mestrado, UFC, Departamento de Engenharia de Transportes, Fortaleza, CE, 2009.
- JOHARI A.; JAVADI A. A.; HABIBAGAHI G., (2011), *Modelling the mechanical behaviour of unsaturated soils using a genetic algorithm-based neural network*, *Computers and Geotechnics*, v 38, p. 2-13, 2011.
- JONES, M.P. and M.W. WITCZAK, “Subgrade Modulus on the San Diego Test Road,” *Transportation Research Record* 641, Transportation Research Board, National Research Council, Washington, D.C., 1972, pp. 1–6.
- JUANG, C. H., LU, P. C., CHEN, C. J. (2002), *Predicting Geotechnical Parameters of Sands from CPT Measurements Using Neural Networks*. *Computer-Aided Civil and Infrastructure Engineering* 17 (2002) 31–42.

- KIM, D., SIDDIKI, N. Z.. Simplification of Resilient Modulus Testing for Subgrades, Research Report HWA/IN/JTRP-2005/23, Joint Transportation Research Program 1284 Civil Engineering Building Purdue University West Lafayette, IN 47907-1284, 2006.
- LAWRENCE, J. & FREDRICKSON, J. (1988). BrainMaker User's Guide and Reference Manual, 7th Ed., Nevada City, CA: California Scientific Software.
- LEE, I.M. & LEE, J.H. (1996). Prediction of pile bearing capacity using artificial neural networks, *Comput Geotech*, Vo.18, No.3, pp. 189–200, ISSN 0266-352X
- LIPPMANN P. R. (1987). An Introduction' to Computing with Neural Nets. *IEEE ASSP MAGAZINE*, 4-22.
- MACÊDO, J. A. G., (1996), Interpretação de Ensaios Deflectométricos Para Avaliação Estrutural de Pavimentos Flexíveis – A Experiência com FWD no Brasil, Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- MALLA, R.B. and S. JOSHI, Establish Subgrade Support Values for Typical Soils in New England, Report No. NETCR 57, New England Transportation Consortium, Fall River, Mass., Apr. 2006.
- MASADA, T., S.M. SARGAND, B. ABDALLA, and J.L. FIGUEROS, Material Properties for Implementation of Mechanistic-Empirical (ME) Pavement Design Procedures, Final Report, Ohio Department of Transportation, Ohio Research Institute for the Transportation and Environment, Athens, 2004.
- MCCULLOCH, W. S. AND W. H. PITTS: 1943, 'A Logical Calculus of the Ideas Immanent in Nervous Activity', *Bulletin of Mathematical Biophysics* 7, 115–133. Reprinted in McCulloch 1964, pp. 16–39.
- MEDINA, J., PREUSLLER, E. S., 1980, "Características resilientes de solos em estudos de pavimentos", *Solos e Rochas*, vol. 3 , no. 1.
- NAJJAR, Y.M. & BASHEER, I.A. (1996). Utilizing computational neural networks for evaluating the permeability of compacted clay liners, *Geotechnical and Geological Engineering*, Vol.14, pp. 193-221.

- NAJJAR, Y.M.; BASHEER, I.A. & MCREYNOLDS, R. (1996). Neural modeling of Kansan soils swelling, Transportation Research Record No. 1526, pp. 14-19
- NATIONAL COOPERATIVE HIGHWAY RESEARCH PROGRAM (2004). NCHRP 1-37A - Guide for mechanistic-empirical design of new rehabilitated pavement structures - Final Report. Transportation Research Board. Illinois, 2004.
- NI, B., T.C. Hopkins, L. SUN, and T.L. BECKHAM, “Modeling the Resilient Modulus of Soils,” Proceedings of the 6th International Conference on the Bearing Capacity of Roads, Railways, and Airfields, Vol. 2, A.A. Balkema Publishers, Rotterdam, the Netherlands, pp. 1131–1142.
- NOGAMI, J. S. V., VILLIBOR, D. F., (1995), Pavimentação de baixo custo com solos lateríticos. Editora Vilibor, São Paulo, SP, 1995.
- OOI, P.S.K., K.G. SANDEFUR, and A.R. ARCHILLA, Correlation of Resilient Modulus of Fine-Grained Soils with Common Soil Parameters for Use in Design of Flexible Pavements, Report No. HWY-L-2000-06, Hawaii Department of Transportation, Honolulu, 2006.
- PACKTER, L. (2005) Neurociência – Elementos de Neurofisiologia, Farmacologia e Psiquiatria, 2009.
- PARK, H.I. & KIM, Y.T. (2010). Prediction of Strength of Reinforced Lightweight Soil Using an Artificial Neural Network, Engineering Computation, In press.
- PARK, H.I. (2010). Development of neural network model to estimate the permeability coefficient of soils, Marine Geosources and Geotechnology.
- PARK, H.I.; KEON, G.C. & LEE, S.R. (2009). Prediction of Resilient Modulus of Granular Subgrade Soils and Subbase Materials Based on Artificial Neural Network, Road Materials and Pavement Design, Vol.10, No. 3, pp. 647- 665.
- PEZO, R.F., A General Method of Reporting Resilient Modulus Tests of Soils: A Pavement Engineer’s Point of View, Presented at the 72nd Annual Meeting of the Transportation Research Board, Washington, D.C., Jan. 1993.

