

TRATAMENTO DE DADOS GEOTÉCNICOS PARA PREDIÇÃO DE MÓDULOS DE
RESILIÊNCIA DE SOLOS E BRITAS UTILIZANDO FERRAMENTAS DE DATA
MINING

José Gustavo Hermida de Mello Ferreira

TESE SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS PROGRAMAS
DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE FEDERAL DO RIO
DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A
OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM ENGENHARIA CIVIL.

Aprovada por:

Prof^a. Laura Maria Goretti da Motta D.Sc.

Prof. Jacques de Medina, L.D.

Prof. Nelson Francisco Favilla Ebecken, D.Sc.

Prof. Alexandre Benetti Parreira, D.Sc.

Prof. Jorge Augusto Pereira Ceratti, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

JUNHO DE 2008

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

FERREIRA, JOSÉ GUSTAVO HERMIDA DE MELLO
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

1. Ensaio Triaxial de Cargas Repetidas
2. Data Mining
3. Redes Neurais Artificiais
4. Módulo de Resiliência de Solos

I. COPPE/UFRJ II. Título (série)

AGRADECIMENTOS

A minha família, pelo incentivo, apoio e principalmente paciência, especialmente Mariana e Ana Lúcia.

A três verdadeiros Professores que tive o grande prazer e sorte de conhecer na COPPE, minha amiga-orientadora-incentivadora-colaboradora Laura Motta, meu “co-orientador” Nelson Ebecken, e Jacques de Medina, exemplos de que a verdadeira competência e seriedade dispensam totalmente o desagradável “salto-alto” acadêmico.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq – pelo apoio financeiro.

A minha amiga Maria Inês, por tudo, especialmente no caso desta tese por me “apresentar” às redes neurais.

Ao Sávio Senna e André Siqueira, meu muito obrigado pela imprescindível ajuda na parte de programação.

A Claudinha e Heloisa, que me possibilitaram passar “naquela” prova de Inglês.

A equipe do Laboratório de Geotecnia, em especial Álvaro, Bororó, Roberto, Washington e Ralf pela infalível disposição em colaborar.

Aos meus colegas de curso Rodrigo Muller, Marcos Fritzen, Antonio Guimarães e Ben-Hur pela grande colaboração.

Aos meus amigos Américo, Giovanni, Zeno, Lulu, Renatinho e Leandro, simplesmente por serem meus amigos.

To the former PEC’s Coordination...”I’ll see you on the dark side of the moon”.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

TRATAMENTO DE DADOS GEOTÉCNICOS PARA PREDIÇÃO DE MÓDULOS DE RESILIÊNCIA DE SOLOS E BRITAS UTILIZANDO FERRAMENTAS DE DATA MINING

José Gustavo Hermida de Mello Ferreira

Junho / 2008

Orientadora: Laura Maria Goretti da Motta

Programa: Engenharia Civil

Este trabalho apresenta os procedimentos utilizados e os resultados obtidos na busca dos relacionamentos existentes entre os parâmetros geotécnicos tradicionais de solos e britas utilizados em pavimentação, e o seu comportamento resiliente, além da predição dos valores do módulo de resiliência com base apenas nos citados parâmetros. No desenvolvimento da pesquisa foi utilizada uma base de dados da qual constam 463 amostras de solos de diversas granulometrias e procedências, cujos Ensaio Triaxiais de Cargas Repetidas foram executados no Laboratório de Geotecnia da COPPE/UFRJ no período de 1996 a 2007. Foram utilizadas ferramentas de Data Mining para proceder ao agrupamento das amostras em famílias de solos em termos de comportamento resiliente e desenvolver o respectivo classificador, e Redes Neurais Artificiais para predição dos valores do módulo de resiliência. Os resultados obtidos permitem sua utilização no desenvolvimento de anteprojetos e sugerem boas possibilidades de aprimoramento mediante melhorias quantitativas e qualitativas da base de dados

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

TREATMENT OF GEOTECHNICAL DATA TO PREDICTION OF RESILIENT MODULUS
OF SOILS AND CRUSHED STONES USING DATA MINING TOOLS

José Gustavo Hermida de Mello Ferreira

June / 2008

Advisors: Laura Maria Goretti da Motta

Department: Civil Engineering

This work presents the procedures used and the results obtained from investigation of relationships existed among geotechnical standard parameters of soils and crushed stones used for pavement and their resilient behavior, besides the prediction of resilient modulus values based only on mentioned parameters. During the research a database including 463 samples of soils of various granulometries and origins were used, in which Dynamic Triaxial Tests were made in the Geotechnical Laboratory of COPPE/UFRJ, during the period from 1996 to 2007. Tools of Data Mining were used to proceed clustering samples in families of soils in terms of resilient behavior and develop the respective classifier and Artificial Neural Networks to prediction of resilient modulus values. The obtained results allow its use on preliminary projects development and suggest good possibilities to improve through quantitative and qualitative improvements of database.

ÍNDICE

ÍNDICE DE FIGURAS.....	viii
ÍNDICE DE TABELAS.....	xi
ÍNDICE DE QUADROS.....	xii
CAPÍTULO 1 - INTRODUÇÃO.....	1
1.1. <i>A proposta desta tese de doutorado.....</i>	3
1.2. <i>Organização do trabalho.....</i>	5
CAPÍTULO 2 - MÓDULO DE RESILIÊNCIA DE SOLOS E BRITAS.....	7
2.1. <i>Metodologias de ensaio.....</i>	7
2.2. <i>Modelos de comportamento resiliente.....</i>	11
2.3. <i>Tentativas de obtenção de correlações e classificações resilientes.....</i>	15
CAPÍTULO 3 - FERRAMENTAS DE DATA MINING PARA EXPLORAÇÃO DA BASE DE DADOS.....	28
3.1. <i>Aspectos gerais.....</i>	28
3.2. <i>Pré-processamento.....</i>	30
3.3. <i>Agrupamento.....</i>	34
3.4. <i>Classificação.....</i>	44
3.5. <i>Software e algoritmos utilizados neste trabalho.....</i>	47
CAPÍTULO 4 - REDES NEURAIS ARTIFICIAIS.....	50
4.1. <i>Introdução.....</i>	50
4.2. <i>Neurônios Artificiais – Modelo MCP.....</i>	52
4.3. <i>Principais arquiteturas de RNAs.....</i>	54
4.4. <i>Aprendizado.....</i>	57
4.5. <i>Redes Multilayer Perceptron.....</i>	60
4.5.1 <i>Arquitetura.....</i>	60
4.5.2 <i>Treinamento.....</i>	62
4.6. <i>Redes GRNN.....</i>	67
4.6.1 <i>Arquitetura.....</i>	67
4.6.2 <i>Treinamento.....</i>	69

4.7	<i>Trabalhos Correlatos</i>	69
CAPÍTULO 5 – BASE DE DADOS.....		74
5.1.	<i>Base de dados utilizada</i>	74
5.2.	<i>Escolha das variáveis</i>	89
5.3.	<i>Amostras não consideradas na base de dados</i>	93
5.4	<i>Histogramas das variáveis</i>	94
CAPÍTULO 6 - AGRUPAMENTO EM FAMÍLIAS DE SOLOS QUANTO À RESILIÊNCIA.....		96
6.1.	<i>Aplicação do algoritmo EM</i>	96
6.2.	<i>Aplicação do algoritmo K-means</i>	97
6.3.	<i>Aplicação do agrupamento por especialista</i>	98
6.4	<i>Resumo e análise dos resultados dos agrupamentos</i>	117
CAPÍTULO 7 - CLASSIFICADOR DE SOLOS QUANTO À RESILIÊNCIA.....		147
7.1.	<i>Classificadores desenvolvidos</i>	147
7.2.	<i>Classificador escolhido</i>	159
CAPÍTULO 8 - DESENVOLVIMENTO DAS REDES NEURAIS ARTIFICIAIS.....		170
8.1.	<i>Metodologia – primeira fase</i>	170
8.2.	<i>Análise dos resultados obtidos – primeira fase</i>	211
8.3	<i>Metodologia – segunda fase</i>	214
8.4	<i>Análise dos resultados obtidos – segunda fase</i>	223
8.5	<i>Considerações finais</i>	226
CAPÍTULO 9 - ANÁLISE DA INFLUENCIA DOS ERROS DE PREDIÇÃO NO DIMENSIONAMENTO DE ESTRUTURAS FLEXÍVEIS.....		239
9.1.	<i>Metodologia</i>	239
9.2.	<i>Resultados obtidos</i>	241
CAPÍTULO 10 - CONCLUSÕES E SUGESTÕES PARA FUTURAS PESQUISAS.....		255
10.1.	<i>Conclusões</i>	255
10.2.	<i>Sugestões para futuras pesquisas</i>	260
REFERÊNCIAS BIBLIOGRÁFICAS.....		261

ÍNDICE DE FIGURAS

Figura 2.1.	Classificação Resiliente dos Solos Granulares (DNER, 1996).....	19
Figura 2.2.	Variação da Relação M_R/CBR com Classificação MCT (DNER, 1996).....	21
Figura 3.1.	Árvore de Classificação.....	41
Figura 3.2.	Uma arquitetura de aprendizado competitivo – Fonte: Han e Kamber (2001).....	43
Figura 3.3.	Esquema de Árvore de Decisão.....	45
Figura 4.1.	Neurônio Esquemático – Fonte: Furtado, 1999.....	51
Figura 4.2.	Esquema de Unidade Processadora de McCulloch e Pitts – Fonte: Furtado, 1999.....	53
Figura 4.3.	Exemplos de Funções de Ativação de Neurônios – Fonte: Furtado, 1999.....	54
Figura 4.4.	Representação de Rede Feedforward de uma camada – Fonte: Furtado, 1999.....	55
Figura 4.5.	Representação de Rede Neural Artificial de Múltiplas Camadas – Fonte: Furtado, 1999.....	55
Figura 4.6.	Representação de Rede Backward – Fonte: Furtado, 1999.....	56
Figura 4.7.	Esquema de Diagrama de Blocos do Aprendizado Supervisionado - Fonte: Furtado, 1999.....	58
Figura 4.8.	Esquema de Diagrama de Blocos do Aprendizado Não Supervisionado – Fonte: Furtado, 1999.....	59
Figura 4.9.	Esquema de Diagrama de Blocos do Aprendizado por Reforço – Fonte: Furtado, 1999.....	59

Figura 4.10.	Fluxo de processamento do algoritmo <i>Backpropagation</i>	63
Figura 4.11.	Exemplo de Superfície de Erro – Fonte: Furtado, 1999.....	64
Figura 4.12.	Mínimos Locais de uma Função – Fonte: Furtado, 1999.....	65
Figura 4.13.	Esquema da Arquitetura GRNN – Fonte: Furtado, 1999.....	68
Figura 5.1.	MR × Pares de Tensões – Amostra S400/02.....	93
Figura 5.2.	MR × Pares de Tensões – Amostra 376.....	94
Figura 5.3.	Histogramas das variáveis do banco de dados utilizado neste estudo.	95
Figura 6.1.	Grupos.....	104
Figura 6.2.	Peneira 1” × Grupos.....	105
Figura 6.3.	Peneira 3/8” × Grupos.....	106
Figura 6.4.	Peneira n° 4 × Grupos	107
Figura 6.5.	Peneira n° 10 × Grupos.....	108
Figura 6.6.	Peneira n° 40 × Grupos.....	109
Figura 6.7.	Peneira n° 200 × Grupos.....	110
Figura 6.8.	IP X Grupos.....	111
Figura 6.9.	Hmold × Grupos.....	112
Figura 6.10.	Densmold × Grupos.....	113
Figura 6.11.	K ₁ × Grupos.....	114
Figura 6.12.	K ₂ × Grupos.....	115
Figura 6.13.	K ₃ × Grupos.....	116
Figura 6.14.	Coefficientes de Variação – 4 grupos – Solos Coesivos.....	118
Figura 6.15.	Coefficientes de Variação – 4 grupos – Solos Intercoesivos.....	118

Figura 6.16.	Coeficientes de Variação – 4 grupos – Solos Intergranulares.....	119
Figura 6.17.	Coeficientes de Variação – 4 grupos – Solos Granulares.....	119
Figura 6.18.	Coeficientes de Variação – 5 grupos – Solos Coesivos1.....	120
Figura 6.19.	Coeficientes de Variação – 5 grupos – Solos Coesivo2.....	120
Figura 6.20.	Coeficientes de Variação – 5 grupos – Solos Intercoesivos.....	121
Figura 6.21.	Coeficientes de Variação – 5 grupos – Solos Intergranulares.....	121
Figura 6.22.	Coeficientes de Variação – 5 grupos – Solos Granulares.....	122
Figura 6.23.	Percentual de material passante na peneira 200 de solos coesivos e granulares em relação ao limite de 35%.....	124
Figura 7.1	Árvore de decisão gerada para classificação de solos quanto à resiliência.....	160
Figura 7.2.	Histogramas das variáveis da base de dados classificada.....	161
Figura 7.3.	Peneira 1" × Classes.....	162
Figura 7.4.	Peneira 3/8" × Classes.....	163
Figura 7.5.	Peneira n ^o 4 × Classes.....	164
Figura 7.6.	Peneira n ^o 10 × Classes.....	165
Figura 7.7.	Peneira n ^o 40 × Classes.....	166
Figura 7.8.	Peneira n ^o 200 × Classes.....	167
Figura 7.9.	Hmold × Classes.....	168
Figura 7.10.	Densmold × Classes.....	169
Figura 8.1.	Algoritmo do Método K-Médias – Fonte: Machado Filho, 2002.....	202
Figura 8.2.	Algoritmo do Método Calinski e Harabasz - Fonte: Machado Filho, 2002.....	203
Figura 9.1.	Estruturas consideradas no projeto fatorial de análise da influencia dos erros de predição.....	240

ÍNDICE DE TABELAS

Tabela 2.1.	Níveis de Tensões do Ensaio Triaxial de Cargas Repetidas Padrão da COPPE/UFRJ para todos os Solos e Britas.....	10
-------------	---	----

ÍNDICE DE QUADROS

Quadro 2.1.	Características Resilientes de Solos Brasileiros (Medina e Preussler, 1980).....	17
Quadro 2.2.	Classificação dos Solos Finos (Método Indireto) – (Pinto, 1991) (DNER, 1996).....	20
Quadro 2.3.	Relação M_R/CBR – (DNER, 1996).....	20
Quadro 2.4.	Correlações utilizadas pela AASHTO (2002).....	24
Quadro 2.5.	Valores típicos de M_R para materiais granulares e de subleito (AASHTO, 2002).....	25
Quadro 5.1 –	Base de Dados.....	77
Quadro 5.2 –	Matriz de Correlação – Constantes K_i	88
Quadro 5.3.	Matriz de Correlação – Módulo de Resiliência e Deformação Específica Resiliente.....	88
Quadro 5.4.	Análise Estatística das Variáveis Independentes (inputs).....	91
Quadro 5.5.	Análise Estatística da Variável Dependente (outputs).....	92
Quadro 6.1.	Algoritmo EM – Procedimento 1.....	100
Quadro 6.2.	Algoritmo EM – Procedimento 2.....	100
Quadro 6.3.	Algoritmo K-means – 4 Grupos – Procedimento 1.....	101
Quadro 6.4.	Algoritmo K-means – 4 Grupos – Procedimento 2.....	101
Quadro 6.5.	Algoritmo K-means – 5 Grupos – Procedimento 2.....	102
Quadro 6.6.	Agrupamento por Especialista – 2 Grupos – Procedimento 2.....	102
Quadro 6.7.	Agrupamento por Especialista – 3 Grupos – Procedimento 2.....	103
Quadro 6.8.	Agrupamento por Especialista – 4 Grupos – Procedimento 2.....	103
Quadro 6.9.	Valores da função log-likelihood.....	117
Quadro 6.10.	Médias dos coeficientes de variação.....	122

Quadro 6.11.	Matriz de Correlação – Constantes Ki – Agrupamento EM – 4 Grupos - Coesivo.....	125
Quadro 6.12.	Matriz de Correlação – Constantes Ki – Agrupamento EM – 4 Grupos - Intercoesivo.....	125
Quadro 6.13.	Matriz de Correlação – Constantes Ki – Agrupamento EM – 4 Grupos - Intergranular.....	126
Quadro 6.14.	Matriz de Correlação – Constantes Ki – Agrupamento EM – 4 Grupos – Granular.....	126
Quadro 6.15.	Matriz de Correlação – Constantes Ki – Agrupamento por Especialista – 2 Grupos – Coesivo.....	127
Quadro 6.16.	Matriz de Correlação – Constantes Ki – Agrupamento por Especialista – 2 Grupos – Granular.....	127
Quadro 6.17.	Matriz de Correlação – Constantes Ki – Agrupamento por Especialista – 3 e 4 Grupos – Coesivo.....	128
Quadro 6.18.	Matriz de Correlação – Constantes Ki – Agrupamento por Especialista – 3 Grupos – Intermediário.....	128
Quadro 6.19.	Matriz de Correlação – Constantes Ki – Agrupamento por Especialista – 3 e 4 Grupos – Granular.....	129
Quadro 6.20.	Matriz de Correlação – Constantes Ki – Agrupamento por Especialista – 4 Grupos – Intercoesivo.....	129
Quadro 6.21.	Matriz de Correlação – Constantes Ki – Agrupamento por Especialista – 4 Grupos – Intergranular.....	130
Quadro 6.22.	Base de Dados – Agrupamentos das Amostras.....	131
Quadro 7.1.	Resumo da Classificação EM – Procedimento 1.....	148
Quadro 7.2.	Resumo da Classificação EM – Procedimento 2.....	149
Quadro 7.3.	Resumo da Classificação – K-means 4 Grupos – Procedimento 1.....	150
Quadro 7.4.	Resumo da Classificação – K-means 4 Grupos – Procedimento 2.....	151
Quadro 7.5.	Resumo da Classificação – K-means 5 Grupos – Procedimento 2.....	152
Quadro 7.6.	Resumo da Classificação – Especialista 2 Grupos – Procedimento 2.....	153

Quadro 7.7.	Resumo da Classificação – Especialista 3 Grupos – Procedimento 2.....	154
Quadro 7.8.	Resumo da Classificação – Especialista 4 Grupos – Procedimento 2.....	155
Quadro 7.9.	Resumo da Classificação Especialista Mais Dois Algoritmos.....	158
Quadro 8.1.	Rede Normalizada 1.....	178
Quadro 8.2.	Rede Normalizada 2.....	179
Quadro 8.3.	Rede Normalizada 3.....	180
Quadro 8.4.	Rede Normalizada 4.....	181
Quadro 8.5.	Rede Normalizada 5.....	182
Quadro 8.6.	Rede Normalizada 6.....	183
Quadro 8.7.	Rede Normalizada 3a.....	184
Quadro 8.8.	Rede Normalizada 3b.....	185
Quadro 8.9.	Rede Normalizada 2a.....	186
Quadro 8.10.	Rede Normalizada 2b.....	187
Quadro 8.11.	Rede Normalizada 2c.....	188
Quadro 8.12.	Rede Módulo 1.....	191
Quadro 8.13.	Rede Módulo 2.....	192
Quadro 8.14.	Rede Módulo 3.....	193
Quadro 8.15.	Rede Módulo 4.....	194
Quadro 8.16.	Rede Módulo 5.....	195
Quadro 8.17.	Rede Módulo 6.....	196
Quadro 8.18.	Rede Módulo 8.....	197
Quadro 8.19.	Rede Módulo 9.....	198

Quadro 8.20. Rede Módulo 11.....	199
Quadro 8.21. Rede Módulo 12.....	200
Quadro 8.22. Valores do Coeficiente Calinski e Harabasz (G) para os agrupamentos realizados.....	203
Quadro 8.23. Parâmetros Estatísticos do Agrupamento.....	205
Quadro 8.24. Rede Módulo 101.....	206
Quadro 8.25. Rede Módulo 102.....	207
Quadro 8.26. Rede Módulo 103.....	208
Quadro 8.27. Erros percentuais médios de algumas amostras para as redes apresentadas nos quadros 8.16, 8.19, 8.20, 8.21, 8.24, 8.25, e 8.26.....	209
Quadro 8.28. Erros Percentuais Médios para o total de padrões e para os conjuntos de validação.....	212
Quadro 8.29. Rede RN 33.....	218
Quadro 8.30. Rede RN 37.....	219
Quadro 8.31. Redes GRNN.....	220
Quadro 8.32. Erros Percentuais Médios – Redes MLP.....	227
Quadro 8.33. Erros Percentuais Médios – Redes MLP.....	228
Quadro 8.34. Erros Percentuais Médios – Redes GRNN – Agrupamento por Especialista.....	229
Quadro 8.35. Erros Percentuais Médios – Redes GRNN – Agrupamento por Algoritmos.....	231
Quadro 8.36. Erros Percentuais Médios – Redes Mesma Classificação.....	233
Quadro 8.37. Comparativo Redes MLP × Rede GRNN.....	234
Quadro 8.38. Erros Percentuais Médios Variando-se o Conjunto de Validação.....	236
Quadro 9.1. Projeto Fatorial – Constantes do Modelo Composto obtidas no ensaio	243

Quadro 9.2.	Projeto Fatorial – Constantes do Modelo Composto obtidas pela Rede Neural.....	245
Quadro 9.3.	Número de estruturas por faixa de erro.....	241
Quadro 9.4.	Erros na Diferença de Tensões e no Número N – Revestimento Espessura = 4,0cm.....	247
Quadro 9.5.	Erros na Diferença de Tensões e no Número N – Revestimento Espessura = 6,0cm.....	249
Quadro 9.6.	Erros na Diferença de Tensões e no Número N – Revestimento Espessura = 8,0cm.....	251
Quadro 9.7.	Erros na Diferença de Tensões e no Número N – Revestimento Espessura = 10,0cm.....	253

Capítulo 1

Introdução

Os pavimentos rodoviários são estruturas lineares, que muitas vezes atravessam formações pedológicas bastante diversas mesmo em pequenas extensões. Devido aos elevados custos de implantação destas estruturas, na prática de projeto procura-se utilizar ao máximo os materiais existentes nas áreas adjacentes ao eixo da rodovia, especialmente no que se refere à camada final de terraplenagem. Mesmo para os materiais que irão constituir a estrutura de pavimento, é sempre conveniente utilizar aqueles cujas distâncias de transporte entre as jazidas das quais se originam e os locais de aplicação sejam as menores possíveis. Sendo assim, um bom projeto de pavimentação deve sempre buscar a otimização no que se refere à utilização dos materiais existentes nas áreas contíguas à rodovia.

Os procedimentos de dimensionamento mecanístico-empíricos permitem uma utilização muito mais racional destes materiais do que aqueles que se baseiam unicamente em parâmetros empíricos. Além disso, ao contrário dos métodos empíricos que levam em conta exclusivamente os parâmetros de resistência relacionados ao cisalhamento, os métodos mecanístico-empíricos consideram a deformabilidade elástica do pavimento, permitindo ainda a análise da vida de fadiga do revestimento, fator determinante no bom desempenho das estruturas, especialmente em países de clima tropical. Apesar de ainda restarem dúvidas substanciais quanto a um aspecto fundamental na utilização deste procedimento, que é a determinação de um fator campo-laboratório adequado, o desenvolvimento das pesquisas tem gerado quase que um consenso a nível mundial quanto à utilização exclusiva destes procedimentos em projetos rodoviários.

No que se refere aos procedimentos de cálculo dos esforços nas estruturas, diversos programas computacionais já foram desenvolvidos e convenientemente testados, e muitos deles já são utilizados corriqueiramente na prática de projeto, não havendo restrições à utilização de metodologias mecanístico-empíricas sob este aspecto. Na fase atual de desenvolvimento destes programas, já foram obtidos sistemas integrados completos, dotados de ferramentas que permitem análises de

diversos fatores que influenciam de forma decisiva no projeto de estruturas rodoviárias, a exemplo daquele elaborado na COPPE/UFRJ por Franco (2007), e no exterior pela AASHTO (2002).

Além dos problemas relativos ao fator de calibração campo-laboratório, o outro entrave para que sejam utilizados exclusivamente métodos de dimensionamento mecanístico-empíricos é a dificuldade na obtenção dos módulos de resiliência dos materiais utilizados, especialmente no que se refere aos solos. Para solos, a modelagem do módulo de resiliência (M_R) é feita a partir dos resultados do ensaio triaxial de cargas repetidas, executado em corpos de prova moldados na umidade ótima de compactação. Com base nestes resultados são definidos os modelos de comportamento resiliente utilizados nos programas de cálculo de tensões e deformações que 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. Os processos por que passam os solos quando submetidos à aplicação de carregamentos são bastante complexos. Suas respostas a esses carregamentos são extremamente dependentes de uma larga gama de fatores, dentre eles a composição mineralógica, as características físicas e os fatores de estado (densidade e umidade). Especificamente quando de seu emprego em pavimentos rodoviários, especialmente os flexíveis, seu comportamento é, na grande maioria dos casos, dependente também do estado de tensões vigente, ou seja, um mesmo solo empregado em camadas diversas apresenta uma resposta diferente às cargas impostas. Estes fatores tornam a modelagem do comportamento dos solos bastante complexa.

Inúmeras tentativas para obtenção de classificações resilientes consistentes e de correlações confiáveis do módulo de resiliência com outras propriedades geotécnicas têm sido feitas por diversos pesquisadores desde o início dos estudos de resiliência, conforme descrito no Capítulo 2. Apesar destes esforços, os resultados obtidos deixam muito a desejar, não havendo condição de se generalizar as classificações e correlações obtidas em função da grande variabilidade dos materiais, que muitas vezes não se enquadram devidamente em nenhum dos grupos classificatórios indicados ou, no que diz respeito às correlações para obtenção do valor de M_R , conduzem a resultados discrepantes em relação àqueles obtidos nos ensaios triaxiais de cargas repetidas.

O ensaio triaxial de cargas repetidas já foi bastante aperfeiçoado (Vianna, 2002), e apresenta resultados suficientemente confiáveis. Entretanto, em comparação com os ensaios tradicionalmente executados para projetos de pavimentação, o mesmo é de execução mais complexa, tanto no que refere aos recursos humanos quanto no que se refere ao equipamento utilizado. Enquanto que os ensaios 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 soma os problemas relativos à grande quantidade de ensaios necessária à devida caracterização dos materiais.

Tendo em vista a grande variabilidade de comportamento dos solos, é imperativo que se efetue um extenso programa de ensaios, de modo que as decisões de projeto sejam tomadas com base em um elevado nível de confiabilidade estatística. Todos esses fatores, somados aos elevados custos de projeto dentro de cenários sempre restritivos no que diz respeito aos recursos financeiros disponíveis, resultam no pouco interesse dos órgãos rodoviários contratantes na adoção de procedimentos de dimensionamento mecanístico-empíricos, ainda que tecnicamente haja quase que um consenso quanto à conveniência de sua utilização. Desta forma, todos os esforços de pesquisa devem ser feitos no sentido de possibilitar a utilização exclusiva de procedimentos racionais de cálculo de estruturas rodoviárias, o que é a motivação da tese aqui proposta.

Nesta linha vêm sendo testadas diversas metodologias. A proposta aqui apresentada é a continuação do estudo preliminar desenvolvido por Ferreira (2002), que apresentou uma avaliação inicial da capacidade das Redes Neurais Artificiais (RNAs) para predição das constantes do Modelo Composto.

1.1 – A proposta desta tese de doutorado

A tese aqui proposta é de que algumas das atuais técnicas computacionais de exploração e análise de bases de dados são capazes de permitir uma melhor compreensão dos fatores que influenciam no comportamento resiliente dos solos e possibilitar a obtenção de ferramentas que permitam modelar este comportamento sem que haja necessidade da execução de ensaios triaxiais de cargas repetidas,

possibilitando com isso a eliminação de um dos maiores empecilhos existentes para a disseminação de procedimentos mecanístico-empíricos de dimensionamento de pavimentos.

Para este fim foram utilizadas ferramentas computacionais de última geração, reunidas em uma disciplina denominada *Data Mining* (Han e Kamber, 2001). Estas ferramentas evoluíram de forma bastante significativa desde a década de 1980, e hoje são utilizadas nas mais diferentes áreas, especialmente aquelas que lidam com extensas bases de dados, da ordem de terabytes. Muitos dos procedimentos desenvolvidos objetivam primordialmente a compreensão de fenômenos extremamente complexos, para os quais a descoberta dos relacionamentos existentes entre as variáveis explicativas não é uma tarefa trivial. Exatamente por isso optou-se por sua utilização, uma vez que as tentativas feitas até hoje para obtenção de classificações e correlações a partir dos parâmetros geotécnicos tradicionais dos solos com suas propriedades resilientes, desenvolvidas em sua grande maioria com base em técnicas estatísticas convencionais, não obtiveram resultados que permitam sua utilização na prática de projeto com a confiabilidade adequada.

Em resumo, propõem-se o desenvolvimento de um classificador de solos quanto à resiliência e de um preditor dos valores do módulo de resiliência utilizando ferramentas de *Data Mining* e Redes Neurais Artificiais, a partir dos parâmetros geotécnicos já especificados para projetos de pavimentação. O uso exclusivo destes parâmetros visa não adicionar qualquer ensaio aos que já são de execução obrigatória, possibilitando desta forma que os estudos geotécnicos pertinentes continuem a ser executados sem alterações no que diz respeito aos procedimentos laboratoriais. Desta forma, o trabalho foi desenvolvido testando como variáveis explicativas os seguintes parâmetros geotécnicos: granulometria por peneiramento, limites de Atterberg, índice de grupo, densidade e umidade de compactação, CBR e expansão. Os demais parâmetros utilizados no estudo foram os pares de tensões aplicados no ensaio triaxial de cargas repetidas, os valores das deformações específicas resilientes, os módulos de resiliência e as constantes experimentais K_1 , K_2 e K_3 obtidas para o Modelo Composto, proposto por Macêdo (1996), conforme apresentado na Equação 1.1.

$$M_R = k_1 \sigma_3^{k_2} \sigma_d^{k_3} \quad (1.1)$$

1.2 – Organização do trabalho

O estudo desenvolvido é aqui apresentado em dez capítulos e um anexo, conforme descrito a seguir:

- *Capítulo 1 – Introdução*, onde é apresentada a motivação da pesquisa e o sumário da tese;
- *Capítulo 2 – Módulo de resiliência de solos e materiais não tratados quimicamente*, onde são apresentados os conceitos básicos de resiliência de solos, a metodologia de ensaio, modelos de comportamento resiliente desenvolvidos e tentativas já efetuadas para obtenção de classificações e correlações resilientes;
- *Capítulo 3 – Ferramentas de Data Mining para exploração da base de dados*, que consiste basicamente na descrição das metodologias e ferramentas computacionais disponíveis para análise da base de dados utilizada neste estudo;
- *Capítulo 4 – Redes Neurais Artificiais*, onde é apresentado um breve histórico do desenvolvimento desta ferramenta e os conceitos fundamentais para sua utilização, além de alguns trabalhos já desenvolvidos nesta linha na área de geotecnia;
- *Capítulo 5 – Base de Dados*, onde é apresentada a base elaborada com os resultados dos ensaios triaxiais dinâmicos disponíveis, executados no Laboratório de Geotecnia da COPPE/UFRJ, bem como uma descrição dos dados que a constituem, os critérios de inclusão dos mesmos e uma análise quanto às matrizes de correlação geradas a partir das variáveis consideradas;
- *Capítulo 6 – Agrupamento em famílias de solos quanto à resiliência*, onde são apresentados os procedimentos de segmentação das amostras quanto à resiliência, os algoritmos utilizados, bem como a análise dos resultados obtidos;
- *Capítulo 7 – Classificador de solos quanto à resiliência*, que consiste na apresentação dos classificadores desenvolvidos a partir dos agrupamentos realizados, bem como a análise de desempenho dos mesmos;

- *Capítulo 8 – Desenvolvimento das Redes Neurais Artificiais*, que consiste na explanação de todos os procedimentos efetuados relativos ao treinamento das redes, incluindo a metodologia e os resultados obtidos;
- *Capítulo 9 – Análise da influência dos erros de predição no dimensionamento de pavimentos flexíveis*, onde é apresentada a análise das conseqüências da modelagem efetuada com base nos resultados da rede neural escolhida em comparação àquela efetuada com os resultados dos ensaios triaxiais de cargas repetidas;
- *Capítulo 10 – Conclusões e sugestões para futuras pesquisas*
- *Referências Bibliográficas*
- *Anexo* – Onde é apresentado o aplicativo que permite a predição dos valores do módulo de resiliência, desenvolvido a partir da rede neural escolhida.

Capítulo 2

Módulo de Resiliência de Solos e Britas

O conceito de módulo de resiliência foi introduzido na pavimentação por Hveem (1955) *apud* Medina (1997). Este autor concluiu que o trincamento dos revestimentos betuminosos originava-se na deformação elástica das camadas subjacentes do pavimento, que gerava excessivos esforços de tração nos revestimentos. O termo resiliente foi introduzido visando diferenciar o comportamento elástico dos materiais utilizados em pavimentação daquele observado nos materiais mais comumente utilizados pelos engenheiros, como concreto, aço, etc. Esta diferenciação tornou-se necessária tendo em vista que as deformações recuperáveis (elásticas) nos pavimentos são muito superiores às aquelas observadas em outros tipos de estrutura. Em termos matemáticos, o módulo de resiliência (M_R) é definido como a razão entre a tensão desvio (σ_d) aplicada repetidamente e a deformação específica resiliente correspondente (ϵ_r), conforme a Equação 2.1.

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

Para efeito de simplificação, os solos, granulares e coesivos, e as misturas de materiais serão daqui por diante denominados apenas “solos”, entendendo-se que se tratam de materiais “in natura”, misturas de solos, solos e britas, britas graduadas ou corridas, desde que estabilizados granulometricamente, sem adição de estabilizantes químicos ou de materiais betuminosos. Os solos aqui denominados como coesivos são aqueles cujo comportamento resiliente é predominantemente influenciado pela tensão desvio, não necessariamente finos.

2.1 Metodologias de Ensaio

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. Os ensaios de carga repetida em que a força vertical aplicada atua sempre no mesmo sentido de compressão, de forma cíclica, de zero a um valor máximo, sendo depois descarregada até anular-se, para ser aplicada novamente após certo intervalo de repouso, visam simular estas condições. A

velocidade e o fluxo de tráfego são simulados respectivamente pelo tempo de pulso e frequência da carga aplicada.

Este ensaio tem basicamente duas fases. A primeira delas, chamada fase de condicionamento, objetiva reduzir a influência das grandes deformações plásticas e reduzir o efeito da história de tensões no valor do módulo de resiliência. É na verdade uma seqüência de carregamentos dinâmicos que permite dotar o material de uma condição como de “pré-adensamento”. A obtenção dos valores de M_R é feita na segunda fase do ensaio, onde para cada par de tensões σ_d (tensão desvio) e σ_3 (tensão confinante) aplicado é feita a medição da deformação resiliente. O módulo de resiliência é então calculado, obtendo-se, por regressão linear, os valores de K_i dos modelos de comportamento resiliente adotados.

Os primeiros ensaios triaxiais de cargas repetidas efetuados no Brasil foram apresentados em Preussler (1978), para solos arenosos e em Svenson (1980), para solos argilosos. Nestas duas teses foram utilizadas metodologias de ensaio que seguiram o padrão proposto por Hicks (1970) e que consistia na aplicação de pares de tensões σ_d e σ_3 escolhidos de forma a cobrir o estado de tensões gerado no pavimento pela passagem do eixo padrão e cargas próximas a este.

Estes métodos usados por Preussler e Svenson, utilizavam pares de tensões diferentes no ensaio caso o solo fosse arenoso ou argiloso, e serviram de base para a normatização feita pelo extinto Departamento Nacional de Estradas de Rodagem (DNER) em 1986, que resultou no método atual DNER ME 131/94. A partir de 1990, os pares de tensões utilizados na COPPE/UFRJ tem sido os constantes da Tabela 2.1 para todos os solos e britas, independentemente da quantidade de finos presentes na amostra. Esta alteração em relação à metodologia normatizada pelo extinto DNER foi efetuada tendo em vista o fato comprovado de que nem sempre a quantidade de finos determina o comportamento quanto ao modelo tensão-deformação não linear, e que na seqüência anteriormente usada para solos argilosos e siltosos necessariamente se admitia, à priori, que a tensão confinante não importava (mantida constante durante todo o ensaio). Além disso, as altas razões de tensão levavam inúmeras vezes à ruptura do corpo-de-prova por falta de confinamento e excesso de tensão vertical.

Em linhas gerais, no método hoje empregado na COPPE/UFRJ mantém-se a tensão confinante constante durante certo intervalo do ensaio, aplicando-se para cada valor de σ_3 três níveis de tensão desvio, conforme descrito na Tabela 2.1, para

qualquer material ou condição de compactação. Esta foi a metodologia empregada em todos os ensaios utilizados neste estudo.

Outra metodologia de ensaio bastante utilizada é a adotada na norma T 307 da AASHTO (2003), que define a seqüência de carregamento a ser empregada levando em consideração o tipo de material utilizado e sua função na estrutura. Assim, foram definidos para efeito de ensaio dois tipos de solos. O Solo Tipo 1 inclui todos os materiais destinados a bases e sub-bases e aqueles destinados ao subleito que apresentem menos de 70% passando na peneira n^o. 10 e no máximo 20% passando na peneira n^o. 200. Todos os solos destinados ao subleito que não se incluam na definição de Solo Tipo 1 são designados pela AASHTO como Solo Tipo 2, devendo ser submetidos ao ensaio triaxial de cargas repetidas mediante a aplicação de pares de tensões diferentes em relação ao Solo Tipo 1.

Ressalve-se que embora as metodologias de ensaio da COPPE/UFRJ e da AASHTO sejam distintas, os níveis de tensões aplicados são similares.

Tabela 2.1 – Níveis de Tensões do Ensaio Triaxial de Cargas Repetidas Padrão da COPPE/UFRJ para todos os Solos e Britas

Par de Tensões	σ_3 (MPa)	σ_d (MPa)	σ_1 / σ_3
1	0,021	0,021	2
2	0,021	0,041	3
3	0,021	0,062	4
4	0,034	0,034	2
5	0,034	0,069	3
6	0,034	0,103	4
7	0,051	0,051	2
8	0,051	0,103	3
9	0,051	0,155	4
10	0,069	0,069	2
11	0,069	0,137	3
12	0,069	0,206	4
13	0,103	0,103	2
14	0,103	0,206	3
15	0,103	0,309	4
16	0,137	0,137	2
17	0,137	0,275	3
18	0,137	0,412	4

2.2 Modelos de comportamento resiliente

Os solos têm seu comportamento tensão-deformação expresso por duas parcelas principais, a parcela relativa à deformação elástica, que cessa quando a estrutura é descarregada, e a parcela plástica, que dá origem a deformações permanentes, não recuperáveis com a retirada das cargas. Para quantificação da deformabilidade elástica destes materiais utiliza-se o Módulo de Resiliência (M_R). Uma característica marcante no comportamento destes materiais é que os mesmos 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. Em vista disso, foram criados diversos modelos que expressam M_R em função das tensões aplicadas aos materiais, especialmente a Tensão Desvio (σ_d) e a Tensão Confinante (σ_3).

Os modelos matemáticos para obtenção dos valores de M_R 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 as outras duas para solos de comportamento coesivo, Equações (2.3) e (2.4).

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

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

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

A Equação (2.2) é ainda hoje muito utilizada para descrever o comportamento resiliente de solos arenosos, sem coesão, tendo em vista que o valor de M_R destes materiais é preponderantemente dependente da tensão confinante, muito embora este modelo não seja capaz de descrever o efeito da dilatância, que influencia o comportamento tensão \times deformação destes solos. Segundo Uzan (1985), este modelo é adequado para utilização quando as deformações específicas situam-se na faixa de 0,0001 a 0,0005, valores observados em boa parte dos ensaios triaxiais de cargas repetidas executados dentro dos níveis de tensão atualmente utilizados. Preussler (1978) estudando solos arenosos oriundos da camada de sub-base do pavimento da rodovia BR-290/RS, obteve bons resultados com este modelo. Espinosa (1987) pesquisando o comportamento de uma brita com duas granulometrias distintas e utilizando corpos de prova de 10x20cm e 5x10cm obteve igualmente bons

resultados, independentemente do tamanho do corpo-de-prova e da granulometria do material.

Este modelo foi bastante empregado em diversos estudos, utilizando-se o mesmo como lei de comportamento resiliente de solos arenosos em estudos comparativos de bacias deflectométricas experimentais e aquelas obtidas através do programa FEPAVE2 (Medina, 1997). Os bons resultados auferidos consagraram-no por muito tempo como o que melhor infere os valores de M_R para solos granulares, sendo ainda muito utilizado no Brasil para este tipo de material.

As Equações (2.3) e (2.4) compõem o modelo conhecido como bi-linear, já que em escala aritmética os pontos experimentais que relacionam o M_R com σ_d se distribuem sobre duas retas. Utilizado para cálculo de M_R para solos coesivos, o modelo indica que abaixo de um determinado nível de tensão desvio, representado pela constante k_1 , os valores de M_R aumentam a uma razão bem superior do que aquela verificada para $\sigma_d < k_1$. Apesar da dificuldade experimental em determinar-se com exatidão o ponto em que as duas retas se interceptam, ou seja, a que nível de tensão desvio a razão de incremento do valor de M_R se acelera, e de não haver ainda uma explicação razoável para a brusca mudança de comportamento observada, o modelo bi-linear foi por muito tempo bastante utilizado, tendo sido inclusive adotado para avaliação das características resilientes de solos do subleito na metodologia de dimensionamento de reforço de pavimentos proposta por Pinto e Preussler (1982) e normatizada pelo antigo DNER através de seu procedimento DNER-PRO 269/94 (DNER, 1994).

Tendo em vista as dificuldades experimentais para determinação das constantes do modelo bi-linear, Svenson (1980) propôs para cálculo de M_R de solos coesivos o modelo representado pela Equação (2.5), em escala log-log, com k_2 negativo. Seu estudo, visando a verificação do comportamento resiliente de solos argilosos compactados, teve como principais objetivos a avaliação das influências dos seguintes fatores: método de compactação, umidade de compactação e tempo de cura. Esta pesquisa foi efetuada utilizando material proveniente do subleito de rodovias do Rio de Janeiro, Minas Gerais e Paraná, resultando na obtenção de valores das constantes k_1 e k_2 bastante variáveis, apresentando inclusive alguns valores muito elevados para as duas constantes. Este modelo é ainda muito utilizado para descrição da variação de M_R com a tensão desvio em solos coesivos.

$$M_R = k_1 \sigma_d^{k_2} \quad (2.5)$$

Motta, Aranovich e Ceratti (1985) estudaram um grande número de solos lateríticos provenientes das camadas do pavimento de diversas rodovias vicinais localizadas nos Estados de Goiás, Paraná, São Paulo, Mato Grosso e Mato Grosso do Sul, objetivando estabelecer modelos para previsão de módulos resilientes e agrupar os materiais em função do comportamento apresentado. Com base nos resultados dos ensaios triaxiais desta pesquisa, Aranovich (1985), propôs o modelo conhecido como combinado ou misto, conforme as Equações (2.6) e (2.7). Tal modelo caracteriza um comportamento resiliente intermediário, diferenciado dos modelos tradicionais para solos arenosos ou coesivos por considerar a influência conjunta das tensões desvio e confinante no valor de M_R , porém expressas por duas equações e cinco constantes.

$$M_R = [k_2 + k_3 (k_1 - \sigma_d)] \sigma_3^{k_5} \quad , \text{ para } \sigma_d < k_1 \quad (2.6)$$

$$M_R = [k_2 + k_4 (\sigma_d - k_1)] \sigma_3^{k_5} \quad , \text{ para } \sigma_d > k_1 \quad (2.7)$$

O modelo conhecido como K- θ , apresentado na Equação (2.8), considera para cálculo do valor de M_R o 1º Invariante de Tensões, ou seja, são levadas em conta todas as tensões principais aplicadas ao corpo-de-prova no ensaio triaxial de cargas repetidas. Segundo Allen e Thompson (1974), citados por Macêdo (1996), este modelo é capaz de produzir melhores ajustes de resultados experimentais em relação ao modelo em função apenas da tensão confinante. Entretanto, para a metodologia atualmente utilizada na execução do ensaio triaxial de cargas repetidas, os ajustes proporcionados pelo modelo de Hicks são geralmente melhores que os obtidos pelo modelo K- θ , considerando-se apenas o valor do coeficiente de correlação R^2 .

$$M_R = k_1 \theta^{k_2} \quad (2.8)$$

Outros modelos desenvolvidos em função do 1º Invariante de Tensões (θ) são apresentados nas Equações (2.9) e (2.10).

$$M_R = k_1 \theta^{k_2} \sigma_d^{k_3} \quad (2.9)$$

$$M_R = k_5 \theta^{k_6} \varepsilon_a^c \quad (2.10)$$

O modelo representado pela Equação (2.9) foi proposto por Uzan (1985) e, segundo o autor, quando de sua utilização devem ser levadas em conta nos valores de θ e σ_d as tensões residuais de compactação, além daquelas oriundas das cargas de roda.

O modelo representado pela Equação (2.10), onde ε_a é a deformação axial resiliente, foi utilizado por Espinosa (1987) em seu estudo do comportamento resiliente de britas, tendo ele concluído que para o material empregado em sua pesquisa este modelo produziu ajustes adequados entre as deformações calculadas e aquelas medidas nos ensaios triaxiais de cargas repetidas.

Outro comportamento observado em materiais utilizados em pavimentação é aquele em que os valores de M_R não variam com o estado de tensões, resultando em um modelo elástico-linear, conforme apresentado na Equação (2.11). Segundo Motta e Medina (1988), este comportamento é observado em materiais bastante distintos, ocorrendo tanto em solos com elevada percentagem de silte na fração fina, quando os valores modulares são muito baixos, quanto em argilas lateríticas e lateritas pedregulhosas, onde os valores de M_R podem ser bastante elevados.

$$M_R = K \quad (2.11)$$

As deficiências de cada um dos modelos aqui apresentados dizem respeito principalmente às seguintes limitações:

- Dificuldades experimentais para definição das constantes, especialmente no modelo bi-linear e no modelo combinado ou misto;
- Simplificações quanto ao real estado de tensões atuante, considerando-se nos modelos mais utilizados no Brasil apenas a influência de σ_3 ou de σ_d , isoladamente.

Macêdo (1996) propôs um modelo aparentemente capaz de eliminar as dificuldades quanto à necessidade de definição prévia do comportamento resiliente dos solos. Este modelo, denominado pelo autor como Modelo Composto, está representado na Equação (2.12), e leva em consideração a influência conjunta das tensões confinante e desvio para qualquer tipo de material. Além disso, os coeficientes de correlação R^2 obtidos por ele para este modelo atingem valores normalmente acima de 0,90, bastante superiores àqueles auferidos para os demais modelos considerados. Este fato pode indicar que a consideração conjunta dos reflexos de σ_3 e σ_d é de fundamental importância na determinação dos valores de M_R no ensaio triaxial de cargas repetidas, não sendo aconselhável a determinação do módulo de resiliência apenas em função de uma das tensões impostas ao corpo-de-prova.

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

Ferreira (2002) realizou uma extensa análise comparativa entre os modelos mais utilizados e o Modelo Composto, concluindo ser este o mais adequado dentre os que foram considerados, tendo em vista que o mesmo apresentou erros de modelagem muito inferiores aos demais quando comparados com os resultados dos ensaios triaxiais.

A versão do AASHTO GUIDE, publicada em 2002, indica um modelo generalizado para cálculo do Módulo de Resiliência, proposto por Uzan (1985), conforme apresentado na Equação 2.13.

$$M_r = k_1 \cdot P_a \left(\frac{\theta}{P_a} \right)^{k_2} \left(\frac{\tau_{oct}}{P_a} + 1 \right)^{k_3} \quad (2.13)$$

onde:

M_r	=	modulo resiliente, psi
θ	=	invariante de tensões = $\sigma_1 + \sigma_2 + \sigma_3$
σ_1	=	tensão principal maior.
σ_2	=	tensão principal intermediária = σ_3 para o ensaio de M_R em amostras cilíndricas.
σ_3	=	tensão principal menor / tensão de confinamento
τ_{oct}	=	tensão de cisalhamento octaédrica
	=	$\frac{1}{3} \sqrt{(\sigma_1 - \sigma_2)^2 + (\sigma_1 - \sigma_3)^2 + (\sigma_2 - \sigma_3)^2}$
P_a	=	pressão atmosférica
k_1, k_2, k_3	=	constantes experimentais

Takeda (2006) desenvolveu uma análise comparativa do desempenho deste modelo em relação ao Modelo Composto, concluindo que ambos são capazes de representar a variação do módulo de resiliência em função do estado de tensões com precisão equivalente.

2.3 Tentativas de obtenção de correlações e classificações resilientes

As tentativas de classificação de solos quanto à resiliência e de correlação de suas propriedades elásticas com suas propriedades geotécnicas tradicionalmente utilizadas em pavimentação vêm sendo feitas praticamente desde os primeiros estudos de deformabilidade elástica destes materiais. A motivação impulsionadora destas tentativas é a necessidade de obtenção das características resilientes dos materiais através de processos mais simples do que os ensaios triaxiais de cargas repetidas. Este ensaio, se comparado aos tradicionalmente utilizados em projetos de

pavimentação, exige a utilização de equipamentos tecnologicamente muito mais sofisticados, além de mão-de-obra mais qualificada. No Brasil, por exemplo, a grande maioria dos laboratórios de solos não está preparada para esta implementação tecnológica e, caso os órgãos rodoviários optassem por exigir de imediato a adoção deste ensaio, não haveria infra-estrutura de projeto capaz de atender tal exigência a curto ou mesmo médio prazos.

No Brasil, o primeiro esboço de classificação de solos quanto ao seu comportamento resiliente foi feito por Medina e Preussler (1980), com base nos resultados de ensaios triaxiais de cargas repetidas realizados na COPPE/UFRJ no período de 1977 a 1980. O Quadro 2.1, inserido a seguir, apresenta os critérios de enquadramento definidos pelos autores.

Este quadro não chega a ser uma classificação e, conforme Medina (1997) pode servir como primeira orientação para escolha de parâmetros K dos modelos de resiliência, estando aberto a modificações, à medida que se acumula experiência. Este quadro de características foi elaborado com base nos poucos resultados de ensaios triaxiais com solos brasileiros disponíveis na época, executados ainda com corpos de prova de 5x10cm, que requeriam o escalpo das frações granulométricas mais grossas. Ressalve-se também que um dos modelos utilizados para solos coesivos é o Bi-linear, de grande imprecisão experimental, e já substituído desde 1990 na prática da COPPE pelo modelo proposto por Svenson (1980). Constata-se ainda que, a menos da percentagem de silte presente na fração fina dos solos, os demais parâmetros de enquadramento são obtidos de ensaios tradicionais para materiais de pavimentação e das classificações TRB e USCS.

Quadro 2.1 – Características Resilientes de Solos Brasileiros,

Medina e Preussler (1980)

% que passa na peneira 200 (0,074mm); finos	Granulometria	Características Físicas (%)				Classe		Modelo $M_R = s(\sigma_3, \sigma_d)$	K	Avaliação como camada de pavimento e subleito				
		LL	IP	CBR	EXP.	TRB	USCS							
Menos de 50%: Solos Arenosos	Graduada (Faixa A)	<45	≤14	>20	< 0,5	A-1-b e A-2	SM e SC		K1=4000 K2=0,90	Resiliência Média. Se K2 < 0,5 e compactado no proctor modificado: Bom para camadas do pavimento				
	Uniforme (Faixa B)	NL	NP	<10	≥2	A-4 A-2-4	SM			K1 = 9500 K2 = 0,75	Se K2 < 0,5, espessura menor que 40 cm, acima de subleito de CBR > 10: Bom em camada do pavimento			
											A-2-6	SC	K1= 2800 K2=0,34	Resiliência Pequena. Em camadas de base e subbase: Muito bom.
											A-2-4	SM	K1= 2600 K2= 0,52	
Intermediária a Uniforme							K1=330 K2= 0,52	Resiliência Grande. Não deve ser utilizado em Pavimentos: Muito ruim como subleito (micáceos)						
Mais de 50%: Solos Argilosos (Lateríticos)	Silte / Finos < 50%	40 a 60	15 a 30	> 12	-	A-7 e A-6	CL e CH		K1=0,07 a 0,11 K2=223 (CBR) – 741 0 < K3 < 2840 K4=200 a –300 (CBR > 10) K4=0 (CBR < 10) K2=32+6,6 (CBR) – K4 (0,2 – K1)	Como subleito e reforço do subleito: bom; Como subbase: aceitável, às vezes				
	Silte / Finos > 50%	35 a 60	15 a 20	≤ 12	-	A-7 e A-6	ML e CL			K3=K4=0 M _R =32+6,6 (CBR)	Como subleito: médio a ruim; Como reforço do subleito: requer estudos e ensaios especiais			
										Como camada de pavimento: não utilizar; Como subleito: requer atenção e ensaios especiais				

O antigo DNER (1996) propõe uma classificação resiliente para solos, com base nos estudos de Pinto e Preussler, orientados por Medina, conforme descrito a seguir.

- Solos Granulares, considerados para fins de classificação resiliente como aqueles que apresentam menos de 35% em peso de material passando na peneira 200, que têm seu comportamento definido pelo modelo $M_R = k_1 \sigma_3^{k_2}$, subdivididos em três grupos A, B e C, cujas características são descritas a seguir, estando as envoltórias de cada grupo apresentadas na Figura 2.1.

Grupo A – Solos com grau de resiliência elevado – não devem ser empregados em estruturas de pavimentos e constituem subleitos de péssima qualidade.

Grupo B – Solos com grau de resiliência intermediário – podem ser empregados em estruturas de pavimentos como base, sub-base e reforço do subleito, ficando seu comportamento dependente das seguintes condições:

$K_2 \leq 0,50$; bom comportamento.

$K_2 > 0,50$; comportamento dependente da espessura da camada e da qualidade do subleito.

Grupo C – Solos com baixo grau de resiliência – podem ser empregados em todas as camadas do pavimento, resultando em estruturas com baixas deflexões.




Figura 2.1 – Classificação Resiliente dos Solos Granulares (DNER,1996)

- Solos Finos, considerados para fins de classificação resiliente como aqueles que apresentam mais de 35% em peso de material passando na peneira 200, que têm seu comportamento definido pelos modelos $M_R = k_2 + k_3 (k_1 - \sigma_d)$, para $\sigma_d < k_1$ e $M_R = k_2 + k_4 (\sigma_d - k_1)$, para $\sigma_d > k_1$, ou seja, o Modelo Bi-linear, divididos em três grupos:

Solo Tipo I – Solo de bom comportamento quanto à resiliência, como subleito e reforço do subleito, podendo ser utilizado também como camada de sub-base.

Solo Tipo II – Solo de comportamento regular quanto à resiliência, podendo ser usado como subleito e reforço do subleito.

Solo Tipo III – Solo de comportamento ruim quanto à resiliência. É vedado seu emprego em camadas de pavimento. Como subleito requer cuidados e estudos especiais.

Na impossibilidade de determinar os valores de M_R , pode-se estimar a classificação indiretamente, a partir da percentagem de silte na fração que passa na peneira 200, S%, e do CBR, conforme consta do Quadro 2.2.

Quadro 2.2 – Classificação dos Solos Finos (Método Indireto) - (Pinto, 1991)
(DNER,1996)

CBR (%)	S%		
	≤35	35 - 65	≥65
≤ 5	III	III	III
6 – 9	II	II	III
≥ 10	I	II	III

O antigo DNER (1996) cita ainda como modelos característicos para cada um dos três tipos de solos finos os transcritos a seguir. Diferentemente da descrição de classificação destes solos, para as classes I e II o modelo assume a formulação de Svenson a partir de 1996, e não o modelo Bi-linear, considerado na sua origem como representativo na elaboração desta classificação.

$$\text{Solo Tipo I : } M_R = 4.874 \sigma_d^{-1,129} \text{ (kgf/cm}^2\text{)} \quad (2.14)$$

$$\text{Solo Tipo II : } M_R = 1.286 \sigma_d^{-0,5478} \text{ (kgf/cm}^2\text{)} \quad (2.15)$$

$$\text{Solo Tipo III : } M_R = 530 \text{ kgf/cm}^2 \quad (2.16)$$

Outra tentativa de classificação, também constante no Manual de Pavimentos Flexíveis do DNER (1996), baseia-se em uma possível relação M_R /CBR, conforme apresentado no Quadro 2.3, que identifica três grupos de solos com relação à razão M_R /CBR, tendo como parâmetro delimitador a relação entre CBR e a percentagem total de argila.

Quadro 2.3 – Relação M_R /CBR – DNER (1996)

Grupo	CBR/ (% argila)	M_R /CBR
G (Solos de Comportamento Granular)	Maior que 0,474	40
I (Solos de Comportamento Intermediário)	Entre 0,202 e 0,474	120
C (Solos de Comportamento Coesivo)	Menor que 0,202	440
Solo Arenoso Fino	-	700

No caso da classificação MCT, foram obtidas relações M_R /CBR para cada uma das regiões definidas pelo ábaco da Figura 2.2.

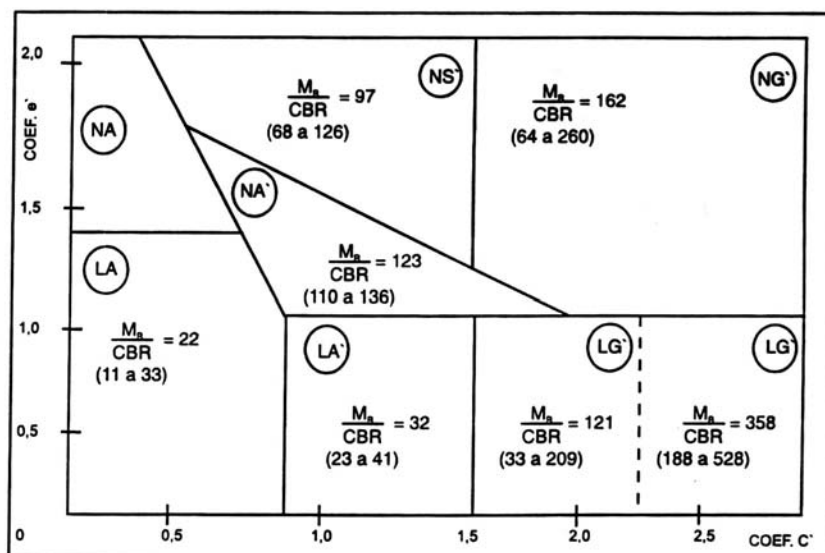


Figura 2.2 – Variação da Relação M_R/CBR com Classificação MCT (DNER, 1996).

Muitas outras tentativas têm sido feitas objetivando correlacionar o CBR ou outras características geotécnicas dos solos com o M_R . É bastante conhecida e utilizada a relação indicada na Equação 2.17, que relaciona diretamente o M_R com o CBR.

$$M_R = 100 \text{ CBR (kgf/cm}^2\text{)} \quad (2.17)$$

Esta correlação é uma simplificação daquela proposta por Heukelom e Klomp, *apud* Medina (1997), indicada na Equação 2.18, que originalmente correlaciona o módulo dinâmico, determinado no campo com o equipamento vibratório da Shell, e o CBR “in situ”. O resultado da equação é em MPa, variando o coeficiente de 5,2 a 20,7.

$$M_R = 10,4 \text{ (CBR)} \quad (2.18)$$

Medina e Preussler (1980) obtiveram a correlação a seguir apresentada, ensaiando solos argilosos com CBR inferior a 20% e utilizando $\sigma_d = 2 \text{ kgf/cm}^2$.

$$M_R = 326 + 67(\text{CBR}) \text{ (R}^2 = 0,82\text{)} \quad (2.19)$$

Para obtenção desta correlação, os pesquisadores aplicaram σ_d elevado procurando induzir altas tensões cisalhantes, como ocorre na penetração do pistão no ensaio CBR, objetivando torná-la mais verossímil.

Visser, Queiroz e Hudson (1981), pesquisando possíveis correlações entre M_R e os Limites de Atterberg com amostras coletadas e ensaiadas na Pesquisa de Inter-

relacionamento de Custos Rodoviários, obtiveram as correlações indicadas em 2.20 e 2.21.

- Solos argilosos

$$\log M_R = 2.932 + 0,0348(LL) + 0,293 \log (\sigma_d) - 0,0683 (LP) \quad (2.20)$$

- Solos arenosos

$$\log M_R = 3.848 + 0,0243(LL) + 0,101 \log (\sigma_d) - 0,0683 (LP) - 0,0198(LP) \times \log (\sigma_d) \quad (2.21)$$

Para elaboração destas correlações foram utilizadas amostras indeformadas nos ensaios triaxiais de cargas repetidas, obtidas mediante a extração de corpos de prova do subleito com tubos de paredes finas, a uma profundidade de 0,90m.

Motta, Aranovich e Ceratti (1985), em seu estudo de solos utilizados em pavimentos de baixo custo, obtiveram diversas correlações, conforme apresentadas a seguir, nas equações 2.22 a 2.38. Como, para uso destas correlações, era necessário distinguir o solo quanto ao aspecto resiliente, os autores utilizaram um procedimento estatístico de agrupamento em famílias, pré-determinando a formação de três grupos (*clusters*) conforme a classificação usual obtida em laboratório na época, ou seja, solos de módulo constante, solos de comportamento granular e solos de comportamento argiloso.

a) solos de módulo constante

$$\ln M_R = -0,244(h_{cp}) + 4,325(\gamma_{scp}) + 0,267(h_{ót}) - 0,007(CBR) + 0,019(\text{miniCBR}) + 0,026(\% < 2\mu) \quad (R^2 = 0,996) \quad (2.22)$$

$$\log M_R = -0,094(h_{cp}) + 1,957(\gamma_{scp}) + 0,092(h_{ót}) + 0,0168(\% < 2\mu) \quad (R^2 = 0,995) \quad (2.23)$$

b) solos de comportamento granular

$$\ln K_1 = 4,560(\gamma_{scp}) \quad (2.24)$$

$$\log K_1 = 1,980(\gamma_{scp}) \quad (R^2=0,996) \quad (2.25)$$

$$K_1 = 7159,038(\gamma_{scp}) - 678,630(h_{ót}) \quad (R^2=0,903) , \text{ ou} \quad (2.26)$$

$$K_1 = 102,513 (\text{CBR}) + 339,173(\%<2\mu) \quad (R^2 = 0,71) \quad (2.27)$$

$$K_2 = 0,191(\gamma_{\text{scp}}) \quad (R^2 = 0,861) \quad (2.28)$$

$$\log K_2 = -0,0048 \text{ GC} \quad (R^2 = 0,879) \quad (2.29)$$

$$\ln K_2 = 0,0111\text{GC} \quad (R^2 = 0,856) \quad (2.30)$$

c) solos de comportamento argiloso

$$K_1 = 0,594(\gamma_{\text{scp}}) \quad (R^2 = 0,951) \quad (2.31)$$

$$K_1 = 0,478(\gamma_{\text{scp}}) + 0,008(\%\text{silte}) \quad (R^2 = 0,961) \quad (2.32)$$

$$K_2 = 11.423,510(\gamma_{\text{scp}}) - 318,855(\% \#200) + 290,762(\%\text{silte}) \\ (R^2 = 0,874), \text{ ou} \quad (2.33)$$

$$K_2 = 13.284,866(\gamma_{\text{scp}}) - 92,348(\% \#200) - 225,125(\%\text{silte}) \\ (R^2 = 0,877) \quad (2.34)$$

$$\ln K_3 = 12,958(\gamma_{\text{scp}}) + 0,359(h_{\text{ót}}) - 0,192(\text{CG}) \quad (R^2 = 0,997), \text{ ou} \quad (2.35)$$

$$K_3 = 24.292,402(\gamma_{\text{scp}}) - 569,008(\%\text{silte}) \quad (R^2 = 0,788) \quad (2.36)$$

$$K_4 = -1.091,276(\gamma_{\text{scp}}) \quad (R^2 = 0,667), \text{ ou} \quad (2.37)$$

$$K_4 = -1.504,713(\gamma_{\text{scp}}) + 36,687(\%\text{silte}) \quad (R^2 = 0,774) \quad (2.38)$$

Constata-se que enquanto as correlações obtidas pelas equações (2.18), (2.19), (2.20) e (2.21) determinam um valor constante para M_R , ou seja, somente podem ser utilizadas considerando-se o comportamento elástico linear, aquelas obtidas por Motta, Aranovich e Cearatti (1985), podem ser utilizadas em modelos elástico não lineares. Além destas limitações, a menos do modelo representado na equação (2.18), todos os outros necessitam para sua utilização do conhecimento prévio do comportamento resiliente do material, o que, atualmente, somente pode ser obtido com segurança após a execução do ensaio triaxial de cargas repetidas, tornando estas correlações pouco aproveitáveis.

Na mesma linha, considerando o comportamento elástico linear, o AASHTO GUIDE (2002) indica a utilização de correlações com outras propriedades dos

materiais para determinação dos valores de M_R , considerando rodovias nível 2, conforme apresentado no quadro 2.4.

Quadro 2.4 – Correlações utilizadas pela AASHTO (2002)

Propriedades	Modelo*	Comentários
CBR	$M_R = 2555(\text{CBR})^{0,64}$	CBR = Índice Suporte Califórnia (%)
Valor R	$M_R = 1155 + 555R$	R = Valor R (AASHTO GUIDE 1993)
Coefficiente estrutural de camada da AASHTO	$M_R = 30000(a_i / 0,14)$	a_i = Coeficiente de camada da AASHTO

* Valores de M_R em psi

Para rodovias nível 3, o AASHTO GUIDE (2002) indica a utilização de valores típicos de M_R com base na classificação do material considerando a umidade ótima de compactação, conforme apresentado no quadro 2.5.

Quadro 2.5 – Valores típicos de M_R para materiais granulares e de subleito,

(AASHTO 2002)

Classificação do Material	Faixa de Valores do M_R (psi)	Valores Típicos de M_R (psi)	Valores Típicos de M_R (MPa)
A-1-a	38.500 – 42.000	40.000	287
A-1-b	35.500 – 40.000	38.000	272
A-2-4	28.000 – 37.500	32.000	229
A-2-5	24.000 – 33.000	28.000	201
A-2-6	21.500 – 31.000	26.000	186
A-2-7	21.500 – 28.000	24.000	172
A-3	24.500 – 35.500	29.000	208
A-4	21.500 – 29.000	24.000	172
A-5	17.000 – 25.500	20.000	143
A-6	13.500 – 24.000	17.000	122
A-7-5	8.000 – 17.500	12.000	86
A-7-6	5.000 – 13.500	8.000	57
CH	5.000 – 13.500	8.000	57
MH	8.000 – 17.500	11.500	82
CL	13.500 – 24.000	17.000	122
ML	17.000 – 25.500	20.000	143
SW	28.000 – 37.500	32.000	229
SP	24.000 – 33.000	28.000	201
SW-SC	21.500 – 31.000	25.500	183
SW-SM	24.000 – 33.000	28.000	201
SP-SC	21.500 – 31.000	25.500	183
SP-SM	24.000 – 33.000	28.000	201
SC	21.500 – 28.000	24.000	172
SM	28.000 – 37.500	32.000	229
GW	39.500 – 42.000	41.000	294
GP	35.500 – 40.000	38.000	272
GW-GC	28.000 – 40.000	34.500	247
GW-GM	35.500 – 40.500	38.500	276
GP-GC	28.000 – 39.000	34.000	244
GP-GM	31.000 – 40.000	36.000	258
GC	24.000 – 37.500	31.000	222
GM	33.000 – 42.000	38.500	276

Uma avaliação elementar das correlações e valores típicos indicados para utilização em projeto pela AASHTO foi feita, mediante a confrontação dos valores de M_R obtidos para a amostra n^o. 201 da base de dados utilizada neste estudo. Esta amostra trata-se de brita corrida, com CBR de 79% e classificada como A-1-a. Para o nível 2 de projeto da AASHTO, o valor de M_R utilizando-se a correlação com CBR seria de aproximadamente 300 MPa. Para o nível 3 de projeto, no qual se considera apenas valores típicos em função da classificação do material, o valor de M_R seria de aproximadamente 287 MPa. Já no ensaio triaxial de cargas repetidas, executado segundo a metodologia empregada pela COPPE/UFRJ, o valor de M_R variou de 195 a 480 MPa, com média de 313 MPa, considerando-se evidentemente o comportamento elástico não linear do material. Constata-se assim que, em termos médios, os valores de M_R obtidos segundo as indicações da AASHTO são razoavelmente compatíveis com aquele obtido no ensaio. Entretanto, considerando-se o comportamento não linear do material, o valor médio pode não ser representativo da realidade. Imaginando-se um pavimento onde este material fosse empregado na camada de base, o que é muito comum, e considerando-se ainda uma camada de revestimento razoavelmente espessa, é muito provável que o estado de tensões vigente resultasse em um valor de M_R mais próximo do limite inferior obtido no ensaio. Considerando então a metodologia da AASHTO, os valores de M_R obtidos seriam aproximadamente 50% superiores ao real, ocasionando o subdimensionamento da estrutura.

Conclusivamente constata-se que, apesar das inúmeras tentativas implementadas por diversos autores para obtenção de classificações resilientes consistentes e de correlações confiáveis de M_R com outras propriedades geotécnicas, os resultados obtidos ainda deixam muito a desejar, não havendo condição de se generalizar essas classificações e correlações. Isto ocorre em função da extrema variabilidade dos materiais, que muitas vezes não se enquadram devidamente em nenhum dos grupos classificatórios indicados ou, no que diz respeito às correlações para obtenção do valor de M_R , apresentam resultados muito diferentes daqueles obtidos em ensaios triaxiais de cargas repetidas.

No caso das classificações comentadas, o enfoque determinístico dado às mesmas pode ser um dos fatores de seu insucesso. Diretrizes fechadas, como, por exemplo, definir famílias de comportamento resiliente segundo os percentuais de silte contidos na fração de solos que passa na peneira 200, ou determinar que solos que apresentam menos de 50% em peso passando na peneira 200 tenham comportamento arenoso são procedimentos por demais determinísticos para a

natureza dos materiais analisados. Quanto às correlações, obtidas normalmente por meio de regressões, os maus resultados podem ser devidos também à técnica estatística utilizada na sua obtenção, que não permite determinar quais das variáveis consideradas realmente influenciam nos resultados de módulo e/ou no valor correto dos coeficientes K_i das equações que regem o comportamento resiliente de um determinado material.

Os resultados insatisfatórios obtidos quanto a classificações e correlações de propriedades resilientes dos solos com os parâmetros geotécnicos tradicionais, indicam que as relações entre estas características são por demais complexas para que sejam convenientemente modeladas mediante o emprego das técnicas até agora utilizadas. Assim sendo, neste trabalho optou-se por empregar outros procedimentos na tentativa de obter resultados mais consistentes e generalizáveis, constituídos de ferramentas de *Data Mining*, que têm se mostrado capazes de modelar com boa precisão fenômenos altamente complexos. Estas ferramentas estão detalhadas nos Capítulos 3 e 4, e os resultados obtidos em sua utilização nos Capítulos 6 e 7.

Capítulo 3

Ferramentas de Data Mining Para Exploração da Base de Dados

O objetivo deste capítulo é apresentar as principais ferramentas disponíveis para utilização em análises e extração de conhecimentos da base de dados elaborada para este trabalho. São apresentados os conceitos básicos das metodologias consideradas as mais aplicáveis, procurando-se descrever de forma sintetizada os processos que podem ser utilizados na busca da melhor compreensão do comportamento resiliente dos solos.

A análise, apresentada nos Capítulos 5, 6 e 7, foi desenvolvida em três etapas, nas quais foram utilizados alguns dos procedimentos descritos a seguir, considerados fundamentais para obtenção dos resultados pretendidos.

A etapa inicial consistiu do pré-processamento dos dados. No caso dos ensaios geotécnicos utilizados neste estudo este procedimento torna-se imprescindível, tendo sido desenvolvido de maneira extremamente criteriosa. Isto se dá em função da baixa confiabilidade destes ensaios, cujos resultados são muito dependentes de fatores tais como operador e equipamento utilizados.

A seguir, foram utilizadas técnicas de agrupamento para determinação do número de famílias existentes na base de dados em função de suas características resilientes.

Por último, foram utilizadas técnicas para desenvolvimento de um classificador de solos em famílias de comportamento resiliente. Com base nas técnicas de classificação foram obtidas regras de relacionamento dos diversos tipos de solos e seu comportamento resiliente.

3.1 – Aspectos gerais

Na década de 1980 teve início o desenvolvimento de processos destinados à extração do conhecimento contido em bancos de dados, ou seja, processos que objetivam identificar e interpretar padrões de dados, reunidos em uma disciplina denominada *KDD (Knowledge Discovery in Databases)*. *KDD* busca descobrir correlacionamentos e dados implícitos nos registros de um banco de dados, extraíndo-os

para obter conhecimento novo, útil e de interesse, ou seja, enfoca o processo global de descoberta do conhecimento contido em dados, incluindo como estes são armazenados e acessados. *KDD* é um processo iterativo e interativo, transformando dados de baixo nível como, por exemplo, os parâmetros geotécnicos, em conhecimento de alto nível como, por exemplo, o relacionamento entre esses parâmetros, preocupando-se em extrair conhecimento útil para o usuário a partir da recuperação de informações, fazendo com que o próprio usuário procure o que lhe interessa em um conjunto de dados pré-selecionado (Furtado, 2004).

KDD é um processo desenvolvido em três etapas básicas: pré-processamento, que objetiva a análise, integração, transformação e limpeza dos dados; *Data Mining*, que se refere à aplicação de algoritmos de extração de padrões; pós-processamento, que consiste na seleção e ordenação das descobertas, representação inteligível do conhecimento e geração de relatórios. *Data Mining* é por natureza um campo multi-disciplinar, tendo sido desenvolvidos trabalhos para áreas que incluem tecnologia de base de dados, inteligência artificial, aprendizagem de máquina, redes neurais, estatística, reconhecimento de padrões, aquisição de conhecimento, acesso a informação, computação de alto desempenho e visualização de dados (Han e Kamber, 2001). Os conceitos de *KDD* e *Data Mining* são muito interligados. Assim, muitos referem-se a *Data Mining* como um sinônimo de *KDD*, enquanto outros consideram *Data Mining* apenas como um passo essencial no processo *KDD*. Adotou-se neste trabalho o termo *Data Mining* como referindo-se a todo o processo de descoberta de conhecimento em bases de dados. A descrição dos conceitos e processos citados é apresentada a seguir, tendo com referência básica o trabalho de Han e Kamber (2001).

Os processos de descoberta de conhecimento em bases de dados consistem resumidamente dos seguintes passos:

- Limpeza dos dados, para remover “ruídos” e dados inconsistentes;
- Integração dos dados, onde múltiplas fontes de dados podem ser combinadas;
- Seleção dos dados, onde dados relevantes para as tarefas de análise são recuperados da base de dados;
- Transformação dos dados, onde os dados são transformados e consolidados na forma apropriada para as tarefas de mineração

mediante operações de agregação ou sumarização;

- Mineração dos dados, onde processos inteligentes são aplicados de forma a extrair padrões dos dados;
- Avaliações de padrões, para identificar aqueles realmente interessantes, que representam conhecimento, com base em algumas medidas de interesse;
- Apresentação do conhecimento, onde são usadas técnicas de visualização e representação do conhecimento extraído da base de dados pelo usuário.

Os quatro primeiros passos referidos podem ser agrupados como tarefas de pré-processamento dos dados, o quinto passo refere-se explicitamente à utilização dos procedimentos computacionais destinados à extração do conhecimento e os dois últimos referem-se às tarefas de pós-processamento.

3.2 - Pré-processamento

➤ Limpeza de dados

As bases de dados do mundo real são altamente suscetíveis a “ruídos” e valores faltantes ou inconsistentes. Assim, nesta fase de pré-processamento, a limpeza dos dados assume grande relevância, tendo em vista que a consideração de dados inconsistentes pode prejudicar de maneira sensível tanto o processamento quanto a análise de seus resultados, podendo ocasionar inclusive interpretações equivocadas em termos de relacionamento de variáveis, valores esperados, etc. Em uma situação extrema, por exemplo, a presença de inconsistências em uma base de dados pode levar à conclusão errônea de que não há conhecimento relevante a ser extraído da mesma, fator que se agrava de forma inversa ao número de padrões disponível para análise, ou seja, quanto menor a base de dados maior o prejuízo causado pela presença de valores discrepantes, faltantes ou inconsistentes. Os procedimentos utilizados para tratar esses problemas são os seguintes:

❖ Valores Faltantes

- Ignorar a amostra, o que, como regra geral, pode ser muito prejudicial em pequenas bases de dados;

- Preencher o valor faltante manualmente, o que somente é possível em bases de dados de pequenas dimensões;
- Usar uma constante global para preencher o campo, por exemplo, “desconhecido” ou “∞”, o que pode induzir o programa de mineração a considerá-la como um valor de interesse, já que os campos assim preenchidos traduzem um eventual relacionamento entre as amostras para as quais foram utilizados. Portanto, apesar de ser um método simples, não é recomendado;
- Usar um valor médio do atributo para preencher os valores faltantes;
- Usar o valor médio do atributo para todas as amostras de uma determinada classe, o que, evidentemente, exige o conhecimento prévio das classes existentes na base de dados;
- Usar o valor mais provável, o que pode ser feito por meio de procedimentos estatísticos ou outros métodos de inferência, como redes neurais e árvores de decisão. Apesar de ser o método mais trabalhoso, é sem dúvida o mais indicado.

❖ Ruídos

Ruídos são erros randômicos ou em desacordo com a medida da variável, por exemplo, CBR = 2000, % passante na peneira 40 = -18%. Os procedimentos mais utilizados para identificação de ruídos são os seguintes:

- Clusterização, quando amostras similares são alocadas em grupos, ou *clusters*. Intuitivamente, valores não alocados em nenhum dos grupos identificados podem ser ruídos, ou *outliers*;
- Inspeção combinada, manual e computacional, que somente é viável para bases de dados de pequenas dimensões;
- Regressão, que pode ser utilizada para identificar *outliers* mediante a obtenção do modelo de variação de uma variável dependente em relação a uma ou mais variáveis explicativas.

❖ **Valores Inconsistentes**

São aqueles que apresentam discrepâncias em códigos ou nomes, do tipo “Idade = 42 e Data de Nascimento = 03/07/1997”. Podem também ocorrer quando um dado atributo tem diferentes nomes em diferentes bases de dados, ou quando há discrepâncias em registros duplicados. Normalmente a correção de dados inconsistentes é feita de forma manual.

➤ **Integração e Transformação de Dados**

As aplicações de *Data Mining* frequentemente requerem a integração, que é a reunião de dados de diferentes fontes de armazenamento, e a transformação, que consiste em converter os dados em uma forma apropriada para realizar as tarefas de mineração.

❖ **Integração de dados**

A tarefa mais importante relativa à integração de diferentes bases de dados consiste na detecção de eventuais conflitos nos valores dos dados, resultantes, por exemplo, de diferentes representações ou diferentes escalas de quantificação de um mesmo atributo.

Outra questão importante é a presença de redundâncias na base de dados já integrada. Essas redundâncias podem ocorrer quando um mesmo atributo tem nomes diferentes em bases de dados distintas, ou quando um atributo é uma derivação de um determinado atributo de outra base de dados. Geralmente as redundâncias são detectadas por meio de uma análise de correlação.

Assim, uma integração de bases de dados de diferentes fontes realizada com cuidado pode ajudar a reduzir ou evitar redundâncias e inconsistências na base de dados resultante. Isto pode auxiliar na acurácia e velocidade dos subseqüentes processos de mineração.

❖ **Transformação de dados**

Esta tarefa consiste na transformação e na consolidação dos dados em formas apropriadas para execução dos procedimentos de mineração, podendo envolver os seguintes passos:

- *Smoothing*, que se destina a remover os “ruídos” presentes nos dados;

- Agregação, quando operações de agregação e sumarização são aplicadas aos dados, tipicamente utilizados na construção de “*data cubes*” para análises em múltiplas granularidades;
- Generalização, quando um dado primitivo, ou de “baixo nível” do tipo “idade” é substituído por um conceito de “alto nível” como, “jovem, meia-idade, idoso”;
- Normalização, quando os dados são escalados dentro de uma faixa específica, como, por exemplo, de -1,0 a 1,0 ou de 0,0 a 1,0;
- Construção de atributos, quando novos atributos são definidos e adicionados a um determinado conjunto para auxiliar no processo de mineração.

➤ **Redução de dados**

As técnicas de redução de dados são utilizadas tendo em vista o fato de que a mineração em bases de dados de menores dimensões torna-se mais eficiente, produzindo aproximadamente os mesmos resultados obtidos nas bases completas. Entretanto, somente podem ser implementadas quando há condições de garantir que a base de dados reduzida mantém a integridade da base original para fins de análise. Contudo, a utilização destes procedimentos normalmente só é interessante, e eventualmente indispensável, em bases de dados muito extensas, da ordem de gigabytes ou terabytes.

As estratégias para redução de dados incluem as seguintes:

- Agregação em “*data cubes*”, quando operações de agregação são aplicadas na construção de “*data cubes*”;
- Redução de dimensões, quando atributos irrelevantes, pouco relevantes ou redundantes podem ser detectados e removidos;
- Compressão de dados, quando mecanismos de codificação ou transformações são utilizados para reduzir ou “comprimir” os dados originais;
- *Numerosity reduction*, quando os dados podem ser substituídos ou estimados por alternativas como modelos paramétricos e não-

paramétricos;

- Discretização e geração de conceitos hierárquicos, quando linhas de valores de dados são substituídas por faixas de valores ou níveis conceituais superiores, do tipo árvores de decisão.

A maioria destas estratégias é destinada a aplicações em bancos de dados de grande porte, o que não é o caso daquele disponível para este trabalho. Considerou-se que as estratégias aplicáveis ao banco de dados objeto deste estudo são aquelas relativas à limpeza dos dados. Assim, de forma manual, os padrões foram analisados buscando identificar dados discrepantes. Quanto a valores faltantes, optou-se por desconsiderar as amostras para as quais não se possuía todos os atributos escolhidos para desenvolvimento das análises.

3.3 - Agrupamento

As amostras contidas em uma base de dados normalmente possuem uma grande quantidade de atributos que, por suas semelhanças, formam classes distintas. Entretanto, a formação dessas classes, ou grupos, pode não constituir um processo trivial, em face da quantidade de objetos, do número de seus atributos e da sutileza das diferenças apresentadas.

Em virtude da disseminação da tecnologia de bancos de dados ocorrida nas últimas décadas, o volume de informações disponíveis é cada vez maior, atingindo valores da ordem de terabytes, o que inviabiliza a sua análise direta. Mesmo para bases de dados menores, a separação em grupos pode ser complexa, tendo em vista que os relacionamentos que eventualmente ocorrem entre as amostras podem não ser facilmente detectáveis.

As técnicas de agrupamento, que são exploratórias por natureza, objetivam justamente otimizar a separação entre os objetos de uma coleção, possibilitando a descoberta de novos padrões, previamente desconhecidos e insuspeitos. Muito embora essas técnicas não sejam ainda capazes de determinar os grupos com total precisão, é um consenso que grupos bem formados são aqueles que apresentam a mínima distância entre os seus objetos e a máxima distância para os demais grupos.

➤ Métodos de Agrupamento

O processo de perceber padrões e agrupar objetos tendo por origem uma grande coleção não é tarefa simples, sendo necessária a utilização de algoritmos de segmentação, especializados em descoberta e formação de grupos de dados.

Segmentação é o processo de agrupamento dos dados em classes ou grupos, de maneira que objetos dentro de um mesmo grupo tenham elevada similaridade, mas objetos pertencentes a grupos distintos sejam muito diferenciados. Para a mensuração de tais similaridades (ou dissimilaridades) são utilizadas diversas técnicas, normalmente baseadas em medidas de distância. É extremamente útil quando não se tem conhecimento prévio sobre o conjunto de dados em questão e é necessário separá-lo em grupos.

De maneira geral, a maioria dos métodos de agrupamento pode ser classificada em cinco grandes categorias: métodos particionais, métodos hierárquicos, métodos baseados em densidade, métodos baseados em malhas e métodos baseados em modelos. A seguir, cada uma das categorias citadas será apresentada com mais detalhes.

❖ Métodos particionais

Considerando-se que n é o número de objetos de uma base de dados e k é o número de grupos desejado, os algoritmos particionais irão gerar k partições utilizando medidas de distância, visando otimizar uma determinada função objetivo, de forma que objetos comparados dentro de uma certa partição guardem máxima similaridade e objetos comparados com objetos de outras partições apresentem mínima similaridade.

Os métodos particionais clássicos mais conhecidos e utilizados são o “*K-Means*” e o “*K-Medoids*”. O método “*K-Means*” é baseado no conceito estatístico do centróide de forma que a semelhança dos objetos “intragrupo” seja alta e a semelhança entre objetos de grupos diferentes, “intergrupo”, seja baixa. Um dos problemas relacionados a este algoritmo é sua grande sensibilidade a dados fora do padrão, ou seja, objetos que tenham um valor extremamente alto ou baixo, que podem causar grandes distorções nos resultados.

Em contrapartida, o método “*K-Medoids*” procura reduzir a sensibilidade a objetos isolados, desconsiderando o centro do grupo como ponto de referência para utilizar o medóide, que é o objeto localizado mais próximo ao centro do grupo. Assim,

este método pode abrandar a influência de objetos isolados, baseando-se no princípio de minimização da dessemelhança entre os objetos de um grupo e o seu ponto de referência. Inicialmente, este algoritmo de segmentação arbitra para cada grupo um objeto como seu representante (o medóide). Cada objeto remanescente é agrupado com o medóide ao qual possui a maior semelhança. Então, iterativamente, é substituído um medóide por um não-medóide, desde que a qualidade da segmentação resultante seja melhor. Esta qualidade é calculada usando uma função de custo que determina a medida de dessemelhança média entre um objeto e o medóide de seu grupo.

Comparativamente, o “*K-Medoids*” pode ser considerado como mais robusto que o “*K-Means*” por trabalhar de forma mais eficiente na presença de dados isolados e outros ruídos, em decorrência do medóide sofrer menos influência de dados desse tipo. Contudo, seu processamento tem maior custo computacional que o método “*K-Means*”. Mas, ambos os métodos apresentam o mesmo problema básico, que é a necessidade de determinação prévia do número de grupos.

❖ **Métodos hierárquicos**

Os métodos hierárquicos de segmentação trabalham agrupando objetos em uma estrutura de árvore de grupos. Estes métodos podem ser classificados de acordo com a estratégia utilizada na decomposição hierárquica como *bottom-up* ou *top-down*, conforme descrito a seguir:

Segmentação hierárquica aglomerativa: esta estratégia *bottom-up* inicia por considerar cada objeto como sendo seu próprio grupo, efetuando a partir daí sucessivas fusões destes grupos em conjuntos maiores, até que todos os objetos estejam alocados em um único grupo, ou até que determinadas condições de conclusão sejam satisfeitas. A maioria dos métodos hierárquicos utiliza esta estratégia, havendo diferenciações apenas na determinação da semelhança “intergrupo”.

Segmentação hierárquica divisiva: esta estratégia *top-down* trabalha no sentido inverso da estratégia *bottom-up*, considerando de início todos os objetos como pertencentes a um único grupo, efetuando a partir daí divisões sucessivas, até que cada objeto forme o próprio grupo ou até que sejam satisfeitas determinadas condições de conclusão, tais como a obtenção de um número desejado de grupos ou que a distância entre dois grupos ultrapasse certo limiar.

A grande vantagem dos métodos hierárquicos reside na simplicidade de interpretação dos resultados. Entretanto, algumas deficiências a eles inerentes podem comprometer seriamente os resultados da segmentação. Estas deficiências referem-se principalmente a uma decisão crítica, que é a seleção dos pontos de fusão ou de divisão, pois uma vez que um grupo de objetos é fundido ou dividido, o próximo passo será processado com base no grupo recém gerado, já que estes métodos não têm habilidade para efetuar ajustes após uma fusão ou divisão terem sido executadas. Assim, se as fusões ou divisões não são bem feitas em alguma etapa do processamento, o resultado final da segmentação pode ficar seriamente comprometido.

Além deste problema crítico, os métodos hierárquicos apresentam como desvantagem a impossibilidade para avaliar se a fusão ou a divisão efetuadas resultam no número ideal de grupos.

❖ **Métodos baseados em densidade**

Os métodos de segmentação baseados em densidade foram desenvolvidos com o objetivo de suprimir as deficiências dos métodos particionais no que se refere à detecção de grupos com formas arbitrárias, ou seja, grupos cujos objetos se apresentam dispersos em uma distribuição espacial bastante irregular. Esses métodos consideram os grupos como regiões densas de objetos separados no espaço por regiões de baixa densidade.

Os principais algoritmos de segmentação implementados com base nestes princípios são os seguintes:

DBSCAN (*Density-Based Spatial Clustering of Application with Noise*): o algoritmo identifica regiões com suficientemente alta densidade, definindo-as como grupos, e é capaz de detectar agrupamentos de formas arbitrárias no espaço de dados, inclusive na presença de ruídos.

A idéia básica do agrupamento com base em densidade envolve novos conceitos, que são o raio de definição da vizinhança - ϵ , e o número mínimo de ocorrências, *MinPts*. A partir desses parâmetros, que são pré-definidos, o DBSCAN verifica a vizinhança próxima de cada objeto. Se a vizinhança de um objeto p contém um número mínimo de ocorrências, então p será considerado como centro de um novo grupo a ser criado em seu entorno, chamado de vizinhança próxima. A partir daí o

algoritmo irá agrupar, de forma iterativa, os objetos com “densidade de alcance” direta em relação ao centro dos grupos, ou seja, os objetos mais próximos são agrupados ao centro de maneira que o grupo mantenha alta densidade. Este processo pode envolver a fusão de grupos com pouca densidade e termina quando nenhum ponto novo pode ser incluído em qualquer grupo. Todo objeto não contido em qualquer um dos grupos formados será considerado como ruído.

OPTICS (*Ordering Points To Identify the Clustering Structure*): este método foi proposto para suprimir uma deficiência do DBSCAN, que é a necessidade de definir *a priori* os parâmetros de entrada. Como visto, o algoritmo DBSCAN depende da introdução de parâmetros ϵ e *MinPts*. Estes parâmetros são definidos de forma empírica, e sua determinação é bastante complexa para bases de dados do mundo real, notadamente aquelas de grandes dimensões. Por exemplo, combinações de parâmetros de entrada apenas levemente diferentes podem conduzir a formação de agrupamentos muito discrepantes em relação aos dados analisados. Além disso, coleções de dados reais com muitas dimensões têm freqüentemente uma inclinação de distribuição induzida por sua estrutura intrínseca, que não pode ser caracterizada por parâmetros de densidade globais.

De forma a superar a dependência originada pelos parâmetros de entrada, o algoritmo OPTICS foi desenvolvido de forma a realizar o cômputo da “ordenação aumentada de agrupamentos” para análise interativa e automática. Esta ordenação representa a estrutura dos dados agrupados por densidade e contém informações que são equivalentes às obtidas em um largo espectro de parâmetros de entrada. Em seu processamento, o algoritmo OPTICS cria uma ordenação dos objetos, armazenando adicionalmente a distância de núcleo e a distância de alcance mais satisfatória para cada objeto, que serão posteriormente usadas para extrair os grupos baseados em densidade.

DENCLUE (*DENsity-based CLUstEring*): é um método baseado em um conjunto de funções de distribuição de densidade, tendo sido desenvolvido com base nos seguintes princípios:

- a influência de cada objeto que compõe uma base de dados pode ser formalmente modelada usando uma função matemática, chamada função de influência, que descreve o impacto de um certo objeto em sua vizinhança;

- a densidade global do espaço de dados pode ser modelada analiticamente como a soma das funções de influência de todos os objetos;
- os grupos podem então ser determinados matematicamente identificando-se a densidade de atração, que é o máximo local da função de densidade global.

As principais vantagens do DENCLUE quando comparado aos demais algoritmos são as seguintes:

- sólida fundamentação matemática e generalização em comparação com outros métodos de segmentação;
- boa capacidade de segmentação em coleções de dados com elevada presença de ruídos;
- permite a descrição matemática para formas arbitrárias de grupos de dados de grandes dimensões;
- utilização de malhas que contêm somente informações sobre a estrutura das células, sendo assim significativamente mais rápidos que alguns algoritmos mais influentes como o DBSCAN.

❖ **Métodos baseados em malhas**

A abordagem de agrupamento feita por estes métodos baseia-se em uma malha de estrutura de dados com múltipla resolução, que divide o espaço de dados em células retangulares. Usualmente, vários níveis de células retangulares correspondem a diferentes níveis de resolução, formando uma estrutura hierárquica. Dessa forma, o espaço de estudo é quantificado em um número finito de células que formam uma malha sobre a qual todas as operações de segmentação serão realizadas.

Alguns exemplos típicos dos métodos baseados em malhas são o STING, que explora informações estatísticas armazenadas nas células da malha; *WAVECLUSTER*, que agrupa os objetos usando o método de transformada ondaleta, e CLIQUE, que é uma combinação de abordagens baseadas em malhas e em densidade para segmentação de bases de dados multidimensionais.

❖ Métodos baseados em modelos

Estes métodos buscam criar um modelo hipotético para cada grupo desejado e procuram ajustar os dados da melhor maneira ao modelo criado. Os algoritmos baseados nestes métodos são bastante robustos, pois têm capacidade de descobrir os grupos através de funções de densidade que refletem a distribuição espacial dos objetos e disponibilizam ferramentas para determinação automática do número de grupos baseados em padrões estatísticos, inclusive em presença de ruídos ou dados fora do padrão. São usualmente baseados na hipótese de que os dados são originados de acordo com uma probabilidade estatística de distribuição. Os métodos de modelos seguem duas principais abordagens: a abordagem estatística e a abordagem de redes neurais.

A abordagem estatística é uma forma de segmentação que utiliza aprendizado de máquina, também conhecida como segmentação conceitual. Dado um conjunto de objetos não rotulados, o método produz um esquema de classificação que vai além dos dados. Diferentemente da segmentação convencional, que basicamente identifica grupos de objetos afins, a segmentação conceitual é um passo a mais para também descrever as características de cada grupo, onde cada grupo representa um conceito ou classe. Portanto, a segmentação conceitual é um processo desenvolvido em duas etapas: primeiramente, é realizada a segmentação e depois a caracterização. Neste método, a avaliação da qualidade da segmentação não é somente função dos objetos individuais, pois ela incorpora fatores como a generalidade e a simplicidade derivadas da descrição dos conceitos.

O COBWEB, por exemplo, é um método simples e bastante popular de segmentação conceitual. Nele, os objetos introduzidos são descritos por pares de atributos categóricos e a segmentação é hierárquica, em forma de uma árvore de classificação, como pode ser visto na Figura 3.1.