- PING, W.V., C. LING, Enhancement of Resilient Modulus Data for the Design of Pavement Structures in Florida, Research Report No.FL/DOT/RMC/BD-543-4, Department of Civil Engineering, FAMU–FSU College of Engineering, Tallahassee, Sep. 2007.
- POWELL, W.D., J.F. POTTER, H.C. MAYHEW, and M.E. NUNN, The Structural Design of Bituminous Roads, TRRL Report LR 1132, Department of Transport, Berkshire, U.K.,1984.
- RADA, G. and M.W. WITCZAK, Comprehensive Evaluation of Laboratory Resilient Moduli Results for Granular Materials, Transportation Research Record 810, Transportation Research Board, National Research Council, Washington, D.C., 1981, pp. 23–33.
- RAHIM, A. M and K. P. GEORGE, “Subgrade soil Index properties to Estimate Resilient Modulus”, Paper Presented at 83rd Annual Meeting of Transportation Research Board, Washington D C, 2004.
- RIBEIRO, A. J. A., SILVA, C. A. U., BARROSO, S. H. A., (2012), Proposition of a Geotechnical Mapping Based on Artificial Neural Networks for the Town of Caucaia, Ceará, Brazil for Paving Purposes. IJET: International Journal of Engineering e Technology, v. 12, p. 65-74, 2012.
- RIBEIRO, A. J. A.; DA SILVA, C. A. U.;BARROSO, S. H. A (2015). Neural Estimation of Localization and Classification of Soils for Use in Low-Traffic-Volume Roads. Transportation Research Record, v. 2473, p. 98-106, 2015.
- RODGHER, S. F. Aplicação de redes neurais artificiais para previsão de propriedades dos solos tropicais. 306f. Tese (Doutorado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2002.
- ROMERO, S. & PAMUKCU, S. (1996). Characterization of granular material by low strain dynamic excitation and ANN, Geotechnical Special Publication, ASTM-ASCE, Vol.58, No.2, pp. 1134-1148.
- ROSENBLATT, FRANK. 1958. The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review 6: 386–408.

- SCHAETZL R. J., ANDERSON S., (2005), Soils: Genesis and Geomorphology. Cambridge University Press, New York.
- SEED, H.B., F.G. MITRY, C.L. MONISMITH, AND C.K. CHAN, NCHRP Report 35: Prediction of Flexible Pavement Deflections from Laboratory Repeated-Load Tests, Highway Research Board, National Research Council, Washington, D.C., 1967.
- SHAHIN, M. A., JAKSA, M. B., MAIER, H. R. (2001), Artificial Neural Network Applications in Geotechnical Engineering. Australian Geomechanics – March 2001.
- SOIL SURVEY STAFF, (1960), Soil Classification, A Comprehensive System, 7th Approximation. Soil Conserv. Serv., U.S. Dept. Agric. U.S. Govt. Printing Office, Washington, DC.265 pp.
- SOIL SURVEY STAFF, (1975), Soil Taxonomy, A Basic System of Soil Classification for Making and Interpreting Soil Surveys. Soil Conserv. Serv., U.S. Dept. Agric. Handbook, vol. 436. U.S. Govt. Printing Office, Washington, DC.754 pp.
- SOIL SURVEY STAFF, (1999), Soil Taxonomy: A Basic System of Soil Classification for Making and Interpreting Soil Surveys, 2nd edn. Agric. Handbook, vol. 436. U.S. Govt. Print. Office, Washington, DC.
- SOLIMAN, H., SHALABY, A, (2010), Sensitivity of Subgrade Resilient Modulus to Moisture Variation. Annual Conference of the Transportation Association of Canada Halifax, Nova Scotia (2010).
- SOUZA JUNIOR, J. D. O Efeito da energia de compactação em propriedades dos solos utilizados na pavimentação do Estado do Ceará. 2005. 211 f. Dissertação (Mestrado em Engenharia de Transportes) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2005.
- SOUZA, M. L. (1979), Método de projeto de pavimentos flexíveis. 2. ed. Rio de Janeiro: DNER, 1979.
- SUKUMARAN, B., KYATHAM, V., SHAH A., SHETH D., (2002), Suitability Of Using California Bearing Ratio Test To Predict Resilient Modulus. Presented For The Federal Aviation Administration Airport Technology Transfer Conference (2002).