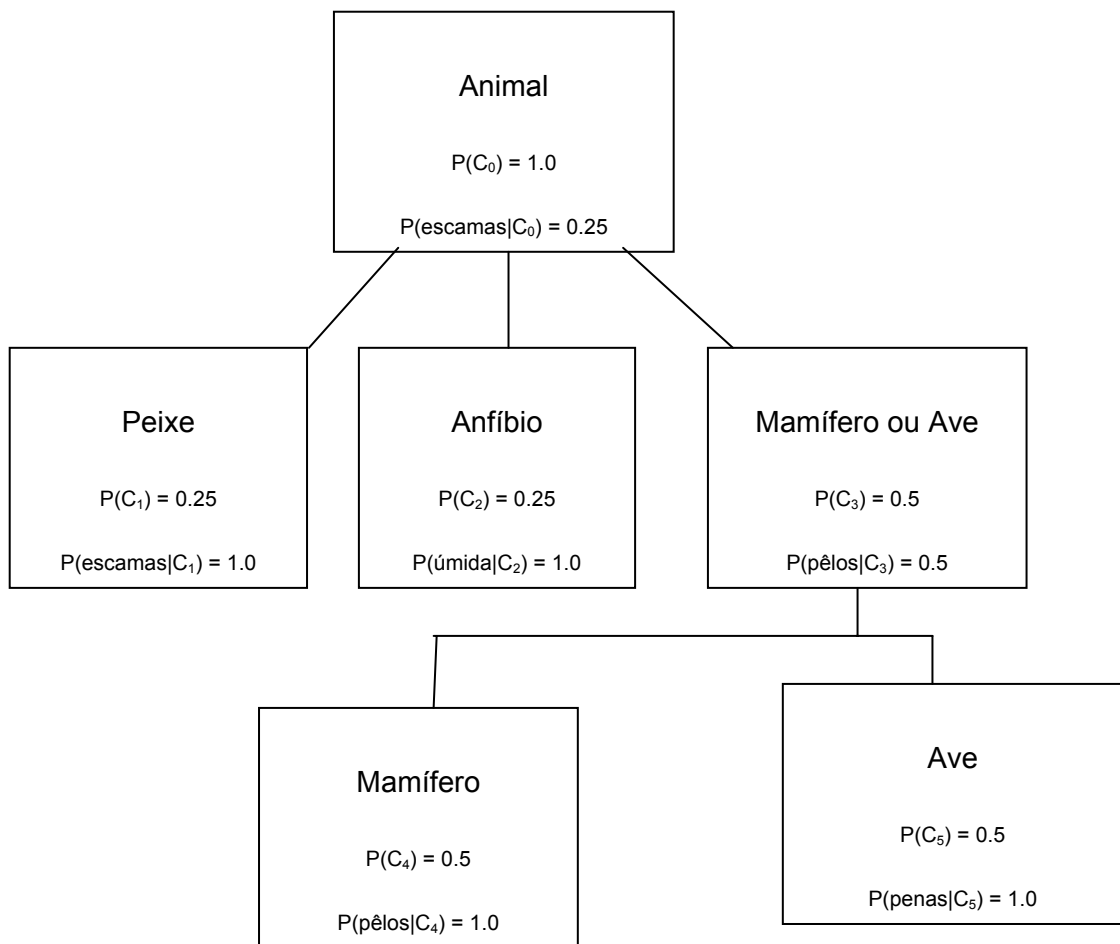


Fig. 3.1 – Árvore de Classificação

Árvore de classificação é diferente de árvore de decisão. Cada nó em uma árvore de classificação se refere a um conceito e contém a descrição probabilística deste conceito que sumariza os objetos classificados sob o nó. A descrição probabilística inclui a probabilidade do conceito e as probabilidades condicionais na forma $P(A_i = V_{ij}|C_k)$, onde $A_i = V_{ij}$ é um par de atributos e C_k é o conceito da classe. Contadores são acumulados e armazenados para cada nó a fim de realizar o cálculo das probabilidades. Os nós de um mesmo nível de uma árvore de classificação formam uma partição. Para classificar um objeto usando uma árvore de classificação, a estratégia é descer a árvore ao longo do caminho de melhor adaptação dos nós. O COBWEB usa uma medida de avaliação heurística chamada “utilidade de categoria” para guiar a construção da árvore.

Enquanto percorre o melhor caminho pela árvore em busca do melhor nó hospedeiro ao qual classificar o objeto, COBWEB aloca temporariamente o objeto em

cada nó e calcula a “utilidade de categoria” da partição resultante. O arranjo que resulta na mais alta “utilidade da categoria” é indicado como hospedeiro ideal para o objeto. Se um objeto não pertencer a quaisquer dos conceitos já representados na árvore, uma nova classe é criada e automaticamente é ajustado o número de classes existentes em uma partição, dispensando que este seja um parâmetro a ser introduzido pelo usuário.

Existem, entretanto, algumas limitações na abordagem do COBWEB. Primeiramente, a consideração da hipótese de probabilidade estatística baseada em atributos independentes, o que freqüentemente não ocorre, havendo muitas vezes uma forte correlação entre eles. Outra limitação é que a representação da probabilidade dos grupos origina um alto custo de atualização e armazenamento, especialmente quando os atributos têm um grande número de valores. Além disso, árvore de classificação pode facilmente perder equilíbrio em sua altura, com a introdução de dados que reflitam uma forte inclinação, o que pode causar degradação dramática de tempo e espaço.

A abordagem de redes neurais busca representar cada grupo como um exemplar. Um exemplar atua como protótipo do grupo e não tem necessariamente que corresponder a um dado ou objeto específicos. Novos objetos podem ser adicionados ao grupo quando o seu exemplar é o de maior semelhança, baseada em alguma medida de distância. Os atributos de um objeto designado para um grupo podem ser preditos pelos atributos do exemplar do grupo.

Os dois mais proeminentes métodos de abordagem por redes neurais são o aprendizado competitivo e os mapas auto-organizáveis de características, ambos envolvendo competição entre as unidades neurais.

O aprendizado competitivo envolve uma arquitetura hierárquica de várias unidades (neurônios artificiais) que competem na forma vencedor-leva-tudo pelo objeto que está sendo apresentado no momento ao sistema. A Figura 3.2 é um exemplo de um sistema de aprendizado competitivo. Cada círculo representa uma unidade. A unidade vencedora dentro de um grupo torna-se ativa (representada por um círculo preenchido), enquanto as outras estão inativas (indicadas por círculos vazios). As conexões entre as camadas são excitatórias - uma unidade numa dada camada pode receber entradas de todas as unidades do próximo nível abaixo. A configuração das unidades ativas em uma camada representa o padrão de entrada do próximo nível acima. As unidades dentro de um grupo para uma dada camada

competem umas com as outras para responder ao padrão que é a saída da camada imediatamente abaixo. As conexões dentro das camadas são inibidoras, uma vez que somente uma unidade dentro de determinado grupo pode ser ativa. A unidade vencedora ajusta os pesos de suas conexões entre as outras unidades do grupo, de forma que ela irá responder até mais fortemente a futuros objetos similares. Se os pesos forem vistos como definindo um exemplar, então os novos objetos adicionados ao grupo são os mais aproximados ao exemplar. O número de grupos e o seu número de unidades são parâmetros de entrada.

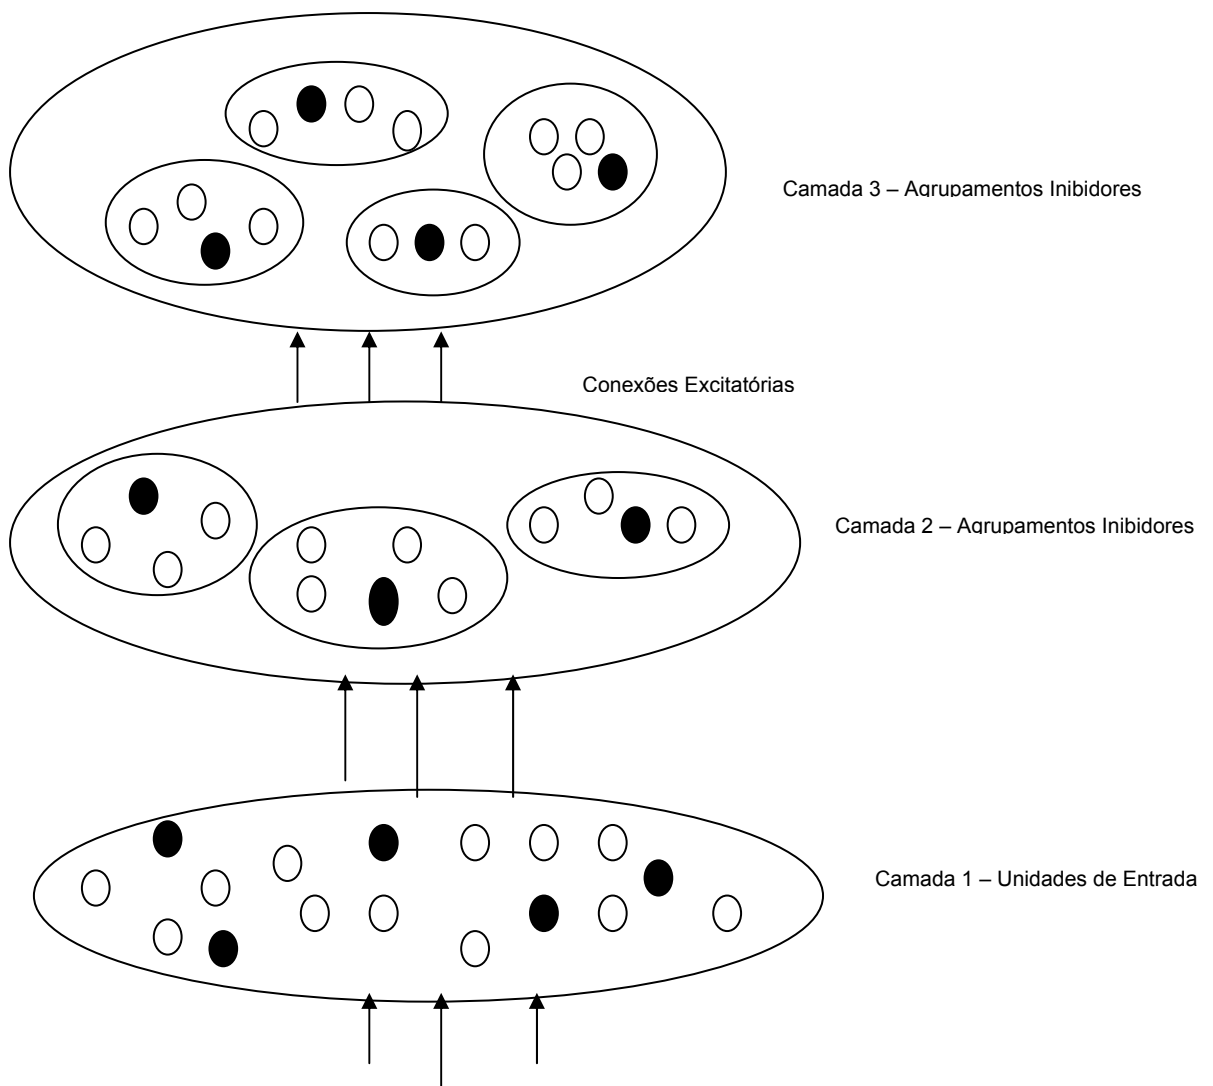


Fig. 3.2 – Uma arquitetura de aprendizado competitivo

Fonte: Han e Kamber, 2001

Ao fim da segmentação (e de qualquer outra segmentação, em geral), cada grupo pode ser encarado como uma nova característica descoberta com alguma regularidade na coleção de objetos. Assim, os grupos resultantes podem ser vistos como um mapeamento de características de baixo nível para características de alto nível.

A segmentação através de mapas auto-organizáveis de características é também realizada com a competição de várias unidades pelo objeto que está sendo apresentado ao sistema. A unidade cujo vetor de pesos é mais próximo a este objeto torna-se o vencedor, ou unidade ativa. Ao fim deste processo de alocação, os pesos da unidade vencedora e de seus vizinhos mais próximos são ajustados, residindo aí a diferença entre os dois métodos. Este método de segmentação admite que existe alguma topologia ou ordenamento entre os objetos de entrada (*inputs*) e que as unidades irão configurar esta estrutura terminado o processo de segmentação.

3.4 - Classificação

Classificação é uma forma de análise de dados utilizada para extrair modelos de descrição de classes de dados. Destina-se basicamente a prever rótulos categóricos e a extrair as regras de relacionamento dos dados.

A classificação de dados é um processo de duas fases. Na primeira fase, um modelo é criado descrevendo um pré-determinado conjunto de classes de dados ou conceitos. O modelo é construído por meio da análise das amostras da base de dados descritas pelos atributos. Cada característica é assumida como pertencente a uma classe pré-definida, como determinado por um dos atributos, denominado atributo de rótulo da classe. As amostras analisadas para construir o modelo formam o conjunto de treinamento. As tarefas de classificação são executadas por meio de aprendizagem supervisionada, ou seja, é conhecida a classe a que pertence cada amostra alocada no conjunto de treinamento. Tipicamente, os modelos são representados em forma de regras de classificação, árvores de decisão ou formulação matemática.

Na segunda fase, o modelo construído é verificado quanto à confiabilidade, mediante a utilização de diversos métodos destinados a verificar sua acurácia. A acurácia de um determinado modelo para um dado conjunto de teste é a percentagem de suas amostras por ele classificadas corretamente.

❖ Classificação por Árvores de Decisão

Uma árvore de decisão é um diagrama desenvolvido em estrutura de árvore, onde cada nó interno denota um teste de atributo, cada ramo representa a resposta a este teste e cada folha uma classe. A Figura 3.3 representa esquematicamente esta estrutura.

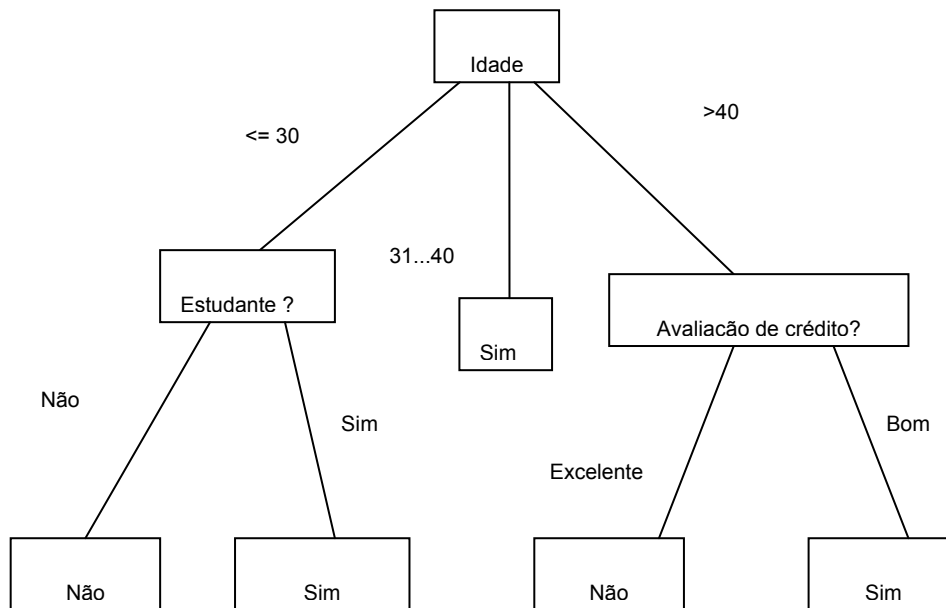


Fig 3.3 – Esquema Árvore de Decisão

O conhecimento representado em árvores de decisão pode ser extraído e representado em forma de regras de classificação do tipo IF-THEN. Uma regra é criada para cada caminho desde o cimo até as folhas. Por exemplo, no esquema da Figura 3.3, que retrata uma hipotética árvore de decisão para compradores de computador, as regras extraídas são as seguintes:

IF *idade* = “<=30” AND *Estudante* = “*não*” THEN comprador de computador = “*não*”

IF *idade* = “<=30” AND *Estudante* = “*sim*” THEN comprador de computador = “*sim*”

IF *idade* = “31...40” THEN comprador de computador = “*sim*”

IF *idade* = “>40” AND *Avaliação de Crédito* = “*Excelente*” THEN

comprador de computador = “não”

IF *idade* = “>40” AND Avaliação de Crédito = “Bom” THEN comprador de computador = “sim”

❖ Classificação Bayesiana

Esta ferramenta de classificação tem como base o Teorema de Bayes e por isso pode prever a probabilidade de uma determinada amostra pertencer a certa classe, considerando que uma outra amostra pertence a esta classe. Estudos comparativos desenvolvidos acerca de diversos algoritmos de classificação concluíram que classificadores bayesianos têm desempenho comparável a árvores de decisão e redes neurais.

Os classificadores bayesianos trabalham da seguinte forma:

1 – Cada amostra é representada por um vetor n -dimensional, $X = (x_1, x_2, \dots, x_n)$, representando as n medidas feitas na amostra para n atributos, respectivamente, A_1, A_2, \dots, A_n .

2 – Suponhamos que existam m classes, C_1, C_2, \dots, C_m . Dada uma amostra desconhecida, X (ou seja, que não tem rótulo), o classificador bayesiano irá atribuí-la a uma classe C_i , se e somente se

$$P(C_i|X) > P(C_j|X) P(C_j) \text{ para } 1 \leq j \leq m, j \neq i$$

Assim $P(C_i|X)$ será maximizado. A classe C_i para a qual $P(C_i|X)$ é maximizada é chamada de “*maximum posteriori hypothesis*”. Do teorema de Bayes,

$$P(C_i|X) = \frac{P(X|C_i) P(C_i)}{P(X)}$$

3 – Como $P(X)$ é constante para todas as classes, somente $P(X|C_i) P(C_i)$ necessita ser maximizado. Se a probabilidade anterior da classe é desconhecida, então é comum assumir que as classes são igualmente prováveis, isto é, $P(C_1) = P(C_2) = \dots = P(C_m)$, e deve-se, portanto, maximizar $P(X|C_i)$. De outra maneira deve-se maximizar $P(X|C_i) P(C_i)$.

4 – Para classificar uma amostra desconhecida X , $P(X|C_i) P(C_i)$ é avaliado para cada classe C_i . A amostra X é então atribuída à classe C_i se e somente se

$$P(X|C_i) P(C_i) > P(X|C_j) P(C_j) \text{ para } 1 \leq j \leq m, j \neq i$$

❖ Classificação por Backpropagation

Backpropagation é um algoritmo de aprendizagem desenvolvido para treinamento de redes neurais do tipo *Multilayer Feed-Forward*. Tendo em vista que o Capítulo 4 trata exclusivamente de redes neurais, serão resumidamente descritos aqui apenas os procedimentos relativos às tarefas de classificação.

O conhecimento na forma de uma rede de unidades conectadas por ligações com diferentes pesos é de difícil interpretação. Este fator tem motivado diversos pesquisadores a buscar extrair o conhecimento contido em redes neurais treinadas e em representá-lo de forma simbólica. Um dos métodos desenvolvidos com base nestes conceitos é a extração de regras.

Vários algoritmos para extração de regras têm sido propostos. Tipicamente, os métodos impõem restrições relativas a procedimentos usados no treinamento, na topologia de redes e na discretização de *inputs*. Geralmente, o primeiro passo para extração de regras é a “poda”, que consiste na remoção de conexões que não resulte em um decréscimo na acurácia de classificação da rede.

Uma vez que a rede treinada tenha sido podada será então efetuada a *clusterização* de ligações, unidades ou valores de ativação. Por exemplo, a *clusterização* é utilizada para achar o conjunto de valores de ativação comuns para cada unidade escondida em uma rede neural treinada de duas camadas. As combinações destes valores de ativação para cada unidade escondida são analisadas. As regras são derivadas das combinações dos valores de ativação com os correspondentes valores das unidades de saída. De forma similar, os conjuntos de valores de *inputs* e valores de ativação são analisados para extrair regras descrevendo os relacionamentos entre as unidades de *input* e escondidas. Finalmente, os dois conjuntos extraídos devem ser combinados na forma de regras IF-THEN.

3.5 - Software e algoritmos utilizados neste trabalho

Para desenvolvimento das tarefas de agrupamento e classificação neste trabalho foi utilizado o software *WEKA (Waikato Environment for Knowledge Analysis)*, desenvolvido na Universidade de Waikato, na Nova Zelândia. O *Weka* é uma ferramenta de *KDD* que contempla uma série de algoritmos de preparação e

mineração de dados, bem como de validação dos resultados. Este sistema é um *software* livre, com código aberto disponível na Web (<http://www.cs.waikato.ac.nz/ml/weka>), desenvolvido em Java, dentro das especificações da GNU (General Public License). Grande parte de seus componentes de *software* foram desenvolvidos em teses e dissertações de pesquisa da universidade, possuindo o sistema interface gráfica amigável, gerando ao final dos procedimentos relatórios com dados analíticos e estatísticos do domínio minerado.

São apresentadas a seguir as descrições dos algoritmos utilizados neste trabalho para agrupamento e classificação, baseadas em Witten e Frank (2005).

Para desenvolvimento das atividades de agrupamento dos dados foram utilizados dois algoritmos, o *K-means*, já descrito anteriormente e o *EM* (*Expectation-Maximization*). O *EM* é um algoritmo que busca determinar as estimativas de maximização da probabilidade para parâmetros em modelos probabilísticos, no qual o modelo depende de variáveis não observáveis. O algoritmo desenvolve um processamento iterativo dividido em duas fases: o passo “*E*” (*expectation*), que calcula uma expectativa da probabilidade incluindo variáveis não observáveis como se fosse possível observá-las, e o passo “*M*” (*maximization*), que calcula a probabilidade máxima dos parâmetros maximizando aquela calculada no passo “*E*”. Os parâmetros encontrados no passo “*M*” são utilizados pelo passo “*E*” da próxima iteração, sendo todo o processamento repetido até que se verifique o critério de parada, que pode ser o número máximo de iterações definido pelo usuário ou a maximização da probabilidade.

O algoritmo de classificação utilizado foi o J4.8, que gera uma árvore de decisão da qual podem ser extraídas regras de classificação do tipo IF-THEN. Este algoritmo é uma implementação em Java do C4.5, *release 8*, última versão de uma família de algoritmos até sua implementação comercial, o C5.0. O C4.5 é um aperfeiçoamento de outro algoritmo, o ID3, de estrutura TDIDT – *Top-Down Induction of Decision Trees* desenvolvido por Ross Quinlan na década de 1970. Para a construção top-down de árvores de decisão, o ID3 utiliza o método *greedy*, que possui uma estratégia de “dividir para conquistar”. Por este método, a árvore inicia com um único nó que contém o conjunto de treinamento. Se os exemplos forem todos de uma mesma classe, então o nó torna-se um nó folha e é rotulado com a respectiva classe. Caso contrário, o algoritmo estabelece um novo corte onde uma ramificação é gerada para cada valor do atributo de decisão. Para este atributo de decisão é selecionado o atributo predictor com maior ganho de informação. O algoritmo usa o mesmo processo para a construção de cada partição da árvore de decisão, finalizando a construção

quando todos os exemplos da cada partição pertencem a uma mesma classe, ou quando não existir mais forma de particionar os atributos dos exemplos remanescentes.

O ganho de informação representa a diferença entre a quantidade de informação necessária para uma predição correta e as correspondentes quantidades acumuladas dos segmentos dos cortes. Para essa avaliação são considerados dois momentos: um antes da inserção de um corte e o outro depois de sua inserção. Se a quantidade de informação requerida é muito menor depois que o corte é introduzido, isso indica que a inclusão deste corte reduz a desordem (entropia) do segmento original.

A entropia é uma medida bem definida da impureza dos dados. Em um conjunto de dados é uma medida da falta de homogeneidade dos dados de entrada em relação à sua classificação. Por exemplo, a entropia é máxima (igual a 1) quando o conjunto de dados não apresenta um mínimo de homogeneidade.

O algoritmo ID3 tende a gerar uma árvore de decisão exata, ou seja, classifica corretamente todos os exemplos que constam do conjunto de treinamento. Entretanto, na grande maioria das aplicações isso não é desejável dada a ocorrência de ruídos e incertezas. Assim sendo, no C4.5 foram desenvolvidos mecanismos de poda para tratar desta questão. O mecanismo de poda em árvores de decisão adotado no C4.5 é baseado na comparação das taxas de estimativas de erro de cada sub-árvore e do nó folha. São processados sucessivos testes a partir do nó raiz da árvore, de forma que, se a estimativa de erro indicar que a árvore será mais precisa se os nós descendentes de um determinado nó " n " forem eliminados, então estes nós descendentes serão eliminados e o nó " n " passará a ser o novo nó folha. Com essa poda a árvore se torna mais precisa a cada processo.

Capítulo 4

Redes Neurais Artificiais

Neste capítulo são apresentados os conceitos fundamentais necessários à implementação de uma Rede Neural Artificial (RNA) para os fins pretendidos nesta tese. Descrevem-se sucintamente o paradigma matemático inspirado no funcionamento do cérebro humano, as origens de sua aplicação computacional e os principais tipos de redes desenvolvidos. Ênfase especial é dada às redes dos tipos *Multilayer Perceptron (MLP)* e *Generalized Regression Neural Networks (GRNN)*, tendo em vista serem estas as utilizadas no desenvolvimento de estudo aqui apresentado.

4.1 Introdução

Rede Neural Artificial, um termo raro há cerca de duas décadas na literatura científica, representa hoje uma vigorosa área de aplicação multidisciplinar, constituindo genuinamente uma ferramenta para o estudo de fenômenos complexos. A modelagem de dados para melhor entender fenômenos complexos, multidimensionais, bem como a tentativa de estimar uma variável dependente em função de outras de mais fácil obtenção, tem levado ao desenvolvimento de várias técnicas de análise. Uma das ferramentas mais exploradas e que tem apresentado bons resultados nas mais diferentes áreas do conhecimento é a técnica das Redes Neurais Artificiais (RNAs).

Segundo Furtado (1999), Redes Neurais Artificiais, comumente chamadas de “Redes Neurais”, representam um paradigma matemático inspirado no funcionamento do cérebro humano, sendo capaz de desempenhar tarefas computacionais em diversas áreas científicas e tecnológicas.

Esses paradigmas procuram compreender e emular as propriedades decorrentes do alto grau de paralelismo e conectividade do cérebro humano, possuindo características como aprendizado por experiência, generalização a partir de um exemplo prévio, através de interpolações e extrapolações, e abstração de características essenciais a partir de entradas de dados incompletos e até mesmo incoerentes, os chamados “ruídos”.

O funcionamento do cérebro humano pode, muito simploriamente, ser descrito como segue. Os neurônios ou células nervosas são as unidades básicas de seu

funcionamento. Apresenta a propriedade de responder a alterações do meio em que se encontram (estímulos), através de modificações da diferença de potencial elétrico existente entre as superfícies interna e externa da membrana celular. Eles reagem prontamente a estes estímulos, e a mudança de potencial propaga-se a outros neurônios, músculos ou glândulas (impulso nervoso). São formados por um corpo celular ou soma, que contém o núcleo, constituindo o centro metabólico do neurônio. Funcionam também como um receptor e integrador de estímulos. Do corpo partem prolongamentos numerosos, os dendritos, especializados na função de receber estímulos. Eles aumentam consideravelmente a superfície celular, tornando possível receber e integrar impulsos trazidos por numerosos terminais axônicos. O axônio é um prolongamento único, especializado na condução de impulsos que transmitem informações a outras células nervosas, musculares ou glandulares. Assim, em geral, as informações são recebidas pelos dendritos e corpo celular e emitidas pelo axônio. A transmissão dinâmica do impulso nervoso de um neurônio para outro depende de estruturas altamente especializadas, as sinapses, que são locais de contato de um axônio com um dendrito. Na porção terminal do axônio existem substâncias químicas chamadas neurotransmissores, responsáveis pela transmissão do impulso nervoso através das sinapses. Um esquema geral destes elementos biológicos pode ser visto na figura 4.1.




Figura 4.1 – Neurônio Esquemático – Fonte: Furtado, 1999

O sistema nervoso tem dois componentes: o Sistema Nervoso Central (SNC), composto pelo encéfalo e pela medula espinhal e o Sistema Nervoso Periférico (SNP), composto pelos nervos, gânglios e terminações nervosas. Anatomicamente estes dois componentes estão separados, mas funcionalmente são interconectados. O sistema nervoso periférico retransmite informações para o sistema nervoso central e executa comandos gerados neste. O aprendizado pode determinar alterações estruturais no cérebro, provavelmente por causar alterações no padrão de interconexões dos diversos

sistemas sensoriais e motores. Assim, nos humanos adultos, os mapas corticais não são estáticos, mas dinâmicos. As alterações produzidas pelo aprendizado e, portanto, pela formação de novas sinapses, podem contribuir para a expressão biológica da individualidade.

4.2 Neurônios Artificiais – Modelo MCP

Sob a ótica computacional, pode-se dizer que no neurônio é realizado o processamento sobre uma ou, geralmente, várias entradas, com o intuito de gerar uma saída. As descrições a seguir são apresentadas conforme Braga, Ludermir e Carvalho (2000) e Furtado (1999).

O neurônio artificial é uma estrutura lógico-matemática que procura simular a forma, o comportamento e as funções do neurônio biológico. Pode-se, grosso modo, associar o dendrito à entrada, o soma ao processamento e o axônio à saída; portanto, o neurônio é considerado uma unidade fundamental processadora de informação. Os dendritos são as entradas, cujas ligações com o corpo celular artificial são realizadas através de canais de comunicação que estão associados a um determinado peso (simulando as sinapses). Os estímulos captados pelas entradas são processados pela função de soma, e o limiar de disparo do neurônio biológico é substituído pela função de transferência. Embora cada neurônio tenha a função de realizar um processamento simples, uma rede de múltiplos neurônios é capaz de realizar operações bastante complexas.

O trabalho original de McCulloch e Pitts (1943), *apud* Braga, Ludermir e Carvalho (2000), enfocou a modelagem de um neurônio biológico e sua capacidade computacional com a apresentação de várias topologias de rede com capacidade de execução de funções booleanas. Este modelo é uma simplificação do que se sabia então a respeito do neurônio biológico. Sua descrição matemática resultou em um modelo com m terminais de entrada x_1, x_2, \dots, x_m (que representam os dendritos) e apenas um terminal de saída y (representando o axônio). Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados W_1, W_2, \dots, W_m cujos valores podem ser positivos ou negativos, dependendo das sinapses correspondentes serem inibitórias ou excitatórias.

O efeito de uma sinapse particular i no neurônio pós-sináptico é dado por $X_i W_i$. Os pesos determinam “em que grau” o neurônio deve considerar sinais de disparo que

ocorrem naquela conexão. No neurônio k é feita a soma ponderada dos sinais recebidos, produzindo um determinado nível de atividade. Se este nível de atividade exceder certo limite, a unidade processadora produzirá uma determinada resposta como saída. McCulloch e Pitts simplificaram o modelo do neurônio, ao considerar que os nós em cada camada da rede disparam sincronicamente, ou seja, são avaliados ao mesmo tempo. A figura 4.2 apresenta esquematicamente uma unidade processadora de McCulloch e Pitts (MCP), que representa o modelo descrito.




Figura 4.2 – Esquema de Unidade Processadora de McCulloch e Pitts

Fonte: Furtado, 1999

Matematicamente o modelo apresentado na figura 4.2 pode ser representado por:

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (2.1)$$

$$y_k = \varphi(u_k) \quad (2.2)$$

onde: x_j – sinais de entrada

w_{kj} – pesos sinápticos ou pesos

y_k – sinais de saída

$\varphi(\theta)$ – função de ativação

Cada neurônio possui uma função de ativação, que limita a amplitude de sinal de saída. A partir do modelo proposto por McCulloch e Pitts, foram derivados vários outros que permitem a produção de uma saída qualquer, não necessariamente zero ou um. Normalmente a faixa de saída está em um intervalo fechado $[0,1]$, mas existem modelos que permitem a produção de uma saída qualquer. Entre os diversos tipos de funções de ativação utilizadas, três são apresentadas na figura 4.3.

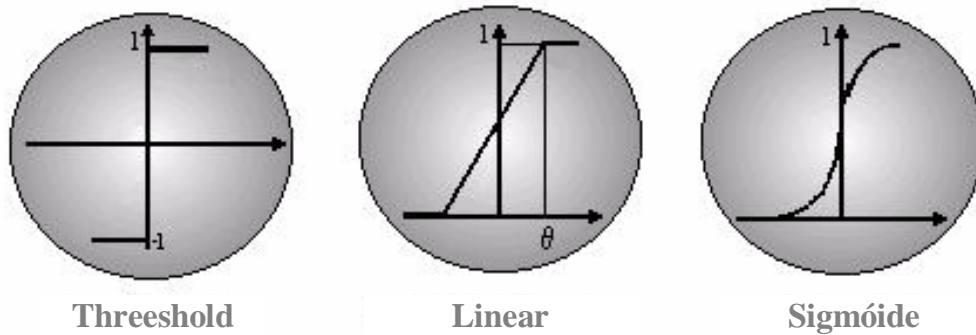


Figura 4.3. – Exemplos de Funções de Ativação de Neurônios - Fonte: Furtado, 1999.

4.3 Principais Arquiteturas de RNAs

As entradas da Rede Neural, simulando a captação de estímulos, podem ser conectadas em muitos neurônios, resultando em uma série de saídas, onde cada neurônio representa uma saída. Estes modelos conexionistas modificam-se, conforme a necessidade de aplicação. A arquitetura pode variar através das diferentes conexões entre as camadas, pelo número de camadas intermediárias, pelo número de unidades processadoras (neurônios), pela função de ativação e pelo processo de aprendizagem, que são seus parâmetros definidores. As principais arquiteturas são as seguintes:

- a) Quanto ao número de camadas: redes de *camada única*, quando só existe um neurônio entre qualquer entrada e qualquer saída da rede (Figura 4.4), e redes de *múltiplas camadas*, quando existe mais de um neurônio entre alguma entrada e alguma saída da rede (Figura 4.5).
- b) Quanto ao tipo de conexão dos neurônios: *feedforward ou acíclica*, quando a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada para os neurônios das camadas de índice menor ou igual a i (Figura 4.5); *backward ou cíclica*, quando a saída de algum neurônio na i -ésima

camada da rede é usada como entrada de neurônios em camadas de índice menor ou igual a i (Figura 4.6).

- c) Quanto à conectividade: rede *totalmente conectada*, quando todos os neurônios de uma determinada camada se conectam com todos os neurônios da camada seguinte (Figura 4.5); rede *parcialmente conectada*, caso algum dos neurônios de uma determinada camada não seja conectado a todos os neurônios da camada seguinte.

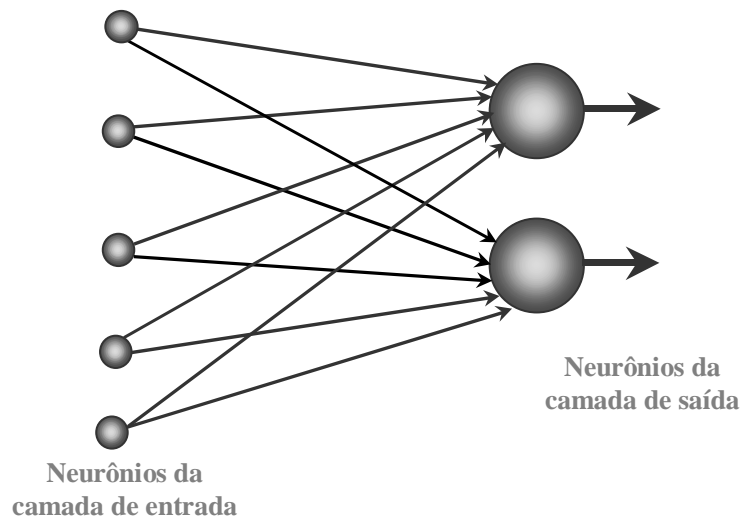


Figura 4.4 – Representação de Rede Feedforward de uma camada - Fonte: Furtado, 1999

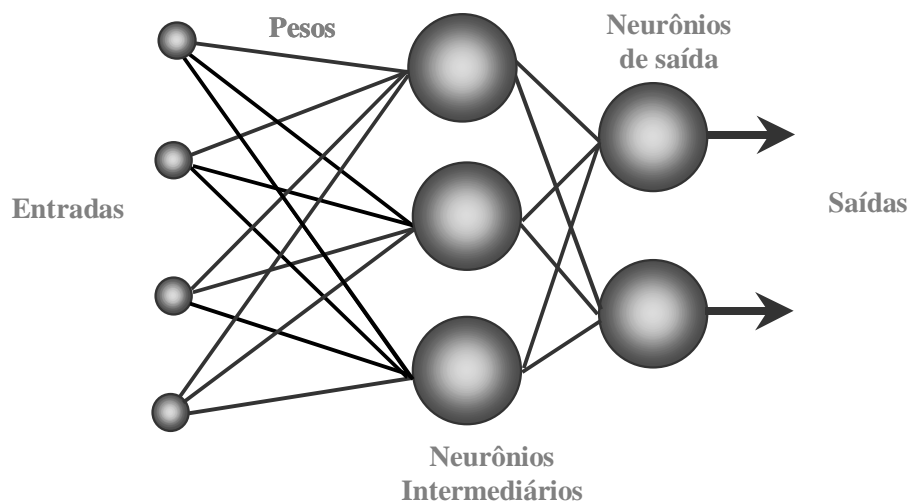


Figura 4.5 – Representação de Rede Neural Artificial de Múltiplas Camadas
Fonte: Furtado, 1999

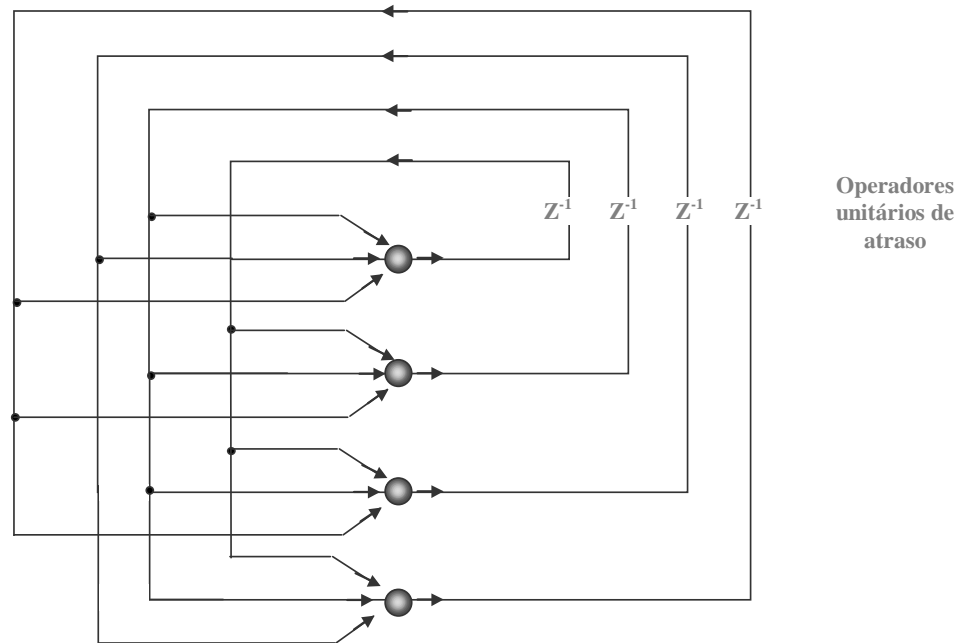


Figura 4.6 – Representação de Rede Backward – Fonte: Furtado, 1999

➤ **Rede Feedforward**

A arquitetura do tipo feedforward em camadas apresenta uma organização similar à do córtex humano, onde os neurônios se dispõem em camadas paralelas e consecutivas, e os axônios se estendem sempre no mesmo sentido, isto é, a informação propaga-se da entrada para a saída, não existindo, portanto, ligações entre os neurônios de uma mesma camada ou com camadas anteriores.

❖ **Rede Feedforward de Uma Camada**

Nesta arquitetura, os neurônios da camada de entrada se comunicam diretamente com os da camada de saída, como esquematizado na Figura 4.4. É chamada de rede de uma camada em referência à camada de saída, pois nos nós da entrada não ocorre qualquer processamento, sendo utilizados apenas para apresentar os padrões à rede. Este tipo de arquitetura tem potencial bastante limitado, sendo capaz de modelar apenas problemas linearmente separáveis, ou seja, problemas cuja solução pode ser obtida dividindo-se o espaço de entrada em duas regiões através de uma reta.

❖ **Rede Feedforward Multicamadas**

Este tipo de rede é caracterizado pela introdução de pelo menos uma camada de neurônios entre as camadas de entrada e saída. Por ser uma rede do tipo *feedforward*, as conexões se dão sempre no sentido da camada de entrada para a de saída.

Quando a rede possuir todos os nós de uma camada comunicando-se com todos os nós da camada posterior, ela é dita *totalmente conectada*. Caso alguma das conexões sinápticas não esteja ligada com a camada subsequente, a rede é dita *parcialmente conectada*. A figura 4.5 representa uma rede *feedforward* multicamada totalmente conectada.

➤ **Rede Recorrente ou Realimentada**

Este tipo de rede distingue-se da rede neural do tipo *feedforward* por permitir a realimentação de uma camada com as informações geradas pela camada posterior, ou ainda por fazer uma realimentação do neurônio com a sua própria saída (*self-feedback*).

Para permitir essa realimentação, um dispositivo de atraso é introduzido, guardando as informações de saída de um instante anterior, até que ela possa ser fornecida como entrada do instante atual.

A figura 4.6 apresenta uma rede recorrente com *self-feedback* e sem neurônios na camada intermediária.

As redes do tipo *feedforward* podem ser consideradas um caso particular das redes realimentadas. Estas, apesar de terem potencial de aproximação de funções maior que as redes do tipo *feedforward*, são consideravelmente mais complexas, tanto para utilização quanto para a análise dos resultados apresentados.

4.4 Aprendizado

A utilização de uma Rede Neural na solução de uma tarefa passa inicialmente por uma fase de aprendizagem, quando a rede extrai informações relevantes de padrões de informação a ela apresentados, criando assim uma representação própria para o problema. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre os elementos processadores, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que

está operando. O conjunto de procedimentos bem definidos utilizado para adaptar os parâmetros de uma Rede Neural para que a mesma possa *aprender* uma determinada função é chamado de *algoritmo de treinamento*.

Através de algoritmos de treinamento é que se definem os pesos sinápticos e o processo de aprendizagem. Este processo, independente do tipo de algoritmo utilizado, segue uma seqüência de eventos. A princípio, a Rede Neural é estimulada pelo meio, sofre uma mudança em seus parâmetros como resposta ao estímulo e, finalmente, responde ao meio com uma nova condição obtida através da mudança ocorrida em sua estrutura interna. Diversos métodos para treinamento de rede foram desenvolvidos, podendo ser agrupados nos seguintes paradigmas:

- ❖ *Aprendizado supervisionado*, quando se utiliza um agente externo para indicar à rede a resposta desejada, ou seja, as entradas e saídas alvo são apresentadas à rede, objetivando ajustar os seus parâmetros, de forma a encontrar uma ligação entre os pares fornecidos. Um diagrama deste tipo de aprendizado é apresentado na Figura 4.7.

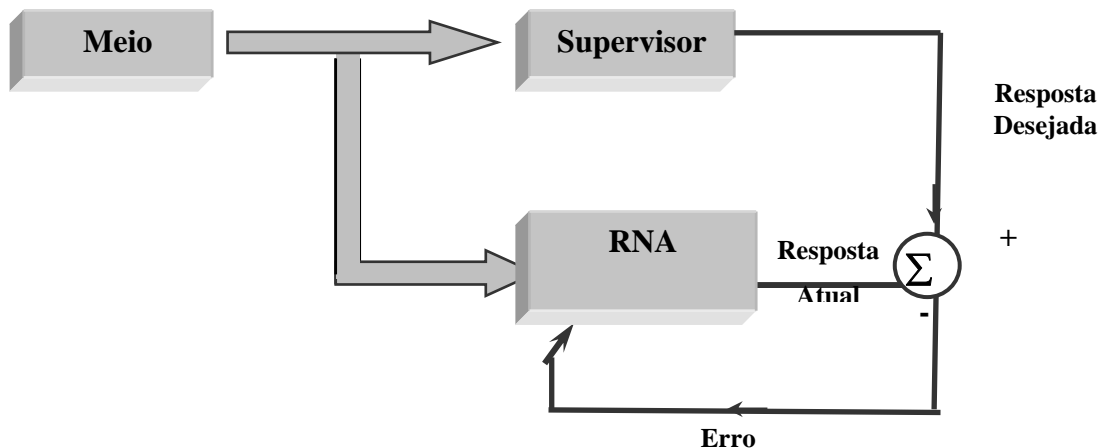


Figura 4.7 – Esquema de Diagrama de Blocos do Aprendizado Supervisionado

Fonte: Furtado, 1999.

- ❖ *Aprendizado não supervisionado*, quando não se apresenta à rede uma saída alvo, devendo ela própria ser capaz de extrair as características relevantes dos impulsos, classificando em grupos pré-existentes. Este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada, pois a rede

deverá codificar as características com as regularidades estatísticas da entrada e criar novas classes e grupos automaticamente. Um diagrama deste tipo de aprendizado é apresentado na Figura 4.8.




Figura 4.8 – Esquema de Diagrama de Blocos do Aprendizado Não Supervisionado

Fonte: Furtado, 1999

- ❖ *Aprendizado por reforço*, que pode ser considerado uma variante do aprendizado supervisionado, no qual não se dispõe das respostas corretas, mas pode-se saber se as respostas que a rede produziu são corretas ou não. Se uma ação tomada pelo sistema de aprendizagem é seguida de estados satisfatórios, então a tendência do sistema de produzir esta ação particular é reforçada, caso contrário, é penalizada. Um diagrama deste tipo de aprendizado é apresentado na Figura 4.9.

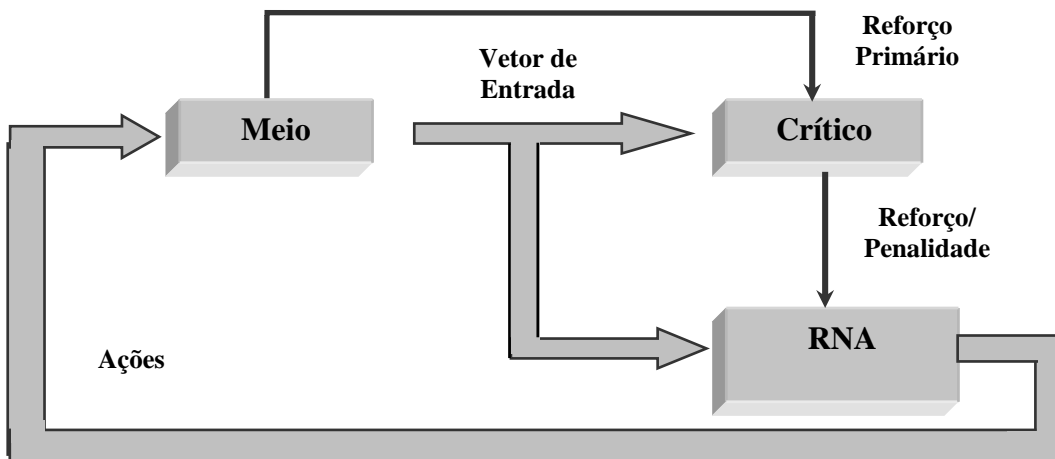


Figura 4.9 – Esquema de Diagrama de Blocos do Aprendizado por Reforço

Fonte: Furtado, 1999

O treinamento é, portanto, o processo pelo qual os parâmetros de uma Rede Neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando.

4.5 Redes Multilayer Perceptron

Conforme já citado, as redes de camada única resolvem apenas problemas linearmente separáveis. A solução de problemas não linearmente separáveis passa pelo uso de redes de uma ou mais camadas intermediárias, ou escondidas. Segundo Cybenko, (1989) *apud* Braga, Ludermir e Carvalho (2000), uma rede com uma camada intermediária pode implementar qualquer função contínua. A utilização de duas camadas intermediárias permite a aproximação de qualquer função. Neste contexto foram desenvolvidas as Redes *Multilayer Perceptron* (MLP), que apresentam um poder computacional muito maior que o de redes com camada única. Ao contrário destas, as MLP podem tratar dados não linearmente separáveis, sendo a precisão obtida e a implementação da função objetivo dependentes do número de neurônios utilizados nas camadas intermediárias. Um dos principais aspectos relacionados ao projeto de redes MLP diz respeito à função de ativação utilizada. Diversas funções não lineares e diferenciáveis têm sido propostas, sendo a mais utilizada a sigmoideal logística.

Em uma rede multicamadas o processamento realizado por cada neurônio é definido pela combinação dos processamentos realizados pelos neurônios da camada anterior que estão a ele conectados. Pode ser dito que as unidades intermediárias de uma rede MLP funcionam como detectores de características. Elas geram uma codificação interna dos padrões de entrada, que é utilizada para a saída da rede. Dado um número suficientemente grande de unidades intermediárias, é possível formar representações internas para qualquer conjunto de padrões de entrada. Entretanto, a utilização de um grande número de camadas intermediárias não é recomendada, pois cada vez que o erro medido durante o treinamento é propagado para a camada anterior, ele se torna menos útil ou preciso. A única camada que tem uma noção precisa do erro cometido é a camada de saída.

4.5.1 Arquitetura

Os sistemas baseados em Redes Neurais Artificiais dependem fortemente da topologia das redes (tamanho, estrutura, conexões), assim como de seus parâmetros

(taxa de aprendizado, momento). Como resultado, a determinação da arquitetura da rede afeta muito o seu desempenho, e é por si só um problema bastante complexo.

Para a solução de problemas práticos de reconhecimento de padrões, aloca-se para a rede um número de unidades intermediárias suficientes para a solução do problema. Deve-se ter cuidado para não utilizar nem unidades demais, o que pode levar a rede a memorizar os padrões de treinamento em vez de extrair deles as características gerais que permitirão a generalização ou o reconhecimento de padrões não vistos durante o treinamento (*overfitting*), nem um número muito pequeno, que pode forçar a rede a gastar um tempo excessivo tentando encontrar uma representação ótima, além de não permitir a melhor modelagem do problema. Normalmente, o número de camadas e o número de neurônios em cada camada são definidos em função de uma inspeção prévia dos dados e da complexidade do problema. Uma vez definida a topologia inicial, a estrutura final mais adequada é usualmente obtida através de refinamentos sucessivos, que podem levar a um tempo de dimensionamento alto, já que este tem um grande componente empírico.

A princípio, sabe-se somente que a última camada deve ter $M = \text{dimensão } (y_{\text{saída}})$ neurônios, isto é, o número de neurônios da camada de saída é o mesmo número de variáveis que serão preditas. Isto não é suficiente, pois só uma camada não mapeia problemas complexos.

O dimensionamento da rede depende do tipo de função a aproximar, e a forma mais usada para realizá-lo ainda é tentativa-e-erro. Inicia-se com uma camada, se o erro obtido for muito grande, passa-se para uma rede de duas camadas e assim sucessivamente.

O número de neurônios na camada intermediária deve estar, a princípio, entre o número de vetores de entrada e de saída. Se a rede aprender, pode-se tentar reduzir o número de neurônios na camada intermediária, caso contrário, é necessário aumentá-lo. O número de neurônios da camada intermediária depende de vários fatores, como:

- Número de exemplos de treinamento;
- Quantidade de ruídos presentes nos exemplos;
- Complexidade da função a ser aprendida;
- Distribuição estatística dos dados de treinamento.

É consumido muito tempo computacional e manual ao se tentar descobrir as melhores variáveis dentre os dados disponíveis e as arquiteturas possíveis para construir uma rede neural artificial eficiente. Caso existam, por exemplo, 20 variáveis de entrada e 15 neurônios na camada escondida em uma rede neural do tipo MLP, existem mais de 16 milhões de arquiteturas possíveis (Furtado, 1999).

4.5.2 Treinamento

Existem atualmente vários algoritmos para treinamento de redes MLP, que são geralmente do tipo supervisionado. De acordo com os parâmetros que eles atualizam, estes algoritmos podem ser classificados em estáticos e dinâmicos. Enquanto os algoritmos estáticos não alteram a estrutura da rede, variando apenas os valores de seus pesos, os algoritmos dinâmicos podem tanto reduzir quanto aumentar o tamanho da rede (número de camadas, número de neurônios nas camadas e número de conexões). Quando o aprendizado estático é utilizado, a mesma regra de aprendizado é empregada para redes MLP com diferentes tamanhos e formatos. É interessante observar que topologias diferentes podem resolver o mesmo problema. O algoritmo de aprendizado mais conhecido para treinamento destas redes é o *Backpropagation*, proposto em 1986 por Rumelhart, Hinton e Williams, que resolveu uma das limitações fundamentais para o treinamento de redes complexas, sendo basicamente utilizado para treinar o *perceptron* multi-camadas (Braga, Ludermir e Carvalho, 2000).

O algoritmo *Backpropagation* é do tipo supervisionado, que utiliza pares entrada/saída desejada para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido, chamadas *forward* e *backward*. A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entrada, e a fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões, ou seja, na fase *forward* os dados seguem da entrada para a saída da rede e na fase *backward* seguem o sentido inverso, como indicado na Figura 4.10.

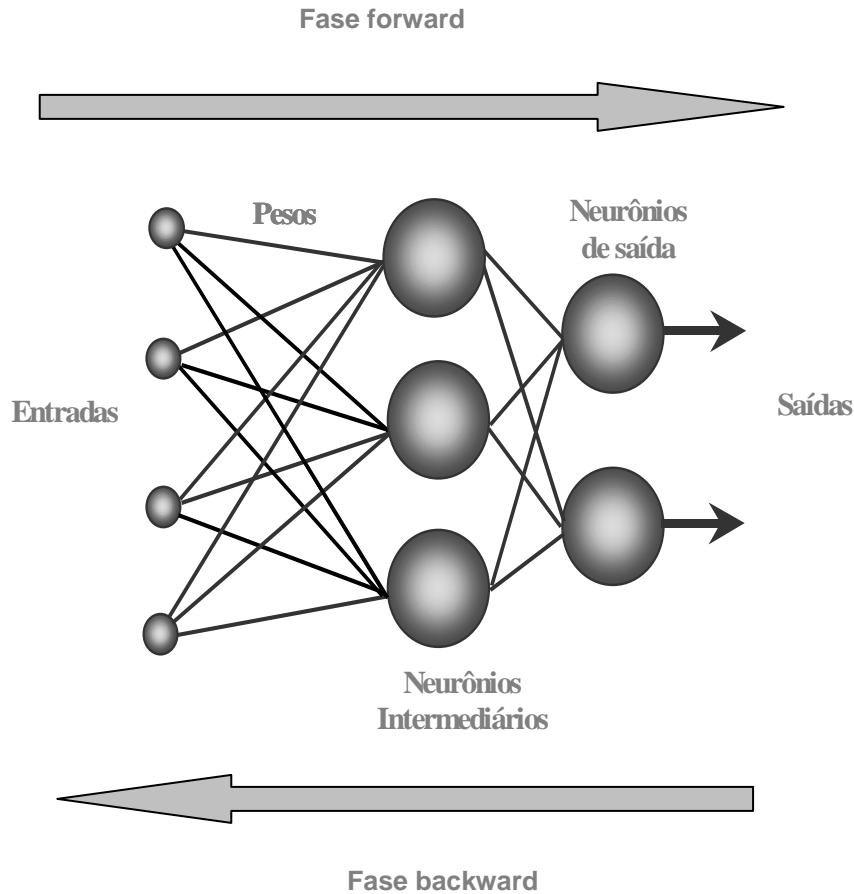


Figura 4.10 – Fluxo de processamento do algoritmo *Backpropagation*

A fase *forward* envolve os seguintes passos:

1. A entrada é apresentada à primeira camada da rede, a camada C^0 .
2. Para cada camada C^i a partir da camada de entrada
 - 2.1. Após os neurônios da camada C^i ($i > 0$) calcularem seus sinais de saída, estes servem como entrada para definição das saídas produzidas pelos neurônios da camada C^{i+1} .
3. As saídas produzidas pelos neurônios da última camada são comparadas às saídas desejadas.

A fase *backward* envolve as etapas listadas a seguir:

1. A partir da última camada, até chegar na camada de entrada:

- 1.1. Os neurônios da camada atual ajustam seus pesos de modo a reduzir seus erros.
- 1.2. O erro de um neurônio das camadas intermediárias é calculado utilizando os erros dos neurônios da camada seguinte conectados a ele, ponderados pelos pesos das conexões entre eles.

O algoritmo *Backpropagation*, que faz uso destas duas fases, é apresentado a seguir:

1. Inicializar pesos e parâmetros.
2. Repetir até o erro ser mínimo ou até a realização de um dado número de ciclos:
 - 2.1. Para cada padrão de treinamento X .
 - 2.1.1. Definir saída da rede da fase forward.
 - 2.1.2. Comparar saídas produzidas com as saídas desejadas.
 - 2.1.3. Atualizar pesos dos neurônios através da fase backward.

O treinamento é um processo de otimização por gradiente em uma superfície, como a da Figura 4.11. Há garantia de convergência se a superfície de erro for simples. Os valores dos pesos da rede definem a coordenada de um ponto desta superfície. O erro produzido pela rede para cada combinação de valores de pesos é dado pela altura da superfície naquele ponto. Assim, quanto mais alto for o ponto, maior o erro produzido pela rede.

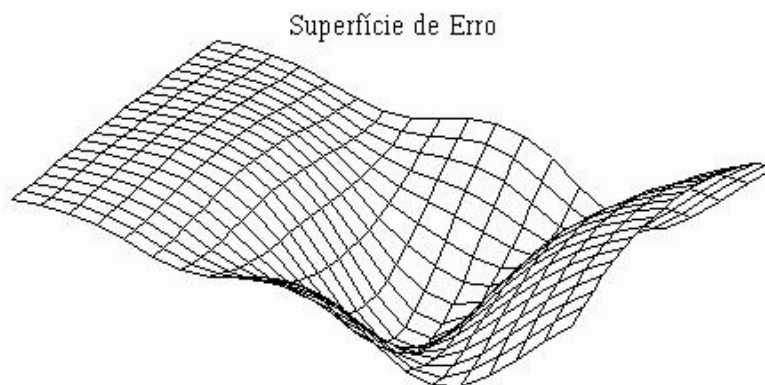


Figura 4.11 – Exemplo de Superfície de Erro – Fonte: Furtado, 1999

O algoritmo *Backpropagation* procura minimizar o erro obtido pela rede ajustando os pesos para que eles correspondam às coordenadas dos pontos mais baixos da superfície de erro. Para isto, ele utiliza o método do gradiente descendente.

O gradiente descendente de uma função está na direção e sentido em que a função tem taxa de variação máxima. Isto garante que a rede caminha na superfície na direção que mais reduzirá o erro obtido. Para superfícies simples, este método certamente encontra a solução com erro mínimo. Para superfícies mais complexas esta garantia não existe, podendo levar o algoritmo a convergir para mínimos locais. O algoritmo *Backpropagation* fornece uma aproximação da trajetória no espaço de pesos calculado pelo método do gradiente descendente. Estes pontos ou áreas podem incluir platôs, mínimos locais ou arestas. Um exemplo de uma superfície com mínimos locais é apresentado na Figura 4.12.

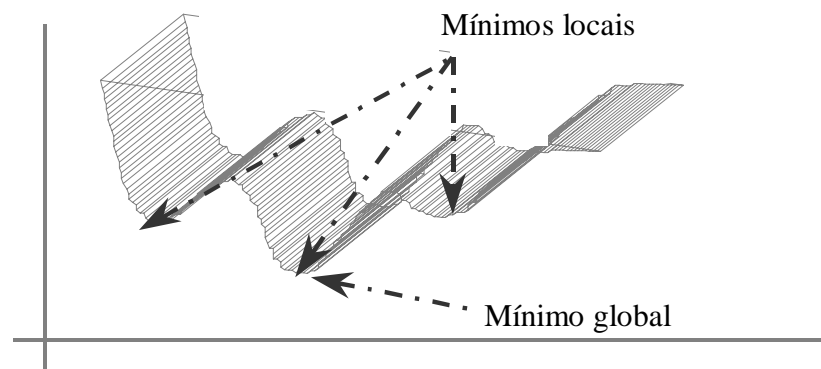


Figura 4.12 - Mínimos Locais de uma Função – Fonte: Furtado, 1999

Um dos problemas enfrentados no treinamento de redes MLP diz respeito à definição de seus parâmetros. A seleção dos parâmetros de treinamento do algoritmo *Backpropagation* é um processo tão pouco compreendido que é muitas vezes chamado de “magia negra” (Braga, Ludermir e Carvalho, 2000). Pequenas diferenças nestes parâmetros podem levar a grandes diferenças tanto no tempo de treinamento quanto na generalização obtida.

Uma dúvida que surge naturalmente diz respeito a quando parar de treinar a rede. Existem vários métodos para a determinação do momento em que o treinamento deve ser encerrado. Estes métodos são chamados de *critérios de parada*, e os mais utilizados são os seguintes:

- Encerrar o treinamento após N ciclos;
- Encerrar o treinamento após o erro quadrático médio ficar abaixo de um determinado valor;
- Encerrar o treinamento quando a porcentagem de classificações corretas estiver acima de um determinado valor;
- Encerrar o treinamento quando o erro do conjunto de teste começar a se elevar, o que indica que a rede entrou em processo de super-especialização.

Embora o algoritmo *Backpropagation* seja bastante eficiente para treinamento de redes MLP, existe uma série de dificuldades em sua utilização. Os principais problemas dizem respeito à sua lentidão para superfícies mais complexas, a uma tendência a convergir para mínimos locais e à ocorrência não rara de super-especialização. As técnicas utilizadas tanto para acelerar a convergência quanto para reduzir a incidência de mínimos locais são as seguintes:

- Utilizar taxa de aprendizado decrescente;
- Adicionar nós intermediários;
- Utilizar um termo *momentum*;
- Adicionar ruídos aos dados.

Dentre estas, a adição do termo *momentum* é uma das mais utilizadas. A inclusão deste termo na fórmula de ajuste dos pesos aumenta a velocidade de aprendizado em regiões muito planas da superfície de erro, e suprime a oscilação de pesos em vales e ravinas, reduzindo a possibilidade de instabilidade da rede.

Outro problema que pode ocorrer no treinamento de redes MLP é a ocorrência de super-especialização (*overfitting*). Conforme já citado, a super-especialização ocorre quando, após certo número de ciclos de treinamento, a rede, em vez de melhorar, começa a piorar a sua taxa de acertos para padrões diferentes daqueles utilizados para o ajuste de pesos. Ou seja, o erro do conjunto de teste começa a crescer. Diz-se então que a rede memorizou os padrões de treinamento, gravando suas peculiaridades e ruídos. Isto tem como resultado um decréscimo em sua capacidade de generalização. Assim como para os problemas de lentidão e mínimos locais, existem alternativas para lidar com o problema de super-especialização, sendo as mais utilizadas as seguintes:

- Encerrar o treinamento quando o erro do conjunto de teste começa a se elevar;
- Podar (*pruning*) os pesos da rede.

4.6 Redes GRNN

A rede GRNN é uma variação das redes de base radial (RBF), que apresenta grande capacidade de generalização e é utilizada principalmente para aproximar funções. Foi desenvolvida originalmente para fins estatísticos, sendo do tipo *feedforward* e baseada na avaliação da função de probabilidade. Treinam rapidamente e permitem a modelagem de funções não lineares.

4.6.1 Arquitetura

A rede GRNN apresenta um número fixo de camadas, a saber: uma camada de entrada, duas camadas escondidas e uma camada de saída (Furtado, 1999, Roitman, 2001).

A primeira camada tem a função de meramente apresentar os dados à rede. A primeira camada escondida memoriza os padrões de entrada e saída. Por isso, nesta camada tem-se a quantidade de neurônios igual à quantidade de padrões de treinamento (vetores). A segunda realiza apenas as operações de adição e divisão. Desta forma, a segunda camada escondida tem a finalidade de armazenar as diferenças entre o padrão de treinamento corrente com os padrões armazenados anteriormente e fazer uma interpolação entre eles para gerar a saída estimada.

As principais vantagens das GRNN são:

- aprendizado rápido, portanto, baixo tempo de treinamento;
- manuseia tanto dados lineares como não-lineares;
- converge para uma superfície ótima de regressão quando há um grande número de amostras;
- pode ser usada com dados escassos;
- a ocorrência de *overtraining* é menos provável, pois somente um parâmetro é ajustado;

- adicionando novos exemplos ao conjunto de treinamento, o modelo não necessita de um novo aprendizado.

Dentre as desvantagens pode-se citar:

- uso intensivo de memória, pois requer que todos os exemplos de treinamento estejam armazenados para uso futuro, isto é, para fazer predição;
- utiliza todos os dados de entrada, mesmo os irrelevantes e redundantes;
- o método para selecionar o fator de *smoothing* é intuitivo;
- para que o treinamento seja feito em um curto intervalo de tempo, é requerido muitos conjuntos de treinamento;

Um exemplo de arquitetura GRNN é apresentado na Figura 4.13.




Figura 4.13 – Esquema da Arquitetura GRNN – Fonte: Furtado, 1999

4.6.2 Treinamento

O treinamento das redes GRNN é rápido e feito em um só passo, pois os vetores de entrada são simplesmente copiados para a camada escondida, logo, cada neurônio é representante de um vetor do conjunto de treinamento apresentado à rede. Quando um conjunto de valores desconhecidos é apresentado, a distância entre estes e os do conjunto de treinamento é calculada, computada e passada para a camada seguinte.

Na camada de adição e divisão existem dois neurônios, chamados, por exemplo, de A e B. O neurônio A computa a soma dos pesos referentes a cada neurônio representante dos vetores conhecidos, e o neurônio B simplesmente computa a soma das distâncias. Os pesos destas médias calculadas decaem exponencialmente com a distância entre os pontos. O neurônio da camada de saída somente apresenta o valor de B dividido por A, fornecendo então a predição.

Uma GRNN pode ser melhor entendida como uma interpolação da função que deve ser ajustada. Esta é chamada de fator de *smoothing* e é o único parâmetro que sofre modificações, permitindo que a GRNN interpole entre os padrões desconhecidos apresentados e os do conjunto de treinamento. A otimização deste fator é considerada crítica para o desempenho da GRNN, e seu valor é usualmente obtido por ajustes interativos de validação.

4.7 Trabalhos Correlatos

Diversas implementações utilizando Redes Neurais Artificiais (RNAs) vêm sendo desenvolvidas na área de geotécnica de pavimentos. O TRB instituiu o “*Committee on Modeling Techniques in Geomechanics*”, que em 2001 (TRB, 2001) publicou um relatório que, entre outras coisas, faz uma breve análise da utilização das RNAs na área da Engenharia Geotécnica. Este relatório ressalta como importante característica desta ferramenta a capacidade de permitir com maior acurácia que os métodos estatísticos convencionais a análise de complexos problemas de engenharia. Especificamente quanto aos materiais utilizados em pavimentação, destaca a possibilidade de uso das RNAs na modelagem do seu comportamento mecânico e no desenvolvimento de modelos de predição de parâmetros geotécnicos que requerem custosos ensaios, tais como coeficiente de permeabilidade, potencial de liquefação e outros, com base em ensaios de mais fácil execução, tais como os Limites de Atterberg, densidade específica e granulometria. Este relatório aponta ainda algumas direções para futuras pesquisas com

implementação de RNAs, citando especificamente a possibilidade de desenvolvimento de modelos híbridos eficientes mediante a abordagem mecanística utilizando essas implementações.

Mesmo com o patrocínio do TRB as pesquisas para utilização de RNAs em estudos de materiais de pavimentação não avançaram muito. No TRB 2005 foram apresentados 55 trabalhos relativos à utilização de RNAs, de um total de 1.621. Destes, 44, ou 80%, tratam de implementações relativas a problemas de tráfego. Apenas um trabalho refere-se à predição do Módulo de Resiliência (Loizos, Karlafits e Karlafits, 2005). Neste trabalho os autores apresentam uma implementação em RNA para determinação do Módulo de Resiliência da camada granular de um pavimento considerando as características de deformabilidade do revestimento e do material do subleito, ou seja, deve ser aplicado em pavimentos existentes, para os quais muitas implementações de RNAs já foram desenvolvidas com base em conceitos de retroanálise.

No “*Annual Meeting*” de 2007 (TRB, 2007), o número de trabalhos apresentados nos quais foram utilizadas redes neurais não se alterou. De um total de 1.865, apenas 55 artigos apresentam algum tipo de implementação com esta ferramenta. Destes, 37, ou 67%, tratam de problemas relacionados a tráfego. Apenas três trabalhos referem-se à predição de características físicas de materiais de pavimentação, sendo dois relativos a concreto asfáltico e um a estabilização química de solos.

Sharin, Jaksa e Maier (2001) publicaram o artigo “*Artificial Neural Network Applications in Geotechnical Engineering*”, que é uma resenha dos trabalhos desenvolvidos até então. Especificamente no que diz respeito a propriedades e comportamento mecânico dos solos os autores citam os seguintes trabalhos:

- Goh (1995a, 1995c) utilizou uma rede neural para modelar a correlação entre a densidade relativa e a resistência à penetração no Teste do Cone de Penetração para areias normalmente adensadas e sobre-adensadas, obtendo coeficientes de correlação de 0,97 e 0,91 para os conjuntos de treinamento e teste respectivamente;
- Ellis et al (1995), desenvolveram um modelo de rede neural para areias baseado na granulometria e na história de tensões;
- Penumadu e Jean-Lou (1997) usaram redes neurais para representar o comportamento de solos arenosos e argilosos.

- Ghaboussi e Sidarta (1998) utilizaram redes neurais para modelar o comportamento de um solo arenoso submetido ao ensaio de compressão triaxial drenado e não drenado.
- Penumadu e Zhao (1999) usaram redes neurais para modelar o comportamento tensão-deformação de areias e pedregulhos no ensaio drenado de compressão triaxial;
- Zhu et al (1998a, 1998b) usaram redes neurais para modelar o comportamento cisalhante de solo residual fino, areia de duna e solo vulcânico do Havaí;
- Cal (1995) utilizou uma rede neural para gerar uma classificação quantitativa de solos com base em três fatores principais (Índice de Plasticidade, Limite de Liquidez e Teor de Argila);
- Romero e Pamukcu (1996) apresentaram redes neurais capazes de caracterizar e estimar o módulo de cisalhamento de materiais granulares.

Outras aplicações citadas pelos autores da resenha incluem a modelagem do comportamento mecânico de areias médias e finas (Ellis et al, 1992) e a simulação do ensaio de compressão uniaxial de solos finos sob carregamento monotônico e cíclico (Basheer, 1998; Basheer e Najar, 1998).

Turk, Logar e Majes (2001), treinaram uma rede neural que foi utilizada para simular o comportamento de amostras de solos sob condições de deformação uniaxial, ou seja, para prever o resultado do ensaio de adensamento, tendo como parâmetros de entrada da rede apenas as propriedades básicas dos solos. Segundo os autores, esta rede, treinada com uma base de dados de 217 amostras, foi capaz de prever com boa acurácia os resultados pretendidos. As variáveis independentes utilizadas para o treinamento da rede foram as seguintes:

- Teor de umidade natural
- Limite de Liquidez
- Índice de Plasticidade
- Pressão de Pré-adensamento
- Tensão vertical inicial
- Deformação vertical inicial em termos do índice de vazios
- Incremento de tensão

A saída alvo pretendida foi o incremento de deformação em termos do índice de vazios.

Os autores apontaram algumas dificuldades surgidas durante o desenvolvimento do estudo. Em primeiro lugar, constataram que enquanto algumas saídas alvo eram previstas com elevada acurácia, outras apresentavam erros bastante elevados. A principal razão para estas discrepâncias foi atribuída ao fato de que o número de amostras que compunham a base de dados era muito pequeno comparado ao número de combinações possíveis quanto às variáveis independentes utilizadas, o comportamento tensão-deformação dos solos e os incrementos de tensões. Segundo os autores, os mesmos estão convencidos de que a acurácia em termos de predição poderia ser muito superior caso a base de dados fosse mais representativa. Os autores constataram também que em alguns grupos de amostras constantes da base de dados utilizada no treinamento os limites de Atterberg e o teor de umidade são muito similares, mas o comportamento destas amostras no ensaio de adensamento é relativamente muito diverso.

Rodgher (2001) propôs a aplicação da técnica de redes neurais artificiais (RNAs) para a previsão de propriedades geotécnicas dos solos do município de São Carlos (SP), baseada em outras propriedades determinadas preliminarmente, objetivando simplificar o processo de obtenção das propriedades dos solos. Foram simuladas cento e noventa e sete RNAs para a previsão das seguintes propriedades: umidade ótima, massa específica seca máxima, mini-CBR na umidade de moldagem obtido na umidade ótima, mini-CBR obtido após 24h de imersão na umidade ótima, expansão e contração obtidas na umidade ótima para as energias normal e intermediária. No treinamento das RNAs foi utilizada uma base de dados com um total de cento e uma amostras que, além de conter os valores das propriedades "alvo" para previsão, também contém: valor de azul ('VA'), coeficiente de atividade ('CA'), análise granulométrica por sedimentação (peneiras #0,42, #0,074 e #0,075), parâmetros da classificação MCT (coeficiente que traduz a argilosidade do solo, perda de peso característica do solo, coeficiente angular da parte mais inclinada do ramo seco da curva de compactação correspondente a 12 golpes e coeficiente que expressa o caráter laterítico do solo) e classificação por cores (croma, valor e matriz). Foram treinadas redes MLP, utilizando como algoritmo de treinamento o *Backpropagation*. Para a previsão de propriedades geotécnicas dos solos, os desempenhos das redes foram bastante bons para umidade ótima, massa específica seca máxima e contração nas energias normal e intermediária. Contudo, o desempenho das RNAs para mini-CBR na

umidade de moldagem, mini-CBR após 24h de imersão e expansão umidade ótima de energias normal e intermediária foram menos satisfatórios. De maneira geral, os resultados obtidos nesse estudo sugerem que modelos que fazem uso das redes neurais artificiais para previsão de propriedades geotécnicas de solos para pavimentação apresentam-se como promissores.

Essa breve explanação de trabalhos publicados indica que vêm sendo desenvolvidos significativos esforços no sentido de modelar o comportamento mecânico dos solos mediante a utilização de RNAs. Contudo, nenhum dos trabalhos teve como objetivo aquele pretendido nesta tese. As deficiências observadas nas tentativas de modelagem do comportamento resiliente dos solos por meio de técnicas matemáticas tradicionais indicam que o mesmo é por demais complexo para que com elas sejam obtidos bons resultados, motivando assim a utilização de RNAs no entendimento do problema. Entretanto, a própria natureza dos solos e dos dados disponíveis dificulta a obtenção de resultados satisfatórios. Os dados obtidos em ensaios geotécnicos são, por natureza, sujeitos a diversos erros e grande variabilidade. Até mesmo boa repetitividade de resultados é de difícil obtenção. Isto ocorre porque, além de se trabalhar com materiais naturais, sujeitos a processos de formação não conhecidos de forma plena, as próprias metodologias de ensaio são muito rudimentares, extremamente dependentes do operador, o que ocasiona erros sucessivos que se refletem na qualidade dos dados.

Capítulo 5

Base de Dados

Neste capítulo é apresentada a Base de Dados utilizada neste trabalho, além dos critérios de escolha das amostras e variáveis nele envolvidas. As Bases de Dados constituem-se em fontes de informações indispensáveis ao desenvolvimento de tecnologia em diversas áreas do conhecimento humano. Especialmente nas áreas que estudam fenômenos naturais ou materiais provenientes da natureza, o desenvolvimento do conhecimento é extremamente calcado em repetitivas observações de um determinado fenômeno ou, no caso dos materiais, na observação e análise de diversos resultados de ensaios ou testes, idealizados para que deles se possa extrair determinadas características de interesse.

5.1 Base de Dados Utilizada

A Base de Dados apresentada no Quadro 5.1 é uma compilação de resultados de 463 amostras de materiais submetidas a ensaios triaxiais a cargas repetidas no Laboratório de Geotecnia da COPPE/UFRJ. Engloba os mais diversos tipos de materiais, desde solos finos coesivos a britas de várias granulometrias, solos lateríticos e algumas misturas não tratadas quimicamente.

Para montagem desta Base de Dados, ou seja, para a escolha das amostras que a comporiam, as diretrizes adotadas foram as seguintes:

- existência de todas as informações quanto às variáveis independentes escolhidas;
- uniformidade de procedimentos na realização dos ensaios triaxiais a cargas repetidas, ou seja, todas as amostras foram ensaiadas segundo a mesma seqüência de tensões e os corpos de prova utilizados foram de dimensões 10x20cm ou 15x30cm.

A Base de Dados é composta por um total de 19 colunas, conforme descrito a seguir.

As duas primeiras colunas referem-se à identificação da amostra, apresentando as seguintes informações:

- **Nº da Amostra na Base de Dados** – Identifica o número da amostra na Base de Dados selecionada para este estudo;
- **Classificação Visual – Táctil - Genética** - Identifica a amostra visualmente e ao tato ou, na falta desta, segundo a classificação pedológica do material;

Da terceira à oitava colunas é apresentada a granulometria de cada amostra segundo o percentual de material passante nas peneiras **#1", #3/8", n.º. 4, n.º. 10, n.º. 40 e n.º. 200.**

As nona e a décima colunas apresentam os resultados dos Limites de Consistência de Atterberg das amostras, quais sejam:

- **LL (%)** - Limite de Liquidez, que caracteriza a umidade limite entre os estados plástico e líquido dos solos; e
- **IP (%)** – Índice de Plasticidade, que se constitui na faixa de umidade na qual o solo encontra-se em estado plástico, ou seja, naquela em que adquire certa resistência ao cisalhamento.

A décima primeira coluna apresenta o valor de **IG** – Índice de Grupo.

As décima segunda e décima terceira colunas apresentam os dados de compactação dos corpos de prova moldados para o ensaio triaxial a cargas repetidas que consistem de:

- **h_{mold} (%)** – Umidade de moldagem do corpo de prova;
- **$\gamma_{\text{s mold}}$ (g/cm³)** – Massa específica aparente seca de moldagem.

Foram consideradas a umidade e a densidade de moldagem ao invés da ótima de compactação tendo em vista que os resultados de módulos de resiliência foram obtidos para esta condição, que pode apresentar alguma diferença em relação às condições ótimas.

As décima quarta e décima quinta colunas apresentam os resultados relativos aos seguintes parâmetros:

- **CBR (%)** – Valor CBR, determinado segundo as normas vigentes, ou seja, após embebição do corpo de prova por quatro dias;
- **Expansão (%)** – Valor que caracteriza a expansibilidade do solo, determinado também após embebição do corpo-de-prova por quatro dias.

A décima sexta coluna apresenta a classificação do solo segundo a metodologia mais utilizada na área rodoviária, elaborada pelo *Transportation Research Board (TRB)* – **TRB**.

Da décima sétima à décima nona colunas são apresentados os valores dos coeficientes experimentais **K_1 (MPa)**, **K_2** e **K_3** do Modelo Composto de resiliência.

Para esta base de dados foram geradas duas matrizes de correlação, utilizando-se o software Excel. Na primeira, apresentada no Quadro 5.2, foram consideradas, além dos parâmetros geotécnicos tradicionais, as constantes K_i do Modelo Composto, e na segunda, apresentada no Quadro 5.3, as tensões desvio e confinante, módulo de resiliência e deformação específica axial. Para geração dessas matrizes foram utilizadas 336 das 463 amostras da base de dados, tendo em vista que foram consideradas apenas as amostras para as quais se dispunha de todos os parâmetros geotécnicos considerados.

Mediante a análise dos valores obtidos constata-se que há correlações significantes entre os parâmetros geotécnicos tradicionais, por exemplo, $IP \times H_{\text{mold}}$ ou $LL \times \% \text{ passante na peneira 200}$, o que já é do conhecimento do meio técnico. As constantes experimentais K_i do Modelo Composto também apresentaram correlações significantes com diversos parâmetros, especialmente as umidade e densidade de moldagem.

Na matriz na qual se considera a deformação axial específica, constata-se que, a menos das tensões desvio e confinante, este parâmetro não apresenta correlação significativa com qualquer dos parâmetros geotécnicos considerados.

Quadro 5.1 - Base de Dados

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria					Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3	
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)		IP (%)	h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)					Expansão (%)
		#1"	#3/8"	4	10	40	200											
0	Solo argiloso de comportamento laterítico (MCT)	100	99	97	90	80	70	58	22	15	20,6	1,523	16	0,21	A-7-6	57	0,109	-0,657
1	Areia argilosa de comportamento laterítico (MCT)	100	99	98	91	79	63	45	15	8	18,1	1,697	8	0,56	A-7-5	76	0,067	-0,544
2	Solo argiloso de comportamento laterítico (MCT)	100	99	98	93	81	70	54	22	14	21,3	1,646	11	0,14	A-7-5	107	0,074	-0,587
3	Solo argiloso de comportamento laterítico (MCT)	95	95	93	83	71	61	60	27	15	19,3	1,599	12	0,10	A-7-5	203	0,038	-0,223
4	Solo argiloso de comportamento laterítico (MCT)	100	99	93	81	65	56	65	32	14	17,4	1,576	12	0,22	A-7-5	184	0,073	-0,313
5	Silte Arenoso	100	99	97	85	69	59	46	14	7	18,7	1,722	24	0,19	A-7-5	258	0,537	-0,433
6	Solo argiloso de comportamento laterítico (MCT)	100	99	97	86	71	64	74	36	17	18,4	1,449	11	0,80	A-7-5	234	0,200	-0,325
7	Solo argiloso de comportamento laterítico (MCT)	100	99	99	87	68	58	49	20	10	14,0	1,656	20	0,44	A-7-6	75	0,146	-0,827
8	Solo argiloso de comportamento laterítico (MCT)	100	99	98	88	64	56	48	19	9	14,2	1,663	17	0,20	A-7-6	401	0,326	-0,371
9	Solo argiloso de comportamento laterítico (MCT)	100	99	99	93	70	55	44	16	7	16,3	1,778	11	0,25	A-7-5	114	0,194	-0,639
10	Solo argiloso de comportamento laterítico (MCT)	100	100	99	97	80	70	59	23	16	18,7	1,531	11	1,24	A-7-5	185	0,063	-0,434
11	Solo argiloso de comportamento laterítico (MCT)	100	99	99	93	75	57	50	25	12	12,7	1,640	6	0,00	A-4	394	0,205	-0,343
12	Solo argiloso de comportamento laterítico (MCT)	100	99	96	79	62	54	45	18	7	14,8	1,748	6	0,05	A-7-6	267	0,209	-0,427
13	Solo argiloso de comportamento laterítico (MCT)	100	100	99	97	79	67	51	17	11	21,8	1,626	4	0,00	A-7-5	227	0,078	-0,409
14	Solo argiloso de comportamento laterítico (MCT)	100	100	99	97	76	63	43	17	9	15,5	1,543	5	0,00	A-7-5	277	0,159	-0,474
15	Argila Arenosa	100	99	99	97	79	68	53	25	15	17,7	1,599	5	0,56	A-7-6	168	0,135	-0,432
16	Solo argiloso de comportamento laterítico (MCT)	100	100	99	97	77	62	39	15	7	16,7	1,529	4	0,00	A-6	298	0,157	-0,315
17	Solo argiloso de comportamento laterítico (MCT)	100	100	99	97	76	61	46	21	10	14,2	1,502	6	0,00	A-7-6	246	0,115	-0,401
18	Solo argiloso de comportamento laterítico (MCT)	100	100	99	95	74	60	46	20	10	15,9	1,496	4	0,00	A-7-6	274	0,165	-0,360
19	Areia argilosa de comportamento laterítico (MCT)	100	99	98	94	78	50	34	12	4	13,1	1,666	4	0,00	A-6	299	0,165	-0,404
20		100	100	99	98	84	59	36	15	7	16,6	1,569	5	0,00	A-6	229	0,156	-0,373
21		100	99	99	97	91	73	50	23	15	20,5	1,603	9	0,15	A-7-6	130	0,163	-0,625
22	Saibro arenoso com mica resid gnaïsse	98	96	87	66	39	26	32	0	0	8,2	2,053	19	1,10	A-2-4	375	0,393	-0,311
23	Saibro arenoso com mica resid gnaïsse	100	98	90	67	40	27	32	0	0	9,9	2,056	16	0,60	A-2-4	381	0,474	-0,213
24	Saibro arenoso com mica resid gnaïsse	96	93	85	64	39	26	31	0	0	9,3	2,043	17	0,40	A-2-4	214	0,255	-0,465
25	Saibro arenoso com mica resid gnaïsse	99	97	90	71	47	35	30	0	0	8,5	2,054	16	0,50	A-2-4	292	0,338	-0,301
26	Saibro arenoso com mica resid gnaïsse	88	81	75	61	39	24	32	0	0	6,5	2,073	20	0,60	A-1-b	578	0,482	-0,273
27	Saibro arenoso com mica resid gnaïsse	100	96	80	59	37	23	0	0	0	7,9	2,079	20	1,05	A-1-b	240	0,303	-0,435
28	Saibro arenoso com mica resid gnaïsse	99	97	93	77	46	30	33	0	0	9,1	2,011	24	1,15	A-2-4	240	0,204	-0,241
29	Saibro arenoso com mica resid gnaïsse	100	99	93	74	43	27	0	0	0	6,4	1,988	21	0,70	A-2-4	334	0,293	-0,278
30	Saibro arenoso com mica resid gnaïsse	100	98	85	61	34	19	0	0	0	7,2	2,088	29	0,50	A-1-b	530	0,413	-0,184
31	Saibro arenoso com mica resid gnaïsse	98	97	95	81	50	32	33	0	0	8,3	2,056	16	0,04	A-2-4	343	0,249	-0,226
32	Saibro arenoso com mica resid gnaïsse	100	97	93	76	46	31	32	0	0	8,0	2,055	16	0,66	A-2-4	262	0,170	-0,191
33	Saibro arenoso com mica resid gnaïsse	96	93	89	75	41	23	26	0	0	8,3	2,116	26	0,00	A-1-b	542	0,380	-0,072
34	Saibro arenoso com mica resid gnaïsse	100	98	97	82	49	34	32	0	0	9,2	2,046	19	0,48	A-2-4	207	0,207	-0,276
35	Saibro arenoso com mica resid gnaïsse	98	97	95	77	50	33	31	0	0	8,0	2,065	20	0,90	A-2-4	443	0,477	-0,371
36	Saibro arenoso com mica resid gnaïsse	100	95	89	78	46	22	21	0	0	5,5	2,025	38	0,00	A-1-b	425	0,356	-0,539
37	Saibro arenoso com mica resid gnaïsse	100	98	95	78	48	31	27	0	0	7,8	2,058	25	0,18	A-2-4	382	0,272	-0,314
38	Saibro arenoso com mica resid gnaïsse	100	99	96	84	55	27	26	0	0	6,6	2,042	36	0,00	A-2-4	459	0,299	-0,266
39	Saibro arenoso com mica resid gnaïsse	97	86	77	63	36	16	0	0	0	4,6	2,042	36	0,00	A-1-b	538	0,448	-0,266
40	Saibro arenoso com mica resid gnaïsse	99	96	91	76	43	20	24	0	0	4,9	2,027	40	0,00	A-1-b	447	0,271	-0,271
41	Saibro arenoso com mica resid gnaïsse	97	91	85	72	42	19	0	0	0	6,5	2,109	34	0,00	A-1-b	510	0,465	-0,534
42	Saibro arenoso com mica resid gnaïsse	98	92	84	67	40	16	0	0	0	5,7	2,031	45	0,00	A-1-b	450	0,400	-0,381

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria					Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3	
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)		IP (%)	h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)					Expansão (%)
		#1"	#3/8"	4	10	40	200											
43	Saibro arenoso com mica resid gnaisse	98	95	90	73	40	19	0	0	0	6,6	2,062	34	0,02	A-1-b	677	0,551	-0,343
44	Saibro arenoso com mica resid gnaisse	100	97	94	82	53	27	25	0	0	6,5	2,022	38	0,04	A-2-4	464	0,500	-0,769
45	Saibro arenoso com mica resid gnaisse	97	94	86	67	40	20	28	0	0	7,7	2,068	32	0,00	A-1-b	382	0,295	-0,186
46	Saibro arenoso com mica resid gnaisse	93	79	70	59	40	21	26	0	0	8,6	2,059	63	0,00	A-1-b	426	0,303	-0,129
47	Saibro arenoso resid gnaisse+Brita	80	61	55	47	28	15	24	0	0	5,2	2,298	86	0,00	A-1-b	807	0,488	-0,087
48	Saibro arenoso resid gnaisse+Brita	77	67	62	54	34	13	0	0	0	3,0	2,259	155	0,00	A-1-b	1.434	0,538	-0,055
49	Saibro arenoso resid gnaisse+Brita	88	82	74	62	37	13	0	0	0	3,4	2,233	97	0,00	A-1-b	1.127	0,539	-0,021
50	Saibro arenoso resid gnaisse+Brita	78	65	60	50	31	17	0	0	0	5,7	2,242	100	0,00	A-1-b	955	0,580	-0,137
51	Saibro arenoso resid gnaisse+Brita	74	56	50	43	26	10	0	0	0	4,1	2,269	112	0,00	A-1-a	956	0,481	-0,092
52	Saibro arenoso resid gnaisse+Brita	84	68	60	50	27	12	0	0	0	4,4	2,286	155	0,00	A-1-a	761	0,432	-0,157
53	Saibro arenoso resid gnaisse+Brita	85	70	62	51	30	11	0	0	0	3,4	2,228	108	0,00	A-1-b	2.008	0,778	-0,020
54	Saibro arenoso resid gnaisse+Brita	61	49	45	39	29	12	0	0	0	5,2	2,268	86	0,00	A-1-a	872	0,495	-0,070
55	Brita Graduada	100	53	37	27	15	5	0	0	0	5,1	2,275	118	0,00	A-1-a	893	0,401	-0,041
56	Brita Graduada	100	54	36	26	14	6	0	0	0	5,0	2,294	118	0,00	A-1-a	973	0,460	-0,046
57	Brita Graduada	100	46	34	27	15	5	0	0	0	5,6	2,207	118	0,00	A-1-a	993	0,465	-0,112
58	Brita Graduada	100	48	36	21	15	6	0	0	0	5,0	2,287	118	0,00	A-1-a	695	0,435	-0,310
59	Brita Graduada	100	56	37	26	13	5	0	0	0	5,2	2,275	118	0,00	A-1-a	926	0,431	-0,038
60	Brita Graduada	100	54	40	30	14	5	0	0	0	5,6	2,238	118	0,00	A-1-a	364	0,152	-0,295
61	Brita Graduada	100	47	34	26	15	6	0	0	0	5,7	2,265	118	0,00	A-1-a	651	0,233	-0,085
62	Argila Arenosa comport. Laterítico	100	100	100	100	91	62	40	11	6	21,9	1,674	33	0,20	A-4	201	0,288	-0,456
63	Areia Argilosa comport. Laterítico	100	100	100	100	91	63	40	11	6	20,9	1,691	20	0,10	A-7-6	221	0,253	-0,349
64	Argila Arenosa comport. Laterítico	100	98	97	97	83	60	41	12	6	20,2	1,706	22	0,10	A-7-6	245	0,180	-0,274
65	Argila Arenosa comport. Laterítico	100	100	100	100	88	60	39	10	5	19,0	1,698	23	0,20	A-4	460	0,188	-0,095
66	Areia Argilosa comport. Laterítico	100	100	100	100	87	60	28	8	5	19,1	1,703	10	0,20	A-4	347	0,155	-0,221
67	Areia Argilosa comport. Laterítico	100	100	100	100	90	61	38	9	5	20,1	1,702	16	0,10	A-4	297	0,167	-0,213
68	Argila Arenosa comport. Laterítico	100	100	100	100	90	62	39	10	5	20,7	1,702	24	0,10	A-4	242	0,197	-0,276
69	Solo Argiloso Fino	100	100	100	99	96	91	65	28	19	18,9	1,742	3	9,80	A-7-5	443	0,167	-0,170
70	Solo Argiloso Fino	100	100	100	100	99	66	26	18	18	18,7	1,781	3	1,10	A-7-5	207	0,031	-0,380
71	Solo Argiloso Fino	100	100	100	100	99	65	35	16	8	12,2	1,934	11	4,20	A-6	861	0,290	-0,288
72	Solo Argiloso Fino	100	100	100	100	100	86	59	33	20	19,0	1,797	15	2,70	A-7-5	616	0,234	-0,337
73	Solo Argiloso Fino	100	100	100	100	97	62	36	22	10	12,2	2,064	24	0,80	A-6	246	0,181	-0,352
74	Solo Argiloso Fino + Areia	100	100	100	100	99	60	31	15	7	11,5	1,966	17	0,20	A-6	292	0,070	-0,652
75	Solo Argiloso Fino + Areia	100	100	100	100	99	53	26	11	4	11,5	1,986	35	0,20	A-6	787	0,394	-0,514
76	Solo Argiloso Fino + Areia	100	100	100	100	99	49	23	8	3	10,7	2,042	36	0,20	A-4	273	0,192	-0,387
77	Solo Argiloso Fino + Areia	100	100	100	100	99	39	20	6	1	9,5	2,017	34	0,20	A-4	377	0,192	-0,362
78	Solo Argiloso Fino + Areia	100	100	100	100	99	34	17	4	0	8,4	1,991	30	0,00	A-2-4	398	0,256	-0,402
79	Solo Argiloso Fino + Areia	100	100	100	100	99	42	21	7	1	8,7	1,982	30	0,10	A-4	518	0,177	-0,242
80	Solo Laterítico Piçarra	100	98	74	61	61	37	40	23	3	13,2	2,026	20	0,70	A-2-6	316	0,388	-0,590
81	Solo Laterítico Piçarra	100	100	77	77	76	44	32	14	3	11,1	2,128	59	0,50	A-6	545	0,255	-0,309
82	Solo Laterítico "in natura"	98	72	50	33	23	12	22	7	0	7,5	2,190	55	0,00	A-2-4	621	0,362	-0,364
83	Solo Laterítico "in natura"	97	83	57	34	24	17	24	8	0	9,0	2,140	47	0,00	A-2-4	567	0,337	-0,024
84		96	74	50	33	24	18	24	8	0	9,7	2,030	25	0,00	A-2-4	775	0,443	-0,107
85		100	79	52	32	24	13	22	5	0	8,0	2,050	42	0,00	A-1-a	589	0,338	-0,257

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria						Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)				
		#1"	#3/8"	4	10	40	200											
86	Solo Laterítico "in natura"	100	78	52	28	16	9	21	5	0	5,0	2,130	50	0,00	A-1-a	780	0,354	-0,091
87	Solo Laterítico "in natura"	94	73	48	29	20	10	17	3	0	7,0	2,120	107	0,00	A-1-a	549	0,286	-0,289
88		97	77	57	39	30	18	24	6	0	10,0	2,000	42	0,00	A-1-b	831	0,347	-0,106
89	Solo Laterítico "in natura"	98	59	38	27	22	7	0	0	0	6,2	2,210	140	0,00	A-1-a	1.321	0,457	-0,191
90	Solo Laterítico "in natura"	98	76	53	35	25	14	25	8	0	10,0	2,110	53	0,50	A-2-4	1.141	0,444	-0,330
91	Solo Laterítico "in natura"	100	87	67	51	37	18	25	8	0	8,6	2,070	70	0,60	A-2-4	809	0,343	-0,126
92		100	99	98	91	69	31	26	9	0	11,6	1,860	64	0,00	A-2-4	719	0,404	-0,177
93	Solo Laterítico "in natura"	100	92	58	30	25	13	21	7	0	6,7	2,220	75	0,00	A-2-4	620	0,248	-0,271
94	Solo Laterítico "in natura"	98	89	63	31	22	10	20	6	0	6,0	2,180	85	0,00	A-1-a	797	0,392	-0,277
95		97	82	51	30	24	11	19	5	0	8,6	2,080	28	0,00	A-1-a	833	0,374	-0,058
96	Solo Laterítico "in natura"	100	82	60	42	30	18	29	9	0	10,0	2,010	65	0,00	A-2-4	662	0,326	-0,200
97	Solo Laterítico "in natura"	94	65	46	31	24	16	31	11	0	10,0	2,030	85	0,00	A-2-4	608	0,348	-0,260
98		100	100	99	95	75	34	21	8	0	10,5	1,900	15	0,00	A-2-6	526	0,195	-0,139
99	Solo Laterítico "in natura"	98	76	58	51	45	23	28	3	0	9,0	1,920	48	0,00	A-1-b	1.025	0,281	-0,139
100	Solo Laterítico "in natura"	97	61	46	41	37	19	25	7	0	10,2	1,990	74	0,00	A-2-4	929	0,291	-0,151
101		96	73	64	59	55	33	32	12	0	13,1	1,790	16	0,00	A-2-6	485	0,250	-0,340
102	Areia siltosa	100	100	100	98	79	30	30	9	0	12,6	1,878	8	0,60	A-2-4	556	0,223	-0,258
103	Areia siltosa	100	97	96	95	79	14	0	0	0	9,2	1,875	54	0,20	A-2-5	1.400	0,387	-0,043
104	Areia Argilosa	100	79	74	69	40	15	0	0	0	5,8	2,212	97	0,00	A-2-4	1.222	0,492	-0,009
105	Areia Argilosa	100	83	72	65	51	22	0	0	0	7,3	1,937	47	0,10	A-3	560	0,097	-0,083
106	Areia siltosa	97	83	76	70	58	40	46	14	2	15,6	1,824	8	0,30	A-7-5	410	0,306	-0,407
107	Areia Argilosa	100	74	64	60	43	6	0	0	0	4,0	2,196	84	0,00	A-2-4	1.198	0,463	-0,085
108	Solo estabilizado granulometricamente	66	44	36	32	23	9	0	0	0	3,0	2,194	68	0,00	A-1-a	488	0,192	-0,139
109	Solo estabilizado granulometricamente	94	70	60	55	40	16	0	0	0	3,7	2,161	53	0,00	A-1-b	719	0,435	-0,357
110		100	98	94	86	63	32	0	0	0	7,6	1,995	8	0,00	A-2-4	290	0,295	-0,201
111	Solo estabilizado granulometricamente	91	74	69	65	45	17	0	0	0	4,7	2,097	53	0,00	A-1-b	578	0,372	-0,180
112	Solo estabilizado granulometricamente	96	77	71	67	49	20	0	0	0	4,6	2,130	42	0,00	A-1-b	666	0,364	-0,085
113		98	95	92	87	66	28	0	0	0	6,4	1,954	6	0,00	A-2-4	383	0,342	-0,235
114	Solo estabilizado granulometricamente	100	79	72	67	51	23	0	0	0	3,4	2,146	54	0,00	A-2-4	356	0,263	-0,693
115	Solo estabilizado granulometricamente	81	62	58	54	42	18	0	0	0	3,7	2,154	30	0,00	A-1-b	555	0,332	-0,142
116	Solo estabilizado granulometricamente	87	70	62	56	41	16	0	0	0	4,3	2,157	72	0,00	A-1-b	755	0,357	-0,095
117	Solo estabilizado granulometricamente	91	76	70	65	49	22	0	0	0	4,8	2,172	32	0,00	A-1-b	451	0,286	-0,156
118		100	100	100	100	87	14	0	0	0	6,3	1,914	11	0,00	A-2-4	856	0,384	-0,090
119		100	100	100	100	89	13	0	0	0	5,1	1,906	12	0,00	A-2-4	831	0,460	-0,310
120		100	100	100	99	81	48	29	11	3	12,1	1,935	11	0,03	A-6	850	0,494	-0,183
121		100	100	100	99	81	48	29	11	3	9,6	1,892	11	0,03	A-6	1.171	0,268	-0,127
122		100	100	100	99	81	48	29	11	3	10,2	1,980	11	0,03	A-6	729	0,192	-0,206
123		100	100	100	93	74	44	32	6	2	10,5	1,821	13	0,02	A-4	609	0,205	-0,109
124		100	100	100	93	74	44	32	6	2	11,8	1,972	13	0,02	A-4	1.084	0,507	-0,139
125		100	100	100	99	82	33	28	6	0	10,8	2,026	16	0,00	A-2-4	991	0,403	-0,109
126		100	100	100	100	88	5	0	0	0	12,2	1,934	15	0,00	A-3	677	0,182	-0,184
127		100	100	100	97	86	22	0	0	0	11,4	1,952	19	0,00	A-2-4	997	0,391	-0,066
128		100	95	91	84	62	27	0	0	0	7,3	1,971	10	0,00	A-2-4	249	0,263	-0,451

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria					Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3	
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)		IP (%)	h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)					Expansão (%)
		#1"	#3/8"	4	10	40	200											
129		100	100	100	100	87	14	0	0	0	6,3	1,914	11	0,00	A-2-4	856	0,384	-0,090
130		100	100	100	100	89	13	0	0	0	5,1	1,906	12	0,00	A-2-4	831	0,460	-0,310
131		100	100	100	99	81	48	29	11	3	10,2	1,980	11	0,03	A-6	729	0,192	-0,206
132		100	100	100	98	69	19	0	0	0	5,5	2,013	17	0,00	A-2-4	1.054	0,473	-0,009
133		100	100	100	93	74	44	32	6	2	10,5	1,821	13	0,02	A-4	609	0,205	-0,109
134		100	100	100	99	82	33	28	6	0	10,8	2,026	16	0,00	A-2-4	991	0,403	-0,109
135		100	100	100	97	86	22	0	0	0	11,4	1,952	19	0,00	A-2-4	997	0,391	-0,066
136		100	100	100	98	74	56	54	27	12	18,4	1,634	9	0,52	A-7-6	139	0,002	-0,391
137		100	100	100	98	78	58	60	35	15	18,0	1,735	12	0,37	A-7-6	253	0,137	-0,477
138		100	100	100	98	67	45	53	31	8	12,9	1,914	26	0,00	A-7-6	250	0,142	-0,359
139		100	100	99	97	77	51	54	31	11	16,5	1,823	16	0,10	A-7-6	120	0,128	-0,607
140		100	100	98	96	81	56	65	37	14	17,3	1,816	11	0,10	A-7-6	199	0,127	-0,414
141		100	100	99	98	81	59	61	31	15	18,7	1,647	9	0,68	A-7-6	113	0,013	-0,490
142		100	100	100	98	75	55	62	37	14	16,3	1,820	17	0,08	A-7-6	174	0,023	-0,416
143		100	96	90	80	43	15	0	0	0	8,8	2,039	24	0,07	A-2-4	714	0,430	-0,011
144		100	96	91	80	44	17	0	0	0	8,2	2,006	9	0,00	A-2-4	603	0,405	-0,091
145		100	100	100	98	74	56	54	27	12	16,5	1,591	9	0,52	A-7-6	339	0,120	-0,156
146		100	100	100	98	67	45	53	31	8	11,1	1,742	26	0,00	A-7-6	900	0,229	-0,005
147		100	100	98	96	81	56	65	37	14	15,5	1,765	11	0,10	A-7-6	823	0,260	-0,140
148		100	100	100	98	77	48	48	25	8	14,9	1,870	5	0,29	A-7-6	118	0,154	-0,575
149		100	100	100	98	79	53	57	31	13	15,0	1,721	18	0,02	A-7-6	652	0,126	-0,135
150		100	100	100	98	78	58	60	35	15	15,6	1,597	12	0,37	A-7-6	873	0,320	-0,134
151		100	100	99	97	77	51	54	31	11	13,4	1,759	16	0,10	A-7-6	829	0,203	-0,013
152		100	100	99	96	71	46	48	27	8	18,3	1,623	5	1,94	A-7-6	412	0,361	-0,447
153		100	96	88	79	66	42	44	24	5	13,3	2,068	9	0,00	A-7-5	365	0,342	-0,293
154		100	100	99	97	70	54	58	30	13	19,0	1,691	6	0,19	A-7-6	128	0,089	-0,420
155		100	100	100	99	70	47	65	37	10	17,2	1,789	14	0,08	A-7-6	163	0,238	-0,506
156		100	100	99	97	80	52	44	23	9	15,1	1,822	20	0,43	A-7-6	447	0,123	-0,057
157		100	100	99	97	75	55	60	34	14	16,7	1,743	19	0,36	A-7-6	354	0,309	-0,575
158		100	100	99	96	71	46	48	27	8	13,5	1,825	6	0,24	A-7-6	141	0,116	-0,586
159		100	99	96	87	56	28	31	13	0	10,2	1,942	4	0,00	A-2-6	301	0,410	-0,297
160		100	100	100	99	62	31	31	18	1	9,5	1,955	6	0,00	A-2-6	282	0,296	-0,404
161		100	99	97	95	78	58	54	24	12	17,1	1,579	18	0,50	A-7-6	647	0,278	-0,307
162		100	99	98	95	74	47	50	28	9	14,8	1,877	18	0,16	A-7-6	130	0,191	-0,539
163		100	98	94	84	46	20	29	12	0	7,8	2,317	11	0,07	A-2-6	423	0,425	-0,316
164		100	99	98	91	63	39	44	23	4	14,0	1,798	4	0,99	A-7-6	120	0,383	-0,502
165		100	100	100	97	76	55	56	27	12	18,0	1,756	9	0,30	A-7-5	84	0,222	-0,503
166		100	99	98	96	73	56	63	35	14	15,2	1,799	8	0,00	A-7-6	81	0,255	-0,693
167		100	100	98	95	76	63	59	26	15	18,0	1,599	5	1,21	A-7-6	95	0,089	-0,493
168		100	97	90	82	69	46	45	24	7	14,6	1,734	15	0,04	A-7-6	94	0,271	-0,824
169		100	100	99	97	75	52	50	26	10	13,7	1,792	6	0,66	A-7-6	95	0,098	-0,461
170		100	100	100	99	69	48	65	34	11	10,7	1,909	22	0,54	A-7-5	197	0,264	-0,594
171		100	100	100	98	66	45	44	20	5	10,1	1,960	16	0,00	A-7-6	152	0,242	-0,414

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria					Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3	
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)		IP (%)	h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)					Expansão (%)
		#1"	#3/8"	4	10	40	200											
172		100	100	98	95	79	54	55	31	13	18,2	1,792	10	0,03	A-7-6	254	0,166	-0,432
173		100	100	99	97	68	42	42	19	4	10,6	1,816	7	0,81	A-7-6	222	0,131	-0,356
174	Brita Graduada	86	57	46	35	17	5	0	0	0	2,9	2,270	120	0,00	A-1-a	1.253	0,511	-0,281
175		100	98	95	84	42	16	0	0	0	7,4	2,096	57	0,00	A-1-b	677	0,457	-0,181
176		100	100	100	97	63	18	0	0	0	5,8	1,893	28	0,00	A-2-4	702	0,417	-0,019
177		100	100	100	97	63	13	0	0	0	7,4	2,017	17	0,00	A-2-4	728	0,413	-0,196
178	Solo Jazida Palmares	100	100	99	97	67	45	42	21	5	15,2	1,784	7	0,36	A-7-5	257	0,284	-0,457
179	Solo Jazida Palmares	100	100	99	95	72	50	39	12	4	18,8	1,626	9	0,54	A-6	247	0,005	-0,304
180	Solo Jazida Morro da Bandeira	100	99	93	78	24	9	22	0	0	11,3	1,918	31	0,00	A-2-4	481	0,327	-0,170
181	Solo Jazida Palmares	100	100	99	93	51	34	46	18	2	18,0	1,709	10	0,23	A-2-7	182	0,156	-0,429
182	Solo Jazida Palmares	100	100	99	97	74	49	39	14	4	16,1	1,766	7	0,57	A-6	227	0,085	-0,394
183	Solo Jazida Palmares	100	100	99	94	73	46	40	15	4	17,4	1,736	8	0,63	A-6	179	0,082	-0,469
184	Solo Jazida Covanca A2	100	100	99	93	59	34	0	0	0	17,3	1,704	5	0,50	A-2-4	138	0,394	-0,501
185	Solo Jazida Covanca A3	100	97	91	74	42	33	37	11	0	10,8	1,956	9	0,37	A-2-6	243	0,222	-0,294
186	Pó de Pedra Concrebrás	100	100	100	76	31	5	0	0	0	8,0	2,060	54	0,00	A-1-b	601	0,481	-0,101
187	Brita Corrida Concrebrás	100	78	62	48	6	1	0	0	0	7,4	2,033	57	0,00	A-1-a	551	0,452	-0,262
188	Pó de Pedra São Pedro	100	100	100	69	29	3	0	0	0	9,1	1,906	59	0,00	A-1-b	477	0,403	-0,111
189	Pó de Pedra N. S. Fátima	100	100	100	78	23	3	0	0	0	10,0	1,910	58	0,00	A-1-b	512	0,354	-0,148
190	Pó de Pedra ESAM	100	100	100	74	28	5	0	0	0	9,5	1,954	60	0,00	A-1-b	441	0,319	-0,237
191	Solo Jazida Manelão	100	100	84	73	38	34	0	0	0	10,1	1,880	20	0,00	A-2-4	464	0,349	-0,175
192	Pó de Pedra Anhanguera	100	100	94	74	22	1	0	0	0	8,8	1,896	33	0,00	A-1-b	566	0,459	-0,109
193	Pó de Pedra Bangu	100	100	99	84	33	4	0	0	0	9,4	1,859	25	0,00	A-1-b	560	0,463	-0,176
194	Pó de Pedra Sepetiba	100	100	94	71	32	5	0	0	0	8,6	2,048	28	0,00	A-1-b	528	0,411	-0,059
195	Pó de Pedra EMASA	100	100	98	72	28	5	0	0	0	7,2	1,978	25	0,00	A-1-b	614	0,408	-0,162
196	Pó de Pedra Santa Luzia	100	100	100	72	25	3	0	0	0	9,4	1,946	26	0,00	A-1-b	597	0,415	-0,184
197	Brita Corrida EMASA	100	78	65	48	19	3	0	0	0	7,5	2,186	82	0,00	A-1-a	726	0,438	-0,187
198	Brita Corrida Anhanguera	100	75	51	37	16	2	0	0	0	6,7	2,268	96	0,00	A-1-a	657	0,322	-0,164
199	Brita Corrida Sepetiba	100	81	65	49	21	3	0	0	0	7,0	2,256	68	0,00	A-1-a	693	0,384	-0,068
200	Brita Corrida Santa Luzia	100	70	61	53	27	4	0	0	0	4,9	2,145	40	0,00	A-1-a	847	0,464	-0,116
201	Brita Corrida Pena Branca	100	77	65	53	30	4	0	0	0	5,6	2,150	79	0,00	A-1-a	969	0,442	-0,044
202	Brita Corrida Bangu	100	52	36	24	8	1	0	0	0	7,5	2,136	72	0,00	A-1-a	483	0,390	-0,151
203	Pó de Pedra Ibrata	100	100	98	80	23	4	0	0	0	8,6	1,908	31	0,00	A-1-b	614	0,408	-0,029
204	Pó de Pedra Tamoio	100	100	95	90	40	6	0	0	0	8,8	1,954	27	0,00	A-1-b	606	0,560	-0,123
205	Brita Corrida Tamoio	100	83	69	57	26	5	0	0	0	6,5	2,150	50	0,00	A-1-a	810	0,476	-0,119
206	Solo Jazida Cachamorra	100	99	97	77	26	9	0	0	0	9,7	1,912	20	0,00	A-1-b	451	0,400	-0,096
207	Solo Jazida João Cândido Km 32 A1	100	98	91	68	31	17	39	8	0	10,6	1,985	12	0,35	A-2-4	404	0,466	-0,191
208	Solo Jazida João Cândido Km 32 A2	100	97	90	69	37	31	38	6	0	10,4	1,970	12	0,25	A-2-4	297	0,438	-0,769
209	Brita Corrida Concrebrás	100	78	62	48	6	1	0	0	0	6,2	2,140	83	0,00	A-1-a	815	0,445	-0,078
210	Brita Corrida Vigné	97	55	34	31	13	2	0	0	0	4,8	2,088	100	0,00	A-1-a	1.051	0,480	-0,063
211	Brita Corrida ESAM	100	64	39	22	8	1	0	0	0	3,8	2,096	76	0,00	A-1-a	678	0,336	-0,017
212	Brita Corrida EMASA	100	78	65	48	19	3	0	0	0	5,9	2,227	100	0,00	A-1-a	938	0,489	-0,085
213	Brita Corrida Anhanguera	100	75	51	37	16	2	0	0	0	6,0	2,293	100	0,00	A-1-a	944	0,473	-0,061
214	Brita Corrida Pena Branca	100	77	65	53	30	4	0	0	0	4,9	2,190	86	0,00	A-1-a	871	0,526	-0,152

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria						Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)				
		#1"	#3/8"	4	10	40	200											
215	Brita Corrida Bangu	100	52	36	24	8	1	0	0	0	6,8	2,230	82	0,00	A-1-a	772	0,464	-0,097
216	Brita Corrida Tamoio	100	83	69	57	26	5	0	0	0	6,3	2,190	82	0,00	A-1-a	938	0,544	-0,132
217	Saibro	100	94	91	87	37	21	0	0	0	9,6	1,910	24	0,07	A-1-b	329	0,029	-0,315
218	Saibro	100	98	93	87	39	17	0	0	0	9,7	1,924	20	0,05	A-1-b	660	0,459	-0,536
219	Argila	100	100	100	94	77	61	57	23	13	16,2	1,629	11	1,80	A-7-6	235	0,173	-0,575
220	Saibro	100	97	92	81	39	21	26	7	0	10,1	1,999	24	0,09	A-2-4	1.269	0,424	-0,014
221	Saibro	100	100	99	95	55	39	49	18	3	15,5	1,795	13	0,78	A-7-5	129	0,276	-0,562
222	Saibro	80	78	76	71	30	15	0	0	0	9,9	1,943	19	0,03	A-1-b	490	0,430	-0,245
223	Argila	100	98	97	95	68	52	51	13	6	13,7	1,648	14	0,02	A-7-5	117	0,194	-0,651
224	Saibro	96	85	83	77	38	20	0	0	0	9,7	1,928	24	0,08	A-1-b	471	0,429	-0,259
225	Saibro	100	92	89	84	44	22	0	0	0	10,7	1,911	18	0,04	A-1-b	546	0,503	-0,265
226	Areia	100	100	93	80	39	19	0	0	0	11,2	1,971	21	0,13	A-1-b	418	0,461	-0,252
227	Saibro	100	98	98	97	65	49	60	23	9	14,4	1,462	6	0,18	A-7-5	200	0,212	-0,577
228	Saibro	100	87	84	79	37	11	0	0	0	8,8	1,952	42	0,00	A-1-b	558	0,470	-0,244
229	Saibro	100	91	89	85	47	30	42	17	1	11,0	1,787	12	0,04	A-2-7	208	0,253	-0,545
230	Saibro	100	98	96	91	47	26	48	16	1	13,0	1,671	15	0,19	A-2-7	142	0,283	-0,651
231	Saibro	100	97	96	91	47	21	0	0	0	8,2	1,968	24	0,01	A-1-b	582	0,376	-0,129
232	Saibro	100	100	92	87	49	31	29	5	0	11,3	1,886	21	0,55	A-2-4	507	0,513	-0,310
233	Saibro	100	88	84	78	39	15	0	0	0	10,0	1,921	22	0,07	A-1-b	468	0,400	-0,247
234	Saibro	100	99	97	96	65	36	0	0	0	10,7	1,815	3	0,62	A-2-6	132	0,397	-0,470
235	Saibro	100	95	91	87	47	19	0	0	0	10,2	1,876	26	0,04	A-1-b	522	0,460	-0,296
236	Saibro	100	98	95	91	55	26	0	0	0	9,8	1,888	29	0,28	A-2-4	451	0,361	-0,239
237	Saibro	100	90	86	79	36	17	0	0	0	10,0	2,012	30	0,00	A-1-b	548	0,448	-0,272
238	Saibro	100	91	89	83	44	25	0	7	0	9,6	1,964	20	0,04	A-2-4	410	0,411	-0,311
239	Saibro	94	92	88	82	40	16	0	0	0	8,7	1,919	25	0,00	A-1-b	562	0,344	-0,136
240	Saibro	93	88	86	82	39	18	0	0	0	9,9	1,857	22	0,16	A-1-b	235	0,331	-0,558
241	Saibro	100	97	94	88	43	17	0	0	0	6,6	1,885	23	0,07	A-1-b	436	0,365	-0,226
242	Saibro	100	94	92	85	41	22	28	7	0	9,8	1,912	16	0,03	A-2-4	262	0,346	-0,580
243	Saibro	95	83	79	71	28	12	0	0	0	9,6	1,980	39	0,02	A-1-b	473	0,470	-0,408
244	Saibro	100	97	97	91	58	34	0	8	0	12,0	1,823	14	0,24	A-2-5	284	0,463	-0,478
245	Saibro	82	69	65	61	27	11	0	0	0	9,5	1,969	32	0,05	A-1-b	436	0,436	-0,436
246	Saibro	100	95	91	87	41	13	0	0	0	9,1	1,927	27	0,07	A-1-b	421	0,410	-0,374
247	Saibro	100	97	94	88	43	17	0	0	0	7,1	1,909	23	0,07	A-1-b	429	0,419	-0,350
248	Saibro com pedregulho	95	89	84	75	40	23	0	0	0	8,2	1,803	37	0,02	A-1-b	227	0,194	-0,467
249	Saibro	100	98	96	92	52	28	36	9	0	9,5	1,874	14	0,68	A-2-4	296	0,386	-0,367
250	Saibro	100	97	93	90	64	37	46	14	1	11,0	1,750	16	0,51	A-7-5	170	0,180	-0,527
251	Saibro	100	92	89	86	43	10	0	0	0	11,4	1,903	28	0,06	A-1-b	449	0,383	-0,235
252	Saibro	100	90	88	84	40	23	31	8	0	9,6	1,940	24	0,02	A-2-4	450	0,338	-0,173
253	Saibro	100	94	90	85	47	25	32	10	0	9,7	1,905	29	0,07	A-2-4	348	0,412	-0,428
254	Saibro com pedregulho	100	84	81	77	40	13	0	0	0	7,2	1,972	75	0,00	A-1-b	577	0,339	-0,139
255	Saibro com pedregulho	100	88	85	80	34	16	26	4	0	7,5	1,945	44	0,00	A-1-b	504	0,370	-0,261
256	Saibro com pedregulho	100	77	74	70	33	16	0	0	0	8,0	2,041	55	0,00	A-1-b	563	0,428	-0,287
257	Saibro com pedregulho	92	81	78	74	28	12	0	0	0	8,9	2,018	47	0,00	A-1-b	523	0,403	-0,310

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria					Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3	
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)		IP (%)	h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)					Expansão (%)
		#1"	#3/8"	4	10	40	200											
258	Saibro	96	86	83	79	46	25	0	0	0	9,2	1,969	40	0,03	A-1-b	575	0,416	-0,207
259	Silte arenoso micáceo	100	100	100	96	86	54	33	14	5	14,8	1,755	7	2,40	A-6	152	0,382	-0,433
260	Silte arenoso micáceo	100	100	100	99	94	56	36	16	7	16,1	1,739	8	2,00	A-6	138	0,296	-0,410
261	Silte arenoso micáceo	100	100	100	97	90	52	33	12	4	16,9	1,708	6	2,15	A-6	118	0,227	-0,439
262	Silte arenoso micáceo	100	100	100	99	97	51	34	10	3	17,3	1,651	12	1,10	A-4	217	0,455	-0,307
263	Silte arenoso micáceo	100	100	100	98	91	55	39	19	8	15,2	1,658	3	5,90	A-6	119	0,334	-0,437
264	Silte arenoso micáceo	100	100	100	98	92	60	35	10	5	15,2	1,756	4	4,00	A-4	130	0,328	-0,384
265	Silte arenoso micáceo	100	100	100	98	89	49	32	14	4	16,7	1,747	9	2,20	A-6	212	0,437	-0,363
266	Silte arenoso micáceo	100	100	100	97	91	55	36	16	6	17,3	1,783	15	0,80	A-6	126	0,439	-0,674
267	Silte arenoso	100	100	100	98	91	51	0	0	3	18,4	1,692	10	0,88	A-4	182	0,489	-0,286
268	Silte arenoso micáceo	100	100	100	97	88	52	30	6	3	13,2	1,641	3	4,70	A-4	118	0,295	-0,422
269	Silte arenoso	100	100	100	97	91	61	38	17	8	19,2	1,674	2	4,00	A-6	91	0,341	-0,440
270	Silte arenoso	100	100	100	99	91	56	28	6	4	16,2	1,732	7	2,40	A-4	197	0,424	-0,337
271	Silte arenoso	100	100	100	96	88	52	27	11	4	12,7	1,769	4	4,20	A-6	172	0,387	-0,446
272	Silte arenoso	100	100	100	99	95	62	36	10	5	17,3	1,682	4	2,90	A-4	149	0,464	-0,471
273	Silte arenoso	100	100	100	98	95	63	34	14	7	19,3	1,701	5	2,50	A-6	199	0,352	-0,195
274	Silte arenoso	100	100	100	99	93	55	35	10	4	17,5	1,734	5	3,10	A-4	161	0,409	-0,471
275	Silte arenoso	100	100	100	96	87	50	31	9	3	14,2	1,758	7	2,60	A-4	264	0,322	-0,287
276	Silte arenoso	100	100	100	96	87	45	28	11	2	16,2	1,785	11	0,44	A-6	303	0,536	-0,339
277	Latossolo vermelho amarelo	100	100	100	99	93	73	62	32	19	26,2	1,473			A-7-6	96	0,069	-0,491
278	Latossolo vermelho amarelo	100	100	100	100	91	69	74	43	18	26,3	1,452			A-7-6	76	0,065	-0,502
279	Podzólico vermelho escuro	100	100	100	100	97	77	79	49	20	28,5	1,490			A-7-6	68	0,086	-0,669
280	Latossolo vermelho escuro	100	100	100	98	88	71	74	37	19	26,8	1,453			A-7-5	74	0,060	-0,538
281	Latossolo vermelho escuro	100	100	100	100	95	77	62	29	20	24,9	1,505			A-7-5	175	0,170	-0,485
282	Latossolo vermelho amarelo	100	100	100	97	83	67	68	36	18	25,0	1,466			A-7-5	102	0,081	-0,472
283	Latossolo vermelho amarelo	100	100	100	99	87	70	66	37	19	25,0	1,501			A-7-6	93	0,223	-0,795
284	Latossolo bruno	100	100	99	98	88	74	74	42	20	27,7	1,462			A-7-6	72	0,030	-0,512
285	Latossolo vermelho amarelo	100	100	98	97	94	67	74	46	18	25,6	1,478			A-7-6	90	0,086	-0,531
286	Latossolo vermelho amarelo	100	100	99	97	85	66	90	57	17	26,8	1,480			A-7-5	87	0,113	-0,556
287	Latossolo vermelho amarelo	100	100	99	98	86	63	70	44	16	17,8	1,670			A-7-6	137	0,113	-0,601
288	Latossolo vermelho amarelo	100	100	99	98	96	80	81	48	20	27,5	1,439			A-7-5	78	0,063	-0,721
289	Latossolo vermelho escuro	100	100	100	99	92	71	80	46	19	30,9	1,412			A-7-5	74	0,038	-0,579
290	Latossolo bruno	100	100	100	99	94	81	66	38	20	25,9	1,482			A-7-6	129	0,069	-0,472
291	Latossolo vermelho amarelo	100	100	99	98	94	61	74	46	16	26,4	1,503			A-7-6	126	0,199	-0,597
292	Latossolo bruno	100	100	100	99	98	84	64	31	20	32,2	1,386			A-7-5	83	0,110	-0,546
293	Latossolo roxo	100	100	99	98	96	91	78	45	20	31,1	1,326			A-7-5	142	0,143	-0,488
294	Latossolo roxo	100	100	100	98	95	86	55	27	18	29,6	1,462			A-7-6	141	0,144	-0,502
295	Latossolo ferrífero	100	100	99	95	85	63	35	12	7	21,3	1,722			A-4	159	0,344	-0,319
296	Latossolo vermelho amarelo	100	100	99	99	95	70	57	26	16	26,7	1,454			A-7-5	84	0,189	-0,546
297	Latossolo vermelho escuro	100	99	98	95	81	69	49	21	13	25,5	1,496			A-6	341	0,273	-0,360
298	Podzólico vermelho escuro	100	100	100	99	98	90	64	31	20	28,4	1,465			A-7-5	32	0,029	-0,708
299	Podzólico vermelho escuro	100	100	100	99	95	82	50	19	18	29,8	1,355			A-7-5	196	0,255	-0,380
300	Latossolo vermelho escuro	100	100	100	100	99	45	33	13	3	14,3	1,762			A-2-6	286	0,223	-0,424

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria					Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3	
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)		IP (%)	h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)					Expansão (%)
		#1"	#3/8"	4	10	40	200											
301	Latossolo bruno	100	100	99	96	85	74	72	34	20	29,3	1,435		A-7-5	118	0,161	-0,454	
302	Latossolo roxo	100	100	100	100	93	79	50	16	13	27,5	1,405		A-6	179	0,155	-0,396	
303	Podzólico vermelho escuro	100	100	100	99	96	85	65	34	20	29,0	1,381		A-7-5	83	0,110	-0,518	
304	Latossolo vermelho amarelo	100	100	100	99	91	70	70	37	19	27,4	1,458		A-7-5	98	0,160	-0,499	
305	Podzólico vermelho escuro	100	100	100	99	96	77	51	27	17	25,6	1,497		A-7-5	104	0,087	-0,506	
306	Latossolo vermelho amarelo	100	100	100	98	94	71	58	27	17	26,5	1,447		A-7-5	86	0,088	-0,506	
307	Latossolo vermelho amarelo	100	100	99	97	90	64	49	20	11	25,0	1,508		A-5	93	0,129	-0,669	
308	Latossolo vermelho amarelo	100	100	100	99	93	73	62	32	19	23,0	1,510		A-7-6	233	0,091	-0,580	
309	Latossolo vermelho amarelo	100	100	100	100	91	69	74	43	18	23,2	1,487		A-7-6	151	0,013	-0,604	
310	Latossolo vermelho amarelo	100	100	100	99	87	70	66	37	19	23,5	1,580		A-7-6	146	0,098	-0,517	
311	Latossolo vermelho amarelo	100	100	99	98	96	80	81	48	20	25,7	1,478		A-7-5	359	0,095	-0,241	
312	Latossolo roxo	100	100	99	98	96	91	78	45	20	30,0	1,336		A-7-5	269	0,082	-0,246	
313	Latossolo roxo	100	100	100	98	95	86	55	27	18	27,3	1,520		A-7-6	223	0,128	-0,329	
314	Latossolo ferrífero	100	100	99	95	85	63	35	12	7	17,4	1,737		A-4	176	0,232	-0,373	
315	Latossolo vermelho escuro	100	99	98	95	81	69	49	21	13	23,6	1,510		A-6	447	0,162	-0,283	
316	Podzólico vermelho escuro	100	100	100	99	95	82	50	19	18	27,0	1,388		A-7-5	242	0,112	-0,363	
317	Latossolo vermelho escuro	100	100	100	100	99	45	33	13	3	12,1	1,796		A-2-6	456	0,143	-0,240	
318	Latossolo roxo	100	100	100	100	93	79	50	16	13	25,9	1,521		A-6	236	0,076	-0,398	
319	Podzólico vermelho escuro	100	100	100	99	96	77	51	27	17	21,6	1,548		A-7-5	199	0,011	-0,530	
320	Latossolo vermelho amarelo	100	100	100	98	94	71	58	27	17	23,4	1,483		A-7-5	168	0,086	-0,461	
321	Latossolo vermelho amarelo	100	100	99	97	90	64	49	20	11	21,0	1,573		A-5	220	0,005	-0,341	
322	Latossolo vermelho amarelo	100	100	100	99	89	55	49	13	8	22,6	1,675		A-7-5	168	0,175	-0,514	
323	Latossolo vermelho escuro	100	99	96	92	90	81	54	17	14	24,3	1,640		A-7-5	79	0,209	-0,763	
324	Podzólico vermelho amarelo	100	100	100	99	96	75	49	15	12	22,8	1,676		A-7-5	84	0,250	-0,673	
325	Latossolo vermelho escuro	100	100	100	100	93	54	45	12	9	25,2	1,530		A-7-5	356	0,106	-0,425	
326	Latossolo vermelho escuro	100	100	100	99	96	90	54	16	13	24,8	1,531		A-7-5	98	0,063	-0,625	
327	Podzólico vermelho escuro	100	100	100	100	98	73	48	17	17	19,0	1,750		A-7-5	284	0,003	-0,258	
328	Latossolo vermelho amarelo	100	100	99	98	93	70	64	24	18	24,6	1,640		A-7-5	46	0,067	-0,776	
329	Latossolo vermelho amarelo	100	100	100	98	86	57	53	17	11	23,7	1,630		A-7-5	277	0,077	-0,347	
330	Podzólico vermelho escuro	100	100	100	99	87	61	59	21	14	23,6	1,526		A-7-5	311	0,004	-0,318	
331	Latossolo vermelho amarelo	100	100	100	99	87	64	74	29	17	24,2	1,620		A-7-5	26	0,004	-0,978	
332	Latossolo vermelho amarelo	100	98	94	79	60	42	63	24	9	19,2	1,710		A-7-5	80	0,124	-0,607	
333	Latossolo vermelho amarelo	100	100	99	97	93	80	69	24	18	25,4	1,625		A-7-5	51	0,056	-0,678	
334	Podzólico vermelho amarelo	100	100	100	99	96	79	83	34	20	28,0	1,540		A-7-5	35	0,027	-0,794	
335	Latossolo ferrífero	100	100	100	99	93	75	52	15	12	21,1	1,840		A-7-5	130	0,156	-0,591	
336	Argila	100	100	100	98	80	66	69	30		23,2	1,537		A-7-6	79	0,124	-0,600	
337	Saibro arenoso	93	77	68	57	32	16	0	0	0	7,8	2,125		A-2-4	477	0,381	-0,266	
338	Saibro vermelho	100	99	96	89	63	28	0	0	0	12,8	1,935		A-2-4	238	0,367	-0,422	
339	Latossolo	100	100	100	100	92	77	69	38	20	25,6	1,548		A-7-5	292	0,266	-0,609	
340	Saibro micáceo	84	76	72	69	49	16	0	0	0	12,7	1,886		A-2-4	208	0,613	-0,625	
341	Podzólico	100	100	100	100	91	54	55	29	13	18,7	1,748		A-7-6	167	0,186	-0,653	
342	Latossolo	100	100	100	100	86	66	61	31	17	19,6	1,645		A-7-6	334	0,141	-0,512	
343	Latossolo	100	100	100	97	71	51	68	34	12	19,0	1,671		A-7-5	114	0,107	-0,603	

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria						Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mold} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)				
		#1"	#3/8"	4	10	40	200											
344	Latossolo	100	100	99	98	83	55	38	19	7	16,4	1,818			A-6	127	0,271	-0,687
345	Latossolo	100	100	100	99	91	79	94	56	20	29,7	1,470			A-7-5	50	0,041	-0,967
346	Argila arenosa	100	100	100	100	99	77	39	14		26,9	1,373	12		A-6	276	0,352	-0,363
347	Areia argilosa	100	100	100	100	97	65	39	13		25,8	1,304	13		A-7-6	203	0,133	-0,340
348	Argila arenosa	100	100	100	100	99	77	39	14		24,4	1,485	12		A-6	378	0,221	-0,395
349	Areia argilosa	100	100	100	100	97	65	39	13		25,3	1,400	13		A-7-6	169	0,048	-0,320
350	Argila arenosa	100	100	100	100	99	77	39	14		23,2	1,596	12		A-6	391	0,495	-0,888
351	Silte argiloso roxo	100	97	93	81	49	26	15	7		9,7	1,946			A-2-4	285	0,279	-0,293
352	Argila siltosa amarelada	100	100	100	95	70	48	61	39		17,0	1,779			A-7-6	211	0,086	-0,380
353	Areia siltosa	100	87	80	65	38	17	0	0		7,9	2,104			A-1-b	883	0,542	-0,174
354	Silte argiloso rosado	100	99	97	87	56	24	27	0		9,1	2,019			A-2-4	421	0,429	-0,206
355	Silte argiloso amarelado	100	100	99	97	79	61	46	18		18,1	1,755			A-7-6	243	0,082	-0,436
356	Silte argiloso avermelhado	100	97	93	85	60	14	0	0		8,4	2,013			A-2-4	477	0,532	-0,282
357	Silte arenoso rosado	100	97	93	81	40	26	39	9		8,4	2,028			A-2-4	296	0,261	-0,317
358	Silte arenoso amarelado	100	98	93	75	35	18	26	8		6,7	1,993			A-2-4	691	0,422	-0,141
359	Areia grossa branca	100	100	97	74	37	13	0	0		5,1	1,904			A-1-b	591	0,443	-0,202
360	Silte argiloso amarelado	100	99	97	85	60	38	0	0		11,8	1,813			A-4	178	0,304	-0,337
361	Silte argiloso rosado	100	99	96	86	60	43	39	17		15,5	1,842			A-6	133	0,336	-0,329
362	Silte argiloso marrom claro	100	99	99	97	81	62	59	33		19,3	1,733			A-7-6	163	0,044	-0,623
363	Silte argiloso avermelhado	100	100	99	96	77	50	47	24		13,0	1,712			A-7-6	588	0,170	-0,268
364	Argila siltosa marrom	100	100	99	96	73	50	63	39		15,6	1,857			A-7-6	267	0,236	-0,475
365	Argila siltosa avermelhada	100	100	99	97	67	55	58	30		15,6	1,835			A-7-6	183	0,037	-0,390
366	Argila arenosa vermelha	100	100	99	94	62	38	33	14		13,3	1,889			A-6	365	0,403	-0,229
367		100	99	96	90	57	31	30	11		11,9	1,842			A-2-6	348	0,450	-0,327
368		100	99	97	92	60	33	30	14		11,7	1,824			A-2-6	287	0,282	-0,341
369		100	99	97	91	58	29	29	15		12,4	1,866			A-2-6	325	0,436	-0,452
370		100	100	98	93	56	30	29	12		11,9	1,842			A-2-6	284	0,387	-0,478
371		100	100	100	97	68	38	34	14		13,0	1,862			A-6	174	0,195	-0,594
372		100	96	91	80	50	37	44	21		12,0	1,999			A-7-6	255	0,382	-0,436
373		100	100	100	97	71	36	35	18		12,4	1,867			A-7-6	312	0,229	-0,437
374		100	96	92	82	54	35	40	18		10,4	2,016			A-7-6	378	0,268	-0,503
375		100	94	90	80	55	34	46	27		11,5	2,002			A-2-7	314	0,377	-0,427
376	Argila amarela	100	100	100	99	90	74	78	47		25,9	1,519			A-7-5	361	0,070	-0,333
377	Argila arenosa vermelho claro c/ óxidos de ferro	100	92	85	78	66	48	40	20		16,7	1,875			A-6	405	0,326	-0,455
378	Silte areno-argiloso variegado	100	100	100	98	50	16	0	0		11,1	1,932			A-2-4	740	0,454	-0,083
379	Solo arenoso fino	100	100	100	99	68	19	0	0	0	9,6	2,009			A-2-4	591	0,437	-0,231
380	Solo argiloso fino	100	100	100	99	76	44	29	13	3	9,4	2,064			A-6	402	0,306	-0,363
381	Solo areno-siltoso	100	100	100	100	95	55	21	2	4	13,9	1,888			A-4	301	0,279	-0,544
382	Solo argiloso fino	100	100	99	97	94	77	44	21	13	18,3	1,791			A-7-6	61	0,126	-0,861
383	Solo arenoso fino	100	100	100	100	95	16	0	0	0	8,8	2,007			A-2-4	628	0,407	-0,207
384	Solo arenoso fino	100	100	100	99	94	48	21	6	3	10,2	2,062			A-4	331	0,400	-0,349
385	Solo argiloso fino	100	100	99	97	88	45	28	11	2	11,3	2,002			A-6	316	0,315	-0,540
386		100	100	100	99	52	23	32	13	0	9,5	2,081			A-2-6	581	0,482	-0,337

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria					Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3	
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)		IP (%)	h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)					Expansão (%)
		#1"	#3/8"	4	10	40	200											
387	Solo argiloso fino	100	100	99	97	89	55	32	14	9	13,5	1,931			A-6	153	0,229	-0,637
388	Podzólico vermelho	100	100	99	98	94	84	58	22	16	22,8	1,845			A-7-5	154	0,215	-0,657
389	Areia fina siltosa	100	100	100	100	77	30	0	0	0	13,5	1,796			A-2-4	778	0,500	-0,221
390	Solo arenoso fino	100	100	99	97	85	27	0	0	0	8,5	2,086			A-2-4	688	0,460	-0,215
391	Podzólico vermelho amarelo	100	100	100	99	91	68	32	8	7	18,1	1,758			A-4	229	0,189	-0,494
392	Podzólico vermelho amarelo	100	100	100	97	88	55	33	13	5	14,3	1,882			A-6	182	0,272	-0,583
393	Podzólico vermelho amarelo	100	100	99	94	81	49	26	9	3	12,7	1,953			A-4	141	0,237	-0,768
394	Podzólico vermelho amarelo	100	100	100	100	99	31	21	5	0	11,4	2,007			A-2-4	512	0,507	-0,353
395	Argila arenosa amarela	100	100	100	96	87	48	38	15	4	16,7	1,719	8	0,13	A-6	79	0,353	-0,991
396	Argila arenosa vermelha com pedregulho	100	100	100	71	57	31	0	0	0	10,5	1,936	17	0,37	A-2-4	446	0,489	-0,487
397	Cascalho laterítico argiloso amarelo	100	100	68	45	35	20	25	5	0	9,0	1,885	12	0,13	A-2-4	469	0,428	-0,778
398	Argila arenosa vermelha	100	100	100	97	90	45	24	5	2	11,0	1,830	12	0,08	A-5	529	0,532	-0,314
399	Cascalho laterítico vermelho	100	100	60	32	25	17	29	6	0	10,4	1,900	17	0,00	A-2-4	1.002	0,512	-0,153
400	Cascalho laterítico fino argiloso amarelo	100	100	79	59	51	39	34	7	1	12,7	1,868	13	0,00	A-4	249	0,253	-0,647
401	Argila arenosa vermelha com pedregulhos	100	100	100	90	84	60	49	19	10	15,7	1,659	14	0,13	A-7-6	185	0,225	-0,506
402	Argila arenosa vermelha com pedregulhos	100	100	100	75	60	41	34	9	2	13,1	1,945	11	0,17	A-4	244	0,333	-0,728
403	Cascalho laterítico argiloso cinza	100	75	45	34	29	16	24	5	0	9,1	1,878	9	0,05	A-1-a	769	0,539	-0,567
404	Cascalho laterítico argiloso cinza	100	100	74	64	59	32	27	8	0	7,6	1,750	22	0,00	A-2-4	1.026	0,361	-0,092
405	Argila arenosa cinza com pedregulhos	100	77	47	33	26	16	28	6	0	10,6	1,886	36	0,19	A-2-4	794	0,485	-0,466
406	Argila arenosa cinza	100	100	100	99	94	41	0	0	0	9,4	1,876	12	0,11	A-4	479	0,538	-0,544
407	Cascalho laterítico argiloso cinza	100	100	63	59	55	19	0	0	0	8,0	2,056	24	0,00	A-2-4	817	0,300	-0,252
408	Cascalho laterítico argiloso cinza	100	100	52	33	27	20	24	5	0	7,8	1,911	22	0,00	A-1-a	450	0,374	-0,714
409	Arenito pouco compacto cinza escuro	100	94	64	38	30	19	26	4	0	7,9	1,804	24	0,13	A-1-a	368	0,398	-0,639
410	Argila arenosa amarela	100	100	100	99	94	28	0	0	0	7,5	1,857	35	0,00	A-2-4	841	0,495	-0,157
411	Cascalho laterítico argiloso vermelho	100	100	81	62	47	24	31	11	0	11,5	1,799	8	0,14	A-2-6	629	0,535	-0,975
412	Cascalho laterítico argiloso amarelo	100	100	63	37	27	14	0	0	0	9,2	1,926	16	0,00	A-1-a	526	0,600	-0,948
413	Cascalho laterítico argiloso amarelo	100	100	82	72	47	27	34	9	0	17,3	1,675	13	0,12	A-2-4	101	0,241	-0,742
414	Cascalho laterítico argiloso amarelo	100	100	70	51	40	15	30	10	0	11,2	1,929	10	0,00	A-2-4	397	0,394	-0,736
415	Cascalho laterítico argiloso vermelho	100	89	60	31	20	16	41	11	0	11,2	1,818	30	0,00	A-2-7	204	0,187	-0,741
416	Cascalho laterítico argiloso cinza	100	97	74	52	41	25	33	11	0	11,0	1,909	17	0,00	A-2-6	458	0,433	-0,649
417	Argila arenosa amarela com pedregulhos	100	100	98	95	89	39	36	8	1	10,6	1,860	14	0,00	A-4	418	0,299	-0,373
418	Cascalho laterítico argiloso amarelo	100	85	61	45	40	29	32	9	0	12,4	1,602	21	0,00	A-2-4	298	0,167	-0,560
419	Cascalho laterítico amarelo	100	100	70	53	44	18	34	9	0	9,7	2,136	22	0,00	A-2-4	569	0,340	-0,332
420	Cascalho laterítico argiloso amarelo	98	67	34	22	18	11	25	6	0	10,4	1,727	26	0,00	A-2-4	729	0,390	-0,392
421	Cascalho laterítico arenoso cinza	100	85	58	42	30	18	31	8	0	12,0	1,855	22	0,00	A-2-4	1.093	0,553	-0,133
422	Argila arenosa amarela com pedregulhos	100	100	100	99	91	64	40	13	7	19,7	1,512	7	0,30	A-7-5	103	0,190	-0,851
423	Cascalho laterítico argiloso cinza	100	100	86	59	49	28	33	7	0	9,1	1,925	13	0,00	A-2-4	659	0,435	-0,269
424	Argila arenosa amarela com pedregulhos	100	100	94	86	74	41	34	10	1	13,8	1,780	15	0,00	A-6	386	0,372	-0,382
425	Cascalho laterítico argiloso vermelho	100	89	71	56	47	20	27	5	0	9,5	1,840	15	0,00	A-1-b	719	0,440	-0,353
426	Argila arenosa amarela	100	100	100	97	84	38	31	10	0	12,9	1,792	11	0,04	A-4	248	0,325	-0,693
427	Argila arenosa cinza claro	100	100	99	98	90	49	31	9	3	11,9	1,627	11	0,00	A-4	298	0,243	-0,429
428	Cascalho laterítico argiloso cinza	100	100	100	100	89	44	0	0	0	8,1	1,608	11	0,09	A-4	219	0,201	-0,811
429	Argila arenosa amarela	100	100	100	96	89	34	0	0	0	9,8	1,911	18	0,00	A-2-4	679	0,521	-0,357

Quadro 5.1 - Base de Dados (Continuação)

N.º da Amostra	CLASSIFICAÇÃO VISUAL - TÁCTIL - GENÉTICA	Granulometria						Índices Físicos		IG	Compactação		CBR		T.R.B	K1 (MPa)	K2	k3
			9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mold} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)				
		#1"	#3/8"	4	10	40	200											
430	Cascalho laterítico argiloso amarelo	100	88	74	57	42	27	23	7	0	11,2	1,902	18	0,00	A-2-4	718	0,467	-0,231
431	Areia fina siltosa cinza claro	100	100	100	89	81	28	0	0	0	7,8	1,890	18	0,00	A-2-4	646	0,507	-0,280
432	Cascalho laterítico argiloso cinza	100	88	57	38	32	13	0	0	0	8,1	1,940	16	0,00	A-1-b	681	0,392	-0,485
433	Cascalho laterítico argiloso amarelo	95	79	67	55	45	24	34	9	0	11,6	1,768	26	0,00	A-2-4	802	0,393	-0,179
434	Cascalho laterítico arenoso amarelo	100	71	46	41	36	12	0	0	0	8,8	1,950	15	0,00	A-1-b	773	0,425	-0,443
435	Cascalho laterítico arenoso cinza	100	88	74	60	51	25	25	8	0	11,8	1,681	26	0,00	A-2-4	350	0,280	-0,689
436	Cascalho laterítico argiloso cinza escuro	95	75	64	48	36	20	0	0	0	10,4	1,736	16	0,00	A-1-b	784	0,391	-0,302
437	Cascalho laterítico argiloso amarelo	100	86	67	55	45	25	22	4	0	11,8	1,661	28	0,00	A-1-b	545	0,387	-0,510
438	Cascalho arenoso cinza	100	91	59	41	38	11	0	0	0	8,5	2,090	112	0,00	A-1-b	1.736	0,599	-0,177
439	Cascalho laterítico	100	92	69	46	34	24	30	9	0	13,4	1,991	77	0,00	A-2-4	570	0,554	-0,680
440	Cascalho laterítico argiloso amarelo	100	94	75	53	45	28	40	11	0	12,8	1,998	42	0,00	A-2-7	598	0,403	-0,378
441	Cascalho laterítico	100	94	75	57	52	37	29	6	0	9,3	2,114	40	0,00	A-4	617	0,437	-0,357
442	Cascalho cinza arenoso médio	100	93	69	46	35	15	0	0	0	9,1	2,121	114	0,04	A-1-b	1.373	0,638	-0,323
443	Cascalho laterítico cinza arenoso fino	100	96	75	52	43	25	27	6	0	11,2	1,931	28	0,00	A-2-4	701	0,412	-0,286
444	Cascalho laterítico	100	92	60	39	31	24	30	7	0	13,2	2,051	37	0,00	A-2-4	372	0,297	-0,453
445	Cascalho cinza claro arenoso médio	97	69	49	40	31	14	26	6	0	9,6	1,862	91	0,00	A-2-4	303	0,212	-0,155
446	Cascalho laterítico	100	94	74	54	41	16	0	0	0	9,9	2,041	52	0,00	A-1-b	1.420	0,633	-0,187
447	Cascalho laterítico arenoso amarelo	100	85	64	48	40	19	24	6	0	13,6	1,956	50	0,00	A-1-b	876	0,677	-0,388
448	Cascalho laterítico arenoso cinza médio	100	84	60	51	44	15	0	0	0	8,9	2,093	88	0,00	A-1-b	896	0,517	-0,726
449	Cascalho laterítico arenoso amarelo médio	100	59	36	27	23	13	24	3	0	12,6	2,020	102	0,00	A-1-a	693	0,509	-0,196
450	Cascalho laterítico	100	74	52	43	34	15	23	4	0	9,8	2,105	85	0,00	A-1-b	1.075	0,451	-0,235
451	Cascalho laterítico	98	75	55	44	35	18	0	0	0	13,1	1,989	45	0,00	A-1-b	397	0,330	-0,081
452	Cascalho laterítico	100	85	67	55	37	24	25	6	0	13,7	1,906	33	0,00	A-1-b	600	0,398	-0,228
453	Cascalho laterítico	100	97	87	74	48	24	28	5	0	12,1	1,978	44	0,00	A-1-b	514	0,433	-0,636
454	Areia argilosa amarela	100	98	96	92	36	22	47	14	0	16,3	1,799			A-2-7	176	0,266	-0,726
455	Argila arenosa amarela	100	100	100	98	62	47	47	17	5	18,3	1,753			A-7-5	72	0,153	-0,884
456	Areia argilosa amarela	100	100	100	98	45	29	49	15	1	19,0	1,690			A-2-7	570	0,515	-0,553
457	Argila arenosa amarela com pedregulhos	100	99	92	69	56	40	46	11	1	21,6	1,627			A-7-5	264	0,204	-0,536
458	Argila arenosa amarela	100	100	100	97	66	44	40	11	2	19,6	1,655			A-6	269	0,287	-0,884
459	Argila arenosa amarela	100	100	99	97	73	49	45	13	4	21,1	1,680			A-7-5	78	0,170	-0,690
460	Argila arenosa amarela	100	100	100	99	76	45	39	11	2	19,7	1,685			A-6	198	0,249	-0,679
461	Argila arenosa amarela	100	100	100	99	70	47	40	11	3	19,5	1,674			A-6	698	0,628	-0,751
462	Argila arenosa amarela com pedregulhos	100	100	97	87	68	49	39	12	4	16,2	1,778			A-6	233	0,249	-0,627

Quadro 5.2 - Matriz de Correlação - Constantes Ki

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>LL</i>	<i>IP</i>	<i>IG</i>	<i>Hmold</i>	<i>Densmold</i>	<i>CBR</i>	<i>Exp</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1															
<i>pen3/8</i>	0,532745	1														
<i>pen4</i>	0,361875	0,891533	1													
<i>pen10</i>	0,294024	0,783347	0,954892	1												N = 336
<i>pen40</i>	0,271033	0,669477	0,769635	0,852654	1											
<i>pen200</i>	0,238951	0,578221	0,643781	0,699378	0,84355	1										
<i>LL</i>	0,245824	0,444348	0,412947	0,418776	0,531632	0,792123	1									
<i>IP</i>	0,224397	0,403106	0,417449	0,464879	0,546891	0,762336	0,890044	1								
<i>IG</i>	0,17176	0,373181	0,452226	0,512108	0,594186	0,823994	0,775308	0,888514	1							
<i>Hmold</i>	0,335379	0,542035	0,541118	0,565328	0,653045	0,828743	0,753971	0,729145	0,737873	1						
<i>Densmold</i>	-0,346946	-0,607028	-0,607804	-0,625493	-0,645576	-0,741607	-0,636061	-0,614507	-0,631365	-0,817169	1					
<i>CBR</i>	-0,376341	-0,773738	-0,729683	-0,689543	-0,630455	-0,613383	-0,500969	-0,441791	-0,392477	-0,585344	0,71316	1				
<i>Exp</i>	0,098085	0,217412	0,257206	0,280857	0,384058	0,443069	0,27713	0,25038	0,344708	0,343458	-0,276973	-0,260981	1			
<i>K1</i>	-0,237425	-0,46009	-0,505669	-0,483267	-0,413005	-0,570043	-0,50843	-0,449701	-0,431928	-0,58602	0,581333	0,608134	-0,264721	1		
<i>K2</i>	-0,18172	-0,305759	-0,370427	-0,422113	-0,453676	-0,61178	-0,605733	-0,599734	-0,617549	-0,522084	0,512939	0,395902	-0,116129	0,603668	1	
<i>K3</i>	-0,214245	-0,347126	-0,239703	-0,210487	-0,286233	-0,398307	-0,408025	-0,35684	-0,269692	-0,415787	0,453371	0,40857	-0,102916	0,594969	0,221919	1

Quadro 5.3 - Matriz de Correlação - Módulo de Resiliência e Deformação Específica Resiliente

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>LL</i>	<i>IP</i>	<i>IG</i>	<i>Hmold</i>	<i>Densmold</i>	<i>CBR</i>	<i>Exp</i>	<i>s3</i>	<i>sd</i>	<i>mr</i>	<i>def</i>
<i>pen1</i>	1																
<i>pen3/8</i>	0,532745	1															
<i>pen4</i>	0,361875	0,891533	1														
<i>pen10</i>	0,294024	0,783347	0,954892	1													N = 6.048
<i>pen40</i>	0,271033	0,669477	0,769635	0,852654	1												
<i>pen200</i>	0,238951	0,578221	0,643781	0,699378	0,84355	1											
<i>LL</i>	0,245824	0,444348	0,412947	0,418776	0,531632	0,792123	1										
<i>IP</i>	0,224397	0,403106	0,417449	0,464879	0,546891	0,762336	0,890044	1									
<i>IG</i>	0,17176	0,373181	0,452226	0,512108	0,594186	0,823994	0,775308	0,888514	1								
<i>Hmold</i>	0,335466	0,542116	0,541062	0,565584	0,653687	0,829857	0,752915	0,728059	0,737805	1							
<i>Densmold</i>	-0,344833	-0,604187	-0,606668	-0,625827	-0,644624	-0,739975	-0,630568	-0,610575	-0,63047	-0,814708	1						
<i>CBR</i>	-0,376341	-0,773738	-0,729683	-0,689543	-0,630455	-0,613383	-0,500969	-0,441791	-0,392477	-0,585474	0,711393	1					
<i>Exp</i>	0,098085	0,217412	0,257206	0,280857	0,384058	0,443069	0,27713	0,25038	0,344708	0,343408	-0,276844	-0,260981	1				
<i>s3</i>	2,16E-17	1,07E-17	1,8E-17	2,73E-17	-1,34E-17	-2,15E-18	-2,31E-17	4,91E-17	9,93E-19	-9,63E-18	1,4E-18	7,99E-18	1,3E-17	1			
<i>sd</i>	9,98E-19	2,33E-17	9,05E-18	-2,12E-19	2,51E-18	2,92E-18	2,74E-17	-1,24E-17	-2,69E-17	7,29E-19	1,04E-17	-1,38E-19	-6,98E-18	0,775193	1		
<i>mr</i>	0,064875	-0,014223	-0,149861	-0,139905	0,008184	0,001024	0,055761	0,056028	0,003639	-0,06405	-0,005354	0,028161	-0,14586	-0,029267	-0,168017	1	
<i>def</i>	0,032168	0,109505	0,154026	0,150327	0,120036	0,13418	0,069681	0,06314	0,083896	0,170136	-0,132704	-0,129244	0,198422	0,532791	0,766186	-0,41343	1

5.2 Escolha das variáveis

A escolha das variáveis envolvidas no processo de *Data Mining* não é uma tarefa trivial, podendo por si só definir o sucesso ou o insucesso da tarefa.

No caso estudado neste trabalho, a escolha das variáveis independentes (*inputs*) foi feita considerando-se dois aspectos principais, quais sejam, a facilidade de obtenção e a confiabilidade de seus valores.

No que respeita à obtenção dos valores dos *inputs* não há qualquer dificuldade, tendo em vista que os mesmos se constituem de parâmetros geotécnicos tradicionais, que são determinados de forma compulsória nos estudos geotécnicos desenvolvidos para projetos de pavimentação.

Quanto à confiabilidade dos valores desses parâmetros, existem contudo alguns problemas que não podem ser ignorados. Isto decorre das já bastante discutidas baixas repetitividade e reprodutividade constatadas nos ensaios tradicionais para solos empregados em pavimentação, especialmente no que diz respeito aos Limites de Atterberg e ao ensaio CBR.

Segundo Waeny (1980), *apud* Reis e Fortes (2004), repetitividade é “o valor máximo esperado para a diferença entre pelo menos dois resultados obtidos com a mesma amostra e o mesmo método, sob as mesmas condições”. Pode-se exemplificar a manutenção das mesmas condições como a manutenção do mesmo operador, mesmo equipamento e mesmas condições ambientais para as repetições.

A reprodutividade, por outro lado, é o “valor máximo esperado para a diferença entre pelo menos dois resultados obtidos com a mesma amostra e o mesmo método, sob condições diferentes”. Assim, é o caso de determinação (um mesmo ensaio) feita por laboratórios diferentes numa mesma amostra.

Neste trabalho, os ensaios tradicionais, que constituem os *inputs* da análise, foram feitos em diversos laboratórios, enquanto que os ensaios triaxiais a cargas repetidas, dos quais resultam as variáveis independentes (*outputs*), foram em sua totalidade realizados no Laboratório de Geotecnia da COPPE/UFRJ.

Para avaliar a hipótese de discrepância entre os *inputs* e os *outputs* definidos, foi feita uma análise estatística da variabilidade dos seus valores, utilizando as amostras de números 259 a 276. Estas amostras, oriundas do subleito da Rodovia BR-116, em um trecho próximo a Juquitiba/SP, foram selecionadas tendo vista que os

ensaios destinados à obtenção dos valores dos *inputs* foram realizados pela EPT Engenharia, que tem laboratório certificado e segue rigorosos padrões de controle de qualidade o que, ainda que consideradas as limitações de cada procedimento de ensaio, confere confiabilidade aos resultados. A análise dos coeficientes de variação das constantes K_i do modelo composto das dezoito amostras permitiu que fosse considerado um modelo de resiliência único para todo o material, demonstrando sua homogeneidade em termos de comportamento resiliente. A partir da constatação desta homogeneidade, foi efetuada uma análise em termos de Média, Desvio Padrão e Coeficiente de Variação (CV) dos *inputs* e *outputs*, que retrata convenientemente os problemas de discrepância dos ensaios tradicionais em relação ao comportamento resiliente dos solos. Esta análise está resumida nos Quadros 5.4 e 5.5, apresentados a seguir.

O Quadro 5.4 resume a análise dos *inputs*. Consta-se pelos valores do Coeficiente de Variação que, para os ensaios analisados, a dispersão dos valores de IP, IG, CBR e Expansão é extremamente elevada, enquanto parâmetros para os quais os ensaios permitem uma confiabilidade muito maior, a exemplo da granulometria e das umidade e densidade de moldagem, os coeficientes de variação são muito inferiores, em alguns casos ínfimos.

A análise feita com relação aos *outputs*, no caso apenas o valor de M_R , é apresentada no Quadro 5.5. Esta análise foi feita considerando-se os valores de M_R obtidos para cada par de tensões, constatando-se que, apesar de uma variabilidade relativamente elevada nos quatro primeiros pares, de modo geral o ensaio apresenta dispersão muito inferior àquelas relativas aos Limites de Atterberg, CBR e Expansão.

Conclusivamente, as amostras analisadas apresentam comportamento resiliente similar, mas algumas propriedades geotécnicas, que constituem os *inputs*, com valores bastante dispersos. Nestas condições, as dificuldades das tarefas de agrupamento e classificação aumentam substancialmente, além de prejudicarem de modo significativo a capacidade de predição e generalização das RNAs, ocasionando erros de predição muito elevados, podendo inclusive inviabilizar o processo. A princípio, a solução adotada para este problema foi a redução do número de variáveis independentes, eliminando-se dos *inputs* aqueles parâmetros que sabidamente apresentam grande dispersão, quais sejam, os Limites de Atterberg e os ensaios de CBR e Expansão. Contudo, foram feitos testes de agrupamento e classificação, além de diversas arquiteturas de redes neurais, nos quais foram incluídos todos os parâmetros tradicionais.

Quadro 5.4 - Análise Estatística das Variáveis Independentes (inputs)

AMOSTRA	VARIÁVEIS INDEPENDENTES												
	#1"	#3/8"	#4	#10	#40	#200	LL	IG	IP	HMOLD	DENSMOLD	CBR	EXP
259	100	100	100	96	86	54	33	6	14	14,8	1,755	7	2,4
260	100	100	100	99	94	56	36	6	16	16,1	1,739	8	2
261	100	100	100	97	90	52	33	4	12	16,9	1,708	6	2,15
262	100	100	100	99	97	51	34	3	10	17,3	1,651	12	1,1
263	100	100	100	98	91	55	39	8	19	15,2	1,658	3	5,9
264	100	100	100	98	92	60	35	5	10	15,2	1,756	4	4
265	100	100	100	98	89	49	32	4	14	16,7	1,747	9	2,2
266	100	100	100	97	91	55	36	6	16	17,3	1,783	15	0,8
267	100	100	100	98	91	51	0	3	0	18,4	1,692	10	0,88
268	100	100	100	97	88	52	30	3	6	13,2	1,641	3	4,7
269	100	100	100	97	91	61	38	8	17	19,2	1,674	2	4
270	100	100	100	99	91	56	28	4	6	16,2	1,732	7	2,4
271	100	100	100	96	88	52	27	4	11	12,7	1,769	4	4,2
272	100	100	100	99	95	62	36	5	10	17,3	1,682	4	2,9
273	100	100	100	98	95	63	34	7	14	19,3	1,701	5	2,5
274	100	100	100	99	93	55	35	4	10	17,5	1,734	5	3,1
275	100	100	100	96	87	50	31	3	9	14,2	1,758	7	2,6
276	100	100	100	96	87	45	28	2	11	16,2	1,785	11	0,44
Média	100	100	100	97,6	90,9	54,4	31,4	4,7	11,4	16,3	1,720	6,8	2,68
Desvio	0	0	0	1,1	3,1	4,8	8,5	1,8	4,6	1,9	0,046	3,5	1,45
CV	0	0	0	0,01	0,03	0,09	0,27	0,38	0,40	0,11	0,03	0,52	0,54

Quadro 5.5 - Análise Estatística da Variável Dependente (outputs)

AMOSTRA		259	260	261	262	263	264	265	266	267	268	269	270	271	272	273	274	275	276	Média	Desvio Padrão	CV
σ_3 (MPa)	σ_d (MPa)	VARIÁVEL DEPENDENTE - MÓDULO DE RESILIÊNCIA CALCULADO (MPa)																				
0,021	0,021	186	214	266	123	177	161	159	313	83	192	134	140	217	153	108	205	230	142	178	57	0,32
0,021	0,041	139	163	198	100	132	125	125	199	69	145	100	112	161	112	95	149	190	113	135	37	0,27
0,021	0,062	116	137	165	88	110	106	107	151	61	122	83	97	134	92	88	123	169	98	114	29	0,26
0,034	0,034	181	203	240	132	168	157	165	279	92	181	127	146	211	153	117	199	234	156	174	47	0,27
0,034	0,069	133	152	176	106	123	120	127	173	75	134	93	115	154	109	102	142	191	123	130	30	0,23
0,034	0,103	112	129	148	94	104	103	110	132	67	113	78	101	129	91	94	118	170	107	111	25	0,22
0,051	0,051	177	194	220	140	161	153	170	254	100	172	122	152	206	152	124	194	237	169	172	40	0,23
0,051	0,103	131	145	162	113	119	117	132	158	82	127	90	120	150	109	109	139	194	133	129	27	0,21
0,051	0,155	110	123	135	99	99	100	114	120	73	107	75	104	125	90	100	115	172	116	110	22	0,20
0,069	0,069	175	187	207	146	156	151	174	236	106	165	119	156	202	152	131	190	240	179	171	36	0,21
0,069	0,137	130	141	153	118	116	116	135	149	87	124	88	124	149	110	114	138	197	142	129	25	0,20
0,069	0,206	109	119	128	104	97	99	117	113	78	104	74	108	124	91	105	114	175	124	110	22	0,20
0,103	0,103	171	179	190	155	150	147	179	215	115	157	114	161	197	151	139	186	243	194	169	33	0,19
0,103	0,206	127	135	140	125	111	113	139	135	94	117	84	128	145	109	121	134	199	153	128	25	0,19
0,103	0,309	106	114	117	111	93	97	120	103	84	99	71	111	121	90	112	111	178	134	109	23	0,21
0,137	0,137	169	173	179	162	146	145	183	201	122	151	111	165	194	151	145	182	246	205	168	32	0,19
0,137	0,275	125	130	132	130	107	111	142	126	100	113	82	131	142	109	127	131	201	162	128	26	0,20
0,137	0,412	105	110	110	115	90	95	123	96	89	95	68	114	119	90	117	108	179	141	109	24	0,22

5.3 Amostras não consideradas na base de dados

Durante o processo de seleção das amostras que comporiam a base de dados, um dos procedimentos iniciais de pré-processamento das atividades de *Data Mining*, observou-se a ocorrência de um comportamento resiliente diferenciado em uma parcela significativa das mesmas. Este comportamento diferenciado caracteriza-se pela elevação do valor de M_R à medida que a tensão desvio é aumentada. Em um total de 526 amostras, 114 (22%) apresentaram algum tipo de anomalia, em maior ou menor grau.

Um exemplo deste comportamento diferenciado, referente à amostra de registro S400/02, é apresentado na Figura 5.1, inserida a seguir. Os pares de tensões indicados no gráfico são aqueles constantes da Tabela 2.1.

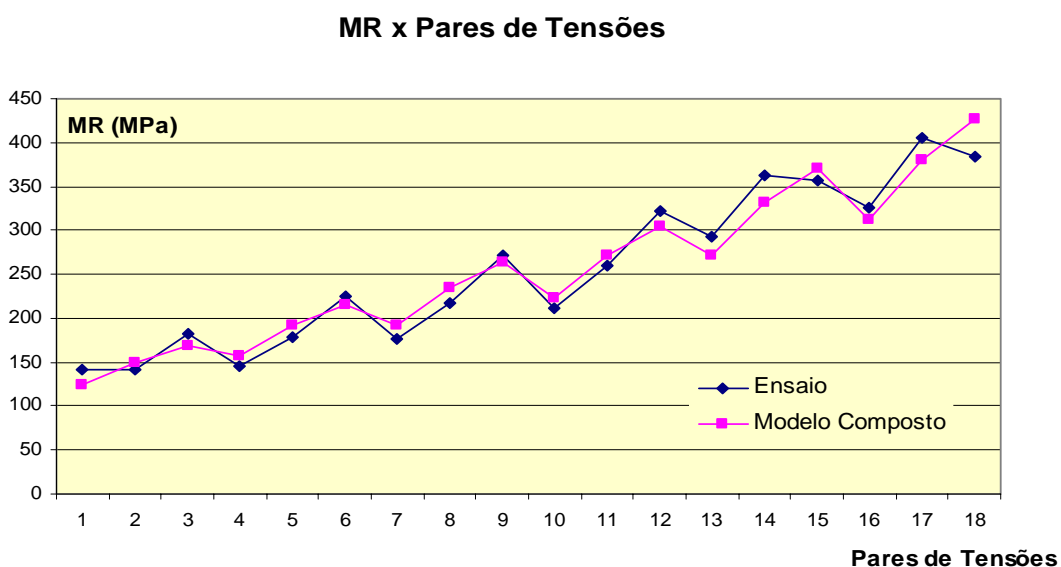


Figura 5.1 – MR × Pares de Tensões – Amostra S400/02

As amostras que apresentaram este comportamento, em um total de 63, foram removidas da base de dados.

Outras amostras que apresentaram resultados tendendo ao comportamento diferenciado, mas que quando efetuada a modelagem por regressão resultaram em valores de K_3 negativos, foram mantidas na base de dados, a exemplo da amostra n^o. 378, apresentada na Figura 5.2 inserida seguir.




Figura 5.2 – MR × Pares de Tensões – Amostra 376

A discussão desse problema não é objeto deste trabalho, em consequência do que não foram avaliadas as causas do mesmo. Contudo, considerando o elevado percentual de amostras que apresentou alguma anomalia, seria interessante futuramente que se procedesse a investigações objetivando determinar os fatores que as originam.

5.4 Histogramas das variáveis

A Figura 5.3, inserida a seguir, apresenta os histogramas das variáveis consideradas na análise, podendo ser considerados uma boa representação da base de dados utilizada.

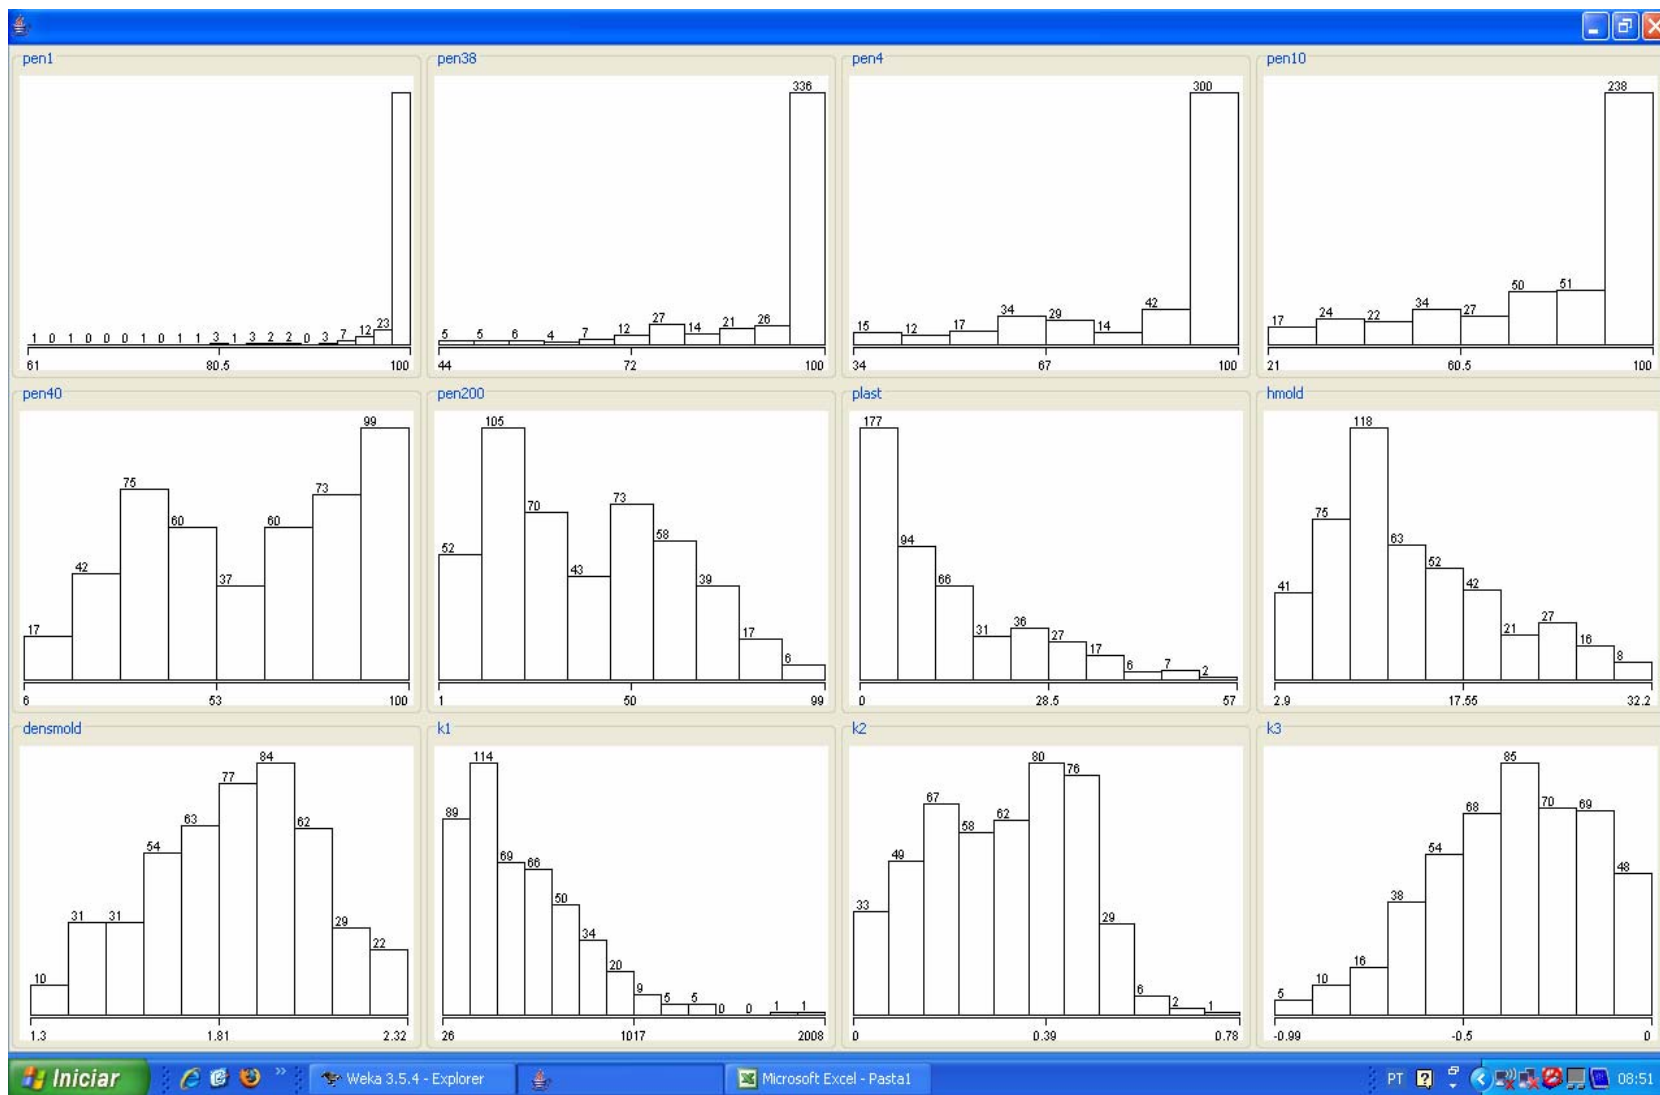


Figura 5.3 – Histogramas das variáveis do banco de dados utilizado neste estudo

Capítulo 6

Agrupamento em Famílias de Solos Quanto à Resiliência

Neste capítulo são descritos os procedimentos de *Data Mining* utilizados para agrupamento das amostras em famílias de solos que apresentam comportamento semelhante quanto ao aspecto de resiliência, bem como os resultados obtidos.

Para determinação dos grupos foram utilizados dois algoritmos, sendo um probabilístico, o *EM algorithm*, e um baseado em medidas de dissimilaridade (ou similaridade) entre os elementos de um conjunto, o *K-means*. Essas medidas fornecem valores numéricos que exprimem a “distância” entre dois objetos, sendo maior a similaridade quanto menor esta distância. Além destes algoritmos, foi efetuado um agrupamento por especialista, procedimento possível em atividades de mineração de dados desde que sejam utilizadas bases de dados de tamanho reduzido.

Para utilização dos algoritmos citados na determinação dos grupos existentes na base de dados, as variáveis utilizadas (atributos) foram selecionadas de duas formas. Inicialmente foram utilizados os parâmetros geotécnicos tradicionais e as constantes K_i do modelo composto (Procedimento 1). Em um segundo agrupamento, foram utilizadas somente as constantes K_i do modelo composto (Procedimento 2). Este segundo agrupamento foi feito considerando que as constantes do modelo retratam de fato o comportamento resiliente dos solos, independentemente dos seus parâmetros geotécnicos.

O resumo dos resultados obtidos por todos os procedimentos é apresentado no item 6.2.4 – Resumo e análise dos resultados.

6.1 Aplicação do algoritmo EM

Este algoritmo foi utilizado previamente ao *K-means* tendo em vista que o mesmo define o número de grupos sem intervenção externa, ou seja, é um procedimento não supervisionado, não sendo necessário indicar qual o número de grupos a serem obtidos na base de dados. Isto torna o agrupamento obtido isento de conceitos prévios do usuário.

Utilizando-se o Procedimento 1, o algoritmo definiu quatro grupos. A análise dos valores médios das constantes K_i do modelo composto de cada um dos grupos gerados indica a existência de um grupo de comportamento fortemente coesivo, o Grupo 2, outro de comportamento marcadamente granular, o Grupo 1, e dois grupos de comportamento intermediário entre o coesivo e o granular, os Grupos 0 e 3, sendo o Grupo 0 constituído de solos mais finos que os do Grupo 3.

Quando o agrupamento é feito segundo o Procedimento 2, utilizando-se apenas os valores de K_i , o algoritmo gera cinco grupos. Nesta condição observa-se a definição de dois grupos de comportamento coesivo, os Grupos 1 e 4, dois grupos com tendências a comportamento intermediário, o Grupo 0 mais coesivo e o Grupo 2 mais granular, e um grupo com comportamento granular, o Grupo 3.

As características obtidas dos diversos grupos quando utilizado o Procedimento 1 são apresentadas no Quadro 6.1, e quando utilizado o Procedimento 2 no Quadro 6.2, inseridos a seguir.

No intuito de exemplificar as saídas geradas pelo algoritmo *EM*, utilizando o Procedimento 2, são inseridas a seguir algumas janelas de visualização dos grupos disponíveis no sistema *Weka*, compreendendo as Figuras de 6.1 a 6.13, nas quais estão destacadas em cinza as áreas nas quais ocorre superposição de amostras dos cinco grupos obtidos.

Estas janelas exemplificam com bastante clareza as dificuldades em correlacionar os parâmetros geotécnicos tradicionais com o comportamento resiliente dos solos, com base em limites fixos. Observa-se, nas áreas destacadas em cinza, que há superposição de valores destes parâmetros em todos os grupos definidos. Isto pode explicar, em parte, porque até agora não se teve sucesso nas tentativas para obtenção de correlações representativas, haja vista que estas tentativas resultaram sempre em limites determinísticos para separação dos solos granulares e coesivos.

6.2 Aplicação do algoritmo *K-means*

O algoritmo *K-means* tem como principal deficiência a necessidade de definir previamente o número de grupos desejado. Contudo, devido ao seu rápido processamento para bases de dados reduzidas, isso não chega a dificultar sua utilização. Neste trabalho foram feitas diversas experimentações com este algoritmo, alterando-se variáveis e número de grupos desejado. São apresentados a seguir os

resultados obtidos considerando-se o Procedimento 1 para quatro grupos, e o Procedimento 2 para quatro e cinco grupos.

Assim como no algoritmo *EM* quando é utilizado o Procedimento 1, no algoritmo *K-means* a análise dos valores médios das constantes K_i do modelo composto de cada um dos grupos gerados indica a existência de um grupo de comportamento fortemente coesivo, o Grupo 2, outro de comportamento tendendo a granular, o Grupo 1, e dois grupos de comportamento intermediário entre o coesivo e o granular, os Grupos 0 e 3, sendo o Grupo 0 constituído de solos mais finos que os do Grupo 3.

Quando o agrupamento é feito segundo o Procedimento 2, utilizando-se apenas os valores de K_i e indicando-se ao algoritmo a formação de quatro grupos, observa-se a definição de um grupo de comportamento coesivo, o Grupo 0, dois grupos com tendências a comportamento intermediário, o Grupo 1 mais coesivo e o Grupo 2 mais granular, e um grupo com comportamento granular, o Grupo 3.

Quando o agrupamento é feito segundo o Procedimento 2, indicando-se ao algoritmo a formação de cinco grupos, observa-se a definição de dois grupos de comportamento coesivo, os Grupos 1 e 4, sendo o Grupo 1 constituído de solos mais finos, dois grupos com tendências a comportamento intermediário, o Grupo 0 e o Grupo 2, com diferenças mínimas entre eles, e um grupo com comportamento granular, o Grupo 3.

Os resultados são resumidos nos Quadros 6.3 a 6.5, inseridos a seguir.

6.3 Aplicação do agrupamento por especialista

O agrupamento por especialista foi feito em três fases, considerando a existência dos grupos conforme descrito a seguir.

Dois grupos: Refere-se ao agrupamento clássico de solos quanto ao seu comportamento resiliente, sendo um grupo coesivo e um grupo granular. Para definição destes grupos foram considerados os valores absolutos das constantes K_2 e K_3 do modelo composto, ou seja, se K_2 é maior que K_3 , o solo é alocado no grupo dos granulares, se não, é alocado no grupo dos coesivos.

Três grupos: Para definição dos grupos quando a base de dados é segmentada em três famílias de solos quanto ao seu comportamento resiliente, foram adotados os seguintes critérios:

Se $K_2 \geq 2K_3$ – solo de comportamento granular

Se $K_3 \geq 2K_2$ – solo de comportamento coesivo

Se $K_2 / K_3 < 2$ – solo de comportamento intermediário

Quatro grupos: Neste caso o agrupamento foi obtido mediante uma subdivisão do grupo de solos de comportamento intermediário definido na segmentação em três grupos, mantidos os critérios para os grupos granular e coesivo. Para esta subdivisão considerou-se o critério definido a seguir, aplicado somente ao grupo de comportamento intermediário definido acima.

Se $K_2 > K_3$ – solo de comportamento intergranular

Se $K_3 > K_2$ – solo de comportamento intercoesivo

Os resultados obtidos considerando-se o Procedimento 2 para todos os agrupamentos são resumidos nos Quadros 6.6 a 6.8, inseridos a seguir.