- SVENSON, M., (1980), Ensaio Triaxiais Dinâmicos de Solos Argilosos, Tese de M.Sc.Universidade Federal do Rio de Janeiro, COPPE, 1980.
- SWINGLER, K. (1996). Applying Neural Networks: A Practical Guide. San Francisco: Morgan Kaufmann Publishers.
- TASKIRAN, T. (2010), Prediction of California bearing ratio (CBR) of fine grained soils by AI methods. *Advances in Engineering Software* 41 (2010) 886–892.
- THOMPSON, M.R. and Q.L. ROBNETT, “Resilient Properties of Subgrade Soils,” *Transportation Engineering Journal*, Vol. 105, No. TE1, 1979, pp. 71–89.
- THOMPSON, M.R. and R.P. ELLIOT, “ILLI-PAVE-Based Response Algorithms for Design of Conventional Flexible Pavements,” *Transportation Research Record* 1043, Transportation Research Board, National Research Council, Washington, D.C., 1985, pp.50–57.
- THOMPSON, M.R. and T.G. LAGROW, A Proposed Conventional Flexible Pavement Thickness Design Procedure, FHWA-IL-UI-223. Illinois University, Urbana–Champaign, Dec. 1988, 47 pp.
- UZAN, J., “Characterization of Granular Materials,” *Transportation Research Record* 1022, Transportation Research Board, National Research Council, Washington, D.C., 1985, pp. 52–59.
- VIANA, H. M. F., (2007), Estudo do comportamento resiliente dos solos tropicais grossos do interior do Estado de São Paulo. São Carlos, 2006. Tese (Doutorado – Programa de Pós-Graduação em Engenharia de Transportes e Áreas de Concentração em Infra-Estrutura de Transportes) – EESC da Universidade de São Paulo, 2006.
- VISSER, A. T., QUEIROZ C.A.V., HUDSON, W. R., 1981, “Prediction of tropical Road bed resilient modulus from standard material tests”, In: *Simpósio Brasileiro de Solos Tropicais*, pp. 615 – 635, COPPE/UFRJ – CNPq – ABMS, Rio de Janeiro, Brasil.
- VON QUINTUS H. L., Evaluation of Procedure to Estimate Subgrade Resilient Modulus For Use in Pavement Structural Design, Research Report NoKS-07-10, Kansas Department of Transportation Bureau of Materials and Research, Nov. 2007.

- WITCZAK, M., X. QI, and M.W. MIRZA, Use of Nonlinear Subgrade Modulus in AASHTO Design Procedures, *Journal of Transportation Engineering*, Vol. 121, No. 3, May/June 1995, pp. 273–282.
- WITCZAK, M.W. and J. UZAN, The Universal Airport Pavement Design System, Report 1 of 4, Granular Material Characterization, University of Maryland, College Park, 1988.
- WOLFE, W.E. and T.S. BUTALIA, Seasonal Instrumentation of SHRP Pavements, Final Report for Ohio Department of Transportation, Ohio State University, Columbus, 2004.
- Y.L. KUO, M.B. JAKSA,\*, A.V. LYAMIN, W.S. KAGGWA (2009). ANN-based model for predicting the bearing capacity of strip footing on multi-layered cohesive soil. *Computers and Geotechnics*. 36. 503-516.
- YANG, Y., AND ROSENBAUM, M. S. (2002). "The artificial neural network as a tool for assessing geotechnical properties." *Geotechnical Engineering Journal*, 20(2), 149-168.
- YANG, Y., ROSENBAUM, M. S., (2002), The artificial neural network as a tool for assessing geotechnical properties. *Geotechnical and Geological Engineering* 20 (2002) 149-168.
- YILDIRIM, B., GUNAYDIN.O. (2011), Estimation of California bearing ratio by using soft computing systems. *Expert Systems with Applications* 38 (2011) 6381–6391.
- ZAMAN, M., D.-H. CHEN, and J. LAGUROS, “Resilient Modulus of Granular Materials,” *Journal of Transportation Engineering*, Vol. 120, No. 6, 1994, pp. 967–988.
- ZAMPIERE, F. L. L., (2006), Modelo estimativo de movimento de pedestres baseado em sintaxe espacial, medidas de desempenho e redes neurais artificiais. Dissertação de Mestrado, UFRS, Porto Alegre, RS - 2006.
- ZEGHAL, M., KHOGALI, W., (2005), Predicting the resilient modulus of unbound granular materials by neural networks. National Research Council Canada (NRCC-47704). BCRA 2005, Trondheim, Norway, June 27-29, 2005, pp. 1-9.