Quadro 6.1 - Algoritmo EM - Procedimento 1												
Atributo	Grupo 0			Grupo 1			Grupo 2			Grupo 3		
	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.
Pen 1"	100,0	4,0	0,04	95,4	7,7	0,08	100,0	0,0	0,00	99,3	1,4	0,01
Pen 3/8"	99,2	1,0	0,01	74,7	12,8	0,17	99,9	0,2	0,01	94,8	4,5	0,05
Pen. 4	97,7	2,6	0,03	57,9	12,7	0,22	99,6	0,6	0,01	85,9	8,3	0,10
Pen.10	91,5	7,6	0,08	45,3	14,5	0,32	97,9	1,6	0,02	72,2	10,7	0,15
Pen. 40	67,5	17,3	0,26	29,1	10,9	0,37	86,7	9,3	0,11	43,5	10,3	0,24
Pen. 200	35,6	15,5	0,44	13,0	6,9	0,53	63,0	12,9	0,20	22,8	10,5	0,46
IP	10,0	9,7	0,97	2,3	3,4	1,48	23,3	11,9	0,51	4,6	6,6	1,43
Hmold	11,8	3,8	0,32	7,6	2,8	0,37	20,1	5,3	0,26	9,6	2,5	0,26
Densmold	1,9	0,1	0,05	2,1	0,2	0,10	1,6	0,2	0,13	1,9	0,1	0,05
K ₁	478	283	0,59	760	312	0,41	195	105	0,54	476	176	0,37
K ₂	0,36	0,12	0,33	0,42	0,11	0,26	0,17	0,11	0,65	0,37	0,10	0,27
K ₃	-0,34	0,20	0,59	-0,24	0,19	0,79	-0,49	0,17	0,35	-0,33	0,20	0,61
N ^o . de Amostras	61			93			199			110		

Quadro 6.2 - Algoritmo EM - Procedimento 2															
Atributo	Grupo 0			Grupo 1			Grupo 2			Grupo 3			Grupo 4		
	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.
Pen 1"	98,6	4,3	0,04	100,0	0,0	0,00	98,4	4,2	0,04	96,8	7,5	0,08	99,8	0,8	0,01
Pen 3/8"	92,0	9,7	0,11	99,7	0,4	0,00	91,0	12,5	0,14	82,0	16,7	0,20	98,2	5,2	0,05
Pen. 4	76,8	17,9	0,23	98,8	3,3	0,03	83,8	17,8	0,21	71,0	22,3	0,31	95,8	9,1	0,10
Pen.10	64,2	22,4	0,35	96,3	5,8	0,06	73,8	21,2	0,29	61,4	26,2	0,43	90,9	13,4	0,15
Pen. 40	46,8	20,9	0,45	84,5	11,9	0,14	49,6	22,9	0,46	41,9	24,5	0,59	73,6	19,5	0,26
Pen. 200	25,1	14,2	0,56	65,6	14,9	0,23	24,1	16,3	0,68	16,7	13,6	0,82	49,8	17,3	0,35
IP	4,8	4,9	1,01	28,8	10,5	0,37	4,7	7,2	1,52	3,8	8,0	2,12	15,9	10,8	0,68
Hmold	11,1	3,8	0,35	22,2	4,3	0,19	9,5	3,2	0,34	7,8	3,0	0,39	15,9	5,5	0,34
Densmold	1,9	0,1	0,06	1,6	0,1	0,09	2,0	0,1	0,07	2,1	0,2	0,08	1,7	0,2	0,11
K ₁	532	181	0,34	97	33	0,34	545	132	0,24	943	268	0,28	239	75	0,31
K ₂	0,46	0,08	0,17	0,13	0,08	0,62	0,35	0,10	0,29	0,44	0,10	0,24	0,22	0,12	0,55
K ₃	-0,52	0,20	0,38	-0,63	0,14	0,22	-0,23	0,09	0,39	-0,11	0,07	0,64	-0,44	0,13	0,30
N ^o . de Amostras	31			66			133			70			163		

Quadro 6.3 - Algoritmo K-means - 4 Grupos - Procedimento 1												
Atributo	Grupo 0			Grupo 1			Grupo 2			Grupo 3		
	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.
Pen 1"	100,0	4,1	0,04	95,6	7,9	0,08	100,0	0,5	0,01	99,1	2,7	0,03
Pen 3/8"	99,7	1,0	0,01	73,6	13,1	0,18	99,8	0,6	0,01	94,8	5,7	0,06
Pen. 4	98,8	2,9	0,03	55,6	11,4	0,21	99,2	1,3	0,01	87,8	9,3	0,11
Pen.10	95,5	5,6	0,06	42,4	12,3	0,29	97,2	3,6	0,04	75,6	12,0	0,16
Pen. 40	79,4	12,9	0,16	27,9	10,7	0,38	86,1	9,9	0,12	44,0	10,4	0,24
Pen. 200	44,8	12,2	0,27	12,4	6,8	0,55	68,1	11,6	0,17	21,2	8,6	0,41
IP	12,8	8,7	0,68	2,4	3,4	1,42	27,9	10,6	0,38	3,4	5,5	1,62
Hmold	13,7	3,5	0,26	7,4	2,7	0,36	22,3	4,5	0,20	9,3	2,2	0,24
Densmold	1,8	0,1	0,06	2,1	0,1	0,05	1,6	0,1	0,06	2,0	0,1	0,05
K ₁	388	265	0,68	800	305	0,38	176	105	0,60	485	198	0,41
K ₂	0,30	0,12	0,40	0,42	0,11	0,26	0,12	0,08	0,67	0,38	0,09	0,24
K ₃	-0,39	0,19	0,49	-0,22	0,18	0,82	-0,52	0,17	0,33	-0,32	0,20	0,63
Nº. de Amostras	117			87			135			124		

Quadro 6.4 - Algoritmo K-means - 4 Grupos - Procedimento 2												
Atributo	Grupo 0			Grupo 1			Grupo 2			Grupo 3		
	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.
Pen 1"	99,9	0,6	0,01	99,3	3,3	0,03	98,6	4,0	0,04	97,2	6,9	0,07
Pen 3/8"	99,3	2,1	0,02	94,8	7,9	0,08	92,2	12,1	0,13	83,6	16,3	0,19
Pen. 4	97,8	5,5	0,06	85,6	16,6	0,19	86,2	17,2	0,20	73,0	22,2	0,30
Pen.10	94,4	9,7	0,10	76,1	21,6	0,28	77,2	20,9	0,27	63,0	25,8	0,41
Pen. 40	79,9	16,0	0,20	57,4	21,3	0,37	54,7	24,7	0,45	42,5	24,1	0,57
Pen. 200	59,2	16,1	0,27	33,3	15,2	0,46	29,3	18,7	0,64	16,4	12,8	0,78
IP	22,9	12,0	0,53	9,2	8,1	0,88	6,1	8,3	1,35	3,6	7,5	2,07
Hmold	19,3	5,8	0,30	12,4	3,9	0,32	10,6	4,4	0,41	7,9	3,0	0,37
Densmold	1,7	0,2	0,10	1,9	0,1	0,07	1,9	0,2	0,09	2,0	0,2	0,08
K ₁	176	84	0,48	367	198	0,54	472	155	0,33	917	253	0,28
K ₂	0,14	0,08	0,57	0,40	0,09	0,23	0,34	0,10	0,29	0,45	0,09	0,20
K ₃	-0,52	0,15	0,29	-0,58	0,15	0,26	-0,26	0,09	0,35	-0,13	0,09	0,69
Nº. de Amostras	163			61			154			85		

Quadro 6.5 - Algoritmo K-means - 5 Grupos - Procedimento 2															
Atributo	Grupo 0			Grupo 1			Grupo 2			Grupo 3			Grupo 4		
	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.
Pen 1"	98,4	4,8	0,05	99,9	0,7	0,01	99,0	3,1	0,03	97,4	6,8	0,07	99,6	2,4	0,02
Pen 3/8"	91,2	14,2	0,16	99,3	2,0	0,02	93,2	9,6	0,10	84,6	16,2	0,19	97,2	5,4	0,06
Pen. 4	84,7	20,1	0,24	98,3	4,1	0,04	86,9	15,6	0,18	74,7	22,3	0,30	88,7	14,1	0,16
Pen.10	77,1	23,9	0,31	95,3	7,5	0,08	78,1	19,9	0,25	63,7	24,8	0,39	80,0	21,3	0,27
Pen. 40	58,4	26,5	0,45	81,0	14,4	0,18	55,7	22,8	0,41	41,1	23,0	0,56	63,7	22,9	0,36
Pen. 200	33,9	21,7	0,64	60,1	15,2	0,25	29,7	15,3	0,52	15,2	11,5	0,76	42,1	20,8	0,49
IP	8,7	10,9	1,24	23,5	11,8	0,50	6,3	7,0	1,12	2,5	5,6	2,19	14,3	11,6	0,81
Hmold	11,1	5,1	0,46	19,5	5,8	0,30	11,1	3,9	0,35	7,9	2,7	0,34	15,1	5,9	0,39
Densmold	1,9	0,2	0,10	1,7	0,2	0,10	1,9	0,2	0,08	2,0	0,2	0,07	1,8	0,2	0,09
K ₁	480	162	0,34	184	83	0,45	430	182	0,42	905	259	0,29	251	181	0,72
K ₂	0,26	0,08	0,31	0,13	0,07	0,54	0,42	0,07	0,17	0,45	0,08	0,18	0,30	0,13	0,43
K ₃	-0,21	0,09	0,43	-0,48	0,11	0,23	-0,37	0,10	0,27	-0,13	0,08	0,62	-0,72	0,12	0,18
N ^o . de Amostras	73			138			111			90			51		

Quadro 6.6 - Agrupamento por Especialista 2 Grupos - Procedimento 2						
Atributo	Coesivo			Granular		
	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.
Pen 1"	99,8	1,3	0,01	97,8	5,8	0,06
Pen 3/8"	97,8	5,9	0,06	87,8	14,7	0,17
Pen. 4	94,1	12,3	0,13	79,6	20,3	0,25
Pen.10	89,0	17,2	0,19	69,3	23,2	0,33
Pen. 40	73,5	20,9	0,28	46,2	23,2	0,50
Pen. 200	51,0	20,1	0,39	20,9	14,5	0,69
IP	18,3	12,5	0,68	3,6	6,4	1,77
Hmold	16,8	6,3	0,38	9,0	3,3	0,37
Densmold	1,7	0,2	0,11	2,0	0,1	0,07
K ₁	262	170	0,65	675	290	0,43
K ₂	0,22	0,13	0,60	0,41	0,09	0,23
K ₃	-0,50	0,17	0,34	-0,19	0,11	0,56
N ^o . de Amostras	263			200		

Quadro 6.7 - Agrupamento por Especialista - 3 Grupos - Procedimento 2									
Atributo	Coesivo			Intermediário			Granular		
	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.
Pen 1"	99,9	0,6	0,01	99,0	3,6	0,04	97,3	6,6	0,07
Pen 3/8"	99,2	2,8	0,03	93,6	10,5	0,11	84,9	16,4	0,19
Pen. 4	97,6	6,1	0,06	86,6	17,0	0,20	75,8	22,1	0,29
Pen.10	94,3	10,0	0,11	78,4	21,8	0,28	64,9	24,4	0,38
Pen. 40	79,8	15,5	0,19	59,0	24,5	0,41	40,9	22,3	0,55
Pen. 200	59,8	16,5	0,28	33,3	18,4	0,55	16,1	12,4	0,77
IP	24,4	11,8	0,48	7,9	8,3	1,06	3,1	6,8	2,17
Hmold	19,7	5,8	0,29	11,6	4,6	0,39	8,0	2,8	0,35
Densmold	1,6	0,2	0,10	1,9	0,2	0,09	2,0	0,2	0,07
K ₁	170	82	0,48	449	215	0,48	817	281	0,34
K ₂	0,14	0,08	0,58	0,36	0,11	0,32	0,43	0,09	0,21
K ₃	-0,55	0,16	0,29	-0,36	0,15	0,42	-0,11	0,06	0,53
Nº. de Amostras	147			216			100		

Quadro 6.8 - Agrupamento por Especialista - 4 Grupos - Procedimento 2												
Atributo	Coesivo			Intercoesivo			Intergranular			Granular		
	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.	Média	Desv. Pad.	C.V.
Pen 1"	99,9	0,6	0,01	99,7	1,7	0,02	98,2	4,8	0,05	97,3	6,6	0,07
Pen 3/8"	99,2	2,8	0,03	96,4	7,5	0,08	90,4	12,3	0,14	84,9	16,4	0,19
Pen. 4	97,6	6,1	0,06	90,2	15,3	0,17	82,7	17,9	0,22	75,8	22,1	0,29
Pen.10	94,3	10,0	0,11	83,3	20,7	0,25	73,0	21,7	0,30	64,9	24,4	0,38
Pen. 40	79,8	15,5	0,19	66,4	23,4	0,35	50,8	23,1	0,45	40,9	22,3	0,55
Pen. 200	59,8	16,5	0,28	40,5	18,5	0,46	25,4	14,7	0,58	16,1	12,4	0,77
IP	24,4	11,8	0,48	12,0	8,5	0,71	4,9	6,3	1,28	3,1	6,8	2,17
Hmold	19,7	5,8	0,29	13,3	4,8	0,36	9,8	3,6	0,36	8,0	2,8	0,35
Densmold	1,6	0,2	0,10	1,8	0,2	0,09	2,0	0,1	0,07	2,0	0,2	0,07
K ₁	170	82	0,48	373	219	0,48	533	219	0,41	817	281	0,34
K ₂	0,14	0,08	0,58	0,32	0,12	0,36	0,39	0,10	0,25	0,43	0,09	0,21
K ₃	-0,55	0,16	0,29	-0,44	0,16	0,37	-0,28	0,08	0,28	-0,11	0,06	0,53
Nº. de Amostras	147			113			103			100		



Figura 6.1 - Grupos
104




Figura 6.2 – Peneira 1" X Grupos

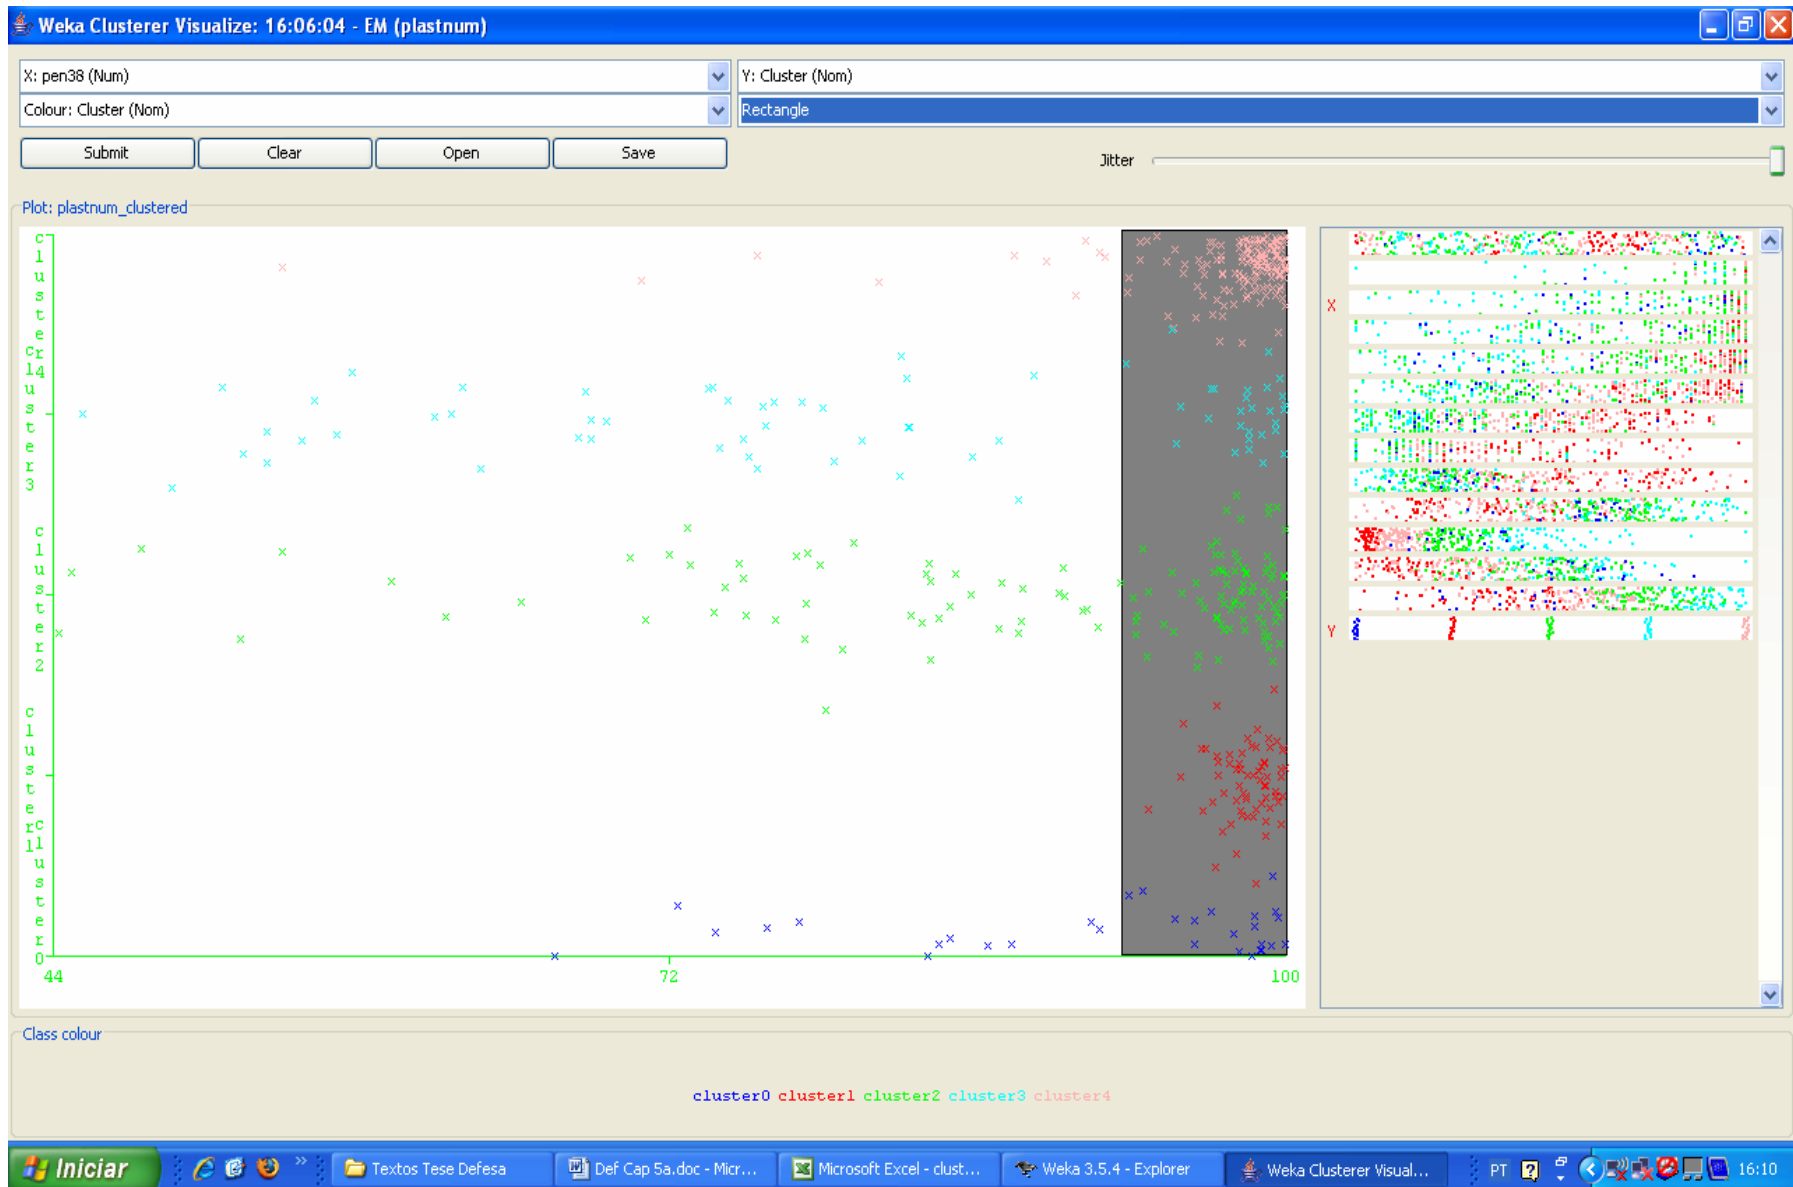


Figura 6.3 – Peneira 3/8" X Grupos



Figura 6.4 – Peneira Nº. 4 X Grupos

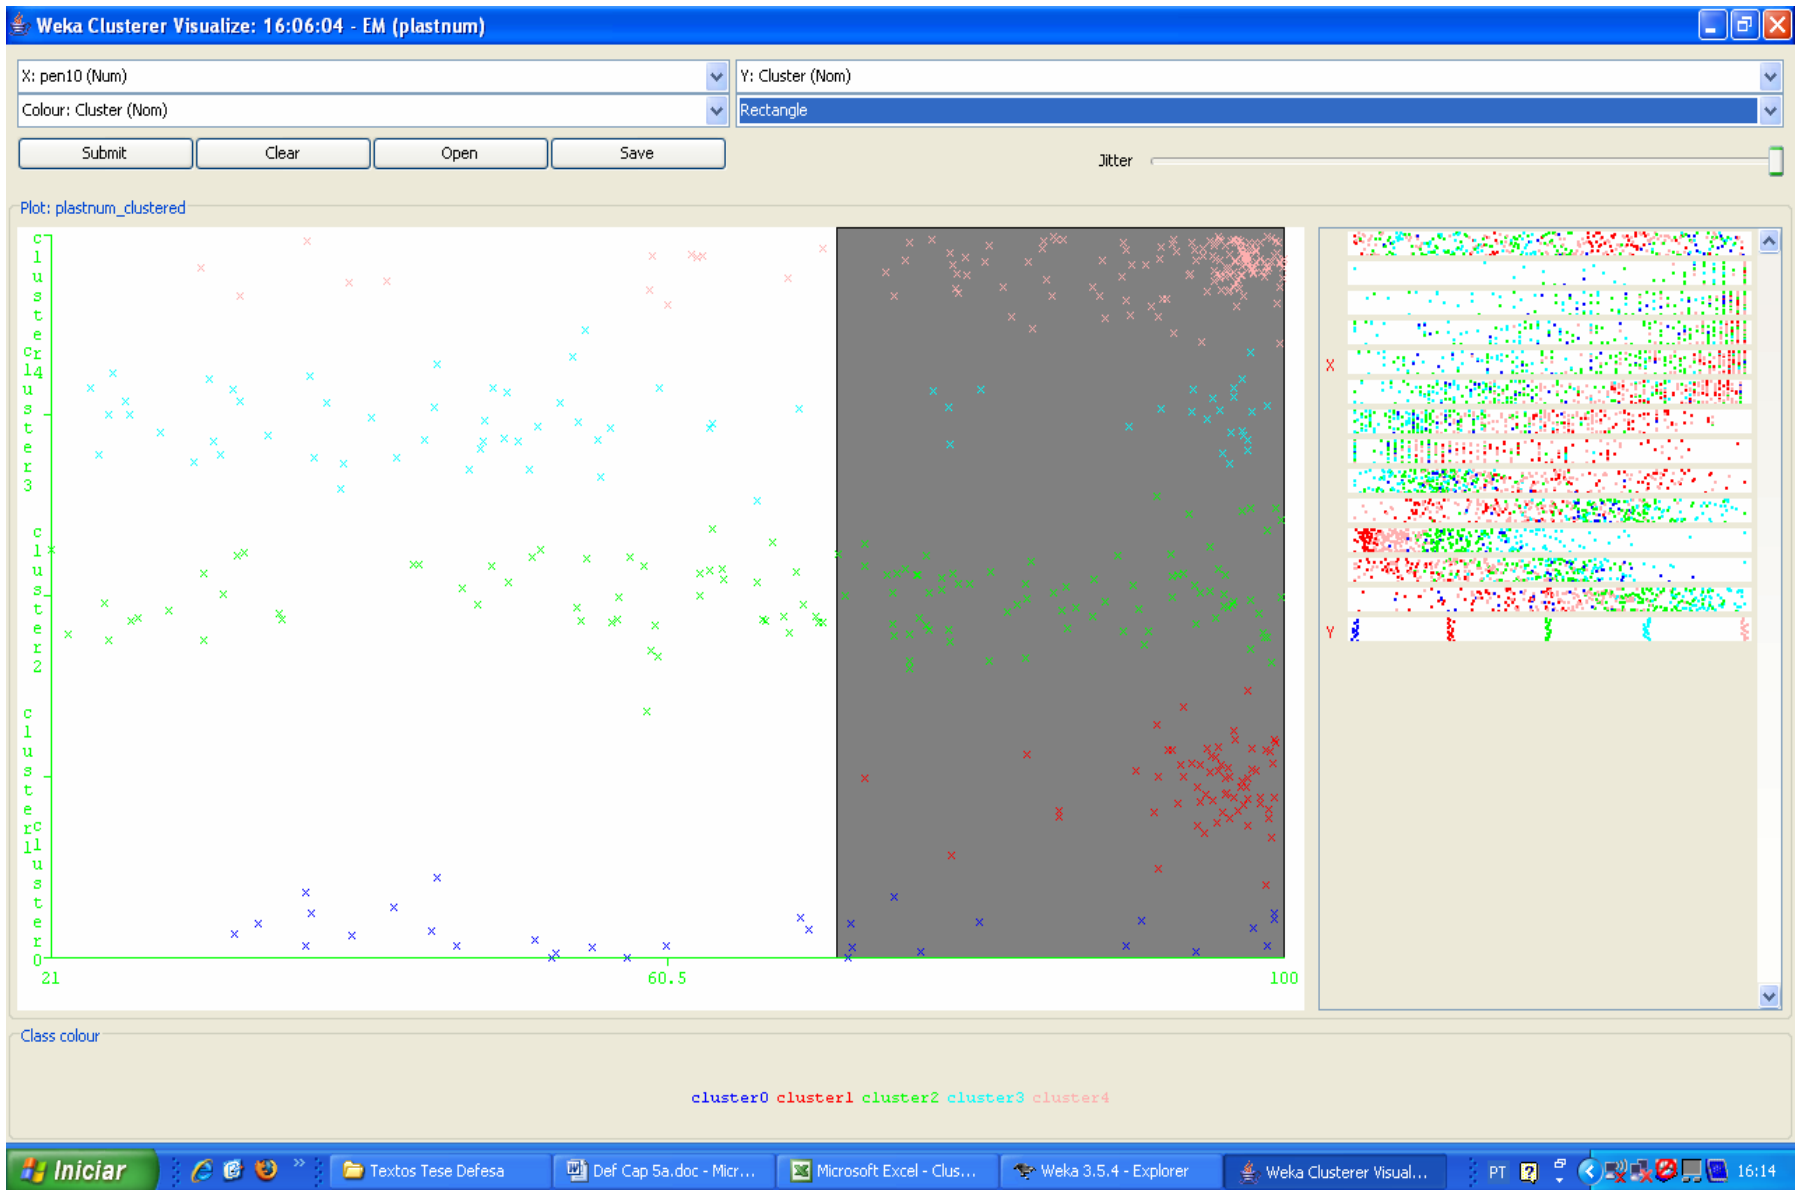


Figura 6.5 – Peneira Nº. 10 X Grupos



Figura 6.6 – Peneira Nº. 40 X Grupos

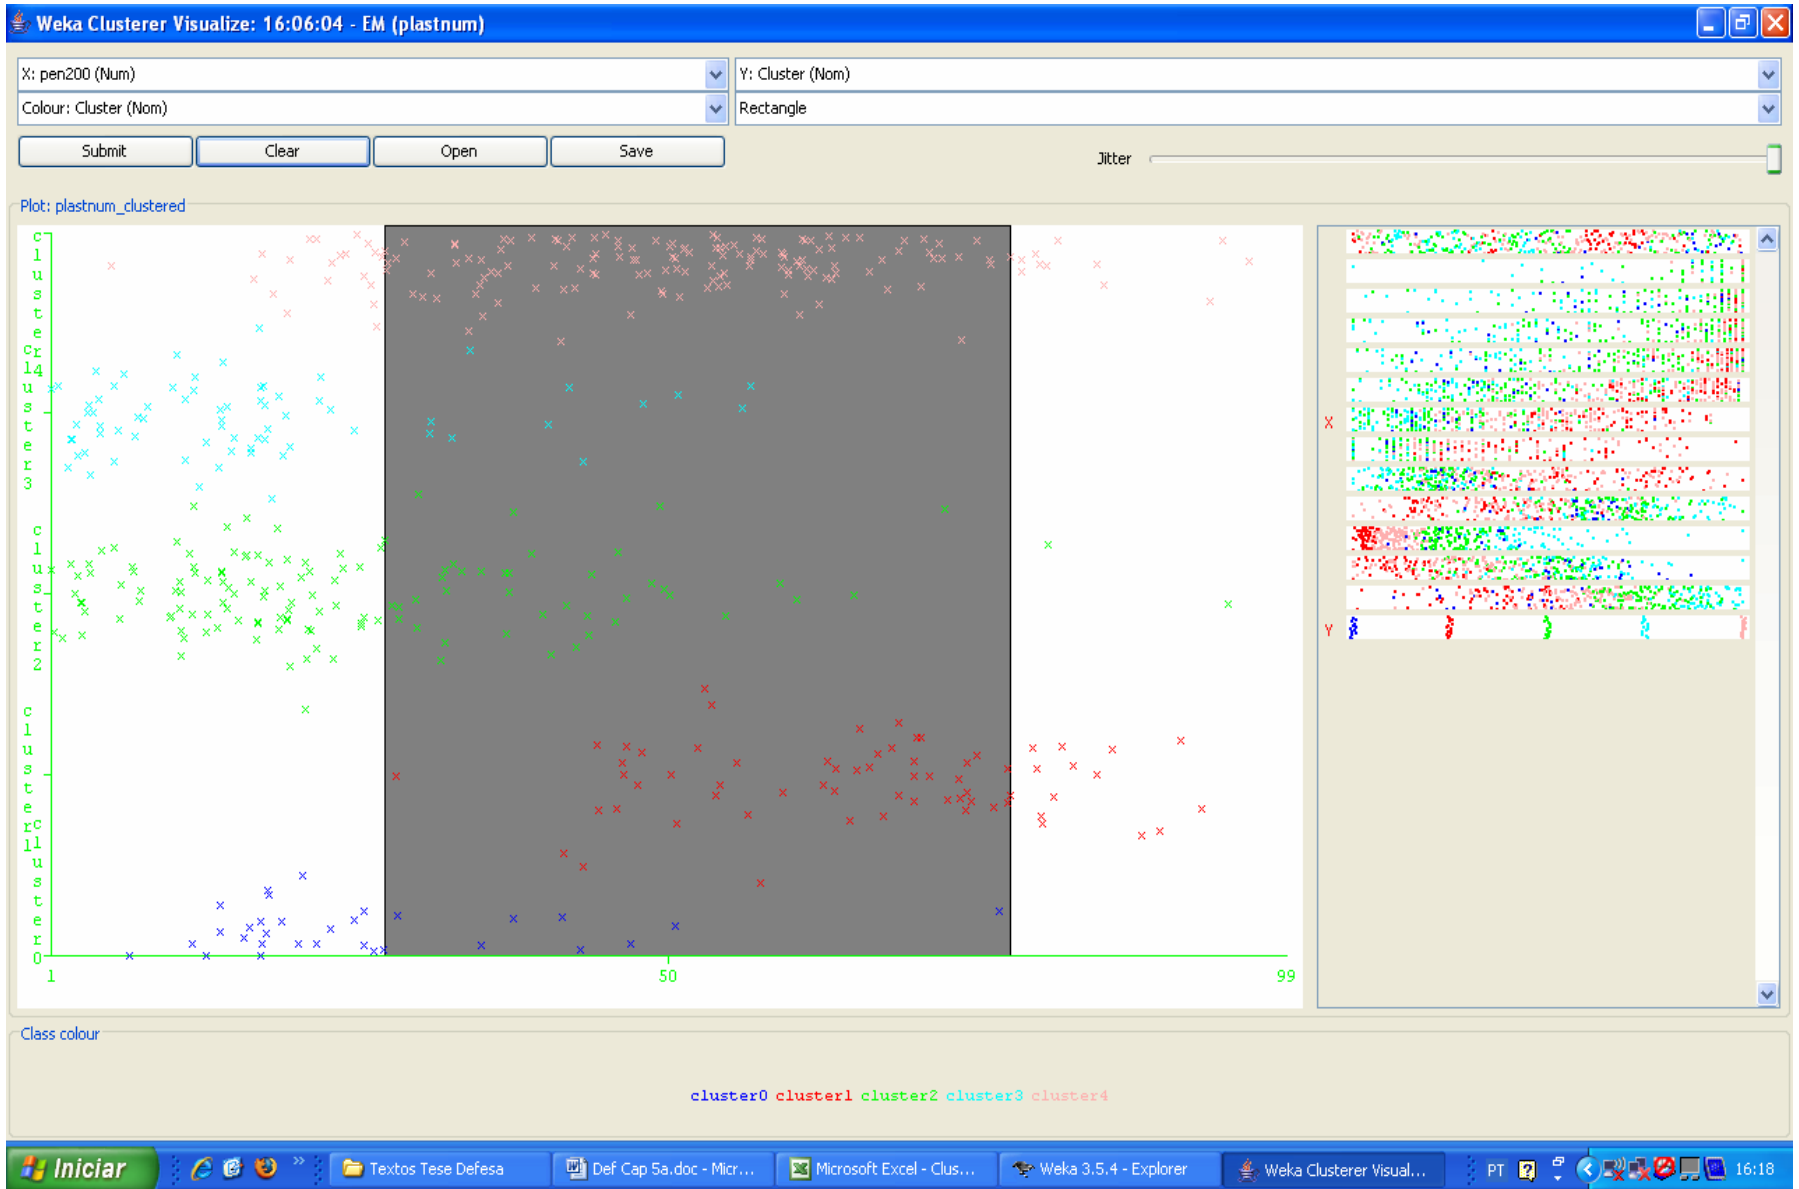


Figura 6.7 – Peneira Nº. 200 X Grupos



Figura 6.8 – IP X Grupos



Figura 6.9 – Hmodal X Grupos

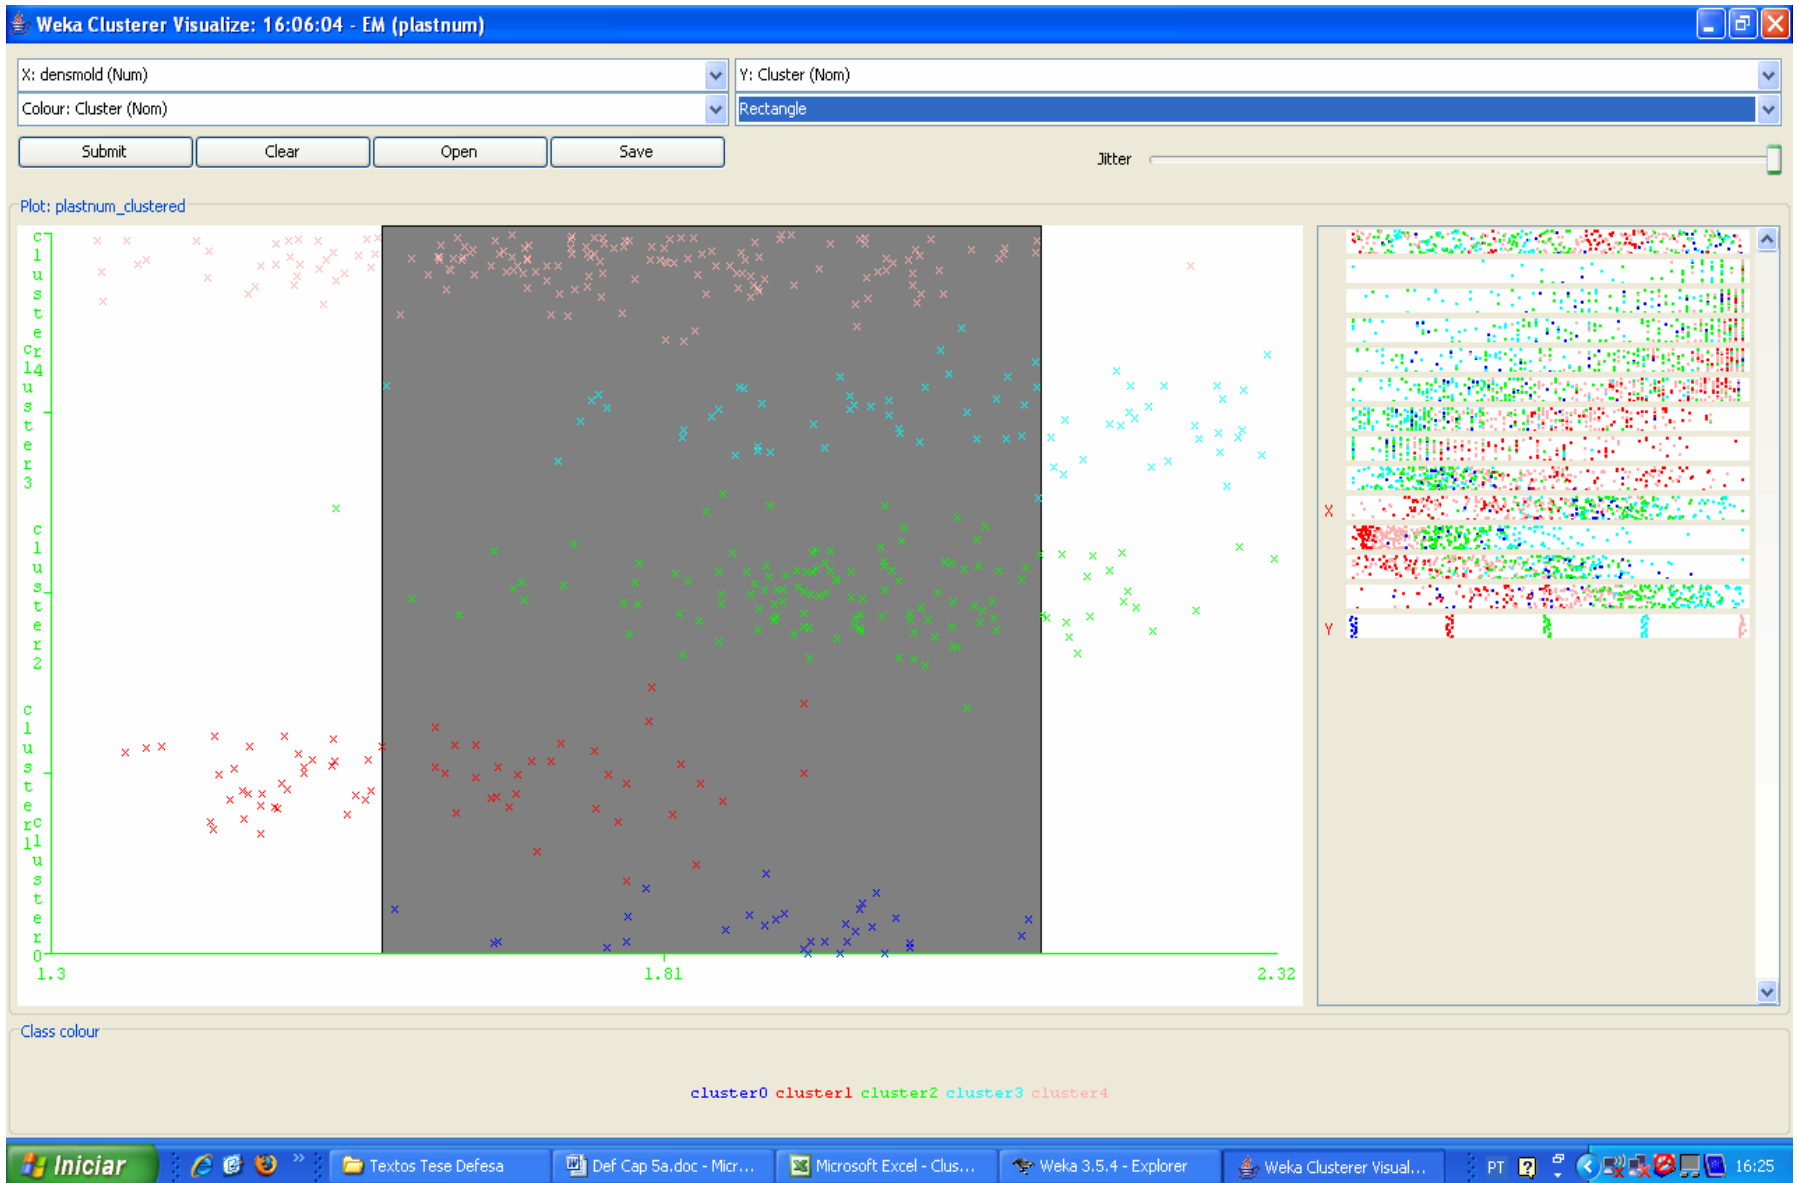


Figura 6.10 – Desnmold X Grupos



Figura 6.11 – K1 X Grupos



Figura 6.12 – K2 X Grupos

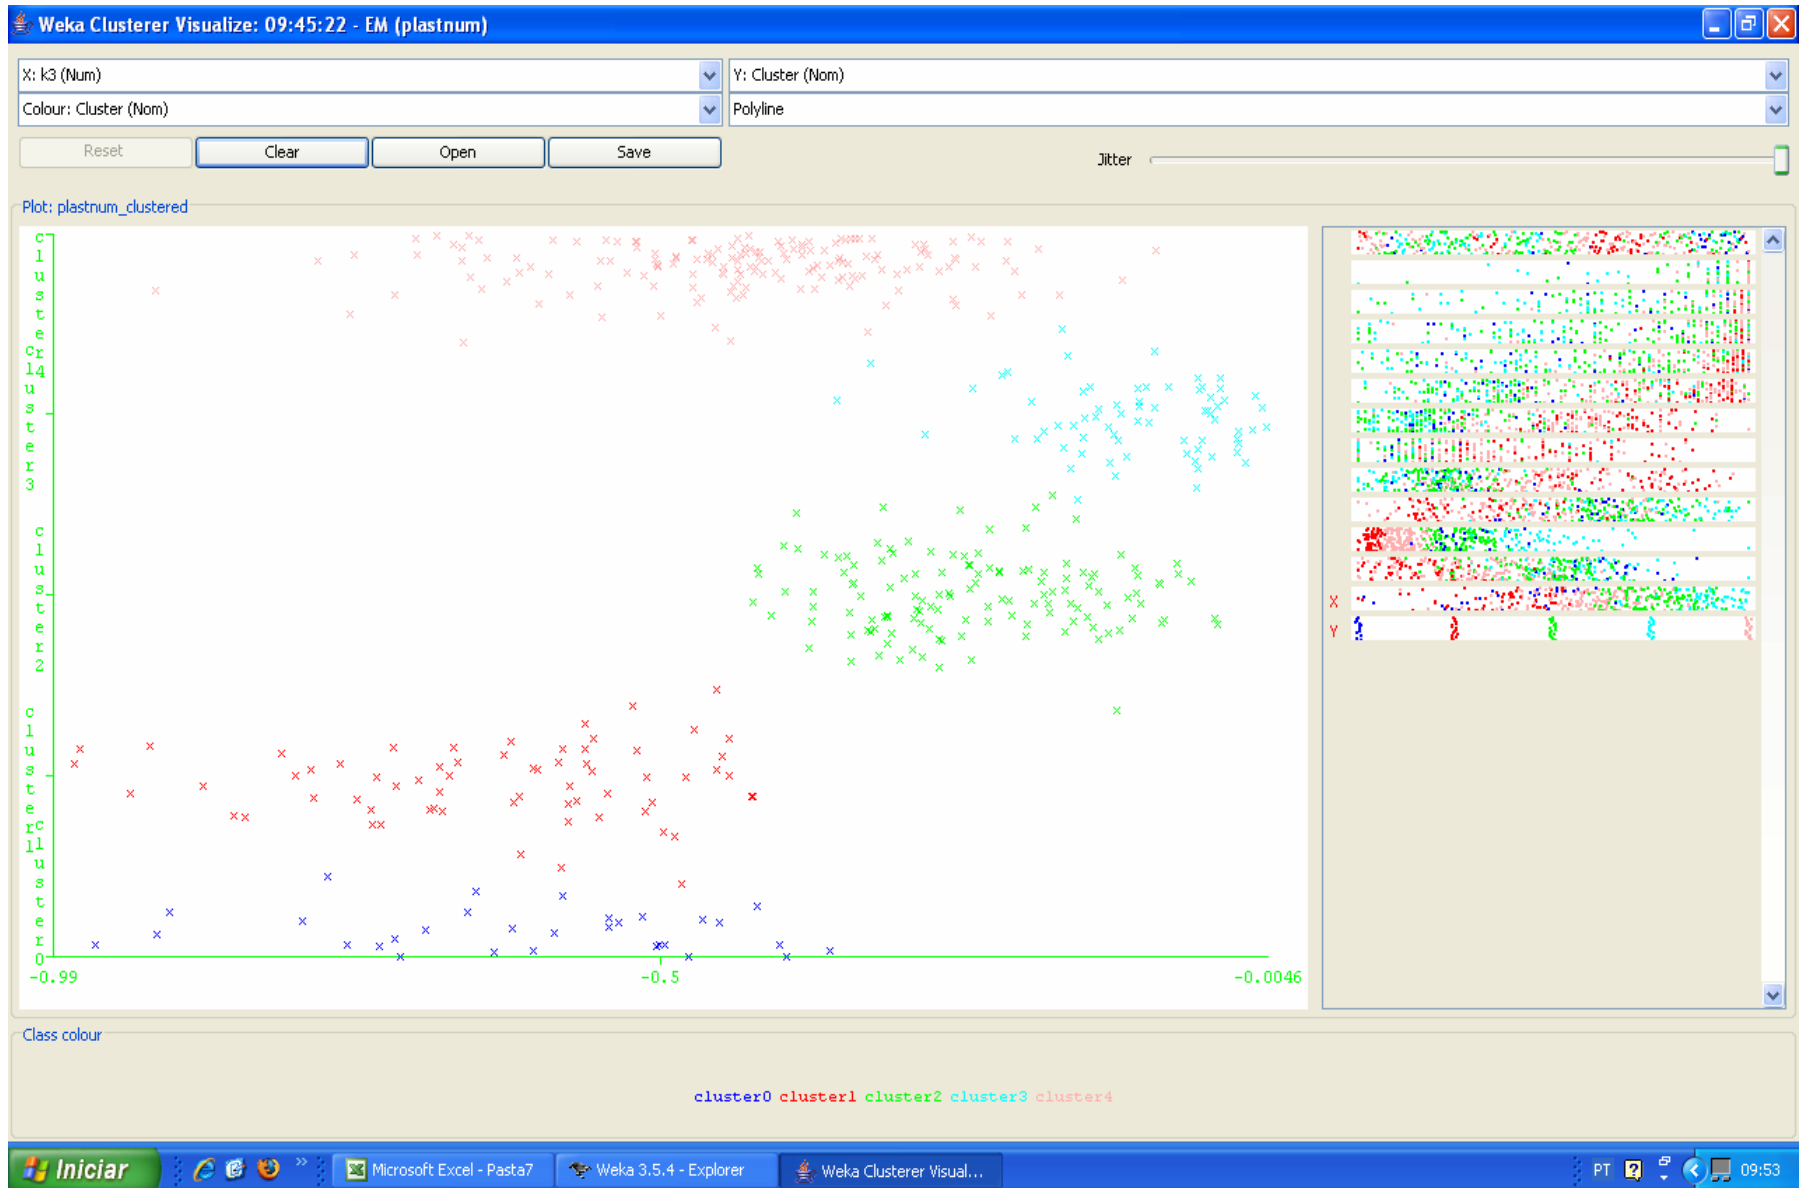


Figura 6.13 – K3 X Grupos

6.4 Resumo e análise dos resultados dos agrupamentos

Para definição do melhor agrupamento, o sistema *Weka* utiliza a função *log-likelihood*, sendo o melhor agrupamento aquele que maximizá-la. No Quadro 6.9, inserido a seguir, são apresentados os valores desta função para cada um dos agrupamentos feitos com o *Weka*.

Quadro 6.9 – Valores da função *log-likelihood*

Algoritmo	Nº. de Grupos	Procedimento	Log-likelihood
EM	4	1	-24,30
	5	2	-5,60
K-means	4	1	-29,67
	4	2	-5,76
	5	2	-5,78

Constata-se que por este critério os agrupamentos feitos segundo o Procedimento 1 são mais adequados à base de dados, e que não há grandes diferenças quanto à precisão dos agrupamentos quando considerados separadamente os Procedimentos 1 e 2. Por este critério, o melhor agrupamento é o gerado pelo algoritmo *K-means* com quatro grupos, utilizando na análise todas as variáveis consideradas.

Se a análise for efetuada considerando os parâmetros estatísticos média, desvio padrão e coeficiente de variação, as conclusões são outras. Admitindo a premissa de que o comportamento resiliente dos solos é refletido pelas constantes K_2 e K_3 do modelo composto, conclui-se que o melhor agrupamento é aquele que resulta nos menores coeficientes de variação destas constantes, já que valores mais reduzidos indicam maior similaridade intra-grupo. Um resumo desses valores para todos os agrupamentos efetuados com quatro e cinco grupos é apresentado nas Figuras 6.14 a 6.22, inseridas a seguir. Os valores relativos à constante K_1 foram incluídos apenas para ilustração de sua maior ou menor homogeneidade em cada grupo, não sendo considerado determinante no comportamento resiliente dos solos.

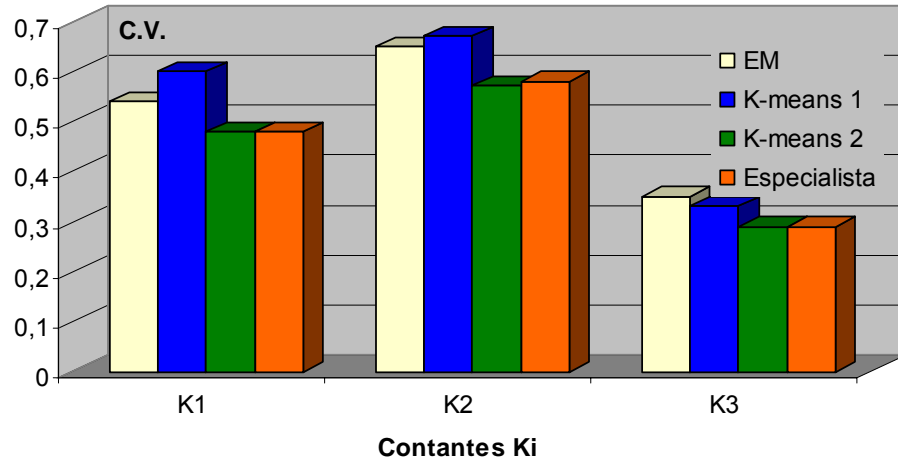


Figura 6.14 – Coeficientes de Variação- 4 grupos – Solos Coesivos




Figura 6.15 – Coeficientes de Variação – 4 grupos - Solos Intercoesivos

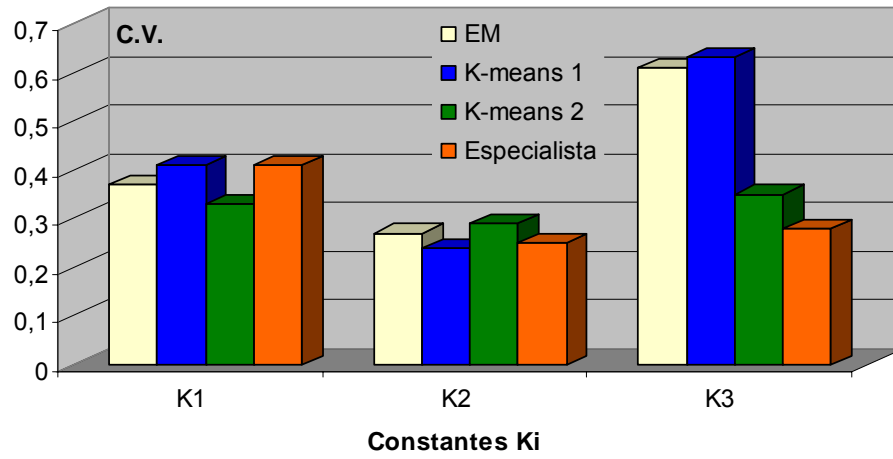


Figura 6.16 – Coeficientes de Variação – 4 grupos - Solos Intergranulares




Figura 6.17 – Coeficientes de Variação – 4 grupos - Solos Granulares




Figura 6.18 – Coeficientes de Variação – 5 grupos - Solos Coesivos 1




Figura 6.19 – Coeficientes de Variação – 5 grupos - Solos Coesivos 2




Figura 6.20 – Coeficientes de Variação – 5 grupos - Solos Intercoesivos




Figura 6.21 – Coeficientes de Variação – 5 grupos - Solos Intergranulares




Figura 6.22 – Coeficientes de Variação – 5 grupos - Solos Granulares

As médias dos coeficientes de variação das constantes K_i de cada um dos agrupamentos são apresentadas no Quadro 6.10, inserido a seguir.

Quadro 6.10 – Médias dos coeficientes de variação

Algoritmo	Nº. de Grupos	Procedimento	Médias C.V.
EM	4	1	0,49
	5	2	0,35
K-means	4	1	0,49
	4	2	0,38
	5	2	0,37
Especialista	4	2	0,38

Observa-se pelos gráficos que os valores dos coeficientes de variação não permitem definir qual o melhor agrupamento, tendo em vista que tanto valores elevados quanto reduzidos são obtidos em todos eles. As médias desses valores também não permitem definir qual o melhor, mas apenas constatar que os

agrupamentos com quatro grupos efetuados com os algoritmos *EM* e *K-means*, quando aplicado a ambos o Procedimento 1, são os mais heterogêneos. Ressalve-se apenas que estes agrupamentos foram determinados como os melhores quando utilizado o critério de maximização da função *log-likelihood*.

Buscando verificar se após o agrupamento em famílias de comportamento resiliente há alguma melhora das correlações existentes entre as variáveis envolvidas, foram elaboradas as matrizes apresentadas nos Quadros 6.11 a 6.21, inseridos a seguir. Os resultados demonstram que na verdade houve uma redução dos coeficientes de correlação das constantes K_i em relação àqueles obtidos quando utilizada a base de dados não segmentada.

Conclusivamente, não foi possível definir qual o melhor agrupamento apenas com base nos resultados dos algoritmos utilizados e na experiência do especialista. Contudo, tais resultados deixam patente a complexidade do comportamento resiliente dos solos, resultando em prejuízo das conclusões das tentativas de natureza determinística já realizadas no intuito de obter correlações entre este comportamento e os parâmetros geotécnicos tradicionalmente utilizados em pavimentação. A título de exemplo pode-se citar uma dessas tentativas, elaborada por Pinto e Preussler, sob orientação de Medina, bastante difundida e já citada, que indica como limite o percentual de 35% de material passante na peneira 200 como definidor de solos granulares e coesivos. Na Figura 6.23, apresentada a seguir, são indicadas as amostras classificadas como coesivas e granulares, segundo os critérios descritos no item 6.3 para divisão em dois grupos. Pode-se constatar que o limite de 35%, determinado a partir da classificação TRB, não é consistente. Uma parte das amostras de comportamento coesivo apresenta percentual inferior a este, assim como alguns solos de comportamento granular apresentam percentual mais elevado que o limite definido. Deve-se considerar, contudo, que o limite de 35% foi determinado há muito tempo, quando não se dispunha de um número significativo de amostras ensaiadas, o equipamento utilizado no ensaio era muito mais sujeito a erros de medição das deformações do que os atualmente em uso, e a modelagem era feita considerando as influências das tensões desvio e confinante separadamente. Levando em conta essas circunstâncias, os autores definiram um limite bastante razoável, que, entretanto, não se confirma em uma análise mais aprofundada, para a qual se dispõe de uma quantidade muito maior de dados e de ferramentas de modelagem e análise muito mais apropriadas.




Figura 6.23 – Percentual de material passante na peneira 200 de solos coesivos e granulares em relação ao limite de 35%

No Quadro 6.22, inserido a seguir, é apresentada a base de dados indicando o grupo em que foram alocadas as amostras em cada um dos agrupamentos analisados. O que se pode constatar primeiramente é que a classificação TRB não se aplica adequadamente à resiliência de solos, ocorrendo discrepâncias significativas quando comparados o comportamento resiliente e esta classificação. Outra constatação é que quando se utiliza a totalidade das variáveis (Procedimento 1), os algoritmos alocam amostras de comportamento resiliente em grupos nos quais as constantes K_i refletem comportamento oposto. Este fato é mais uma confirmação das dificuldades em correlacionar as variáveis consideradas.

Quadro 6.11 - Matriz de Correlação - Constantes Ki - Agrupamento EM - 4 Grupos - Coesivo

	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen3/8</i>	1										
<i>pen4</i>	0,466864	1									
<i>pen10</i>	0,384802	0,609109	1								N=199
<i>pen40</i>	0,146998	0,344846	0,585455	1							
<i>pen200</i>	-0,039531	0,066619	0,316929	0,588388	1						
<i>IP</i>	-0,031148	-0,171172	0,06318	0,0071	0,491184	1					
<i>Hmold</i>	0,023926	0,047091	0,248544	0,364534	0,785278	0,550738	1				
<i>Densmold</i>	0,021391	0,004456	-0,122815	-0,262378	-0,671955	-0,45703	-0,854616	1			
<i>K1</i>	0,061382	0,070134	0,043077	-0,069855	-0,332521	-0,279206	-0,463144	0,374038	1		
<i>K2</i>	0,070465	0,153925	-0,05832	-0,064506	-0,467533	-0,530474	-0,423863	0,391173	0,357234	1	
<i>K3</i>	0,057957	-0,001833	-0,043882	-0,020031	-0,153817	-0,196465	-0,26578	0,148125	0,579929	0,058992	1

Quadro 6.12 - Matriz de Correlação - Constantes Ki - Agrupamento EM - 4 Grupos - Intercoesivo

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1											
<i>pen3/8</i>	0,509935	1										
<i>pen4</i>	0,243267	0,738698	1									
<i>pen10</i>	0,165637	0,409064	0,718819	1								N=61
<i>pen40</i>	-0,011313	0,359728	0,41023	0,478714	1							
<i>pen200</i>	-0,199008	-0,331774	-0,409826	-0,459821	-0,018862	1						
<i>IP</i>	-0,223786	-0,429226	-0,488338	-0,455046	-0,283803	0,742646	1					
<i>Hmold</i>	-0,209682	-0,403175	-0,547661	-0,558264	-0,168438	0,794354	0,68049	1				
<i>Densmold</i>	0,196064	0,492552	0,512419	0,424246	0,130641	-0,736001	-0,766663	-0,733865	1			
<i>K1</i>	0,11028	0,512022	0,654984	0,640074	0,519776	-0,518963	-0,527202	-0,605314	0,574524	1		
<i>K2</i>	0,319427	0,501669	0,541249	0,440914	0,115275	-0,56763	-0,654643	-0,633667	0,700787	0,529598	1	
<i>K3</i>	-0,067328	0,405978	0,515417	0,541043	0,372196	-0,489092	-0,468662	-0,570443	0,538502	0,809479	0,445554	1

Quadro 6.13 - Matriz de Correlação - Constantes Ki - Agrupamento EM - 4 Grupos - Intergranular

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1											
<i>pen3/8</i>	0,357184	1										
<i>pen4</i>	0,033148	0,466195	1									
<i>pen10</i>	-0,060375	0,104073	0,763181	1							N=110	
<i>pen40</i>	0,011167	-0,070754	-0,222098	0,098991	1							
<i>pen200</i>	-0,040207	-0,124158	-0,310566	-0,133548	0,762579	1						
<i>IP</i>	0,211394	-0,045624	-0,31681	-0,198893	0,431275	0,560584	1					
<i>Hmold</i>	0,128215	-0,139002	-0,36451	-0,255768	0,187653	0,379287	0,605268	1				
<i>Densmold</i>	-0,037786	0,241576	0,260126	0,125232	0,064876	0,026731	-0,089422	-0,42413	1			
<i>K1</i>	0,158409	0,016246	-0,146647	-0,14084	-0,14253	-0,326387	-0,161342	-0,18451	0,07986	1		
<i>K2</i>	0,114491	0,134842	0,09691	-0,029546	-0,205475	-0,329981	-0,091133	-0,041286	0,139648	0,506335	1	
<i>K3</i>	0,005613	0,052199	0,378616	0,329259	-0,273961	-0,394758	-0,391228	-0,372809	0,279208	0,416367	0,009346	1

Quadro 6.14 - Matriz de Correlação - Constantes Ki - Agrupamento EM - 4 Grupos - Granular

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1											
<i>pen3/8</i>	0,364778	1										
<i>pen4</i>	-0,062083	0,693187	1									
<i>pen10</i>	-0,250375	0,337111	0,876514	1							N=93	
<i>pen40</i>	-0,183882	0,36824	0,617072	0,69497	1							
<i>pen200</i>	-0,14145	0,401302	0,412827	0,366171	0,776753	1						
<i>IP</i>	0,241712	0,288065	-0,097364	-0,304318	0,065858	0,470815	1					
<i>Hmold</i>	0,306619	0,402504	0,098572	-0,040109	0,187596	0,467926	0,586862	1				
<i>Densmold</i>	-0,213539	-0,44535	-0,187738	-0,085949	-0,315668	-0,552375	-0,504939	-0,746009	1			
<i>K1</i>	-0,012245	-0,049045	-0,065464	-0,060514	0,001218	-0,217175	-0,163204	-0,245549	0,321093	1		
<i>K2</i>	-0,085544	0,153528	0,206799	0,183803	0,055485	-0,151618	-0,309372	-0,010068	0,093596	0,640221	1	
<i>K3</i>	-0,160722	-0,40757	-0,148933	-0,026625	-0,203273	-0,341068	-0,189525	-0,378261	0,518061	0,414441	0,00886	1

Quadro 6.15 - Matriz de Correlação - Constantes Ki - Agrupamento por Especialista - 2 Grupos - Coesivo

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1											
<i>pen3/8</i>	0,526886	1										
<i>pen4</i>	0,365943	0,918517	1									
<i>pen10</i>	0,288854	0,811134	0,948962	1							N=263	
<i>pen40</i>	0,232702	0,643182	0,717334	0,816934	1							
<i>pen200</i>	0,167543	0,507839	0,534163	0,591296	0,784583	1						
<i>IP</i>	0,179522	0,266423	0,219562	0,246094	0,38244	0,65601	1					
<i>Hmold</i>	0,359954	0,500147	0,448936	0,447502	0,525612	0,724674	0,588132	1				
<i>Densmold</i>	-0,372292	-0,643437	-0,626833	-0,626956	-0,602521	-0,630856	-0,450745	-0,747879	1			
<i>K1</i>	-0,14812	-0,310714	-0,376467	-0,335977	-0,17562	-0,315178	-0,093902	-0,3855	0,373794	1		
<i>K2</i>	-0,077323	-0,062924	-0,080753	-0,116792	-0,144193	-0,27023	-0,314535	-0,1334	0,230445	0,388122	1	
<i>K3</i>	-0,11348	-0,234269	-0,202237	-0,166597	-0,198596	-0,282953	-0,068171	-0,310192	0,254149	0,452827	-0,195494	1

Quadro 6.16 - Matriz de Correlação - Constantes Ki - Agrupamento por Especialista - 2 Grupos - Granular

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1											
<i>pen3/8</i>	0,526886	1										
<i>pen4</i>	0,365943	0,918517	1									
<i>pen10</i>	0,288854	0,811134	0,948962	1							N=200	
<i>pen40</i>	0,232702	0,643182	0,717334	0,816934	1							
<i>pen200</i>	0,167543	0,507839	0,534163	0,591296	0,784583	1						
<i>IP</i>	0,179522	0,266423	0,219562	0,246094	0,38244	0,65601	1					
<i>Hmold</i>	0,359954	0,500147	0,448936	0,447502	0,525612	0,724674	0,588132	1				
<i>Densmold</i>	-0,372292	-0,643437	-0,626833	-0,626956	-0,602521	-0,630856	-0,450745	-0,747879	1			
<i>K1</i>	-0,14812	-0,310714	-0,376467	-0,335977	-0,17562	-0,315178	-0,093902	-0,3855	0,373794	1		
<i>K2</i>	-0,077323	-0,062924	-0,080753	-0,116792	-0,144193	-0,27023	-0,314535	-0,1334	0,230445	0,388122	1	
<i>K3</i>	-0,11348	-0,234269	-0,202237	-0,166597	-0,198596	-0,282953	-0,068171	-0,310192	0,254149	0,452827	-0,195494	1

Quadro 6.17 - Matriz de Correlação - Constantes Ki - Agrupamento por Especialista - 3 e 4 Grupos - Coesivo

	pen1	pen3/8	pen4	pen10	pen40	pen200	IP	Hmold	Densmold	K1	K2	K3
pen1	1											
pen3/8	0,301694	1										
pen4	0,175506	0,848447	1									
pen10	0,180603	0,726072	0,932806	1							N=147	
pen40	0,184643	0,572445	0,658083	0,724307	1							
pen200	0,127382	0,497435	0,538606	0,574061	0,865012	1						
IP	0,106166	0,342276	0,347079	0,379446	0,411341	0,520176	1					
Hmold	0,121677	0,431843	0,401439	0,42717	0,675981	0,789693	0,582024	1				
Densmold	-0,039281	-0,26441	-0,235715	-0,2756	-0,486269	-0,623742	-0,432724	-0,799495	1			
K1	-0,064846	-0,286892	-0,246904	-0,230619	-0,234718	-0,298132	-0,330644	-0,380076	0,225253	1		
K2	0,034186	-0,211675	-0,241573	-0,299351	-0,37369	-0,480818	-0,389154	-0,441385	0,402514	0,129991	1	
K3	-0,151508	0,081417	0,125965	0,142629	0,078088	0,134301	0,085073	0,070635	-0,168851	0,503776	-0,407753	1

Quadro 6.18 - Matriz de Correlação - Constantes Ki - Agrupamento por Especialista - 3 Grupos - Intermediário

	pen1	pen3/8	pen4	pen10	pen40	pen200	IP	Hmold	Densmold	K1	K2	K3
pen1	1											
pen3/8	0,595149	1										
pen4	0,383391	0,851234	1									
pen10	0,304015	0,738613	0,955662	1							N=216	
pen40	0,308622	0,639013	0,75434	0,828531	1							
pen200	0,279237	0,552207	0,632639	0,670905	0,825446	1						
IP	0,235157	0,325453	0,327481	0,363144	0,458714	0,67261	1					
Hmold	0,256405	0,409966	0,4465	0,498265	0,612495	0,810777	0,61044	1				
Densmold	-0,244357	-0,434684	-0,485406	-0,533205	-0,586486	-0,708094	-0,495729	-0,824559	1			
K1	-0,108436	-0,411055	-0,509625	-0,478817	-0,359515	-0,451072	-0,220062	-0,394357	0,395673	1		
K2	-0,059993	-0,1174	-0,197603	-0,236406	-0,289603	-0,373251	-0,336963	-0,175859	0,16842	0,295351	1	
K3	-0,102132	-0,153765	0,035976	0,082949	0,014401	-0,035574	-0,072671	-0,129307	0,136327	0,157913	-0,442749	1

Quadro 6.19 - Matriz de Correlação - Constantes Ki - Agrupamento por Especialista - 3 e 4 Grupos - Granular

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1											
<i>pen3/8</i>	0,466024	1										
<i>pen4</i>	0,31286	0,929708	1									
<i>pen10</i>	0,24004	0,825119	0,949544	1							N=100	
<i>pen40</i>	0,145348	0,619729	0,699419	0,835107	1							
<i>pen200</i>	0,050997	0,440565	0,462291	0,563856	0,758901	1						
<i>IP</i>	0,140313	0,260806	0,217532	0,250931	0,364586	0,736068	1					
<i>Hmold</i>	0,405686	0,554335	0,467609	0,43473	0,454206	0,619162	0,574158	1				
<i>Densmold</i>	-0,414109	-0,725849	-0,664994	-0,637997	-0,583024	-0,57698	-0,54338	-0,738644	1			
<i>K1</i>	-0,156285	-0,17526	-0,220317	-0,126416	0,107044	0,033408	0,023389	-0,206991	0,200344	1		
<i>K2</i>	-0,199907	-0,115208	-0,143412	-0,183519	-0,224768	-0,354151	-0,453374	-0,281767	0,351072	0,484678	1	
<i>K3</i>	-0,102729	-0,169538	-0,142596	-0,079098	-0,074964	-0,108076	0,109224	-0,245261	0,190915	0,266785	-0,184493	1

Quadro 6.20 - Matriz de Correlação - Constantes Ki - Agrupamento por Especialista - 4 Grupos - Intercoesivo

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1											
<i>pen3/8</i>	0,408951	1										
<i>pen4</i>	0,20292	0,781105	1									
<i>pen10</i>	0,150175	0,662186	0,960759	1							N=113	
<i>pen40</i>	0,181293	0,560083	0,751788	0,843447	1							
<i>pen200</i>	0,212561	0,498724	0,646421	0,697028	0,819881	1						
<i>IP</i>	0,197234	0,307065	0,357709	0,389962	0,402773	0,623286	1					
<i>Hmold</i>	0,077035	0,310299	0,423679	0,491867	0,588281	0,794243	0,518395	1				
<i>Densmold</i>	-0,062923	-0,271612	-0,370177	-0,431125	-0,497313	-0,668568	-0,462685	-0,828299	1			
<i>K1</i>	0,075659	-0,29372	-0,427585	-0,362825	-0,248792	-0,306661	-0,075155	-0,246019	0,219155	1		
<i>K2</i>	-0,20428	-0,166372	-0,325029	-0,345801	-0,373431	-0,375546	-0,292611	-0,137376	0,077401	0,177854	1	
<i>K3</i>	0,102897	0,053067	0,322094	0,375039	0,345008	0,323599	0,233493	0,138702	-0,091949	-0,092195	-0,826748	1

Quadro 6.21 - Matriz de Correlação - Constantes Ki - Agrupamento por Especialista - 4 Grupos - Intergranular

	<i>pen1</i>	<i>pen3/8</i>	<i>pen4</i>	<i>pen10</i>	<i>pen40</i>	<i>pen200</i>	<i>IP</i>	<i>Hmold</i>	<i>Densmold</i>	<i>K1</i>	<i>K2</i>	<i>K3</i>
<i>pen1</i>	1											
<i>pen3/8</i>	0,408951	1										
<i>pen4</i>	0,20292	0,781105	1									
<i>pen10</i>	0,150175	0,662186	0,960759	1							N=103	
<i>pen40</i>	0,181293	0,560083	0,751788	0,843447	1							
<i>pen200</i>	0,212561	0,498724	0,646421	0,697028	0,819881	1						
<i>IP</i>	0,197234	0,307065	0,357709	0,389962	0,402773	0,623286	1					
<i>Hmold</i>	0,077035	0,310299	0,423679	0,491867	0,588281	0,794243	0,518395	1				
<i>Densmold</i>	-0,062923	-0,271612	-0,370177	-0,431125	-0,497313	-0,668568	-0,462685	-0,828299	1			
<i>K1</i>	0,075659	-0,29372	-0,427585	-0,362825	-0,248792	-0,306661	-0,075155	-0,246019	0,219155	1		
<i>K2</i>	-0,20428	-0,166372	-0,325029	-0,345801	-0,373431	-0,375546	-0,292611	-0,137376	0,077401	0,177854	1	
<i>K3</i>	0,102897	0,053067	0,322094	0,375039	0,345008	0,323599	0,233493	0,138702	-0,091949	-0,092195	-0,826748	1

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras

Nº da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos								
							LL (%)	IP (%)		h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos	3 Grupos	4 Grupos			5 Grupos			
	#1"	#3/8"	4	10	40	200												Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2	
0	100	99	97	90	80	70	58	22	15	20,6	1,523	16	0,21	A-7-6	57	0,11	-0,66	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
1	100	99	98	91	79	63	45	15	8	18,1	1,697	8	0,56	A-7-5	76	0,07	-0,54	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
2	100	99	98	93	81	70	54	22	14	21,3	1,646	11	0,14	A-7-5	107	0,07	-0,59	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
3	95	95	93	83	71	61	60	27	15	19,3	1,599	12	0,10	A-7-5	203	0,04	-0,22	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
4	100	99	93	81	65	56	65	32	14	17,4	1,576	12	0,22	A-7-5	184	0,07	-0,31	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
5	100	99	97	85	69	59	46	14	7	18,7	1,722	24	0,19	A-7-5	258	0,54	-0,43	Granular	Intermediario	Intergranular	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo2	Intergranular
6	100	99	97	86	71	64	74	36	17	18,4	1,449	11	0,80	A-7-5	234	0,20	-0,32	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
7	100	99	99	87	68	58	49	20	10	14,0	1,656	20	0,44	A-7-6	75	0,15	-0,83	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2
8	100	99	98	88	64	56	48	19	9	14,2	1,663	17	0,20	A-7-6	401	0,33	-0,37	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Intergranular	Intergranular
9	100	99	99	93	70	55	44	16	7	16,3	1,778	11	0,25	A-7-5	114	0,19	-0,64	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
10	100	100	99	97	80	70	59	23	16	18,7	1,531	11	1,24	A-7-5	185	0,06	-0,43	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
11	100	99	99	93	75	57	50	25	12	12,7	1,640	6	0,00	A-4	394	0,20	-0,34	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intercoesivo	
12	100	99	96	79	62	54	45	18	7	14,8	1,748	6	0,05	A-7-6	267	0,21	-0,43	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
13	100	100	99	97	79	67	51	17	11	21,8	1,626	4	0,00	A-7-5	227	0,08	-0,41	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
14	100	100	99	97	76	63	43	17	9	15,5	1,543	5	0,00	A-7-5	277	0,16	-0,47	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
15	100	99	99	97	79	68	53	25	15	17,7	1,599	5	0,56	A-7-6	168	0,14	-0,43	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
16	100	100	99	97	77	62	39	15	7	16,7	1,529	4	0,00	A-6	298	0,16	-0,31	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
17	100	100	99	97	76	61	46	21	10	14,2	1,502	6	0,00	A-7-6	246	0,12	-0,40	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
18	100	100	99	95	74	60	46	20	10	15,9	1,496	4	0,00	A-7-6	274	0,17	-0,36	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
19	100	99	98	94	78	50	34	12	4	13,1	1,666	4	0,00	A-6	299	0,17	-0,40	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
20	100	100	99	98	84	59	36	15	7	16,6	1,569	5	0,00	A-6	229	0,16	-0,37	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
21	100	99	99	97	91	73	50	23	15	20,5	1,603	9	0,15	A-7-6	130	0,16	-0,62	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
22	98	96	87	66	39	26	32	0	0	8,2	2,053	19	1,10	A-2-4	375	0,39	-0,31	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
23	100	98	90	67	40	27	32	0	0	9,9	2,056	16	0,60	A-2-4	381	0,47	-0,21	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
24	96	93	85	64	39	26	31	0	0	9,3	2,043	17	0,40	A-2-4	214	0,25	-0,46	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Coesivo	Coesivo	Coesivo2	Coesivo1
25	99	97	90	71	47	35	30	0	0	8,5	2,054	16	0,50	A-2-4	292	0,34	-0,30	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Coesivo2	Intergranular
26	88	81	75	61	39	24	32	0	0	6,5	2,073	20	0,60	A-1-b	578	0,48	-0,27	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular
27	100	96	80	59	37	23	0	0	0	7,9	2,079	20	1,05	A-1-b	240	0,30	-0,44	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Coesivo	Coesivo	Coesivo2	Intergranular
28	99	97	93	77	46	30	33	0	0	9,1	2,011	24	1,15	A-2-4	240	0,20	-0,24	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intergranular	Intergranular	Coesivo2	Intercoesivo
29	100	99	93	74	43	27	0	0	0	6,4	1,988	21	0,70	A-2-4	334	0,29	-0,28	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Coesivo2	Intercoesivo

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	9.5mm #3/8"	4.8mm 4	2.0mm 10	0.42mm 40	0.076mm 200	LL (%)	IP (%)		h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos		3 Grupos			4 Grupos			5 Grupos	
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
30	100	98	85	61	34	19	0	0	0	7,2	2,088	29	0,50	A-1-b	530	0,41	-0,18	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
31	98	97	95	81	50	32	33	0	0	8,3	2,056	16	0,04	A-2-4	343	0,25	-0,23	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo
32	100	97	93	76	46	31	32	0	0	8,0	2,055	16	0,66	A-2-4	262	0,17	-0,19	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intergranular	Coesivo2	Intercoesivo	Intercoesivo	
33	96	93	89	75	41	23	26	0	0	8,3	2,116	26	0,00	A-1-b	542	0,38	-0,07	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Granular	
34	100	98	97	82	49	34	32	0	0	9,2	2,046	19	0,48	A-2-4	207	0,21	-0,28	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Coesivo	Coesivo2	Coesivo1	Coesivo1	
35	98	97	95	77	50	33	31	0	0	8,0	2,065	20	0,90	A-2-4	443	0,48	-0,37	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
36	100	95	89	78	46	22	21	0	0	5,5	2,025	38	0,00	A-1-b	425	0,36	-0,54	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	Intergranular
37	100	98	95	78	48	31	27	0	0	7,8	2,058	25	0,18	A-2-4	382	0,27	-0,31	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo
38	100	99	96	84	55	27	26	0	0	6,6	2,042	36	0,00	A-2-4	459	0,30	-0,27	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo
39	97	86	77	63	36	16	0	0	0	4,6	2,042	36	0,00	A-1-b	538	0,45	-0,27	Granular	Intermediario	Intergranular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
40	99	96	91	76	43	20	24	0	0	4,9	2,027	40	0,00	A-1-b	447	0,27	-0,27	Coesivo	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
41	97	91	85	72	42	19	0	0	0	6,5	2,109	34	0,00	A-1-b	510	0,46	-0,53	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	Intergranular
42	98	92	84	67	40	16	0	0	0	5,7	2,031	45	0,00	A-1-b	450	0,40	-0,38	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
43	98	95	90	73	40	19	0	0	0	6,6	2,062	34	0,02	A-1-b	677	0,55	-0,34	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
44	100	97	94	82	53	27	25	0	0	6,5	2,022	38	0,04	A-2-4	464	0,50	-0,77	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	Coesivo2
45	97	94	86	67	40	20	28	0	0	7,7	2,068	32	0,00	A-1-b	382	0,30	-0,19	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo
46	93	79	70	59	40	21	26	0	0	8,6	2,059	63	0,00	A-1-b	426	0,30	-0,13	Granular	Granular	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo
47	80	61	55	47	28	15	24	0	0	5,2	2,298	86	0,00	A-1-b	807	0,49	-0,09	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
48	77	67	62	54	34	13	0	0	0	3,0	2,259	155	0,00	A-1-b	1.434	0,54	-0,05	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
49	88	82	74	62	37	13	0	0	0	3,4	2,233	97	0,00	A-1-b	1.127	0,54	-0,02	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
50	78	65	60	50	31	17	0	0	0	5,7	2,242	100	0,00	A-1-b	955	0,58	-0,14	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
51	74	56	50	43	26	10	0	0	0	4,1	2,269	112	0,00	A-1-a	956	0,48	-0,09	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
52	84	68	60	50	27	12	0	0	0	4,4	2,286	155	0,00	A-1-a	761	0,43	-0,16	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
53	85	70	62	51	30	11	0	0	0	3,4	2,228	108	0,00	A-1-b	2.008	0,78	-0,02	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
54	61	49	45	39	29	12	0	0	0	5,2	2,268	86	0,00	A-1-a	872	0,49	-0,07	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
55	100	53	37	27	15	5	0	0	0	5,1	2,275	118	0,00	A-1-a	893	0,40	-0,04	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
56	100	54	36	26	14	6	0	0	0	5,0	2,294	118	0,00	A-1-a	973	0,46	-0,05	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
57	100	46	34	27	15	5	0	0	0	5,6	2,207	118	0,00	A-1-a	993	0,46	-0,11	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
58	100	48	36	21	15	6	0	0	0	5,0	2,287	118	0,00	A-1-a	695	0,43	-0,31	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
59	100	56	37	26	13	5	0	0	0	5,2	2,275	118	0,00	A-1-a	926	0,43	-0,04	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

Nº da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos								
	#1"	9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm³)	CBR (%)	Expansão (%)					2 Grupos	3 Grupos	4 Grupos			5 Grupos			
		#3/8"	4	10	40	200												Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2	
60	100	54	40	30	14	5	0	0	0	5,6	2,238	118	0,00	A-1-a	364	0,15	-0,29	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intergranular	Coesivo2	Intercoesivo	
61	100	47	34	26	15	6	0	0	0	5,7	2,265	118	0,00	A-1-a	651	0,23	-0,08	Granular	Granular	Granular	Granular	Granular	Intergranular	Intergranular	Intercoesivo	
62	100	100	100	100	91	62	40	11	6	21,9	1,674	33	0,20	A-4	201	0,29	-0,46	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
63	100	100	100	100	91	63	40	11	6	20,9	1,691	20	0,10	A-7-6	221	0,25	-0,35	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
64	100	98	97	97	83	60	41	12	6	20,2	1,706	22	0,10	A-7-6	245	0,18	-0,27	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
65	100	100	100	100	88	60	39	10	5	19,0	1,698	23	0,20	A-4	460	0,19	-0,10	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
66	100	100	100	100	87	60	28	8	5	19,1	1,703	10	0,20	A-4	347	0,16	-0,22	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Coesivo2	Intercoesivo	
67	100	100	100	100	90	61	38	9	5	20,1	1,702	16	0,10	A-4	297	0,17	-0,21	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Coesivo2	Intercoesivo	
68	100	100	100	100	90	62	39	10	5	20,7	1,702	24	0,10	A-4	242	0,20	-0,28	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
69	100	100	100	99	96	91	65	28	19	18,9	1,742	3	9,80	A-7-5	443	0,17	-0,17	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Intergranular	Intercoesivo	
70	100	100	100	100	100	99	66	26	18	18,7	1,781	3	1,10	A-7-5	207	0,03	-0,38	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
71	100	100	100	100	99	65	35	16	8	12,2	1,934	11	4,20	A-6	861	0,29	-0,29	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
72	100	100	100	100	100	86	59	33	20	19,0	1,797	15	2,70	A-7-5	616	0,23	-0,34	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Intergranular	Intercoesivo	
73	100	100	100	100	97	62	36	22	10	12,2	2,064	24	0,80	A-6	246	0,18	-0,35	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
74	100	100	100	100	99	60	31	15	7	11,5	1,966	17	0,20	A-6	292	0,07	-0,65	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
75	100	100	100	100	99	53	26	11	4	11,5	1,986	35	0,20	A-6	787	0,39	-0,51	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	
76	100	100	100	100	99	49	23	8	3	10,7	2,042	36	0,20	A-4	273	0,19	-0,39	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
77	100	100	100	100	99	39	20	6	1	9,5	2,017	34	0,20	A-4	377	0,19	-0,36	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intercoesivo	
78	100	100	100	100	99	34	17	4	0	8,4	1,991	30	0,00	A-2-4	398	0,26	-0,40	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intercoesivo	
79	100	100	100	100	99	42	21	7	1	8,7	1,982	30	0,10	A-4	518	0,18	-0,24	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
80	100	98	74	61	61	37	40	23	3	13,2	2,026	20	0,70	A-2-6	316	0,39	-0,59	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Coesivo2	Coesivo2	
81	100	100	77	77	76	44	32	14	3	11,1	2,128	59	0,50	A-6	545	0,26	-0,31	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo	
82	98	72	50	33	23	12	22	7	0	7,5	2,190	55	0,00	A-2-4	621	0,36	-0,36	Coesivo	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	
83	97	83	57	34	24	17	24	8	0	9,0	2,140	47	0,00	A-2-4	567	0,34	-0,02	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Intergranular	Intercoesivo
84	96	74	50	33	24	18	24	8	0	9,7	2,030	25	0,00	A-2-4	775	0,44	-0,11	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
85	100	79	52	32	24	13	22	5	0	8,0	2,050	42	0,00	A-1-a	589	0,34	-0,26	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intercoesivo	
86	100	78	52	28	16	9	21	5	0	5,0	2,130	50	0,00	A-1-a	780	0,35	-0,09	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
87	94	73	48	29	20	10	17	3	0	7,0	2,120	107	0,00	A-1-a	549	0,29	-0,29	Coesivo	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intercoesivo	
88	97	77	57	39	30	18	24	6	0	10,0	2,000	42	0,00	A-1-b	831	0,35	-0,11	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
89	98	59	38	27	22	7	0	0	0	6,2	2,210	140	0,00	A-1-a	1.321	0,46	-0,19	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

Nº da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	9.5mm #3/8"	4.8mm 4	2.0mm 10	0.42mm 40	0.076mm 200	LL (%)	IP (%)		hmod (%)	γsmold (g/cm³)	CBR (%)	Expansão (%)					2 Grupos		3 Grupos			4 Grupos			5 Grupos	
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
90	98	76	53	35	25	14	25	8	0	10,0	2,110	53	0,50	A-2-4	1.141	0,44	-0,33	Granular	Intermediario	Intergranular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
91	100	87	67	51	37	18	25	8	0	8,6	2,070	70	0,60	A-2-4	809	0,34	-0,13	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
92	100	99	98	91	69	31	26	9	0	11,6	1,860	64	0,00	A-2-4	719	0,40	-0,18	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Intergranular	Granular	Granular	
93	100	92	58	30	25	13	21	7	0	6,7	2,220	75	0,00	A-2-4	620	0,25	-0,27	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
94	98	89	63	31	22	10	20	6	0	6,0	2,180	85	0,00	A-1-a	797	0,39	-0,28	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
95	97	82	51	30	24	11	19	5	0	8,6	2,080	28	0,00	A-1-a	833	0,37	-0,06	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
96	100	82	60	42	30	18	29	9	0	10,0	2,010	65	0,00	A-2-4	662	0,33	-0,20	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
97	94	65	46	31	24	16	31	11	0	10,0	2,030	85	0,00	A-2-4	608	0,35	-0,26	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
98	100	100	99	95	75	34	21	8	0	10,5	1,900	15	0,00	A-2-6	526	0,19	-0,14	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
99	98	76	58	51	45	23	28	3	0	9,0	1,920	48	0,00	A-1-b	1.025	0,28	-0,14	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
100	97	61	46	41	37	19	25	7	0	10,2	1,990	74	0,00	A-2-4	929	0,29	-0,15	Granular	Intermediario	Intergranular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
101	96	73	64	59	55	33	32	12	0	13,1	1,790	16	0,00	A-2-6	485	0,25	-0,34	Coesivo	Intermediario	Intercoesivo	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
102	100	100	100	98	79	30	30	9	0	12,6	1,878	8	0,60	A-2-4	556	0,22	-0,26	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
103	100	97	96	95	79	14	0	0	0	9,2	1,875	54	0,20	A-2-5	1.400	0,39	-0,04	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	Granular	Granular
104	100	79	74	69	40	15	0	0	0	5,8	2,212	97	0,00	A-2-4	1.222	0,49	-0,01	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
105	100	83	72	65	51	22	0	0	0	7,3	1,937	47	0,10	A-3	560	0,10	-0,08	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo
106	97	83	76	70	58	40	46	14	2	15,6	1,824	8	0,30	A-7-5	410	0,31	-0,41	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
107	100	74	64	60	43	6	0	0	0	4,0	2,196	84	0,00	A-2-4	1.198	0,46	-0,08	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
108	66	44	36	32	23	9	0	0	0	3,0	2,194	68	0,00	A-1-a	488	0,19	-0,14	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
109	94	70	60	55	40	16	0	0	0	3,7	2,161	53	0,00	A-1-b	719	0,44	-0,36	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
110	100	98	94	86	63	32	0	0	0	7,6	1,995	8	0,00	A-2-4	290	0,30	-0,20	Granular	Intermediario	Intergranular	Intercoesivo	Intergranular	Intergranular	Intergranular	Coesivo2	Intercoesivo	Intercoesivo
111	91	74	69	65	45	17	0	0	0	4,7	2,097	53	0,00	A-1-b	578	0,37	-0,18	Granular	Granular	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
112	96	77	71	67	49	20	0	0	0	4,6	2,130	42	0,00	A-1-b	666	0,36	-0,09	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Intergranular	Granular	Granular
113	98	95	92	87	66	28	0	0	0	6,4	1,954	6	0,00	A-2-4	383	0,34	-0,24	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo
114	100	79	72	67	51	23	0	0	0	3,4	2,146	54	0,00	A-2-4	356	0,26	-0,69	Coesivo	Coesivo	Coesivo	Granular	Intergranular	Intercoesivo	Coesivo2	Coesivo2	Coesivo2	Coesivo2
115	81	62	58	54	42	18	0	0	0	3,7	2,154	30	0,00	A-1-b	555	0,33	-0,14	Granular	Granular	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
116	87	70	62	56	41	16	0	0	0	4,3	2,157	72	0,00	A-1-b	755	0,36	-0,10	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
117	91	76	70	65	49	22	0	0	0	4,8	2,172	32	0,00	A-1-b	451	0,29	-0,16	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo
118	100	100	100	100	87	14	0	0	0	6,3	1,914	11	0,00	A-2-4	856	0,38	-0,09	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	Granular	Granular
119	100	100	100	100	89	13	0	0	0	5,1	1,906	12	0,00	A-2-4	831	0,46	-0,31	Granular	Intermediario	Intergranular	Intercoesivo	Intercoesivo	Granular	Intergranular	Intergranular	Intergranular	Intergranular

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos								
							LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos	3 Grupos	4 Grupos			5 Grupos			
	#1"	9.5mm	4.8mm	2.0mm	0.42mm	0.076mm												Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2	
																										#3/8"
120	100	100	100	99	81	48	29	11	3	12,1	1,935	11	0,03	A-6	850	0,49	-0,18	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
121	100	100	100	99	81	48	29	11	3	9,6	1,892	11	0,03	A-6	1.171	0,27	-0,13	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
122	100	100	100	99	81	48	29	11	3	10,2	1,980	11	0,03	A-6	729	0,19	-0,21	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
123	100	100	100	93	74	44	32	6	2	10,5	1,821	13	0,02	A-4	609	0,21	-0,11	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
124	100	100	100	93	74	44	32	6	2	11,8	1,972	13	0,02	A-4	1.084	0,51	-0,14	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
125	100	100	100	99	82	33	28	6	0	10,8	2,026	16	0,00	A-2-4	991	0,40	-0,11	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
126	100	100	100	100	88	5	0	0	0	12,2	1,934	15	0,00	A-3	677	0,18	-0,18	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
127	100	100	100	97	86	22	0	0	0	11,4	1,952	19	0,00	A-2-4	997	0,39	-0,07	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
128	100	95	91	84	62	27	0	0	0	7,3	1,971	10	0,00	A-2-4	249	0,26	-0,45	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Coesivo	Coesivo2	Coesivo1	
129	100	100	100	100	87	14	0	0	0	6,3	1,914	11	0,00	A-2-4	856	0,38	-0,09	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
130	100	100	100	100	89	13	0	0	0	5,1	1,906	12	0,00	A-2-4	831	0,46	-0,31	Granular	Intermediario	Intergranular	Intercoesivo	Intercoesivo	Granular	Intergranular	Intergranular	
131	100	100	100	99	81	48	29	11	3	10,2	1,980	11	0,03	A-6	729	0,19	-0,21	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
132	100	100	100	98	69	19	0	0	0	5,5	2,013	17	0,00	A-2-4	1.054	0,47	-0,01	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
133	100	100	100	93	74	44	32	6	2	10,5	1,821	13	0,02	A-4	609	0,21	-0,11	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
134	100	100	100	99	82	33	28	6	0	10,8	2,026	16	0,00	A-2-4	991	0,40	-0,11	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
135	100	100	100	97	86	22	0	0	0	11,4	1,952	19	0,00	A-2-4	997	0,39	-0,07	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
136	100	100	100	98	74	56	54	27	12	18,4	1,634	9	0,52	A-7-6	139	0,00	-0,39	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
137	100	100	100	98	78	58	60	35	15	18,0	1,735	12	0,37	A-7-6	253	0,14	-0,48	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
138	100	100	100	98	67	45	53	31	8	12,9	1,914	26	0,00	A-7-6	250	0,14	-0,36	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
139	100	100	99	97	77	51	54	31	11	16,5	1,823	16	0,10	A-7-6	120	0,13	-0,61	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
140	100	100	98	96	81	56	65	37	14	17,3	1,816	11	0,10	A-7-6	199	0,13	-0,41	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
141	100	100	99	98	81	59	61	31	15	18,7	1,647	9	0,68	A-7-6	113	0,01	-0,49	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
142	100	100	100	98	75	55	62	37	14	16,3	1,820	17	0,08	A-7-6	174	0,02	-0,42	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
143	100	96	90	80	43	15	0	0	0	8,8	2,039	24	0,07	A-2-4	714	0,43	-0,01	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Granular	Granular	
144	100	96	91	80	44	17	0	0	0	8,2	2,006	9	0,00	A-2-4	603	0,40	-0,09	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Intergranular	Granular	
145	100	100	100	98	74	56	54	27	12	16,5	1,591	9	0,52	A-7-6	339	0,12	-0,16	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Coesivo2	Intercoesivo	
146	100	100	100	98	67	45	53	31	8	11,1	1,742	26	0,00	A-7-6	900	0,23	0,00	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	
147	100	100	98	96	81	56	65	37	14	15,5	1,765	11	0,10	A-7-6	823	0,26	-0,14	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Granular	Granular	Intercoesivo	
148	100	100	100	98	77	48	48	25	8	14,9	1,870	5	0,29	A-7-6	118	0,15	-0,58	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
149	100	100	100	98	79	53	57	31	13	15,0	1,721	18	0,02	A-7-6	652	0,13	-0,13	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos								
							LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos	3 Grupos	4 Grupos			5 Grupos			
	#1"	#3/8"	4	10	40	200												Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2	
																										9.5mm
150	100	100	100	98	78	58	60	35	15	15,6	1,597	12	0,37	A-7-6	873	0,32	-0,13	Granular	Granular	Granular	Coesivo	Intercoesivo	Granular	Granular	Granular	
151	100	100	99	97	77	51	54	31	11	13,4	1,759	16	0,10	A-7-6	829	0,20	-0,01	Granular	Granular	Granular	Coesivo	Intercoesivo	Granular	Granular	Intercoesivo	
152	100	100	99	96	71	46	48	27	8	18,3	1,623	5	1,94	A-7-6	412	0,36	-0,45	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular	
153	100	96	88	79	66	42	44	24	5	13,3	2,068	9	0,00	A-7-5	365	0,34	-0,29	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
154	100	100	99	97	70	54	58	30	13	19,0	1,691	6	0,19	A-7-6	128	0,09	-0,42	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
155	100	100	100	99	70	47	65	37	10	17,2	1,789	14	0,08	A-7-6	163	0,24	-0,51	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
156	100	100	99	97	80	52	44	23	9	15,1	1,822	20	0,43	A-7-6	447	0,12	-0,06	Granular	Granular	Granular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
157	100	100	99	97	75	55	60	34	14	16,7	1,743	19	0,36	A-7-6	354	0,31	-0,57	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intercoesivo	Coesivo2	Coesivo2	
158	100	100	99	96	71	46	48	27	8	13,5	1,825	6	0,24	A-7-6	141	0,12	-0,59	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
159	100	99	96	87	56	28	31	13	0	10,2	1,942	4	0,00	A-2-6	301	0,41	-0,30	Granular	Intermediario	Intergranular	Intercoesivo	Intergranular	Intergranular	Coesivo2	Intergranular	
160	100	100	100	99	62	31	31	18	1	9,5	1,955	6	0,00	A-2-6	282	0,30	-0,40	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular	
161	100	99	97	95	78	58	54	24	12	17,1	1,579	18	0,50	A-7-6	647	0,28	-0,31	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
162	100	99	98	95	74	47	50	28	9	14,8	1,877	18	0,16	A-7-6	130	0,19	-0,54	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo1	Coesivo1	
163	100	98	94	84	46	20	29	12	0	7,8	2,317	11	0,07	A-2-6	423	0,42	-0,32	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
164	100	99	98	91	63	39	44	23	4	14,0	1,798	4	0,99	A-7-6	120	0,38	-0,50	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular	
165	100	100	100	97	76	55	56	27	12	18,0	1,756	9	0,30	A-7-5	84	0,22	-0,50	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
166	100	99	98	96	73	56	63	35	14	15,2	1,799	8	0,00	A-7-6	81	0,26	-0,69	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2
167	100	100	98	95	76	63	59	26	15	18,0	1,599	5	1,21	A-7-6	95	0,09	-0,49	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
168	100	97	90	82	69	46	45	24	7	14,6	1,734	15	0,04	A-7-6	94	0,27	-0,82	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo1	Coesivo2	
169	100	100	99	97	75	52	50	26	10	13,7	1,792	6	0,66	A-7-6	95	0,10	-0,46	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1
170	100	100	100	99	69	48	65	34	11	10,7	1,909	22	0,54	A-7-5	197	0,26	-0,59	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
171	100	100	100	98	66	45	44	20	5	10,1	1,960	16	0,00	A-7-6	152	0,24	-0,41	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
172	100	100	98	95	79	54	55	31	13	18,2	1,792	10	0,03	A-7-6	254	0,17	-0,43	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
173	100	100	99	97	68	42	42	19	4	10,6	1,816	7	0,81	A-7-6	222	0,13	-0,36	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
174	86	57	46	35	17	5	0	0	0	2,9	2,270	120	0,00	A-1-a	1.253	0,51	-0,28	Granular	Intermediario	Intergranular	Granular	Granular	Granular	Granular	Granular	Granular
175	100	98	95	84	42	16	0	0	0	7,4	2,096	57	0,00	A-1-b	677	0,46	-0,18	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Intergranular	Granular	Granular
176	100	100	100	97	63	18	0	0	0	5,8	1,893	28	0,00	A-2-4	702	0,42	-0,02	Granular	Granular	Granular	Intercoesivo	Intergranular	Granular	Granular	Granular	Granular
177	100	100	100	97	63	13	0	0	0	7,4	2,017	17	0,00	A-2-4	728	0,41	-0,20	Granular	Granular	Granular	Intercoesivo	Intergranular	Granular	Intergranular	Granular	Granular
178	100	100	99	97	67	45	42	21	5	15,2	1,784	7	0,36	A-7-5	257	0,28	-0,46	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
179	100	100	99	95	72	50	39	12	4	18,8	1,626	9	0,54	A-6	247	0,01	-0,30	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					Especialista	Especialista	Especialista	4 Grupos					5 Grupos	
																					Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
																										2 Grupos	3 Grupos
#3/8"	4	10	40	200																							
180	100	99	93	78	24	9	22	0	0	11,3	1,918	31	0,00	A-2-4	481	0,33	-0,17	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo	
181	100	100	99	93	51	34	46	18	2	18,0	1,709	10	0,23	A-2-7	182	0,16	-0,43	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1		
182	100	100	99	97	74	49	39	14	4	16,1	1,766	7	0,57	A-6	227	0,08	-0,39	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
183	100	100	99	94	73	46	40	15	4	17,4	1,736	8	0,63	A-6	179	0,08	-0,47	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
184	100	100	99	93	59	34	0	0	0	17,3	1,704	5	0,50	A-2-4	138	0,39	-0,50	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular		
185	100	97	91	74	42	33	37	11	0	10,8	1,956	9	0,37	A-2-6	243	0,22	-0,29	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Coesivo	Coesivo2	Coesivo1		
186	100	100	100	76	31	5	0	0	0	8,0	2,060	54	0,00	A-1-b	601	0,48	-0,10	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Granular	Granular		
187	100	78	62	48	6	1	0	0	0	7,4	2,033	57	0,00	A-1-a	551	0,45	-0,26	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular		
188	100	100	100	69	29	3	0	0	0	9,1	1,906	59	0,00	A-1-b	477	0,40	-0,11	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Granular		
189	100	100	100	78	23	3	0	0	0	10,0	1,910	58	0,00	A-1-b	512	0,35	-0,15	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo		
190	100	100	100	74	28	5	0	0	0	9,5	1,954	60	0,00	A-1-b	441	0,32	-0,24	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo		
191	100	100	84	73	38	34	0	0	0	10,1	1,880	20	0,00	A-2-4	464	0,35	-0,18	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo		
192	100	100	94	74	22	1	0	0	0	8,8	1,896	33	0,00	A-1-b	566	0,46	-0,11	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Intergranular	Granular		
193	100	100	99	84	33	4	0	0	0	9,4	1,859	25	0,00	A-1-b	560	0,46	-0,18	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Granular		
194	100	100	94	71	32	5	0	0	0	8,6	2,048	28	0,00	A-1-b	528	0,41	-0,06	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Intergranular	Granular		
195	100	100	98	72	28	5	0	0	0	7,2	1,978	25	0,00	A-1-b	614	0,41	-0,16	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Granular		
196	100	100	100	72	25	3	0	0	0	9,4	1,946	26	0,00	A-1-b	597	0,42	-0,18	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Granular		
197	100	78	65	48	19	3	0	0	0	7,5	2,186	82	0,00	A-1-a	726	0,44	-0,19	Granular	Granular	Granular	Granular	Granular	Granular	Intergranular	Granular		
198	100	75	51	37	16	2	0	0	0	6,7	2,268	96	0,00	A-1-a	657	0,32	-0,16	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intercoesivo		
199	100	81	65	49	21	3	0	0	0	7,0	2,256	68	0,00	A-1-a	693	0,38	-0,07	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular		
200	100	70	61	53	27	4	0	0	0	4,9	2,145	40	0,00	A-1-a	847	0,46	-0,12	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular		
201	100	77	65	53	30	4	0	0	0	5,6	2,150	79	0,00	A-1-a	969	0,44	-0,04	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular		
202	100	52	36	24	8	1	0	0	0	7,5	2,136	72	0,00	A-1-a	483	0,39	-0,15	Granular	Granular	Granular	Granular	Granular	Intergranular	Intergranular	Intercoesivo		
203	100	100	98	80	23	4	0	0	0	8,6	1,908	31	0,00	A-1-b	614	0,41	-0,03	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Granular	Granular		
204	100	100	95	90	40	6	0	0	0	8,8	1,954	27	0,00	A-1-b	606	0,56	-0,12	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Granular	Granular		
205	100	83	69	57	26	5	0	0	0	6,5	2,150	50	0,00	A-1-a	810	0,48	-0,12	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular		
206	100	99	97	77	26	9	0	0	0	9,7	1,912	20	0,00	A-1-b	451	0,40	-0,10	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Granular		
207	100	98	91	68	31	17	39	8	0	10,6	1,985	12	0,35	A-2-4	404	0,47	-0,19	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		
208	100	97	90	69	37	31	38	6	0	10,4	1,970	12	0,25	A-2-4	297	0,44	-0,77	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Coesivo2		
209	100	78	62	48	6	1	0	0	0	6,2	2,140	83	0,00	A-1-a	815	0,44	-0,08	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular		

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	9.5mm #3/8"	4.8mm 4	2.0mm 10	0.42mm 40	0.076mm 200	LL (%)	IP (%)		h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					Especialista	Especialista	Especialista	4 Grupos					5 Grupos	
																					Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
																										2 Grupos	3 Grupos
210	97	55	34	31	13	2	0	0	0	4,8	2,088	100	0,00	A-1-a	1.051	0,48	-0,06	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	
211	100	64	39	22	8	1	0	0	0	3,8	2,096	76	0,00	A-1-a	678	0,34	-0,02	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	
212	100	78	65	48	19	3	0	0	0	5,9	2,227	100	0,00	A-1-a	938	0,49	-0,09	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	
213	100	75	51	37	16	2	0	0	0	6,0	2,293	100	0,00	A-1-a	944	0,47	-0,06	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	
214	100	77	65	53	30	4	0	0	0	4,9	2,190	86	0,00	A-1-a	871	0,53	-0,15	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	
215	100	52	36	24	8	1	0	0	0	6,8	2,230	82	0,00	A-1-a	772	0,46	-0,10	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	
216	100	83	69	57	26	5	0	0	0	6,3	2,190	82	0,00	A-1-a	938	0,54	-0,13	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular	
217	100	94	91	87	37	21	0	0	0	9,6	1,910	24	0,07	A-1-b	329	0,03	-0,31	Coesivo	Coesivo	Coesivo	Intergranular	Intergranular	Coesivo	Coesivo2	Coesivo1		
218	100	98	93	87	39	17	0	0	0	9,7	1,924	20	0,05	A-1-b	660	0,46	-0,54	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	
219	100	100	100	94	77	61	57	23	13	16,2	1,629	11	1,80	A-7-6	235	0,17	-0,58	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
220	100	97	92	81	39	21	26	7	0	10,1	1,999	24	0,09	A-2-4	1.269	0,42	-0,01	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Granular	Granular	Granular	
221	100	100	99	95	55	39	49	18	3	15,5	1,795	13	0,78	A-7-5	129	0,28	-0,56	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1		
222	80	78	76	71	30	15	0	0	0	9,9	1,943	19	0,03	A-1-b	490	0,43	-0,25	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	
223	100	98	97	95	68	52	51	13	6	13,7	1,648	14	0,02	A-7-5	117	0,19	-0,65	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo1	Coesivo1		
224	96	85	83	77	38	20	0	0	0	9,7	1,928	24	0,08	A-1-b	471	0,43	-0,26	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
225	100	92	89	84	44	22	0	0	0	10,7	1,911	18	0,04	A-1-b	546	0,50	-0,26	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
226	100	100	93	80	39	19	0	0	0	11,2	1,971	21	0,13	A-1-b	418	0,46	-0,25	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
227	100	98	98	97	65	49	60	23	9	14,4	1,462	6	0,18	A-7-5	200	0,21	-0,58	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
228	100	87	84	79	37	11	0	0	0	8,8	1,952	42	0,00	A-1-b	558	0,47	-0,24	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
229	100	91	89	85	47	30	42	17	1	11,0	1,787	12	0,04	A-2-7	208	0,25	-0,54	Coesivo	Coesivo	Coesivo	Intergranular	Intergranular	Coesivo	Coesivo2	Coesivo1		
230	100	98	96	91	47	26	48	16	1	13,0	1,671	15	0,19	A-2-7	142	0,28	-0,65	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo2		
231	100	97	96	91	47	21	0	0	0	8,2	1,968	24	0,01	A-1-b	582	0,38	-0,13	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Granular	
232	100	100	92	87	49	31	29	5	0	11,3	1,886	21	0,55	A-2-4	507	0,51	-0,31	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
233	100	88	84	78	39	15	0	0	0	10,0	1,921	22	0,07	A-1-b	468	0,40	-0,25	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
234	100	99	97	96	65	36	0	0	0	10,7	1,815	3	0,62	A-2-6	132	0,40	-0,47	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular	
235	100	95	91	87	47	19	0	0	0	10,2	1,876	26	0,04	A-1-b	522	0,46	-0,30	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
236	100	98	95	91	55	26	0	0	0	9,8	1,888	29	0,28	A-2-4	451	0,36	-0,24	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo	
237	100	90	86	79	36	17	0	0	0	10,0	2,012	30	0,00	A-1-b	548	0,45	-0,27	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
238	100	91	89	83	44	25	0	7	0	9,6	1,964	20	0,04	A-2-4	410	0,41	-0,31	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
239	94	92	88	82	40	16	0	0	0	8,7	1,919	25	0,00	A-1-b	562	0,34	-0,14	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo	

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	9.5mm #3/8"	4.8mm 4	2.0mm 10	0.42mm 40	0.076mm 200	LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos		3 Grupos			4 Grupos			5 Grupos	
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
240	93	88	86	82	39	18	0	0	0	9,9	1,857	22	0,16	A-1-b	235	0,33	-0,56	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intergranular	Intercoesivo	Coesivo2	Coesivo2	
241	100	97	94	88	43	17	0	0	0	6,6	1,885	23	0,07	A-1-b	436	0,36	-0,23	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo	
242	100	94	92	85	41	22	28	7	0	9,8	1,912	16	0,03	A-2-4	262	0,35	-0,58	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Coesivo2	Coesivo2		
243	95	83	79	71	28	12	0	0	0	9,6	1,980	39	0,02	A-1-b	473	0,47	-0,41	Granular	Intermediario	Intergranular	Granular	Intergranular	Intergranular	Intercoesivo	Intergranular		
244	100	97	97	91	58	34	0	8	0	12,0	1,823	14	0,24	A-2-5	284	0,46	-0,48	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular		
245	82	69	65	61	27	11	0	0	0	9,5	1,969	32	0,05	A-1-b	436	0,44	-0,44	Granular	Intermediario	Intergranular	Granular	Granular	Intercoesivo	Intercoesivo	Intergranular		
246	100	95	91	87	41	13	0	0	0	9,1	1,927	27	0,07	A-1-b	421	0,41	-0,37	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		
247	100	97	94	88	43	17	0	0	0	7,1	1,909	23	0,07	A-1-b	429	0,42	-0,35	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		
248	95	89	84	75	40	23	0	0	0	8,2	1,803	37	0,02	A-1-b	227	0,19	-0,47	Coesivo	Coesivo	Coesivo	Intergranular	Intergranular	Coesivo	Coesivo2	Coesivo1		
249	100	98	96	92	52	28	36	9	0	9,5	1,874	14	0,68	A-2-4	296	0,39	-0,37	Granular	Intermediario	Intergranular	Intercoesivo	Intergranular	Intergranular	Coesivo2	Intergranular		
250	100	97	93	90	64	37	46	14	1	11,0	1,750	16	0,51	A-7-5	170	0,18	-0,53	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1		
251	100	92	89	86	43	10	0	0	0	11,4	1,903	28	0,06	A-1-b	449	0,38	-0,24	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		
252	100	90	88	84	40	23	31	8	0	9,6	1,940	24	0,02	A-2-4	450	0,34	-0,17	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo		
253	100	94	90	85	47	25	32	10	0	9,7	1,905	29	0,07	A-2-4	348	0,41	-0,43	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Coesivo2	Intergranular		
254	100	84	81	77	40	13	0	0	0	7,2	1,972	75	0,00	A-1-b	577	0,34	-0,14	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo		
255	100	88	85	80	34	16	26	4	0	7,5	1,945	44	0,00	A-1-b	504	0,37	-0,26	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		
256	100	77	74	70	33	16	0	0	0	8,0	2,041	55	0,00	A-1-b	563	0,43	-0,29	Granular	Intermediario	Intergranular	Granular	Intergranular	Intergranular	Intergranular	Intergranular		
257	92	81	78	74	28	12	0	0	0	8,9	2,018	47	0,00	A-1-b	523	0,40	-0,31	Granular	Intermediario	Intergranular	Granular	Intergranular	Intergranular	Intergranular	Intergranular		
258	96	86	83	79	46	25	0	0	0	9,2	1,969	40	0,03	A-1-b	575	0,42	-0,21	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		
259	100	100	100	96	86	54	33	14	5	14,8	1,755	7	2,40	A-6	152	0,38	-0,43	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular		
260	100	100	100	99	94	56	36	16	7	16,1	1,739	8	2,00	A-6	138	0,30	-0,41	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
261	100	100	100	97	90	52	33	12	4	16,9	1,708	6	2,15	A-6	118	0,23	-0,44	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
262	100	100	100	99	97	51	34	10	3	17,3	1,651	12	1,10	A-4	217	0,45	-0,31	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular		
263	100	100	100	98	91	55	39	19	8	15,2	1,658	3	5,90	A-6	119	0,33	-0,44	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intercoesivo	Coesivo2	Intergranular		
264	100	100	100	98	92	60	35	10	5	15,2	1,756	4	4,00	A-4	130	0,33	-0,38	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Intergranular		
265	100	100	100	98	89	49	32	14	4	16,7	1,747	9	2,20	A-6	212	0,44	-0,36	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular		
266	100	100	100	97	91	55	36	16	6	17,3	1,783	15	0,80	A-6	126	0,44	-0,67	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Coesivo2		
267	100	100	100	98	91	51	0	0	3	18,4	1,692	10	0,88	A-4	182	0,49	-0,29	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular		
268	100	100	100	97	88	52	30	6	3	13,2	1,641	3	4,70	A-4	118	0,30	-0,42	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1		
269	100	100	100	97	91	61	38	17	8	19,2	1,674	2	4,00	A-6	91	0,34	-0,44	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intercoesivo	Coesivo2	Intergranular		

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

Nº da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	#3/8"	4	10	40	200	LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos		3 Grupos			4 Grupos			5 Grupos	
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
270	100	100	100	99	91	56	28	6	4	16,2	1,732	7	2,40	A-4	197	0,42	-0,34	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular		
271	100	100	100	96	88	52	27	11	4	12,7	1,769	4	4,20	A-6	172	0,39	-0,45	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular		
272	100	100	100	99	95	62	36	10	5	17,3	1,682	4	2,90	A-4	149	0,46	-0,47	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular		
273	100	100	100	98	95	63	34	14	7	19,3	1,701	5	2,50	A-6	199	0,35	-0,20	Granular	Intermediario	Intergranular	Coesivo	Coesivo	Intergranular	Coesivo2	Intercoesivo		
274	100	100	100	99	93	55	35	10	4	17,5	1,734	5	3,10	A-4	161	0,41	-0,47	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular		
275	100	100	100	96	87	50	31	9	3	14,2	1,758	7	2,60	A-4	264	0,32	-0,29	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular		
276	100	100	100	96	87	45	28	11	2	16,2	1,785	11	0,44	A-6	303	0,54	-0,34	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intercoesivo	Intergranular		
277	100	100	100	99	93	73	62	32	19	26,2	1,473			A-7-6	96	0,07	-0,49	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
278	100	100	100	100	91	69	74	43	18	26,3	1,452			A-7-6	76	0,07	-0,50	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
279	100	100	100	100	97	77	79	49	20	28,5	1,490			A-7-6	68	0,09	-0,67	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
280	100	100	100	98	88	71	74	37	19	26,8	1,453			A-7-5	74	0,06	-0,54	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
281	100	100	100	100	95	77	62	29	20	24,9	1,505			A-7-5	175	0,17	-0,48	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
282	100	100	100	97	83	67	68	36	18	25,0	1,466			A-7-5	102	0,08	-0,47	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
283	100	100	100	99	87	70	66	37	19	25,0	1,501			A-7-6	93	0,22	-0,79	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2		
284	100	100	99	98	88	74	74	42	20	27,7	1,462			A-7-6	72	0,03	-0,51	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
285	100	100	98	97	94	67	74	46	18	25,6	1,478			A-7-6	90	0,09	-0,53	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
286	100	100	99	97	85	66	90	57	17	26,8	1,480			A-7-5	87	0,11	-0,56	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
287	100	100	99	98	86	63	70	44	16	17,8	1,670			A-7-6	137	0,11	-0,60	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
288	100	100	99	98	96	80	81	48	20	27,5	1,439			A-7-5	78	0,06	-0,72	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
289	100	100	100	99	92	71	80	46	19	30,9	1,412			A-7-5	74	0,04	-0,58	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
290	100	100	100	99	94	81	66	38	20	25,9	1,482			A-7-6	129	0,07	-0,47	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
291	100	100	99	98	94	61	74	46	16	26,4	1,503			A-7-6	126	0,20	-0,60	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
292	100	100	100	99	98	84	64	31	20	32,2	1,386			A-7-5	83	0,11	-0,55	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
293	100	100	99	98	96	91	78	45	20	31,1	1,326			A-7-5	142	0,14	-0,49	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
294	100	100	100	98	95	86	55	27	18	29,6	1,462			A-7-6	141	0,14	-0,50	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
295	100	100	99	95	85	63	35	12	7	21,3	1,722			A-4	159	0,34	-0,32	Granular	Intermediario	Intergranular	Coesivo	Coesivo	Intergranular	Coesivo2	Intergranular		
296	100	100	99	99	95	70	57	26	16	26,7	1,454			A-7-5	84	0,19	-0,55	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
297	100	99	98	95	81	69	49	21	13	25,5	1,496			A-6	341	0,27	-0,36	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Coesivo2	Intercoesivo		
298	100	100	100	99	98	90	64	31	20	28,4	1,465			A-7-5	32	0,03	-0,71	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
299	100	100	100	99	95	82	50	19	18	29,8	1,355			A-7-5	196	0,26	-0,38	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

Nº da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	#3/8"	4	10	40	200	LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos		3 Grupos			4 Grupos			5 Grupos	
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
300	100	100	100	100	99	45	33	13	3	14,3	1,762			A-2-6	286	0,22	-0,42	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
301	100	100	99	96	85	74	72	34	20	29,3	1,435			A-7-5	118	0,16	-0,45	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
302	100	100	100	100	93	79	50	16	13	27,5	1,405			A-6	179	0,16	-0,40	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
303	100	100	100	99	96	85	65	34	20	29,0	1,381			A-7-5	83	0,11	-0,52	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
304	100	100	100	99	91	70	70	37	19	27,4	1,458			A-7-5	98	0,16	-0,50	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
305	100	100	100	99	96	77	51	27	17	25,6	1,497			A-7-5	104	0,09	-0,51	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
306	100	100	100	98	94	71	58	27	17	26,5	1,447			A-7-5	86	0,09	-0,51	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
307	100	100	99	97	90	64	49	20	11	25,0	1,508			A-5	93	0,13	-0,67	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
308	100	100	100	99	93	73	62	32	19	23,0	1,510			A-7-6	233	0,09	-0,58	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
309	100	100	100	100	91	69	74	43	18	23,2	1,487			A-7-6	151	0,01	-0,60	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
310	100	100	100	99	87	70	66	37	19	23,5	1,580			A-7-6	146	0,10	-0,52	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
311	100	100	99	98	96	80	81	48	20	25,7	1,478			A-7-5	359	0,09	-0,24	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Intergranular	Coesivo2	Intercoesivo	
312	100	100	99	98	96	91	78	45	20	30,0	1,336			A-7-5	269	0,08	-0,25	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
313	100	100	100	98	95	86	55	27	18	27,3	1,520			A-7-6	223	0,13	-0,33	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
314	100	100	99	95	85	63	35	12	7	17,4	1,737			A-4	176	0,23	-0,37	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
315	100	99	98	95	81	69	49	21	13	23,6	1,510			A-6	447	0,16	-0,28	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Intergranular	Intercoesivo		
316	100	100	100	99	95	82	50	19	18	27,0	1,388			A-7-5	242	0,11	-0,36	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
317	100	100	100	100	99	45	33	13	3	12,1	1,796			A-2-6	456	0,14	-0,24	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo		
318	100	100	100	100	93	79	50	16	13	25,9	1,521			A-6	236	0,08	-0,40	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
319	100	100	100	99	96	77	51	27	17	21,6	1,548			A-7-5	199	0,01	-0,53	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
320	100	100	100	98	94	71	58	27	17	23,4	1,483			A-7-5	168	0,09	-0,46	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
321	100	100	99	97	90	64	49	20	11	21,0	1,573			A-5	220	0,01	-0,34	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
322	100	100	100	99	89	55	49	13	8	22,6	1,675			A-7-5	168	0,18	-0,51	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
323	100	99	96	92	90	81	54	17	14	24,3	1,640			A-7-5	79	0,21	-0,76	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2	
324	100	100	100	99	96	75	49	15	12	22,8	1,676			A-7-5	84	0,25	-0,67	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2	
325	100	100	100	100	93	54	45	12	9	25,2	1,530			A-7-5	356	0,11	-0,43	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
326	100	100	100	99	96	90	54	16	13	24,8	1,531			A-7-5	98	0,06	-0,63	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
327	100	100	100	100	98	73	48	17	17	19,0	1,750			A-7-5	284	0,00	-0,26	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
328	100	100	99	98	93	70	64	24	18	24,6	1,640			A-7-5	46	0,07	-0,78	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2	
329	100	100	100	98	86	57	53	17	11	23,7	1,630			A-7-5	277	0,08	-0,35	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

Nº da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos										
	#1"	9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos		3 Grupos			4 Grupos			5 Grupos		
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2			
330	100	100	100	99	87	61	59	21	14	23,6	1,526			A-7-5	311	0,00	-0,32	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1
331	100	100	100	99	87	64	74	29	17	24,2	1,620			A-7-5	26	0,00	-0,98	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2
332	100	98	94	79	60	42	63	24	9	19,2	1,710			A-7-5	80	0,12	-0,61	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
333	100	100	99	97	93	80	69	24	18	25,4	1,625			A-7-5	51	0,06	-0,68	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
334	100	100	100	99	96	79	83	34	20	28,0	1,540			A-7-5	35	0,03	-0,79	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2	
335	100	100	100	99	93	75	52	15	12	21,1	1,840			A-7-5	130	0,16	-0,59	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
336	100	100	100	98	80	66	69	30		23,2	1,537			A-7-6	79	0,12	-0,60	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
337	93	77	68	57	32	16	0	0	0	7,8	2,125			A-2-4	477	0,38	-0,27	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
338	100	99	96	89	63	28	0	0	0	12,8	1,935			A-2-4	238	0,37	-0,42	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular		
339	100	100	100	100	92	77	69	38	20	25,6	1,548			A-7-5	292	0,27	-0,61	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo2		
340	84	76	72	69	49	16	0	0	0	12,7	1,886			A-2-4	208	0,61	-0,63	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2		
341	100	100	100	100	91	54	55	29	13	18,7	1,748			A-7-6	167	0,19	-0,65	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
342	100	100	100	100	86	66	61	31	17	19,6	1,645			A-7-6	334	0,14	-0,51	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
343	100	100	100	97	71	51	68	34	12	19,0	1,671			A-7-5	114	0,11	-0,60	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1		
344	100	100	99	98	83	55	38	19	7	16,4	1,818			A-6	127	0,27	-0,69	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2		
345	100	100	100	99	91	79	94	56	20	29,7	1,470			A-7-5	50	0,04	-0,97	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2		
346	100	100	100	100	99	77	39	14		26,9	1,373	12		A-6	276	0,35	-0,36	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Coesivo2	Intergranular			
347	100	100	100	100	97	65	39	13		25,8	1,304	13		A-7-6	203	0,13	-0,34	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1			
348	100	100	100	100	99	77	39	14		24,4	1,485	12		A-6	378	0,22	-0,39	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intergranular	Coesivo2	Intercoesivo			
349	100	100	100	100	97	65	39	13		25,3	1,400	13		A-7-6	169	0,05	-0,32	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1			
350	100	100	100	100	99	77	39	14		23,2	1,596	12		A-6	391	0,49	-0,89	Coesivo	Intermediario	Intercoesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2		
351	100	97	93	81	49	26	15	7		9,7	1,946			A-2-4	285	0,28	-0,29	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intergranular	Coesivo2	Intercoesivo			
352	100	100	100	95	70	48	61	39		17,0	1,779			A-7-6	211	0,09	-0,38	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1			
353	100	87	80	65	38	17	0	0		7,9	2,104			A-1-b	883	0,54	-0,17	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Granular	Granular	Granular		
354	100	99	97	87	56	24	27	0		9,1	2,019			A-2-4	421	0,43	-0,21	Granular	Granular	Granular	Intercoesivo	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		
355	100	100	99	97	79	61	46	18		18,1	1,755			A-7-6	243	0,08	-0,44	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1			
356	100	97	93	85	60	14	0	0		8,4	2,013			A-2-4	477	0,53	-0,28	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		
357	100	97	93	81	40	26	39	9		8,4	2,028			A-2-4	296	0,26	-0,32	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intergranular	Coesivo2	Intercoesivo			
358	100	98	93	75	35	18	26	8		6,7	1,993			A-2-4	691	0,42	-0,14	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Intergranular	Intergranular	Granular		
359	100	100	97	74	37	13	0	0		5,1	1,904			A-1-b	591	0,44	-0,20	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Granular		

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos							
	#1"	#3/8"	4	10	40	200	LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos	3 Grupos	4 Grupos			5 Grupos		
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2
360	100	99	97	85	60	38	0	0	11,8	1,813			A-4	178	0,30	-0,34	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular	
361	100	99	96	86	60	43	39	17	15,5	1,842			A-6	133	0,34	-0,33	Granular	Intermediario	Intergranular	Intercoesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular	
362	100	99	99	97	81	62	59	33	19,3	1,733			A-7-6	163	0,04	-0,62	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
363	100	100	99	96	77	50	47	24	13,0	1,712			A-7-6	588	0,17	-0,27	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intercoesivo	
364	100	100	99	96	73	50	63	39	15,6	1,857			A-7-6	267	0,24	-0,48	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
365	100	100	99	97	67	55	58	30	15,6	1,835			A-7-6	183	0,04	-0,39	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
366	100	100	99	94	62	38	33	14	13,3	1,889			A-6	365	0,40	-0,23	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intergranular	
367	100	99	96	90	57	31	30	11	11,9	1,842			A-2-6	348	0,45	-0,33	Granular	Intermediario	Intergranular	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Intergranular	
368	100	99	97	92	60	33	30	14	11,7	1,824			A-2-6	287	0,28	-0,34	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	Coesivo2	Intercoesivo	
369	100	99	97	91	58	29	29	15	12,4	1,866			A-2-6	325	0,44	-0,45	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular	
370	100	100	98	93	56	30	29	12	11,9	1,842			A-2-6	284	0,39	-0,48	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Intergranular	
371	100	100	100	97	68	38	34	14	13,0	1,862			A-6	174	0,19	-0,59	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
372	100	96	91	80	50	37	44	21	12,0	1,999			A-7-6	255	0,38	-0,44	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Coesivo2	Intergranular	
373	100	100	100	97	71	36	35	18	12,4	1,867			A-7-6	312	0,23	-0,44	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
374	100	96	92	82	54	35	40	18	10,4	2,016			A-7-6	378	0,27	-0,50	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Coesivo2	Coesivo2	
375	100	94	90	80	55	34	46	27	11,5	2,002			A-2-7	314	0,38	-0,43	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Coesivo2	Intergranular	
376	100	100	100	99	90	74	78	47	25,9	1,519			A-7-5	361	0,07	-0,33	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1	
377	100	92	85	78	66	48	40	20	16,7	1,875			A-6	405	0,33	-0,45	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Coesivo2	Intergranular	
378	100	100	100	98	50	16	0	0	11,1	1,932			A-2-4	740	0,45	-0,08	Granular	Granular	Granular	Intercoesivo	Intergranular	Granular	Granular	Granular	
379	100	100	100	99	68	19	0	0	9,6	2,009			A-2-4	591	0,44	-0,23	Granular	Intermediario	Intergranular	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Intergranular	
380	100	100	100	99	76	44	29	13	9,4	2,064			A-6	402	0,31	-0,36	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intergranular	
381	100	100	100	100	95	55	21	2	13,9	1,888			A-4	301	0,28	-0,54	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
382	100	100	99	97	94	77	44	21	18,3	1,791			A-7-6	61	0,13	-0,86	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2	
383	100	100	100	100	95	16	0	0	8,8	2,007			A-2-4	628	0,41	-0,21	Granular	Intermediario	Intergranular	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Granular	
384	100	100	100	99	94	48	21	6	10,2	2,062			A-4	331	0,40	-0,35	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Coesivo2	Intergranular	
385	100	100	99	97	88	45	28	11	11,3	2,002			A-6	316	0,31	-0,54	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Coesivo2	
386	100	100	100	99	52	23	32	13	9,5	2,081			A-2-6	581	0,48	-0,34	Granular	Intermediario	Intergranular	Intercoesivo	Intergranular	Intergranular	Intergranular	Intergranular	
387	100	100	99	97	89	55	32	14	13,5	1,931			A-6	153	0,23	-0,64	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1	
388	100	100	99	98	94	84	58	22	22,8	1,845			A-7-5	154	0,22	-0,66	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
389	100	100	100	100	77	30	0	0	13,5	1,796			A-2-4	778	0,50	-0,22	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular	

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	#3/8"	4	10	40	200	LL (%)	IP (%)		h _{mol} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos		3 Grupos			4 Grupos			5 Grupos	
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
390	100	100	99	97	85	27	0	0	0	8,5	2,086			A-2-4	688	0,46	-0,21	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Granular		
391	100	100	100	99	91	68	32	8	7	18,1	1,758			A-4	229	0,19	-0,49	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
392	100	100	100	97	88	55	33	13	5	14,3	1,882			A-6	182	0,27	-0,58	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1		
393	100	100	99	94	81	49	26	9	3	12,7	1,953			A-4	141	0,24	-0,77	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo1	Coesivo2		
394	100	100	100	100	99	31	21	5	0	11,4	2,007			A-2-4	512	0,51	-0,35	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intergranular		
395	100	100	100	96	87	48	38	15	4	16,7	1,719	8	0,13	A-6	79	0,35	-0,99	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo1	Coesivo2		
396	100	100	100	71	57	31	0	0	0	10,5	1,936	17	0,37	A-2-4	446	0,49	-0,49	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Intergranular		
397	100	100	68	45	35	20	25	5	0	9,0	1,885	12	0,13	A-2-4	469	0,43	-0,78	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Coesivo2		
398	100	100	100	97	90	45	24	5	2	11,0	1,830	12	0,08	A-5	529	0,53	-0,31	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intergranular		
399	100	100	60	32	25	17	29	6	0	10,4	1,900	17	0,00	A-2-4	1.002	0,51	-0,15	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular		
400	100	100	79	59	51	39	34	7	1	12,7	1,868	13	0,00	A-4	249	0,25	-0,65	Coesivo	Coesivo	Coesivo	Intergranular	Intergranular	Coesivo	Coesivo2	Coesivo2		
401	100	100	100	90	84	60	49	19	10	15,7	1,659	14	0,13	A-7-6	185	0,23	-0,51	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo1		
402	100	100	100	75	60	41	34	9	2	13,1	1,945	11	0,17	A-4	244	0,33	-0,73	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	Coesivo2		
403	100	75	45	34	29	16	24	5	0	9,1	1,878	9	0,05	A-1-a	769	0,54	-0,57	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Intercoesivo	Intergranular		
404	100	100	74	64	59	32	27	8	0	7,6	1,750	22	0,00	A-2-4	1.026	0,36	-0,09	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Granular	Granular		
405	100	77	47	33	26	16	28	6	0	10,6	1,886	36	0,19	A-2-4	794	0,49	-0,47	Granular	Intermediario	Intergranular	Granular	Granular	Intercoesivo	Intercoesivo	Intergranular		
406	100	100	100	99	94	41	0	0	0	9,4	1,876	12	0,11	A-4	479	0,54	-0,54	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular		
407	100	100	63	59	55	19	0	0	0	8,0	2,056	24	0,00	A-2-4	817	0,30	-0,25	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intercoesivo		
408	100	100	52	33	27	20	24	5	0	7,8	1,911	22	0,00	A-1-a	450	0,37	-0,71	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Intercoesivo	Coesivo2		
409	100	94	64	38	30	19	26	4	0	7,9	1,804	24	0,13	A-1-a	368	0,40	-0,64	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Intercoesivo	Coesivo2		
410	100	100	100	99	94	28	0	0	0	7,5	1,857	35	0,00	A-2-4	841	0,50	-0,16	Granular	Granular	Granular	Intercoesivo	Intercoesivo	Granular	Granular	Granular		
411	100	100	81	62	47	24	31	11	0	11,5	1,799	8	0,14	A-2-6	629	0,54	-0,97	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Coesivo2		
412	100	100	63	37	27	14	0	0	0	9,2	1,926	16	0,00	A-1-a	526	0,60	-0,95	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Intercoesivo	Coesivo2		
413	100	100	82	72	47	27	34	9	0	17,3	1,675	13	0,12	A-2-4	101	0,24	-0,74	Coesivo	Coesivo	Coesivo	Intergranular	Intergranular	Coesivo	Coesivo1	Coesivo2		
414	100	100	70	51	40	15	30	10	0	11,2	1,929	10	0,00	A-2-4	397	0,39	-0,74	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Coesivo2		
415	100	89	60	31	20	16	41	11	0	11,2	1,818	30	0,00	A-2-7	204	0,19	-0,74	Coesivo	Coesivo	Coesivo	Granular	Granular	Coesivo	Coesivo2	Coesivo2		
416	100	97	74	52	41	25	33	11	0	11,0	1,909	17	0,00	A-2-6	458	0,43	-0,65	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Coesivo2		
417	100	100	98	95	89	39	36	8	1	10,6	1,860	14	0,00	A-4	418	0,30	-0,37	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intergranular	Intergranular	Intergranular		
418	100	85	61	45	40	29	32	9	0	12,4	1,602	21	0,00	A-2-4	298	0,17	-0,56	Coesivo	Coesivo	Coesivo	Intergranular	Intergranular	Coesivo	Coesivo2	Coesivo1		
419	100	100	70	53	44	18	34	9	0	9,7	2,136	22	0,00	A-2-4	569	0,34	-0,33	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular		

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos							
	#1"	9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos	3 Grupos	4 Grupos			5 Grupos		
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2
420	98	67	34	22	18	11	25	6	0	10,4	1,727	26	0,00	A-2-4	729	0,39	-0,39	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intergranular	Intergranular	Intergranular
421	100	85	58	42	30	18	31	8	0	12,0	1,855	22	0,00	A-2-4	1,093	0,55	-0,13	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
422	100	100	100	99	91	64	40	13	7	19,7	1,512	7	0,30	A-7-5	103	0,19	-0,85	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2
423	100	100	86	59	49	28	33	7	0	9,1	1,925	13	0,00	A-2-4	659	0,43	-0,27	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
424	100	100	94	86	74	41	34	10	1	13,8	1,780	15	0,00	A-6	386	0,37	-0,38	Coesivo	Intermediario	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Intergranular
425	100	89	71	56	47	20	27	5	0	9,5	1,840	15	0,00	A-1-b	719	0,44	-0,35	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
426	100	100	100	97	84	38	31	10	0	12,9	1,792	11	0,04	A-4	248	0,33	-0,69	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo2	Coesivo2
427	100	100	99	98	90	49	31	9	3	11,9	1,627	11	0,00	A-4	298	0,24	-0,43	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1
428	100	100	100	100	89	44	0	0	0	8,1	1,608	11	0,09	A-4	219	0,20	-0,81	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo2
429	100	100	100	96	89	34	0	0	0	9,8	1,911	18	0,00	A-2-4	679	0,52	-0,36	Granular	Intermediario	Intergranular	Coesivo	Intercoesivo	Intergranular	Intergranular	Intergranular
430	100	88	74	57	42	27	23	7	0	11,2	1,902	18	0,00	A-2-4	718	0,47	-0,23	Granular	Granular	Granular	Intergranular	Intergranular	Granular	Intergranular	Granular
431	100	100	100	89	81	28	0	0	0	7,8	1,890	18	0,00	A-2-4	646	0,51	-0,28	Granular	Intermediario	Intergranular	Intercoesivo	Intercoesivo	Intergranular	Intergranular	Intergranular
432	100	88	57	38	32	13	0	0	0	8,1	1,940	16	0,00	A-1-b	681	0,39	-0,49	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Intercoesivo	Intergranular
433	95	79	67	55	45	24	34	9	0	11,6	1,768	26	0,00	A-2-4	802	0,39	-0,18	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
434	100	71	46	41	36	12	0	0	0	8,8	1,950	15	0,00	A-1-b	773	0,43	-0,44	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Intercoesivo	Intergranular
435	100	88	74	60	51	25	25	8	0	11,8	1,681	26	0,00	A-2-4	350	0,28	-0,69	Coesivo	Coesivo	Coesivo	Intergranular	Intergranular	Intercoesivo	Coesivo2	Coesivo2
436	95	75	64	48	36	20	0	0	0	10,4	1,736	16	0,00	A-1-b	784	0,39	-0,30	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Intergranular	Intergranular
437	100	86	67	55	45	25	22	4	0	11,8	1,661	28	0,00	A-1-b	545	0,39	-0,51	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Intergranular
438	100	91	59	41	38	11	0	0	0	8,5	2,090	112	0,00	A-1-b	1,736	0,60	-0,18	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
439	100	92	69	46	34	24	30	9	0	13,4	1,991	77	0,00	A-2-4	570	0,55	-0,68	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Coesivo2
440	100	94	75	53	45	28	40	11	0	12,8	1,998	42	0,00	A-2-7	598	0,40	-0,38	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
441	100	94	75	57	52	37	29	6	0	9,3	2,114	40	0,00	A-4	617	0,44	-0,36	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
442	100	93	69	46	35	15	0	0	0	9,1	2,121	114	0,04	A-1-b	1,373	0,64	-0,32	Granular	Intermediario	Intergranular	Granular	Granular	Granular	Granular	Granular
443	100	96	75	52	43	25	27	6	0	11,2	1,931	28	0,00	A-2-4	701	0,41	-0,29	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular
444	100	92	60	39	31	24	30	7	0	13,2	2,051	37	0,00	A-2-4	372	0,30	-0,45	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Coesivo2	Intergranular
445	97	69	49	40	31	14	26	6	0	9,6	1,862	91	0,00	A-2-4	303	0,21	-0,15	Granular	Intermediario	Intergranular	Granular	Granular	Intergranular	Coesivo2	Intercoesivo
446	100	94	74	54	41	16	0	0	0	9,9	2,041	52	0,00	A-1-b	1,420	0,63	-0,19	Granular	Granular	Granular	Granular	Granular	Granular	Granular	Granular
447	100	85	64	48	40	19	24	6	0	13,6	1,956	50	0,00	A-1-b	876	0,68	-0,39	Granular	Intermediario	Intergranular	Granular	Granular	Granular	Intercoesivo	Granular
448	100	84	60	51	44	15	0	0	0	8,9	2,093	88	0,00	A-1-b	896	0,52	-0,73	Coesivo	Intermediario	Intercoesivo	Granular	Granular	Intercoesivo	Intercoesivo	Coesivo2
449	100	59	36	27	23	13	24	3	0	12,6	2,020	102	0,00	A-1-a	693	0,51	-0,20	Granular	Granular	Granular	Granular	Granular	Granular	Intergranular	Granular

Quadro 6.22 - Base de Dados - Agrupamentos das Amostras (Continuação)

N° da Amostra	Granulometria						ÍNDICES FÍSICOS		IG	Compactação		CBR		T.R.B	K1	K2	K3	Agrupamentos									
	#1"	9.5mm	4.8mm	2.0mm	0.42mm	0.076mm	LL (%)	IP (%)		h _{mod} (%)	γ _{smold} (g/cm ³)	CBR (%)	Expansão (%)					2 Grupos		3 Grupos			4 Grupos			5 Grupos	
																		Especialista	Especialista	Especialista	Algoritmo EM Procedimento 1	Algoritmo Kmeans Procedimento 1	Algoritmo Kmeans Procedimento 2	Algoritmo EM Procedimento 2	Algoritmo Kmeans Procedimento 2		
450	100	74	52	43	34	15	23	4	0	9,8	2,105	85	0,00	A-1-b	1.075	0,45	-0,23	Granular	Intermediario	Intergranular	Granular	Granular	Granular	Granular	Granular	Granular	
451	98	75	55	44	35	18	0	0	0	13,1	1,989	45	0,00	A-1-b	397	0,33	-0,08	Granular	Granular	Granular	Granular	Granular	Intergranular	Intergranular	Intergranular	Intercoesivo	
452	100	85	67	55	37	24	25	6	0	13,7	1,906	33	0,00	A-1-b	600	0,40	-0,23	Granular	Intermediario	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	Intergranular	
453	100	97	87	74	48	24	28	5	0	12,1	1,978	44	0,00	A-1-b	514	0,43	-0,64	Coesivo	Intermediario	Intercoesivo	Intergranular	Intergranular	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	
454	100	98	96	92	36	22	47	14	0	16,3	1,799			A-2-7	176	0,27	-0,73	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo2		
455	100	100	100	98	62	47	47	17	5	18,3	1,753			A-7-5	72	0,15	-0,88	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo2	
456	100	100	100	98	45	29	49	15	1	19,0	1,690			A-2-7	570	0,51	-0,55	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Intergranular	
457	100	99	92	69	56	40	46	11	1	21,6	1,627			A-7-5	264	0,20	-0,54	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1		
458	100	100	100	97	66	44	40	11	2	19,6	1,655			A-6	269	0,29	-0,88	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Intercoesivo	Coesivo2	Coesivo2		
459	100	100	99	97	73	49	45	13	4	21,1	1,680			A-7-5	78	0,17	-0,69	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo1	Coesivo1	
460	100	100	100	99	76	45	39	11	2	19,7	1,685			A-6	198	0,25	-0,68	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo	Coesivo2	Coesivo2	
461	100	100	100	99	70	47	40	11	3	19,5	1,674			A-6	698	0,63	-0,75	Coesivo	Intermediario	Intercoesivo	Coesivo	Intercoesivo	Intercoesivo	Intercoesivo	Intercoesivo	Coesivo2	
462	100	100	97	87	68	49	39	12	4	16,2	1,778			A-6	233	0,25	-0,63	Coesivo	Coesivo	Coesivo	Intercoesivo	Intercoesivo	Coesivo	Coesivo2	Coesivo1		

Capítulo 7

Classificador de Solos Quanto à Resiliência

Neste capítulo são descritos os procedimentos de *Data Mining* utilizados para desenvolvimento de classificadores das amostras da base de dados em famílias de solos que apresentam comportamento semelhante quanto ao aspecto de resiliência, bem como os resultados obtidos.

Para desenvolvimento dos classificadores foram testados todos os algoritmos disponíveis do sistema *Weka* que processam dados numéricos. Os resultados obtidos determinaram a escolha do algoritmo J4.8 como o que tem melhor adaptação aos dados, visto que na maioria dos testes efetuados foi o que apresentou os maiores percentuais de acerto.

7.1 Classificadores desenvolvidos

Em uma primeira etapa foram desenvolvidos classificadores para todos os agrupamentos apresentados no Capítulo 6. Os procedimentos obedecidos nesta etapa para cada agrupamento consistiram na retirada de aproximadamente 20% das amostras de cada grupo gerado para proceder à futura validação do modelo, removendo-se uma a cada cinco amostras, de forma seqüencial, utilização do algoritmo J4.8 para desenvolvimento do classificador com as amostras restantes e, por fim, validação do modelo mediante a classificação das amostras retiradas inicialmente.

Os resultados obtidos são resumidos nos Quadros 7.1 a 7.8 inseridos a seguir. Desses quadros constam os dados de interesse relativos aos classificadores desenvolvidos como, por exemplo, o número de amostras classificadas corretamente e incorretamente, e as matrizes de alocação, que indicam o número de amostras alocadas em cada uma das classes. Exemplificando a interpretação dessas matrizes, na Quadro 7.1, Validação do Modelo, constata-se que duas amostras alocadas pelo algoritmo *EM* na grupo “Intercoesivo” são classificadas pelo modelo como “Coesivo”, assim como uma das amostras alocada pelo *EM* no mesmo grupo é classificada como “Intergranular”, e nenhuma classificada como “Granular”.

Quadro 7.1 - Resumo da Classificação EM - Procedimento 1

Algoritmo de Agrupamento: EM 4 Grupos Procedimento 1								
Algoritmo de Classificação: J4.8				Geração	Validação			
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	365	79			
			%	96,8	91,3			
Número de Amostras Utilizadas na Geração do Modelo: 377		Amostras Classificadas Incorretamente		Número	12			
				%	3,2			
Número de Amostras Utilizadas para Validação do Modelo: 86					8,7			
Matrizes de Alocação								
Geração do Modelo				Validação do Modelo				
a	b	c	d	a	b	c	d	← classificado como a = Coesivo b = Intercoesivo c = Intergranular d = Granular
79	1	0	0	38	1	0	0	
0	87	1	0	2	9	1	0	
0	2	39	8	0	0	20	2	
0	0	0	160	0	0	1	12	
Modo de Teste: Avaliado no conjunto de treinamento								
Número de regras de classificação geradas: 13								

Quadro 7.2 - Resumo da Classificação EM - Procedimento 2

Algoritmo de Agrupamento: EM 5 Grupos Procedimento 2											
Algoritmo de Classificação: J4.8				Geração	Validação						
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	295	47						
			%	79,3	51,6						
Número de Amostras Utilizadas na Geração do Modelo: 372		Amostras Classificadas Incorretamente	Número	77	44						
Número de Amostras Utilizadas para Validação do Modelo: 91			%	20,7	48,4						
Matrizes de Alocação											
Geração do Modelo					Validação do Modelo						
a	b	c	d	e	a	b	c	d	e	← classificado como a = Coesivo 1 b = Coesivo 2 c = Intercoesivo d = Intergranular e = Granular	
47	6	0	0	0	6	7	0	0	0		
13	105	2	10	1	10	17	1	4	0		
0	4	17	4	0	0	3	1	1	1		
1	11	1	88	6	1	5	1	16	3		
1	4	1	12	38	0	2	0	5	7		
Modo de Teste: Avaliado no conjunto de treinamento											
Número de regras de classificação geradas: 46											

Quadro 7.3 - Resumo da Classificação K-means 4 Grupos - Procedimento 1

Algoritmo de Agrupamento: K-means 4 Grupos - Procedimento 1								
Algoritmo de Classificação: J4.8				Geração	Validação			
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	324	73			
			%	87,1	80,2			
Número de Amostras Utilizadas na Geração do Modelo: 372		Amostras Classificadas Incorretamente	Número	48	18			
Número de Amostras Utilizadas para Validação do Modelo: 91			%	12,9	19,8			
Matrizes de Alocação								
Geração do Modelo				Validação do Modelo				
a	b	c	d	a	b	c	d	← classificado como a = Coesivo b = Intercoesivo c = Intergranular d = Granular
92	16	0	0	22	4	1	0	
16	77	1	0	0	22	1	0	
0	5	91	4	0	6	18	0	
0	0	6	64	0	0	6	11	
<p>Modo de Teste: Avaliado no conjunto de treinamento</p> <p>Número de regras de classificação geradas: 19</p>								

Quadro 7.4 - Resumo da Classificação K-means 4 Grupos - Procedimento 2

Algoritmo de Agrupamento: K-means 4 Grupos Procedimento 2								
Algoritmo de Classificação: J4.8				Geração	Validação			
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	314	50			
			%	84,4	55,0			
Número de Amostras Utilizadas na Geração do Modelo: 372		Amostras Classificadas Incorretamente	Número	58	41			
Número de Amostras Utilizadas para Validação do Modelo: 91			%	15,6	45,0			
Matrizes de Alocação								
Geração do Modelo				Validação do Modelo				
a	b	c	d	a	b	c	d	← classificado como a = Coesivo b = Intercoesivo c = Intergranular d = Granular
120	6	4	1	23	5	4	0	
4	40	4	1	4	4	3	1	
10	0	99	15	6	5	15	4	
2	3	8	55	2	2	5	8	
<p>Modo de Teste: Avaliado no conjunto de treinamento</p> <p>Número de regras de classificação geradas: 53</p>								

Quadro 7.5 - Resumo da Classificação K-means 5 Grupos - Procedimento 2

Algoritmo de Agrupamento: K-means 5 Grupos Procedimento 2											
Algoritmo de Classificação: J4.8				Geração	Validação						
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	298	43						
			%	80,1	47,3						
Número de Amostras Utilizadas na Geração do Modelo: 372		Amostras Classificadas Incorretamente	Número	74	48						
Número de Amostras Utilizadas para Validação do Modelo: 91			%	19,9	52,7						
Matrizes de Alocação											
Geração do Modelo					Validação do Modelo						
a	b	c	d	e	a	b	c	d	e	← classificado como a = Coesivo 1 b = Coesivo 2 c = Intercoesivo d = Intergranular e = Granular	
104	1	2	4	0	19	4	3	1	0		
10	21	3	5	2	3	1	2	3	1		
9	2	34	4	10	2	0	5	5	2		
3	2	2	80	2	3	3	4	7	5		
5	0	3	5	59	1	0	2	4	11		
Modo de Teste: Avaliado no conjunto de treinamento											
Número de regras de classificação geradas: 61											

Quadro 7.6 - Resumo da Classificação Especialista 2 Grupos - Procedimento 2

Algoritmo de Agrupamento: Especialista 2 Grupos Procedimento 2					
Algoritmo de Classificação: J4.8				Geração	Validação
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	321	77
			%	86,5	83,7
Número de Amostras Utilizadas na Geração do Modelo: 371		Amostras Classificadas Incorretamente	Número	50	15
Número de Amostras Utilizadas para Validação do Modelo: 92			%	13,5	16,3
Matrizes de Alocação					
Geração do Modelo			Validação do Modelo		
a	b	a	b	← classificado como a = Coesivo c = Granular	
121	39	48	4		
11	200	11	29		
<p>Modo de Teste: Avaliado no conjunto de treinamento</p> <p>Número de regras de classificação geradas: 10</p>					

Quadro 7.7 - Resumo da Classificação Especialista 3 Grupos - Procedimento 2

Algoritmo de Agrupamento: Especialista 3 Grupos Procedimento 2					
Algoritmo de Classificação: J4.8				Geração	Validação
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	309	61
			%	83,3	66,3
Número de Amostras Utilizadas na Geração do Modelo: 371		Amostras Classificadas Incorretamente	Número	62	31
Número de Amostras Utilizadas para Validação do Modelo: 92			%	16,7	33,7
Matrizes de Alocação					
Geração do Modelo			Validação do Modelo		
a	b	c	a	b	c
49	31	0	20	8	1
9	149	15	10	32	1
1	6	111	0	11	9
<p>← classificado como a = Coesivo b = Intermediário c = Granular</p>					
<p>Modo de Teste: Avaliado no conjunto de treinamento</p> <p>Número de regras de classificação geradas: 27</p>					

Quadro 7.8 - Resumo da Classificação Especialista 4 Grupos - Procedimento 2

Algoritmo de Agrupamento: Especialista 4 Grupos Procedimento 2								
Algoritmo de Classificação: J4.8				Geração	Validação			
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	315	53			
			%	84,2	60,0			
Número de Amostras Utilizadas na Geração do Modelo: 374		Amostras Classificadas Incorretamente	Número	59	36			
Número de Amostras Utilizadas para Validação do Modelo: 89			%	15,8	40,0			
Matrizes de Alocação								
Geração do Modelo				Validação do Modelo				
a	b	c	d	a	b	c	d	← classificado como a = Coesivo b = Intercoesivo c = Intergranular d = Granular
73	6	2	1	20	5	2	1	
6	64	7	5	4	10	3	5	
5	7	68	11	1	4	12	4	
1	2	6	110	0	1	6	11	
<p>Modo de Teste: Avaliado no conjunto de treinamento</p> <p>Número de regras de classificação geradas: 54</p>								

Algumas constatações podem ser feitas com base nos resultados obtidos, como comentado a seguir.

Em primeiro lugar, observa-se que os índices de acerto dos classificadores gerados a partir dos agrupamentos efetuados com base no Procedimento 2 são muito inferiores àqueles advindos dos agrupamentos nos quais se utilizou o Procedimento 1. Isto indica uma dificuldade de associação dos parâmetros geotécnicos tradicionais às constantes K_i do modelo composto, ou seja, baixa correspondência entre os citados parâmetros e o comportamento resiliente dos solos. Mesmo para os classificadores que apresentaram excelente desempenho, foram constatadas inconsistências quanto à esta associação. Por exemplo, o classificador de melhor desempenho, aquele gerado pela utilização do algoritmo de agrupamento *EM* segundo o Procedimento 1, com 91,3% de acertos no conjunto de validação, apresenta os seguintes resultados:

Amostra 103: $K_2 = 0,39$ e $K_3 = -0,04$ – Classificação: Intercoesivo

Amostra 114: $K_2 = 0,26$ e $K_3 = -0,69$ – Classificação: Granular

Amostra 118: $K_2 = 0,38$ e $K_3 = -0,09$ – Classificação: Intercoesivo

Constata-se que as amostras 103 e 118 têm comportamento resiliente nitidamente dependente da tensão confinante, portanto granular, e a amostra 114 apresenta grande dependência da tensão desvio e tem, portanto, comportamento coesivo. Essas inconsistências são observadas em todos os agrupamentos realizados e conseqüentemente nos classificadores desenvolvidos a partir deles.

Outra constatação é de que, no caso da base de dados utilizada, quanto maior o número de grupos, menor o índice de acerto dos classificadores.

Quanto às discrepâncias observadas, pelo menos três hipóteses podem ser levantadas quanto às suas causas. A primeira delas diz respeito aos dados relativos a uma parcela das variáveis de entrada, ou seja, aos ensaios de granulometria dos materiais. Esses dados foram fornecidos por diversos laboratórios, muitos deles laboratórios de campo, e podem conter erros, de execução ou registro, não identificáveis. A segunda hipótese é de que muitos solos apresentam comportamento resiliente incompatível com suas características granulométricas, não havendo como identificar as eventuais incompatibilidades no âmbito deste estudo e de posse apenas dos dados disponíveis. Uma terceira hipótese seria uma combinação das duas primeiras, ou seja, podem existir na base de dados registros incorretos assim como

solos que apresentam comportamento resiliente dissociado de suas características granulométricas.

Em vista destas discrepâncias, optou-se por elaborar uma base de dados que apresentasse mais consistência nas relações entre os ensaios geotécnicos tradicionais e o comportamento resiliente dos solos.

O critério inicialmente utilizado para elaboração desta nova base de dados foi de que a amostra permaneceria desde que nos agrupamentos que geraram quatro grupos tivesse sido alocada no mesmo grupo em pelo menos três deles, prevalecendo sempre o grupo indicado pelo especialista.

Considerando a existência de quatro grupos, a aplicação deste critério resultou em uma base de dados muito deficiente, com um total de apenas 195 amostras, sendo que no grupo “Intercoesivo” restaram apenas cinco. O principal problema observado foi a alocação das amostras nos grupos “Intercoesivo” e “Intergranular” que, em função das discordâncias entre os algoritmos utilizados, resultaram no descarte da maior parte delas.

Tendo em vista os maus resultados da análise com quatro grupos, optou-se por aprofundá-la considerando a existência de apenas três grupos, coesivo, intermediário e granular. Para isso, as amostras alocadas nos grupos intercoesivo e intergranular foram admitidas como tendo comportamento intermediário. Por esse critério a base de dados remanescente tem um total de 318 amostras, sendo 49 granulares, 145 intermediárias e 124 coesivas. Embora o número de amostras granulares seja muito inferior aos demais, esta base é muito mais consistente quanto ao aspecto de associação das constantes K_i do modelo composto à classe definida quanto ao comportamento resiliente do material do que a gerada com quatro grupos. Os resultados da análise são resumidos no Quadro 7.9, inserido a seguir.

Quadro 7.9 - Resumo da Classificação Especialista Mais Dois Algoritmos

Algoritmo de Agrupamento: Especialista mais dois algoritmos				Geração	Validação	
Algoritmo de Classificação: J4.8						
Variáveis Utilizadas na Classificação: pen1, pen38, pen4, pen10, pen40, pen200, hmodal, densmodal		Amostras Classificadas Corretamente	Número	224	53	
			%	87,5	85,5	
Número de Amostras Utilizadas na Geração do Modelo: 256		Amostras Classificadas Incorretamente		Número	32	
Número de Amostras Utilizadas para Validação do Modelo: 62				%	12,5	
					9	
					14,5	
Matrizes de Alocação						
Geração do Modelo			Validação do Modelo			
a	b	c	a	b	c	← classificado como a = Coesivo b = Intermediário c = Granular
37	3	0	23	1	0	
2	102	12	5	22	2	
0	15	85	0	1	8	
Modo de Teste: Validação Cruzada						
Número de regras de classificação geradas: 12						

7.2 Classificador escolhido

A escolha do classificador baseou-se essencialmente nos valores das constantes K_i do modelo composto, visto que a geração da base de dados com 318 amostras teve como critério a manutenção da classe indicada pelo especialista. Tendo em vista que o classificador gerado a partir desta base apresenta índice de acerto no conjunto de validação de 85,5%, utilizando como método de teste a validação cruzada, considerou-se ser este o melhor dentre todos os que foram avaliados, admitindo-se que foi obtido um modelo que apresenta desempenho e consistência satisfatórios. Contudo, deve-se considerar também que ao se reduzir a base de dados pode ter ocorrido perda de informação relevante, o que é inevitável neste caso, já que não é possível definir se as amostras retiradas constituem “ruídos” ou solos de comportamento não convencional.

São apresentadas a seguir as Figuras 7.1 a 7.10, que constam da árvore de decisão gerada para três classes e das janelas disponíveis no sistema *Weka* que permitem a visualização dos dados.

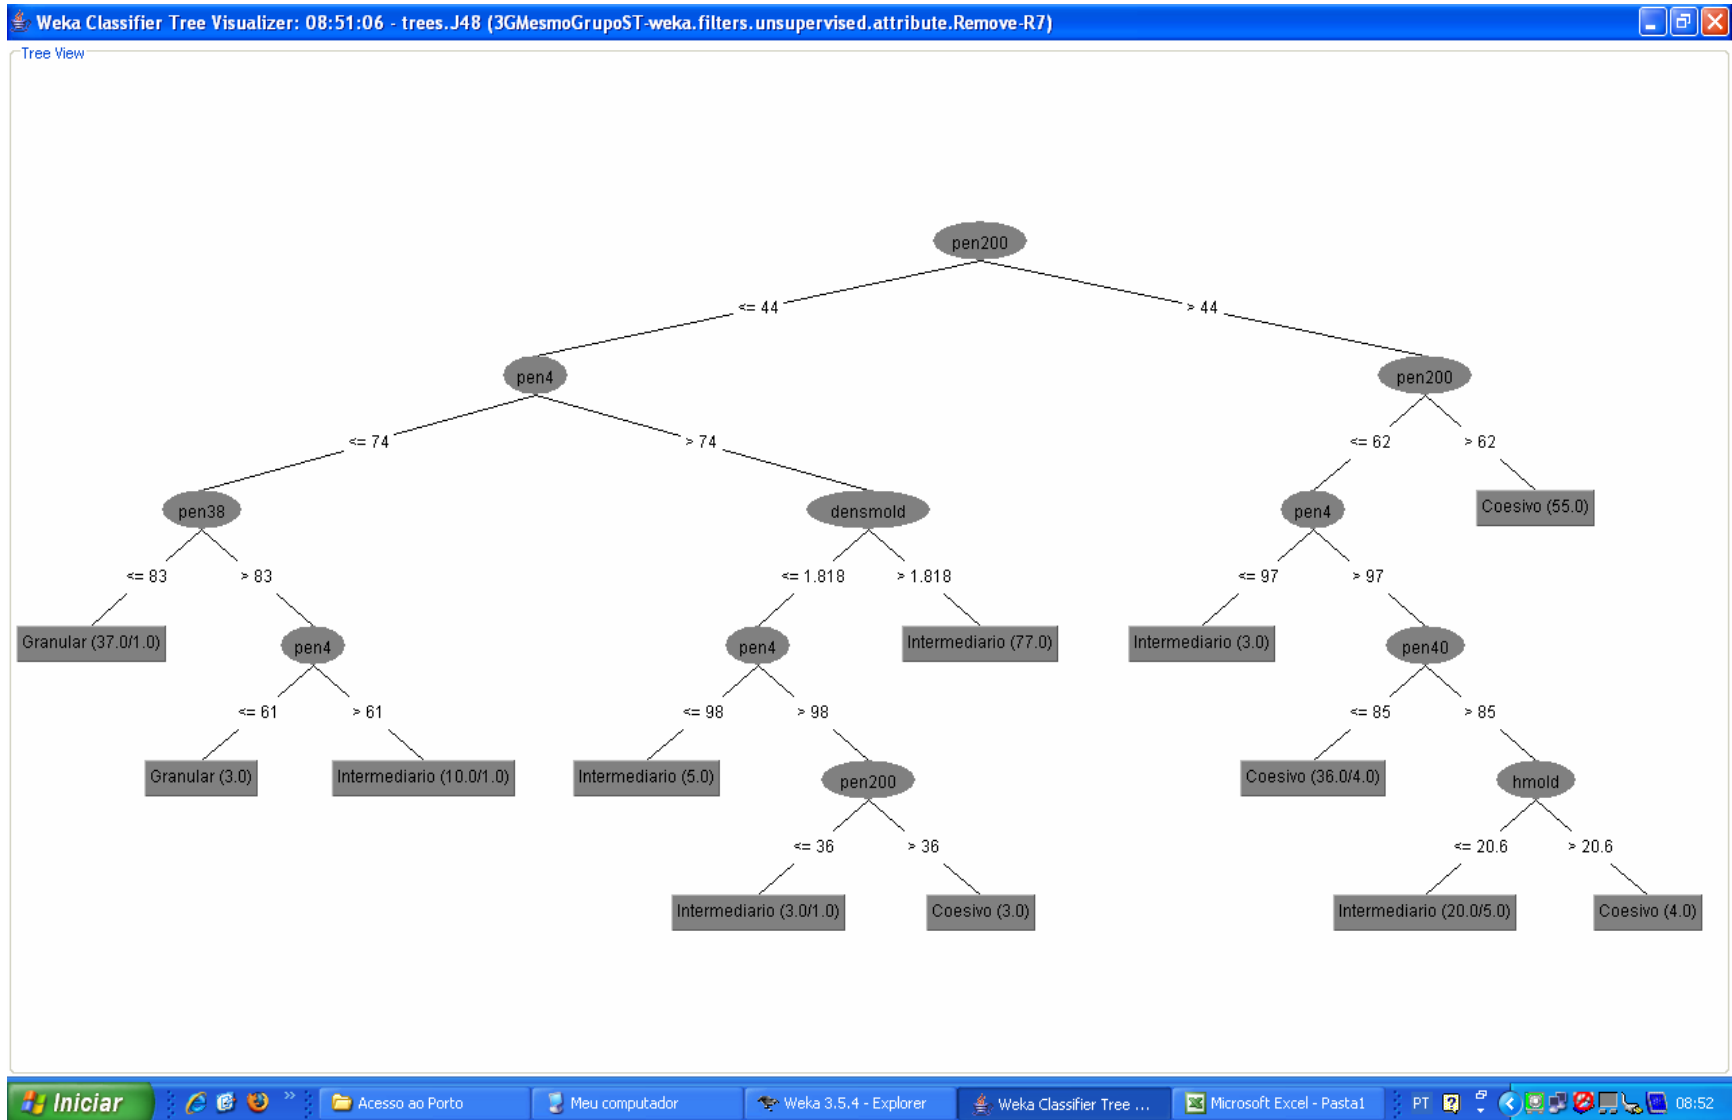


Figura 7.1 – Árvore de decisão gerada para classificação de solos quanto à resiliência

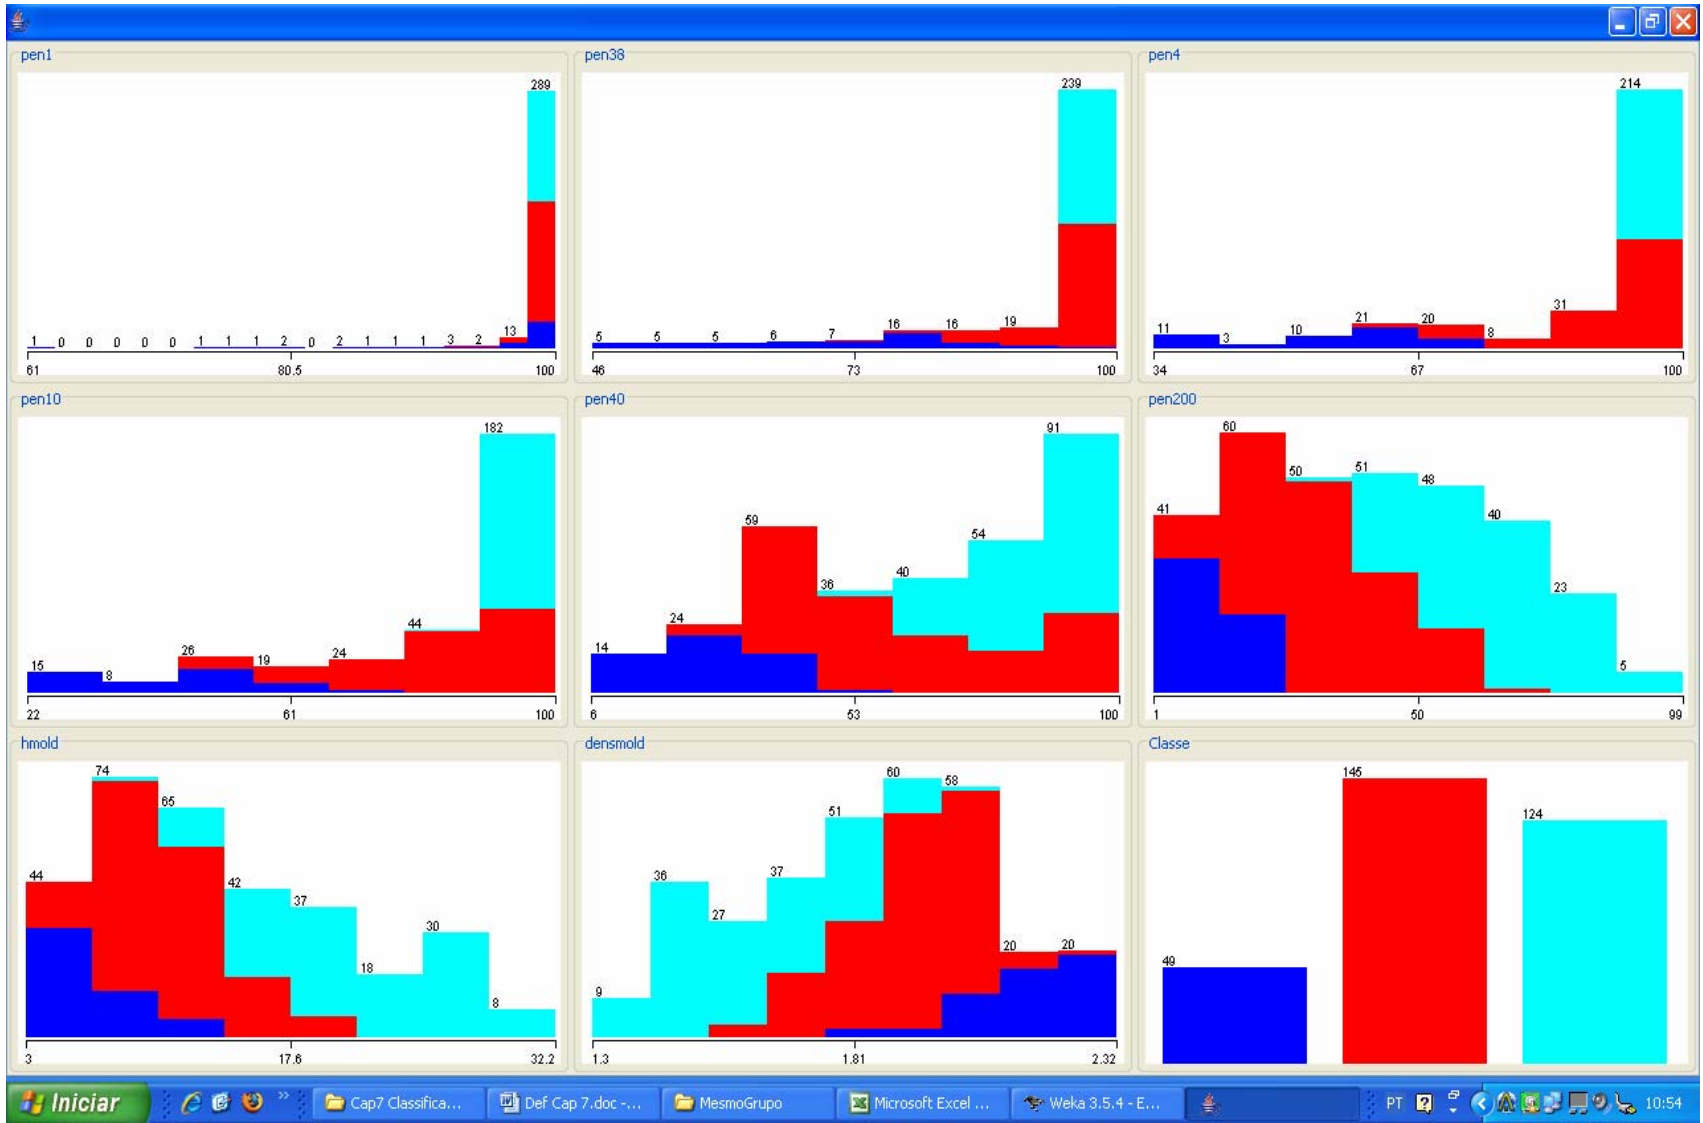


Figura 7.2 – Histogramas das variáveis da base de dados classificada

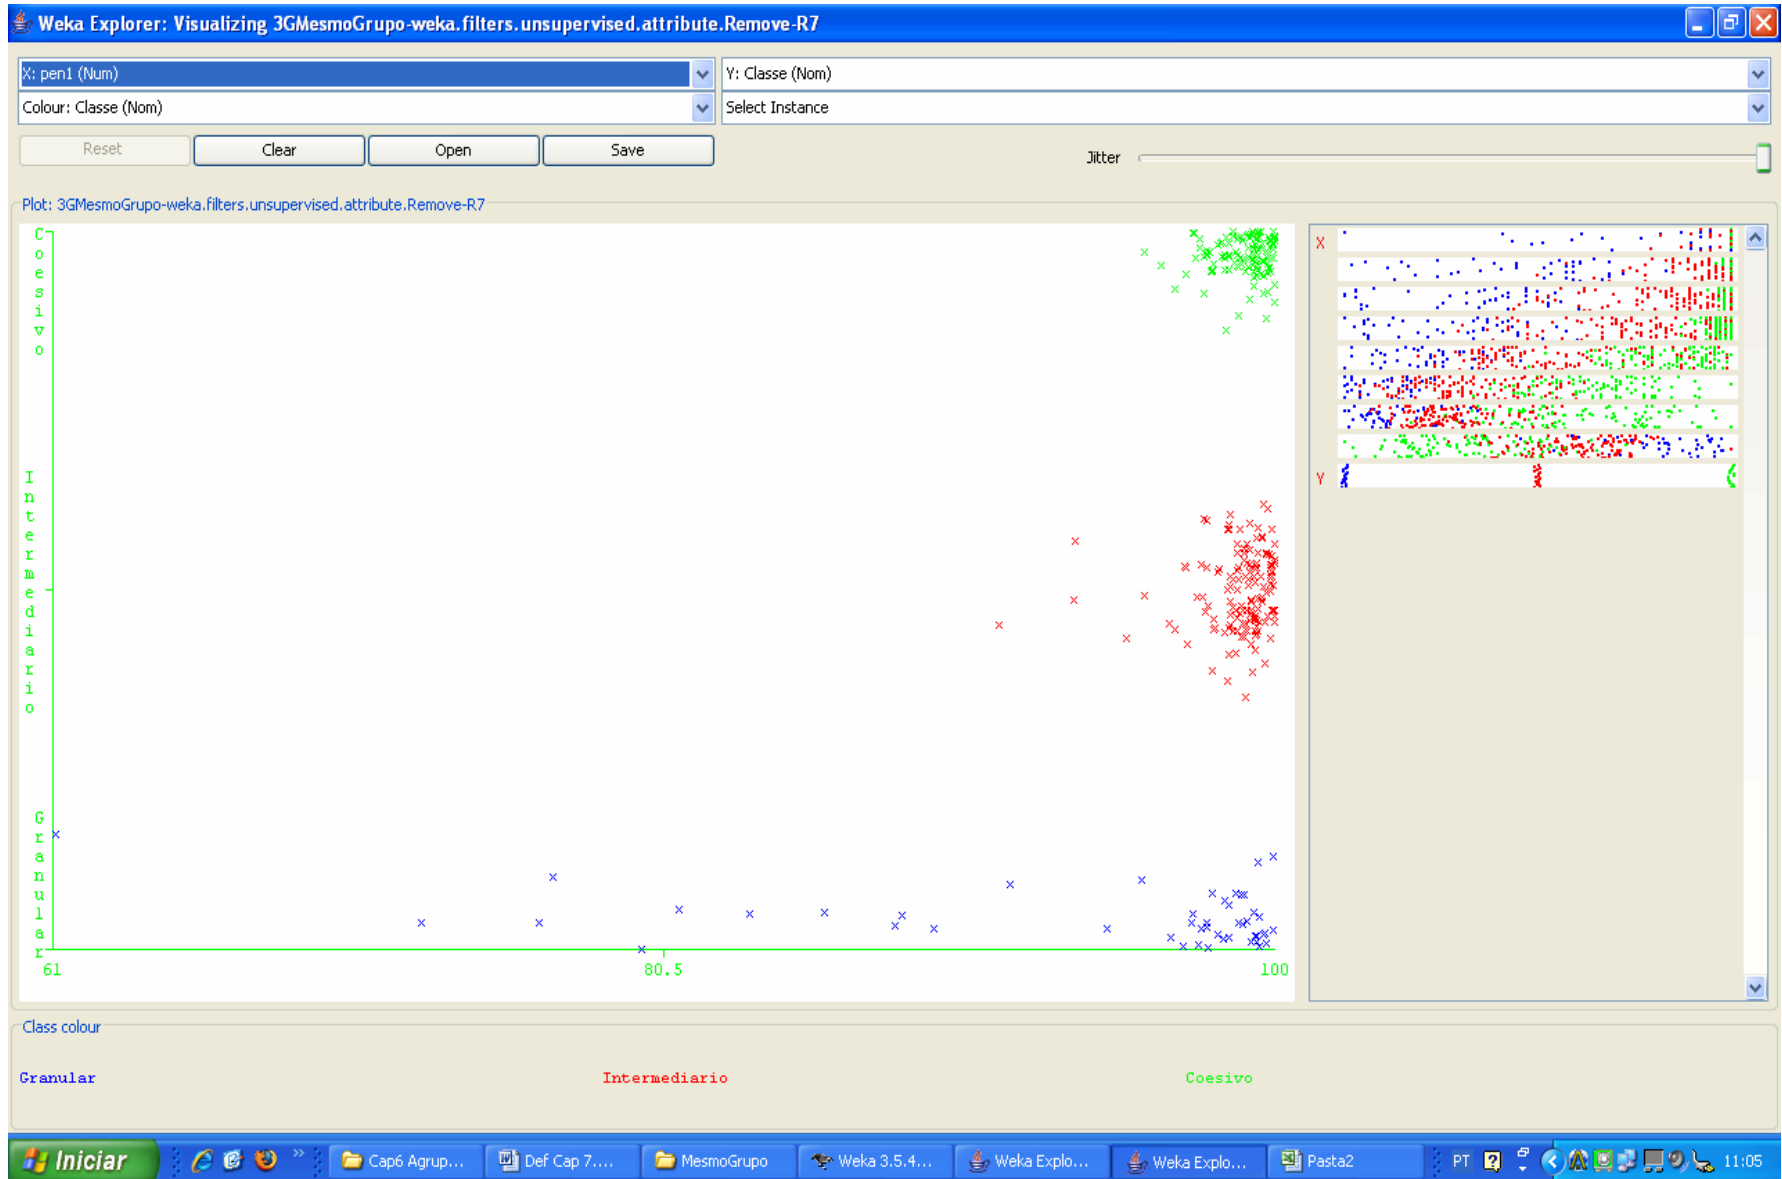


Figura 7.3 – Peneira 1” X Classes

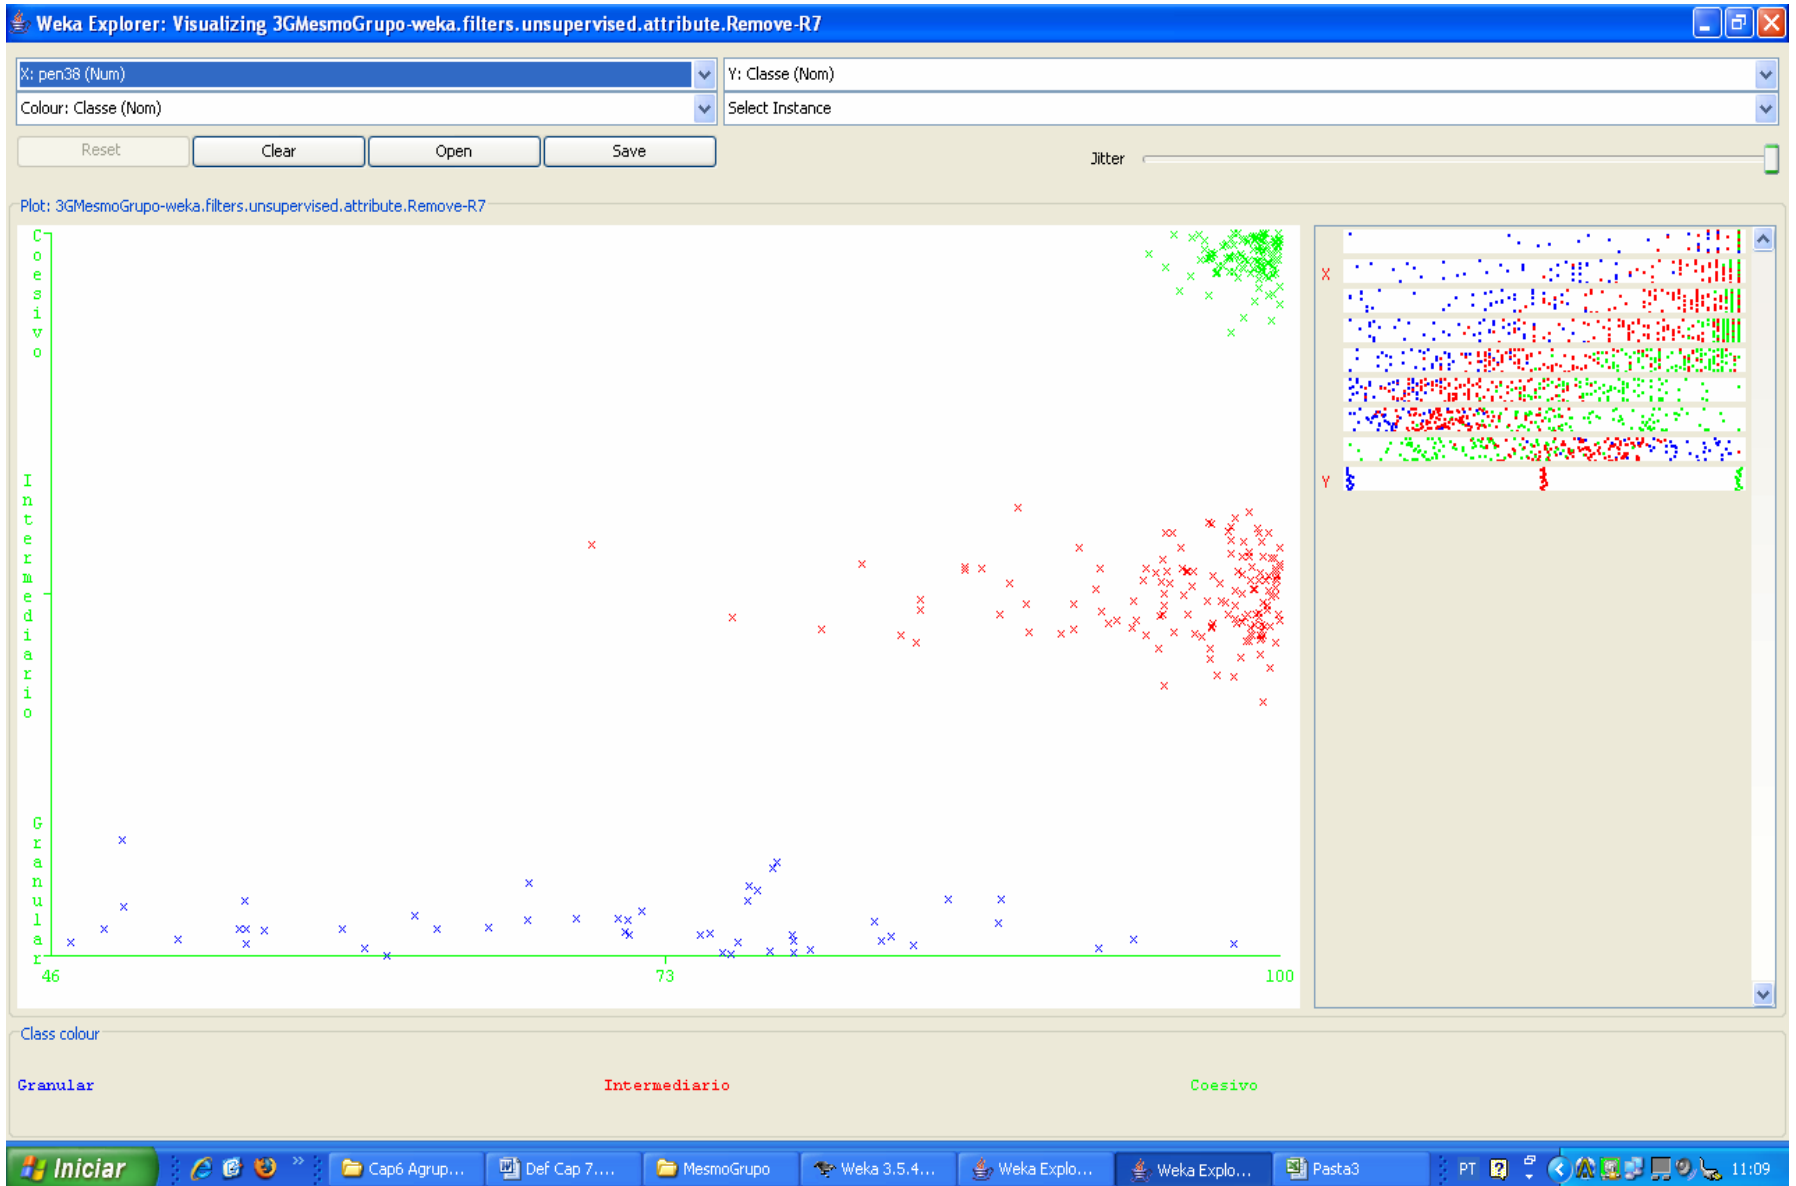


Figura 7.4 – Peneira 3/8" X Classes

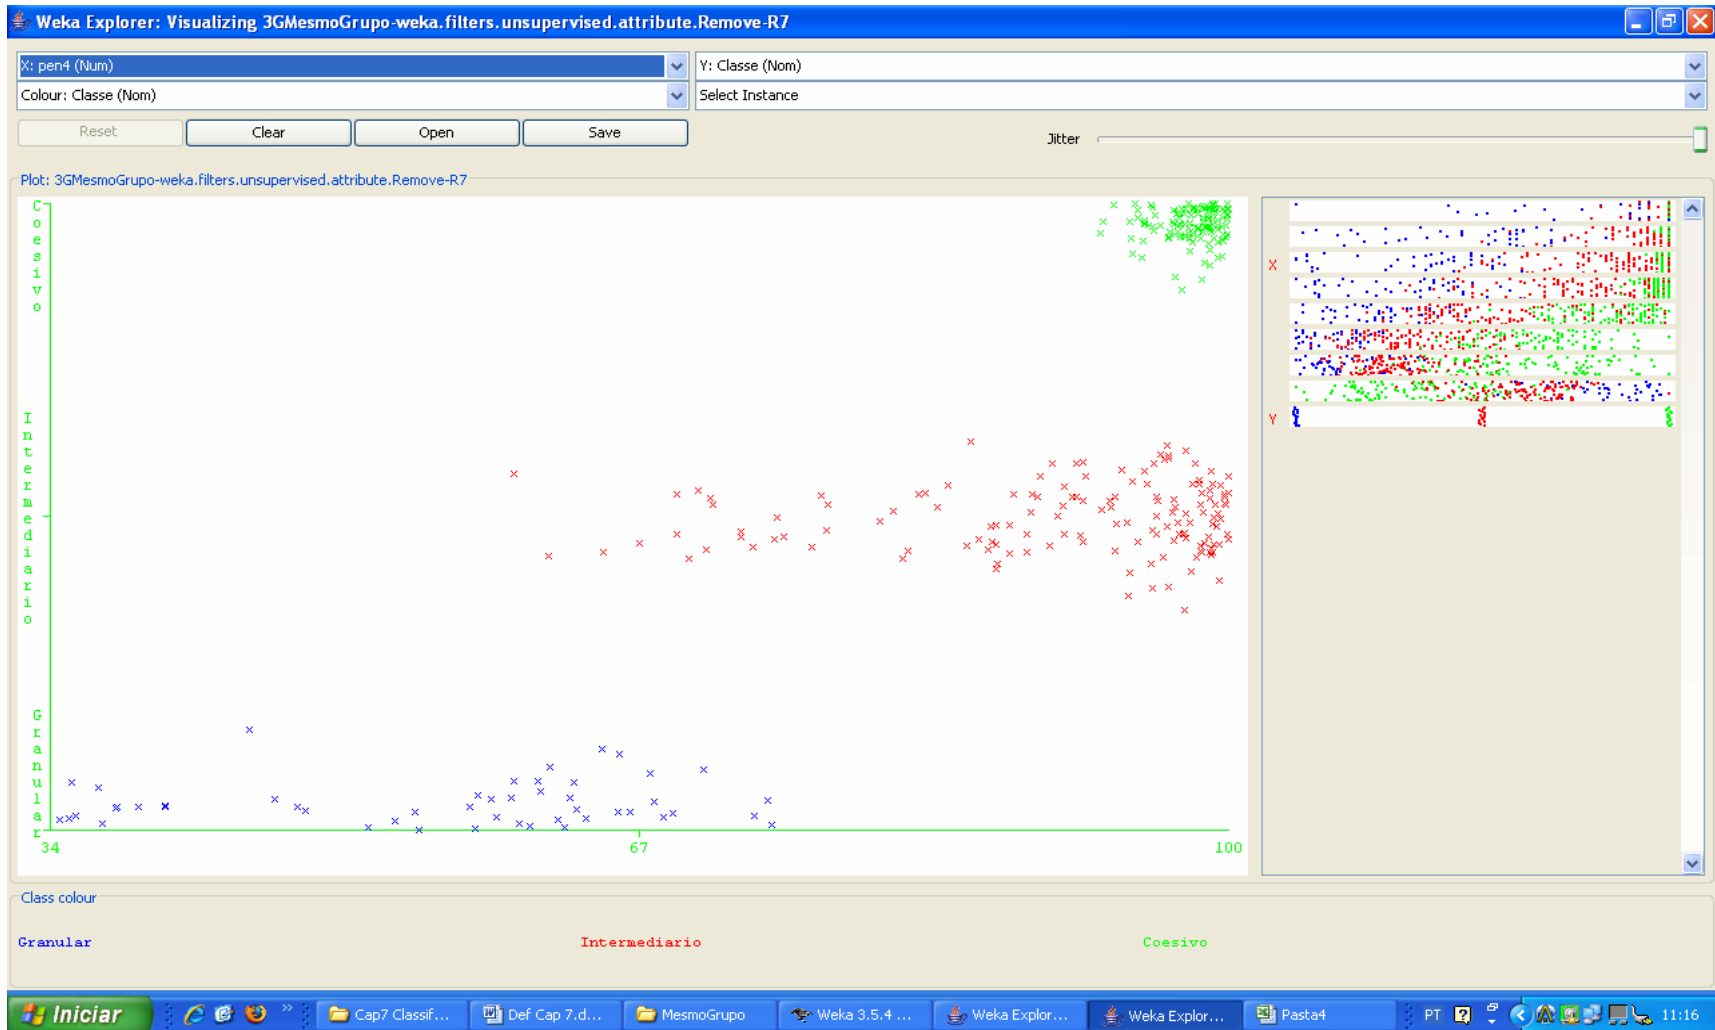


Figura 7.5 – Peneira 4 X Classes

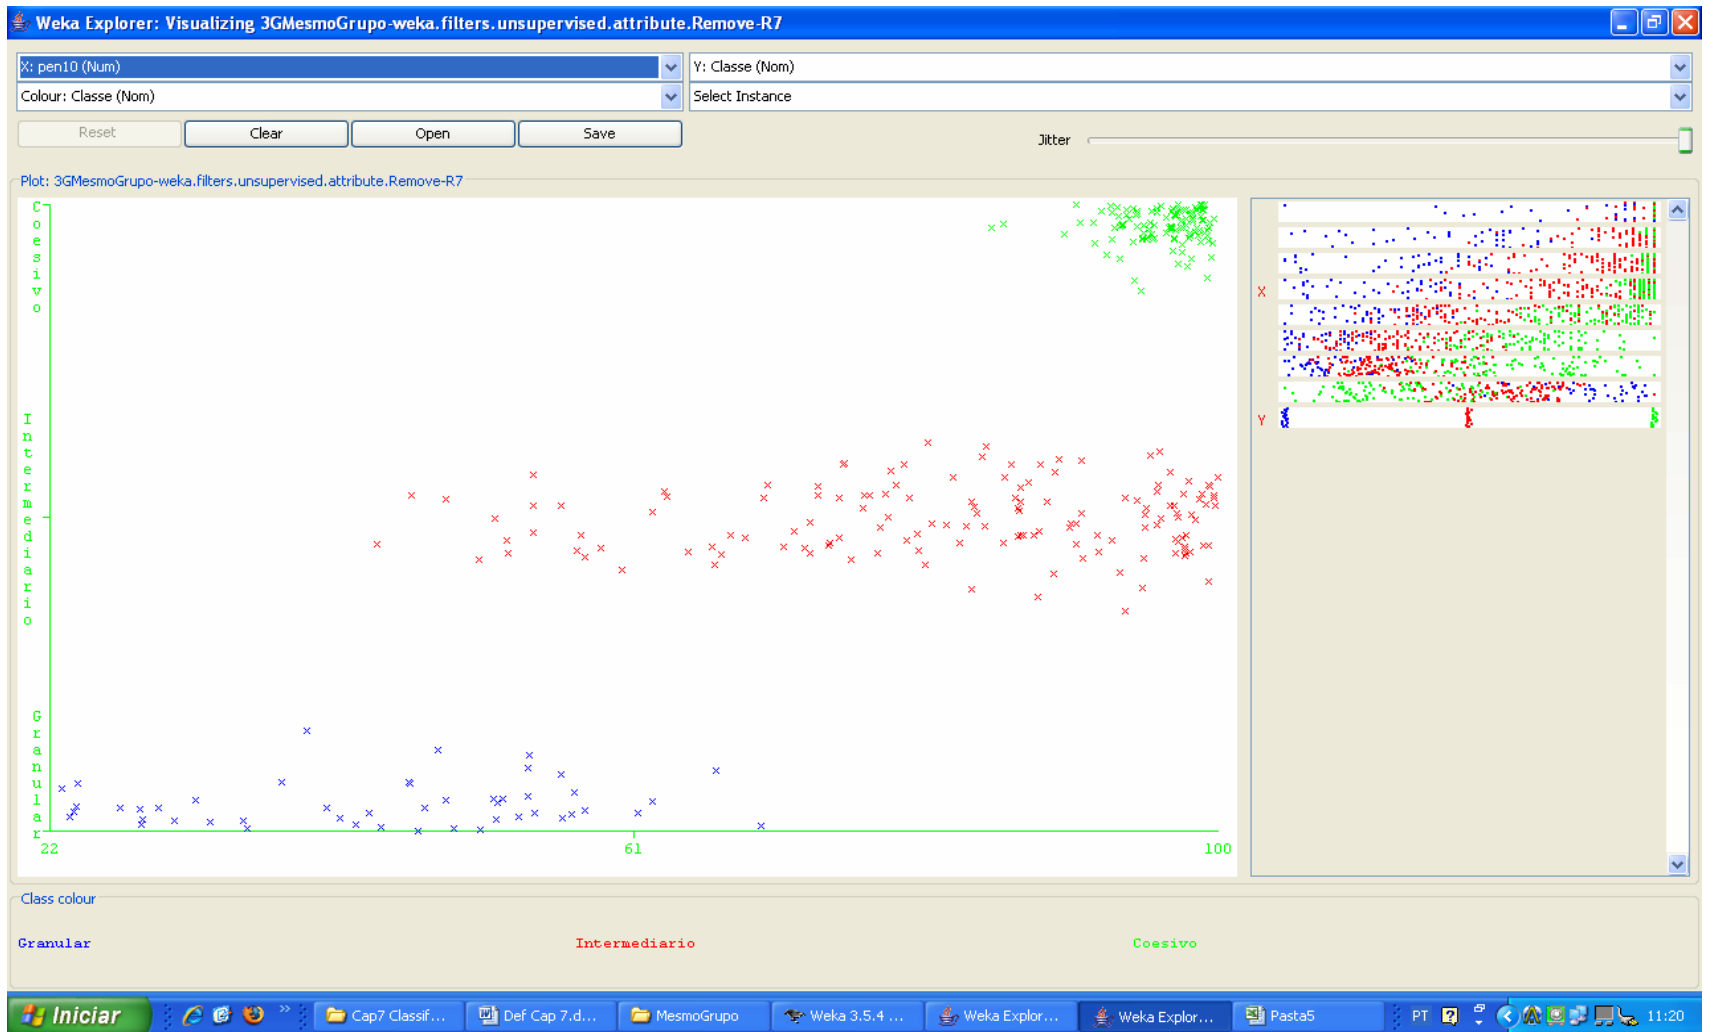


Figura 7.6 – Peneira 10 X Classes

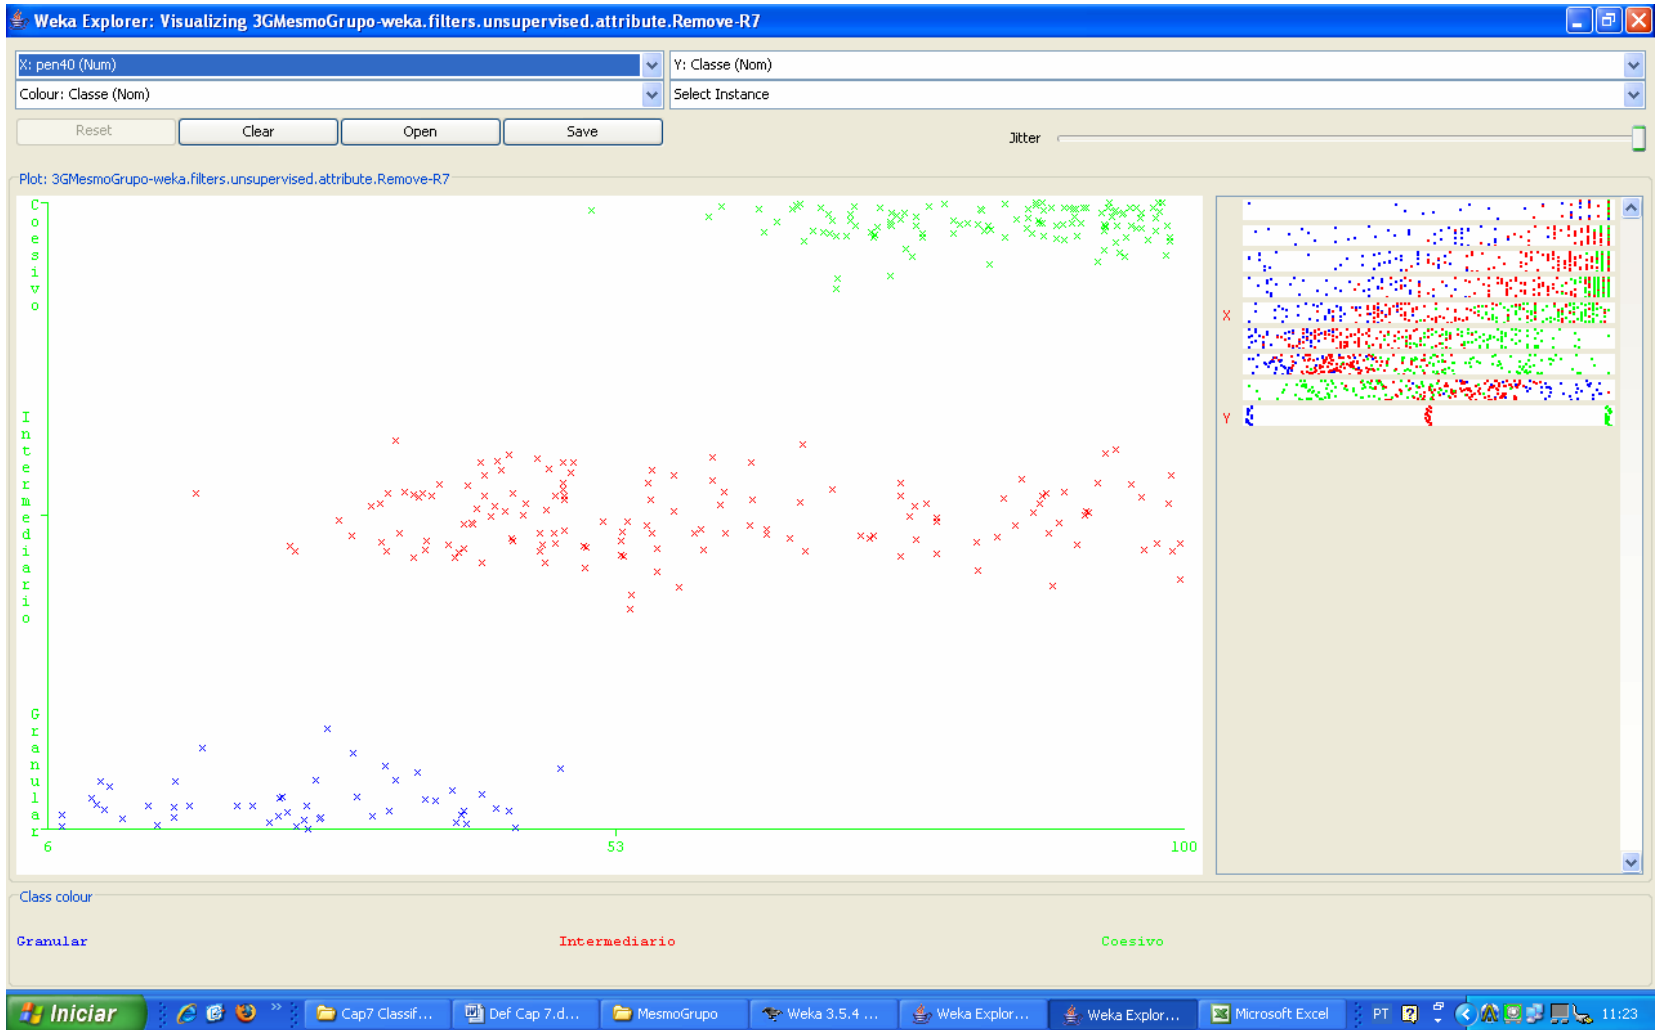


Figura 7.7 – Peneira 40 X Classes

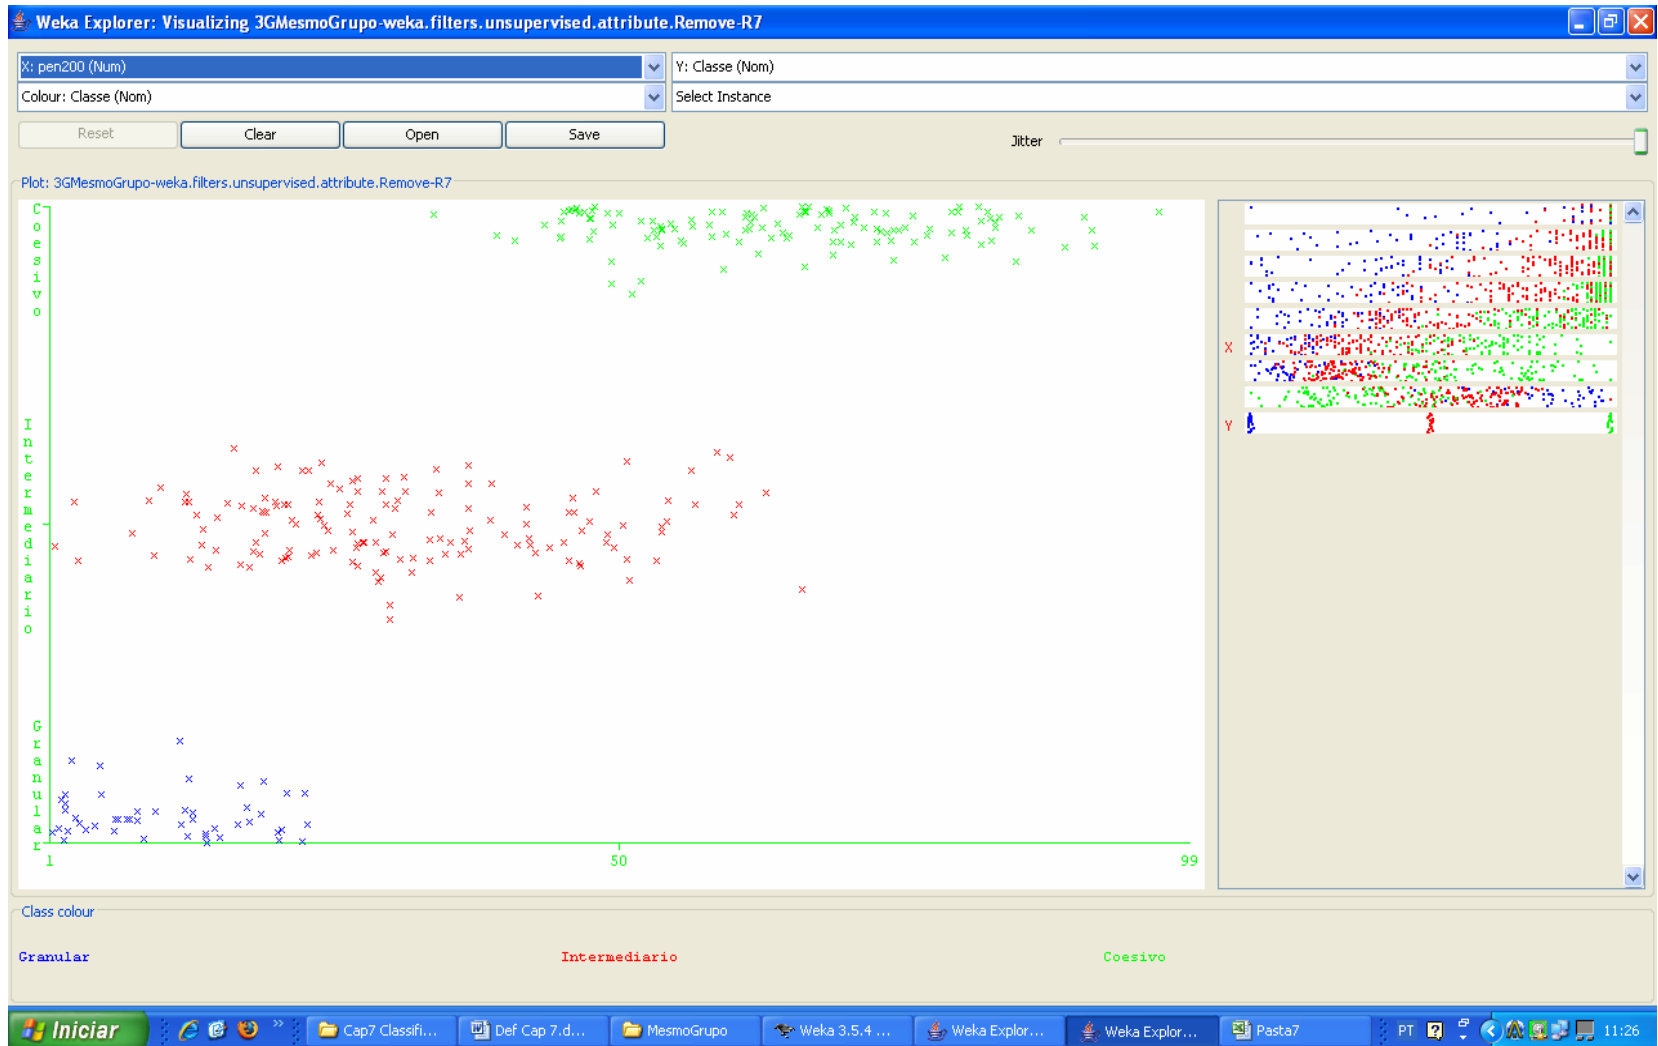


Figura 7.8 – Peneira 200 X Classes

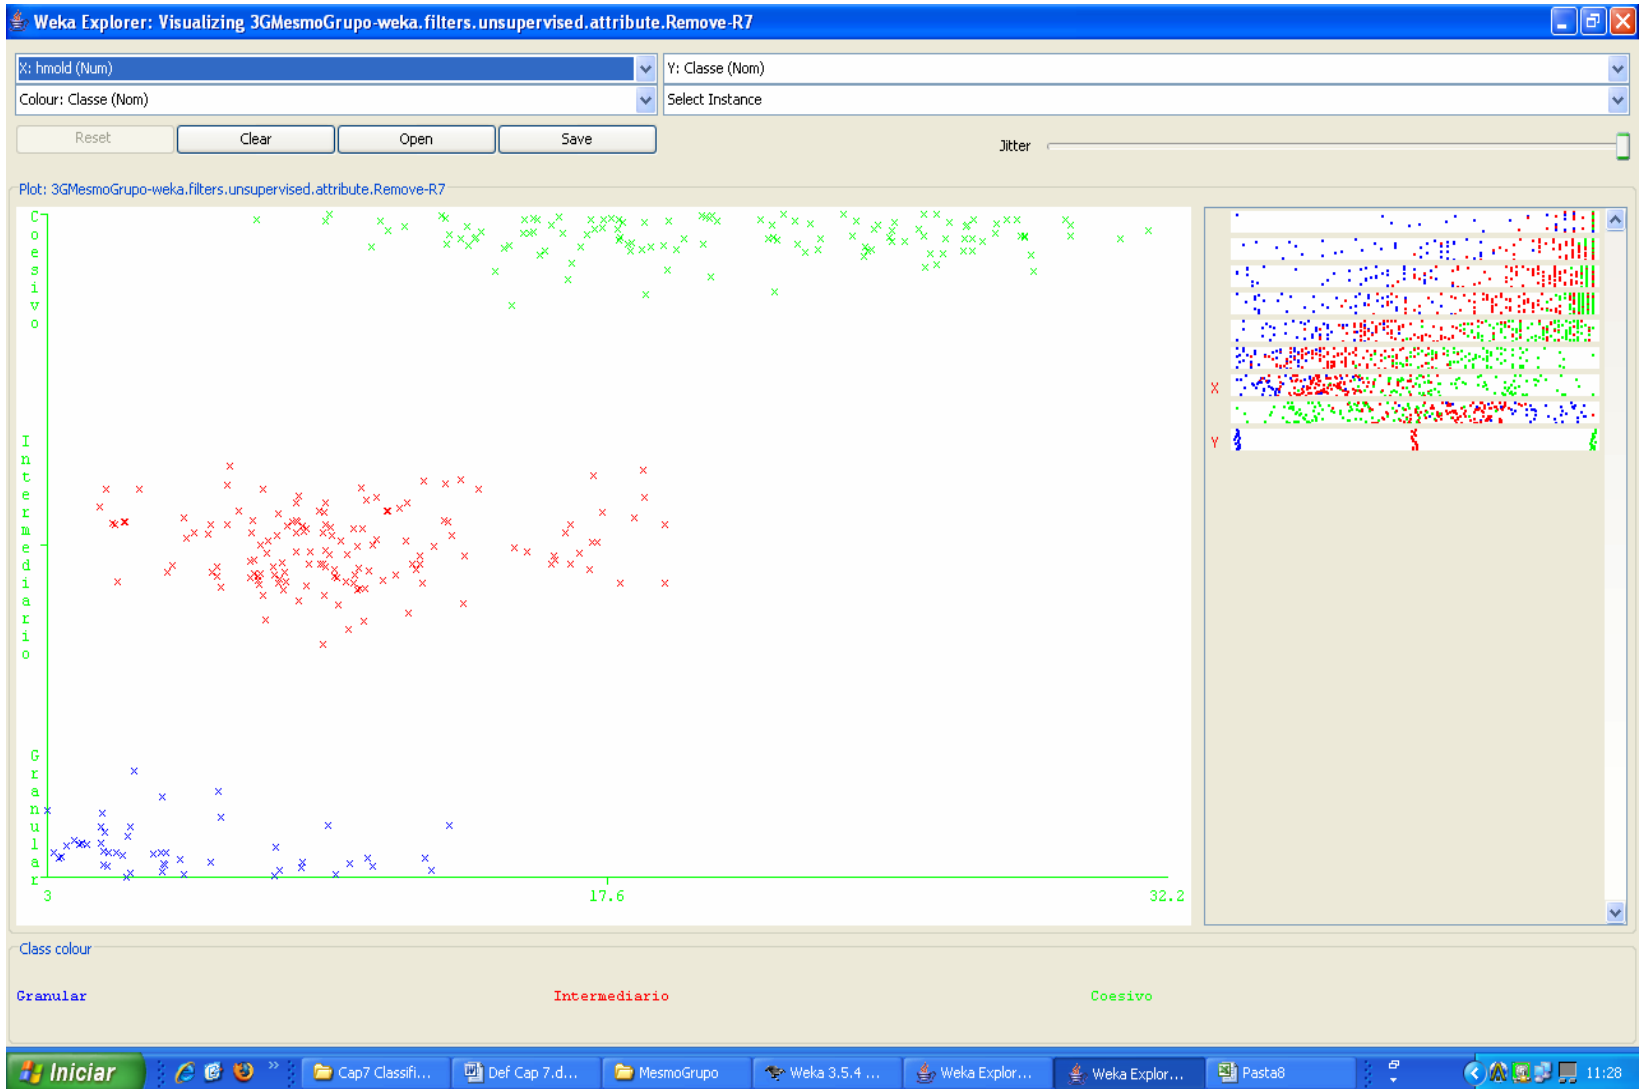


Figura 7.9 – Hmold X Classes



Figura 7.10 – Densmold X Classes

Capítulo 8

Desenvolvimento das Redes Neurais Artificiais

Este capítulo trata dos estudos desenvolvidos para obtenção de uma Rede Neural capaz de prever valores de M_R com um erro aceitável. São apresentados a metodologia utilizada, os resultados obtidos e sua análise.

Os estudos foram desenvolvidos em duas fases. A primeira fase teve como objetivo uma avaliação preliminar em termos de arquitetura, ou seja, uma definição quanto ao número de camadas, número de neurônios por camada e funções de ativação, de forma a definir uma arquitetura mínima capaz de mapear o problema com confiabilidade adequada. Nesta fase foi utilizada primeiramente a base de dados composta de 285 amostras apresentada em Ferreira (2002).

A segunda fase foi desenvolvida na medida em que novas amostras foram sendo disponibilizadas, sendo então efetuados os procedimentos de *Data Mining* relativos ou pré-processamento dos dados, resultando ao final na base de dados com 463 amostras apresentada no Capítulo 5.

8.1 Metodologia – Primeira Fase

Para elaboração e treinamento das redes neurais apresentadas neste trabalho foi utilizado o *software NeuroShell-2 Release 4.0*. Este programa, que funciona em ambiente Windows com interface gráfica, foi desenvolvido especificamente para aplicações de Redes Neurais, o que torna possível sua utilização sem que haja necessidade de profundos conhecimentos de computação avançada, já que o mesmo permite a construção das redes e resolução das aplicações sem que haja necessidade de programação prévia.

Resumidamente, os passos básicos necessários para a construção de uma rede neural através do programa *NeuroShell-2* são os seguintes:

1. Define-se o problema que se deseja solucionar, ou seja, que variáveis deverão ter seus valores preditos pela rede neural;
2. As variáveis independentes, que constituem as entradas da rede são escolhidas;

3. Determinam-se quais amostras farão parte dos conjuntos de treinamento, de teste e, se for o caso, de validação, e a forma pela qual o programa deverá selecioná-las;
4. Define-se a arquitetura desejada para a rede;
5. Efetua-se o treinamento da rede através do algoritmo selecionado, definindo-se o critério de parada, se por um valor limite de erro ou pelo número máximo de iterações que o programa executará;
6. Se houver necessidade, deve-se redefinir a arquitetura e os parâmetros iniciais da rede e reiniciar o treinamento, repetindo-se o processo até que seja obtido o erro máximo admissível;
7. Após obter-se o erro admissível, estando assim a rede treinada, a obtenção dos valores das variáveis de saída da rede para novos casos é feita através de um arquivo executável, gerado pelo próprio software que, após uma etapa de programação complementar, permite a impostação dos valores das variáveis de entrada, predizendo o resultado das variáveis de saída desejadas.

Na primeira fase do estudo foi utilizada a classe Rede Neural Feedforward Multicamadas, do tipo *Multilayer Perceptron (MLP)*, cuja arquitetura é organizada de forma que os neurônios são dispostos em camadas paralelas e consecutivas, e a informação propaga-se sempre no mesmo sentido, da entrada para a saída, não existindo, portanto, ligações que possibilitem a realimentação de uma camada com informações geradas pela camada posterior.

Neste tipo de arquitetura, os neurônios da(s) camada(s) oculta(s) intervêm equilibrando os pesos sinápticos, dando condições à rede de melhor mapear problemas mais complexos.

Para treinamento das redes elaboradas neste trabalho foi utilizado o tipo supervisionado, que se caracteriza pela existência de um agente externo – supervisor – que indica à rede a resposta desejada para o padrão de entrada. Através do erro, que consiste na diferença entre os valores esperados e aqueles obtidos, o agente externo ajusta os parâmetros da rede até que o mesmo seja minimizado, passando a não existir mais ou atingindo um valor considerado satisfatório. A partir deste momento, diz-se que a rede adquiriu conhecimento (aprendizado) e encontra-se treinada. Dentre os diversos grupos nos quais pode-se dividir o aprendizado, optou-se pelo Aprendizado Hetero-Associativo, no qual a rede aprende a associar padrões de natureza diferente, ou seja, as respostas são dadas em função do mapeamento entre as entradas e saídas que a rede aprendeu.

O algoritmo de treinamento utilizado é do tipo *Backpropagation*, que permite modificar aos poucos os valores das sinapses de modo a otimizar a saída da rede. Este algoritmo consiste do seguinte (Furtado, 1999):

1. As variáveis de entrada e saída são normalizadas, fazendo-se uma transformação algébrica para que variem no intervalo 0 e 1;
2. Escolhe-se para inicializar um conjunto de parâmetros W_m , onde W_m é o vetor de sinapses, para $m = 1, \dots, M$, variando-se este valor geralmente de $-0,1$ a $0,1$;
3. Escolhe-se uma taxa de aprendizado η . Se este valor for grande, a rede pode divergir e, se for pequeno, pode tornar o processo muito lento. Valores típicos se situam na faixa entre 0,05 e 0,1. Uma possibilidade é iniciar com um valor maior no começo, para acelerar a convergência, e menor no final, para garantir um ajuste fino;
4. O número de camadas ocultas é inicialmente de uma. Se o problema não chegar a uma solução, opta-se por duas camadas;
5. Para a camada de saída, pode-se considerar uma regra: se a saída for contínua, usa-se a função linear e, se for lógica, a função tangente hiperbólica;
6. Estabelece-se algum critério de parada, seja este um número máximo de iterações, K_{max} , ou que o valor esperado atinja um erro máximo pré-estabelecido;
7. Calculam-se os erros da camada de saída;
8. Atualizam-se as sinapses mediante o ganho obtido;
9. Recalcula-se o vetor sinapse e retorna-se ao passo 7 até satisfazer o critério de parada.

Uma RNA realiza tanto o treinamento quanto o teste dos pares entrada-saída disponíveis, separando do conjunto completo de dados dois conjuntos, o conjunto de treinamento e o conjunto de teste. A rede é treinada com o primeiro conjunto e seu desempenho é avaliado com o segundo. Este procedimento é realizado objetivando detectar se a rede entrou em processo de super-especialização, ou seja, se a rede está “decorando” as saídas alvo, ao invés de predizê-las. Um refinamento deste processo é a utilização de um conjunto de dados adicional, denominado conjunto de validação, também selecionado de forma automática pelo programa, mas utilizado apenas após o término do treinamento da rede, quando então são preditos os valores da saída alvo, de forma a possibilitar a avaliação os erros de predição de padrões totalmente desconhecidos pela rede treinada. Caso os valores dos erros deste conjunto sejam muito superiores àqueles obtidos com os padrões de treinamento é certo que a rede entrou em processo de super-especialização, o que a torna incapaz de prever com base em padrões não constantes do conjunto de treinamento.

Ferreira (2002) apresentou uma avaliação inicial da capacidade das RNAs para predição das constantes do Modelo Composto. Em uma primeira tentativa optou por treinar a rede de modo que esta pudesse prever diretamente os valores das constantes K_i do Modelo Composto. Nesta tentativa, somente foram utilizadas para montagem do conjunto de dados entrada-saída da rede as amostras componentes da base de dados existente na época que não apresentavam lacunas relativas a dados faltantes, ou seja, aquelas das quais se dispunha dos valores de todas as variáveis de entrada consideradas. As saídas alvo foram constituídas dos valores de K_1 , K_2 e K_3 do Modelo Composto e as variáveis de entrada foram as seguintes:

- Granulometria, sendo um neurônio para cada peneira (PEN1, PEN38, PEN4, PEN10, PEN40 e PEN200), Limite de Liquidez (LL), Índice de Plasticidade (IP), Umidade de Moldagem (HMOLD), Densidade de Moldagem (DENSMOLD), CBR e Expansão (EXP).

Os resultados obtidos foram totalmente inconsistentes. Os valores de K_1 praticamente não variaram. Os valores de K_2 e K_3 , ao contrário, apresentaram grande variação. Ao final, o erro associado foi muito elevado, o que provavelmente foi causado pelo pequeno conjunto de pares entrada-saída disponíveis, apenas 223, agravado pela necessidade de a rede prever os valores de três variáveis.

Devido aos péssimos resultados obtidos, um problema incontornável tendo em vista a impossibilidade de aumentar o número de pares de modo a prover a rede dos subsídios necessários a um aprendizado adequado, optou-se por determinar as constantes do Modelo Composto de forma indireta. Assim, a variável de saída escolhida foi a deformação específica resiliente (ϵ_r), tendo em vista que, de posse deste valor e dos valores de σ_3 e σ_d , é possível, por regressão linear múltipla, a determinação das constantes K_1 , K_2 e K_3 . Este procedimento elevou o número de pares de entrada-saída da rede para um total de 3511, bastante satisfatório para implementação e treinamento de uma RNA.

Nesta alternativa foram introduzidas como variáveis de entrada os valores das tensões desvio e confinante aplicadas no ensaio triaxial dinâmico, além dos resultados dos ensaios geotécnicos tradicionais. Desta forma, o número de variáveis de entrada da rede foi de 14, tendo apenas uma saída alvo.

Nestas condições os resultados obtidos sofreram uma melhora considerável. Apesar de a rede treinada ter apresentado ainda uma confiabilidade muito aquém da

desejável, ficou evidenciado o significativo potencial para a predição pretendida e que, mediante um refinamento dos dados de entrada e o desenvolvimento de diversas alternativas em termos de arquitetura de rede, seria provável a obtenção de resultados práticos consistentes.

O trabalho agora apresentado é basicamente a tentativa de confirmação das hipóteses levantadas por Ferreira (2002) quanto à capacidade de predição pelas redes neurais dos valores de M_R .

Assim sendo, o estudo foi desenvolvido procurando em última análise simular o Ensaio Triaxial Dinâmico por intermédio de diversas arquiteturas de redes neurais, tendo como variáveis de entrada os parâmetros obtidos nos ensaios tradicionais de materiais para projetos de pavimentos e as tensões desvio e confinante aplicadas na metodologia de ensaio utilizada na COPPE/UFRJ. A variável de saída escolhida a princípio foi a deformação específica resiliente (ϵ_r), tendo em vista ser este o parâmetro obtido no ensaio. De posse deste valor e dos valores de σ_3 e σ_d , é possível, por regressão linear, a determinação das constantes de qualquer dos modelos de resiliência atualmente utilizados no Brasil.

Desta forma, as variáveis de entrada consideradas foram as relacionadas a seguir:

- Granulometria, sendo um neurônio para cada peneira (PEN1, PEN38, PEN4, PEN10, PEN40 e PEN200), Limite de Liquidez (LL), Índice de Grupo (IG), Índice de Plasticidade (IP), Umidade de Moldagem (HMOLD), Densidade de Moldagem (DENSMOLD), CBR, Expansão (EXP), Classificação TRB (TRB), σ_3 (S3), e σ_d (SD).

Os valores de deformação específica resiliente utilizados como saída alvo não foram os obtidos diretamente do ensaio. Estes valores foram recalculados após a otimização do Modelo Composto de Resiliência para cada amostra, feita mediante a eliminação das observações discrepantes conforme metodologia proposta por Ferreira (2002).

O desempenho relativo das redes treinadas foi avaliado mediante a comparação do Erro Percentual Médio obtido segundo a metodologia descrita a seguir. Um dos arquivos de saída do *software* Neuroshell-2 (*.out*) consiste dos erros absolutos entre as saídas alvo apresentadas à rede para treinamento e a saída calculada por esta, ou seja:

$$\text{Erro} = \text{Saída Alvo} - \text{Saída Calculada} \quad (8.1)$$

De posse desses valores foi determinado o erro percentual, em módulo, associado a cada padrão apresentado à rede, segundo a seguinte equação:

$$\text{Erro (\%)} = (\text{Erro} / \text{Saída Alvo}) \times 100 \quad (8.2)$$

O erro percentual médio de toda a rede foi determinado mediante a média aritmética do erro percentual obtido para todos os padrões, segundo a seguinte equação:

$$\text{Erro Percentual Médio (\%)} = \sum \text{Erro (\%)} / n \quad (8.3)$$

onde

“n” é o número total de padrões da base de dados utilizada.

Foram treinadas 11 redes tendo como saída alvo a deformação específica resiliente. De forma a sintetizar os dados de arquitetura e os resultados obtidos, foram elaboradas fichas individuais para cada uma delas.

Os dados constantes destas fichas são os seguintes:

- ARQUITETURA, onde é apresentado o número de camadas utilizado, o número de neurônios por camada e a função de ativação empregada. Assim, por exemplo, a “Rede Normalizada 1” foi treinada com três camadas, sendo uma oculta. A primeira camada foi definida com 16 neurônios (número de variáveis de entrada, *inputs*) e função de ativação Linear. A segunda camada (camada oculta) foi definida com 74 neurônios e função de ativação Logística. A terceira camada (camada de saída, *outputs*) foi definida com apenas 1 neurônio (saída alvo) e função de ativação Logística.

- NÚMERO DE PADRÕES, onde são apresentados o número e o percentual em relação ao total dos padrões alocados em cada conjunto de treinamento, teste e validação. Por exemplo, para a “Rede Normalizada 1” foram alocados 4.248 padrões no conjunto de treinamento e 1.062 no conjunto de teste, perfazendo respectivamente 80% e 20% do número total de padrões apresentados à rede, que foi de 5.310.

- ERRO PERCENTUAL MÉDIO DOS CONJUNTOS, onde são apresentados os erros obtidos para cada conjunto (treinamento, teste e validação) e para toda a rede

(total). Por exemplo, para a “Rede Normalizada 1” foi obtido um erro percentual médio de 42% para toda a rede, não tendo sido calculados os erros relativos a cada conjunto.

- ESTATÍSTICA DA REDE, onde são apresentados os resultados estatísticos da rede já treinada, composta dos seguintes parâmetros:

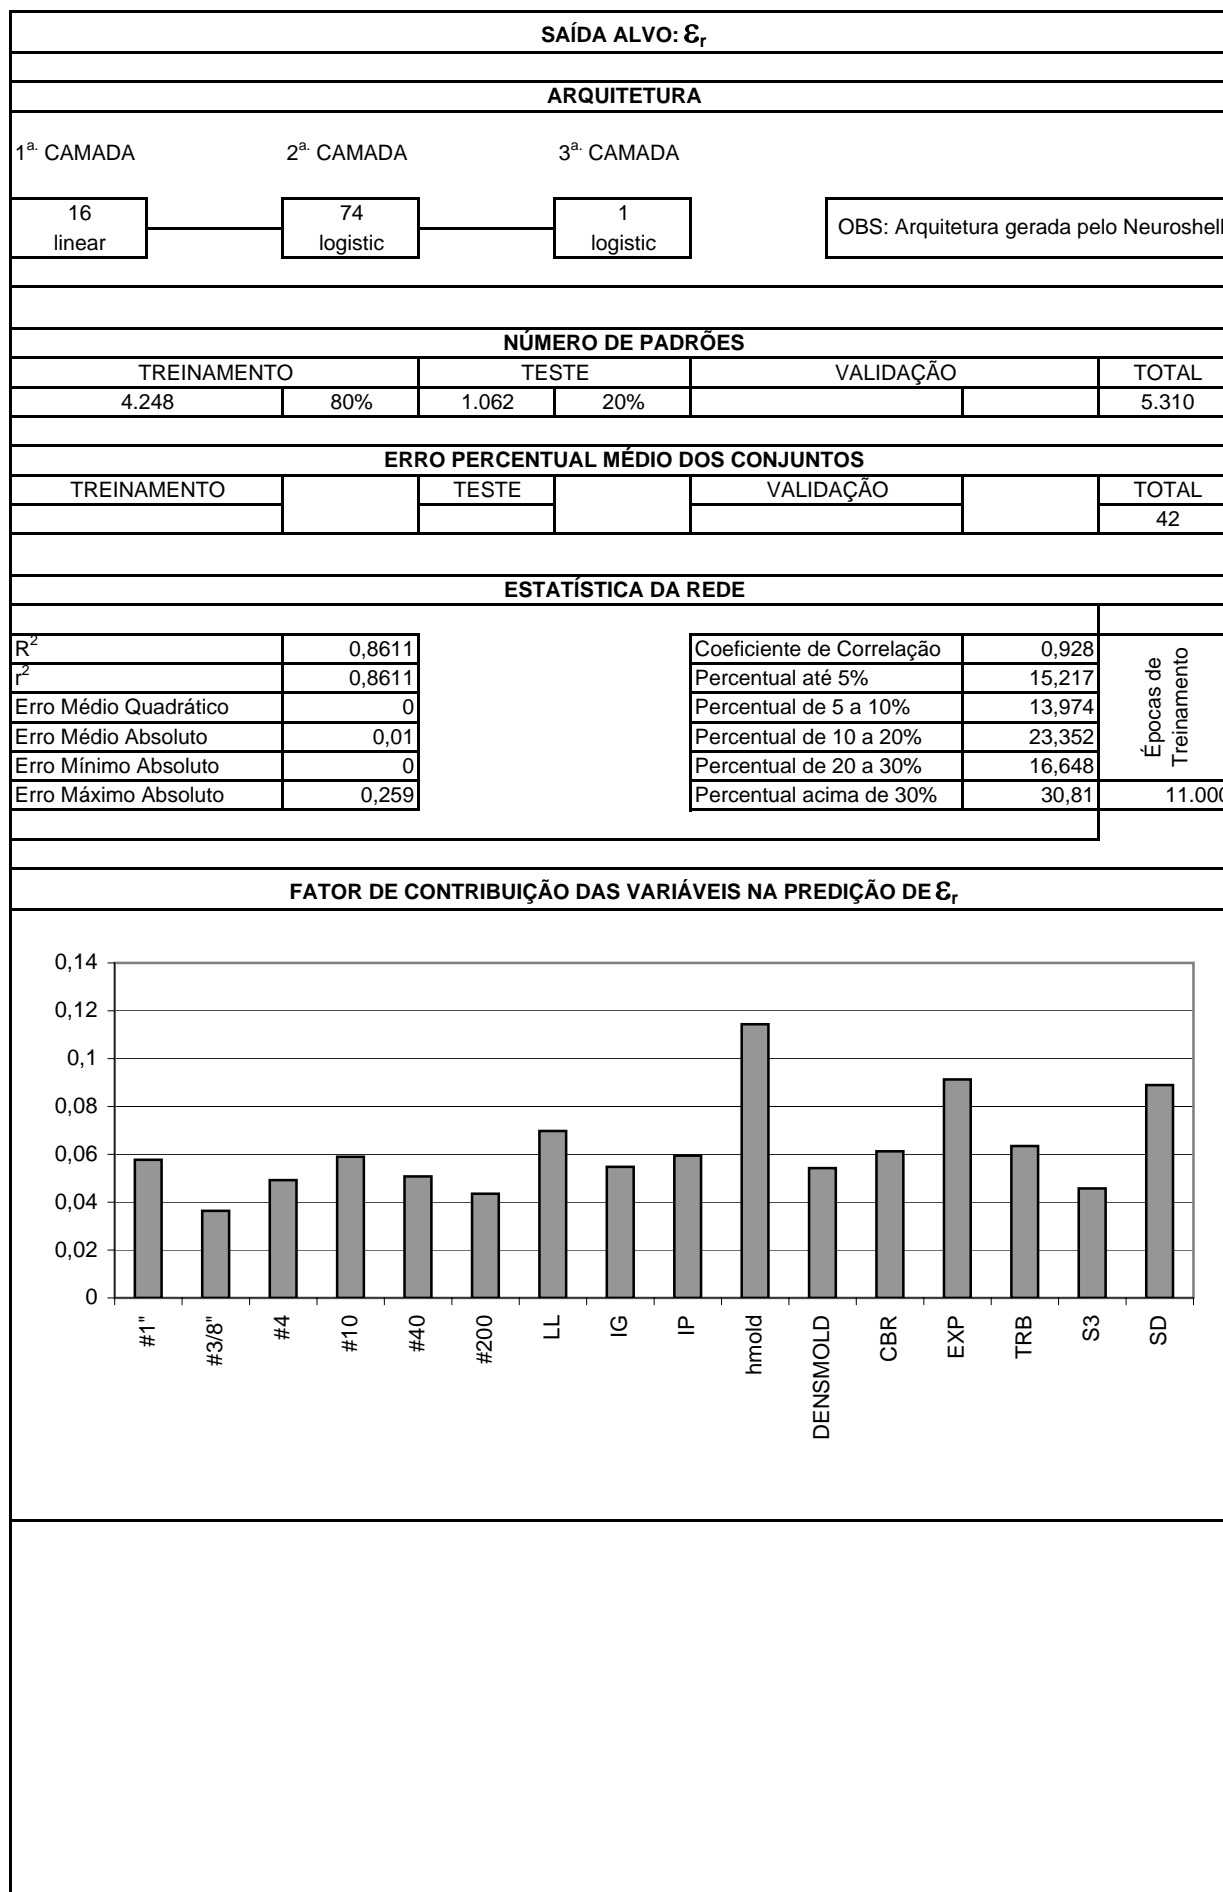
- R^2 – Coeficiente de determinação múltipla, que representa a variação da variável dependente que é explicada pelo conjunto de variáveis independentes selecionadas;
- r^2 – É o quadrado do Coeficiente de Correlação Linear de Pearson;
- Erro Médio Quadrático – Média de todas as saídas alvo menos as saídas preditas, elevada ao quadrado;
- Erro Médio Absoluto – Média de todas as saídas alvo menos as saídas preditas;
- Erro Mínimo Absoluto – É o menor erro entre todos os pares saída alvo menos saída predita;
- Erro Máximo Absoluto – É o maior erro entre todos os pares saída alvo menos saída predita;
- Coeficiente de Correlação – Coeficiente de Correlação Linear de Pearson, que é uma medida estatística da força de relacionamento entre as saídas alvo e as saídas preditas.
- Os valores indicados como “Percentual até 5%, de 5 a 10%, de 10 a 20%, de 20 a 30% e acima de 30%” indicam o percentual de padrões que apresentaram erros nestas faixas. Por exemplo, para a “Rede Normalizada 1”, 15,217% dos padrões apresentaram erro até 5%, 13,874% apresentaram erro ente 5 e 10%, 23,352% apresentaram erro de 10 a 20%, 16,648% apresentaram erro de 20 a 30% e 30,810% apresentaram erro acima de 30%.
- Épocas de Treinamento indica o número de épocas treinadas pela rede. No caso da “Rede Normalizada 1”, a mesma foi treinada por 11.000 épocas. Uma época equivale a uma apresentação de todos os pares entrada-saída à rede.

- FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE ε_a (ou M_R), onde é apresentada a contribuição relativa de cada variável na predição da variável de saída considerada. Por exemplo, no caso da “Rede Normalizada 1”, a umidade de moldagem (hmold) contribui com quase 0,12.

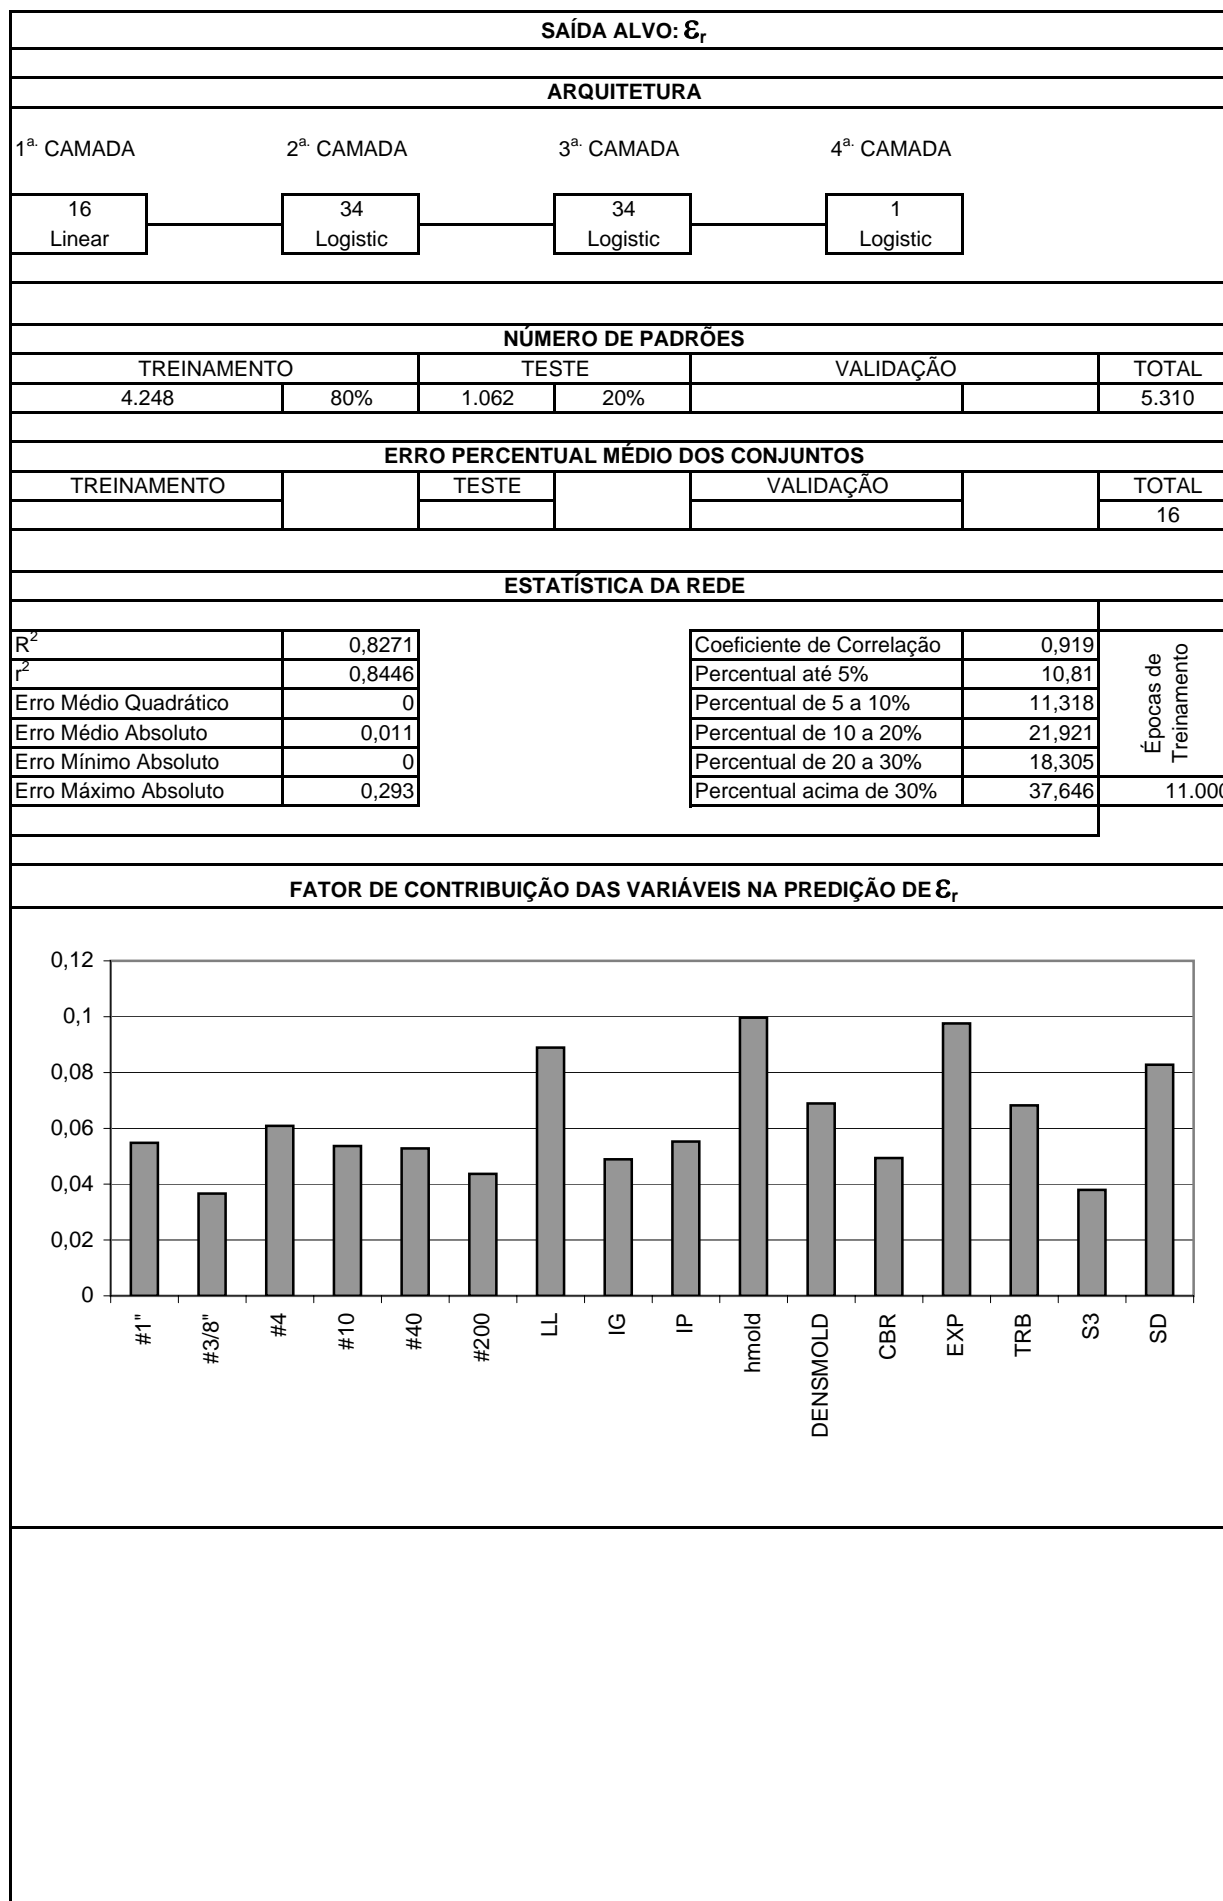
- ERRO PERCENTUAL MÉDIO DAS AMOSTRAS DE TESTE, onde são apresentados os erros percentuais médios obtidos para cada amostra reservada para validação da rede (não constaram da base de dados utilizada no treinamento). Por exemplo, para a “Rede Módulo 5”, o erro da amostra 290 é de 105% e a média dos erros das amostras de validação é de 141%.

As fichas individuais para cada rede treinada são apresentadas a seguir, constantes dos Quadros 8.1 a 8.11.

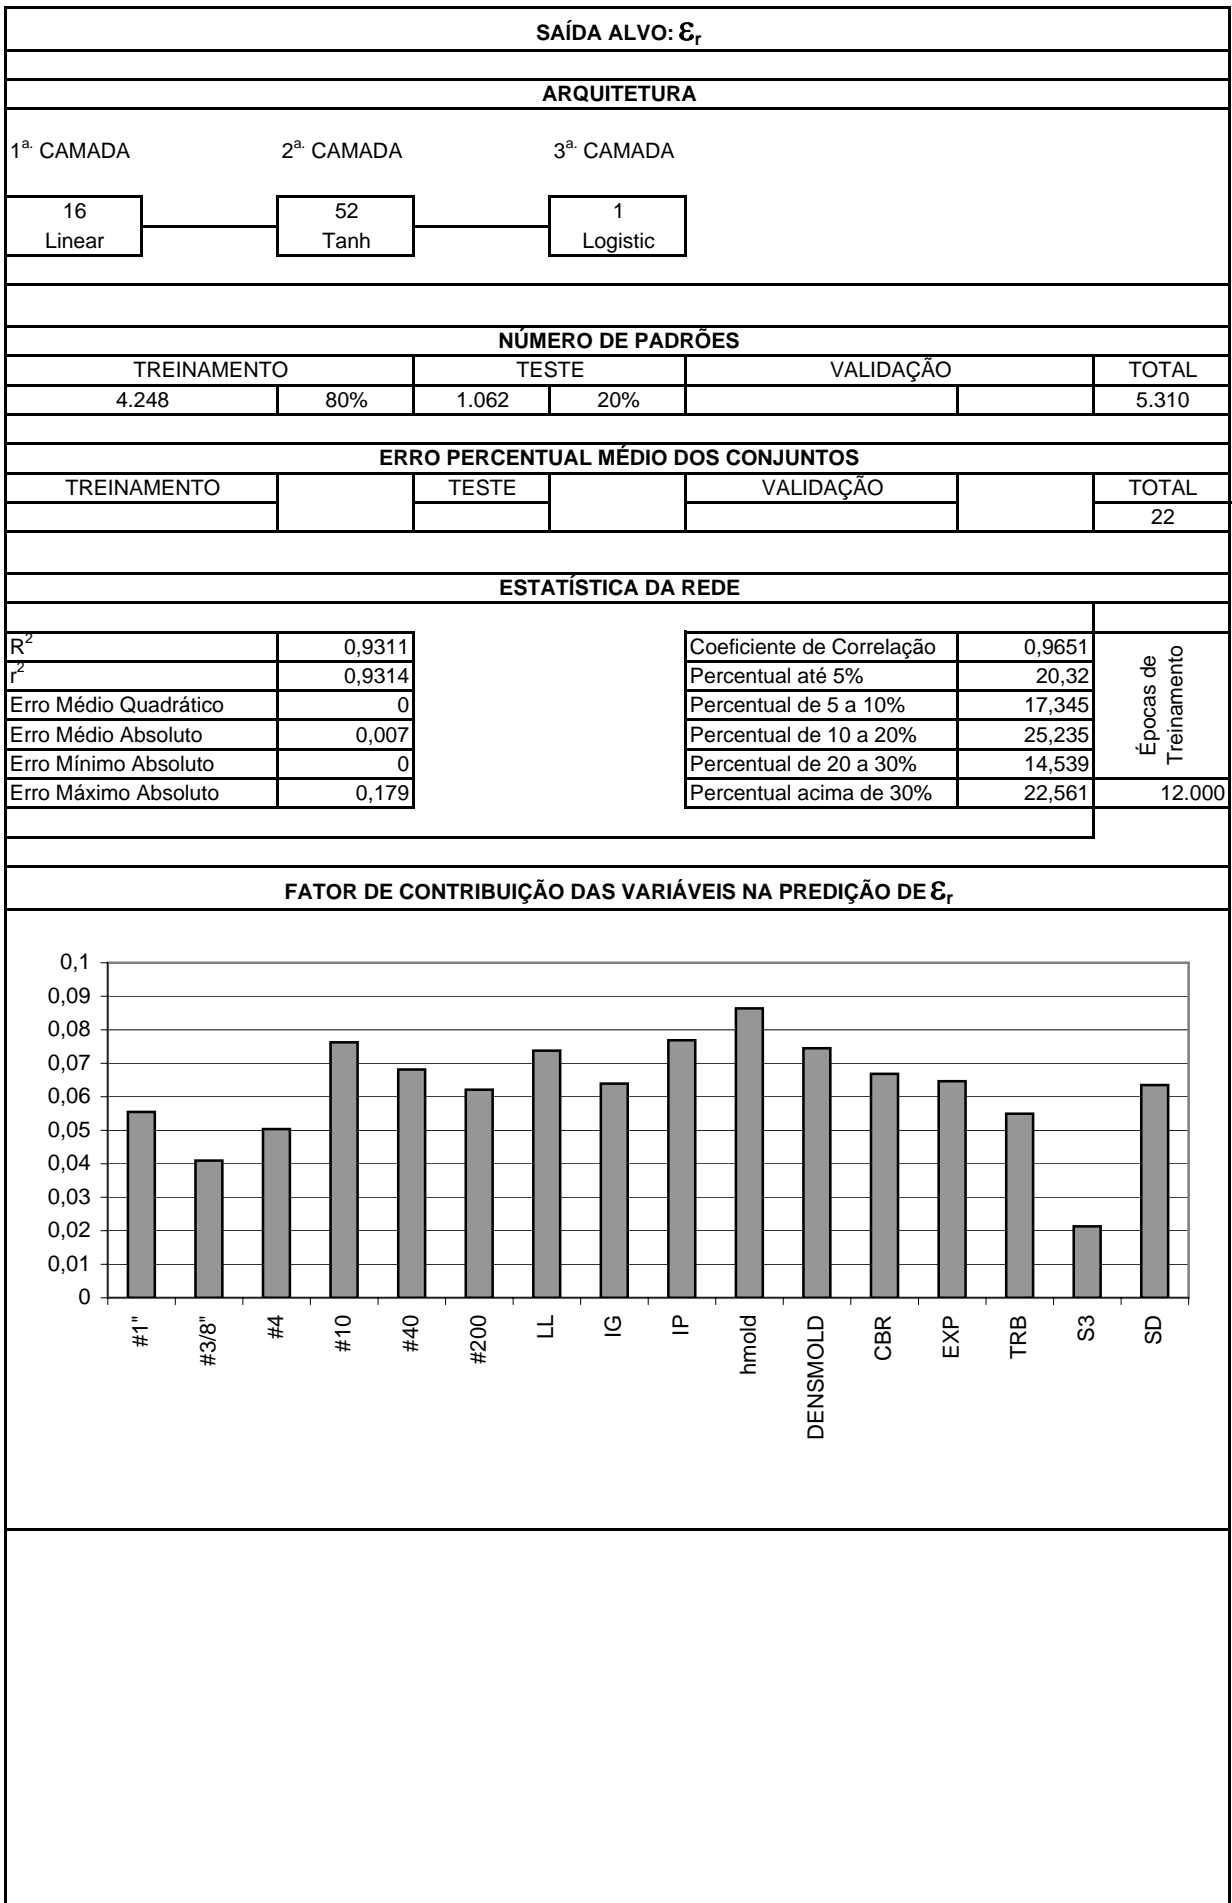
Quadro 8.1 - Rede Normalizada 1



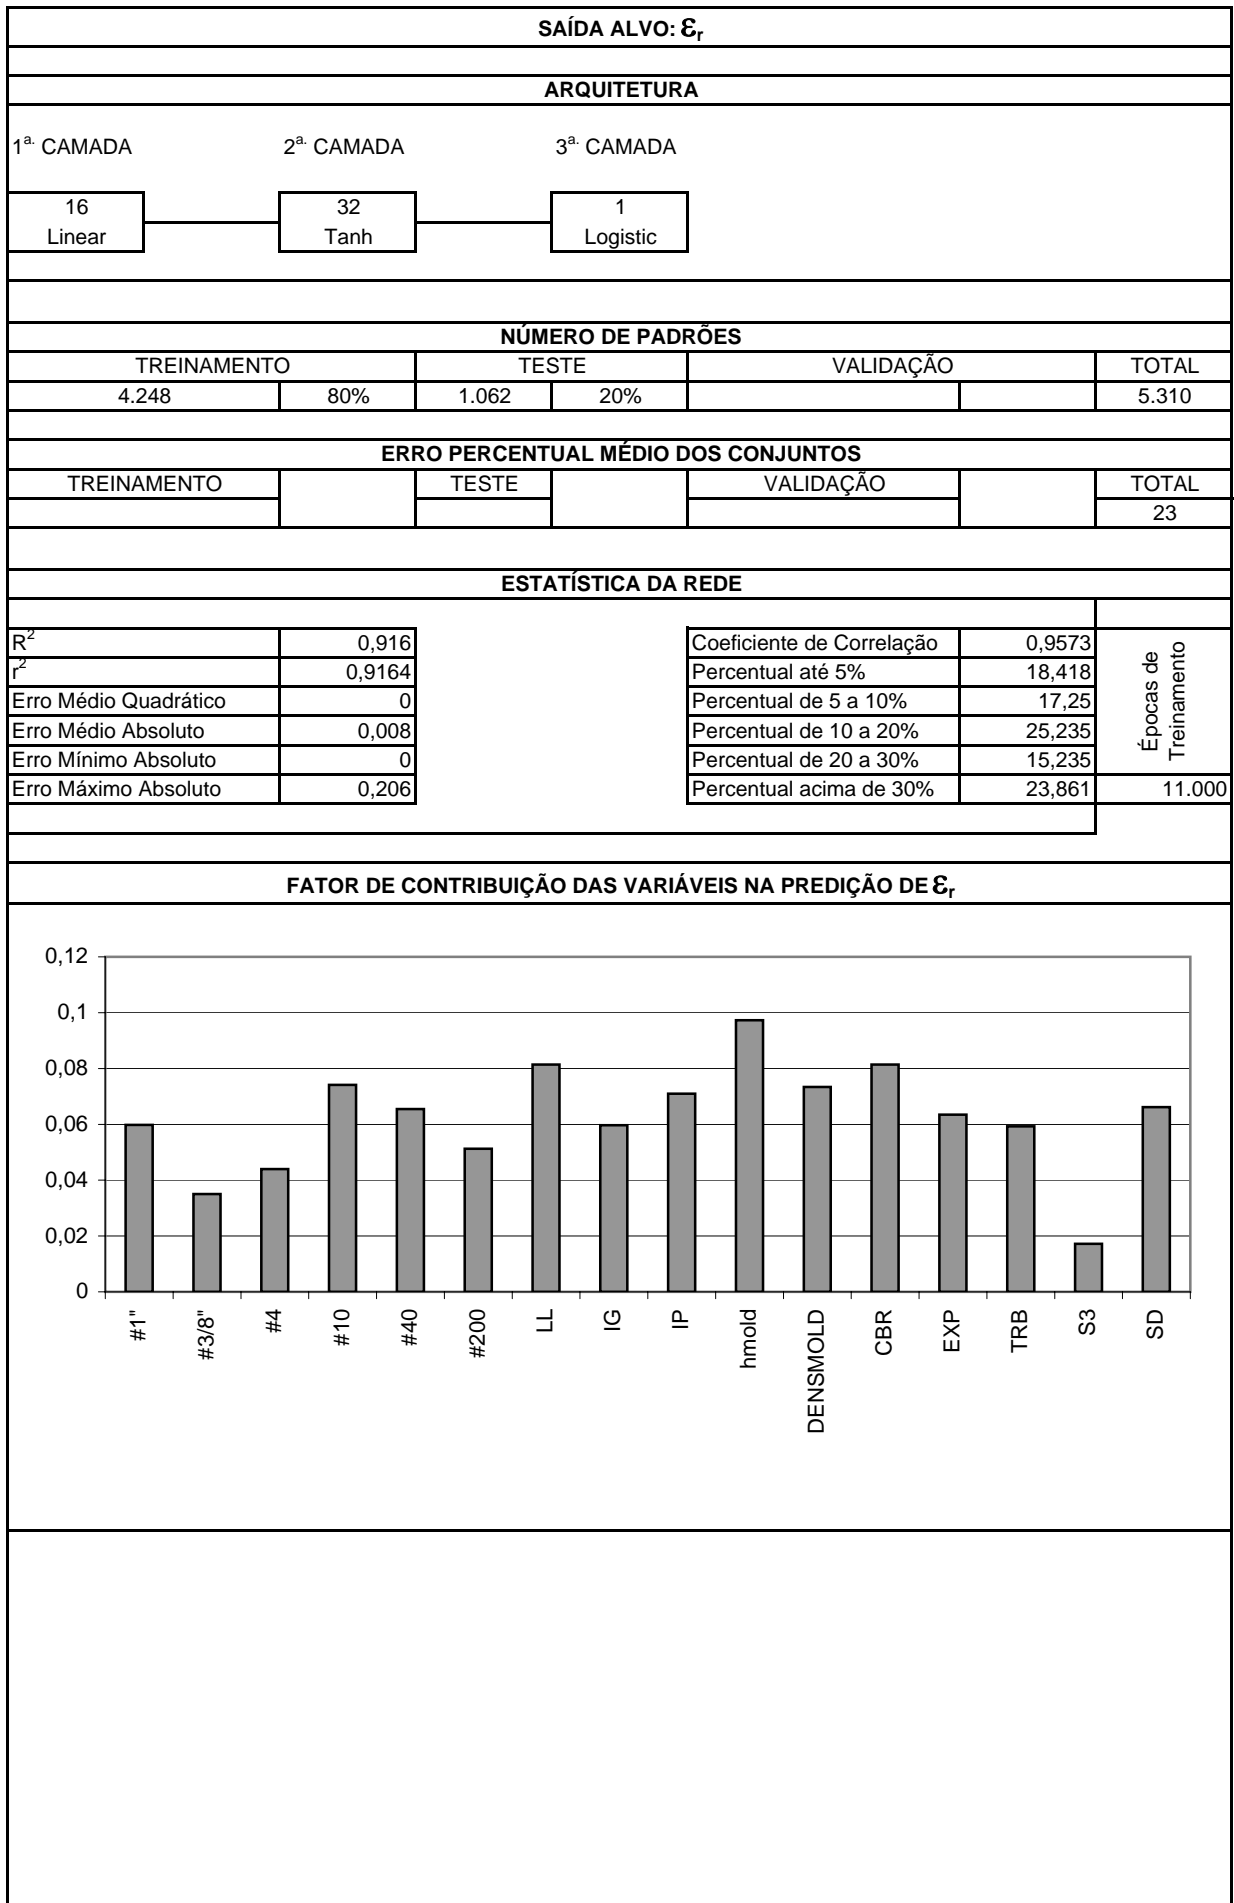
Quadro 8.2 - Rede Normalizada 2



Quadro 8.3 - Rede Normalizada 3



Quadro 8.4 - Rede Normalizada 4



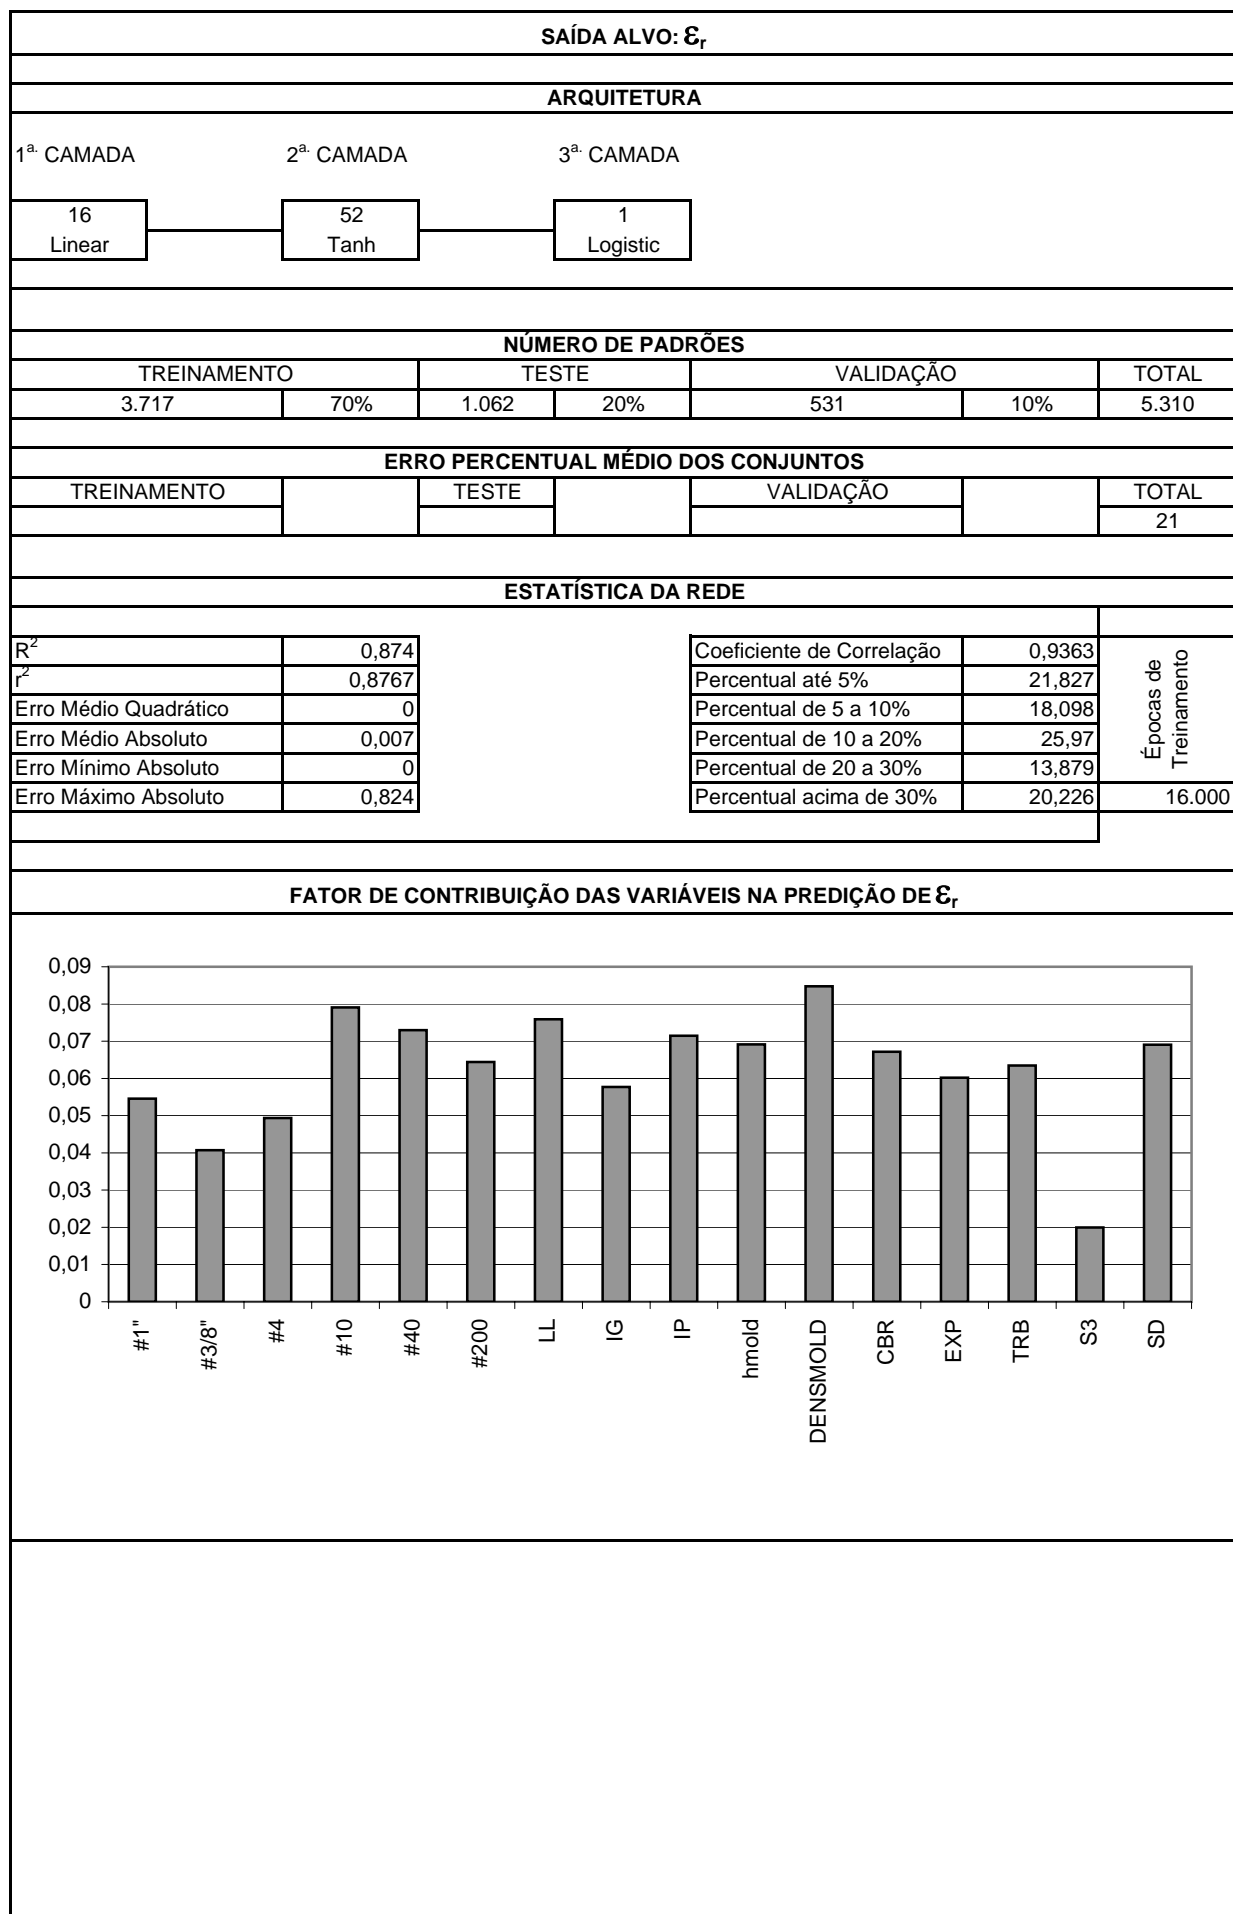
Quadro 8.5 - Rede Normalizada 5

SAÍDA ALVO: ϵ_r																																								
ARQUITETURA																																								
1ª CAMADA	2ª CAMADA			3ª CAMADA																																				
16 Linear	64 Tanh			1 Logistic																																				
NÚMERO DE PADRÕES																																								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																																		
4.248	80%	1.062	20%			5.310																																		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS																																								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																																		
						23																																		
ESTATÍSTICA DA REDE																																								
R^2	0,9208				Coeficiente de Correlação	0,9596																																		
r^2	0,9208				Percentual até 5%	20,546																																		
Erro Médio Quadrático	0				Percentual de 5 a 10%	17,853																																		
Erro Médio Absoluto	0,007				Percentual de 10 a 20%	23,635																																		
Erro Mínimo Absoluto	0				Percentual de 20 a 30%	13,691																																		
Erro Máximo Absoluto	0,248				Percentual acima de 30%	24,275																																		
						Épocas de Treinamento																																		
						11.000																																		
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE ϵ_r																																								
<table border="1" style="margin-top: 10px; width: 100%; border-collapse: collapse;"> <caption>Contribuição das Variáveis na Predição de ϵ_r</caption> <thead> <tr> <th>Variável</th> <th>Fator de Contribuição</th> </tr> </thead> <tbody> <tr><td>#1</td><td>0,055</td></tr> <tr><td>#3/8</td><td>0,042</td></tr> <tr><td>#4</td><td>0,046</td></tr> <tr><td>#10</td><td>0,066</td></tr> <tr><td>#40</td><td>0,069</td></tr> <tr><td>#200</td><td>0,058</td></tr> <tr><td>LL</td><td>0,079</td></tr> <tr><td>IG</td><td>0,065</td></tr> <tr><td>IP</td><td>0,074</td></tr> <tr><td>hmodal</td><td>0,092</td></tr> <tr><td>DENSMOLD</td><td>0,065</td></tr> <tr><td>CBR</td><td>0,066</td></tr> <tr><td>EXP</td><td>0,066</td></tr> <tr><td>TRB</td><td>0,060</td></tr> <tr><td>S3</td><td>0,028</td></tr> <tr><td>SD</td><td>0,065</td></tr> </tbody> </table>							Variável	Fator de Contribuição	#1	0,055	#3/8	0,042	#4	0,046	#10	0,066	#40	0,069	#200	0,058	LL	0,079	IG	0,065	IP	0,074	hmodal	0,092	DENSMOLD	0,065	CBR	0,066	EXP	0,066	TRB	0,060	S3	0,028	SD	0,065
Variável	Fator de Contribuição																																							
#1	0,055																																							
#3/8	0,042																																							
#4	0,046																																							
#10	0,066																																							
#40	0,069																																							
#200	0,058																																							
LL	0,079																																							
IG	0,065																																							
IP	0,074																																							
hmodal	0,092																																							
DENSMOLD	0,065																																							
CBR	0,066																																							
EXP	0,066																																							
TRB	0,060																																							
S3	0,028																																							
SD	0,065																																							

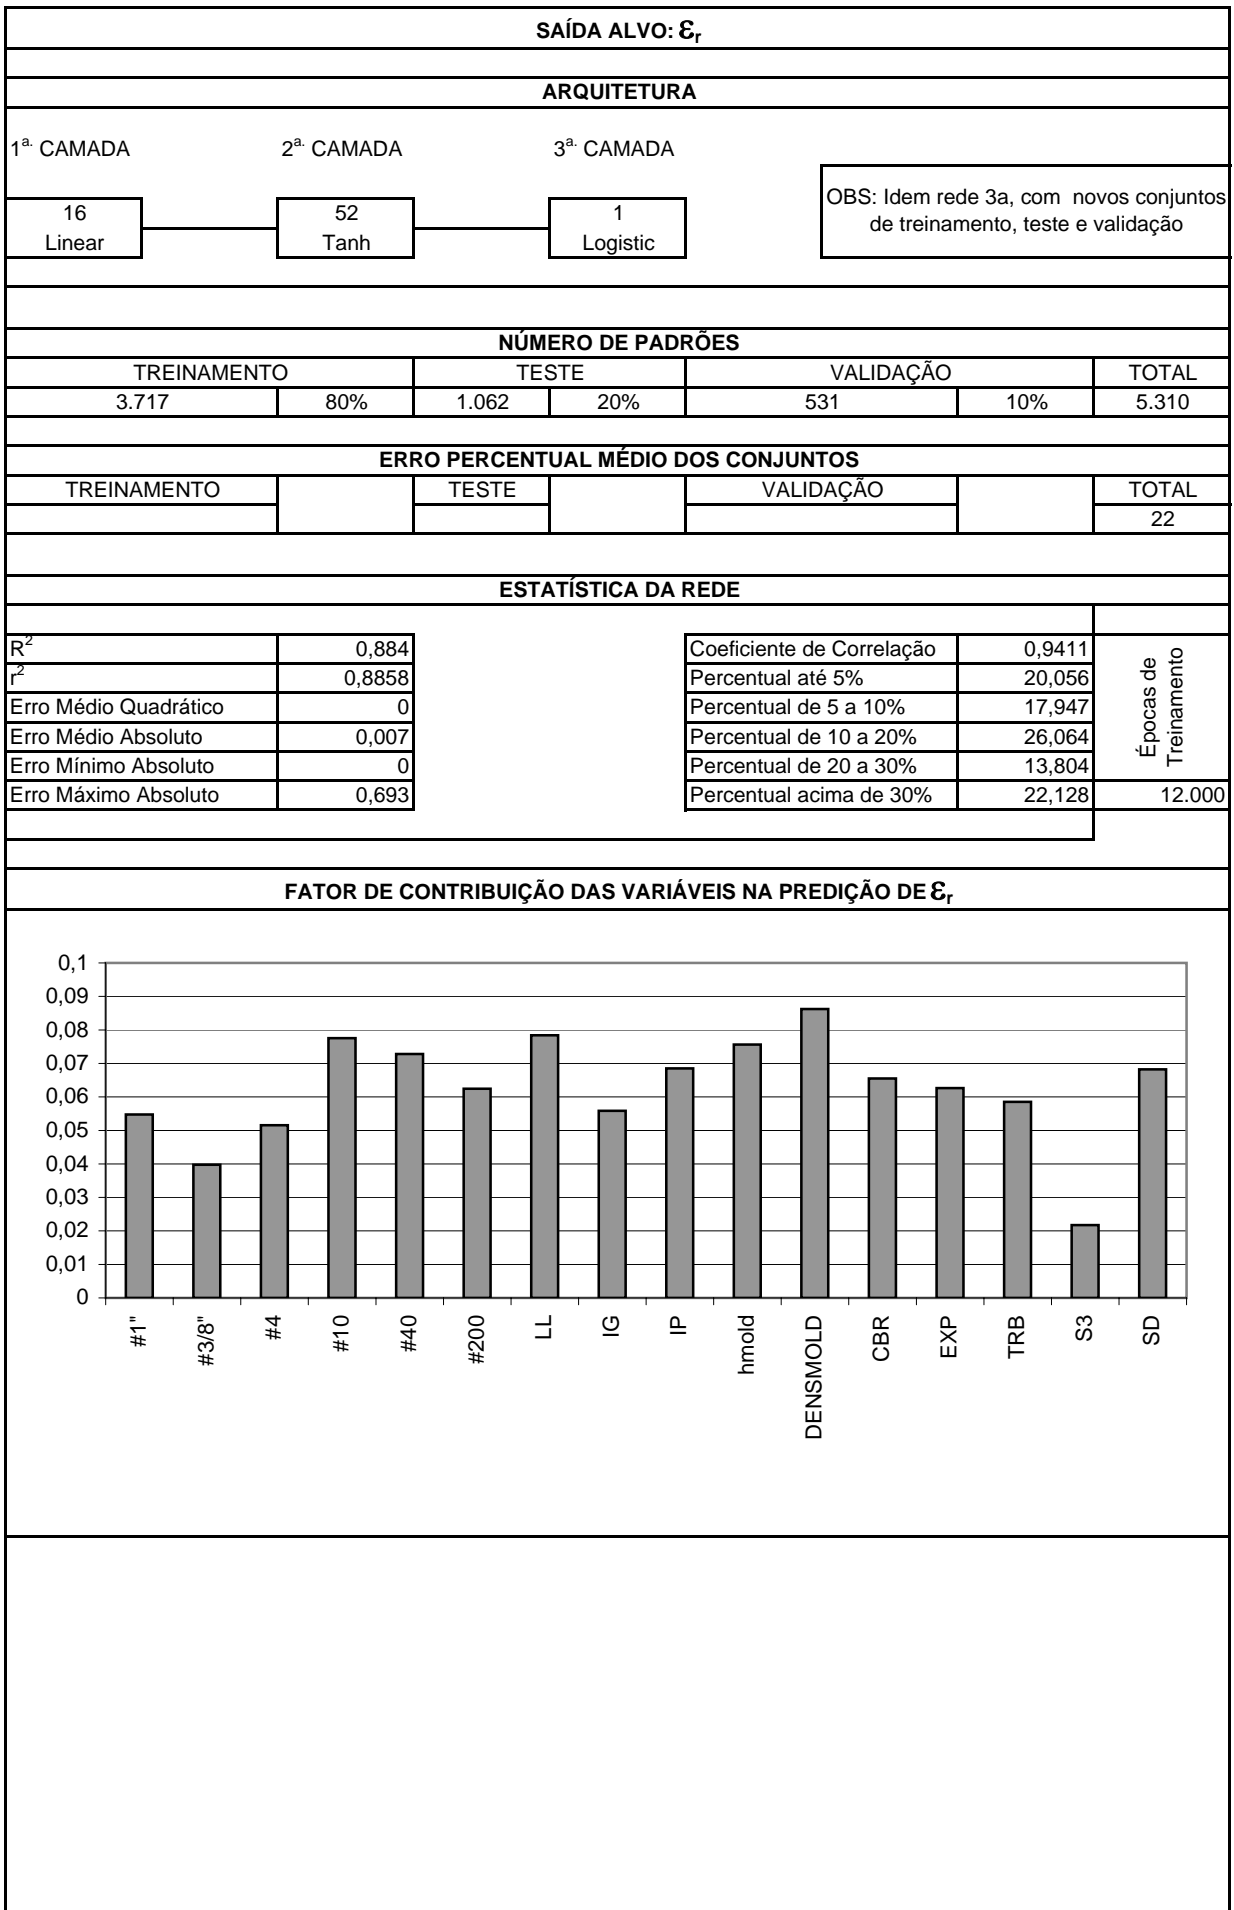
Quadro 8.6 - Rede Normalizada 6

SAÍDA ALVO: ϵ_r																																								
ARQUITETURA																																								
1ª. CAMADA		2ª. CAMADA		3ª. CAMADA																																				
16 Linear		32 Logistic		1 Logistic																																				
NÚMERO DE PADRÕES																																								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																																		
4.248		80%		1.062		20%																																		
						5.310																																		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS																																								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																																		
						27																																		
ESTATÍSTICA DA REDE																																								
R^2	0,8677	Coeficiente de Correlação			0,9316	Épocas de Treinamento																																		
r^2	0,8678	Percentual até 5%			17,476																																			
Erro Médio Quadrático	0	Percentual de 5 a 10%			14,934																																			
Erro Médio Absoluto	0,009	Percentual de 10 a 20%			22,524																																			
Erro Mínimo Absoluto	0	Percentual de 20 a 30%			14,953																																			
Erro Máximo Absoluto	0,24	Percentual acima de 30%			30,113																																			
					14.000																																			
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE ϵ_r																																								
<table border="1"> <caption>Data for Fator de Contribuição das Variáveis na Predição de ϵ_r</caption> <thead> <tr> <th>Variável</th> <th>Fator de Contribuição</th> </tr> </thead> <tbody> <tr><td>#1</td><td>0,070</td></tr> <tr><td>#3/8</td><td>0,035</td></tr> <tr><td>#4</td><td>0,058</td></tr> <tr><td>#10</td><td>0,055</td></tr> <tr><td>#40</td><td>0,050</td></tr> <tr><td>#200</td><td>0,052</td></tr> <tr><td>LL</td><td>0,085</td></tr> <tr><td>IG</td><td>0,055</td></tr> <tr><td>IP</td><td>0,058</td></tr> <tr><td>hmold</td><td>0,105</td></tr> <tr><td>DENSMOLD</td><td>0,060</td></tr> <tr><td>CBR</td><td>0,060</td></tr> <tr><td>EXP</td><td>0,085</td></tr> <tr><td>TRB</td><td>0,050</td></tr> <tr><td>S3</td><td>0,040</td></tr> <tr><td>SD</td><td>0,082</td></tr> </tbody> </table>							Variável	Fator de Contribuição	#1	0,070	#3/8	0,035	#4	0,058	#10	0,055	#40	0,050	#200	0,052	LL	0,085	IG	0,055	IP	0,058	hmold	0,105	DENSMOLD	0,060	CBR	0,060	EXP	0,085	TRB	0,050	S3	0,040	SD	0,082
Variável	Fator de Contribuição																																							
#1	0,070																																							
#3/8	0,035																																							
#4	0,058																																							
#10	0,055																																							
#40	0,050																																							
#200	0,052																																							
LL	0,085																																							
IG	0,055																																							
IP	0,058																																							
hmold	0,105																																							
DENSMOLD	0,060																																							
CBR	0,060																																							
EXP	0,085																																							
TRB	0,050																																							
S3	0,040																																							
SD	0,082																																							

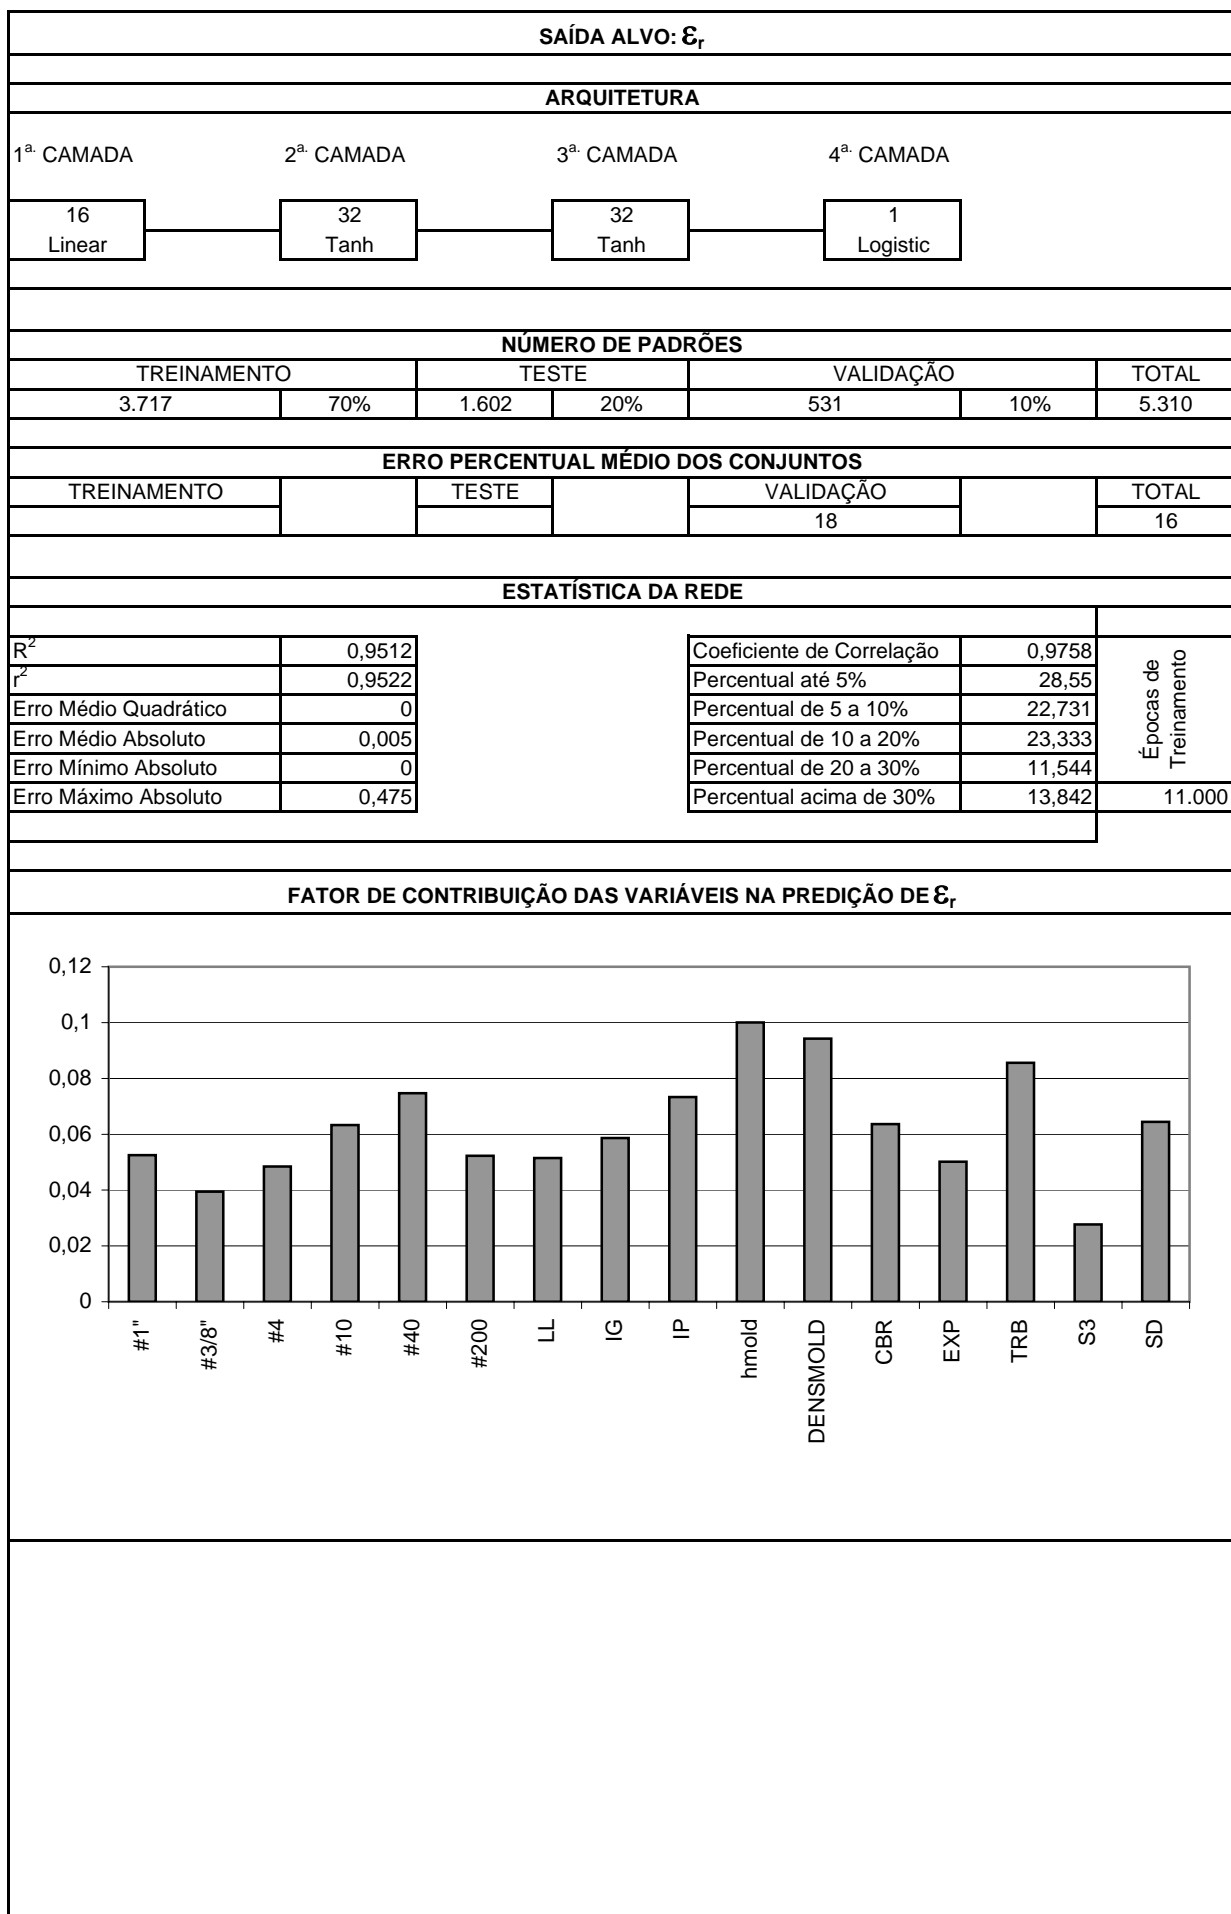
Quadro 8.7 - Rede Normalizada 3a



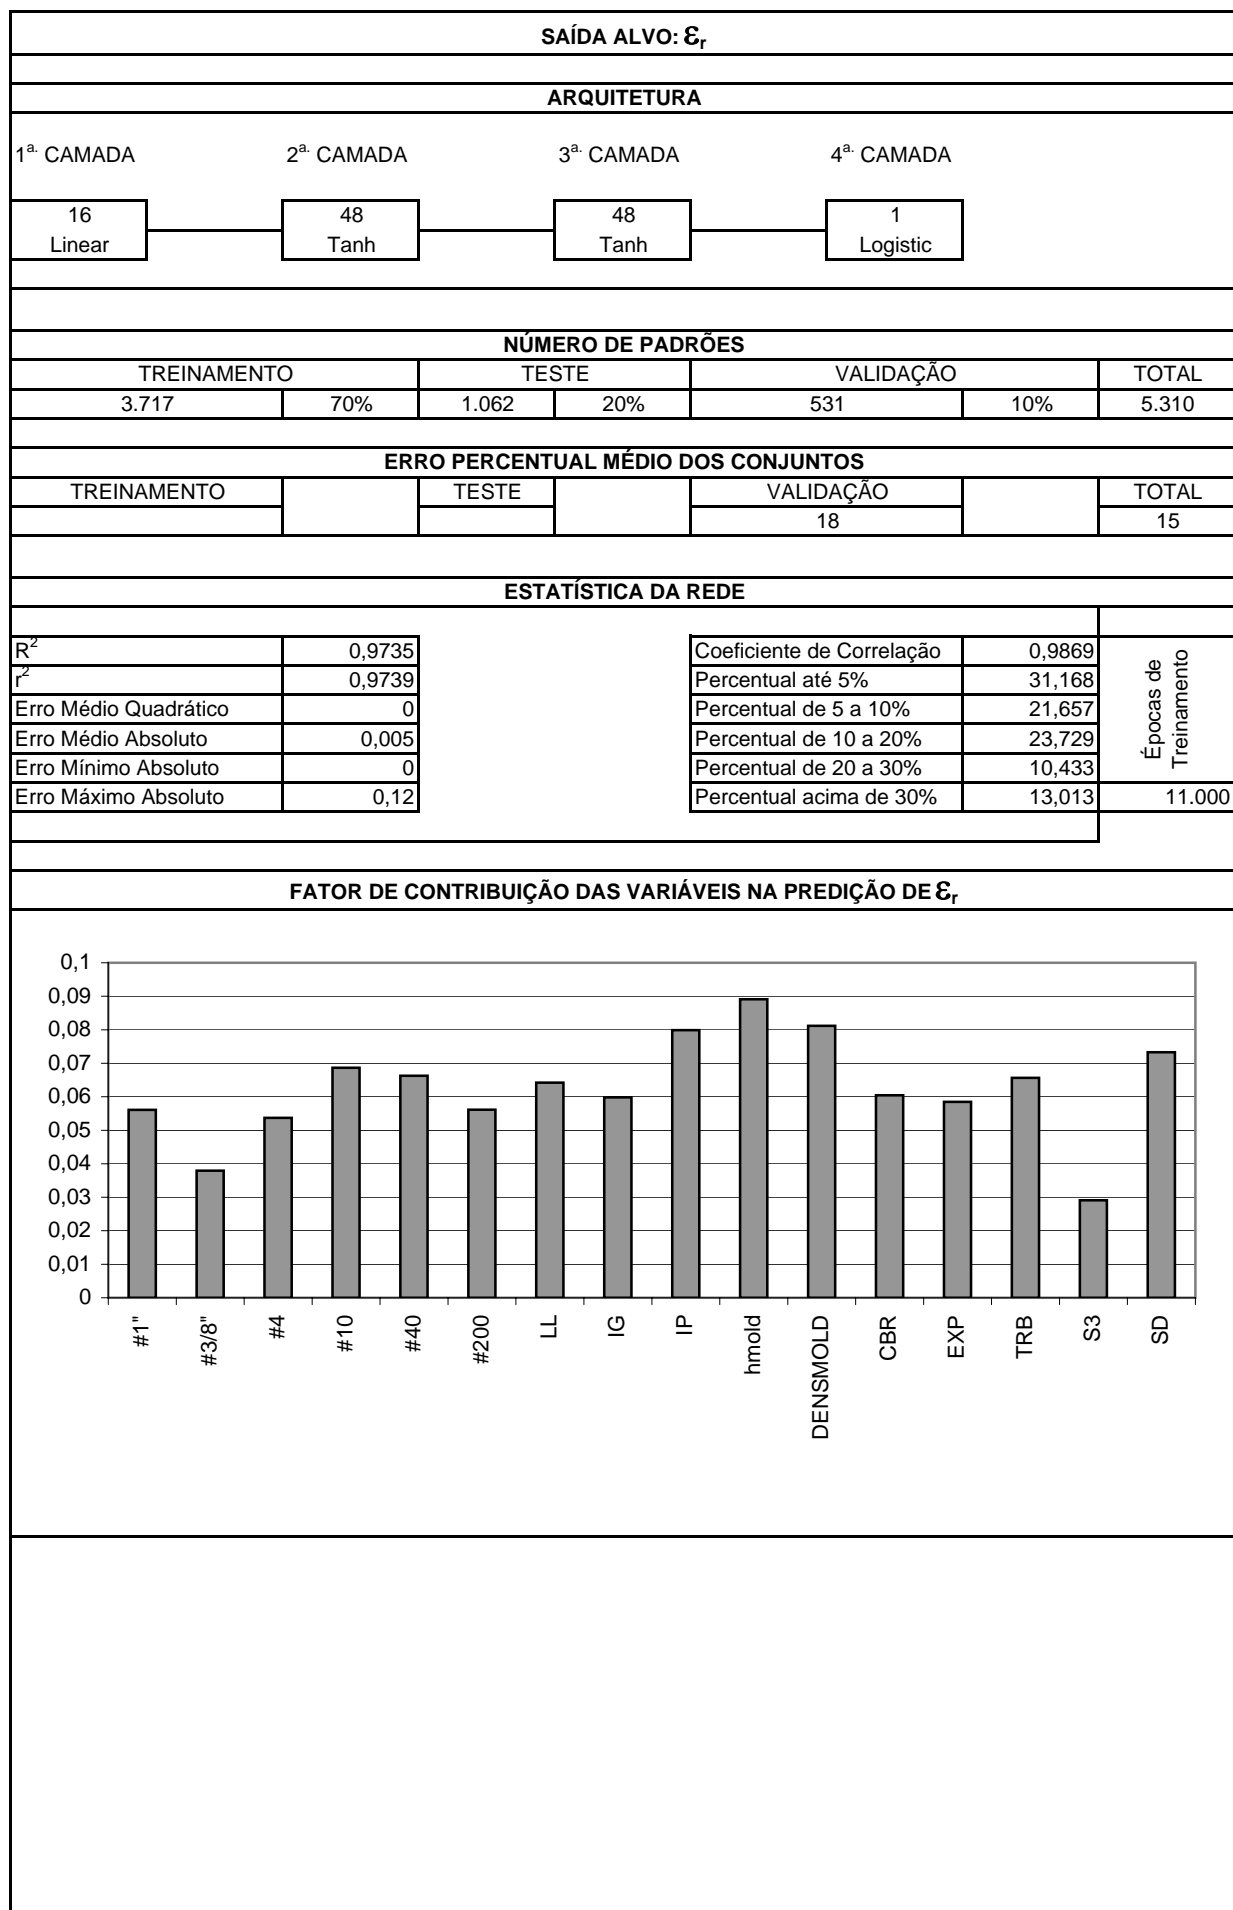
Quadro 8.8 - Rede Normalizada 3b



Quadro 8.9 - Rede Normalizada 2a



Quadro 8.10 - Rede Normalizada 2b



Quadro 8.11 - Rede Normalizada 2c

SAÍDA ALVO: ϵ_r																																					
ARQUITETURA																																					
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA																																		
16 Linear	48 Tanh	48 Tanh	1 Logistic																																		
NÚMERO DE PADRÕES																																					
TREINAMENTO	TESTE		VALIDAÇÃO																																		
4.104	80%	1.026	20%																																		
			TOTAL																																		
			5.130																																		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS																																					
TREINAMENTO	TESTE		VALIDAÇÃO																																		
			TOTAL																																		
			8																																		
ESTATÍSTICA DA REDE																																					
R^2	0,9952	Coeficiente de Correlação	0,9976																																		
r^2	0,9953	Percentual até 5%	55,4																																		
Erro Médio Quadrático	0	Percentual de 5 a 10%	21,54																																		
Erro Médio Absoluto	0,002	Percentual de 10 a 20%	14,055																																		
Erro Mínimo Absoluto	0	Percentual de 20 a 30%	3,899																																		
Erro Máximo Absoluto	0,055	Percentual acima de 30%	5,107																																		
			Épocas de Treinamento																																		
			34.000																																		
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE ϵ_r																																					
<table border="1" style="display: none;"> <caption>Data for Fator de Contribuição das Variáveis</caption> <thead> <tr> <th>Variável</th> <th>Fator de Contribuição</th> </tr> </thead> <tbody> <tr><td>#1</td><td>0,051</td></tr> <tr><td>#3/8</td><td>0,042</td></tr> <tr><td>#4</td><td>0,052</td></tr> <tr><td>#10</td><td>0,062</td></tr> <tr><td>#40</td><td>0,070</td></tr> <tr><td>#200</td><td>0,052</td></tr> <tr><td>LL</td><td>0,069</td></tr> <tr><td>IG</td><td>0,060</td></tr> <tr><td>IP</td><td>0,072</td></tr> <tr><td>hmodal</td><td>0,077</td></tr> <tr><td>DENSMOLD</td><td>0,085</td></tr> <tr><td>CBR</td><td>0,072</td></tr> <tr><td>EXP</td><td>0,062</td></tr> <tr><td>TRB</td><td>0,070</td></tr> <tr><td>S3</td><td>0,028</td></tr> <tr><td>SD</td><td>0,075</td></tr> </tbody> </table>				Variável	Fator de Contribuição	#1	0,051	#3/8	0,042	#4	0,052	#10	0,062	#40	0,070	#200	0,052	LL	0,069	IG	0,060	IP	0,072	hmodal	0,077	DENSMOLD	0,085	CBR	0,072	EXP	0,062	TRB	0,070	S3	0,028	SD	0,075
Variável	Fator de Contribuição																																				
#1	0,051																																				
#3/8	0,042																																				
#4	0,052																																				
#10	0,062																																				
#40	0,070																																				
#200	0,052																																				
LL	0,069																																				
IG	0,060																																				
IP	0,072																																				
hmodal	0,077																																				
DENSMOLD	0,085																																				
CBR	0,072																																				
EXP	0,062																																				
TRB	0,070																																				
S3	0,028																																				
SD	0,075																																				

Os resultados obtidos utilizando-se a deformação específica resiliente como saída alvo permitiram algumas conclusões, quais sejam:

- O problema é por demais complexo para ser devidamente mapeado por arquiteturas mais simples, com apenas uma camada oculta ou com duas camadas com número reduzido de neurônios;
- A rede “2c” obteve os melhores resultados, mas com aproximadamente 32.000 épocas de treinamento, enquanto as demais foram treinadas de 10.000 a 20.000 épocas;
- Apesar do erro percentual médio obtido na rede normalizada 2c (8%) ser um valor excelente, o número de saídas alvo com erro elevado ainda é muito grande, não permitindo uma utilização prática da rede treinada;

Constatou-se que há uma tendência clara de ocorrência dos maiores erros de predição quando as deformações específicas normalizadas atingem a ordem de grandeza de milésimos, o que pode significar uma dificuldade intrínseca das RNAs em prever convenientemente valores desta ordem.

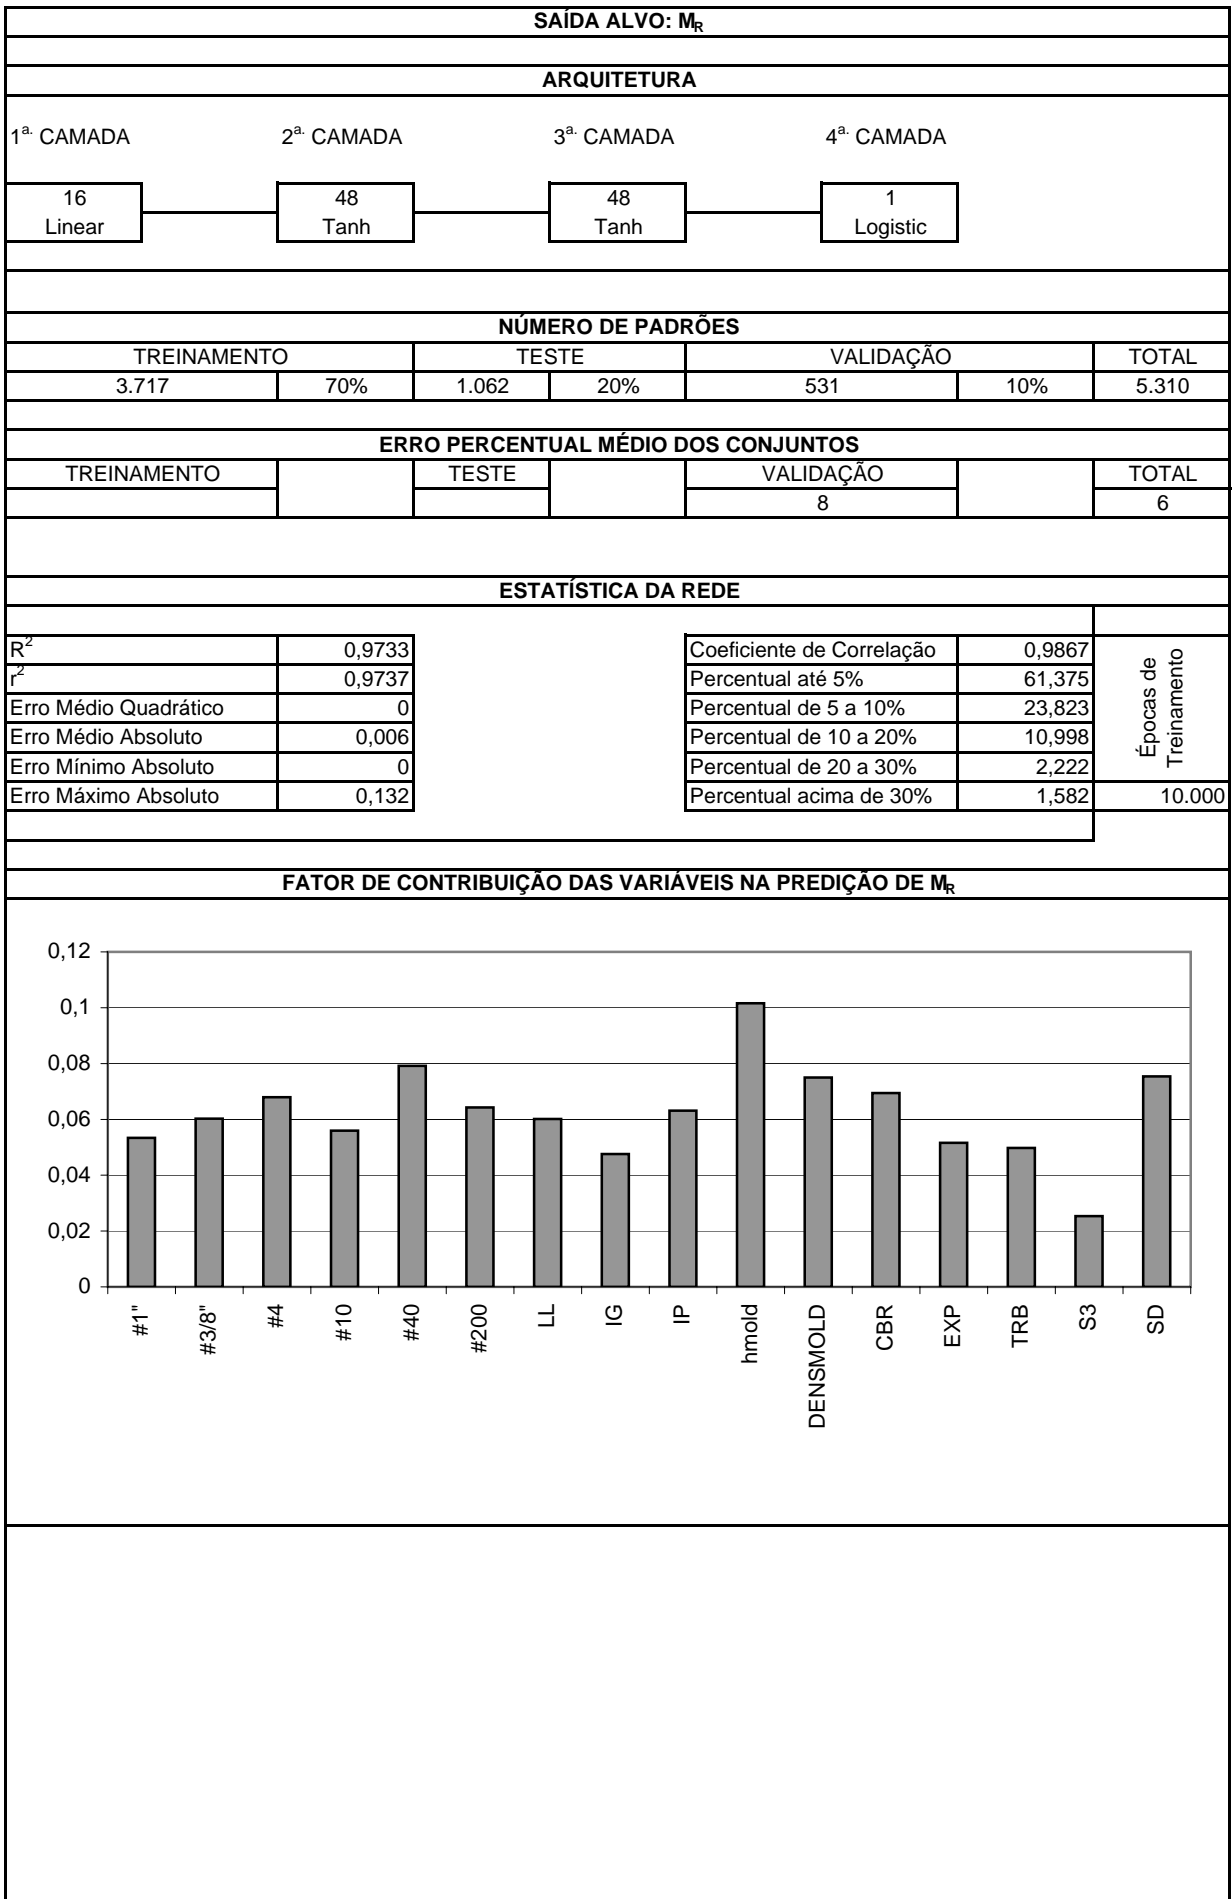
Em função destas dificuldades, optou-se pela obtenção indireta dos valores da deformação específica, determinando-se como saída alvo o valor do Módulo de Resiliência, que quando normalizado atinge geralmente ordens de grandeza de décimos e no máximo de centésimos. Foram inicialmente utilizadas 10 diferentes configurações, variando-se arquiteturas, conjuntos de teste, treinamento e validação, número de variáveis de entrada e a própria base de dados.

Os resultados obtidos tendo como saída alvo o valor do Módulo de Resiliência foram muito melhores que aqueles obtidos quando considerada como saída alvo a deformação específica resiliente, uma vez que os erros percentuais médios apresentaram uma queda significativa. A partir desta constatação, as análises foram aprofundadas para esta condição.

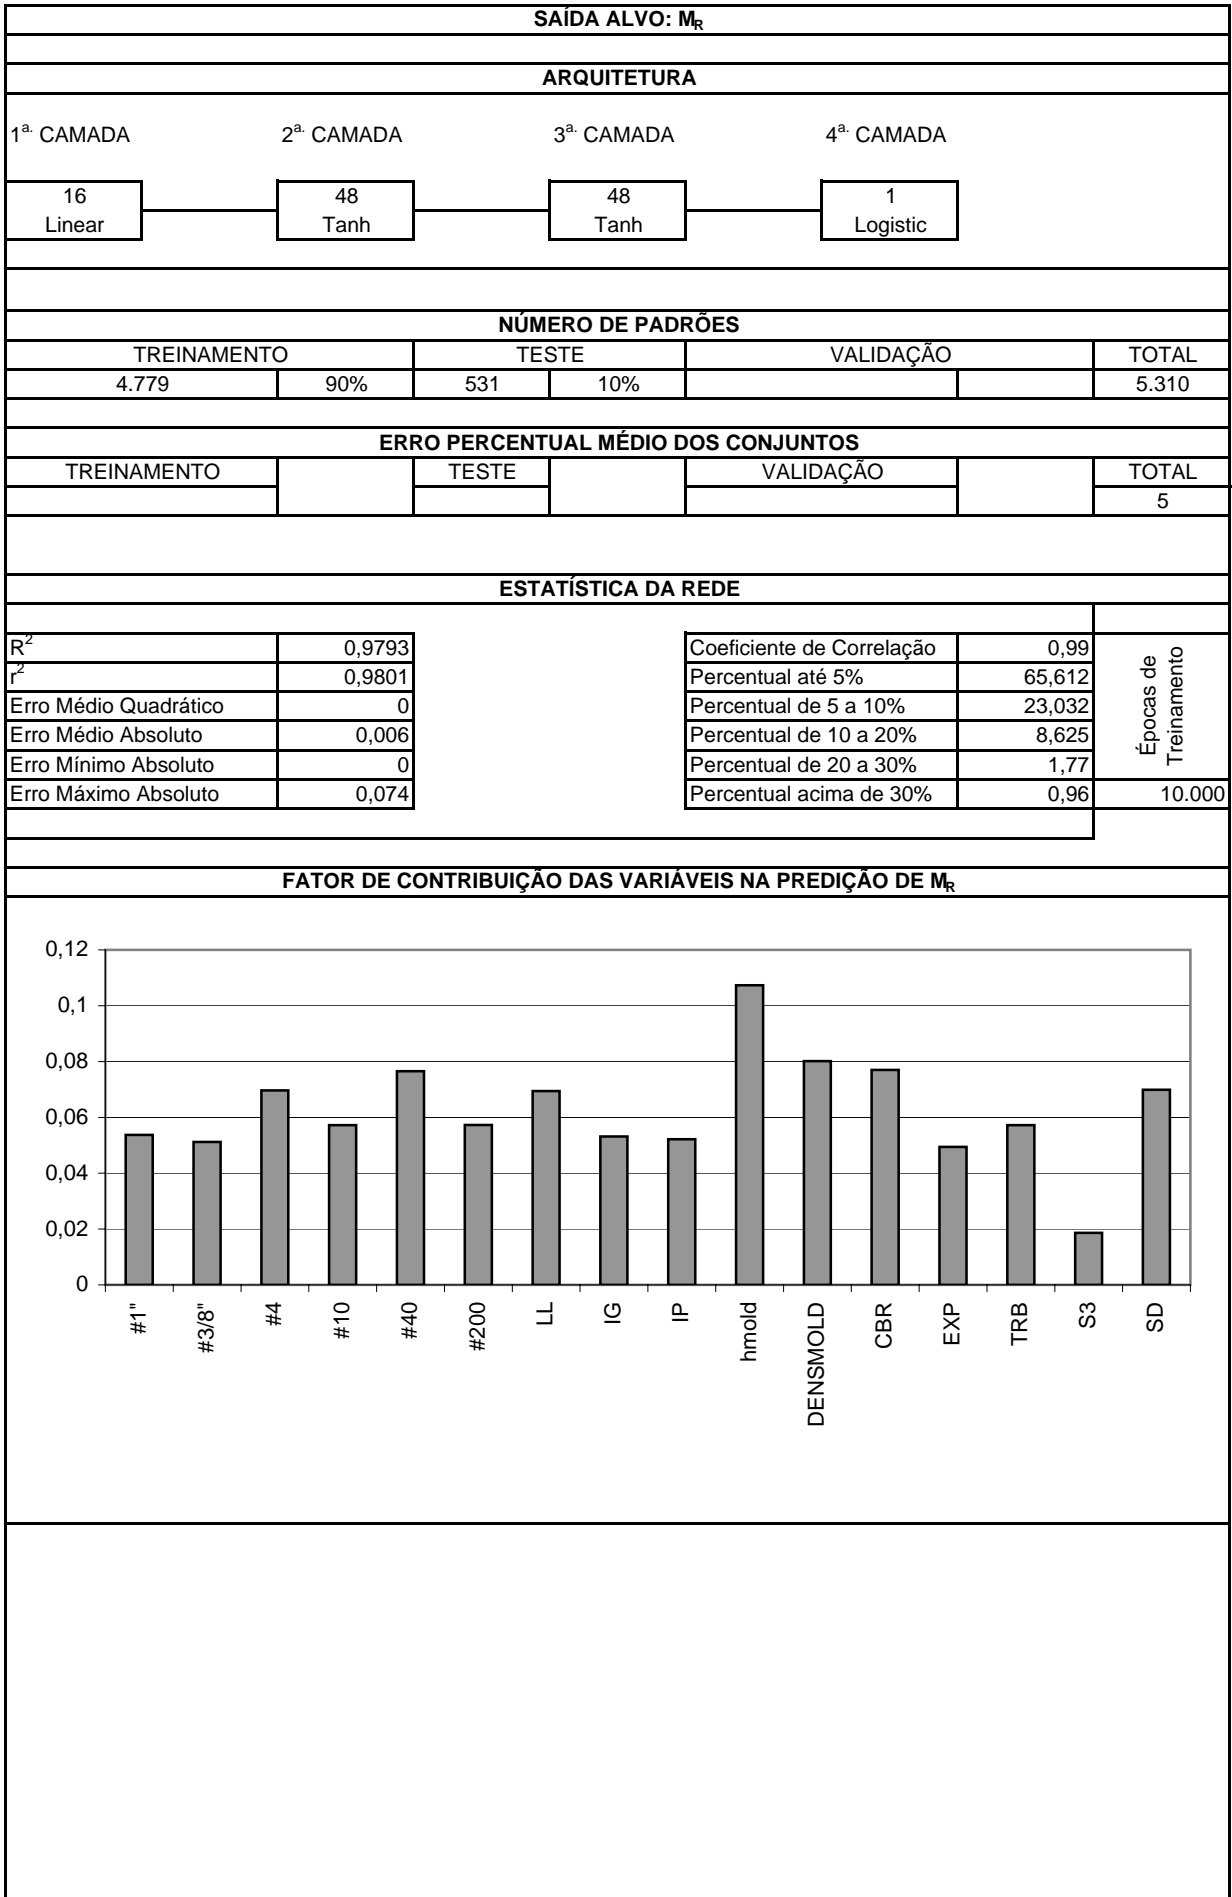
Para treinamento das redes Módulo 1, Módulo 2, Módulo 3, Módulo 4, Módulo 5, Módulo 6 e Módulo 8 foi utilizada a base de dados primitiva (Ferreira 2002), compreendendo as amostras de números 1 a 285, perfazendo um total de 5.130 padrões. As redes Módulo 9, Módulo 11 e Módulo 12 foram treinadas adicionando-se à base de dados as amostras de números 286 a 346, cujos ensaios foram executados já

no âmbito desta pesquisa. Para efeito de validação foram separadas 35 amostras, que não fizeram parte da base de dados utilizada para treinamento das redes. Desta forma, foram utilizadas 309 amostras para treinamento, perfazendo um total de 5.562 padrões. As fichas individuais para cada uma delas são apresentadas a seguir, constantes dos Quadros 8.12 a 8.21.

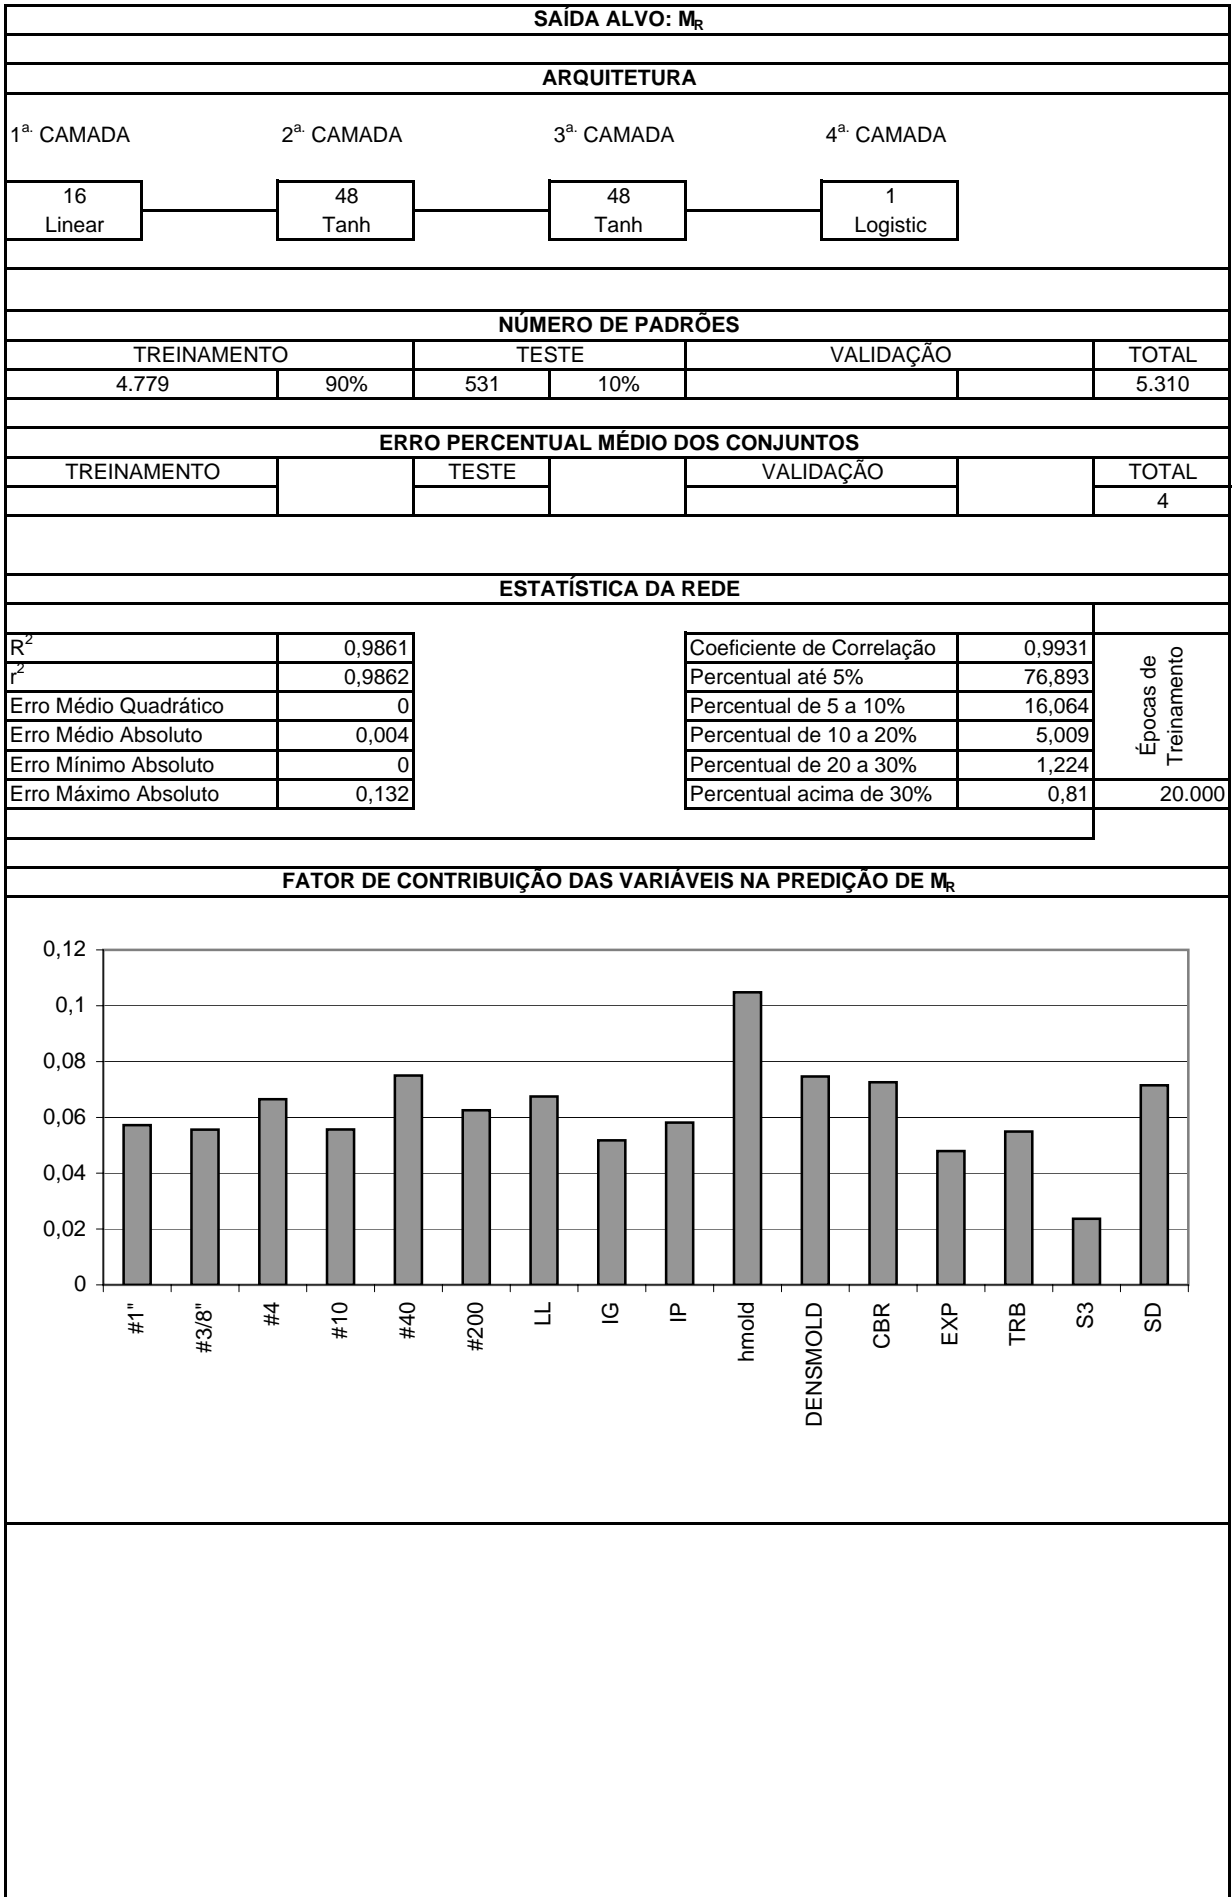
Quadro 8.12 - Rede Módulo 1



Quadro 8.13 - Rede Módulo 2



Quadro 8.14 - Rede Módulo 3



Quadro 8.15 - Rede Módulo 4

SAÍDA ALVO: M_r																																						
ARQUITETURA																																						
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA																																			
15 linear	45 tanh	45 tanh	1 logistic																																			
NÚMERO DE PADRÕES																																						
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																																
4.104		80%		1.026		20%	5.130																															
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS																																						
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																																
						4																																
ESTATÍSTICA DA REDE																																						
R^2	0,9914	Coeficiente de Correlação		0,9957	Épocas de Treinamento																																	
r^2	0,9915	Percentual até 5%		77,135																																		
Erro Médio Quadrático	0	Percentual de 5 a 10%		17,173																																		
Erro Médio Absoluto	0,004	Percentual de 10 a 20%		5,127																																		
Erro Mínimo Absoluto	0	Percentual de 20 a 30%		0,429																																		
Erro Máximo Absoluto	0,067	Percentual acima de 30%		0,136			20.000																															
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r																																						
<table border="1"> <caption>Data for Fator de Contribuição das Variáveis na Predição de M_r</caption> <thead> <tr> <th>Variável</th> <th>Fator de Contribuição</th> </tr> </thead> <tbody> <tr><td>#1</td><td>0,068</td></tr> <tr><td>#3/8</td><td>0,060</td></tr> <tr><td>#4</td><td>0,058</td></tr> <tr><td>#10</td><td>0,066</td></tr> <tr><td>#40</td><td>0,079</td></tr> <tr><td>#200</td><td>0,076</td></tr> <tr><td>LL</td><td>0,068</td></tr> <tr><td>IP</td><td>0,062</td></tr> <tr><td>IG</td><td>0,066</td></tr> <tr><td>hmodal</td><td>0,111</td></tr> <tr><td>DENSMOLD</td><td>0,083</td></tr> <tr><td>CBR</td><td>0,080</td></tr> <tr><td>EXP</td><td>0,053</td></tr> <tr><td>S3</td><td>0,020</td></tr> <tr><td>SD</td><td>0,058</td></tr> </tbody> </table>							Variável	Fator de Contribuição	#1	0,068	#3/8	0,060	#4	0,058	#10	0,066	#40	0,079	#200	0,076	LL	0,068	IP	0,062	IG	0,066	hmodal	0,111	DENSMOLD	0,083	CBR	0,080	EXP	0,053	S3	0,020	SD	0,058
Variável	Fator de Contribuição																																					
#1	0,068																																					
#3/8	0,060																																					
#4	0,058																																					
#10	0,066																																					
#40	0,079																																					
#200	0,076																																					
LL	0,068																																					
IP	0,062																																					
IG	0,066																																					
hmodal	0,111																																					
DENSMOLD	0,083																																					
CBR	0,080																																					
EXP	0,053																																					
S3	0,020																																					
SD	0,058																																					

Quadro 8.16 - Rede Módulo 5

SAÍDA ALVO: M_r									
ARQUITETURA									
1ª. CAMADA		2ª. CAMADA		3ª. CAMADA		4ª. CAMADA			
15 linear		30 tanh		30 tanh		1 logistic			
NÚMERO DE PADRÕES									
TREINAMENTO			TESTE		VALIDAÇÃO			TOTAL	
3.848			75%		1.282 25%		5.130		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS									
TREINAMENTO			TESTE		VALIDAÇÃO			TOTAL	
								4,7	
ESTATÍSTICA DA REDE									
R^2		0,9843		Coeficiente de Correlação			0,9922		Épocas de Treinamento
r^2		0,9844		Percentual até 5%			66,803		
Erro Médio Quadrático		0		Percentual de 5 a 10%			22,749		
Erro Médio Absoluto		0,005		Percentual de 10 a 20%			8,616		
Erro Mínimo Absoluto		0		Percentual de 20 a 30%			1,345		
Erro Máximo Absoluto		0,132		Percentual acima de 30%			0,487		
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r									
ERRO PERCENTUAL DAS AMOSTRAS DE TESTE									
AM10	AM20	AM30	AM40	AM50	AM60	AM70	AM76	AM80	
AM90	AM100	AM110	AM120	AM130	AM140	AM150	AM160	AM170	
AM180	AM190	AM200	AM210	AM220	AM224	AM230	AM240	AM250	
AM260	AM270	AM276	AM280	AM290	AM300	AM330	AM340	MÉDIA	
				105	14	256	189	141	

Quadro 8.17 - Rede Módulo 6

SAÍDA ALVO: M_r																																			
ARQUITETURA																																			
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA																																
15 linear	45 tanh	45 tanh	1 logistic																																
NÚMERO DE PADRÕES																																			
TREINAMENTO	TESTE		VALIDAÇÃO																																
4.617	90%	513	10%																																
			TOTAL																																
			5.130																																
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS																																			
TREINAMENTO	TESTE		VALIDAÇÃO																																
			TOTAL																																
			3																																
ESTATÍSTICA DA REDE																																			
R^2	0,995	Coeficiente de Correlação	0,9976																																
\bar{r}^2	0,9951	Percentual até 5%	85,029																																
Erro Médio Quadrático	0	Percentual de 5 a 10%	12,398																																
Erro Médio Absoluto	0,003	Percentual de 10 a 20%	2,339																																
Erro Mínimo Absoluto	0	Percentual de 20 a 30%	0,195																																
Erro Máximo Absoluto	0,046	Percentual acima de 30%	0,039																																
			Épocas de Treinamento																																
			30.000																																
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r																																			
<table border="1" style="display: none;"> <caption>Data for Fator de Contribuição das Variáveis na Predição de M_r</caption> <thead> <tr> <th>Variável</th> <th>Fator de Contribuição</th> </tr> </thead> <tbody> <tr><td>#1''</td><td>0,07</td></tr> <tr><td>#3/8''</td><td>0,055</td></tr> <tr><td>#4</td><td>0,06</td></tr> <tr><td>#10</td><td>0,06</td></tr> <tr><td>#40</td><td>0,08</td></tr> <tr><td>#200</td><td>0,075</td></tr> <tr><td>LL</td><td>0,06</td></tr> <tr><td>IP</td><td>0,065</td></tr> <tr><td>IG</td><td>0,055</td></tr> <tr><td>hmodal</td><td>0,11</td></tr> <tr><td>DENSMOLD</td><td>0,085</td></tr> <tr><td>CBR</td><td>0,085</td></tr> <tr><td>EXP</td><td>0,06</td></tr> <tr><td>S3</td><td>0,02</td></tr> <tr><td>SD</td><td>0,065</td></tr> </tbody> </table>				Variável	Fator de Contribuição	#1''	0,07	#3/8''	0,055	#4	0,06	#10	0,06	#40	0,08	#200	0,075	LL	0,06	IP	0,065	IG	0,055	hmodal	0,11	DENSMOLD	0,085	CBR	0,085	EXP	0,06	S3	0,02	SD	0,065
Variável	Fator de Contribuição																																		
#1''	0,07																																		
#3/8''	0,055																																		
#4	0,06																																		
#10	0,06																																		
#40	0,08																																		
#200	0,075																																		
LL	0,06																																		
IP	0,065																																		
IG	0,055																																		
hmodal	0,11																																		
DENSMOLD	0,085																																		
CBR	0,085																																		
EXP	0,06																																		
S3	0,02																																		
SD	0,065																																		

Quadro 8.18 - Rede Módulo 8

SAÍDA ALVO: M_r																																						
ARQUITETURA																																						
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA																																			
15 linear	30 tanh	30 tanh	1 logistic																																			
NÚMERO DE PADRÕES																																						
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																																
4.617		90%		513		10%	5.130																															
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS																																						
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																																
						3																																
ESTATÍSTICA DA REDE																																						
R^2	0,994	Coeficiente de Correlação		0,997	Épocas de Treinamento																																	
\bar{r}^2	0,9941	Percentual até 5%		81,384																																		
Erro Médio Quadrático	0	Percentual de 5 a 10%		14,795																																		
Erro Médio Absoluto	0,003	Percentual de 10 a 20%		3,509																																		
Erro Mínimo Absoluto	0	Percentual de 20 a 30%		0,273																																		
Erro Máximo Absoluto	0,031	Percentual acima de 30%		0,039																																		
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r																																						
<table border="1"> <caption>Data for Fator de Contribuição das Variáveis na Predição de M_r</caption> <thead> <tr> <th>Variável</th> <th>Fator de Contribuição</th> </tr> </thead> <tbody> <tr><td>#1</td><td>0,070</td></tr> <tr><td>#3/8</td><td>0,065</td></tr> <tr><td>#4</td><td>0,070</td></tr> <tr><td>#10</td><td>0,062</td></tr> <tr><td>#40</td><td>0,085</td></tr> <tr><td>#200</td><td>0,068</td></tr> <tr><td>LL</td><td>0,052</td></tr> <tr><td>IP</td><td>0,088</td></tr> <tr><td>IG</td><td>0,055</td></tr> <tr><td>hrmold</td><td>0,105</td></tr> <tr><td>DENSMOLD</td><td>0,078</td></tr> <tr><td>CBR</td><td>0,070</td></tr> <tr><td>EXP</td><td>0,050</td></tr> <tr><td>S3</td><td>0,018</td></tr> <tr><td>SD</td><td>0,050</td></tr> </tbody> </table>							Variável	Fator de Contribuição	#1	0,070	#3/8	0,065	#4	0,070	#10	0,062	#40	0,085	#200	0,068	LL	0,052	IP	0,088	IG	0,055	hrmold	0,105	DENSMOLD	0,078	CBR	0,070	EXP	0,050	S3	0,018	SD	0,050
Variável	Fator de Contribuição																																					
#1	0,070																																					
#3/8	0,065																																					
#4	0,070																																					
#10	0,062																																					
#40	0,085																																					
#200	0,068																																					
LL	0,052																																					
IP	0,088																																					
IG	0,055																																					
hrmold	0,105																																					
DENSMOLD	0,078																																					
CBR	0,070																																					
EXP	0,050																																					
S3	0,018																																					
SD	0,050																																					

Quadro 8.19 - Rede Módulo 9

SAÍDA ALVO: M_r								
ARQUITETURA								
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA					
15 linear	30 tanh	30 tanh	1 logistic					
NÚMERO DE PADRÕES								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
4.768	86%	429	8%	365	6%	5.562		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
				4,7		4,0		
ESTATÍSTICA DA REDE								
R^2	0,9918	Coeficiente de Correlação		0,9961	Épocas de Treinamento			
r^2	0,9922	Percentual até 5%		73,067				
Erro Médio Quadrático	0	Percentual de 5 a 10%		19,22				
Erro Médio Absoluto	0,004	Percentual de 10 a 20%		6,76				
Erro Mínimo Absoluto	0	Percentual de 20 a 30%		0,719				
Erro Máximo Absoluto	0,043	Percentual acima de 30%		0,234				
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r								
ERRO PERCENTUAL DAS AMOSTRAS DE TESTE								
AM10	AM20	AM30	AM40	AM50	AM60	AM70	AM76	AM80
34	74	53	107	48	45	17	26	11
AM90	AM100	AM110	AM120	AM130	AM140	AM150	AM160	AM170
59	37	18	12	41	22	448	22	37
AM180	AM190	AM200	AM210	AM220	AM224	AM230	AM240	AM250
16	89	59	81	39	14	5	15	5
AM260	AM270	AM276	AM280	AM290	AM300	AM330	AM340	MÉDIA
34	6	15	5	110	35	172	119	55

Quadro 8.20 - Rede Módulo 11

SAÍDA ALVO: M_r								
ARQUITETURA								
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA					
15 linear	30 tanh	30 tanh	1 logistic					
NÚMERO DE PADRÕES								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
3.783	68%	834	15%	945	17%	5.562		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
				5,6		4,6		
ESTATÍSTICA DA REDE								
R^2	0,9858	Coeficiente de Correlação		0,993	Épocas de Treinamento			
r^2	0,986	Percentual até 5%		67,512				
Erro Médio Quadrático	0	Percentual de 5 a 10%		21,881				
Erro Médio Absoluto	0,005	Percentual de 10 a 20%		8,936				
Erro Mínimo Absoluto	0	Percentual de 20 a 30%		1,366				
Erro Máximo Absoluto	0,106	Percentual acima de 30%		0,306				
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r								
ERRO PERCENTUAL DAS AMOSTRAS DE TESTE								
AM10	AM20	AM30	AM40	AM50	AM60	AM70	AM76	AM80
19	53	8	101	52	128	33	17	24
AM90	AM100	AM110	AM120	AM130	AM140	AM150	AM160	AM170
55	60	85	17	82	77	490	22	33
AM180	AM190	AM200	AM210	AM220	AM224	AM230	AM240	AM250
24	43	68	84	5	14	47	23	76
AM260	AM270	AM276	AM280	AM290	AM300	AM330	AM340	MÉDIA
53	9	24	29	115	15	61	64	60

Quadro 8.21 - Rede Módulo 12

SAÍDA ALVO: M_r								
ARQUITETURA								
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA					
15 linear	30 tanh	15 tanh	1 logistic					
NÚMERO DE PADRÕES								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
3.814	69%	720	13%	1.028	18%	5.562		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
				5,9		5,3		
ESTATÍSTICA DA REDE								
R^2	0,9833	Coeficiente de Correlação			0,9918	Épocas de Treinamento		
r^2	0,9836	Percentual até 5%			59,691			
Erro Médio Quadrático	0	Percentual de 5 a 10%			25,89			
Erro Médio Absoluto	0,006	Percentual de 10 a 20%			12,1			
Erro Mínimo Absoluto	0	Percentual de 20 a 30%			1,924			
Erro Máximo Absoluto	0,077	Percentual acima de 30%			0,396		45.000	
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r								
ERRO PERCENTUAL DAS AMOSTRAS DE TESTE								
AM10	AM20	AM30	AM40	AM50	AM60	AM70	AM76	AM80
44	77	34	8	48	40	25	19	34
AM90	AM100	AM110	AM120	AM130	AM140	AM150	AM160	AM170
58	54	59	9	11	33	54	47	70
AM180	AM190	AM200	AM210	AM220	AM224	AM230	AM240	AM250
77	32	138	72	65	16	62	61	13
AM260	AM270	AM276	AM280	AM290	AM300	AM330	AM340	MÉDIA
41	45	19	21	103	18	85	304	54

As redes Módulo 1, Módulo 2, Módulo 3, Módulo 4, Módulo 5, Módulo 6 e Módulo 8 foram treinadas objetivando a princípio avaliar a arquitetura mínima capaz de inferir com precisão aceitável o valor de M_R . Esta procura por uma arquitetura a mais simples possível se justifica pelo fato comprovado na prática de que redes super-dimensionadas tendem a ter uma redução significativa em sua capacidade de generalização, ocasionando erros de predição elevados quando são a ela apresentados padrões diversos daqueles empregados em seu treinamento. Outra consequência importante do super-dimensionamento da rede é o aumento da possibilidade de super-especialização, quando a rede passa a “decorar” os valores da saída alvo, ao invés de inferi-los. Uma regra empírica em arquiteturas de redes neurais é a utilização de um número de neurônios nas camadas ocultas múltiplo inteiro daquele adotado na camada de entrada de dados (*inputs*). Assim sendo, iniciou-se a análise considerando para as camadas ocultas um número de neurônios de três vezes o número de variáveis de entrada, obtendo-se o melhor resultado em termos de erro percentual médio de toda a rede de 3% para a “Rede Módulo 6”. Uma vez obtido este valor, procedeu-se à redução do número de neurônios das camadas intermediárias para duas vezes o número de variáveis de entrada, conforme apresentado para as redes Módulo 8, Módulo 9 e Módulo 11. Nesta condição, os erros médios percentuais obtidos para toda a rede variaram de 3 a 4,6%, indicando que ainda havia possibilidade de redução do número de neurônios das camadas intermediárias. Ressalve-se que para as redes Módulo 9 e Módulo 11 a base de dados foi aumentada elevando o número de padrões apresentado à rede de 5.130 para 5.562. As implicações resultantes deste incremento da base de dados serão analisadas no item 8.2 – Análise dos Resultados Obtidos – Primeira Fase. Uma vez constatado que os erros médios percentuais ainda se mostravam bastante reduzidos, foi testada nova arquitetura, reduzindo-se o número de neurônios da terceira camada, conforme apresentado na “Rede Módulo 12”. O treinamento desta rede resultou em um erro percentual médio de 5,3%, considerado compatível com as necessidades de confiabilidade de predição, sendo então esta definida a princípio como a melhor entre todas as analisadas.

Apesar dos bons resultados apresentados pela rede “Módulo 12” no que se refere aos seus parâmetros estatísticos e ao erro percentual médio associado, os erros obtidos para as amostras de validação foram, em sua grande maioria, muito elevados. Optou-se então por proceder ao agrupamento das amostras em famílias de comportamento resiliente, buscando assim facilitar a aprendizagem da rede mediante a apresentação de padrões mais homogêneos. Para este fim foi utilizada uma

ferramenta destinada à exploração de dados desenvolvida na própria COPPE/UFRJ por Machado Filho, (2002). Esta ferramenta disponibiliza diversos elementos que possibilitam um bom aprofundamento na análise de agrupamento de dados. Contudo, por constituir esta fase apenas de uma avaliação inicial, foram considerados somente os aspectos mais significativos do agrupamento realizado, ou seja, o número de grupos identificados e a alocação das amostras em cada um deles.

A ferramenta de análise utilizada foi implementada através do desenvolvimento de um algoritmo baseado no método K-Médias para segmentação de bases de dados em um número crescente e sucessivo de grupos. Resumidamente este método particional pode ser assim descrito (Machado Filho, 2002):

“Após a informação do número de grupos desejado (k), são selecionados randomicamente “ k ” objetos que irão representar, inicialmente, os valores médios dos grupos. Para cada um dos objetos restantes é determinado o seu grupo correspondente, baseado na distância entre o objeto e o valor médio do grupo. O objeto pertencerá ao grupo que tiver o valor médio mais próximo.” A Figura 8.1 apresenta o algoritmo do método K-Médias

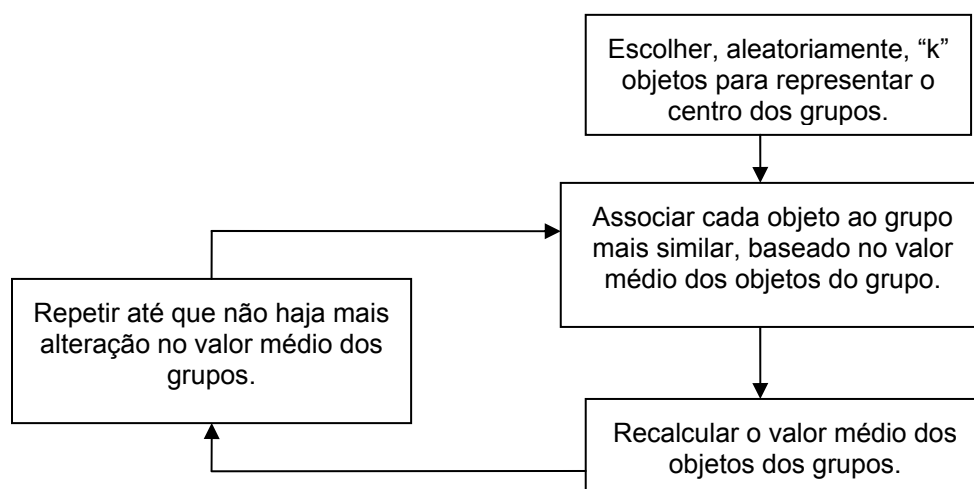


Figura 8.1 – Algoritmo do Método K-Médias – Fonte: Machado Filho, 2002

As variáveis utilizadas neste agrupamento foram a Granulometria, (#1, #3/8, #4, #10, #40 e #200), Limite de Liquidez (LL), Índice de Grupo (IG), Índice de Plasticidade (IP), Umidade de Moldagem (HMOLD), Densidade de Moldagem (DENSMOLD), CBR, Expansão (EXP) e os valores das constantes experimentais do Modelo Composto K_1 , K_2 e K_3 .

O número ótimo de grupos, ou seja, aquele que origina a melhor distribuição dos objetos, é o que maximizar a função de otimização de Calinski e Harabasz (Han e Kamber, 2001). A Figura 8.2 apresenta o algoritmo do método destes autores.

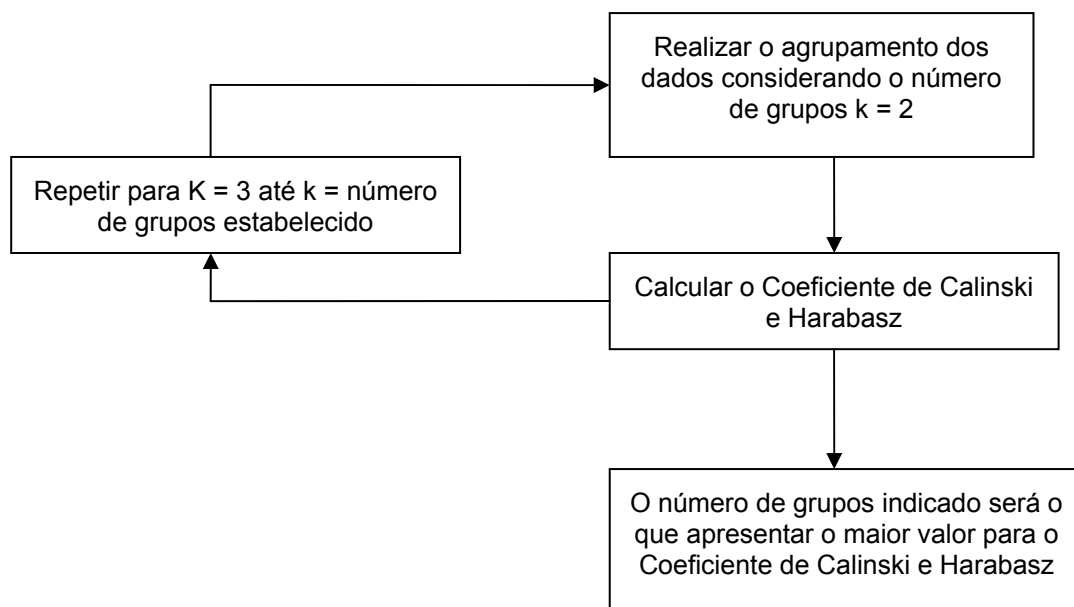


Fig. 8.2 – Algoritmo do método Calinski e Harabasz – Fonte: Machado Filho, 2002

Para a base de dados analisada os resultados do Coeficiente Calinski e Harabasz (G) foram os constantes no Quadro 8.22.

Quadro 8.22 – Valores do Coeficiente Calinski e Harabasz (G) para os agrupamentos realizados

No. de Grupos	2	3	4	5	6	7	8	9	10
G	308,33	311,59	234,04	222,20	206,74	186,90	165,95	167,79	168,20

O agrupamento ótimo indicou a existência de três famílias distintas. A partir deste agrupamento foram treinadas as respectivas redes neurais, utilizando-se como base de dados para cada uma delas as amostras classificadas como do Grupo1 (Rede Módulo 101), Grupo 2 (Rede Módulo 102) e Grupo 3 (Rede Módulo 103). As arquiteturas dessas redes foram definidas com 30 neurônios em cada camada oculta tendo em vista que o número de padrões disponível para treinamento é bastante

reduzido, e a manutenção de apenas 15 neurônios na terceira camada, a exemplo da rede Módulo 12, poderia resultar em grande dificuldade de aprendizagem. Em termos de treinamento foram obtidos excelentes valores para os parâmetros estatísticos com reduzido número de épocas. Os valores do erro percentual médio de toda a rede também apresentaram uma redução significativa em relação às redes treinadas considerando uma base de dados única. Estes valores, de 3,6% para a rede Módulo 101, 2,7% para a rede Módulo 102 e 1,4% para a rede Módulo 103, indicam que o treinamento de redes considerando bases de dados agrupadas em famílias de comportamento resiliente é um caminho promissor. Entretanto, o problema de elevados erros para as amostras de teste persistiu, muito embora para a rede Módulo 103 o mesmo tenha apresentado média de 27%, o que é um resultado muito melhor que os obtidos para as demais redes treinadas.

A seguir são apresentados os seguintes quadros:

- Quadro 8.23, que é um resumo estatístico do agrupamento realizado;
- Quadros 8.24 a 8.26, que são as fichas individuais para cada uma das redes treinadas considerando o agrupamento de amostras;
- Quadro 8.27, que sintetiza os erros percentuais médios obtidos em algumas das redes treinadas para diversas amostras.

Quadro 8.23 - Parâmetros Estatísticos do Agrupamento

Variável	Grupo 1			Grupo 2			Grupo 3		
	Mínimo	Média	Máximo	Mínimo	Média	Máximo	Mínimo	Média	Máximo
#1	95,00	99,94	100,00	80,00	99,01	100,00	61,00	92,98	100,00
#3/8	83,00	99,44	100,00	73,00	95,21	100,00	44,00	69,13	100,00
#4	74,00	98,50	100,00	64,00	91,64	100,00	34,00	53,64	74,00
#10	61,00	95,66	100,00	59,00	82,24	100,00	21,00	41,82	69,00
#40	47,00	80,13	100,00	22,00	50,95	99,00	6,00	24,25	45,00
#200	26,00	55,54	99,00	1,00	20,44	44,00	1,00	9,43	23,00
LL	0,00	44,43	74,00	0,00	9,48	39,00	0,00	5,18	31,00
IG	0,00	8,29	20,00	0,00	0,09	3,00	0,00	0,00	0,00
IP	0,00	19,79	37,00	0,00	1,67	14,00	0,00	1,32	11,00
Hmold	9,20	15,91	26,10	3,40	8,38	13,10	2,90	5,89	10,20
Densmold	1,45	1,74	2,08	1,73	1,96	2,32	1,92	2,18	2,34
CBR	2,00	12,03	36,00	4,00	28,45	75,00	25,00	88,60	156,00
EXP	0,00	0,99	9,80	0,00	0,12	1,15	0,00	0,01	0,60
K1	15	517	2.289	207	576	1.752	364	950	2.008
K2	-0,060	0,230	0,610	0,03	0,37	0,62	0,05	0,42	0,78
K3	-1,110	-0,400	0,100	-0,77	-0,21	0,44	-0,44	-0,07	0,26

Totais	
Amostras	346
Não Agrupadas	0
Agrupadas	346

Grupo	Número de Amostras
1	125
2	130
3	91

Quadro 8.24 - Rede Módulo 101

SAÍDA ALVO: M_r								
ARQUITETURA								
1ª. CAMADA		2ª. CAMADA		3ª. CAMADA		4ª. CAMADA		
15 linear		30 tanh		30 tanh		1 logistic		
NÚMERO DE PADRÕES								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
1.644		81%		176		2.034		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
				4,2		3,6		
ESTATÍSTICA DA REDE								
R^2	0,9943		Coeficiente de Correlação		0,9973			
r^2	0,9945		Percentual até 5%		76,254			
Erro Médio Quadrático	0		Percentual de 5 a 10%		18,043			
Erro Médio Absoluto	0,004		Percentual de 10 a 20%		4,818			
Erro Mínimo Absoluto	0		Percentual de 20 a 30%		0,688			
Erro Máximo Absoluto	0,05		Percentual acima de 30%		0,197			
						Épocas de Treinamento		
						12.000		
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r								
ERRO PERCENTUAL DAS AMOSTRAS DE TESTE								
AM10	AM20	AM30	AM40	AM50	AM60	AM70	AM76	AM80
63	34							210
AM90	AM100	AM110	AM120	AM130	AM140	AM150	AM160	AM170
45	51	45						
AM180	AM190	AM200	AM210	AM220	AM224	AM230	AM240	AM250
		73		34			17	
AM260	AM270	AM276	AM280	AM290	AM300	AM330	AM340	MÉDIA
				56		45	82	63

Quadro 8.25 - Rede Módulo 102

SAÍDA ALVO: M_r								
ARQUITETURA								
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA					
15 linear	30 tanh	30 tanh	1 logistic					
NÚMERO DE PADRÕES								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
1.644	81%	214	11%	176	8%	2.034		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
				3,3		2,7		
ESTATÍSTICA DA REDE								
R^2	0,9938	Coeficiente de Correlação			0,9976	Épocas de Treinamento		
r^2	0,9951	Percentual até 5%			86,726			
Erro Médio Quadrático	0	Percentual de 5 a 10%			11,062			
Erro Médio Absoluto	0,004	Percentual de 10 a 20%			2,114			
Erro Mínimo Absoluto	0	Percentual de 20 a 30%			0,098			
Erro Máximo Absoluto	0,047	Percentual acima de 30%			0			
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r								
ERRO PERCENTUAL DAS AMOSTRAS DE TESTE								
AM10	AM20	AM30	AM40	AM50	AM60	AM70	AM76	AM80
		63	112					
AM90	AM100	AM110	AM120	AM130	AM140	AM150	AM160	AM170
					15		15	46
AM180	AM190	AM200	AM210	AM220	AM224	AM230	AM240	AM250
22	53		58			34		32
AM260	AM270	AM276	AM280	AM290	AM300	AM330	AM340	MÉDIA
17					150			51

Quadro 8.26 - Rede Módulo 103

SAÍDA ALVO: M_r								
ARQUITETURA								
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA					
14 linear	28 tanh	28 tanh	1 logistic					
NÚMERO DE PADRÕES								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
1.167	81%	129	9%	144	10%	1.440		
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS								
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL		
				1,8		1,4		
ESTATÍSTICA DA REDE								
R^2	0,9979	Coeficiente de Correlação		0,999	Épocas de Treinamento			
r^2	0,998	Percentual até 5%		97,083				
Erro Médio Quadrático	0	Percentual de 5 a 10%		2,569				
Erro Médio Absoluto	0,004	Percentual de 10 a 20%		0,347				
Erro Mínimo Absoluto	0	Percentual de 20 a 30%		0				
Erro Máximo Absoluto	0,088	Percentual acima de 30%		0				
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r								
ERRO PERCENTUAL DAS AMOSTRAS DE TESTE								
AM10	AM20	AM30	AM40	AM50	AM60	AM70	AM76	AM80
				54	46	12	22	
AM90	AM100	AM110	AM120	AM130	AM140	AM150	AM160	AM170
			36	38		25		
AM180	AM190	AM200	AM210	AM220	AM224	AM230	AM240	AM250
					18			
AM260	AM270	AM276	AM280	AM290	AM300	AM330	AM340	MÉDIA
	5	37	6					27

Quadro 8.27 - Erros percentuais médios de algumas amostras para as redes apresentadas nos quadros 8.16, 8.19, 8.20, 8.21, 8.24, 8.25 e 8.26

AMOSTRA	GRUPO	REDES NEURAIS						
		MÓD. 5	MÓD. 9	MÓD. 11	MÓD. 12	MÓD. 101	MÓD. 102	MÓD. 103
1	1	6	5	15	6	4		
2	1	8	6	9	11	6		
3	1	2	2	10	3	4		
10	1	8	34	19	44	63		
20	1	4	74	53	77	34		
30	2	4	53	8	34		63	
34	2	5	4	3	5		2	
40	2	2	107	101	6		112	
47	3	9	2	5	5			1
48	3	4	2	4	5			1
50	3	7	48	52	48			54
60	3	4	45	128	40			46
70	3	6	17	33	25			12
76	3	5	26	17	19			22
80	1	4	11	24	34	210		
90	1	5	59	55	58	45		
100	1	9	37	60	54	51		
110	1	4	18	85	59	45		
120	3	3	12	17	9			36
130	3	2	41	82	11			38
140	2	2	22	77	33		15	
150	3	2	448	490	54			25
160	2	2	22	22	47		15	
170	2	5	37	33	70		46	
180	2	6	16	24	77		22	
190	2	7	89	43	32		53	
200	1	6	59	68	138	73		
210	2	3	81	84	72		58	
220	1	7	39	5	65	34		
224	3	8	14	14	16			18
230	2	5	5	47	62		34	
240	1	3	15	23	61	17		
250	2	10	5	76	13		32	
260	2	4	34	53	41		17	
270	3	3	6	9	45			5
276	3	2	15	24	19			37
280	3	3	5	29	21			6
286	2	75	5	6	6		3	
287	2	78	4	9	7		3	
288	1	26	3	9	5	4		
289	2	32	4	4	6		2	
290	1	105	110	115	103	56		
291	2	84	3	7	4		3	
292	1	254	4	6	4	3		
293	2	33	5	12	9		2	
294	2	28	5	5	9		3	
295	2	79	6	4	6		3	
296	1	66	4	7	2	4		
297	2	36	5	5	4		3	
298	1	83	7	3	11	6		
299	1	82	5	3	11	4		
300	2	14	35	15	18		150	
301	2	28	4	9	5		2	
302	2	32	2	6	5		2	

Quadro 8.27 - Erros percentuais médios de algumas amostras para as redes apresentadas nos quadros 8.16, 8.19, 8.20, 8.21, 8.24, 8.25 e 8.26 (Continuação)

AMOSTRA	GRUPO	REDES NEURAIAS						
		MÓD. 5	MÓD. 9	MÓD. 11	MÓD. 12	MÓD. 101	MÓD. 102	MÓD. 103
303	1	64	2	7	7	3		
304	2	52	2	6	6		2	
305	2	57	5	3	4		4	
306	2	47	3	5	6		3	
307	2	43	4	3	4		2	
308	2	60	6	4	8		2	
309	2	83	4	7	3		3	
310	2	14	25	18	5		374	
311	2	21	5	4	7		4	
312	2	60	4	8	7		2	
313	2	42	14	5	7		3	
314	3	88	5	4	5			1
315	2	36	6	5	7		4	
316	2	19	6	11	3		283	
317	2	48	3	3	5		2	
318	2	28	6	4	5		7	
319	1	20	3	5	3			
320	2	50	7	2	7		1	
321	2	12	10	5	10		2	
322	2	44	10	7	8		2	
323	2	11	1	4	2		3	
324	2	52	5	2	6		7	
325	2	26	3	3	5		2	
326	2	42	7	4	3		14	
327	2	88	3	3	2		2	
328	2	37	16	47	16		17	
329	1	383	6	4	12	3		
330	1	256	172	61	85	45		
331	1	473	11	11	7	10		
332	1	504	7	8	5	6		
333	1	616	7	7	8	5		
334	1	650	4	4	10	5		
335	1	582	10	8	17	3		
336	1	87	15	9	15	9		
337	1	53	8	6	15	3		
338	1	740	5	12	10	4		
339	1	184	11	8	5	8		
340	1	189	119	64	304	82		
341	1	1025	5	7	8	3		
342	1	379	9	10	12	8		
343	1	265	13	10	6	7		
344	1	639	10	6	6	3		
345	1	575	6	6	9	2		
346	1	343	6	5	11	4		

X	Amostras constantes da base de dados utilizada para treinamento
X	Amostras utilizadas para validação

8.2 Análise dos Resultados Obtidos – Primeira Fase

Os resultados obtidos se apresentaram muito aquém das necessidades em termos de confiabilidade das redes treinadas, e algumas hipóteses foram analisadas buscando determinar as causas dos elevados erros obtidos para as amostras de validação, quais sejam:

- a) As redes treinadas sofreram processo de super-especialização, impedindo que as mesmas sejam capazes de prever com base em padrões não constantes das bases de dados utilizadas no treinamento;
- b) A diversidade e o número de padrões utilizados são ainda insuficientes para representar a gama real de tipos de solos utilizáveis em pavimentação, impedindo assim que a rede atinja bom aprendizado;
- c) Há um desequilíbrio na base de dados quanto à distribuição das amostras, ou seja, existem padrões quantitativamente bem representados, enquanto outros apresentam deficiência neste aspecto;
- d) Ocorrem discrepâncias significativas nos dados de entrada da rede, ou seja, existem *inputs* muito diferenciados para valores de *outputs* muito similares, o que indica uma base de dados qualitativamente deficiente;
- e) Há ainda a possibilidade de estar ocorrendo uma combinação de duas ou mais das hipóteses acima levantadas.

A seguir é apresentada a análise em detalhes de cada uma dessas hipóteses.

Para verificar a hipótese levantada na alínea a), relativa a uma eventual super-especialização das redes, dois indicadores devem ser analisados. O primeiro deles diz respeito à evolução do erro dos conjuntos de treinamento e teste durante o processo de aprendizagem da rede. Normalmente, a tendência dos erros de ambos os conjuntos é sofrer redução ao longo deste processo. A super-especialização fica caracterizada quando o erro do conjunto de treinamento passa a sofrer uma redução significativa enquanto o do conjunto de teste tem um comportamento inverso, aumentando a medida que a rede é treinada. No que se refere às redes apresentadas,

nenhuma delas apresentou tal anomalia, não caracterizando, portanto, a ocorrência de super-especialização.

Outro indicador seguro quanto à ocorrência de super-especialização é o erro obtido para os conjuntos de validação. Neste aspecto, a anomalia fica caracterizada quando o erro associado a estes conjuntos é muito superior àquele obtido para a rede como um todo. Nesta fase foram calculados os erros dos conjuntos de validação em nove das redes treinadas, não se constatando em quaisquer delas indícios de super-especialização. O Quadro 8.28 – Erros Percentuais Médios, apresenta os valores obtidos.

Quadro 8.28 – Erros Percentuais Médios para o total de padrões e para os conjuntos de validação

Rede	Erro Percentual Médio Total	Erro Percentual Médio Validação
Normalizada 2a	16,0	18,0
Normalizada 2b	15,0	18,0
Módulo 1	6,0	8,0
Módulo 9	4,0	4,7
Módulo 11	4,6	5,6
Módulo 12	5,3	5,6
Módulo 101	3,6	4,2
Módulo 102	2,7	3,3
Módulo 103	1,4	1,9

Com base nestes resultados pode-se considerar que a hipótese de super-especialização está descartada.

No caso da hipótese referente à alínea b), relativa a uma possível insuficiência em termos de tipos de solos e de número de padrões utilizados para treinamento das redes, a mesma aparentemente procede. Solos são materiais que sob a ação de cargas têm comportamento altamente complexo, dependente de uma série de fatores que podem inclusive não estar contemplados nos *inputs* utilizados. Contudo, os resultados obtidos demonstraram que as redes são capazes de inferir

com elevada precisão os valores de M_R com base nos parâmetros relativos aos ensaios tradicionais para materiais de pavimentação, desde que os padrões a ela apresentados para predição guardem alguma semelhança com aqueles utilizados em seu treinamento.

Um indício muito forte da validade da hipótese apresentada foi observado quando do aumento do número de amostras da base de dados. As amostras de números 286 a 346 foram utilizadas para treinamento somente a partir da rede Módulo 9. Na rede Módulo 5 estas amostras foram utilizadas para validação da rede, ou seja, não fizeram parte da base de dados de treinamento. As amostras de números 286 a 328, classificadas visualmente como saibro ou saibro pedregulhoso, foram coletadas da camada de sub-base do pavimento da Rodovia BR-101/RJ, no trecho entre a cidade de Angra dos Reis e a Divisa RJ/SP. As amostras de números 329 a 346, classificadas visualmente como silte arenoso ou silte arenoso micáceo, foram coletadas do subleito da Rodovia BR-116/SP, em um segmento próximo à cidade de Juquitiba. Considerando os resultados da rede Módulo 5, a média do erro percentual médio para as amostras de números 286 a 328 é de 53% e para as amostras de números 329 a 346 é de 441%. Desconsiderando-se quaisquer outros fatores intervenientes e ressaltando-se que nenhum dos dois conjuntos de amostras foi utilizado no treinamento da rede, uma explicação possível para a discrepância entre seus erros médios é que, no caso do primeiro conjunto, os solos ensaiados constituem padrões mais condizentes com aqueles constantes da base de dados, que se tratam de modo geral de amostras obtidas em pavimentos existentes e que, portanto, estão presumivelmente enquadradas nas especificações vigentes quanto a parâmetros geotécnicos. Ao contrário, o segundo conjunto constitui um material de subleito empregado sem qualquer restrição quanto a estes parâmetros, podendo assim não apresentar semelhanças com os padrões de treinamento. Esta hipótese é reforçada se considerarmos que, após serem as citadas amostras adicionadas ao banco de dados de treinamento, seus erros apresentaram uma redução drástica. Por exemplo, para a amostra n^o 330, o erro obtido na rede Módulo 5 é de 256%, reduzindo-se para 85% na rede Módulo 12. Ainda que este último constitua um valor muito elevado, fica evidente o total desconhecimento do padrão pela rede Módulo 5.

A hipótese levantada na alínea c) diz respeito a uma dificuldade de aprendizagem intrínseca das redes neurais quando utilizadas bases de dados que apresentam desequilíbrio quantitativo de padrões similares. Supondo, num exemplo extremo, que numa base de dados qualquer uma determinada classe de objetos seja

representada por 60% dos padrões, uma segunda classe por 35% e uma terceira classe por apenas 5%, a aprendizagem dos padrões que representam apenas 5% do total seria muito difícil, resultando para esta classe uma predição com erros provavelmente muito elevados. Supondo agora uma outra base de dados com as mesmas três classes, sendo a primeira representada por 40% dos padrões, a segunda por 35% e a terceira por 25%. Neste caso, apesar de haver certo desequilíbrio, as possibilidades de aprendizagem de todos os padrões são muito mais consistentes que no primeiro caso. A situação ideal é aquela na qual todas as classes estão representadas aproximadamente na mesma proporção.

Para a base de dados utilizada nesta fase do estudo, uma verificação inicial quanto ao desequilíbrio no número de padrões de cada classe constante da base de dados foi feita mediante o agrupamento realizado, já descrito no item 8.1. Conforme os resultados obtidos, o melhor agrupamento é aquele que identifica três classes ou grupos. Dos 346 objetos apresentados para agrupamento, 125 (36%) pertencem ao Grupo 1, 130 (38%) ao Grupo 2 e 91 (26%) ao Grupo 3. Apesar de não ocorrerem as proporções ideais, não há, a princípio, um desequilíbrio tal que seja capaz de prejudicar a aprendizagem da rede. Contudo, tendo em vista que a análise do agrupamento não foi aprofundada nesta fase, não seria ainda possível descartar a hipótese de que ocorram proporções significativamente desiguais.

A hipótese apontada na alínea d), relativa à existência de discrepâncias significativas nos dados de entrada da rede, é provavelmente a mais consistente dentre as levantadas como eventuais causas do mau desempenho em termos de predição verificado nesta fase. A análise da mesma já foi apresentada no Capítulo 5 – Base de Dados.

8.3 Metodologia – Segunda Fase

A segunda fase do desenvolvimento das RNAs consistiu inicialmente do aprofundamento dos mesmos procedimentos efetuados na primeira fase. Assim, em um processo dinâmico, a base de dados foi sendo aumentada na medida em que novas amostras foram ensaiadas, sendo treinadas ao longo do processo um total de 64 arquiteturas de redes do tipo *Multilayer Perceptron (MLP)*, incluindo bases nas quais as amostras foram agrupadas em famílias de solos quanto à resiliência.

Os testes efetuados consistiram em alterações nos seguintes parâmetros:

- Variáveis de entrada da rede;
- Número de camadas intermediárias;
- Número de neurônios por camada;
- Funções de ativação;
- Variável a ser predita, módulo de resiliência ou deformação específica resiliente;
- Amostras de validação.

Quanto às variáveis de entrada da rede optou-se por considerar a princípio apenas a granulometria, a densidade e a umidade de moldagem, e as tensões desvio e confinante. Nesta condição os resultados sofreram uma melhoria considerável no que se refere ao erro percentual médio das amostras de validação, que caiu de 54% quando considerados nas variáveis de entrada os Limites de Atterberg e os ensaios de CBR e Expansão, para 38% quando não foram apresentadas à rede estas variáveis.

Ao longo do processo de testes, optou-se por considerar também o Índice de Plasticidade (IP), primeiramente com o valor numérico obtido no ensaio e depois considerando o mesmo como uma variável dummy, ou seja, se o solo apresenta alguma plasticidade o valor da variável é 1, se não é 0. Para as redes nas quais se considerou a base total, sem classificação em famílias quanto ao comportamento resiliente, os resultados das amostras de validação foram aproximadamente os mesmos. Para as redes classificadas houve uma pequena melhora. Assim sendo, optou-se por dar continuidade à análise considerando o IP como uma variável dummy.

No que diz respeito ao número de camadas, foram feitos três testes com apenas uma camada intermediária, que apresentaram resultados de erro médio percentual nas amostras de validação de 51, 111 e 178%, muito superiores àquele obtido com duas camadas intermediárias, ficando por isso definida a utilização da arquitetura da rede com um total de quatro camadas.

Quanto ao número de neurônios por camada, foi considerado para as camadas intermediárias sempre um múltiplo inteiro do número de neurônios da camada de entrada das redes. Por este critério, definidas onze variáveis de entrada e duas camadas intermediárias, o número de neurônios nestas camadas é de vinte e dois. Foram feitos dois testes alterando o número de neurônios das camadas

intermediárias. No primeiro deles, a RN20, foram alocados apenas onze neurônios na terceira camada, resultando em um aumento do erro médio percentual das amostras de validação de 38 para 115%. Outro teste foi feito, aumentando para trinta e três o número de neurônios na segunda camada, a RN37, o que resultou também em elevação do erro médio percentual, desta vez para 60%. Assim sendo, a configuração básica ficou definida com onze neurônios na camada de entrada, vinte e dois neurônios em cada camada intermediária e um neurônio na camada de saída.

A análise quanto a quais funções de ativação utilizar para maximizar a precisão das redes foi necessária tendo em vista que estas funções apresentam desempenho muito dependente do tipo de dados utilizados e da tarefa a executar. Em muitos aspectos não existe também um consenso entre os especialistas quanto à sua utilização. Algumas observações contidas no próprio manual de utilização do *software NeuroShell-2* (Ward Systems Group, Inc, 1993), apresentadas a seguir, retratam a incerteza quanto quais funções utilizar em quais camadas, a saber:

“Função Linear – O uso desta função deve ser geralmente limitado à camada de saída. Ela é utilizável para problemas cujas saídas são variáveis contínuas.”

“Função Tangente Hiperbólica – Muitos especialistas consideram que esta função deve ser a única utilizada, mas nós não concordamos....Nós temos experimentado bons resultados quando utilizamos a tangente hiperbólica na camada oculta de uma rede com três camadas e as funções logística ou linear na camada de saída.”

Com vistas a ilustrar ainda mais as discordâncias entre os especialistas quanto à utilização destas funções, constata-se que diversos trabalhos foram desenvolvidos desconsiderando as observações acima, utilizando, por exemplo, a função linear na camada de entrada da rede como, por exemplo, os trabalhos de Furtado (1999), e Silva, Calôba e Vieira (2005).

No intuito de verificar as duas observações apresentadas acima foram feitos testes com uma rede considerando na camada de saída a função linear. A rede, após treinar 255.000 épocas, apresentou erro percentual médio nas amostras de validação de 47%, acima daquele já obtido com função logística.

Quanto à utilização da função tangente hiperbólica em todas as camadas foram testadas três arquiteturas, que resultaram em erros médios percentuais nas amostras de teste de 42% em uma delas e 38% nas demais.

Os melhores resultados foram obtidos utilizando as funções linear na camada de entrada, tangente hiperbólica nas camadas ocultas e logística na camada de saída.

No que se refere à variável a ser predita, foram feitas novas tentativas de utilização da deformação específica resiliente. Os resultados demonstraram que os erros percentuais médios são muito superiores àqueles obtidos tendo como saída alvo o módulo de resiliência, como já constatado na primeira fase do estudo. Sendo assim, foi adotado em definitivo o valor de M_R como saída alvo.

Outra verificação foi feita alterando-se o conjunto de amostras de validação das redes, objetivando avaliar se havia grande influência no valor do erro percentual médio obtido. Foi treinada apenas uma rede nestas condições, observando-se uma elevação do erro de 38 para 48%, constatando-se assim que, apesar de não ocorrer uma alteração significativa, há influência no resultado, ainda que não seja decisiva.

Uma vez efetuados todos os testes descritos e consolidada a base de dados apresentada no Capítulo 5, foram efetuados os procedimentos finais de treinamento das redes.

O melhor resultado obtido foi o da rede RN33, apresentada no Quadro 8.29, com erro percentual médio de 40% e máximo de 138% nas amostras de validação. Tendo em vista que este erro ainda se apresentava muito elevado, foram efetuados testes com redes do tipo GRNN. Estes testes demonstraram que este tipo de rede apresenta desempenho bem mais satisfatório que as do tipo MLP. Para a mesma base dados e mesmas amostras de validação da rede RN33, o erro percentual médio caiu para 30%, e o erro máximo para 89%. Assim sendo, optou-se por adotar este tipo de rede em definitivo.

As redes do tipo GRNN têm como grande vantagem sobre as MLP uma arquitetura fixa de três camadas, além do fato de que durante o processo de treinamento apenas o fator de *smoothing* é alterado, sendo definido por ajustes iterativos de validação.

Uma vez constatado o melhor desempenho das redes GRNN, as redes desenvolvidas a partir dos procedimentos de classificação de amostras em famílias de solos quanto à resiliência foram também deste tipo. As fichas resumo das redes GRNN treinadas são apresentadas no Quadro 8.31, inserido a seguir.

Quadro 8.29 - Rede RN 33

SAÍDA ALVO: M_r						
ARQUITETURA						
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA			
11 linear	22 tanh	22 tanh	1 logistic			
NÚMERO DE PADRÕES						
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL
7.056	94,0%	338	4,5%	112	1,5%	7.506
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS						
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL
8,4		9,0		8,7		8,5
ESTATÍSTICA DA REDE						
R^2	0,9716	Coeficiente de Correlação		0,9857	Épocas de Treinamento	
\bar{r}^2	0,9716	Percentual até 5%		44,018		
Erro Médio Quadrático	0	Percentual de 5 a 10%		27,152		
Erro Médio Absoluto	0,008	Percentual de 10 a 20%		20,437		
Erro Mínimo Absoluto	0	Percentual de 20 a 30%		5,222		
Erro Máximo Absoluto	0,135	Percentual acima de 30%		3,171		
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r						

Quadro 8.30 - Rede RN 37

SAÍDA ALVO: M_r																														
ARQUITETURA																														
1ª. CAMADA	2ª. CAMADA	3ª. CAMADA	4ª. CAMADA																											
11 linear	33 tanh	22 tanh	1 logistic																											
NÚMERO DE PADRÕES																														
TREINAMENTO		TESTE		VALIDAÇÃO		TOTAL																								
6.434	85,7%	728	9,7%	344	4,6%	7.506																								
ERRO PERCENTUAL MÉDIO DOS CONJUNTOS																														
TREINAMENTO	TESTE	VALIDAÇÃO		TOTAL																										
				5,6																										
ESTATÍSTICA DA REDE																														
R^2	0,9872	Coeficiente de Correlação		0,9937	Épocas de Treinamento																									
\bar{r}^2	0,9874	Percentual até 5%		59,353																										
Erro Médio Quadrático	0	Percentual de 5 a 10%		25,220																										
Erro Médio Absoluto	0,005	Percentual de 10 a 20%		12,323																										
Erro Mínimo Absoluto	0	Percentual de 20 a 30%		2,265																										
Erro Máximo Absoluto	0,089	Percentual acima de 30%		0,839			129.000																							
FATOR DE CONTRIBUIÇÃO DAS VARIÁVEIS NA PREDIÇÃO DE M_r																														
<table border="1"> <caption>Data for Fator de Contribuição das Variáveis na Predição de M_r</caption> <thead> <tr> <th>Variável</th> <th>Fator de Contribuição</th> </tr> </thead> <tbody> <tr><td>#1</td><td>0,085</td></tr> <tr><td>#3/8</td><td>0,105</td></tr> <tr><td>#4</td><td>0,082</td></tr> <tr><td>#10</td><td>0,098</td></tr> <tr><td>#40</td><td>0,152</td></tr> <tr><td>#200</td><td>0,118</td></tr> <tr><td>IP</td><td>0,062</td></tr> <tr><td>hmodal</td><td>0,108</td></tr> <tr><td>DENSMOLD</td><td>0,115</td></tr> <tr><td>S3</td><td>0,022</td></tr> <tr><td>SD</td><td>0,052</td></tr> </tbody> </table>							Variável	Fator de Contribuição	#1	0,085	#3/8	0,105	#4	0,082	#10	0,098	#40	0,152	#200	0,118	IP	0,062	hmodal	0,108	DENSMOLD	0,115	S3	0,022	SD	0,052
Variável	Fator de Contribuição																													
#1	0,085																													
#3/8	0,105																													
#4	0,082																													
#10	0,098																													
#40	0,152																													
#200	0,118																													
IP	0,062																													
hmodal	0,108																													
DENSMOLD	0,115																													
S3	0,022																													
SD	0,052																													

Quadro 8.31 - Redes GRNN

SAÍDA ALVO: M_r							
ARQUITETURA GRNN							
1ª. CAMADA		2ª. CAMADA		3ª. CAMADA			
logistic							
REDE	Especialista - Procedimento 2						
	2G Coesivo	2G Granular	3G Coesivo	3G Intermed.	3G Granular	4G Intercoe	4G Intergran
Número de Padrões							
Treinamento	3.791	3.014	2.123	3.289	1.377	1.685	1.653
Teste	421	334	235	365	153	187	183
Validação	-	-	-	-	-	-	-
Total	4.212	3.348	2.358	3.654	1.530	1.872	1.836
Erro Percentual Médio							
Treinamento	-	-	-	-	-	-	-
Teste	-	-	-	-	-	-	-
Validação	-	-	-	-	-	-	-
Total	5,4	3,3	3,7	3,9	1,2	5,1	3,2
ESTATÍSTICA DAS REDES							
R^2	0,9605	0,9831	0,9769	0,9687	0,9960	0,9659	0,9850
r^2	0,9620	0,9834	0,9782	0,9693	0,9961	0,9668	0,9851
Erro Médio Quadrático	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Erro Médio Absoluto	0,007	0,011	0,007	0,005	0,004	0,007	0,011
Erro Mínimo Absoluto	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Erro Máximo Absoluto	0,203	0,205	0,179	0,247	0,084	0,212	0,111
Coefficiente de Correlação	0,9808	0,9917	0,9890	0,9845	0,9980	0,9833	0,9925
Percentual até 5%	62,369	75,269	74,555	70,389	94,183	63,835	76,307
Percentual de 5 a 10%	20,584	15,800	14,970	16,639	5,033	20,459	14,216
Percentual de 10 a 20%	14,008	8,572	9,712	11,576	0,784	13,034	9,205
Percentual de 20 a 30%	2,683	0,358	0,551	1,232	0,000	2,244	0,272
Percentual acima de 30%	0,356	0,000	0,212	0,164	0,000	0,427	0,000
Número de Testes do Fator de Smoothing	178	119	34	183	269	345	381
REDE	K-means - Procedimento 1				k-means - Procedimento 2		
	4G Coesivo	4G Intercoe.	4G Intergr.	4G Granular	4G Coesivo	4G Intercoe.	4G Intergr.
Número de Padrões							
Treinamento	2.007	1.685	1.780	1.215	2.398	891	2.285
Teste	225	187	200	135	266	99	253
Validação	-	-	-	-	-	-	-
Total	2.232	1.872	1.980	1.350	2.664	990	2.538
Erro Percentual Médio							
Treinamento	-	-	-	-	-	-	-
Teste	-	-	-	-	-	-	-
Validação	-	-	-	-	-	-	-
Total	3,9	4,7	3,4	3,4	4,1	5,5	3,9
ESTATÍSTICA DAS REDES							
R^2	0,9677	0,9690	0,9777	0,9739	0,9739	0,9594	0,9807
r^2	0,9682	0,9696	0,9785	0,9749	0,9754	0,9615	0,9810
Erro Médio Quadrático	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Erro Médio Absoluto	0,007	0,008	0,006	0,007	0,006	0,010	0,014
Erro Mínimo Absoluto	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Erro Máximo Absoluto	0,237	0,193	0,189	0,208	0,164	0,225	0,114
Coefficiente de Correlação	0,9840	0,9847	0,9892	0,9874	0,9876	0,9805	0,9904
Percentual até 5%	72,047	67,415	78,490	76,211	71,021	62,828	69,622
Percentual de 5 a 10%	15,994	17,254	12,749	13,390	17,643	17,172	20,252
Percentual de 10 a 20%	10,556	12,714	8,191	9,758	10,623	15,657	9,653
Percentual de 20 a 30%	1,257	2,457	0,570	0,641	0,713	3,939	0,433
Percentual acima de 30%	0,146	0,160	0,000	0,000	0,000	0,404	0,039
Número de Testes do Fator de Smoothing	98	337	17	27	133	361	250

Quadro 8.31 - Redes GRNN (Continuação)

SAÍDA ALVO: M_r							
ARQUITETURA GRNN							
1ª. CAMADA		2ª. CAMADA		3ª. CAMADA			
logistic		[]		[]			
REDE	k-means - Procedimento 2						EM Proc. 1
	4G Granular	5G Coes. 1	5G Coes. 2	5G Inter. 1	5G Inter. 2	5G Gran.	4G Coesivo
Número de Padrões - Procedimento 2							
Treinamento	1.232	2.042	729	1.620	1.053	1.296	2.916
Teste	136	226	81	180	117	144	324
Validação	-	-	-	-	-	-	-
Total	1.368	2.268	810	1.800	1.170	1.440	3.240
Erro Percentual Médio							
Treinamento	-	-	-	-	-	-	-
Teste	-	-	-	-	-	-	-
Validação	-	-	-	-	-	-	-
Total	1,9	3,9	7,5	4,3	2,4	1,0	3,9
ESTATÍSTICA DAS REDES							
R^2	0,9908	0,9772	0,9456	0,9799	0,9869	0,9952	0,9388
r^2	0,9909	0,9783	0,9490	0,9802	0,9870	0,9952	0,9429
Erro Médio Quadrático	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Erro Médio Absoluto	0,007	0,006	0,014	0,010	0,010	0,004	0,013
Erro Mínimo Absoluto	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Erro Máximo Absoluto	0,126	0,182	0,237	0,141	0,102	0,093	0,343
Coefficiente de Correlação	0,9954	0,9891	0,9742	0,9901	0,9935	0,9976	0,9710
Percentual até 5%	89,105	71,737	53,333	72,333	81,624	94,306	57,738
Percentual de 5 a 10%	8,626	17,901	20,617	13,333	14,530	4,444	22,553
Percentual de 10 a 20%	2,120	9,921	17,778	13,833	3,846	1,250	14,881
Percentual de 20 a 30%	0,146	0,441	6,296	0,500	0,000	0,000	3,439
Percentual acima de 30%	0,000	0,000	1,975	0,000	0,000	0,000	1,389
Número de Testes do Fator de Smoothing	260	43	848	151	125	107	534
REDE	EM - Procedimento 1			EM - Procedimento 2			
	4G Intercoe.	4G Intergr.	4G Granular	5G Coes. 1	5G Coes. 2	5G Intercoe.	5G Intergr.
Número de Padrões							
Treinamento	870	1.620	1.361	972	2.333	438	1.938
Teste	102	180	151	108	259	48	222
Validação	-	-	-	-	-	-	-
Total	972	1.800	1.512	1.080	2.592	486	2.160
Erro Percentual Médio							
Treinamento	-	-	-	-	-	-	-
Teste	-	-	-	-	-	-	-
Validação	-	-	-	-	-	-	-
Total	4,2	4,2	6,2	4,2	4,4	6,3	3,9
ESTATÍSTICA DAS REDES							
R^2	0,9656	0,9684	0,9388	0,9701	0,9792	0,9490	0,9785
r^2	0,9664	0,9697	0,9428	0,9735	0,9801	0,9525	0,9795
Erro Médio Quadrático	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Erro Médio Absoluto	0,013	0,005	0,013	0,009	0,006	0,013	0,006
Erro Mínimo Absoluto	0,0	0,0	0,0	0,0	0,0	0,0	0,0
Erro Máximo Absoluto	0,265	0,219	0,343	0,252	0,176	0,206	0,168
Coefficiente de Correlação	0,9831	0,9848	0,9710	0,9866	0,9900	0,9760	0,9897
Percentual até 5%	69,650	68,111	57,738	70,648	68,017	58,436	72,377
Percentual de 5 a 10%	16,152	18,889	22,553	17,778	19,792	19,342	16,605
Percentual de 10 a 20%	12,243	12,000	14,881	11,204	11,150	14,815	10,123
Percentual de 20 a 30%	1,955	0,944	3,439	0,307	0,926	6,584	0,802
Percentual acima de 30%	0,000	0,056	1,389	0,000	0,116	0,823	0,093
Número de Testes do Fator de Smoothing	280	225	534	230	60	404	180

Quadro 8.31 - Redes GRNN (Continuação)

SAÍDA ALVO: M_r							
ARQUITETURA GRNN							
1ª. CAMADA		2ª. CAMADA		3ª. CAMADA			
logistic							
REDE	EM Proc. 2	Mesma Classificação				Base Completa	
	5G Granular	Coesivo	Intermed.	Granular	Total		
Número de Padrões - Procedimento 2							
Treinamento	1.021	1.787	2.070	675	4.563	6.380	
Teste	113	201	233	75	513	701	
Validação	-	64	73	24	162	425	
Total	1.134	2.052	2.376	774	5.238	7.506	
Erro Percentual Médio							
Treinamento	-	3,2	3,7	1,4	3,8	3,6	
Teste	-	7,0	9,0	4,4	10,5	10,1	
Validação	-	9,0	10,8	5,5	11,2	9,8	
Total	1,9	3,7	4,5	1,8	4,6	4,6	
ESTATÍSTICA DAS REDES							
R^2	0,9910	0,9802	0,9658	0,9920	0,9705	0,9697	
r^2	0,9911	0,9818	0,9665	0,9921	0,9713	0,9703	
Erro Médio Quadrático	0,0	0,0	0,0	0,0	0,0	0,0	
Erro Médio Absoluto	0,007	0,006	0,005	0,007	0,005	0,005	
Erro Mínimo Absoluto	0,0	0,0	0,0	0,0	0,0	0,0	
Erro Máximo Absoluto	0,188	0,154	0,248	0,085	0,200	0,220	
Coefficiente de Correlação	0,9955	0,9909	0,9831	0,9960	0,9855	0,9850	
Percentual até 5%	90,300	74,366	66,919	89,406	67,411	66,707	
Percentual de 5 a 10%	8,025	16,813	17,635	9,302	17,087	17,466	
Percentual de 10 a 20%	1,499	8,825	13,510	1,292	13,882	14,375	
Percentual de 20 a 30%	0,176	0,341	1,684	0,000	1,432	1,239	
Percentual acima de 30%	0,000	0,195	0,253	0,000	0,248	0,213	
Número de Testes do Fator de Smoothing	140	52	34	135	46	47	

8.4 Análise dos Resultados Obtidos – Segunda Fase

A análise desenvolvida quanto à segunda fase do estudo das arquiteturas de redes neurais baseou-se nos seguintes pontos principais:

- Parâmetros estatísticos;
- Desempenho comparativo das redes *Multilayer Perceptron* (MLP) em relação às redes GRNN;
- Desempenho comparativo das redes com amostras classificadas em relação às redes nas quais se utilizou a base de dados total;
- Influência do tamanho da base de dados; e,
- Desempenho em relação à “ruídos”.

No que se refere aos parâmetros estatísticos das diversas redes, os mesmos podem ser observados nos Quadros 8.29 a 8.31. Com relação às redes MLP, fica patente que o fato de que valores excelentes desses parâmetros não indicam necessariamente bom desempenho das redes. Considerando as redes RN33 e RN37, observa-se que a segunda apresenta parâmetros estatísticos bem superiores à primeira, para aproximadamente o mesmo número de épocas de treinamento. Contudo, o desempenho observado nas amostras de validação é muito superior para a RN33, que apresentou erro percentual médio de 40% e máximo de 138%, enquanto a RN37 apresentou erros respectivos de 60 e 222%. O mesmo constata-se, por exemplo, quando comparados os resultados da Rede Módulo 9, treinada na primeira fase, que apresentou excelentes valores dos parâmetros estatísticos, mas péssimos resultados nas amostras de validação, com erro percentual médio de 55% e máximo de 448%.

Quanto às redes do tipo GRNN, os resultados neste aspecto são semelhantes, embora não tão expressivos quanto nas redes MLP, como se pode observar no Quadro 8.31, por exemplo, na rede K-means – Procedimento 2 – 4 Grupos – Intergranular, que nas amostras de validação apresentou erro médio percentual de 52% e máximo de 193%, ou na rede Especialista – Procedimento 2 – 2 Grupos – Coesivo, que apresentou respectivamente erros de 36 e 150%, ambas com bons parâmetros estatísticos.

A partir do Quadro 8.34 é apresentado também um resumo das amostras por faixa de erro médio percentual. Para efeito de análise foram estabelecidas as seguintes faixas:

- Erro \leq 15% - Baixo
- $15% <$ Erro \leq 30% - Médio
- $30% <$ Erro \leq 50% - Alto
- Erro $>$ 50% - Muito Alto

Com relação ao desempenho comparativo das redes MLP e GRNN, constata-se que o segundo tipo apresenta resultados bem melhores que o primeiro. Os Quadros 8.32 a 8.37, inseridos a seguir, constituem um resumo dos resultados de diversas redes treinadas. As redes MLP, apresentadas nos Quadros 8.32 e 8.33, foram treinadas variando-se a arquitetura, as funções de transferência e a própria base de dados, obtendo-se os melhores resultados na RN33, assim mesmo com erro percentual médio de 40% e máximo de 138%, ambos relativamente elevados. No Quadro 8.37 pode-se observar que o desempenho da rede GRNN, para a mesma base de dados e mesmas amostras de validação, é claramente superior àquele obtido nas duas redes MLP. Além dos melhores valores de erros percentuais médio e máximo, é possível constatar que a maioria das amostras é alocada nas faixas de erro “Baixo” e “Médio”, ocorrendo o inverso nas redes MLP. No Quadro 8.36 também é possível observar com clareza o desempenho bastante superior das redes GRNN em relação às MLP, tanto naquelas nas quais foram utilizadas as amostras classificadas em famílias de solos quanto à resiliência, quanto naquelas nas quais se utilizou o base total. Em função destes resultados não há dúvidas quanto ao fato de que as redes GRNN são muito mais adequadas que as MLP para resolução do problema estudado.

Quando se procede à comparação entre as redes treinadas com amostras classificadas em famílias de solos quanto ao comportamento resiliente e aquelas treinadas com a base integral, Quadros 8.32 a 8.37, constata-se que muitas das redes com amostras classificadas apresentam excelente desempenho, com erros percentuais médios e máximos em níveis muito bons. Contudo, ao se considerar todo o conjunto de amostras classificadas, os resultados deixam muito a desejar. Por exemplo, nas redes treinadas com base no agrupamento feito pelo algoritmo K-means – Procedimento 2 – 4 Grupos, Quadro 8.35, observa-se que a classe “Granular” apresenta excelentes resultados, a classe “Coesivo” resultados medianos e as demais

resultados muito ruins. Considerando a rede treinada com a base total, Quadro 8.37, constata-se que os resultados são medianos, mas que a ocorrência de amostras de validação com erros muito elevados é bem inferior àquela verificada nas redes treinadas com amostras classificadas. Mesmo para as redes treinadas com a base de dados com 318 amostras, Quadro 8.36, obtida conforme descrito no Capítulo 7, os resultados, neste aspecto, são muito próximos das redes treinadas com 463 amostras na base de dados. As redes com amostras classificadas que apresentaram desempenho superior àquele verificado na rede treinada com base integral foram as constantes do agrupamento efetuado pelo Especialista – Procedimento 2 – 3 Grupos, Quadro 8.34. Entretanto, o classificador obtido para este agrupamento mostrou-se extremamente ineficaz, inviabilizando a utilização dessas redes.

Em relação ao tamanho da base de dados, foi procedida uma análise treinando-se três redes do tipo GRNN nas quais foram alocadas 10, 20 e 30% das amostras no conjunto de validação. Os resultados são apresentados no Quadro 8.38. Em função desses resultados pode-se constatar que para o mesmo conjunto de validação há poucas diferenças quando nele são alocados 10 e 20% das amostras, o que não acontece quando se destina 30% delas à validação, situação na qual há uma nítida perda de capacidade de generalização, tendo em vista que o erro percentual máximo apresenta grande aumento. Outro aspecto interessante é que algumas amostras apresentaram redução no erro quando destinado um percentual menor para treinamento como, por exemplo, as amostras de números 20, 50 e 210. Quando os resultados são analisados considerando o conjunto de validação de cada rede individualmente, a perda de capacidade de generalização fica mais óbvia, ocorrendo aumento tanto no erro percentual médio quanto no máximo.

Esses resultados confirmam a necessidade de prover a rede do maior número possível de amostras, mas também indicam a necessidade de melhoria em termos qualitativos, pois a diminuição do erro nas amostras número 20, 50 e 210 para a rede treinada com 30% das amostras no conjunto de validação somente se justifica pela presença de ruídos nas outras duas bases de dados.

No que diz respeito ao desempenho das redes neurais treinadas na presença de ruídos, não foi possível obter uma conclusão sustentável. Contudo, há indicações de que as mesmas não são capazes de lidar com ruídos de forma satisfatória. Um exemplo disso são os resultados de erro obtido para a amostra número 340. Essa amostra apresenta erro muito alto em todas as redes treinadas, sejam elas classificadas ou não, MLP ou GRNN, como pode ser observado nos Quadros 8.33.

8.34 e 8.37. De fato, os dados da mesma podem ser considerados um tanto suspeitos quando comparados a granulometria, que indica um material com características nitidamente granulares, com as constantes do modelo composto, que determinam elevada contribuição da tensão desvio, além do baixo valor da constante K_1 , característico de materiais coesivos.

8.5 Considerações Finais

Os resultados obtidos demonstram que as redes neurais são capazes de inferir de forma adequada os valores do módulo de resiliência com base nos dados de caracterização e compactação dos solos. Isto fica evidente se considerados os erros percentuais médios dos conjuntos de treinamento, teste e validação de algumas delas. Contudo fica clara também a dificuldade de dotar as redes de boa capacidade de generalização, haja vista que nas amostras de validação foram obtidos alguns erros bastante elevados. Constatou-se que nas redes treinadas com bases de dados elaboradas com amostras agrupadas em famílias de comportamento resiliente os problemas de generalização se agravam. Isto pode estar ocorrendo por falhas no agrupamento das amostras, decorrentes da presença de “ruídos” nos dados preditivos, que não podem ser solucionadas sem que a obtenção e o registro dos mesmos sejam devidamente controlados, o que não é o caso daqueles utilizados neste estudo.

Os problemas relativos à presença de “ruídos” são menos impactantes na base de dados total, não agrupada. Isto se deve ao fato de que seus efeitos são diluídos de forma mais adequada em um domínio mais heterogêneo, possibilitando à rede neural maior capacidade de generalização. Assim sendo, para desenvolvimento do aplicativo para predição dos valores do módulo de resiliência optou-se pela rede neural “Base Total”, do tipo GRNN.

Quadro 8.32 - Erros Percentuais Médios - Redes MLP

REDES NEURAIS												
AM	RN17	RN18	RN20	RN21	RN22	RN23	RN24	RN25	RN26	RN27	RN28	RN29
10	72	84	16	44	27	74	40	75	76	66	20	39
20	45	75	44	86	35	57	52	61	107	30	75	5
30	9	60	59	27	10	61	48	185	32	20	116	32
40	12	11	70	12	33	4	4	397	73	303	20	26
50	31	14	73	12	16	58	32	108	32	554	50	57
60	22	40	21	23	6	3	23	19	18	24	21	15
70	22	91	70	62	31	27	43	64	45	80	49	69
80	41	58	35	34	222	119	68	88	119	11	249	125
90	25	29	25	29	45	22	44	72	40	30	33	37
100	24	19	82	55	37	66	32	7	36	60	95	24
110	60	45	49	23	27	44	4	44	55	37	35	17
120	14	100	8	38	67	10	15	37	125	25	60	18
130	8	82	11	29	113	10	21	133	53	78	22	30
140	31	44	18	29	35	4	39	23	10	3	65	10
150	18	76	34	69	12	125	6	65	1431	491	59	31
160	183	32	93	146	98	266	153	39	139	446	294	246
170	15	9	50	74	35	74	13	15	28	25	7	12
180	34	35	151	2	13	6	61	67	27	42	15	10
190	76	42	29	34	76	31	6	75	77	23	27	12
200	52	152	30	30	43	48	25	46	84	276	57	28
210	61	8	36	474	32	224	59	76	899	76	626	26
220	33	13	76	17	20	51	31	18	78	39	24	34
230	31	19	60	20	27	131	74	65	742	81	731	31
240	9	47	9	30	6	35	10	27	21	9	10	19
250	30	25	25	10	50	53	22	14	101	43	21	9
Média	38	48	47	56	45	64	37	73	178	115	111	38
Máximo	183	152	151	474	222	266	153	397	1431	554	731	246

Quadro 8.34 - Erros Percentuais Médios - Redes GRNN - Agrupamento por Especialista

Amostra	REDES NEURAIS - ESPECIALISTA - PROCEDIMENTO 2								
	2 Grupos		3 Grupos			4 Grupos			
	Coesivo	Granular	Coesivo	Intermediário	Granular	Coesivo	Intercoesivo	Intergranular	Granular
10	26		26			26			
20	16		18			18			
30		8			40				40
40		21		39				25	
50		6			4				4
60				16					
71				18					
80	37			31			36		
90				58					
100		59		51				28	
110		25		70				25	
120		134							
130		4		4				4	
140	20		33			33			
150		13							
160	34			35			31		
170	15		14			14			
180		35		28				14	
190		10		34				6	
200		5			31				31
210		13			27				27
220		34			27				27
230	58		26			26			
240	16			24			11		
250	20		6			6			
260	17			13			5		
270		77		18				74	
280	6		8			8			
290	58		55			55			
300	33			62			31		
310	10		38			38			
320	14		15			15			
330	52		52			52			
340		71		72				240	
350	69			29			28		

Quadro 8.34 - Erros Percentuais Médios - Redes GRNN - Agrupamento por Especialista (Continuação)

Amostra	REDES NEURAIS - ESPECIALISTA - PROCEDIMENTO 2								
	2 Grupos		3 Grupos			4 Grupos			
	Coesivo	Granular	Coesivo	Intermediário	Granular	Coesivo	Intercoesivo	Intergranular	Granular
360	9			11			11		
370	9			27			7		
380	78			77			76		
390		6			15				15
400	150		27			27			
410		8							
420		59		59			7		
430		6		5				5	
440		6		6				6	
450		36		20				11	
460	39		40			40			
média	36	30	28	34	24	28	24	40	24
máx	150	134	55	77	40	55	76	240	40
Erro Baixo									
N.o de Amostras	6	11	4	5	2	4	5	6	2
% de Amostras	27,3	52,4	30,8	20,8	33,3	30,8	50,0	54,5	33,3
Erro % Médio	10,5	7,7	10,8	7,8	9,5	10,8	8,2	7,7	9,5
Erro Médio									
N.o de Amostras	6	2	4	8	2	4	1	3	2
% de Amostras	27,3	9,5	30,8	33,3	33,3	30,8	10,0	27,3	33,3
Erro % Médio	19,2	23,0	24,3	22,5	27,0	24,3	28,0	26,0	27,0
Erro Alto									
N.o de Amostras	4	3	3	4	2	3	3	0	2
% de Amostras	18,2	14,3	23,1	16,7	33,3	23,1	30,0	0,0	33,3
Erro % Médio	35,8	35,0	37,0	34,8	35,5	37,0	32,7		35,5
Erro Muito Alto									
N.o de Amostras	6	5	2	7	0	2	1	2	0
% de Amostras	27,3	23,8	15,4	29,2	0,0	15,4	10,0	18,2	0,0
Erro % Médio	77,5	80,0	53,5	64,1		53,5	76,0	157,0	

Quadro 8.35 - Erros Percentuais Médios - Redes GRNN - Agrupamento por Algoritmos

Amostra	REDE NEURAL																	
	KMEANS - PROCEDIMENTO 2 4 GRUPOS				KMEANS - PROCEDIMENTO 2 5 GRUPOS					EM - PROCEDIMENTO 1				EM - PROCEDIMENTO 2				
	Coesivo	Intercoesivo	Intergranular	Granular	Coesivo1	Coesivo2	Intercoesivo	Intergranular	Granular	Coesivo	Intercoesivo	Intergranular	Granular	Coesivo 1	Coesivo 2	Intercoesivo	Intergranular	Granular
10	27				26					13					26			
20	14				15					14					15			
30			9				26					145					9	
40			18				30					19					18	
50				4				37					7					4
60			60				18						29					
71							8			64							8	
80		39				41						16		41				
90													46					
100				31				31				54						31
110			83				84				78			70				
120				13				131			21							27
130				5				4			7						5	
140	19				18					62				20				
150										27								
160			38					39		35				33				
170	14				14					14				14				
180			36				14					31					17	
190			11				14					10					10	
200				6					5				5					6
210				6					12				6					12
220				9					15			50						10
230	57					45					50			55				
240		91				151						23		17				
250	8				6						25			20				
260	11				11					5				15				
270			193					18		17				16				
280	8				4					4				8				
290	73				13					57				23				
300	57				18					33					63			
310	15				65					15				35				
320	22				81					39					34			
330	52				50					52					25			

Quadro 8.35 - Erros Percentuais Médios - Redes GRNN - Agrupamento por Algoritmos (Continuação)

Amostra	REDE NEURAL																	
	KMEANS - PROCEDIMENTO 2 4 GRUPOS				KMEANS - PROCEDIMENTO 2 5 GRUPOS					EM - PROCEDIMENTO 1				EM - PROCEDIMENTO 2				
	Coesivo	Intercoesivo	Intergranular	Granular	Coesivo1	Coesivo2	Intercoesivo	Intergranular	Granular	Coesivo	Intercoesivo	Intergranular	Granular	Coesivo 1	Coesivo 2	Intercoesivo	Intergranular	Granular
340		312				295						73			325			
350										63								
360			27				10				69				34			
370		6					24			27					8			
380							117			76							78	
390			71					15									5	
400	48	49	60			17						47			50			
410								6			30							
420			59				6						40				12	
430		18		22				6				6					31	
440			7				6					38					7	
450				17				36					12					22
460	48					46				44					91			
Média	32	86	52	13	27	99	28	28	29	35	40	39	30	22	34	325	18	16
Máximo	73	312	193	31	81	295	84	117	131	76	78	145	73	35	91	325	78	31
Erro Baixo																		
N.o de Amostras	7	1	3	6	6	0	3	4	6	6	1	2	4	1	4	0	7	4
% de Amostras	46,7	16,7	23,1	66,7	50,0	0,0	50,0	44,4	60,0	31,6	14,3	20,0	44,4	33,3	21,1	0,0	63,6	57,1
Erro % Médio	12,7	6,0	9,0	7,2	10,5		12,0	6,5	9,8	10,8	7,0	8,0	7,5	8,0	13,0		8,0	8,0
Erro Médio																		
N.o de Amostras	2	1	2	2	3	1	2	3	0	3	3	3	1	1	6	0	2	2
% de Amostras	13,3	16,7	15,4	22,2	25,0	16,7	33,3	33,3	0,0	15,8	42,9	30,0	11,1	33,3	31,6	0,0	18,2	28,6
Erro % Médio	24,5	18,0	22,5	19,5	20,7	17,0	24,0	22,7		23,7	25,3	19,3	29	23,0	20,7		17,5	24,5
Erro Alto																		
N.o de Amostras	2	2	2	1	1	3	0	1	3	4	1	4	2	1	5	0	1	1
% de Amostras	13,3	33,3	15,4	11,1	8,3	50,0	0,0	11,1	30,0	21,1	14,3	40,0	22,2	33,3	26,3	0,0	9,1	14,3
Erro % Médio	48,0	44,0	37,0	31,0	50,0	44,0		39,0	34,7	37,8	50,0	41,5	43,0	35,0	38,4		31,0	31,0
Erro Muito Alto																		
N.o de Amostras	4	2	6	0	2	2	1	1	1	6	2	1	2	0	4	1	1	0
% de Amostras	26,7	33,3	46,2	0,0	16,7	33,3	16,7	11,1	10,0	31,6	28,6	10,0	22,2	0,0	21,1	100,0	9,1	0,0
Erro % Médio	59,8	201,5	87,7		73,0	223,0	84,0	117,0	131	62,3	73,5	145,0	63,5		69,8	325	78,0	

Quadro 8.36 - Erros Percentuais Médios - Redes Mesma Classificação

Amostra	Rede Neural							
	Coesivo		Intermediário		Granular		Base Total	
	MLP	GRNN	MLP	GRNN	MLP	GRNN	MLP	GRNN
10	64	12					41	26
20	48	14					30	41
40			12	40			11	42
50					32	5	44	14
80			51	18			73	18
110			47	70			105	73
130			1	5			3	6
140	13	20					23	18
160			11	39			95	16
170	24	14					100	14
180			172	27			71	28
190			195	33			39	34
200					6	6	16	7
210					8	4	9	14
240			550	26			26	25
270			24	17			43	19
280	25	3					26	3
290	16	17					57	41
310	27	34					103	33
320	25	81					44	82
330	46	51					26	52
360			61	34			320	43
370			14	8			5	18
380			43	39			45	77
440			16	7			24	7
460	146	46					150	19
Média	43	29	92	28	15	5	59	30
Máximo	146	81	550	70	32	6	320	82
Erro Baixo								
N.o de Amostras	1	4	4	3	2	3	4	7
% de Amostras	10,0	40,0	30,8	23,1	66,7	100,0	15,4	26,9
Erro % Médio	13,0	10,8	9,5	6,7	7,0	5,0	7,0	10,3
Erro Médio								
N.o de Amostras	5	2	2	4	0	0	7	9
% de Amostras	50,0	20,0	15,4	30,8	0,0	0,0	26,9	34,6
Erro % Médio	23,4	18,5	20,0	22,0	-	-	24,4	20,8
Erro Alto								
N.o de Amostras	2	2	2	5	1	0	6	6
% de Amostras	20,0	20,0	15,4	38,5	33,3	0,0	23,1	23,1
Erro % Médio	47,0	40,0	45,0	37,0	32,0	0,0	42,7	39,0
Erro Muito Alto								
N.o de Amostras	2	2	5	1	0	0	9	4
% de Amostras	20,0	20,0	38,5	7,7	0,0	0,0	34,6	15,4
Erro % Médio	105,0	66,0	205,8	70,0	0,0	0,0	119,3	71,0

Quadro 8.37 - Comparativo Redes MLP X Rede GRNN

Amostra	REDE NEURAL		
	RN37 MLP	RN33 MLP	Base Total GRNN
10	38	18	26
20	222	40	48
30	77	14	27
40	7	42	38
50	122	10	32
60	47	33	32
70	4	5	2
80	34	138	17
90	49	68	51
100	67	90	37
110	62	90	57
120	159	103	84
130	3	11	7
140	61	26	7
150	26	28	19
160	27	42	31
170	18	23	33
180	80	63	35
190	8	9	10
200	46	4	9
210	49	9	27
220	25	34	30
230	16	56	23
240	38	19	26
250	112	34	25
260	28	26	6
270	27	14	22
280	17	9	4
290	22	28	41
300	22	71	32
310	147	96	26
320	21	52	75
330	10	38	53
340	177	55	89
350	79	77	25
360	65	45	11
370	34	51	12
380	107	45	78
390	81	7	26
400	134	14	18
410	100	46	22
420	77	31	10
430	78	10	46
440	64	22	8

Quadro 8.37 - Comparativo Redes MLP X Rede GRNN (Continuação)

Amostra	REDE NEURAL		
	RN37 MLP	RN33 MLP	Base Total GRNN
450	28	8	21
460	30	81	21
Média	60	40	30
Máximo	222	138	89
Erro Baixo			
N.o de Amostras	5	13	11
% de Amostras	10,9	28,3	23,9
Erro % Médio	7,0	9,5	7,8
Erro Médio			
N.o de Amostras	13	8	17
% de Amostras	28,3	17,4	37,0
Erro % Médio	23,6	23,8	23,6
Erro Alto			
N.o de Amostras	8	11	11
% de Amostras	17,4	23,9	23,9
Erro % Médio	41,9	39,1	36,8
Erro Muito Alto			
N.o de Amostras	20	14	7
% de Amostras	43,5	30,4	15,2
Erro % Médio	103,6	77,9	69,6

Quadro 8.38 - Erros Percentuais Médios Variando-se o Conjunto de Validação

Amostra	REDE RN33 GRNN				
	10% ERRO	20% ERRO	30% ERRO	20% ERRO	30% ERRO
2					44
5				63	108
10	26	25	44	25	44
12					26
15				26	24
20	48	51	21	51	21
22					3
25				15	7
30	27	25	25	25	25
32					42
35				15	35
40	38	38	41	38	41
42					34
45				6	5
50	32	33	7	33	7
52					28
55				7	7
60	32	34	34	34	34
62					7
65				13	13
80	17	18	18	18	18
82					9
85				29	30
90	51	58	58	58	58
92					29
95				30	30
100	37	28	17	28	17
102					41
105				45	47
110	57	71	73	71	73
112					9
115				20	60
120	84	77	91	77	91
122					2
125				5	3
130	7	5	4	5	4
132					28
135				4	3
140	7	10	21	10	21
142					22
145				55	69
150	19	34	34	34	34
152					22
155				52	58
160	31	26	34	26	34
162					56
165				268	261
170	33	42	44	42	44
172					19
175				20	17
180	35	36	36	36	36
182					10
185				96	96
190	10	11	10	11	10
192					10
195				5	31

Quadro 8.38 - Erros Percentuais Médios Variando-se o Conjunto de Validação (Continuação)

Amostra	REDE RN33 GRNN				
	10% ERRO	20% ERRO	30% ERRO	20% ERRO	30% ERRO
200	9	7	6	7	6
202					55
205				5	5
210	27	28	12	28	12
212					8
215				14	16
220	30	31	48	31	48
222					28
225				174	26
230	23	30	28	30	28
232					22
235				125	13
240	26	26	26	26	26
242					74
245				24	14
250	25	24	19	24	19
252					7
255				21	18
260	6	6	9	6	9
262					21
265				23	24
270	22	19	20	19	20
272					29
275				29	31
280	4	5	7	5	7
282					54
285				4	5
290	41	52	56	52	56
293					25
295				145	126
300	32	32	30	32	30
302					41
305				48	50
310	26	33	33	33	33
312					45
315				45	57
320	75	71	80	71	80
322					50
325				59	60
330	53	53	52	53	52
332					43
335				13	19
340	89	74	246	74	246
342					47
345				36	33
350	25	19	72	19	72
352					7
355				4	3
360	11	10	28	10	28
362					50
365				42	53
370	12	11	7	11	7
372					145
375				58	101
380	78	77	78	77	78
382					90

Quadro 8.38 - Erros Percentuais Médios Variando-se o Conjunto de Validação (Continuação)

Amostra	REDE RN33 GRNN				
	10% ERRO	20% ERRO	30% ERRO	20% ERRO	30% ERRO
385				55	55
390	26	10	33	10	33
392					9
395				39	37
400	18	27	28	27	28
402					29
405				8	8
410	22	21	26	21	26
412					53
415				50	47
420	10	8	58	8	58
422					33
425				26	8
430	46	31	32	31	32
432					37
435				23	24
440	8	6	5	6	5
442					15
445				161	169
450	21	21	22	21	22
452					10
455				37	154
460	21	36	43	36	43
Média	31	31	38	38	39
Máximo	89	77	246	268	261
Erro Baixo					
N.o de Amostras	10	11	9	25	35
% de Amostras	22,2	24,4	20,0	27,8	25,9
Erro % Médio	8,4	8,1	7,4	8,3	7,6
Erro Médio					
N.o de Amostras	17	14	14	25	37
% de Amostras	37,8	31,1	31,1	27,8	27,4
Erro % Médio	23,6	24,1	23,5	24,3	23,9
Erro Alto					
N.o de Amostras	11	11	12	19	32
% de Amostras	24,4	24,4	26,7	21,1	23,7
Erro % Médio	36,8	34,5	38,0	38,0	39,8
Erro Muito Alto					
N.o de Amostras	7	9	10	21	31
% de Amostras	15,6	20,0	22,2	23,3	23,0
Erro % Médio	69,6	64,9	86,4	90,2	90,9

Capítulo 9

Análise da Influência dos Erros de Predição no Dimensionamento de Estruturas de Pavimentos Flexíveis

A modelagem matemática de fenômenos de qualquer natureza resulta sempre em um determinado erro associado, havendo por isso necessidade de avaliar o nível do mesmo de forma a se ter noção da confiabilidade do procedimento que está sendo utilizado. A melhor RNA obtida neste trabalho apresentou erro médio percentual de 30% nas amostras do conjunto de validação, conforme descrito no Capítulo 8. Os ensaios triaxiais de cargas repetidas, como qualquer ensaio, apresentam certa margem de erro, bastante variável, mas que alcança valores da ordem de 15% quando a modelagem é feita através do Modelo Composto, ou seja, a metade do erro médio obtido com a melhor RNA. Entretanto, a simples confrontação deste erro com aquele auferido nos ensaios de laboratório pode não refletir de forma adequada sua influência no dimensionamento. Assim, torna-se necessária a quantificação da influência do erro do modelo de comportamento resiliente gerado a partir dos valores de módulo de resiliência obtidos pela rede neural no dimensionamento das estruturas.

9.1 Metodologia

Para avaliar a influência dos erros de predição no dimensionamento de estruturas de pavimentos flexíveis foi elaborado um projeto fatorial contemplando uma estrutura típica, com espessuras constantes para as camadas granulares, variando-se somente os modelos de resiliência e a espessura do revestimento, conforme apresentado na Figura 9.1, inserida a seguir.

Revestimento em CBUQ espessuras de 4, 6, 8 e 10cm
Base – espessura = 20cm
Sub-base – espessura = 20cm
Subleito

Figura 9.1 – Estruturas consideradas no projeto fatorial de análise da influência dos erros de predição

Para elaboração do projeto fatorial foram utilizados para cada camada modelos de resiliência que apresentaram os quatro níveis de erro considerados, conforme descrito no Capítulo 8. Assim, a consideração de uma estrutura de três camadas e quatro níveis de erro, resulta em um projeto fatorial com um total de sessenta e quatro estruturas para cada espessura de revestimento e, considerando as quatro espessuras de revestimento utilizadas, o total analisado é de 256 estruturas comparativas. No Quadro 9.1, inserido a seguir, são apresentados os valores das constantes do Modelo Composto obtido nos ensaios, além do número da amostra na base de dados utilizada em cada camada. No Quadro 9.2, também inserido a seguir, é indicado o nível de erro obtido a partir dos resultados da rede neural junto ao número da amostra utilizada, e as constantes K_i são também aquelas advindas da utilização da rede neural.

Considerou-se, para fins de análise, a diferença de tensões no revestimento ($\Delta\sigma$) e seu reflexo nos valores calculados para o Número N de repetições do eixo padrão. Para cálculo dos valores de $\Delta\sigma$ foi utilizado o programa FEPAVE2. Os valores de Número N foram obtidos segundo a Equação 9.1, mediante a utilização da curva de fadiga indicada na Equação 9.2 (Motta, Medina e Souza, 2002).

$$N_f = K_1 (\Delta\sigma)^{-n_1} \quad (9.1)$$

$$N_f = 4.700 (\Delta\sigma)^{-2,13} \text{ (MPa)} \quad (9.2)$$

9.2 Resultados obtidos

Os resultados em termos de erros percentuais obtidos estão apresentados nos Quadros 9.4 a 9.7. Consta-se que os erros são em muitos casos elevados para as espessuras de revestimento de 4,0 e 6,0cm. Para as espessuras de revestimento de 8,0 e 10,0cm há uma queda substancial nos mesmos, podendo o erro médio ser considerado aceitável para os padrões de projetos de pavimento. Para essas duas últimas espessuras, considerando as mesmas faixas de erro estabelecidas para análise comparativa dos resultados da rede neural, observa-se que os resultados são satisfatórios. O Quadro 9.3, inserido a seguir, apresenta o número de estruturas por faixa de erro para cada espessura de revestimento considerada.

Quadro 9.3 – Número de estruturas por faixa de erro

Faixa de Erro (%)	Espessuras do Revestimento (cm)			
	4,0	6,0	8,0	10,0
Erro \leq 15	19	21	35	37
15 < Erro \leq 30	15	20	23	21
30 < Erro \leq 50	21	20	6	6
Erro > 50	9	3	-	-

Quanto aos erros observados quando da aplicação dos resultados obtidos na utilização da rede neural, três aspectos importantes devem ser ressaltados.

Um aspecto positivo refere-se ao fato de que as estruturas foram analisadas considerando apenas uma amostra como representativa do material de determinada camada. Na prática de projeto a disponibilidade de ensaios de caracterização e compactação para definição do modelo a ser utilizado é bem maior. Por exemplo, para o subleito, a Instrução de Serviço IS-206 (DNIT, 2005) estabelece a coleta de amostras e ensaios de seu material constituinte com espaçamento de 200m, o que representa cinco amostras a cada quilômetro. Para as jazidas de material de terraplenagem e pavimentação a instrução estabelece a coleta de pelo menos nove amostras por horizonte de material. Assim sendo, a definição dos modelos de

resiliência será feita com base em uma quantidade de dados muito superior à considerada no projeto fatorial elaborado neste trabalho, o que tende a minimizar de forma significativa o erro de modelagem pela rede neural.

Um aspecto negativo refere-se à curva de fadiga adotada neste estudo para cálculo do Número N. A constante $n1$ desta curva, que reflete a dependência da mistura asfáltica em relação às tensões, tende a ser maior que a da curva adotada. Motta, Medina e Sousa (2002) apresentaram uma coletânea de trinta e duas curvas de fadiga da qual se obtém um valor médio de 2,92 para esta constante. Assim sendo, as diferenças entre o Número N calculado com base nos ensaios triaxiais de carga repetida e com utilização da rede neural tendem a ser maiores que as obtidos neste estudo.

Outro aspecto a ser considerado é que os erros finais obtidos no comparativo entre os resultados da rede neural e do ensaio não apresentam boa correlação com as faixas de erro definidas. Por exemplo, a estrutura 64 deveria apresentar o maior erro final dentre as analisadas, tendo em vista que todas as amostras utilizadas para cálculo situam-se na faixa de erro “Muito Alto”, o que não acontece. O que se pode constatar é que os maiores erros tendem a se concentrar nas estruturas para as quais foram utilizadas na camada de base amostras na faixa de erro “Muito Alto”, o que fica bastante evidente quando se observa os resultados obtidos para espessura de revestimento de 10,0cm. Isto indica que uma melhor predição por parte da rede dos valores de M_R para os materiais granulares tende a reduzir de forma substancial o erro médio.

Deve-se ressaltar, contudo, que os resultados comparativos aqui apresentados são válidos para os critérios particulares utilizados nesta análise e não podem ser generalizados, tendo em vista que a análise mecanístico-empírica pode ser feita de outras formas, considerando, por exemplo, outros critérios de ruptura.

Quadro 9.1 - Projeto Fatorial - Constantes do Modelo Composto obtidas no ensaio

Estrutura	Amostras			SUBLEITO			SUBBASE			BASE		
	Subleito	Sub-base	Base	K1	K2	K3	K1	K2	K3	K1	K2	K3
1E	70	420	190	4.757	0,04	-0,39	7.484	0,39	-0,40	3.728	0,32	-0,24
2E	250	420	190	3.902	0,18	-0,53	7.484	0,39	-0,40	3.728	0,32	-0,24
3E	430	420	190	4.245	0,47	-0,24	7.484	0,39	-0,40	3.728	0,32	-0,24
4E	320	420	190	4.101	0,09	-0,47	7.484	0,39	-0,40	3.728	0,32	-0,24
5E	70	410	190	4.757	0,04	-0,39	3.911	0,50	-0,16	3.728	0,32	-0,24
6E	250	410	190	3.902	0,18	-0,53	3.911	0,50	-0,16	3.728	0,32	-0,24
7E	430	410	190	4.245	0,47	-0,24	3.911	0,50	-0,16	3.728	0,32	-0,24
8E	320	410	190	4.101	0,09	-0,47	3.911	0,50	-0,16	3.728	0,32	-0,24
9E	70	180	190	4.757	0,04	-0,39	3.406	0,33	-0,17	3.728	0,32	-0,24
10E	250	180	190	3.902	0,18	-0,53	3.406	0,33	-0,17	3.728	0,32	-0,24
11E	430	180	190	4.245	0,47	-0,24	3.406	0,33	-0,17	3.728	0,32	-0,24
12E	320	180	190	4.101	0,09	-0,47	3.406	0,33	-0,17	3.728	0,32	-0,24
13E	70	90	190	4.757	0,04	-0,39	8.922	0,45	-0,33	3.728	0,32	-0,24
14E	250	90	190	3.902	0,18	-0,53	8.922	0,45	-0,33	3.728	0,32	-0,24
15E	430	90	190	4.245	0,47	-0,24	8.922	0,45	-0,33	3.728	0,32	-0,24
16E	320	90	190	4.101	0,09	-0,47	8.922	0,45	-0,33	3.728	0,32	-0,24
17E	70	420	390	4.757	0,04	-0,39	7.484	0,39	-0,40	3.973	0,46	-0,22
18E	250	420	390	3.902	0,18	-0,53	7.484	0,39	-0,40	3.973	0,46	-0,22
19E	430	420	390	4.245	0,47	-0,24	7.484	0,39	-0,40	3.973	0,46	-0,22
20E	320	420	390	4.101	0,09	-0,47	7.484	0,39	-0,40	3.973	0,46	-0,22
21E	70	410	390	4.757	0,04	-0,39	3.911	0,50	-0,16	3.973	0,46	-0,22
22E	250	410	390	3.902	0,18	-0,53	3.911	0,50	-0,16	3.973	0,46	-0,22
23E	430	410	390	4.245	0,47	-0,24	3.911	0,50	-0,16	3.973	0,46	-0,22
24E	320	410	390	4.101	0,09	-0,47	3.911	0,50	-0,16	3.973	0,46	-0,22
25E	70	180	390	4.757	0,04	-0,39	3.406	0,33	-0,17	3.973	0,46	-0,22
26E	250	180	390	3.902	0,18	-0,53	3.406	0,33	-0,17	3.973	0,46	-0,22
27E	430	180	390	4.245	0,47	-0,24	3.406	0,33	-0,17	3.973	0,46	-0,22
28E	320	180	390	4.101	0,09	-0,47	3.406	0,33	-0,17	3.973	0,46	-0,22
29E	70	90	390	4.757	0,04	-0,39	8.922	0,45	-0,33	3.973	0,46	-0,22
30E	250	90	390	3.902	0,18	-0,53	8.922	0,45	-0,33	3.973	0,46	-0,22
31E	430	90	390	4.245	0,47	-0,24	8.922	0,45	-0,33	3.973	0,46	-0,22
32E	320	90	390	4.101	0,09	-0,47	8.922	0,45	-0,33	3.973	0,46	-0,22
33E	70	420	210	4.757	0,04	-0,39	7.484	0,39	-0,40	4.074	0,48	-0,07
34E	250	420	210	3.902	0,18	-0,53	7.484	0,39	-0,40	4.074	0,48	-0,07
35E	430	420	210	4.245	0,47	-0,24	7.484	0,39	-0,40	4.074	0,48	-0,07
36E	320	420	210	4.101	0,09	-0,47	7.484	0,39	-0,40	4.074	0,48	-0,07
37E	70	410	210	4.757	0,04	-0,39	3.911	0,50	-0,16	4.074	0,48	-0,07
38E	250	410	210	3.902	0,18	-0,53	3.911	0,50	-0,16	4.074	0,48	-0,07
39E	430	410	210	4.245	0,47	-0,24	3.911	0,50	-0,16	4.074	0,48	-0,07
40E	320	410	210	4.101	0,09	-0,47	3.911	0,50	-0,16	4.074	0,48	-0,07

Quadro 9.1 - Projeto Fatorial - Constantes do Modelo Composto obtidas no ensaio (Continuação)												
Estrutura	Amostras			SUBLEITO			SUBBASE			BASE		
	Subleito	Sub-base	Base	K1	K2	K3	K1	K2	K3	K1	K2	K3
41E	70	180	210	4.757	0,04	-0,39	3.406	0,33	-0,17	4.074	0,48	-0,07
42E	250	180	210	3.902	0,18	-0,53	3.406	0,33	-0,17	4.074	0,48	-0,07
43E	430	180	210	4.245	0,47	-0,24	3.406	0,33	-0,17	4.074	0,48	-0,07
44E	320	180	210	4.101	0,09	-0,47	3.406	0,33	-0,17	4.074	0,48	-0,07
45E	70	90	210	4.757	0,04	-0,39	8.922	0,45	-0,33	4.074	0,48	-0,07
46E	250	90	210	3.902	0,18	-0,53	8.922	0,45	-0,33	4.074	0,48	-0,07
47E	430	90	210	4.245	0,47	-0,24	8.922	0,45	-0,33	4.074	0,48	-0,07
48E	320	90	210	4.101	0,09	-0,47	8.922	0,45	-0,33	4.074	0,48	-0,07
49E	70	420	50	4.757	0,04	-0,39	7.484	0,39	-0,40	3.482	0,58	-0,14
50E	250	420	50	3.902	0,18	-0,53	7.484	0,39	-0,40	3.482	0,58	-0,14
51E	430	420	50	4.245	0,47	-0,24	7.484	0,39	-0,40	3.482	0,58	-0,14
52E	320	420	50	4.101	0,09	-0,47	7.484	0,39	-0,40	3.482	0,58	-0,14
53E	70	410	50	4.757	0,04	-0,39	3.911	0,50	-0,16	3.482	0,58	-0,14
54E	250	410	50	3.902	0,18	-0,53	3.911	0,50	-0,16	3.482	0,58	-0,14
55E	430	410	50	4.245	0,47	-0,24	3.911	0,50	-0,16	3.482	0,58	-0,14
56E	320	410	50	4.101	0,09	-0,47	3.911	0,50	-0,16	3.482	0,58	-0,14
57E	70	180	50	4.757	0,04	-0,39	3.406	0,33	-0,17	3.482	0,58	-0,14
58E	250	180	50	3.902	0,18	-0,53	3.406	0,33	-0,17	3.482	0,58	-0,14
59E	430	180	50	4.245	0,47	-0,24	3.406	0,33	-0,17	3.482	0,58	-0,14
60E	320	180	50	4.101	0,09	-0,47	3.406	0,33	-0,17	3.482	0,58	-0,14
61E	70	90	50	4.757	0,04	-0,39	8.922	0,45	-0,33	3.482	0,58	-0,14
62E	250	90	50	3.902	0,18	-0,53	8.922	0,45	-0,33	3.482	0,58	-0,14
63E	430	90	50	4.245	0,47	-0,24	8.922	0,45	-0,33	3.482	0,58	-0,14
64E	320	90	50	4.101	0,09	-0,47	8.922	0,45	-0,33	3.482	0,58	-0,14

Quadro 9.2 - Projeto Fatorial - Constantes do Modelo Composto obtidas pela Rede Neural

Estrutura	Nível de Erro / Amostras			SUBLEITO			SUBBASE			BASE		
	Subleito	Sub-base	Base	K1	K2	K3	K1	K2	K3	K1	K2	K3
1	B 70	B 420	B 190	4.710	0,00	-0,37	7.484	0,31	-0,45	3.258	0,27	-0,09
2	M 250	B 420	B 190	2.910	0,23	-0,30	7.484	0,31	-0,45	3.258	0,27	-0,09
3	A 430	B 420	B 190	5.485	0,26	-0,23	7.484	0,31	-0,45	3.258	0,27	-0,09
4	MA 320	B 420	B 190	6.930	0,01	-0,57	7.484	0,31	-0,45	3.258	0,27	-0,09
5	B 70	M 410	B 190	4.710	0,00	-0,37	4.179	0,30	-0,20	3.258	0,27	-0,09
6	M 250	M 410	B 190	2.910	0,23	-0,30	4.179	0,30	-0,20	3.258	0,27	-0,09
7	A 430	M 410	B 190	5.485	0,26	-0,23	4.179	0,30	-0,20	3.258	0,27	-0,09
8	MA 320	M 410	B 190	6.930	0,01	-0,57	4.179	0,30	-0,20	3.258	0,27	-0,09
9	B 70	A 180	B 190	4.710	0,00	-0,37	2.127	0,28	-0,02	3.258	0,27	-0,09
10	M 250	A 180	B 190	2.910	0,23	-0,30	2.127	0,28	-0,02	3.258	0,27	-0,09
11	A 430	A 180	B 190	5.485	0,26	-0,23	2.127	0,28	-0,02	3.258	0,27	-0,09
12	MA 320	A 180	B 190	6.930	0,01	-0,57	2.127	0,28	-0,02	3.258	0,27	-0,09
13	B 70	MA 90	B 190	4.710	0,00	-0,37	3.834	0,26	-0,08	3.258	0,27	-0,09
14	M 250	MA 90	B 190	2.910	0,23	-0,30	3.834	0,26	-0,08	3.258	0,27	-0,09
15	A 430	MA 90	B 190	5.485	0,26	-0,23	3.834	0,26	-0,08	3.258	0,27	-0,09
16	MA 320	MA 90	B 190	6.930	0,01	-0,57	3.834	0,26	-0,08	3.258	0,27	-0,09
17	B 70	B 420	M 390	4.710	0,00	-0,37	7.484	0,31	-0,45	4.381	0,26	0,01
18	M 250	B 420	M 390	2.910	0,23	-0,30	7.484	0,31	-0,45	4.381	0,26	0,01
19	A 430	B 420	M 390	5.485	0,26	-0,23	7.484	0,31	-0,45	4.381	0,26	0,01
20	MA 320	B 420	M 390	6.930	0,01	-0,57	7.484	0,31	-0,45	4.381	0,26	0,01
21	B 70	M 410	M 390	4.710	0,00	-0,37	4.179	0,30	-0,20	4.381	0,26	0,01
22	M 250	M 410	M 390	2.910	0,23	-0,30	4.179	0,30	-0,20	4.381	0,26	0,01
23	A 430	M 410	M 390	5.485	0,26	-0,23	4.179	0,30	-0,20	4.381	0,26	0,01
24	MA 320	M 410	M 390	6.930	0,01	-0,57	4.179	0,30	-0,20	4.381	0,26	0,01
25	B 70	A 180	M 390	4.710	0,00	-0,37	2.127	0,28	-0,02	4.381	0,26	0,01
26	M 250	A 180	M 390	2.910	0,23	-0,30	2.127	0,28	-0,02	4.381	0,26	0,01
27	A 430	A 180	M 390	5.485	0,26	-0,23	2.127	0,28	-0,02	4.381	0,26	0,01
28	MA 320	A 180	M 390	6.930	0,01	-0,57	2.127	0,28	-0,02	4.381	0,26	0,01
29	B 70	MA 90	M 390	4.710	0,00	-0,37	3.834	0,26	-0,08	4.381	0,26	0,01
30	M 250	MA 90	M 390	2.910	0,23	-0,30	3.834	0,26	-0,08	4.381	0,26	0,01
31	A 430	MA 90	M 390	5.485	0,26	-0,23	3.834	0,26	-0,08	4.381	0,26	0,01
32	MA 320	MA 90	M 390	6.930	0,01	-0,57	3.834	0,26	-0,08	4.381	0,26	0,01
33	B 70	B 420	A 210	4.710	0,00	-0,37	7.484	0,31	-0,45	2.592	0,26	-0,05
34	M 250	B 420	A 210	2.910	0,23	-0,30	7.484	0,31	-0,45	2.592	0,26	-0,05
35	A 430	B 420	A 210	5.485	0,26	-0,23	7.484	0,31	-0,45	2.592	0,26	-0,05
36	MA 320	B 420	A 210	6.930	0,01	-0,57	7.484	0,31	-0,45	2.592	0,26	-0,05
37	B 70	M 410	A 210	4.710	0,00	-0,37	4.179	0,30	-0,20	2.592	0,26	-0,05
38	M 250	M 410	A 210	2.910	0,23	-0,30	4.179	0,30	-0,20	2.592	0,26	-0,05
39	A 430	M 410	A 210	5.485	0,26	-0,23	4.179	0,30	-0,20	2.592	0,26	-0,05
40	MA 320	M 410	A 210	6.930	0,01	-0,57	4.179	0,30	-0,20	2.592	0,26	-0,05

Quadro 9.2 - Projeto Fatorial - Constantes do Modelo Composto obtidas pela Rede Neural (Continuação)												
Estrutura	Nível de Erro / Amostras			SUBLEITO			SUBBASE			BASE		
	Subleito	Sub-base	Base	K1	K2	K3	K1	K2	K3	K1	K2	K3
41	B 70	A 180	A 210	4.710	0,00	-0,37	2.127	0,28	-0,02	2.592	0,26	-0,05
42	M 250	A 180	A 210	2.910	0,23	-0,30	2.127	0,28	-0,02	2.592	0,26	-0,05
43	A 430	A 180	A 210	5.485	0,26	-0,23	2.127	0,28	-0,02	2.592	0,26	-0,05
44	MA 320	A 180	A 210	6.930	0,01	-0,57	2.127	0,28	-0,02	2.592	0,26	-0,05
45	B 70	MA 90	A 210	4.710	0,00	-0,37	3.834	0,26	-0,08	2.592	0,26	-0,05
46	M 250	MA 90	A 210	2.910	0,23	-0,30	3.834	0,26	-0,08	2.592	0,26	-0,05
47	A 430	MA 90	A 210	5.485	0,26	-0,23	3.834	0,26	-0,08	2.592	0,26	-0,05
48	MA 320	MA 90	A 210	6.930	0,01	-0,57	3.834	0,26	-0,08	2.592	0,26	-0,05
49	B 70	B 420	MA 50	4.710	0,00	-0,37	7.484	0,31	-0,45	3.823	0,27	-0,07
50	M 250	B 420	MA 50	2.910	0,23	-0,30	7.484	0,31	-0,45	3.823	0,27	-0,07
51	A 430	B 420	MA 50	5.485	0,26	-0,23	7.484	0,31	-0,45	3.823	0,27	-0,07
52	MA 320	B 420	MA 50	6.930	0,01	-0,57	7.484	0,31	-0,45	3.823	0,27	-0,07
53	B 70	M 410	MA 50	4.710	0,00	-0,37	4.179	0,30	-0,20	3.823	0,27	-0,07
54	M 250	M 410	MA 50	2.910	0,23	-0,30	4.179	0,30	-0,20	3.823	0,27	-0,07
55	A 430	M 410	MA 50	5.485	0,26	-0,23	4.179	0,30	-0,20	3.823	0,27	-0,07
56	MA 320	M 410	MA 50	6.930	0,01	-0,57	4.179	0,30	-0,20	3.823	0,27	-0,07
57	B 70	A 180	MA 50	4.710	0,00	-0,37	2.127	0,28	-0,02	3.823	0,27	-0,07
58	M 250	A 180	MA 50	2.910	0,23	-0,30	2.127	0,28	-0,02	3.823	0,27	-0,07
59	A 430	A 180	MA 50	5.485	0,26	-0,23	2.127	0,28	-0,02	3.823	0,27	-0,07
60	MA 320	A 180	MA 50	6.930	0,01	-0,57	2.127	0,28	-0,02	3.823	0,27	-0,07
61	B 70	MA 90	MA 50	4.710	0,00	-0,37	3.834	0,26	-0,08	3.823	0,27	-0,07
62	M 250	MA 90	MA 50	2.910	0,23	-0,30	3.834	0,26	-0,08	3.823	0,27	-0,07
63	A 430	MA 90	MA 50	5.485	0,26	-0,23	3.834	0,26	-0,08	3.823	0,27	-0,07
64	MA 320	MA 90	MA 50	6.930	0,01	-0,57	3.834	0,26	-0,08	3.823	0,27	-0,07

NÍVEIS DE ERRO		
B	BAIXO	ATÉ 15%
M	MÉDIO	16 A 30%
A	ALTO	31 A 50%
MA	MUITO ALTO	>50%

NÚMERO DE AMOSTRAS POR FAIXA DE ERRO			
ERRO	SUBLEITO	SUB-BASE	BASE
B	6	4	1
M	9	5	3
A	5	3	3
MA	4	2	1

Quadro 9.4 - Erros na Diferença de Tensões e no Número N - Restimento Espessura = 4,0cm											
Rede Neural			Ensaio			Erro $\Delta\sigma$		Número N			
Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	kgf/cm ²	%	Rede	Ensaio	Erro	Erro %
1	18	20,81	1E	19	19,99	0,82	4	1,03E+07	1,12E+07	9,20E+05	9
2	30	21,81	2E	23	20,34	1,47	7	9,31E+06	1,08E+07	1,49E+06	16
3	27	21,55	3E	46	22,62	-1,07	5	9,55E+06	8,61E+06	-9,36E+05	10
4	16	20,65	4E	20	20,10	0,55	3	1,05E+07	1,11E+07	6,19E+05	6
5	22	22,17	5E	30	23,72	-1,55	7	8,99E+06	7,78E+06	-1,20E+06	13
6	37	23,70	6E	34	24,19	-0,49	2	7,80E+06	7,46E+06	-3,33E+05	4
7	32	23,08	7E	64	28,01	-4,93	18	8,25E+06	5,46E+06	-2,79E+06	34
8	20	21,98	8E	31	23,88	-1,90	8	9,15E+06	7,67E+06	-1,48E+06	16
9	31	24,59	9E	25	21,89	2,70	12	7,21E+06	9,23E+06	2,03E+06	28
10	46	26,37	10E	29	22,35	4,02	18	6,21E+06	8,83E+06	2,62E+06	42
11	40	25,72	11E	57	26,00	-0,28	1	6,55E+06	6,40E+06	-1,49E+05	2
12	29	24,33	12E	26	22,06	2,27	10	7,37E+06	9,08E+06	1,71E+06	23
13	23	22,39	13E	20	20,29	2,10	10	8,80E+06	1,09E+07	2,05E+06	23
14	38	23,87	14E	23	20,64	3,23	16	7,68E+06	1,05E+07	2,79E+06	36
15	33	23,29	15E	49	23,32	-0,03	0	8,09E+06	8,07E+06	-2,22E+04	0
16	21	22,21	16E	21	20,40	1,81	9	8,95E+06	1,07E+07	1,78E+06	20
17	16	18,86	17E	22	22,77	-3,91	17	1,27E+07	8,49E+06	-4,19E+06	33
18	29	19,81	18E	26	23,17	-3,36	15	1,14E+07	8,18E+06	-3,24E+06	28
19	25	19,52	19E	51	25,83	-6,31	24	1,18E+07	6,49E+06	-5,30E+06	45
20	14	18,72	20E	23	22,92	-4,20	18	1,29E+07	8,37E+06	-4,51E+06	35
21	21	20,17	21E	34	26,74	-6,57	25	1,10E+07	6,03E+06	-4,96E+06	45
22	36	21,63	22E	38	27,29	-5,66	21	9,47E+06	5,77E+06	-3,70E+06	39
23	30	21,01	23E	70	32,26	-11,25	35	1,01E+07	4,04E+06	-6,04E+06	60
24	19	20,01	24E	35	26,93	-6,92	26	1,12E+07	5,94E+06	-5,24E+06	47
25	29	22,51	25E	28	24,74	-2,23	9	8,70E+06	7,12E+06	-1,59E+06	18
26	38	23,53	26E	32	25,17	-1,64	7	7,92E+06	6,86E+06	-1,06E+06	13
27	27	22,32	27E	62	29,09	-6,77	23	8,86E+06	5,04E+06	-3,82E+06	43
28	22	20,39	28E	29	24,87	-4,48	18	1,07E+07	7,04E+06	-3,71E+06	34
29	44	24,16	29E	23	23,07	1,09	5	7,48E+06	8,26E+06	7,73E+05	10
30	36	21,86	30E	27	23,50	-1,64	7	9,26E+06	7,94E+06	-1,32E+06	14
31	31	21,25	31E	54	26,46	-5,21	20	9,84E+06	6,17E+06	-3,67E+06	37
32	20	20,22	32E	24	23,21	-2,99	13	1,09E+07	8,15E+06	-2,78E+06	25
33	20	23,05	33E	24	24,57	-1,52	6	8,27E+06	7,22E+06	-1,05E+06	13
34	33	24,29	34E	28	25,00	-0,71	3	7,40E+06	6,96E+06	-4,40E+05	6

Quadro 9.4 - Erros na Diferença de Tensões e no Número N - Restimento Espessura = 4,0cm (Continuação)											
Rede Neural			Ensaio			Erro $\Delta\sigma$		Número N			
Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	kgf/cm ²	%	Rede	Ensaio	Erro	Erro %
35	29	23,88	35E	54	27,66	-3,78	14	7,67E+06	5,61E+06	-2,06E+06	27
36	18	22,88	36E	26	24,73	-1,85	7	8,40E+06	7,12E+06	-1,28E+06	15
37	25	24,41	37E	36	28,30	-3,89	14	7,32E+06	5,34E+06	-1,98E+06	27
38	40	25,93	38E	40	28,79	-2,86	10	6,44E+06	5,15E+06	-1,29E+06	20
39	34	25,35	39E	72	33,19	-7,84	24	6,76E+06	3,81E+06	-2,95E+06	44
40	23	24,21	40E	37	28,45	-4,24	15	7,45E+06	5,28E+06	-2,17E+06	29
41	33	26,68	41E	30	26,46	0,22	1	6,06E+06	6,17E+06	1,08E+05	2
42	48	28,45	42E	34	26,86	1,59	6	5,28E+06	5,97E+06	6,89E+05	13
43	43	27,80	43E	64	30,56	-2,76	9	5,55E+06	4,54E+06	-1,01E+06	18
44	31	26,45	44E	32	26,60	-0,15	1	6,17E+06	6,10E+06	-7,39E+04	1
45	26	24,64	45E	25	24,87	-0,23	1	7,18E+06	7,04E+06	-1,41E+05	2
46	40	26,14	46E	29	25,29	0,85	3	6,33E+06	6,79E+06	4,62E+05	7
47	35	25,58	47E	56	28,29	-2,71	10	6,63E+06	5,35E+06	-1,28E+06	19
48	24	24,42	48E	26	25,00	-0,58	2	7,32E+06	6,96E+06	-3,57E+05	5
49	17	19,58	49E	29	27,91	-8,33	30	1,17E+07	5,50E+06	-6,21E+06	53
50	30	20,59	50E	33	28,33	-7,74	27	1,05E+07	5,33E+06	-5,19E+06	49
51	25	20,28	51E	60	31,33	-11,05	35	1,09E+07	4,30E+06	-6,56E+06	60
52	15	19,43	52E	30	28,05	-8,62	31	1,19E+07	5,45E+06	-6,46E+06	54
53	21	20,91	53E	41	31,55	-10,64	34	1,02E+07	4,24E+06	-5,94E+06	58
54	36	22,42	54E	44	32,02	-9,60	30	8,78E+06	4,11E+06	-4,67E+06	53
55	31	21,79	55E	76	36,16	-14,37	40	9,33E+06	3,17E+06	-6,15E+06	66
56	19	20,74	56E	42	31,71	-10,97	35	1,04E+07	4,19E+06	-6,17E+06	60
57	30	23,36	57E	35	29,74	-6,38	21	8,04E+06	4,81E+06	-3,23E+06	40
58	45	25,01	58E	39	30,18	-5,17	17	6,95E+06	4,66E+06	-2,29E+06	33
59	39	24,43	59E	69	33,89	-9,46	28	7,31E+06	3,64E+06	-3,67E+06	50
60	27	23,12	60E	36	29,89	-6,77	23	8,22E+06	4,76E+06	-3,46E+06	42
61	22	21,15	61E	30	28,18	-7,03	25	9,94E+06	5,39E+06	-4,54E+06	46
62	37	22,62	62E	33	28,62	-6,00	21	8,61E+06	5,22E+06	-3,39E+06	39
63	32	22,03	63E	62	31,87	-9,84	31	9,11E+06	4,15E+06	-4,96E+06	54
64	20	20,97	64E	31	28,33	-7,36	26	1,01E+07	5,33E+06	-4,79E+06	47
							Médias	15			29

Quadro 9.5 - Erros na Diferença de Tensões e no Número N - Restimento Espessura = 6,0cm											
Rede Neural			Ensaio			Erro $\Delta\sigma$		Número N			
Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	kgf/cm ²	%	Rede	Ensaio	Erro	Erro %
1	16	15,70	1E	17	15,26	0,44	3	1,87E+07	1,99E+07	1,17E+06	6
2	27	16,92	2E	20	15,68	1,24	8	1,60E+07	1,88E+07	2,81E+06	18
3	24	16,64	3E	41	18,20	-1,56	9	1,66E+07	1,37E+07	-2,88E+06	17
4	14	15,49	4E	18	15,39	0,10	1	1,93E+07	1,96E+07	2,68E+05	1
5	20	16,73	5E	25	17,85	-1,12	6	1,64E+07	1,43E+07	-2,11E+06	13
6	33	18,37	6E	29	18,36	0,01	0	1,34E+07	1,34E+07	1,56E+04	0
7	28	17,75	7E	54	22,08	-4,33	20	1,44E+07	9,07E+06	-5,37E+06	37
8	18	16,51	8E	27	18,01	-1,50	8	1,68E+07	1,40E+07	-2,85E+06	17
9	26	18,44	9E	22	16,65	1,79	11	1,33E+07	1,65E+07	3,23E+06	24
10	39	20,27	10E	25	17,10	3,17	19	1,09E+07	1,56E+07	4,75E+06	44
11	35	19,60	11E	49	20,70	-1,10	5	1,17E+07	1,04E+07	-1,28E+06	11
12	24	18,18	12E	23	16,80	1,38	8	1,37E+07	1,62E+07	2,51E+06	18
13	21	16,92	13E	17	15,45	1,47	10	1,60E+07	1,94E+07	3,41E+06	21
14	34	18,52	14E	21	15,88	2,64	17	1,32E+07	1,83E+07	5,11E+06	39
15	29	17,93	15E	43	18,73	-0,80	4	1,41E+07	1,29E+07	-1,25E+06	9
16	19	16,70	16E	19	15,60	1,10	7	1,64E+07	1,90E+07	2,57E+06	16
17	15	14,73	17E	19	16,68	-1,95	12	2,15E+07	1,65E+07	-5,00E+06	23
18	27	15,98	18E	23	17,11	-1,13	7	1,81E+07	1,56E+07	-2,45E+06	14
19	23	15,60	19E	45	19,92	-4,32	22	1,90E+07	1,13E+07	-7,71E+06	41
20	13	14,52	20E	20	16,83	-2,31	14	2,21E+07	1,62E+07	-5,97E+06	27
21	19	15,75	21E	28	19,30	-3,55	18	1,86E+07	1,21E+07	-6,54E+06	35
22	32	17,35	22E	32	19,81	-2,46	12	1,52E+07	1,14E+07	-3,73E+06	25
23	27	16,75	23E	59	24,04	-7,29	30	1,63E+07	7,56E+06	-8,77E+06	54
24	17	15,54	24E	29	19,47	-3,93	20	1,92E+07	1,19E+07	-7,31E+06	38
25	25	17,49	25E	24	18,09	-0,60	3	1,49E+07	1,39E+07	-1,03E+06	7
26	38	19,25	26E	28	18,54	0,71	4	1,21E+07	1,32E+07	1,01E+06	8
27	33	18,61	27E	53	22,17	-3,56	16	1,30E+07	8,99E+06	-4,06E+06	31
28	23	17,25	28E	25	18,24	-0,99	5	1,53E+07	1,36E+07	-1,72E+06	11
29	19	15,94	29E	20	16,88	-0,94	6	1,81E+07	1,61E+07	-2,09E+06	11
30	32	17,54	30E	23	17,35	0,19	1	1,48E+07	1,52E+07	3,47E+05	2
31	28	16,91	31E	47	20,39	-3,48	17	1,60E+07	1,07E+07	-5,26E+06	33
32	18	15,72	32E	21	17,02	-1,30	8	1,87E+07	1,58E+07	-2,91E+06	16
33	18	16,94	33E	21	17,71	-0,77	4	1,59E+07	1,45E+07	-1,44E+06	9
34	30	18,38	34E	25	18,17	0,21	1	1,34E+07	1,37E+07	3,32E+05	2

Quadro 9.5 - Erros na Diferença de Tensões e no Número N - Restimento Espessura = 6,0cm (Continuação)

Rede Neural			Ensaio			Erro $\Delta\sigma$		Número N			
Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	kgf/cm ²	%	Rede	Ensaio	Erro	Erro %
35	26	17,93	35E	47	21,02	-3,09	15	1,41E+07	1,01E+07	-4,06E+06	29
36	16	16,71	36E	33	17,86	-1,15	6	1,64E+07	1,42E+07	-2,17E+06	13
37	22	17,94	37E	30	20,21	-2,27	11	1,41E+07	1,09E+07	-3,16E+06	22
38	35	19,60	38E	34	20,68	-1,08	5	1,17E+07	1,04E+07	-1,26E+06	11
39	30	19,00	39E	60	24,57	-5,57	23	1,25E+07	7,22E+06	-5,26E+06	42
40	20	17,72	40E	31	20,36	-2,64	13	1,45E+07	1,08E+07	-3,71E+06	26
41	28	19,54	41E	26	19,07	0,47	2	1,18E+07	1,24E+07	6,26E+05	5
42	41	21,29	42E	29	19,51	1,78	9	9,80E+06	1,18E+07	2,00E+06	20
43	36	20,64	43E	55	23,00	-2,36	10	1,05E+07	8,31E+06	-2,16E+06	21
44	26	19,29	44E	27	19,21	0,08	0	1,21E+07	1,22E+07	1,07E+05	1
45	22	18,12	45E	22	17,90	0,22	1	1,38E+07	1,42E+07	3,64E+05	3
46	35	19,75	46E	25	18,36	1,39	8	1,15E+07	1,34E+07	1,93E+06	17
47	31	19,15	47E	49	21,44	-2,29	11	1,23E+07	9,65E+06	-2,63E+06	21
48	20	17,90	48E	23	18,05	-0,15	1	1,42E+07	1,39E+07	-2,50E+05	2
49	15	15,06	49E	25	19,30	-4,24	22	2,05E+07	1,21E+07	-8,41E+06	41
50	27	16,33	50E	28	19,75	-3,42	17	1,72E+07	1,15E+07	-5,74E+06	33
51	23	15,95	51E	51	22,79	-6,84	30	1,81E+07	8,48E+06	-9,65E+06	53
52	13	14,84	52E	26	19,45	-4,61	24	2,11E+07	1,19E+07	-9,26E+06	44
53	19	16,09	53E	33	21,70	-5,61	26	1,78E+07	9,41E+06	-8,38E+06	47
54	32	17,73	54E	37	22,17	-4,44	20	1,45E+07	8,99E+06	-5,48E+06	38
55	27	17,09	55E	63	25,87	-8,78	34	1,56E+07	6,47E+06	-9,18E+06	59
56	17	15,87	56E	35	21,86	-5,99	27	1,83E+07	9,26E+06	-9,06E+06	49
57	25	17,84	57E	29	20,59	-2,75	13	1,43E+07	1,05E+07	-3,76E+06	26
58	38	19,62	58E	33	21,04	-1,42	7	1,17E+07	1,00E+07	-1,61E+06	14
59	34	19,00	59E	58	24,54	-5,54	23	1,25E+07	7,24E+06	-5,25E+06	42
60	23	17,58	60E	30	20,75	-3,17	15	1,47E+07	1,03E+07	-4,38E+06	30
61	20	16,26	61E	25	19,48	-3,22	17	1,74E+07	1,18E+07	-5,56E+06	32
62	33	17,90	62E	29	19,94	-2,04	10	1,42E+07	1,13E+07	-2,91E+06	21
63	28	17,29	63E	53	23,17	-5,88	25	1,53E+07	8,18E+06	-7,08E+06	46
64	18	16,05	64E	26	19,64	-3,59	18	1,79E+07	1,16E+07	-6,25E+06	35
							Médias	12			24

Quadro 9.6 - Erros na Diferença de Tensões e no Número N - Restimento Espessura = 8,0cm

Rede Neural			Ensaio			Erro $\Delta\sigma$		Número N			
Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	kgf/cm ²	%	Rede	Ensaio	Erro	Erro %
1	14	10,40	1E	15	10,13	0,27	3	4,51E+07	4,77E+07	2,60E+06	6
2	24	10,67	2E	18	10,24	0,43	4	4,27E+07	4,66E+07	3,91E+06	9
3	21	10,62	3E	36	10,80	-0,18	2	4,31E+07	4,16E+07	-1,52E+06	4
4	12	10,35	4E	16	10,17	0,18	2	4,55E+07	4,73E+07	1,73E+06	4
5	17	10,84	5E	21	11,17	-0,33	3	4,13E+07	3,87E+07	-2,55E+06	6
6	28	11,21	6E	25	11,30	-0,09	1	3,84E+07	3,78E+07	-6,49E+05	2
7	24	11,06	7E	46	12,20	-1,14	9	3,95E+07	3,21E+07	-7,45E+06	19
8	15	10,78	8E	23	11,21	-0,43	4	4,18E+07	3,84E+07	-3,34E+06	8
9	22	11,48	9E	18	10,71	0,77	7	3,65E+07	4,23E+07	5,82E+06	16
10	33	11,91	10E	21	10,82	1,09	10	3,38E+07	4,14E+07	7,66E+06	23
11	29	11,75	11E	42	11,71	0,04	0	3,48E+07	3,50E+07	2,53E+05	1
12	20	11,41	12E	19	10,74	0,67	6	3,70E+07	4,21E+07	5,09E+06	14
13	18	10,91	13E	15	10,23	0,68	7	4,07E+07	4,67E+07	5,98E+06	15
14	29	11,27	14E	18	10,32	0,95	9	3,80E+07	4,58E+07	7,84E+06	21
15	25	11,14	15E	37	11,00	0,14	1	3,89E+07	4,00E+07	1,06E+06	3
16	16	10,87	16E	16	10,26	0,61	6	4,10E+07	4,64E+07	5,37E+06	13
17	13	10,00	17E	17	10,81	-0,81	7	4,90E+07	4,15E+07	-7,49E+06	15
18	24	10,27	18E	20	10,93	-0,66	6	4,63E+07	4,05E+07	-5,75E+06	12
19	20	10,19	19E	39	11,56	-1,37	12	4,71E+07	3,60E+07	-1,11E+07	24
20	12	9,95	20E	18	10,85	-0,90	8	4,95E+07	4,12E+07	-8,34E+06	17
21	16	10,44	21E	24	11,82	-1,38	12	4,47E+07	3,43E+07	-1,04E+07	23
22	28	10,81	22E	27	11,95	-1,14	10	4,15E+07	3,35E+07	-7,98E+06	19
23	24	10,66	23E	48	12,99	-2,33	18	4,28E+07	2,81E+07	-1,47E+07	34
24	15	10,39	24E	25	11,86	-1,47	12	4,52E+07	3,41E+07	-1,11E+07	25
25	21	11,10	25E	20	11,37	-0,27	2	3,92E+07	3,73E+07	-1,96E+06	5
26	32	11,56	26E	23	11,49	0,07	1	3,60E+07	3,64E+07	4,68E+05	1
27	28	11,40	27E	44	12,35	-0,95	8	3,71E+07	3,13E+07	-5,81E+06	16
28	19	11,05	28E	21	11,40	-0,35	3	3,96E+07	3,71E+07	-2,55E+06	6
29	17	10,51	29E	17	10,90	-0,39	4	4,41E+07	4,08E+07	-3,29E+06	7
30	28	10,88	30E	20	11,01	-0,13	1	4,09E+07	3,99E+07	-1,02E+06	2
31	24	10,74	31E	40	11,74	-1,00	9	4,21E+07	3,48E+07	-7,27E+06	17
32	15	10,47	32E	18	10,93	-0,46	4	4,44E+07	4,05E+07	-3,89E+06	9
33	15	10,95	33E	18	11,31	-0,36	3	4,04E+07	3,77E+07	-2,69E+06	7
34	26	11,27	34E	21	11,42	-0,15	1	3,80E+07	3,69E+07	-1,05E+06	3

Quadro 9.6 - Erros na Diferença de Tensões e no Número N - Restimento Espessura = 8,0cm (Continuação)											
Rede Neural			Ensaio			Erro $\Delta\sigma$		Número N			
Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	kgf/cm ²	%	Rede	Ensaio	Erro	Erro %
35	23	11,18	35E	41	12,07	-0,89	7	3,86E+07	3,28E+07	-5,82E+06	15
36	14	10,90	36E	19	11,35	-0,45	4	4,08E+07	3,74E+07	-3,37E+06	8
37	18	11,36	37E	25	12,25	-0,89	7	3,73E+07	3,18E+07	-5,54E+06	15
38	30	11,73	38E	28	12,37	-0,64	5	3,49E+07	3,11E+07	-3,73E+06	11
39	26	11,59	39E	50	13,26	-1,67	13	3,58E+07	2,69E+07	-8,92E+06	25
40	17	11,31	40E	26	12,29	-0,98	8	3,77E+07	3,16E+07	-6,11E+06	16
41	23	11,95	41E	22	11,83	0,12	1	3,35E+07	3,43E+07	7,28E+05	2
42	34	12,33	42E	25	11,94	0,39	3	3,14E+07	3,36E+07	2,22E+06	7
43	30	12,19	43E	46	12,74	-0,55	4	3,21E+07	2,93E+07	-2,88E+06	9
44	21	11,89	44E	23	11,87	0,02	0	3,39E+07	3,40E+07	1,22E+05	0
45	19	11,43	45E	19	11,39	0,04	0	3,69E+07	3,71E+07	2,76E+05	1
46	30	11,79	46E	22	11,50	0,29	3	3,45E+07	3,64E+07	1,88E+06	5
47	26	11,66	47E	42	12,24	-0,58	5	3,53E+07	3,19E+07	-3,47E+06	10
48	17	11,38	48E	20	11,43	-0,05	0	3,72E+07	3,69E+07	-3,46E+05	1
49	13	10,11	49E	21	11,94	-1,83	15	4,79E+07	3,36E+07	-1,43E+07	30
50	24	10,38	50E	24	12,06	-1,68	14	4,53E+07	3,29E+07	-1,24E+07	27
51	21	10,31	51E	44	12,76	-2,45	19	4,59E+07	2,92E+07	-1,68E+07	36
52	12	10,07	52E	22	11,98	-1,91	16	4,83E+07	3,33E+07	-1,49E+07	31
53	16	10,55	53E	29	12,81	-2,26	18	4,37E+07	2,89E+07	-1,48E+07	34
54	28	10,92	54E	30	12,94	-2,02	16	4,06E+07	2,83E+07	-1,23E+07	30
55	24	10,78	55E	52	13,76	-2,98	22	4,18E+07	2,48E+07	-1,69E+07	41
56	15	10,51	56E	29	12,85	-2,34	18	4,41E+07	2,87E+07	-1,53E+07	35
57	21	11,23	57E	24	12,42	-1,19	10	3,83E+07	3,09E+07	-7,39E+06	19
58	33	11,66	58E	27	12,53	-0,87	7	3,53E+07	3,03E+07	-5,02E+06	14
59	29	11,51	59E	48	13,33	-1,82	14	3,63E+07	2,66E+07	-9,75E+06	27
60	20	11,16	60E	25	12,46	-1,30	10	3,88E+07	3,07E+07	-8,11E+06	21
61	17	10,63	61E	21	12,02	-1,39	12	4,30E+07	3,31E+07	-9,91E+06	23
62	28	11,00	62E	24	12,13	-1,13	9	4,00E+07	3,25E+07	-7,52E+06	19
63	24	10,86	63E	45	12,88	-2,02	16	4,11E+07	2,86E+07	-1,25E+07	30
64	15	10,58	64E	22	12,05	-1,47	12	4,35E+07	3,29E+07	-1,05E+07	24
							Médias	8			15

Quadro 9.7 - Erros na Diferença de Tensões e no Número N - Restimento Espessura = 10,0cm

Rede Neural			Ensaio			Erro $\Delta\sigma$		Número N			
Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	kgf/cm ²	%	Rede	Ensaio	Erro	Erro %
1	12	8,48	1E	13	8,33	0,15	2	6,96E+07	7,23E+07	2,70E+06	4
2	21	8,89	2E	16	8,47	0,42	5	6,30E+07	6,98E+07	6,84E+06	11
3	19	8,80	3E	31	9,23	-0,43	5	6,43E+07	5,81E+07	-6,22E+06	10
4	11	8,40	4E	14	8,38	0,02	0	7,10E+07	7,14E+07	3,62E+05	1
5	15	8,84	5E	18	9,13	-0,29	3	6,37E+07	5,95E+07	-4,23E+06	7
6	25	9,34	6E	21	9,29	0,05	1	5,67E+07	5,73E+07	6,52E+05	1
7	21	9,16	7E	39	10,27	-1,11	11	5,91E+07	4,63E+07	-1,28E+07	22
8	13	8,76	8E	19	9,18	-0,42	5	6,50E+07	5,88E+07	-6,17E+06	9
9	19	9,34	9E	16	8,78	0,56	6	5,67E+07	6,46E+07	7,98E+06	14
10	28	9,86	10E	19	8,92	0,94	11	5,05E+07	6,25E+07	1,20E+07	24
11	25	9,67	11E	36	9,90	-0,23	2	5,26E+07	5,01E+07	-2,57E+06	5
12	17	9,26	12E	17	8,83	0,43	5	5,77E+07	6,39E+07	6,15E+06	11
13	15	8,89	13E	13	8,40	0,49	6	6,30E+07	7,10E+07	8,08E+06	13
14	25	9,39	14E	16	8,55	0,84	10	5,60E+07	6,84E+07	1,24E+07	22
15	22	9,21	15E	32	9,37	-0,16	2	5,84E+07	5,63E+07	-2,10E+06	4
16	14	8,82	16E	14	8,45	0,37	4	6,40E+07	7,01E+07	6,12E+06	10
17	12	8,23	17E	15	8,82	-0,59	7	7,42E+07	6,40E+07	-1,02E+07	14
18	21	8,64	18E	17	8,97	-0,33	4	6,69E+07	6,18E+07	-5,13E+06	8
19	18	8,54	19E	34	9,81	-1,27	13	6,86E+07	5,10E+07	-1,75E+07	26
20	10	8,16	20E	16	8,87	-0,71	8	7,56E+07	6,33E+07	-1,23E+07	16
21	14	8,59	21E	20	9,60	-1,01	11	6,77E+07	5,34E+07	-1,43E+07	21
22	24	9,09	22E	23	9,75	-0,66	7	6,00E+07	5,17E+07	-8,33E+06	14
23	21	8,91	23E	41	10,84	-1,93	18	6,26E+07	4,13E+07	-2,14E+07	34
24	13	8,51	24E	21	9,65	-1,14	12	6,91E+07	5,29E+07	-1,62E+07	23
25	18	9,11	25E	18	9,26	-0,15	2	5,98E+07	5,77E+07	-2,04E+06	3
26	28	9,64	26E	20	9,40	0,24	3	5,30E+07	5,59E+07	2,92E+06	6
27	24	9,46	27E	38	10,38	-0,92	9	5,51E+07	4,53E+07	-9,89E+06	18
28	16	9,03	28E	18	9,31	-0,28	3	6,09E+07	5,71E+07	-3,83E+06	6
29	15	8,65	29E	15	8,88	-0,23	3	6,67E+07	6,31E+07	-3,63E+06	5
30	25	9,14	30E	18	9,04	0,10	1	5,93E+07	6,07E+07	1,41E+06	2
31	21	8,98	31E	35	9,94	-0,96	10	6,16E+07	4,96E+07	-1,20E+07	19
32	13	8,58	32E	16	8,94	-0,36	4	6,79E+07	6,22E+07	-5,69E+06	8
33	13	8,85	33E	16	9,17	-0,32	3	6,36E+07	5,89E+07	-4,63E+06	7
34	23	9,30	34E	19	9,32	-0,02	0	5,72E+07	5,69E+07	-2,61E+05	0

Quadro 9.7 - Erros na Diferença de Tensões e no Número N - Restimento Espessura = 10,0cm (Continuação)											
Rede Neural			Ensaio			Erro $\Delta\sigma$		Número N			
Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	Estrutura	Deflexão	$\Delta\sigma$ (kgf/cm ²)	kgf/cm ²	%	Rede	Ensaio	Erro	Erro %
35	20	9,16	35E	35	10,18	-1,02	10	5,91E+07	4,72E+07	-1,19E+07	20
36	12	8,77	36E	17	9,22	-0,45	5	6,48E+07	5,82E+07	-6,55E+06	10
37	16	9,18	37E	21	9,90	-0,72	7	5,88E+07	5,01E+07	-8,73E+06	15
38	26	9,68	38E	24	10,05	-0,37	4	5,25E+07	4,85E+07	-4,03E+06	8
39	22	9,50	39E	42	11,05	-1,55	14	5,47E+07	3,96E+07	-1,50E+07	28
40	14	9,10	40E	22	9,95	-0,85	9	5,99E+07	4,95E+07	-1,04E+07	17
41	20	9,64	41E	19	9,58	0,06	1	5,30E+07	5,37E+07	7,09E+05	1
42	29	10,14	42E	21	9,72	0,42	4	4,76E+07	5,21E+07	4,48E+06	9
43	26	9,97	43E	39	10,67	-0,70	7	4,93E+07	4,27E+07	-6,64E+06	13
44	18	9,57	44E	20	9,63	-0,06	1	5,38E+07	5,31E+07	-7,12E+05	1
45	16	9,23	45E	16	9,23	0,00	0	5,81E+07	5,81E+07	0,00E+00	0
46	26	9,72	46E	19	9,38	0,34	4	5,21E+07	5,62E+07	4,10E+06	8
47	23	9,55	47E	36	10,29	-0,74	7	5,40E+07	4,61E+07	-7,94E+06	15
48	15	9,16	48E	17	9,29	-0,13	1	5,91E+07	5,73E+07	-1,75E+06	3
49	12	8,29	49E	18	9,61	-1,32	14	7,31E+07	5,33E+07	-1,97E+07	27
50	21	8,73	50E	21	9,76	-1,03	11	6,54E+07	5,16E+07	-1,38E+07	21
51	18	8,60	51E	38	10,65	-2,05	19	6,76E+07	4,28E+07	-2,47E+07	37
52	10	8,22	52E	19	9,66	-1,44	15	7,44E+07	5,27E+07	-2,16E+07	29
53	14	8,66	53E	23	10,28	-1,62	16	6,66E+07	4,62E+07	-2,04E+07	31
54	24	9,16	54E	26	10,43	-1,27	12	5,91E+07	4,48E+07	-1,43E+07	24
55	21	8,98	55E	44	11,38	-2,40	21	6,16E+07	3,72E+07	-2,44E+07	40
56	13	8,58	56E	24	10,34	-1,76	17	6,79E+07	4,56E+07	-2,23E+07	33
57	18	9,18	57E	21	9,98	-0,80	8	5,88E+07	4,92E+07	-9,58E+06	16
58	28	9,70	58E	23	10,12	-0,42	4	5,23E+07	4,78E+07	-4,51E+06	9
59	25	9,52	59E	41	11,07	-1,55	14	5,44E+07	3,95E+07	-1,50E+07	27
60	17	9,10	60E	22	10,03	-0,93	9	5,99E+07	4,87E+07	-1,12E+07	19
61	15	8,72	61E	18	9,67	-0,95	10	6,56E+07	5,26E+07	-1,30E+07	20
62	25	9,21	62E	21	9,82	-0,61	6	5,84E+07	5,09E+07	-7,45E+06	13
63	21	9,04	63E	38	10,75	-1,71	16	6,07E+07	4,20E+07	-1,87E+07	31
64	13	8,64	64E	19	9,72	-1,08	11	6,69E+07	5,21E+07	-1,48E+07	22
							Médias	7			15

Capítulo 10

Conclusões e Sugestões Para Futuras Pesquisas

São apresentadas a seguir as principais conclusões obtidas neste trabalho, bem como sugestões para futuras pesquisas, objetivando aprimorar as análises efetuadas e sanar ou ao menos reduzir as deficiências constatadas. O objetivo principal do estudo foi o treinamento de uma rede neural capaz de inferir os valores do módulo de resiliência de solos com base nos parâmetros geotécnicos tradicionais utilizados em projetos de pavimentação. Este objetivo foi alcançado, tendo em vista que foi obtido um preditor capaz de determinar com razoável precisão os valores de M_R , ainda que não no mesmo nível dos ensaios triaxiais de cargas repetidas. A principal vantagem sobre as correlações parciais até agora obtidas é o fato de o preditor inferir sobre um domínio amplo de tipos de solos, ao contrário das correlações correntes, restritas a casos muito particulares e por isso de pouca utilidade prática.

10.1 Conclusões

O estudo desenvolvido demonstrou de forma indiscutível a complexidade do comportamento resiliente dos solos. Isto fica patente ao se observar os resultados da utilização de uma ferramenta como a rede neural artificial, capaz de modelar problemas altamente complexos e que ainda assim apresentou dificuldades na modelagem deste comportamento. Entretanto, as análises efetuadas indicam que estas dificuldades originam-se de aspectos quantitativos e qualitativos da base de dados disponível e não na ferramenta em si, havendo assim possibilidades promissoras de atingir um melhor desempenho mediante o aprimoramento desta base.

Contudo, apesar dessas dificuldades, foi desenvolvida uma rede neural capaz de auferir os valores de M_R a partir dos valores dos seguintes parâmetros geotécnicos dos solos:

- Percentagem de material passante nas peneiras 1", 3/8", n°4, n°10, n°40 e n°200;
- Índice de Plasticidade (IP), considerado como uma variável dummy, ou seja, se o material apresenta alguma plasticidade o valor é 1, se não, o valor é 0;

- Massa Específica Aparente Seca e Umidade Ótima;

Além desses parâmetros, são consideradas pela rede neural como variáveis explicativas as tensões desvio e confinante utilizadas na metodologia da COPPE/UFRJ para execução do ensaio triaxial de cargas repetidas.

As saídas da rede neural são os valores dos módulos de resiliência para cada par de tensões do ensaio, possibilitando desta forma a obtenção dos respectivos valores de deformação específica resiliente e, por regressão linear, os modelos de resiliência de cada amostra, podendo-se optar por aquele que se considerar mais conveniente.

Outras conclusões advindas de todo o estudo elaborado são apresentadas a seguir.

a) Quanto às Correlações

As matrizes de correlação dos ensaios geotécnicos tradicionais e parâmetros de resiliência demonstraram que as constantes experimentais K_i do Modelo Composto apresentam correlações significantes com diversos parâmetros, especialmente as umidade e densidade de moldagem. Quando se considera a deformação específica resiliente, ao invés das constantes citadas, constata-se que esta não apresenta correlação significativa com qualquer dos parâmetros geotécnicos. Isso é um forte indicativo da complexidade das relações entre estas variáveis, concluindo-se que por mais que se busque a obtenção de modelos matemáticos que correlacionem tais parâmetros com o módulo de resiliência por meio de técnicas estatísticas convencionais, o resultado será provavelmente semelhante àqueles que já foram obtidos, ou seja, será circunscrito a casos específicos e muito particulares.

b) Quanto à escolha das variáveis

O processo de escolha das variáveis a serem consideradas na análise demonstrou que os parâmetros relativos aos Limites de Atterberg e aos ensaios de CBR e Expansão apresentam grande dispersão para solos cujo comportamento resiliente é muito similar. Conclusivamente, a inclusão destes parâmetros traz prejuízos à análise, podendo-se considerar que os mesmos não devem ser empregados na modelagem do comportamento resiliente de solos com base nos parâmetros geotécnicos tradicionalmente utilizados em projetos de pavimentação.

c) Quanto ao Agrupamento

O agrupamento em famílias de solos quanto à resiliência mostrou-se particularmente difícil para a base de dados disponível. Foram utilizados dois procedimentos de segmentação, considerando-se no primeiro todos os atributos relativos aos parâmetros geotécnicos tradicionais e as constantes K_i do modelo composto, e no segundo somente estas constantes, admitindo-se que as mesmas refletem de maneira adequada o comportamento resiliente dos solos.

Para definição do melhor agrupamento, o sistema *Weka* utiliza a função *log-likelihood*, sendo o melhor aquele que maximizá-la. Concluiu-se que, por este critério, os agrupamentos feitos considerando todos os parâmetros são mais adequados à base de dados disponível após a depuração efetuada, e que não há grandes diferenças quanto à precisão dos mesmos quando considerados separadamente os dois procedimentos utilizados. Verificou-se que o melhor agrupamento é o gerado pelo algoritmo *K-means*, com quatro grupos, utilizando a base de dados integral. Entretanto, quando se utiliza a totalidade das variáveis, os algoritmos de segmentação alocam amostras de comportamento resiliente em grupos nos quais as constantes K_i refletem comportamento oposto. Constatou-se também que os algoritmos utilizados são incapazes de detectar “ruídos” na base de dados utilizada.

Quando a análise é desenvolvida considerando os parâmetros estatísticos média, desvio padrão e coeficiente de variação, as conclusões são outras. Admitindo a premissa de que o comportamento resiliente dos solos é refletido pelas constantes K_2 e K_3 do modelo composto, conclui-se que o melhor agrupamento é aquele que resulta nos menores coeficientes de variação destas constantes, já que valores mais reduzidos indicam maior similaridade intra-grupo. Concluiu-se que os valores dos coeficientes de variação não permitem definir qual o melhor agrupamento, tendo em vista que tanto valores elevados quanto reduzidos são obtidos em todos eles. As médias destes valores também não permitem definir qual o melhor agrupamento, mas apenas constatar que as segmentações com quatro grupos efetuadas com os algoritmos *EM* e *K-means*, quando utilizadas todos os parâmetros, são os mais heterogêneos.

Os coeficientes de correlação dos parâmetros geotécnicos com as constantes K_i das matrizes geradas para os agrupamentos em famílias de solos quanto à resiliência resultaram muito inferiores àqueles obtidos quando utilizada a base de

dados integral, o que constitui um indício de que o agrupamento em famílias pode não ser adequado para fins de predição.

Os resultados insatisfatórios, e até contraditórios, dos procedimentos de segmentação implementados não permitiram definir qual o melhor agrupamento apenas com base nos resultados dos algoritmos utilizados e na experiência do especialista, deixando patente a complexidade do comportamento resiliente dos solos e a precariedade das tentativas de natureza determinística já realizadas no intuito de obter correlações entre este comportamento e os parâmetros geotécnicos tradicionalmente utilizados em pavimentação.

Outra conclusão importante advinda dos procedimentos de agrupamento é de que a classificação TRB não se aplica adequadamente à resiliência de solos, ocorrendo discrepâncias significativas quando comparados o comportamento resiliente e esta classificação.

d) Quanto à Classificação

Foi obtido um classificador com confiabilidade compatível com projetos de pavimentação, apresentando índice de acerto de 85,5% no conjunto de amostras de validação, utilizando como método de teste a validação cruzada. Contudo, para obter este índice de acerto foi necessário remover aproximadamente 31% das amostras da base de dados original. Deve-se ressaltar que ao se efetuar esta redução pode ter ocorrido perda de informação relevante.

Este resultado é compatível com aqueles obtidos nos procedimentos de agrupamento, já que o desempenho dos classificadores é diretamente proporcional à qualidade da segmentação na qual se baseia. Considerando que os agrupamentos realizados deixaram a desejar, o classificador obtido também não poderia apresentar resultados muito promissores. Contudo, conclui-se que o algoritmo J4.8 é capaz de apresentar bom desempenho para o problema analisado, desde que seja possível produzir um agrupamento adequado das amostras.

e) Quanto às Redes Neurais

Com relação às redes MLP, concluiu-se que o fato de as redes apresentarem excelentes valores em seus parâmetros estatísticos não indica necessariamente bom desempenho das mesmas. Neste caso a grande dificuldade é obter um equilíbrio entre a arquitetura da rede e sua capacidade de generalização. Quanto às redes do

tipo GRNN, os resultados neste aspecto são semelhantes, embora não tão expressivos quanto nas redes MLP, em função de sua arquitetura fixa.

Com relação ao desempenho comparativo das redes dos tipos MLP e GRNN, concluiu-se que o segundo tipo apresenta resultados bem melhores, com erros percentuais médio e máximo significativamente inferiores, sendo a maioria das amostras alocada nas faixas de erro “Baixo” e “Médio”, ocorrendo o inverso nas redes MLP.

Quando se procede à comparação entre as redes treinadas com amostras classificadas em famílias de solos quanto ao comportamento resiliente e aquelas treinadas com a base integral, constata-se que muitas das redes com amostras classificadas apresentam excelente desempenho. Contudo, ao se considerar todo o conjunto de amostras classificadas, os resultados deixam muito a desejar, o que indica que com a base de dados disponível para esse estudo é conveniente adotar a rede treinada com a base integral.

Em relação ao tamanho da base de dados, observou-se uma nítida perda de capacidade de generalização proporcionalmente à redução da mesma, evidenciando a necessidade de prover a rede do maior número possível de amostras. Constatou-se também que o aspecto qualitativo das amostras alocadas para análise é fundamental, tendo em vista que as redes treinadas se mostraram incapazes de lidar com “ruídos” de forma satisfatória.

Os resultados obtidos demonstram que as redes neurais são capazes de inferir de forma adequada os valores do módulo de resiliência com base nos dados de caracterização e compactação dos solos. Isto fica evidente se considerados os erros percentuais médios dos conjuntos de treinamento, teste e validação de muitas delas. Contudo fica clara também a dificuldade de dotar as redes de boa capacidade de generalização, haja vista que nas amostras de validação foram obtidos alguns erros bastante elevados.

f) Quanto à análise dos erros de predição

Concluiu-se que os erros de dimensionamento, resultantes da predição dos valores de M_R pela rede neural, são ainda elevados, em muitas situações, para espessuras reduzidas de revestimento, na faixa de 4,0 a 6,0cm. Para as espessuras de revestimento de 8,0 e 10,0cm, há uma queda substancial nos mesmos, podendo o erro médio ser considerado aceitável para os padrões de projetos de pavimento.

Apesar dos erros constatados, é possível concluir que o preditor dos valores de M_R obtido pode ser utilizado com segurança para elaboração de anteprojetos, e que há possibilidade de desenvolvimento do mesmo para que se atinja o nível de projeto.

10.2 Sugestões para futuras pesquisas

Como sugestões para desenvolvimento de trabalhos futuros nesta linha de pesquisas apresentam-se:

- Aumentar da base de dados, especialmente o número de amostras de comportamento resiliente granular;
- Controlar a qualidade dos dados de parâmetros geotécnicos a serem utilizados;
- Avaliar uma forma eficiente e simples de adicionar aos parâmetros geotécnicos apresentados à rede neural uma característica dos solos que possibilite a distinção dos solos lateríticos;
- A partir de uma base de dados mais volumosa e de melhor qualidade, procurar obter classificadores e redes neurais mais eficientes.
- Utilizar otimizadores de redes neurais de forma a procurar melhorar seu desempenho.
- Utilizar métodos de meta aprendizagem para os classificadores, como *Bagging* e *Boosting*.
- Utilizar algoritmos baseados na técnica *Support Vector Machine*, para desenvolvimento de classificadores lineares.

REFERÊNCIAS BIBLIOGRÁFICAS

AMERICAN ASSOCIATION OF STATE HIGHWAY AND TRANSPORTATION OFFICIALS, *AASHTO Materials, Part 1, Specifications*, Washington, DC, 2003, 767p.

AMERICAN ASSOCIATION OF STATE HIGHWAY AND TRANSPORTATION OFFICIALS, *Guide for Mechanistic-Empirical Design*, Washington, DC, 2002.

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.

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.

BRAGA, A. A., LUDERMIR, T. B., CARVALHO, A.C. P. L. F., 2000, "Redes Neurais Artificiais: Teoria e Aplicações, Livros Técnicos e Científicos Editora S.A., Rio de Janeiro.

DNER-PRO 269/94: Projeto de Restauração de Pavimentos Flexíveis – TECNAPAV, Rio de Janeiro, 1994.

DNER, 1996, "Manual de Pavimentação", IPR/DNER/ABNT Publ. 697, 2ª ed., Rio de Janeiro, RJ, Brasil, 320p.

DNIT, 2005, "Diretrizes Básicas Para Elaboração de Estudos e Projetos Rodoviários – Escopos Básicos / Instruções de Serviço", DNIT/DPP/CGEP/IPR, Publ. 717, 2ª ed., Rio de Janeiro, RJ, Brasil, 489p.

ESPINOSA, V.R.P., 1987, *Ensaio Triaxiais de Carga Repetida de Uma Brita*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

FERREIRA, J. G. H. M. (2002), *Elaboração e análise da base de dados de ensaios triaxiais dinâmicos da COPPE/UFRJ*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

FRANCO, F. A. C. P, 2007, *Método automático de dimensionamento mecanístico-empírico de pavimentos asfálticos*, Tese de D.Sc, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

FURTADO. M. I. V., 1999, *Um estudo sobre predição da qualidade do ar utilizando redes neurais*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

FURTADO, M. I. V., 2004, *Inteligência Competitiva para o Ensino Superior Privado: Uma Abordagem Através da Mineração de textos*, Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

HAN, J. KAMBER, M., 2001, *Data Mining Concepts and Techniques*, San Francisco, Morgan Kaufmann Publishers.

HICKS, R. G., 1970, *Factors Influencing the Resilient Properties of Granular Materials*, Tese de PhD, Universidade da Califórnia, Berkeley.

LOIZOS, A., KARLAFTIS, G. A., KARLAFTIS, M. G., 2005, *A genetically optimized neural networks approach for estimating the moduli of unbound pavement materials*. In: 84th Annual Meeting of the Transportation Research Board, 05-231.pdf, Washington, D.C., Jan.

- 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.
- MACHADO FILHO, O. M., 2002, *Exploração e análise de agrupamento de dados*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- MEDINA, J., 1997, *Mecânica dos Pavimentos*, 1ª. ed. Rio de Janeiro. COPPE/UFRJ.
- MEDINA, J., PREUSLLER, E. S., 1980, “Características resilientes de solos em estudos de pavimentos”, *Solos e Rochas*, vol. 3 , nº. 1.
- MOTTA, L. M. G., ARANOVICH, L. A. S., CERATTI, J. A. P., 1985, “Comportamento Resiliente de Solos utilizados em Pavimentos de Baixo Custo”, *Solos e Rochas*, v.8, n. 3 (Dez), pp. 15-41.
- MOTTA, L. M. G., MEDINA, J., 1988, “Considerações sobre Ensaios de Carga Repetida de Solos e Materiais de Pavimentação”, *Simpósio sobre Novos Conceitos em Ensaios de Campo e Laboratório em Geotecnia*, COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- MOTTA, L. M. G., MEDINA, J., SOUSA, A. M. 2002, “*Características de fadiga e resiliência de concretos asfálticos brasileiros*”, 16º. Encontro de Asfalto, Instituto Brasileiro de Petróleo e Gás - IBP, Rio de Janeiro, RJ, Brasil.
- PINTO, S., 1991, *Estudo do comportamento à fadiga de misturas betuminosas e aplicação na avaliação estrutural de pavimentos*, Tese D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- PINTO, S., PREUSSLER E. S., 1982, “Aplicação do método para projeto de reforço de pavimentos flexíveis considerando a resiliência” – 17ª. RAP – ABPv – Rio de Janeiro, RJ, Brasil.
- PREUSSLER, E. S., 1978, *Ensaio Triaxiais Dinâmicos e um Solo Arenoso*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- REIS, M., FORTES, R. M., 2004, “Repetitividade de medidas de ensaios em corpos-de-prova de misturas asfálticas de microvestimentos asfálticos a frio, utilizando o load wheel tester – LWT” – 35ª. RAPv – ABPV – Rio de Janeiro, RJ, Brasil.
- ROITMAN, V. L., 2001, *Um modelo computacional de redes neurais para predição do índice de desemprego aberto*, Tese D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.
- RODQUER, S. F., 2002, *Aplicação de redes neurais artificiais para previsão de propriedades de solos tropicais*, Tese D.Sc., Escola de Engenharia de São Carlos - EESC, São Carlos, SP, Brasil.
- SILVA, M. A. V., CALÔBA, L. P., VIEIRA, A., 2005, “Utilização de redes neurais artificiais na estimativa do módulo de resiliência de solos brasileiros através de ensaios físicos e mecânicos tradicionais” – 36ª. RAP – ABPV – Curitiba, PR, Brasil.
- SHARIN, M. A., JAKSA, M. B., MAIER, H. R., 2001, *Artificial neural network applications in geotechnical engineering*. Disponível em: www.ecms.adelaide.edu.au/civeng/staff.
- SVENSON, M., 1980, *Ensaio Triaxiais Dinâmicos de Solos Argilosos*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

TAKEDA, M. C., 2006, *A influência da variação da umidade pós-compactação no comportamento mecânico de solos de rodovias do interior paulista*, Tese D.Sc., Escola de Engenharia de São Carlos - EESC, São Carlos, SP, Brasil.

TRANSPORTATION RESEARCH BOARD, 2001, *Modeling techniques in geomechanics*, TBR Committee on Modeling Techniques in Geomechanics. Disponível em: www.gulliver.trb.org/publications.

TRANSPORTATION RESEARCH BOARD, 2007, *86th Annual Meeting*, Washington, DC, EUA.

TURK, G., LOGAR, J., MAJES, B., 2001, *Modeling soil behavior in uniaxial strain conditions by neural networks*, *Advances in Engineering Software*. Disponível em: www.elsevier.com.

UZAN, J., 1985, "Characterization of Granular Material", TRR 1022, Transportation Research Board.

VIANNA, A. A. D., 2002, *Contribuição para o estabelecimento de um material padrão e de metodologia para calibração de equipamentos de ensaios dinâmicos*, Tese de M.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

VISSER, A. T., QUEIROZ C.A.V., HUDSON, W. R., 1981, "Prediction of tropical roadbed resilient modulus from standard material tests", In: *Simpósio Brasileiro de Solos Tropicais*, pp. 615 – 635, COPPE/UFRJ – CNPq – ABMS, Rio de Janeiro, RJ, Brasil.

WARD SYSTEMS GROUP, INC., 1993, *NeuroShell 2*, 2^a. ed. Frederick, MD, USA.

WITTEN, I. H., FRANK, W., 2005, *Data Mining – Practical Machine Learning Tools and Techniques*, 2^a. ed., San Francisco, CA, Morgan Kaufmann Publishers.

REFERÊNCIAS BIBLIOGRÁFICAS CITADAS COMO APUD

ALLEN, J. J., THONPSON, M. R., 1974, "Significance of Variable Confined Triaxial Testing", *Transportation Engineering Journal*, ASCE, vol. 100, n^o. TE-4.

BASHEER, I. A., 1998, "Neuromechanistic-based modeling and simulation of constitutive behavior of fine-grained soils", Tese de Ph. D., Kansas State University, Manhattan, KS, EUA.

BASHEER, I. A., NAJJAR, Y. M. 1998, "Modeling cyclic constitutive behavior by neural networks. Theoretical and real data", *Proc., 12th Engineering Mechanics Conf.*, H. Murakami and J. E. Luco, eds, La Jolla, CA, EUA.

CAL, Y., 1995, "Soil classification by neural network", *Advances in Engineering Software*, 22(2), 95-97.

CYBENKO, G., 1989, "Approximation by superpositions of a sigmoid function", *Mathematics of Control, Signals and Systems*, EUA.

ELLIS, G. W., YAO, C., ZHAO, R., 1992, "Neural network modeling of the mechanical behavior of sand", *Proc., Engineering Mechanics*, ASCE, 421-424.

ELLIS, G. W., YAO, C., ZHAO, R., PENUMABU, D., 1995, "Stress-strain modeling of sands using artificial neural network", J. Geotech. Engrg., ASCE, 121(5), 429-435.

GHABOUSSI, J., SIDARTA, D. E., 1998, "New nested adaptive neural networks (NANN) for constitutive modeling", J. Computers and Geotechnics, 22(1), 29-52.

GOH, A. T. C., 1994, "Nonlinear modeling in geotechnical engineering using neural networks", Australian Civil Engineering Transactions, CE36(4), 293-297.

GOH, A. T. C., 1995, "Modeling soil correlations using neural networks", J. Computing and Civil Engrg, ASCE, 122(1), 70-73.

HEUKELON, W., KLOMP, A. J. G., 1962, "Dynamic testing as a means of controlling pavement during and after construction. Proceedings,1".INTERN. CONF. STRUCTURAL DESIGN OF ASPHALT PAVEMENT, Univ. Michigan, Ann Arbor, EUA.

HVEEN, F. N., 1955, "Pavement deflection and fatigue failures", Bulletin n°. 114, HRB, p.43-87, Washington, DC, EUA.

McCULLOCK, W. S., PITTS, W., 1943, "A logical calculus of the ideas immanent in nervous activity", Bulletin of Mathematical Biophysics, EUA.

PENUMADU, D., JEAN-LOU, C., 1997, "Geomaterial modeling using artificial neural networks", Artificial Neural Networks for Civil Engineering: Fundamentals and Applications, ASCE, 160-184.

PENUMADU, D., ZHAO, R., 1999, "Triaxial compression behavior of sand and gravel using artificial neural networks (ANN)", J. Computers and Geotechnics, 24, 207-230

ROMERO, S., PAMUKCU, S., 1996, "Characterization of granular material by low strain dynamic excitation and ANN", Geotechnical Special Publication, ASTM-ASCE, 58(2), 1134-1148.

WAENY, J. C.C., 1980, "Repetitividade e reprodutividade II, IPT, São Paulo, Brasil.

ZHU, J. H., ZAMAN, M. M., ANDERSON, S. A., 1998a, "Modeling of soil behavior with a recurrent neural network", Canadian Geotech. J., 35(5), 858-872.

ZHU, J. H., ZAMAN, M. M., ANDERSON, S. A., 1998b, "Modeling of shearing behavior of a residual soil whit recurrent neural network", Int. J. Numerical and Analytical Methods in Geomechanics, 22(8), 671-687.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)